Universidad Católica de Santa María

Facultad de Arquitectura e Ingenierías Civil y del Ambiente

Escuela Profesional de Ingeniería Civil

Modelo predictivo basado en técnicas de Machine Learning para optimizar la programación de obras en proyectos de infraestructura vial, Arequipa 2025

Tesis presentada por:

Castillo Molina, Edisson Hugo

ORCID: 0009-0006-2198-4274

Para optar el Título Profesional de Ingeniero Civil

Asesora:

Mg. García Godos Peñaloza, Luz Matilde

ORCID: 0000-0003-0591-2191

Arequipa - Perú

2026

UCSM-ERP

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA CIVIL

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 12 de Octubre del 2026

Dictamen: 016353-C-EPIC-2026

Visto el borrador del expediente 016353, presentado por:

2020227031 - CASTILLO MOLINA EDISSON HUGO

Titulado:

MODELO PREDICTIVO BASADO EN TÉCNICAS DE MACHINE LEARNING PARA OPTIMIZAR LA PROGRAMACIÓN DE OBRAS EN PROYECTOS DE INFRAESTRUCTURA VIAL, AREQUIPA 2025

Nuestro dictamen es:

APROBADO

Titulo Profesional/Titulo de Segunda Especialidad/Grado Académico a optar:

INGENIERO CIVIL

71256920 - TORRES ALMIRON JENIFFER CARLA
DICTAMINADOR

46309156 - MONTOYA VILLANUEVA FILIBERTO RODY
DICTAMINADOR

46890195 - DE LA CRUZ MENDOZA FERNANDO ARON
DICTAMINADOR

Modelo predictivo basado en técnicas de Machine Learning para optimizar la programación de obras en proyectos de infraestructura vial, Arequipa 2025

INFORME DE ORIGINALIDAD

8%	3%	5%	4%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universitat Oberta de Catalunya Trabajo del estudiante	1%
2	repositorio.ucsm.edu.pe Fuente de Internet	1%
3	Submitted to Universidad Católica de Santa María Trabajo del estudiante	1%
4	hdl.handle.net Fuente de Internet	1%
5	Submitted to University of Hertfordshire Trabajo del estudiante	<1%
6	Submitted to Universidad Andina Nestor Caceres Velasquez Trabajo del estudiante	<1%
7	Submitted to University of East London Trabajo del estudiante	<1%
8	cdn.www.gob.pe Fuente de Internet	<1%
9	Flores Arnao, Alodia. "Intención de voto a través de un modelo de análisis de sentimientos en twitter basado en técnicas de Machine Learning", Universidad Nacional del Altiplano de Puno (Peru) Publicación	<1%
10	Salvatierra, Cristhian Alexander Camacho| Reina, José Humberto Reyes. "Proyecto de Optimización financiera en la gestión de recuperación de energía de clientes masivos en el departamento de control de energía de la Corporación Nacional de Electricidad CNEL EP - Unidad de Negocio El Oro, Ecuador.", Escuela Superior Politécnica del Litoral (Ecuador) Publicación	<1%
11	Submitted to Kingston University Trabajo del estudiante	<1%
12	Tarazona Velásquez, Elkin. "Diseño y aplicación piloto de la guía para la gestión de proyectos de diseño de infraestructura física de Data Center para Softtek	<1%

DEDICATORIA

A Dios, cuya memoria es eterna y jamás me ha soltado de su mano. Gracias por ser mi estandarte en cada batalla y por recordarme, con su presencia, que nunca he peleado solo.

A mis padres, Manuel y Luz por ser el reflejo vivo del gran amor y sacrificio que, como grano de trigo, cayó en tierra para dar el fruto que hoy soy. Que el Señor les recompense su labor de amor y su entrega incondicional. A mis hermanos, Michael y Crithian compañeros de sangre que aliviaron mis tiempos de angustia.

A mi abuela Florentina, que desde el cielo alumbra mi camino e irradia de amor los recuerdos que guardo por ella. A mi abuelo Cleofo, que hoy descansa en los brazos del padre, tu vida fue mejor enseñanza y tu memoria es mi mayor corona. A mi abuela Olga, por recordarme en cada momento que soy amado y recordarme que soy el eco de la ternura de Dios.

AGRADECIMIENTOS

Agradezco a Dios sobre todas las cosas, por haberme concedido la fortaleza, la perseverancia y, sobre todo, por no permitir que perdiera la fe y la esperanza de culminar este trabajo y cerrar satisfactoriamente esta importante etapa de mi vida académica.

A mis padres, por su amor, esfuerzo y sacrificio, quienes con su apoyo y voluntad hicieron posible que pudiera estudiar y formarme en esta hermosa carrera. A mis hermanos, por ser una fuente constante de motivación, cariño e inspiración para seguir adelante y superarme cada día, agradecer a mi abuela Florentina que nunca me abandona siempre está a mi lado.

Expreso también mi sincero agradecimiento a los diversos profesionales que, con generosidad y disposición, compartieron sus conocimientos y experiencia técnica durante las distintas etapas de consulta de esta investigación. Asimismo, agradezco el acceso a la información proporcionada por las plataformas de gestión e inversión del Estado peruano, cuyo contenido fue fundamental para el desarrollo y análisis de este estudio. Mi especial reconocimiento a las obras que hicieron posible la aplicación y experimentación del modelo desarrollado, permitiendo contrastar sus resultados y realizar un seguimiento de las obras públicas analizadas.

Finalmente, expreso mi profundo agradecimiento a la Universidad Católica de Santa María, por la formación académica y profesional brindada a lo largo de estos años

A todos ellos, mi más sincero y profundo agradecimiento.

RESUMEN

La programación de obras de infraestructura vial en Arequipa presenta desviaciones superiores al 50% respecto al plazo contractual, evidenciando las limitaciones de los métodos tradicionales frente a la variabilidad e interacciones no lineales entre actividades. La investigación tuvo como objetivo general determinar en qué medida un modelo predictivo basado en técnicas de machine learning optimiza la programación de obra en proyectos de infraestructura vial, Arequipa 2025. El estudio siguió un enfoque cuantitativo, aplicado, de nivel explicativo y diseño no experimental correlacional-predictivo. Se trabajó con una muestra de 10 obras viales ejecutadas y liquidadas entre 2022 y 2025, obtenidas de fuentes oficiales (INFOBRAS, SSI-MEF), que generaron un dataset de 8539 registros de actividades. Se entrenaron y compararon 42 algoritmos de regresión mediante validación cruzada agrupada (GroupKFold); los cinco de mejor desempeño fueron optimizados y combinados en un ensamble mediante Stacking y Voting Regressor. El StackingRegressor (ARDRegression, AdaBoost, Lasso y LassoLars, con metamodelo Ridge) constituyó la solución final, alcanzando sobre el conjunto de prueba (1690 registros) un RMSE de 7.46 días, MAE de 4.90 días, R^2 de 0.8061 y MAPE de 62,1%, con intervalo de confianza bootstrap del RMSE de [6.98; 7.92] días al 95%, superando a los modelos individuales. Su validación en casos de estudio reales evidenció errores porcentuales menores a los del método tradicional PERT. Se concluye que el modelo predictivo optimiza la programación de obras al reducir el error de estimación frente a los métodos convencionales, operando como herramienta complementaria cuya efectividad depende de la disponibilidad y similitud de los datos históricos empleados.

Palabras clave: machine learning, programación de obras, infraestructura vial.

ABSTRACT

Road infrastructure project scheduling in Arequipa shows deviations exceeding 50% relative to contractual deadlines, highlighting the limitations of traditional methods when faced with variability and non-linear interactions between activities. The general objective of this research was to determine the extent to which a predictive model based on machine learning techniques optimizes construction scheduling for road infrastructure projects in Arequipa (2025). The study employed a quantitative, applied approach at an explanatory level, using a non-experimental, correlational-predictive design. The analysis utilized a sample of 10 road projects executed and closed out between 2022 and 2025 sourced from official databases (INFOBRAS, SSI-MEF) generating a dataset of 8539 activity records. Forty-two regression algorithms were trained and compared using GroupKFold cross-validation; the five best-performing algorithms were optimized and combined into an ensemble using Stacking and Voting Regressor techniques. The StackingRegressor (comprising ARDRegression, AdaBoost, Lasso, and LassoLars, with a Ridge metamodel) emerged as the final solution; on the test set (1.690 records), it achieved an RMSE of 7.46 days, MAE of 4.90 days, R^2 of 0.8061, and MAPE of 62.1%, with a 95% bootstrap confidence interval for RMSE of [6.98; 7.92] days, thereby outperforming individual models. Validation against real-world case studies demonstrated lower percentage errors compared to the traditional PERT method. The study concludes that the predictive model optimizes construction scheduling by reducing estimation errors relative to conventional methods, serving as a complementary tool whose effectiveness depends on the availability and similarity of the historical data used.

Keywords: machine learning, construction scheduling, road infrastructure.

ÍNDICE

DEDICATORIA

AGRADECIMIENTOS

RESUMEN

ABSTRACT

INTRODUCCION 1

CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA 2

1.1. Situación problemática 2

1.2. Definición del problema 5

1.3. Formulación del problema 5

1.4. Objetivo general y específicos 6

1.5. Importancia de la investigación 6

1.6. Viabilidad y presupuesto 8

1.7. Alcance y limitaciones 10

CAPÍTULO II: MARCO TEORICO 12

2.1. Antecedentes de la investigación 12

2.2. Bases teóricas 30

2.3. Definición de términos básicos 77

2.4. Formulación de hipótesis 80

CAPITULO III: METODOLOGIA DE LA INVESTIGACION 81

3.1. Diseño metodológico 81

3.2. Población y muestra 83
3.3. Definición de variables 85
3.4. Operacionalización de variables 89
3.5. Técnicas e instrumentos de recolección de datos 90
3.6. Técnicas e instrumentos de procesamiento de datos 93
CAPITULO IV: DESARROLLO 96
4.1. Lugar de la investigación 96
4.2. Obtención de los datos 97
4.3. Obtención de la muestra 99
4.4. Limpieza de datos y preparación de datos 108
4.5. Análisis exploratorio de los datos 114
4.6. Preparación de los datos para el modelamiento 148
4.7. Exploración y Preselección de Modelos Candidatos 161
4.8. Optimización de Hiperparámetros y Construcción del Ensamble (Fine-tune) 178
4.9. Evaluación final de la solución 196
4.10. Síntesis del Desarrollo Experimental 206
CAPITULO V: RESULTADOS 210
5.1. Comportamiento de obras de infraestructura vial en Arequipa 2022-2025 210
5.2. Modelo de interfaz web 214
5.3. Caso de estudio 218
5.4. Evaluación del modelo predictivo 220

CAPITULO VI: DISCUSIÓN 262

6.1. Respecto a los objetivos específicos 262

6.2. Respecto al objetivo general 270

CONCLUSIÓN 273

RECOMENDACIONES 275

REFERENCIAS 276

ANEXOS 282

ÍNDICE DE TABLAS

Tabla 1: Antecedes directamente relacionados con la duración de actividades. 25
Tabla 2: Antecedentes metodológicos y su uso en la tesis. 29
Tabla 3: Tipos de relación de precedencia.....42
Tabla 4: Operacionalización de las variables 89
Tabla 5: Contenido de la matriz base de datos históricos.....92
Tabla 6: Documentación exigida, verificación y causal de exclusión.....102
Tabla 7: Sesgos derivados de seleccionar la muestra. 104
Tabla 8: Obras representativas seleccionadas para el entrenamiento del modelo. 106
Tabla 9: Numero de registros para dataset.....107
Tabla 10: Tabla de asignación de códigos por una misma denominación.....110
Tabla 11: Tabla de variables para el modelo de machine learning.....112
Tabla 12: Ejemplo de la estructuración de la información. 113
Tabla 13: Tipos de datos según su formato. 118
Tabla 14: Tabla de estadística descriptiva. 119
Tabla 15: Numero de filas por obra. 122
Tabla 16: Estadística del target por grupo. 139
Tabla 17: Estadística de DURACION_TOTAL_DIAS.....141
Tabla 18: Detección de outliers. 143
Tabla 19: Variables derivadas creadas en la ingeniería de características. 151
Tabla 20: Predictores utilizados en el entrenamiento (15 variables) 154
Tabla 21: Variables excluidas y variable objetivo.....156
Tabla 22: Resultado de la partición de datos. 161
Tabla 23: Catálogo de modelos de regresión evaluados, por grupo. 163
Tabla 24: Resultados comparativos de validación cruzada GroupKFold 42 modelos. 172
Tabla 25: Modelos preseleccionados top 5 por R^2.....177
Tabla 26: Mejores hiperparámetros para AdaBoost (RandomizedSearchCV). 180
Tabla 27: Análisis Residual del modelo A08_ARDRegression. 193
Tabla 28: Desempeño de los modelos de ensamble en el conjunto de prueba. 196
Tabla 29: Evaluación final comparativa en el conjunto de prueba (test set). 198
Tabla 30: Intervalo de confianza bootstrap del RMSE (modelo final, 95 %) 204
Tabla 31: Desempeño del modelo final por rango de duración de la partida 205
Tabla 32: Controles de fuga en el procesamiento de datos.....208
Tabla 33: Obras escogidas para el análisis. 219
Tabla 34: Tipología de caso de estudio. 220
Tabla 35: Tabla de comparación de Duración "169730".....222
Tabla 36: Tabla de comparación de Duración "169592".....223
Tabla 37: Tabla de comparación de Duración "500532".....226
Tabla 38: Tabla de error (%).....226
Tabla 39: Obras en la que se probó el modelo.....227
Tabla 40: Comparación de Duración "559764".....228
Tabla 41: Tabla de comparación de Duración "557503".....230
Tabla 42: Comparación de errores PERT y ML obra "169730".....231
Tabla 43: Comparación de errores PERT y ML obra " 169592".....237
Tabla 44: Comparación de errores PERT y ML obra "500532".....242

Tabla 45: Comparación de errores PERT y ML obra "559764".....245
Tabla 46: Comparación de errores PERT y ML obra "557503".....246
Tabla 47: Estadísticos descriptivos de la obra "169730".....247
Tabla 48: Pruebas de normalidad de la obra "169730". 248
Tabla 49: Estadísticos de Prueba Wilcoxon "169730". 249
Tabla 50: Comparación de resultados obra"169730". 249
Tabla 51: Estadísticos descriptivos de la obra "169592".....250
Tabla 52: Pruebas de normalidad de la obra "169592". 250
Tabla 53: Estadísticos de Prueba Wilcoxon "169592". 251
Tabla 54: Comparación de resultados obra"169592". 252
Tabla 55: Estadísticos descriptivos de la obra "500532".....252
Tabla 56: Pruebas de normalidad de la obra "500532". 253
Tabla 57: Estadísticos de Prueba Wilcoxon "500532". 254
Tabla 58: Comparación de resultados obra"500532". 254
Tabla 59: Estadísticos descriptivos de la obra "559764".....255
Tabla 60: Pruebas de normalidad de la obra "559764". 255
Tabla 61: Estadísticos de Prueba Wilcoxon "559764". 256
Tabla 62: Comparación de resultados obra"559764". 257
Tabla 63: Estadísticos descriptivos de la obra "557503".....257
Tabla 64: Pruebas de normalidad de la obra "557503". 258
Tabla 65: Estadísticos de Prueba Wilcoxon "557503". 259
Tabla 66: Comparación de resultados obra"557503". 259
Tabla 67: Tabla resumen de errores por obra. 260
Tabla 68: Desempeño R^2 265
Tabla 69: Error medio del análisis estadístico. 267
Tabla 70: Comparación entre esta tesis y los antecedentes. 271

ÍNDICE DE FIGURAS

Figura 1: Mapa Vial de Arequipa. 83
Figura 2: Diagrama de flujo - Esquema Metodológico. 95
Figura 3: Mapa de la ubicación de obras de infraestructura vial en Arequipa. 96
Figura 4: Sistema de búsqueda en INFOBRAS 97
Figura 5: Representación gráfica del estado de obras viales en Arequipa 2022 - 2025 98
Figura 6: Diagrama de flujo de selección de muestra 105
Figura 7: Cantidad de registros por obra. 123
Figura 8: Porción por Obra. 123
Figura 9: Histograma de ID_PARTIDA de media y la mediana. 125
Figura 10: Histograma de NUMERO_DE_PARTIDA_(MS_PROJECT). 125
Figura 11: Histograma de PREDECESORAS 126
Figura 12: Histograma de METRADO_TOTAL. 126
Figura 13: Histograma de RENDIMIENTO. 127
Figura 14: Histograma de DURACION_TOTAL_DIAS. 127
Figura 15: Histograma DIA_TRABAJADO. 128
Figura 16: Histograma METRADO_DIARIO 128
Figura 17: Histograma de METRADO_ACOMULADO. 129
Figura 18: Histograma de ES_PRIMER_DIA. 129
Figura 19: Histograma de ES_ULTIMO_DIA. 130
Figura 20: Histograma de PORCENTAJE_COMPLETADO. 130
Figura 21: Histograma de DURACION_ACOMULADA_DEL_TOTAL_DE_OBRA. 131
Figura 22: Matriz de correlación. 133
Figura 23: Correlación de target con feactures. 134
Figura 24: METRADO_TOTAL VS DURACION_TOTAL_DIAS 135
Figura 25: RENDIMIENTO VS DURACION_TOTAL_DIAS. 135
Figura 26: DIA_TRABAJADO VS DURACION_TOTAL_DIAS. 136
Figura 27: METRADO_ACOMULADO VS DURACION_TOTAL_DIAS. 136
Figura 28: Gráfico caja del target (DURACION_TOTAL_DIAS). 138
Figura 29: Grafico violín del target (DURACION_TOTAL_DIAS). 138
Figura 30: Distribución de log(DURACION_TOTAL_DIAS) 140
Figura 31: Q-Q Plot (Normal). 141
Figura 32: Frecuencias de CODIGO_PARTIDA. 144
Figura 33: Frecuencia de DESCRIPCION_PARTIDA. 144
Figura 34: Diagrama de comportamiento de validación cruzada. 166
Figura 35: Comparación de modelos R2. 174
Figura 36: Comparación de modelos RMSE. 175
Figura 37: Heatmap de todas las métricas normalizadas por modelo. 176
Figura 38: Learning Curve - F01_AdaBoost 182
Figura 39: Learning Curve - A08_ARDRegression 183
Figura 40: Learning Curve - A03_Lasso 183
Figura 41: Learning Curve - A06_LassoLars 184
Figura 42: Learning Curve - A01_LinearRegression 184
Figura 43: Permutation Importance del mejor modelo. 186
Figura 44: Feature Importance - F01_AdaBoost 188

Figura 45: Residuos vs predicciones - A08_ARDRegression. 190
Figura 46: Distribución de Residuos - A08_ARDRegression. 190
Figura 47: Q-Q Plot de Residuos - A08_ARDRegression. 191
Figura 48: Grafico de Predicciones vs Valores Reales - J01_stackingEnsemble 200
Figura 49: Distribución de errores - J01_stackingEnsemble. 200
Figura 50: Residuos vs predicciones J01_stackingEnsemble 201
Figura 51: Distribución de residuos J01_stackingEnsemble 201
Figura 52: Q-Q J01_stackingEnsemble 202
Figura 53: Diagrama de flujo del modelo de machine learning. 209
Figura 54: Histograma y polígono de desviación y plazo contractual. 210
Figura 55: Histograma de desviación porcentual y monto de ejecución planificada. 211
Figura 56: Desviación porcentual por el sistema de contrata. 212
Figura 57: Estado del censo poblacional y desvió porcentual. 213
Figura 58: Interfaz de entrada de la WEB 215
Figura 59: Interfaz de entrenamiento de datos. 215
Figura 60: Interfaz de elección modelo y tamaño de datos. 216
Figura 61: Interfaz de ingeniería de caracterización. 217
Figura 62: Interfaz para predecir. 218
Figura 63: Obra "169730", predicción de la duración de actividades. 221
Figura 64: Obra "169592", predicción de la duración de actividades. 223
Figura 65: Obra " 500532", predicción de la duración de actividades. 225
Figura 66: Datos de ejecución "559764". 227
Figura 67: Obra "559764"predicción de la duración de actividades. 228
Figura 68: Cronograma de las partidas en ejecución "559764". 229
Figura 69: Datos de ejecución "557503". 229
Figura 70: Obra "557503"predicción de la duración de actividades. 229
Figura 71: Cronograma de las partidas en ejecución "559764". 231
Figura 72: Validación agrupada por obra frente a prueba aleatoria 265

ÍNDICE DE ANEXOS

ANEXOS 1: Vista para verificar mi modelo “559764”. 282
ANEXOS 2: Vista para verificar mi modelo “557503”. 283
ANEXOS 3: Panel fotográfico "559764" 284
ANEXOS 4: Panel fotografico"557503" 288
ANEXO 5: Matriz de Consistencia. 294
ANEXO 6: Obras finalizadas periodo 2022-2025 Arequipa. 295
ANEXO 7: Tabla de agrupación de partidas de cartel CR-001 318
ANEXO 8: Tabla agrupación de partidas de cerco perimétrico CP-001 318
ANEXO 9: Tabla de agrupación de partidas de movilización MD-001 318
ANEXO 10: Tabla de agrupación de partidas de limpieza LT-001 319
ANEXO 11: Tabla de agrupación de partidas de transporte TP-001 319
ANEXO 12: Tabla de agrupación de partidas de demolición DL-001 320
ANEXO 13: Tabla de agrupación de partidas de trazo y replanteo TR-001 321
ANEXO 14: Tabla de agrupación de partidas de eliminación EM-001 322
ANEXO 15: Tabla de agrupación de partidas de acarreo AC-001 322
ANEXO 16: Tabla de agrupación de partidas de curado CD-001 323
ANEXO 17: Tabla de agrupación de partidas de corte CT-003 324
ANEXO 18: Tabla de agrupación de partidas de junta JT-001 325
ANEXO 19: Tabla de agrupación de partidas de relleno RL-001 326
ANEXO 20: Tabla de agrupación de partidas acero FY-001 327
ANEXO 21: Tabla de agrupamiento de partidas de encofrado y desencofrado ED-001 328
ANEXO 22: Tabla de agrupación de partidas de excavación EX-001 330
ANEXO 23: Tabla de agrupación de partidas de perfilado y compactación PC-001 332
ANEXO 24: Tabla de agrupación de partidas de pintado PP-001 334
ANEXO 25: Tabla de agrupación de partidas de señales de tránsito SL-001 335
ANEXO 26: Tabla de agrupación de cama de adoquín AR-001 337
ANEXO 27: Tabla de agrupación de partidas de baranda metálica BM-001 337
ANEXO 28: Tabla de agrupación de partidas de base BS-001 338
ANEXO 29: Tabla de agrupación de partidas de carpeta asfáltica AS-001 339
ANEXO 30: Tabla de agrupación de partidas de concreto CN-XXX 340
ANEXO 31: Tabla de agrupación de partidas de adoquín AQ-001 344
ANEXO 32: Tabla de agrupación de partidas de imprimación IM-001 345
ANEXO 33: Tabla de agrupación de partidas de sanitarias SR-001 345
ANEXO 34: Tabla de agrupación de partidas de tarrajeo RR-001 347
ANEXO 35: Tabla de agrupación de partidas de acabados de concreto AB-001 348
ANEXO 36: Tabla de agrupación de partidas de sembrado SM-001 349
ANEXO 37: Tabla de agrupación de partidas de riego RO-001 350
ANEXO 38: Tabla de agrupación de partidas de arenado para pavimento flexible AI-002 350
ANEXO 39: Tabla de agrupación de partidas de Barrido BR-084 350
ANEXO 40: Tabla de agrupación de partidas de sellado de arena SQ-001 351
ANEXO 41: Tabla de agrupación de partidas de varios VS-001 351
ANEXO 42: Tabla de agrupación de partidas de cama de arena para tuberías CM-001 352

INTRODUCCION

La programación de obras es uno de los procesos más críticos en la gestión de proyectos de infraestructura vial, ya que de su precisión dependen el cumplimiento de plazos, presupuestos y calidad. A nivel internacional, la planificación sigue dependiendo del juicio experto y de métodos determinísticos, lo que genera subjetividad y estimaciones inexactas frente a la variabilidad e interacciones no lineales entre actividades. En el Perú, y particularmente en Arequipa, esta problemática se agrava: los cronogramas de obras viales no se cumplen debido a estimaciones poco realistas, generando sobrecostos, paralizaciones y desconfianza en la gestión pública.

Ante ello, surge la necesidad de explorar métodos alternativos capaces de aprender de la información histórica disponible en plataformas oficiales del Estado (INFOBRAS, SSI) para generar estimaciones más precisas que las de los enfoques convencionales. En este marco, la presente investigación tiene como objetivo general determinar en qué medida un modelo predictivo basado en técnicas de machine learning optimiza la programación de obra en proyectos de infraestructura vial, Arequipa 2025.

Para ello, se empleó un enfoque cuantitativo, aplicado, de nivel explicativo y diseño no experimental correlacional-predictivo, sobre una muestra de diez obras viales ejecutadas en Arequipa (2022-2025), a partir de las cuales se construyó un dataset de 8539 registros de actividades. Con esta base se entrenaron, compararon y optimizaron múltiples algoritmos de regresión, integrados en un modelo de ensamble cuyo desempeño fue validado mediante métricas estadísticas y casos de estudio reales contrastados con el método tradicional PERT.

El informe se organiza en seis capítulos: planteamiento del problema, marco teórico, metodología, desarrollo del modelo predictivo, resultados y discusión, culminando con las conclusiones y recomendaciones del estudio.

CAPÍTULO I:

PLANTEAMIENTO DEL PROBLEMA

1. Planteamiento del problema

1.1. Situación problemática

A nivel Internacional, la programación de obras continúa realizándose de forma manual, dependiendo en gran medida de la experiencia y el juicio de unos pocos profesionales, lo que genera subjetividad y falta de estandarización en los procesos de planificación. Esta dependencia de la intuición humana provoca que los cronogramas sean lentos, costosos, propensos a errores y, en muchos casos, incapaces de adaptarse a la variabilidad entre distintos proyectos o tipos de actividades. En consecuencia, las empresas constructoras pierden eficiencia, repiten errores de planificación y no logran garantizar la optimización ni la coherencia de sus planes de trabajo. Esta situación pone en manifiesto la necesidad de contar con métodos automatizados y escalables que puedan aprender, generalizar y reutilizar el conocimiento de planificación y una secuencia de actividades a partir de datos históricos. (Amer & Golparvar-Fard, 2021)

La falta de aprovechamiento de la información almacenada en los proyectos anteriores impide comprender las causas reales de retrasos y limita la precisión de cronogramas (Awada et al., 2021). Asimismo, las disputas en la industria de la construcción producto de conflictos de percepción, cambios imprevistos, retrasos y fallas en la comunicación siguen siendo frecuentes y costosas, afectando directamente a contratistas, propietarios y gerentes de proyectos (Ayhan et al., 2021). Estas disputas suelen gestionarse con base en la experiencia subjetiva, lo que incrementa el riesgo de decisiones erróneas y resultados ineficientes.

Las metodologías tradicionales de planificación no logran capturar la complejidad las interrelaciones de factores que inciden en retrasos. En la práctica, los gerentes de proyecto

continúan utilizando aproximaciones cualitativas o empíricas, que conllevan estimaciones inexactas de plazos (Banerjee, 2021). Esto se traduce en sobrecostos, disminución de la calidad final de las obras y pérdida de competitividad en las organizaciones (Fan, 2025). En países como el Reino Unido, más del 50% de los proyectos terminan fuera del plazo previsto debido a estimaciones subjetivas de riesgo temporal y a la falta de análisis de datos empíricos (Fitzsimmons et al., 2022). A escala global, cerca del 90% de los proyectos de gran envergadura presentan demoras significativas, lo que ocasiona conflictos legales, pérdidas económicas y riesgo de quiebra para las empresas (Liu & Luo, 2026).

Diversos autores coinciden que la raíz del problema está en la dependencia de métodos tradicionales y en la dificultad para predecir con precisión la duración total de los proyectos, ya que estos enfoques no consideran adecuadamente los riesgos, la variabilidad de los datos ni las interacciones no lineales entre actividades. (Lotfi et al., 2025)

Además, los planificadores deben actualizar constantemente los cronogramas bajo presión de tiempo, sacrificando la calidad de la planificación y afectando la confiabilidad del control del proyecto (Jung et al., 2022). En entornos con alta incertidumbre, por ejemplo, condiciones climáticas adversas o interrupciones en la cadena de suministro, los métodos convencionales se vuelven insuficientes para garantizar estimaciones realistas (Seyisoglu et al., 2025).

En el contexto peruano, esta problemática se refleja con particular gravedad en el sector de infraestructura vial. En la mayoría de los proyectos del sur del Perú, los cronogramas elaborados en la etapa de planificación no se cumplen debido a la falta de estimaciones realistas sobre la gestión de riesgos, la gestión de calidad, la variabilidad geográfica y climática, los retrasos en la provisión de recursos y los conflictos contractuales.

Según la Federación Panamericana de Consultores (2023) realizaron un estudio a 427 proyectos de construcción, se obtuvo que los retrasos varian entre 6 y 24 meses, lo que representa un promedio del 52% respecto al cronograma inicial.

De acuerdo con el informe de obras públicas paralizadas en territorio nacional de Contraloría del 2022 a 2025 menciona que el Ministerio de Transportes y Comunicaciones MTC registra 742 obras paralizadas, de las cuales un 25.5% están relacionadas con el incumplimiento de plazos, lo que directamente se entiende como un retrasó para el cronograma planificado.

El Estado peruano, a través del Ministerio de Transportes y Comunicaciones, ha destinado más de 400 millones de soles para destrabar proyectos y cumplir con los plazos establecidos. Sin embargo, los retrasos persisten, evidenciando que los métodos tradicionales no son suficientes.

El Plan Nacional de Infraestructura para la Competitividad (PNIC) plantea el compromiso del Estado de diseñar proyectos que atiendan a la mayor cantidad de ciudadanos y que además se ejecuten dentro de los plazos previstos, con transparencia y honestidad. El gran reto del PNIC es lograr que dichos proyectos se desarrollen cumpliendo estrictamente los cronogramas y presupuestos establecidos. Asimismo, el plan reconoce la necesidad de introducir nuevas metodologías para la programación de cronogramas y presupuestos, con el objetivo de garantizar su cumplimiento y evitar la desconfianza de la población hacia la gestión pública.

En este escenario, las obras de infraestructura vial en el Perú presentan una alta incidencia de incumplimiento de plazos debido a una inadecuada percepción del tiempo reflejada en los cronogramas elaborados durante la etapa de planificación. Esto genera mayores costos, desconfianza social y pérdida de eficiencia en la gestión pública.

Sin embargo, la gestión de riesgos en el país, basada en el enfoque PMBOK, aún no logra mitigar adecuadamente los retrasos, además se advierte que los riesgos no identificados en las etapas preliminares se traducen posteriormente en perjuicios técnicos, económicos y sociales (Bedregal Yabarrena et al., 2025).

1.2. Definición del problema

Surge la necesidad de desarrollar un modelo predictivo que, mediante el uso de técnicas de machine learning, sea capaz de aprovechar los datos históricos de proyectos para estimar de manera más precisa los tiempos de ejecución y optimizar la programación de cronogramas en la etapa de planificación. Este enfoque busca superar las limitaciones de los métodos tradicionales, reducir las desviaciones temporales y mejorar la toma de decisiones en la gestión de obras de infraestructura vial en Arequipa.

1.3. Formulación del problema

1.3.1. Formulación del problema general

¿En qué medida el modelo predictivo basado en técnicas de machine learning Optimiza la programación de obras de infraestructura vial en Arequipa 2025?

1.3.2. Formulación de problemas específicos

PE.1 ¿Cuáles son los factores y variables de proyectos de infraestructura vial que afectan la programación de obras de infraestructura vial, Arequipa 2025?

PE.2 ¿Cómo diseñar y entrenar un modelo predictivo con técnicas de machine learning, que permita Optimizar la programación de obras de infraestructura vial, Arequipa 2025?

PE.3 ¿Cómo evaluar el desempeño del modelo predictivo desarrollando su confiabilidad frente a métodos tradicionales en la programación de obras de infraestructura vial, Arequipa 2025?

PE.4 ¿En qué medida la implementación de modelo predictivo basado en machine learning optimiza la programación de obras y disminución de la desviación de plazos?

1.4. Objetivo general y específicos

1.4.1. Objetivo general

Determinar en qué medida el modelo predictivo basado en técnicas de Machine Learning optimiza la programación de obra en proyectos de infraestructura vial, Arequipa 2025.

1.4.2. Objetivos específicos

OE.1 Identificar los factores y variables de proyectos de infraestructura vial que afectan la programación de obras de infraestructura vial, Arequipa 2025.

OE.2 Diseñar y entrenar un modelo predictivo en técnicas de machine learning, que permita optimizar la programación de obras de infraestructura vial, Arequipa 2025.

OE.3 Evaluar el desempeño del modelo predictivo desarrollado y su confiabilidad frente a métodos tradicionales de programación de obra de infraestructura vial, Arequipa 2025

OE.4 Determinar en qué medida la implementación del modelo predictivo basado en machine learning optimiza la programación de obras y disminución de la desviación de plazos.

1.5. Importancia de la investigación

Para el trabajo de investigación, poder explicar el por qué se decide escoger el tema al igual que las variables que influyen, son el eje principal de esta misma, por lo que se especifica en diferentes temas de la siguiente manera:

- ***Importancia técnica:*** La presente investigación es técnicamente relevante porque propone la incorporación de técnicas de machine learning en la programación de cronogramas de obra, lo que representa un avance significativo frente a los métodos

tradicionales de planificación basados en el juicio experto o en herramientas determinísticas. El modelo predictivo permitirá procesar grandes volúmenes de datos históricos para identificar patrones y relaciones ocultas entre variables, generando estimaciones más precisas del tiempo de ejecución. Esta innovación técnica contribuirá al fortalecimiento de la ingeniería de la construcción en el Perú, impulsando la adopción de tecnologías propias de la Construcción 4.0, que promueven la digitalización, automatización y optimización de los procesos constructivos.

- ***Importancia económica:*** Desde el punto de vista económico, la investigación permitirá reducir los sobrecostos generados por retrasos en la ejecución de obras de infraestructura vial, los cuales representan una pérdida significativa de recursos públicos y privados. Al mejorar la precisión del cronograma durante la etapa de planificación, se optimizará el uso del presupuesto asignado y se disminuirán los gastos asociados con ampliaciones de plazo, penalidades y paralizaciones. De esta manera, el modelo predictivo contribuirá a una gestión más eficiente del gasto en el sector construcción, incrementando la productividad y la competitividad de las empresas contratistas y consultoras, así como el aprovechamiento racional de los recursos del Estado.

- ***Importancia social:*** La investigación tiene una gran relevancia social, ya que la mejora de la planificación y cumplimiento de los cronogramas, impactara directamente en el beneficio de la población. Una programación más precisa y eficiente permitirá que las carreteras, puentes y vías sean entregadas en los plazos establecidos, favoreciendo la conectividad, el acceso a servicios básicos y el desarrollo regional. Además, la reducción de obras paralizadas y conflictos contractuales fortalecerá la confianza de la ciudadanía en las instituciones públicas y contribuirá al cumplimiento del Objetivo de

Desarrollo Sostenible N.º 9 (Industria, innovación e infraestructura), promoviendo un desarrollo más equitativo y sostenible en Arequipa.

- ***Importancia medioambiental:*** En el aspecto medioambiental, una planificación más eficiente mediante machine learning permite optimizar el uso de recursos materiales, humanos y energéticos, evitando desperdicios asociados a reprogramaciones, sobretiempos o uso ineficiente de maquinaria. Al disminuir los retrasos y la necesidad de trabajos correctivos, se reducen también las emisiones de gases contaminantes y el impacto ambiental durante la ejecución de las obras. De esta forma, la aplicación de herramientas predictivas contribuye indirectamente a una gestión de proyectos más sostenible y alineada con los principios de construcción responsable y eficiencia en el uso de los recursos naturales.

1.6. Viabilidad y presupuesto

La investigación resultó factible gracias a la disponibilidad de información en los portales oficiales peruanos InfObrás (Sistema de Información de Obras Públicas) y SSI (Sistema de Seguimiento de Inversiones), los cuales proporcionan acceso público y gratuito a datos relevantes sobre proyectos de inversión. Este acceso está garantizado por la Ley de Transparencia y Acceso a la Información Pública (Ley N.º 27806), que promueve la difusión y libre consulta de información relacionada con la gestión estatal y la ejecución de obras públicas.

- ***Viabilidad técnica:*** La investigación es técnicamente viable, ya que se cuenta con la disponibilidad de herramientas computacionales y entornos de programación que permiten implementar modelos de machine learning, tales como Python, junto con bibliotecas especializadas como Scikit-learn, TensorFlow o PyTorch. Además, existen fuentes de datos accesibles y

verificables provenientes de plataformas oficiales del Estado peruano, como el portal InfObras (Contraloría General de la República) y el Sistema de Seguimiento de Inversiones (SSI) del Ministerio de Economía y Finanzas, que contienen información histórica sobre plazos, presupuestos, estados de avance y características técnicas de las obras. La combinación de estos recursos garantiza la factibilidad de recopilar, procesar y modelar los datos necesarios para entrenar y validar el modelo predictivo propuesto, asegurando la solidez técnica del estudio.

- ***Viabilidad social:*** La investigación presenta una alta viabilidad social, puesto que aborda un problema que afecta directamente a la ciudadanía, los retrasos y paralizaciones de obras públicas de infraestructura vial. La propuesta tiene el potencial de mejorar la eficiencia en la planificación y ejecución de proyectos, promoviendo una gestión pública más transparente y confiable. Además, los resultados del estudio beneficiarán a diversos actores sociales desde autoridades locales y regionales hasta empresas constructoras y comunidades usuarias al contribuir a la entrega oportuna de obras que impulsan la conectividad, el desarrollo económico y la calidad de vida en Arequipa. La aceptación social del uso de tecnologías de inteligencia artificial en la administración pública también refuerza su viabilidad y pertinencia en el contexto actual de transformación digital.

- ***Viabilidad económica:*** La viabilidad económica de la investigación es favorable, ya que el desarrollo del modelo predictivo no requiere inversiones elevadas en infraestructura física, sino principalmente recursos informáticos y de análisis de datos, de bajo costo en comparación con los beneficios que puede generar. Las herramientas de programación utilizadas son en su mayoría de

código abierto y gratuitas, lo que reduce los gastos operativos. Asimismo, la implementación de un modelo de machine learning permitirá a futuro optimizar la asignación de presupuestos, reducir sobrecostos por ampliaciones de plazo y evitar pérdidas derivadas de retrasos o paralizaciones. En términos globales, la relación costo–beneficio del proyecto es positiva, ya que la inversión en el desarrollo metodológico se traduce en una mejora significativa en la eficiencia económica y la gestión de recursos del sector construcción.

1.7. Alcance y limitaciones

1.7.1. Alcance

Delimitar los puntos de investigación y entender hasta donde investigar:

a) El ámbito geográfico de la investigación corresponde a la región de Arequipa.

b) Se seleccionará obras de infraestructura vehicular que hayan sido ejecutadas por la modalidad de contrata que cumplan con lo siguiente:

- Obras concluidas en el periodo 2022-2025.
- Que cuenten con un cronograma contractual inicial y cronograma valorizado actualizado, con su programación en la etapa de planificación y que estén definidas sus actividades de precedencia.
- Su modalidad de ejecución puede ser de suma alzada o precios unitarios.

c) Se desarrollará un modelo de Machine Learning orientado a estimar la duración de las actividades de ejecución de obras viales.

1.7.2. Limitaciones

Disponibilidad de información: limitada por la calidad, completitud y consistencia de los registros históricos de las obras viales.

Representatividad de los datos: el modelo se basa en obras de infraestructura vial de Arequipa, por lo que sus resultados no necesariamente son generalizables a otras regiones.

Variables disponibles: la predicción está condicionada por las variables registradas en las fuentes consultadas, sin incorporar factores difíciles de cuantificar, como clima, conflictos sociales o desempeño del personal.

Calidad de los registros: pueden existir diferencias entre los plazos contractuales, planificados y reales debido a modificaciones, ampliaciones de plazo o registros administrativos.

Aplicación del modelo: el modelo predictivo complementa, pero no reemplaza, los métodos tradicionales de programación de obra.

CAPÍTULO II:

MARCO TEORICO

2. Marco teórico

2.1. Antecedentes de la investigación

2.1.1. Antecedentes internacionales

En Estado Unidos, segun Amer y Golparvar-Fard en 2021 escribieron su artículo científico “Modelado de plantillas de trabajo de construcción dinámica a partir de registros de programación existentes mediante aprendizaje automático secuencial”, El estudio tuvo como objetivo automatizar el aprendizaje del conocimiento de planificación y programación de proyectos de construcción, aprovechando cronogramas históricos para crear plantillas dinámicas de procesos (Dynamic Process Templates, DPTs) que pudieran capturar la lógica y secuencia de actividades sin depender del trabajo manual de los planificadores. Para lograrlo, los autores recopilaron 32 cronogramas reales de obras que contenían más de 78000 actividades, y aplicaron un enfoque de aprendizaje automático secuencial, utilizando redes neuronales recurrentes con memoria a largo y corto plazo (LSTM-RNN) combinadas con procesamiento de lenguaje natural (NLP) para analizar descripciones textuales de las actividades y sus dependencias. Los resultados demostraron que el modelo fue capaz de aprender patrones de planificación con altos niveles de precisión (entre 76% y 98%), mostrando robustez frente a variaciones lingüísticas y capacidad para predecir actividades sucesoras y predecesoras en distintos tipos de proyectos.

En Estados Unidos, según Hriday y Rehman en 2025 el artículo científico “Aplicaciones de inteligencia artificial y aprendizaje automático en la gestión de proyectos de construcción: mejora de la programación, la estimación de costes y la mitigación de riesgos”, El estudio tuvo como objetivo cuantificar la relación entre la adopción de la inteligencia

artificial y el aprendizaje automático (AI y ML) y el desempeño de proyectos de construcción en tres áreas clave: adherencia al cronograma, precisión en la estimación de costos y efectividad en la mitigación de riesgos. Para ello, los autores aplicaron una metodología cuantitativa, transversal y multicaso, utilizando una muestra de 102 proyectos de construcción pertenecientes a distintas empresas y sectores, los cuales cumplían criterios de integridad de datos y registros de riesgos verificables. Se construyó un Índice de Adopción de AI y ML (0 a 100) que medía el alcance, frecuencia de uso, sofisticación de los modelos y profundidad de integración con sistemas BIM, ERP y de planificación. Las variables dependientes fueron el porcentaje de retraso en el cronograma, el sobrecosto, la tasa de detección de riesgos y el impacto residual del riesgo. Los resultados mostraron que un aumento de 10 puntos en el índice de adopción se asocia con una reducción aproximada de 1.2 puntos porcentuales en retrasos, 0.9 puntos en sobrecostos, un incremento del 0.04 en la tasa de detección de riesgos y una disminución de 0.06 en la severidad del riesgo residual, siendo los efectos más fuertes en proyectos de mayor complejidad. En conclusión, la investigación evidenció que la integración profunda y frecuente de herramientas de Inteligencia Artificial con Machine Learning en la gestión de proyectos de construcción mejora significativamente el control del tiempo, los costos y los riesgos.

En Estados Unidos, según Jung, Amer y Golparvar-Fard en 2022 “Viabilidad de un enfoque integrado de aprendizaje automático y heurístico para el monitoreo del estado del cronograma en la construcción”, El estudio tiene como objetivo evaluar la viabilidad de un enfoque integrado basado en heurísticas y métodos de aprendizaje automático para analizar la calidad o “salud” de los cronogramas de construcción, buscando superar las limitaciones de los métodos tradicionales que dependen de criterios fijos y juicios subjetivos. Para ello, los autores emplearon una metodología mixta, que combina las reglas heurísticas del modelo de evaluación de la Agencia de Gestión de Contratos de Defensa (DCMA) de 14 puntos con técnicas de

aprendizaje profundo y procesamiento de lenguaje natural (NLP). Su muestra incluyó 35 proyectos reales de construcción (residenciales y comerciales), de los cuales se extrajeron más de 460000 secuencias de actividades para entrenar modelos generativos LSTM que aprendieran patrones de secuenciación y validaran la lógica entre actividades. Los resultados demostraron que ninguno de los cronogramas reales cumplió completamente los 14 criterios de la DCMA, revelando que las métricas cuantitativas existentes no reflejan adecuadamente la viabilidad de los cronogramas. En consecuencia, los autores concluyen que la combinación de heurísticas con aprendizaje automático ofrece un camino prometedor hacia un sistema automatizado capaz de evaluar de manera más objetiva y eficiente la calidad de los cronogramas de construcción.

En Estados Unidos, según Lotfi, Sadeghi, Ali, Ramyar, Ghafourian y Farbod en 2025 “Un aprendizaje automático robusto y resiliente con un enfoque de riesgo para la programación de proyectos”, El estudio se centra en predecir la duración total de proyectos complejos mediante un enfoque de aprendizaje automático que integra robustez, resiliencia y gestión del riesgo. Su objetivo principal fue mejorar la precisión en la estimación del tiempo de finalización de proyectos, incorporando factores de incertidumbre y riesgo que suelen afectar la planificación tradicional. La metodología empleó un modelo robusto de regresión LASSO estocástica, que minimiza la desviación media absoluta ponderada por riesgo (WVaR) e introduce coeficientes de resiliencia y conservadurismo para simular escenarios de incertidumbre en proyectos nacionales a gran escala. Como muestra se utilizaron datos históricos de duración, complejidad, experiencia del equipo y disponibilidad de recursos en proyectos de infraestructura. Los resultados demostraron que el modelo de regresión tipo raíz cuadrada mejoró la precisión de predicción en un 36 % respecto al modelo base, y que ajustes en los coeficientes de riesgo y resiliencia permitieron reducir los errores de estimación sin afectar la estabilidad del modelo, consolidando el robustez, resiliencia y gestión del riesgo como una herramienta eficaz para la programación de proyectos bajo condiciones inciertas.

En Estados Unidos, según Basak y Mohammadamin en 2025 “Gestión predictiva de proyectos en la construcción: un enfoque basado en datos para la programación de proyectos y la estimación de recursos mediante aprendizaje automático”. El estudio tiene como objetivo optimizar la programación de obras y la estimación de recursos mediante la utilización de modelos de aprendizaje automático, superando las limitaciones de los métodos tradicionales que no captan la variabilidad de los proyectos. Para ello, los autores implementaron un marco metodológico que integra modelos como Support Vector Machine (SVM) para clasificar riesgos de retrasos relacionados con condiciones climáticas y disponibilidad laboral, y Random Forest para predecir necesidades de recursos y fluctuaciones de costos; además, se emplearon GBM, ANN y LSTM para optimización de cronogramas y predicción de demoras. La metodología se aplicó en un proyecto urbano de doce meses, donde el modelo procesó datos históricos, informes de campo y registros en tiempo real para generar predicciones interpretables. Los resultados mostraron una reducción del 18 % en retrasos, una mejora del 25 % en la asignación de recursos y una optimización del 7 % en los tiempos del proyecto, evidenciando que la incorporación del aprendizaje automático permite decisiones más proactivas y eficientes en la gestión de la construcción.

En Estados Unidos, según Saksham, Ulrike, Sevilay y Ayoola en 2025 “Modelo predictivo basado en aprendizaje automático para la aparición y resolución de disputas en proyectos de tuberías”. La investigación se propuso predecir la ocurrencia de disputas y los mecanismos de resolución más adecuados en proyectos de construcción de ductos, utilizando un enfoque basado en aprendizaje automático para fortalecer la adopción de decisiones en la gestión de conflictos, los autores analizaron 60 proyectos de ductos en distintas regiones del mundo, extrayendo información sobre variables técnicas, ambientales, sociales y regulatorias. Emplearon y compararon cinco modelos de machine learning random forest, regresión logística, Naïve Bayes, KNN y AdaBoost, evaluando su desempeño mediante métricas de

precisión y F1 score. El modelo random forest obtuvo los mejores resultados (92 a 98% de precisión y F1), mostrando una alta capacidad predictiva. Entre los hallazgos más relevantes, se determinó que los factores ambientales, la participación comunitaria y el cumplimiento regulatorio son los principales determinantes en la aparición y resolución de disputas, mientras que los aspectos técnicos y financieros tienen menor impacto. El estudio concluye que la aplicación de modelos predictivos permite anticipar conflictos y diseñar estrategias preventivas más efectivas en proyectos de infraestructura energética.

En el Líbano, según Mohamad, F. Jordan“Enfoque y Issam en 2021 “Enfoque de aprendizaje automático basado en datos para integrar envíos de campo en la programación de proyectos”. La investigación tuvo como objetivo aprovechar los datos generados en obras de construcción para predecir retrasos en la programación de proyectos, específicamente analizando las solicitudes de vaciado de concreto (CPRs), con el fin de mejorar la precisión de los cronogramas durante la ejecución de proyectos y fortalecer la toma de decisiones de los gerentes de construcción. La metodología consistió en aplicar un modelo de aprendizaje automático Random Forest (bosques aleatorios) sobre una base de 1001 solicitudes de vaciado de concreto recolectadas en un proyecto de uso mixto en Beirut. Se siguieron cuatro etapas: recolección y limpieza de datos, selección de características significativas (como tipo de estructura, volumen de concreto, ubicación y resistencia), balanceo de clases mediante el algoritmo SMOTE y ajuste del modelo para predecir la aceptación o rechazo de las solicitudes. Como resultados, el modelo logró una precisión del 91%, con un recall (casos verdaderos) del 61% y una precisión del 44%, mostrando su eficacia para anticipar rechazos y, por tanto, posibles retrasos. Además, al comparar el método propuesto con el cronograma tradicional basado en el método de la ruta crítica (CPM), se observó una diferencia del 10% en la duración del proyecto, evidenciando que el enfoque basado en aprendizaje automático proporciona estimaciones más realistas y detalladas de los plazos de obra.

En el Líbano, según Sawma, Assaf, Safa y Srour en 2022 “Pronóstico de la producción de campo mediante series temporales de aprendizaje automático”. La investigación tiene como objetivo proponer un marco genérico basado en aprendizaje automático (Machine Learning) para pronosticar la producción en campo durante proyectos de construcción, reduciendo la incertidumbre y mejorando la gestión de recursos. Para ello, los autores implementaron un modelo predictivo de series de tiempo con redes neuronales artificiales (ANN), específicamente un Perceptrón Multicapa (MLP), que integra factores internos (como horas de maquinaria y recursos) y externos (como condiciones climáticas). La metodología se aplicó a actividades de excavación en un proyecto de infraestructura real en el Medio Oriente, utilizando datos recolectados durante ocho meses de registros diarios de obra. Los resultados mostraron una alta precisión del modelo ($R^2 = 0.94$ y RMSE entre 548 y 652 m^3), evidenciando que la propuesta permite pronosticar eficazmente la producción futura y facilita una planificación proactiva y basada en datos para los administradores de proyectos.

En Turquía, según Ayhan, Dikmen y Birgonul en 2021, “Predicción de la ocurrencia de disputas en la construcción mediante técnicas de aprendizaje automático”. La investigación tuvo como propósito predecir la ocurrencia de disputas en proyectos de construcción a través de técnicas de Machine Learning, buscando ofrecer un modelo predictivo que sirviera como herramienta de alerta temprana para la gestión de conflictos en el sector. Para ello, los autores identificaron variables clave desde la literatura y elaboraron un modelo conceptual, a partir del cual diseñaron un cuestionario aplicado a expertos de 75 empresas internacionales, obteniendo datos de 108 proyectos de construcción en 19 países. La metodología incluyó el uso de pruebas Chi-cuadrado para determinar las variables más influyentes y la aplicación de distintos modelos de clasificación basados en algoritmos de aprendizaje automático, entre ellos Naïve Bayes, kNN, C4.5, MLP y máquinas de soporte vectorial (SVM), además de modelos ensemble como voting, stacking y AdaBoost. Los resultados demostraron que el modelo basado en SVM con

función kernel RBF alcanzó una precisión del 90.46%, mientras que el modelo combinado mediante votación mayoritaria logró el mejor rendimiento con un 91.11% de exactitud, concluyendo que las variaciones y eventos imprevistos en los proyectos, así como las habilidades de comunicación y coordinación de las partes, son los factores más determinantes en la aparición de disputas en la construcción.

En Turquía, según Mostifi, Behzat y Toğan en 2025 "Modelo de predicción de retrasos en la construcción mediante una red de atención de gráficos multicabezal con reconocimiento de relaciones", tiene como objetivo diseñar un modelo predictivo de retrasos en obras de construcción basado en redes de atención de grafos (Graph Attention Network, GAT) con un mecanismo multihead. La investigación busca mejorar la predicción de retrasos considerando las dependencias espaciales y contractuales entre las actividades constructivas, superando los modelos tradicionales de aprendizaje automático que tratan los datos de manera aislada. La metodología consistió en recopilar y procesar datos de tres proyectos reales de construcción, estructurándolos en redes que representan tareas eléctricas, de concreto e instalación. Cada red se configuró bajo dos tipos de dependencia alineación contractual y proximidad espacial y se entrenó el modelo GAT para predecir el Schedule Performance Index (SPI), un indicador clave del rendimiento del cronograma. Los resultados mostraron que el modelo logró precisiones entre 65% y 77%, siendo más efectivo al considerar la estructura relacional de las tareas; por ejemplo, alcanzó 76.8% de exactitud en tareas de aislamiento bajo redes espaciales y 76% en tareas de concreto bajo dependencias contractuales. En conjunto, la investigación demuestra que el modelo GAT propuesto mejora la representación y comprensión de las interdependencias en los proyectos de construcción, ofreciendo una herramienta predictiva más confiable para la gestión de retrasos y la toma de decisiones.

En la India, según Banerjee, Putta y Mohan en 2021 "Identificación, evaluación y predicción de riesgos para megaproyectos de construcción: un paradigma de predicción de

riesgos basado en un modelo de aprendizaje automático y análisis cruzado". La investigación buscó desarrollar un marco dinámico orientado a la evaluación de la complejidad de los riesgos en megaproyectos de construcción, buscando identificar los factores de riesgo más críticos y sus subcomponentes para mejorar la gestión y distribución del riesgo entre los distintos actores del proyecto. Para ello, los autores aplicaron un enfoque mixto: primero realizaron un análisis cualitativo mediante entrevistas con expertos de la industria y luego una fase cuantitativa basada en encuestas a 70 profesionales del sector, donde se evaluaron 63 factores de riesgo en dimensiones como costo, tiempo, calidad y alcance. Los datos recolectados fueron procesados con técnicas estadísticas y de aprendizaje automático, destacando el uso de un modelo híbrido basado en un algoritmo genético combinado con K-means (GA K means), junto con la técnica de sobremuestreo SMOTE y la prueba de rango Wilcoxon, para optimizar la identificación y agrupación de riesgos. Los resultados permitieron clasificar los factores de riesgo más influyentes, como los retrasos en permisos y regulaciones, inestabilidad política, errores de diseño, equipos inadecuados y condiciones imprevistas del sitio, concluyendo que este enfoque de análisis cruzado mejora la precisión en la predicción de riesgos y contribuye a una gestión más eficaz de los megaproyectos de construcción.

En Taiwán, según Cheng, Chang y Korir en 2019 "Un nuevo enfoque para estimar el cronograma de finalización en proyectos de construcción mediante aprendizaje secuencial y no secuencial". El estudio tuvo como objetivo principal diseñar un modelo de inferencia que permitiera predecir con mayor precisión el tiempo estimado para la finalización de proyectos de construcción (ESTC), considerando tanto factores secuenciales (dependientes del tiempo) como no secuenciales (independientes del tiempo) que influyen en la duración de una obra. Para ello, los autores desarrollaron el modelo NN-LSTM (Neural Network Long Short Term Memory), que combina las características de las redes neuronales feedforward (FNN) y las redes neuronales recurrentes (RNN), permitiendo capturar relaciones complejas en los datos

temporales. La metodología empleada se sustentó en una base de datos de 226 casos históricos de 11 proyectos de construcción de concreto reforzado en el norte de Taiwán, analizados mediante validación cruzada de 10 pliegues. Los resultados mostraron que el modelo NN-LSTM logró una precisión notable, obteniendo un error porcentual absoluto medio (MAPE) inferior al 5 % y un error absoluto medio (MAE) del 2 %, superando a métodos tradicionales como el Earned Value Management (EVM) y otros modelos de inteligencia artificial. En conclusión, el NN-LSTM demostró ser una herramienta confiable para los gerentes de proyectos al ofrecer estimaciones precisas de los plazos de ejecución y facilitar una gestión proactiva del cronograma.

En China y Taiwan, según Ching-Lung Fan en 2025 “Optimización y evaluación del rendimiento de clasificadores de aprendizaje automático para predecir la calidad y el cronograma de la construcción.”, tuvo como objetivo proporcionar un marco de predicción de la calidad y el cronograma de proyectos de construcción mediante modelos de aprendizaje automático (Machine Learning), con el fin de convertir esos resultados en estrategias prácticas de gestión. La investigación empleó un conjunto de datos públicos del Public Construction Intelligence Cloud (PCIC), que contiene 1015 proyectos con 499 tipos de defectos, para analizar la relación entre los defectos, la calidad y el cumplimiento del cronograma. Se aplicaron nueve clasificadores supervisados de Machine Learninig incluidos Multilayer Perceptron (MLP), Support Vector Machine (SVM), Random Forest (RF), Decision Tree (DT), AdaBoost, Gradient Boosting, KNN, LDA y Logistic Regression. Cada modelo fue ajustado mediante optimización de hiperparámetros y validación cruzada para determinar su rendimiento predictivo. Los resultados mostraron que el MLP obtuvo el mejor desempeño, alcanzando una precisión del 94.1 % en la predicción de calidad y del 98.4 % en la del cronograma, superando a los demás algoritmos. El estudio concluyó que el uso de ML, especialmente redes neuronales como el MLP, permite identificar defectos críticos y predecir

riesgos de retrasos y deficiencias, proporcionando una herramienta eficaz para la gestión proactiva de la calidad y los plazos en proyectos de obras públicas.

En China, según Feng, Cao, Liu y Cong Liu en 2025 “Predicción del rendimiento de las organizaciones en redes de proyectos mediante aprendizaje automático: evidencia de la industria de las APP en China”. La investigación tuvo como objetivo predecir el desempeño organizacional en redes de proyectos de asociaciones público-privadas (APP), analizando cómo las posiciones globales y locales de las organizaciones dentro de estas redes influyen en su rendimiento. Para ello, se usaron datos de 745 proyectos PPP de transporte en China entre 2014 y 2021, que involucraron 885 organizaciones y 3546 relaciones interorganizacionales. La metodología consistió en aplicar el algoritmo de aprendizaje automático XGBoost (regresión con árboles potenciados), construyendo tres modelos: el G-model (posiciones globales), el L-model (posiciones locales) y el GL-model (combinadas). Los resultados mostraron que las posiciones globales, locales y combinadas predicen significativamente el desempeño organizacional, especialmente en las dimensiones de mercado e innovación, aunque no en el desempeño financiero. Las variables más influyentes fueron la centralidad de grado, la posición tipo estrella (I) y la centralidad de intermediación, observándose patrones no lineales en las relaciones entre posición y desempeño. En conjunto, el estudio demuestra que el uso de modelos predictivos basados en aprendizaje automático ofrece una comprensión más profunda del impacto estructural de las redes en el rendimiento de las organizaciones APP.

En China, según Jiang, Li, Fang, Liu y Zhao en 2023 “Pronóstico de la duración de la construcción basado en el método de aprendizaje automático”, busca predecir con precisión la duración de los proyectos de construcción a través de la aplicación de modelos de aprendizaje automático, reemplazando los métodos empíricos basados en la experiencia que suelen generar errores en la planificación. El estudio tiene como objetivo principal construir un modelo predictivo confiable que ayude a los gestores de proyectos a estimar los tiempos de ejecución,

optimizando la gestión y control de costos. Para ello, los autores utilizaron una base de datos de 30 proyectos de construcción y aplicaron el algoritmo Random Forest (RF), comparando sus resultados con un modelo de regresión lineal múltiple (MLR). Las variables analizadas incluyeron el área total construida, el número de pisos, la altura y el costo por unidad de área. Los resultados demostraron que el modelo de Random Forest ofrece una mayor precisión predictiva ($R^2 = 0.9439$), identificando la altura y el área total como los factores más influyentes en la duración de los proyectos. En conclusión, los autores destacan que el enfoque basado en aprendizaje automático mejora notablemente la estimación del tiempo de construcción, aunque recomiendan ampliar la muestra para validar el modelo en contextos más diversos.

En China, según Liu y Luo "Un modelo eficiente basado en aprendizaje automático para la predicción de la duración de tareas de construcción con conjuntos de datos a gran escala", tuvo como propósito diseñar un modelo de aprendizaje automático eficaz para estimar la duración de las actividades de construcción utilizando grandes volúmenes de datos reales. La investigación buscó superar las limitaciones de los métodos tradicionales de planificación, que dependen de juicios subjetivos, proponiendo un modelo denominado KLWLS-SVMR que combina K-Means clustering con Locally Weighted Least Squares Support Vector Machine Regression. Para ello, se empleó un conjunto de 140378 tareas de construcción provenientes de proyectos de infraestructura del Reino Unido (base de datos de la Universidad de Cambridge). La metodología incluyó el uso de características numéricas y textuales, extraídas mediante topic modeling con modelos como BERT, así como una selección híbrida de características con PCA y Random Forest. Los resultados demostraron que el modelo propuesto superó a once algoritmos tradicionales (como Random Forest, XGBoost y AdaBoost), alcanzando un $R^2 = 0.973$, con una reducción del 53.5% en RMSE y del 79.7% en tiempo de cómputo respecto a otros métodos, evidenciando su precisión y eficiencia para la predicción de duraciones en tareas de construcción.

En el Reino Unido, según Fitzsimmons, Lu, Hong y Brilakis en 2022 “Análisis de riesgos del cronograma de construcción: un enfoque híbrido de aprendizaje automático”, La investigación tuvo como propósito desarrollar un método híbrido orientado a incrementar la precisión del análisis de riesgos en los cronogramas de construcción. La investigación se llevó a cabo en el Reino Unido, donde se analizaron datos de 302 proyectos de infraestructura completados, que incluían 293263 tareas. El estudio buscó predecir y estimar de forma mas objetiva los retrasos en proyectos de construcción, superando las limitaciones de los métodos tradicionales como Monte Carlo, que dependen de estimaciones subjetivas. Para lograrlo, los autores combinaron un modelo de Red Bayesiana Empírica basada en Mezclas Gaussianas con una Máquina de Vectores de Soporte (SVM) y luego aplicaron una simulación Monte Carlo. La metodología incluyó la recopilación de cronogramas históricos en formato Primavera P6, su conversión y procesamiento mediante técnicas de modelado de tópicos, selección de características y entrenamiento de los algoritmos para estimar las desviaciones de duración en las tareas. Como resultado, el modelo híbrido predijo los retrasos con un 54.4% más de precisión que el método tradicional Monte Carlo, demostrando su potencial para ofrecer una evaluación más confiable y basada en datos históricos del riesgo temporal en proyectos de construcción.

En Canadá, según Gondia, Siam, El-Dakhakhni y Nassar en 2020 “Algoritmos de aprendizaje automático para la predicción del riesgo de retraso en proyectos de construcción”. El estudio tiene como propósito identificar y aumentar modelos de aprendizaje automático que permitan analizar y predecir el riesgo de retrasos en proyectos de construcción a partir de datos objetivos, superando las limitaciones de los métodos tradicionales basados en juicios subjetivos. Para lograrlo, los autores recopilaron información de 51 proyectos de edificación en Egipto, pertenecientes a 28 empresas constructoras, y construyeron un conjunto de datos multivariante que incluía nueve fuentes de riesgo (como propietario, contratista, diseño,

materiales, etc.). Aplicaron una metodología basada en análisis exploratorio de datos y técnicas de clasificación supervisada, utilizando dos algoritmos de aprendizaje automático: árboles de decisión (Decision Tree) y clasificación bayesiana ingenua (Naïve Bayes). Los modelos fueron entrenados y validados mediante pruebas de validación cruzada de 10 pliegues, evaluando su rendimiento con matrices de confusión y métricas de precisión, sensibilidad y especificidad. Los resultados mostraron que el modelo Naïve Bayes presentó un mejor desempeño predictivo que el árbol de decisión, demostrando su eficacia para estimar con precisión los niveles de riesgo de retraso y contribuir a la gestión preventiva de riesgos en proyectos de construcción.

En Chile, Lagos, Herrera, Mac Cawley y Alarcón en 2024 "Predecir el rendimiento del cronograma de construcción con Last Planner System y aprendizaje automático", tuvo como propósito predecir el desempeño del cronograma de obras en etapas tempranas de ejecución, combinando indicadores del Last Planner System (LPS) y métricas tradicionales de gestión de proyectos mediante técnicas de aprendizaje automático. La investigación se llevó a cabo bajo el enfoque de Design Science Research, utilizando una base de datos de 164 proyectos de construcción reales (principalmente edificaciones en altura e industriales) obtenidos del sistema informático IMPERA, con un total de 1464 puntos de muestra distribuidos en nueve intervalos de ejecución. Se evaluaron 18 artefactos de solución aplicando modelos de regresión lineal y árboles de decisión, priorizando los interpretables y descartando redes neuronales por su carácter de "caja negra". Los resultados mostraron que el modelo más eficaz (basado en árboles de decisión y solo con indicadores LPS) alcanzó un coeficiente de determinación R^2 = 0.96 y un error absoluto medio (MAE) de 1.24 %, demostrando que las métricas del LPS como Percent Plan Complete (PPC) y Percent Constraints Removed (PCR) pueden predecir con alta precisión el cumplimiento del cronograma. En conclusión, el estudio evidenció que el uso de indicadores LPS supera a los métodos tradicionales para la detección temprana de desviaciones en la planificación de proyectos de construcción.

Tabla 1:
Antecedes directamente relacionados con la duración de actividades.

Estudio	Datos	Modelo	Validación	Comparación convencional	Resultado principal
Fitzsimmons et al. (2022), Reino Unido	302 proyectos de infraestructura; 293263 tareas	Red bayesiana empírica + SVM + simulación Monte Carlo	Validacion cruzada	Monte Carlo tradicional	Predicción de retrasos 54,4 % más precisa
Liu & Luo (2026), Reino Unido (base de Cambridge)	140378 tareas de infraestructura	KLWLS-SVMR (K-means + SVM ponderada); texto con BERT	Validacion cruzada	11 algoritmos de ML (RF, XGBoost, AdaBoost, etc.)	R^2 = 0,973; RMSE - 53,5 %; tiempo de cómputo - 79,7 %
Lagos et al. (2024), Chile	164 proyectos; 1464 puntos de muestra	Regresión lineal y árboles de decisión (18 artefactos)	Validacion cruzada	Indicadores tradicionales de gestión de proyectos	R^2 = 0,96; MAE = 1,24 %
Jiang et al. (2023), China	30 proyectos de edificación	Random Forest	Validacion cruzada	Regresión lineal múltiple	R^2 = 0,9439; altura y área, variables más influyentes
Cheng et al. (2019), Taiwán	226 casos de 11 proyectos de concreto reforzado	NN-LSTM	Validación cruzada de 10 pliegues (sin agrupación indicada)	Earned Value Management (EVM)	MAPE < 5 %; MAE = 2 %
Awada et al. (2021), Líbano	1001 solicitudes de vaciado de concreto, un proyecto	Random Forest + SMOTE	Validacion cruzada	Cronograma CPM	Precisión 91 %; recall 61 %; diferencia de 10 % en duración respecto del CPM
Sawma Awad et al. (2022), Medio Oriente	Un proyecto, 8 meses de registros diarios de excavación	Perceptrón multicapa (series de tiempo)	Validacion cruzada	No se indica	R^2 = 0,94; RMSE de 548 - 652 m^3 (producción, no duración)
Mostofi et al. (2025), Turquía	3 proyectos	Red de atención de grafos (GAT)	Validacion cruzada	Modelos de ML que tratan las tareas de forma aislada	Exactitud de 65 -77 % sobre el SPI
Gondia et al. (2020), Canadá/Egipto	51 proyectos de edificación, 28 empresas	Árbol de decisión y Naïve Bayes	Validación cruzada de 10 pliegues	Juicio subjetivo (método tradicional)	Naïve Bayes superó al árbol de decisión en riesgo de retraso (clasificación)

Fuente: Elaboración Propia

2.1.2. Antecedentes Nacionales

"Construcción de un modelo predictivo de productividad de las palas aplicando el aprendizaje automático Random Forest Regressor de Machine Learning" fue desarrollada en Lima, por Víctor Alexander Juárez Racchumi en la Universidad Nacional de Ingeniería, bajo la asesoría del M.Sc. José Antonio Corimanya Mauricio (Juarez Racchumi & Corimanya Mauricio). El estudio tuvo como objetivo principal mejorar la predicción de la productividad de las palas mineras mediante técnicas de aprendizaje automático, comparando distintos modelos para identificar aquel con mayor precisión y determinar la importancia de las variables operativas en la productividad. Su metodología fue de tipo aplicada y diseño no experimental, utilizando datos históricos del sistema Dispatch de la mina Open Pit FIGMM (Moquegua). Se construyó un dataset de más de 28000 registros con variables cuantitativas y cualitativas, que fueron procesadas y modeladas en Python mediante Jupyter Notebook, aplicando algoritmos de Machine Learning en especial el Random Forest Regressor con validación cruzada para seleccionar los mejores hiperparámetros. Los resultados demostraron que este modelo obtuvo una precisión del 99.7 % en el entrenamiento y 91.1 % en el testeo, superando ampliamente a los demás modelos, como el Dummy Regressor, que alcanzó solo -0.03 %. Asimismo, el estudio identificó que las variables con mayor influencia en la productividad fueron la flota de pala, el código de pala, el tiempo de carguío y el tiempo hang, confirmando que el modelo propuesto mejora significativamente la estimación de productividad frente a los métodos tradicionales.

La investigación titulada "Propuesta metodológica enfocada en la evaluación de riesgos para evitar la modificación contractual en proyectos de infraestructura vial bajo la modalidad de contrata en la ciudad de Arequipa", fue desarrollada por Víctor Antonio Banda Salas en la Universidad Católica de Santa María. La investigación tuvo como propósito desarrollar una metodología para evaluar los riesgos asociados a las modificaciones contractuales en obras

viales, orientada a mejorar la gestión de los plazos y presupuestos en proyectos de infraestructura pública. Metodológicamente, se aplicó un enfoque mixto (cuantitativo y cualitativo) mediante entrevistas, encuestas y análisis de información de campo, empleando herramientas como Microsoft Project y Risk 8.0 para el procesamiento de datos y la identificación de riesgos. La investigación se desarrolló bajo un diseño no experimental transversal, con un caso de estudio ubicado en los distritos de Arequipa, Paucarpata, Mariano Melgar y José Luis Bustamante y Rivero, donde se contó con la participación de 10 expertos en ingeniería civil para la validación de la metodología a través del método Delphi. Como resultado, la metodología propuesta obtuvo una validación del 91.25% de aceptación por parte de los especialistas, demostrando su efectividad para identificar, evaluar y mitigar riesgos que ocasionan modificaciones contractuales en proyectos viales, contribuyendo así a una gestión más eficiente y sostenible de la infraestructura pública

La tesis “Modelo para la gestión eficiente de sistemas de alcantarillado basado en Machine Learning y GIS”, desarrollada por Víctor Manuel Perales Apaza en la Universidad Católica de Santa María, en la ciudad de Arequipa, (2025). El estudio tuvo como objetivo proponer un modelo que optimice la gestión de los sistemas de alcantarillado mediante el uso de técnicas de aprendizaje automático y Sistemas de Información Geográfica (GIS). Para ello, la metodología se estructuró en tres etapas: diagnóstico de la red (procesando información en formato shapefile y realizando limpieza de datos), aplicación de algoritmos de agrupamiento o clustering específicamente k-means y DBSCAN para clasificar las tuberías según su estado, y finalmente la implementación de los resultados en un entorno GIS para su visualización y análisis espacial. La muestra utilizada fue la red de alcantarillado del distrito de Mariano Melgar (Arequipa). Los resultados mostraron que el modelo permitió identificar grupos de tuberías según su condición, priorizando aquellas que requerían mantenimiento o reemplazo. Se concluyó que la integración de machine learning con GIS facilita la gestión preventiva y

eficiente de los sistemas de alcantarillado, sentando las bases para futuros modelos de gestión de activos urbanos en el ámbito del saneamiento.

La tesis titulada “Uso de redes neuronales artificiales para determinar una nueva alternativa de método de diseño de mezcla de concretos de resistencias convencionales en la ciudad de Arequipa 2022”, desarrollada por Fernando Loayza Cáceres y Álvaro Gonzalo Ramos Butrón en la Universidad Católica de Santa María (2023), tuvo como objetivo determinar una alternativa eficiente al método tradicional de diseño de mezclas de concreto mediante el uso de redes neuronales artificiales. La investigación fue de tipo cuantitativa, experimental y de nivel aplicativo, basada en la recopilación y procesamiento de datos de diversos diseños de mezcla de concreto para alimentar una red neuronal programada en Python con el entorno Spyder. La población de estudio estuvo compuesta por datos experimentales de diseños de mezcla realizados en investigaciones previas de la región, centrados en resistencias entre 175 kg/cm² y 280 kg/cm². El modelo de aprendizaje automático utilizado fue una Red Neuronal Artificial (RNA), configurada con un enfoque de entrenamiento tipo backpropagation, capaz de aprender patrones y optimizar combinaciones de materiales locales. Los resultados mostraron que el modelo logró predecir con precisión la resistencia a la compresión del concreto, proponiendo un método accesible y eficiente que reduce desperdicios de materiales, equilibra resistencia y costo, y promueve la formalización en la construcción arequipeña.

Tabla 2:
Antecedentes metodológicos y su uso en la tesis.

Decisión de diseño	Estudios	Aporte	Uso en esta tesis
Organización de la base de datos	Seyisoglu et al. (2025)	Integran datos históricos, informes de campo y registros en tiempo real en un marco de ML (SVM, Random Forest, GBM, ANN y LSTM) con predicciones interpretables; reportan 18 % menos de retrasos y 25 % de mejora en asignación de recursos	Estructura de la base de datos de actividades de obra
Variables a extraer	Fitzsimmons et al. (2022); Liu & Luo (2026); Jiang et al. (2023)	Cronogramas históricos P6 con modelado de tópicos y selección de características; variables numéricas y textuales con selección híbrida (PCA y Random Forest); variables físicas (área, pisos, altura, costo por área)	Definición de los predictores por actividad y obra
Selección y comparación de modelos	Fan (2025); Ayhan et al. (2021); Timalsina et al. (2025); Liu & Luo (2026)	Comparan entre 5 y 11 algoritmos con optimización de hiperparámetros y validación cruzada (MLP, SVM, RF, AdaBoost, kNN, árboles); Ayhan et al. incluyen ensambles Voting, Stacking y AdaBoost, y el Voting obtuvo la mayor exactitud (91,11 %)	Comparación de 42 modelos, preselección de 5 y ensambles Voting y Stacking
Línea base y flujo en Python	Juarez Racchumi & Corimanya (2023); Cáceres Loayza et al. (2023)	Flujo en Python (Jupyter, Spyder) con Random Forest y validación cruzada para ajustar hiperparámetros, y comparación con un regresor ficticio (Dummy) de $R^2 \approx 0$; red neuronal entrenada con datos locales	Cuaderno de entrenamiento y uso de modelos de referencia
Interpretación de resultados	Lagos et al. (2024); Jiang et al. (2023); Feng et al. (2025); Timalsina et al. (2025)	Priorizan modelos interpretables frente a redes de “caja negra”; identifican las variables más influyentes (altura y área; centralidad de red; factores ambientales y regulatorios); hallan patrones no lineales	Análisis de importancia de variables y lectura de la relación no lineal
Validación y contraste estadístico	Gondia et al. (2020); Banerjee et al. (2021)	Validación cruzada de 10 pliegues con matrices de confusión; uso de la prueba de rangos de Wilcoxon	Validación cruzada agrupada y prueba de Wilcoxon

Fuente: Elaboración propia.

2.2. Bases teóricas

2.2.1. Importancia de la gestión de proyectos

La gestión de proyectos es esencial para organizar, dirigir y controlar los recursos y actividades requeridas para cumplir los objetivos definidos de un proyecto. En el ámbito de la construcción su importancia radica en que permite articular el alcance, plazo, costo, calidad, recursos, riesgos y demás componentes que intervienen durante la ejecución de una obra. El PMBOK Guide reconoce que tradicionalmente el éxito de un proyecto se ha relacionado con el cumplimiento del tiempo, costo, alcance y calidad, aunque actualmente también debe considerarse el logro de los objetivos y resultados esperados del proyecto (Project Management Institute, 2021).

Desde un enfoque de Lean Construction, la gestión está orientada a optimizar los procesos de trabajo, reducir desperdicios y generar valor mediante una mayor integración entre los participantes del proyecto (Lean Construction Institute, 2023).

La gestión deja de centrarse únicamente en verificar el cumplimiento de un cronograma y pasa a incorporar mecanismos para incrementar la confiabilidad de la planificación y del proceso de producción (Last Planner System Lean Construction Institute, 2024).

2.2.2. Infraestructura vial

En el Perú su planificación, diseño, construcción y conservación se encuentran sustentados en un conjunto de normas y documentos técnicos emitidos por el Ministerio de Transportes y Comunicaciones (MTC). Entre estos documentos se encuentran el Manual de Carreteras: Diseño Geométrico (DG-2018), las Especificaciones Técnicas Generales para Construcción (EG-2013), el Manual de Carreteras: Suelos, Geología, Geotecnia y Pavimentos (Sección de suelos y pavimentos). Estos instrumentos establecen parámetros técnicos aplicables al diseño,

la construcción, la supervisión y la evaluación de los distintos elementos que conforman una carretera.

2.2.2.1. Elementos que conforman una infraestructura vial

Los principales componentes relacionados con la ejecución de una obra vial se encuentran la explanación, la subrasante, las capas granulares, el pavimento, los sistemas de drenaje y las obras complementarias.

La explanación corresponde al conjunto de trabajos de movimiento de tierras necesarios para conformar la plataforma de la carretera. Comprende principalmente las actividades de corte y relleno o terraplén, mediante las cuales se modifica el terreno natural hasta alcanzar las cotas establecidas en el proyecto. El terraplén se conforma mediante capas que deben ser compactadas de acuerdo con los requisitos técnicos establecidos, mientras que la subrasante constituye la superficie sobre la cual se apoya directamente la estructura del pavimento (Ministerio de Transportes y Comunicaciones MTC, 2014).

La subrasante cumple una función fundamental debido a que constituye el soporte de la estructura del pavimento. Sus características de resistencia y comportamiento condicionan el diseño y desempeño de las capas superiores. El MTC considera la capacidad de soporte de la subrasante, expresada mediante el CBR, como uno de los parámetros fundamentales para la caracterización de esta capa y para el diseño de la estructura del pavimento (Ministerio de Transportes y Comunicaciones MTC, 2018).

Cuando las condiciones del suelo resultan insuficientes, pueden requerirse alternativas como estabilización, reemplazo del material, utilización de geosintéticos o modificación de la rasante (Ministerio de Transportes y Comunicaciones MTC, 2014).

Sobre la subrasante se disponen, según la solución adoptada, las capas de subbase y base, cuya función consiste en proporcionar capacidad estructural, distribuir las cargas transmitidas por el

tránsito y generar una superficie adecuada para la colocación de la capa de rodadura. Las características de estas capas dependen de los materiales utilizados, las condiciones de la subrasante y las exigencias de diseño. El control de sus propiedades físicas y mecánicas resulta necesario para garantizar que la estructura alcance las condiciones establecidas en el proyecto. (Ministerio de Transportes y Comunicaciones MTC, 2013)

Finalmente, la superficie de rodadura o pavimento constituye el componente directamente expuesto al tránsito. Su solución puede corresponder, entre otras alternativas, a pavimentos flexibles, rígidos o semirrígidos, incluyendo los pavimentos de adoquines. El MTC diferencia estas soluciones según los materiales y comportamiento estructural empleados, estableciendo metodologías y criterios específicos para cada alternativa (Ministerio de Transportes y Comunicaciones MTC, 2013).

2.2.2.2. Pavimentos

El pavimento constituye el elemento estructural de la infraestructura vial destinado a proporcionar una superficie de circulación adecuada para el tránsito, distribuyendo las cargas vehiculares hacia las capas inferiores y protegiendo la subrasante frente a las acciones producidas por el tránsito y el ambiente (American Association of State Highway and Transportation Officials, 1993).

Para efectos de este estudio, los pavimentos se agrupan en flexibles, rígidos y articulados, debido a que cada alternativa presenta características estructurales, componentes, procedimientos constructivos y controles de calidad diferenciados. Estas diferencias son relevantes, puesto que determinan actividades, recursos, rendimientos y secuencias constructivas particulares que pueden incidir en la duración de los proyectos.

Pavimento flexible

Casos de utilización

El pavimento flexible se utiliza principalmente en carreteras, vías urbanas y otras superficies destinadas al tránsito vehicular en las que se adopta una estructura conformada por capas granulares y materiales asfálticos. Su selección se encuentra condicionada por factores como las características del tránsito, la disposición de soporte de la subrasante, las condiciones ambientales, materiales disponibles y los criterios de diseño establecidos para el proyecto (Ministerio de Transportes y Comunicaciones MTC, 2018).

Una de sus principales características es que la estructura distribuye progresivamente las cargas del tránsito a través de las diferentes capas que la conforman. La solución resulta aplicable a diferentes categorías de vías, siempre que las condiciones de diseño y las características de los materiales permitan satisfacer los requerimientos estructurales y funcionales establecidos(Ministerio de Transportes y Comunicaciones MTC, 2013).

Componentes

El pavimento flexible está constituido por diferentes capas que trabajan conjuntamente para soportar y distribuir las cargas producidas por el tránsito. De manera general, su estructura puede comprender:

- Subrasante: superficie de apoyo de la estructura del pavimento.
- Subbase: capa ubicada sobre la subrasante, cuando corresponde, que contribuye a la distribución de cargas y proporciona condiciones adecuadas para la construcción.

- Base: capa estructural que proporciona capacidad de soporte y distribuye las cargas hacia las capas inferiores.
- Capa o capas asfálticas: constituyen la superficie de rodadura y proporcionan características funcionales y estructurales a la vía.

Procedimiento constructivo

La ejecución de un pavimento flexible comprende una serie de etapas sucesivas, que comienzan con el acondicionamiento de la superficie de fundación y prosiguen con la construcción gradual de las capas estructurales del pavimento. El EG-2013 establece especificaciones relacionadas con los materiales, equipos, procedimientos de ejecución y controles correspondientes a las diferentes actividades de construcción.

El procedimiento comprende la preparación y conformación de la subrasante, seguida de la ejecución de la subbase y base cuando estas forman parte de la estructura diseñada. Cada capa debe ser extendida, nivelada, humedecida cuando corresponda y compactada hasta alcanzar las condiciones especificadas (Ministerio de Transportes y Comunicaciones MTC, 2013).

Posteriormente se realizan las actividades asociadas con la preparación de la superficie y colocación de las capas asfálticas. Estas comprenden, según la solución adoptada, la aplicación de tratamientos previos, producción y transporte de la mezcla, extendido mediante equipos apropiados y compactación. Finalmente se verifica que la superficie terminada cumpla con las condiciones establecidas en las especificaciones técnicas (American Association of State Highway and Transportation Officials, 1993).

Pavimento rígido

Casos de utilización

El pavimento rígido se utiliza cuando se adopta una solución estructural basada principalmente en una losa de concreto de cemento hidráulico, diseñada para soportar y distribuir las cargas producidas por el tránsito. Su utilización puede resultar conveniente en proyectos donde las condiciones de tránsito, características del suelo, disponibilidad de materiales, condiciones ambientales, requerimientos de durabilidad y criterios económicos o técnicos justifican la utilización de concreto hidráulico (American Association of State Highway and Transportation Officials, 1993).

Componentes

Pavimento rígido comprende principalmente:

- Subrasante: terreno preparado que sirve como soporte.
- Subbase: capa de apoyo que puede utilizarse para mejorar las condiciones de soporte, drenaje y uniformidad.
- Losa de concreto hidráulico: elemento estructural principal del pavimento.
- Juntas: elementos destinados a controlar determinados efectos asociados al comportamiento del concreto y a permitir los movimientos previstos.
- Elementos de transferencia o conexión: utilizados cuando corresponda según el diseño.
- La configuración final depende de las condiciones específicas establecidas en el proyecto y del diseño estructural adoptado.

Procedimiento constructivo

La construcción comienza con la preparación y aceptación de la superficie de apoyo, seguida de la ejecución de las capas inferiores que correspondan. Posteriormente se realizan

las actividades necesarias para la colocación del concreto hidráulico, incluyendo su producción, transporte, distribución, colocación, consolidación y acabado (Ministerio de Transportes y Comunicaciones MTC, 2013).

Una vez colocado el concreto, se ejecutan las actividades relacionadas con el acabado superficial, texturizado, formación o corte de juntas y curado, de acuerdo con las especificaciones del proyecto. El control de estas actividades es fundamental para garantizar que la losa alcance las características requeridas.

La secuencia constructiva presenta relaciones de dependencia entre las actividades. Por ejemplo, la colocación del concreto requiere que la superficie de apoyo se encuentre preparada y aprobada, mientras que determinadas actividades posteriores dependen del estado y condiciones del concreto colocado. Estas relaciones deben ser consideradas al elaborar la programación de obra.

Control de calidad

El aseguramiento de la calidad del pavimento rígido incluye la verificación de los materiales empleados en la elaboración del concreto, así como la inspección de sus propiedades durante el proceso de colocación y una vez finalizado este. El Manual de Ensayo de Materiales establece métodos para evaluar diferentes propiedades de los materiales utilizados en infraestructura vial (MTC, 2016).

Durante la ejecución pueden realizarse controles sobre el concreto fresco, incluyendo el asentamiento, así como controles sobre el concreto endurecido mediante ensayos destinados a determinar su resistencia, de acuerdo con las especificaciones del proyecto. También se verifican aspectos relacionados con el espesor, acabado, juntas y condiciones de curado.

Estos controles permiten determinar si la ejecución satisface los requisitos técnicos establecidos y, cuando corresponde, detectar oportunamente condiciones que requieran corrección.

Pavimento articulado

Casos de utilización

El pavimento articulado constituye una solución de pavimentación basada en unidades prefabricadas, principalmente adoquines de concreto o piedra, que se colocan sobre una superficie preparada y una capa de asiento. Puede utilizarse en determinadas vías urbanas, vías de tránsito de características específicas, espacios peatonales, estacionamientos y otras superficies donde las condiciones del proyecto permitan la utilización de este sistema.

La selección de esta alternativa depende de las condiciones de tránsito, características de la superficie de apoyo, disponibilidad de materiales, requerimientos funcionales y criterios establecidos en el proyecto. En comparación con las soluciones flexibles y rígidas, su principal característica constructiva es que la superficie de rodadura se conforma mediante unidades individuales que trabajan conjuntamente.

Componentes

La estructura de un pavimento articulado puede comprender:

- Subrasante: superficie preparada que sirve de apoyo.
- Subbase: capa que puede formar parte de la estructura según las condiciones del proyecto.
- Base: capa estructural que proporciona soporte y distribución de cargas.

- Cama de asiento: generalmente constituida por arena, sobre la cual se colocan los adoquines.
- Adoquines: unidades que conforman la superficie de rodadura.
- Material de sellado de juntas: utilizado para llenar los espacios existentes entre los adoquines.

Procedimiento constructivo

El procedimiento comienza con la preparación y compactación de la superficie de apoyo, seguida de la ejecución de las capas estructurales previstas en el proyecto. Posteriormente se coloca y nivela la cama de asiento, sobre la cual se instalan los adoquines siguiendo el patrón y alineamiento establecido.

Una vez colocados los adoquines, se realizan las actividades de confinamiento, llenado de juntas y compactación de la superficie, con el propósito de lograr la adecuada trabazón entre las unidades, especificaciones relacionadas con la colocación, materiales y procedimientos aplicables a este tipo de pavimento (Ministerio de Transportes y Comunicaciones MTC, 2013).

2.2.3. Gestión del cronograma del proyecto

La Gestión del Cronograma del Proyecto agrupa los procesos necesarios para administrar la finalización oportuna del proyecto de ingeniería civil (Project Management Institute, 2017). Un cronograma deficiente en un proyecto de construcción genera penalidades contractuales, sobrecostos por ampliación de plazo, conflictos con subcontratistas y, en obras públicas, observaciones de los órganos de control (Kerzner, 2022).

Los Fundamentos para la Dirección de Proyectos PMBOK sexta edición del Project Management Institute, la Gestión del Cronograma del Proyecto comprende seis procesos:

Planificar la Gestión del Cronograma, Definir las Actividades, Secuenciar las Actividades, Estimar la Duración de las Actividades, Desarrollar el Cronograma y Controlar el Cronograma.

2.2.3.1. Planificar la gestión del cronograma

La planificación de la gestión del cronograma consiste en definir los lineamientos, procedimientos y documentos que orientarán la elaboración, administración, ejecución y supervisión del cronograma del proyecto (Project Management Institute, 2017).

Plan de Gestión del Cronograma, documento que forma parte del Plan para la Dirección del Proyecto y que debe ser coherente con el Plan de Gestión del Alcance y con el enfoque de desarrollo adoptado (predictivo, tipo cascada, propio de la mayoría de los proyectos de infraestructura civil por la secuencialidad física de sus partidas (Porject Management Institute, 2019).

En proyectos de infraestructura civil, es recomendable que este documento explicite además la calendarización de recursos críticos (equipo pesado, cuadrillas especializadas), las condiciones de trabajo por temporada y el procedimiento de actualización del cronograma valorizado, dado que este último constituye la base para la elaboración de valorizaciones y el cálculo del valor ganado (Ministerio de Economía y Finanzas del Perú MEF, 2024).

2.2.3.2. Definir las actividades

Definir las actividades consiste en identificar y registrar las tareas necesarias para generar los entregables del proyecto, desglosando los paquetes de trabajo de la EDT en actividades específicas que permitan estimar, programar, ejecutar y controlar la obra. (Project Management Institute, 2017).

Herramientas y técnicas

- Juicio de expertos del personal técnico con experiencia en obras similares.

- Descomposición, técnica mediante la cual se subdivide cada paquete de trabajo de la EDT o WBS en actividades de menor tamaño, hasta alcanzar un nivel de detalle que permita estimar, asignar recursos y controlar el avance.
- Planificación gradual, aplicable cuando se cuenta con información detallada solo para las partidas de corto plazo, mientras que las partidas de etapas posteriores se mantienen en un nivel más general hasta contar con mayor definición del proyecto (Project Management Institute, 2017).
- Reuniones técnicas de coordinación entre el equipo de obra, el proyectista y, cuando aplique, los subcontratistas especializados.

Salidas principales

- Lista de actividades del cronograma, con su identificador y una descripción del alcance del trabajo suficientemente detallada.
- Atributos de las actividades: predecesoras, sucesoras, relaciones lógicas, adelantos y retrasos, requisitos de recursos, restricciones y supuestos.
- Hitos del proyecto, tales como la culminación del perfilado y compactación de la subrasante, la compactación del afirmado de la última progresiva, la entrega de casco y la recepción de obra; los hitos tienen duración nula, ya que representan un punto o evento significativo.
- Solicitudes de cambio, cuando la descomposición revela trabajo no contemplado inicialmente en la línea base del alcance.

2.2.3.3. Secuenciar las actividades

Secuenciar las actividades consiste en establecer y documentar las dependencias entre las tareas del proyecto, definiendo un orden lógico de ejecución que optimice el trabajo y respete las restricciones técnicas, contractuales y constructivas (Project Management Institute, 2017).

En obras civiles, la secuenciación responde en gran medida a la lógica constructiva: no es posible levantar la superestructura sin haber concluido la cimentación, ni realizar los acabados sin haber culminado las instalaciones empotradas en muros y losas (Kerzner, 2022).

Método de diagramación por precedencia

El método de diagramación por precedencia representa las actividades mediante nodos conectados por flechas que establecen sus dependencias y el orden lógico de ejecución dentro del cronograma del proyecto (Project Management Institute, 2017). El PDM es la base sobre la cual operan prácticamente todos los programas informáticos de programación de obra actualmente en uso, como Microsoft Project y Oracle Primavera P6.

A diferencia del método de diagramación por flechas (ADM), en desuso en la práctica profesional actual, el PDM no requiere actividades ficticias y permite representar directamente los cuatro tipos de relaciones lógicas que se describen en el apartado tipos de relaciones de precedencia, lo que lo hace especialmente adecuado para modelar la complejidad de los cronogramas de obras civiles, donde coexisten actividades secuenciales, superpuestas y paralela (Project Management Institute, 2019).

Actividades predecesoras

Una actividad predecesora es aquella que precede a una actividad dependiente (sucesora) dentro del cronograma del proyecto (Project Management Institute, 2017). En un proyecto de edificación, por ejemplo, la actividad "vaciado de zapatas" es predecesora de la actividad

"vaciado de columnas del primer nivel", puesto que esta última no puede iniciarse sin que la cimentación haya alcanzado la resistencia mínima requerida. Cada actividad del cronograma, con excepción de la primera y la última, debería conectarse con al menos una actividad predecesora y una actividad sucesora, de modo que el modelo de red no presente actividades aisladas "colgadas" (Project Management Institute, 2019).

Actividades sucesoras

Una actividad sucesora es una actividad dependiente que ocurre lógicamente después de otra actividad en el cronograma del proyecto. Siguiendo el ejemplo anterior, la actividad "encofrado y vaciado de columnas" es sucesora de "vaciado de zapatas y cimientos". La correcta identificación de las relaciones entre predecesoras y sucesoras es determinante para el cálculo de la ruta crítica del proyecto, ya que de dichas relaciones dependen las fechas tempranas y tardías de inicio y fin de cada actividad (Project Management Institute, 2017).

Tabla 3:
Tipos de relación de precedencia.

Tipo de relación	Descripción
Final a Inicio (FC)	La actividad sucesora no puede iniciar hasta que haya concluido la actividad predecesora. Es la relación predominante en programación de obra.
Final a Final (FF)	La actividad sucesora no puede finalizar hasta que haya concluido la actividad predecesora.
Inicio a Inicio (CC)	La actividad sucesora no puede comenzar hasta que haya comenzado la actividad predecesora.
Inicio a Final (CF)	La actividad sucesora no puede finalizar hasta que haya comenzado la actividad predecesora.

Nota: Tipos de relación de precedencia del PDM aplicados a proyectos de construcción. Adaptado de PMI (2017).

Fuente: Elaboración propia.

Adicionalmente, en la secuenciación de actividades se determina el tipo de dependencia que vincula cada par de actividades, considerando dos atributos combinables: obligatoria o discrecional e interna o externa (Project Management Institute, 2017).

- Dependencias obligatorias (lógica dura): son inherentes a la naturaleza física del trabajo, como la imposibilidad de levantar la estructura antes de concluir la cimentación.
- Dependencias discrecionales (lógica preferida): se basan en buenas prácticas constructivas, aunque existan secuencias alternativas aceptables; por ejemplo, ejecutar primero las instalaciones eléctricas y luego las sanitarias dentro de un mismo muro, cuando técnicamente ambas podrían realizarse en paralelo.
- Dependencias externas: relacionan actividades del proyecto con factores externos al equipo de obra, como la entrega de estructuras metálicas prefabricadas por parte de un proveedor o la obtención de una licencia o autorización municipal.
- Dependencias internas: están bajo el control del equipo de obra, como la relación entre el habilitado de acero y su colocación en el elemento estructural.

Asimismo, en el proceso de secuenciación se determinan los adelantos (leads) y retrasos (lags) entre actividades (Project Management Institute, 2017). Un adelanto permite que una actividad sucesora se anticipe respecto de su predecesora (por ejemplo, iniciar el cerco perimetral de obra dos semanas antes de concluir los trabajos preliminares), mientras que un retraso obliga a que transcurra un lapso de tiempo entre el fin o inicio de la predecesora y el inicio o fin de la sucesora, como el tiempo de curado del concreto (habitualmente entre 7 y 28 días, según la norma técnica aplicable) que debe transcurrir antes de retirar el encofrado o de aplicar cargas sobre un elemento estructural (Kerzner, 2022).

2.2.3.4. Estimar la duración de las actividades

Estimar la duración de las actividades consiste en determinar el tiempo necesario para completar cada tarea según los recursos disponibles, proporcionando información esencial para elaborar el cronograma del proyecto (Project Management Institute, 2017).

En proyectos de construcción, la estimación de la duración se ve influenciada por factores propios del sector, tales como el rendimiento de las cuadrillas (expresado habitualmente en unidades de obra por jornal, por ejemplo m^2 de encofrado por día-hombre, m^3 de concreto vaciado por día), la disponibilidad y capacidad de la maquinaria y el equipo, Las condiciones climáticas del lugar, la experiencia adquirida por el personal en tareas repetitivas y las limitaciones de acceso y espacio en la zona de trabajo. (Ministerio de Economía y Finanzas del Perú MEF, 2024).

El equipo de programación debe considerar la denominada ley de los rendimientos decrecientes, según la cual incrementar el número de recursos asignados a una actividad no siempre reduce su duración de manera proporcional, así como los efectos de la sobreasignación de personal en espacios de trabajo reducidos, típicos en obras de edificación en altura (Project Management Institute, 2017).

Estimación análoga

La estimación análoga calcula la duración o el costo de un proyecto a partir de datos históricos de proyectos similares, utilizando parámetros como el tiempo de ejecución, las dimensiones y la complejidad (Project Management Institute, 2017).

La estimación análoga se emplea frecuentemente en las etapas tempranas del proyecto, cuando se dispone de escasa información de detalle, por ejemplo, para estimar la duración total de una edificación multifamiliar a partir de la duración registrada en un proyecto anterior de características similares en área techada y número de pisos (Kerzner, 2022).

Se trata de un método de estimación de valor bruto, relativamente económico y rápido de aplicar, pero también el menos exacto de las técnicas descritas en este apartado; su fiabilidad depende directamente de que el proyecto de referencia sea efectivamente comparable en magnitud, complejidad técnica y contexto, y de que quien efectúa la estimación posea experiencia en obras de similares características (Project Management Institute, 2017).

Estimación paramétrica

La estimación paramétrica permite calcular la duración o el costo de una actividad mediante modelos estadísticos que relacionan datos históricos con parámetros del proyecto (Project Management Institute, 2017).

Por ejemplo, si el recurso asignado es capaz de instalar 25 metros de cable por hora, la duración requerida para instalar 1000 metros sería de 40 horas. Utilizada en los expedientes técnicos de obra a través de los denominados análisis de precios unitarios APU y sus rendimientos asociados contenidos en bases de datos como CAPECO o las propias bases de datos históricas de la empresa constructora, permite alcanzar niveles de exactitud superiores a los de la estimación análoga, siempre que se cuente con información confiable sobre rendimientos y con metrados verificados.

Estimación de tres puntos - PERT

La estimación de tres puntos o también conocida como técnica PERT (Program Evaluation and Review Technique), mejora la fidelidad de las estimaciones de duración de un único valor al incorporar la incertidumbre y el riesgo inherentes a la ejecución de obra (Project Management Institute, 2017). Esta técnica requiere una para cada actividad:

- Duración optimista (tO): duración estimada considerando el mejor escenario posible para la actividad.

- Duración más probable (tM): duración estimada en función de los recursos que probablemente se asignen, su productividad esperada y las condiciones normales de trabajo.
- Duración pesimista (tP): duración estimada considerando el peor escenario razonable (lluvias, retrasos en el suministro de materiales, ausentismo de personal, interferencias con otras partidas).

Adicionalmente y como complemento vigente y de uso extendido en la gestión de proyectos de construcción, heredado de la técnica PERT original desarrollada por la Marina de los Estados Unidos, suele emplearse la fórmula de distribución beta, que pondera con mayor peso la duración más probable y que en la práctica profesional actual continúa siendo la más recomendada cuando existe mayor certidumbre sobre el valor modal (Kerzner, 2022):

$$\mathbf{tE = (tO + 4tM + tP) / 6}$$

2.2.4. Contrato y tiempo de ejecución

Bajo la Ley General de Contrataciones Públicas (Ley N° 32069) y su Reglamento (D.S. N° 009-2025-EF), las reglas referidas al tiempo de ejecución contractual abarcan el inicio del cómputo, la vigencia del contrato, las prórrogas y la suspensión del plazo:

1. Vigencia del Contrato vs. Plazo de Ejecución

- Vigencia del Contrato: Inicia desde el día siguiente de la suscripción del documento o desde la notificación de la orden de compra o servicio. Su vigencia se extiende hasta que se emita la conformidad, el pago final o quede consentida la liquidación técnica-financiera.
- Plazo de Ejecución: Es el tiempo determinado en las bases para que el contratista cumpla con la entrega de bienes, servicios u obra.

2. Inicio del Cómputo del Plazo de Ejecución

El inicio varía según la tipología del contrato:

- Bienes y Servicios: Computa desde el día siguiente de la firma del contrato o notificación de la orden, salvo que en las bases se disponga una fecha de inicio sujeta a condición (ej. entrega del terreno o del anticipo).
- Obras (Solo construcción): No inicia automáticamente con la firma. Se requiere el cumplimiento de condiciones previas fijadas por la ley:
    - Notificación al contratista de la designación del inspector/supervisor.
    - Entrega total o parcial del terreno y canteras.
    - Entrega del expediente técnico de obra completo.
    - Entrega del adelanto directo de haber sido solicitado.
    - Obras bajo Diseño y Construcción:
    - Componente Diseño: Computa desde la suscripción del contrato.
    - Componente Ejecución de Obra: Computa desde la aprobación formal del expediente técnico elaborado.

3. Ampliación de Plazo

Permite extender el plazo de ejecución únicamente cuando ocurren hechos ajenos a la voluntad del contratista:

Causales:

- Caso fortuito o fuerza mayor acreditados.

- Demoras provocadas por la Entidad (ej. retraso en absolver consultas, demoras en aprobación de adicionales de obra).
- Efectos: Si se aprueba, se modifica el calendario de ejecución y genera el reconocimiento de incrementos en los gastos generales costos directos.

4. Suspensión del Plazo de Ejecución

- Ocurre cuando eventos extraordinarios paralizan la ejecución de las prestaciones sin que sea imputable a ninguna de las partes:
    - Acuerdo entre partes: La Entidad y el contratista acuerdan la suspensión del plazo de ejecución hasta que cese el evento.
    - Suspensión por culpa de la Entidad: Si la paralización obedece a causales imputables a la Entidad, la autoridad de la gestión administrativa puede autorizar la suspensión del plazo mientras se resuelve el problema, debiendo iniciarse el deslinde de responsabilidades administrativas.
- Consecuencia: Durante la suspensión no corren los plazos ni se aplican penalidades por mora.

5. Modificaciones contractuales que afectan el tiempo

- Adicionales de prestación: Si se autoriza un adicional de obra o servicio (hasta el límite legal del 25%), este debe incluir el plazo necesario para su ejecución, el cual amplía el plazo del contrato principal.
- Reducción de prestaciones: Si la Entidad reduce metas/prestaciones (hasta un 25%), el plazo de ejecución contractual puede ajustarse proporcionalmente.

2.2.4.1. Riesgos derivados del incumplimiento del tiempo de ejecución

En los textos y fragmentos de la Ley N.° 32069 (Ley General de Contrataciones Públicas) e información legal relevante abordada anteriormente, el incumplimiento del tiempo de ejecución genera los siguientes riesgos específicos estructurados según la normativa:

1. Aplicación Automática de Penalidades por Mora

- Afectación económica inmediata: El atraso injustificado genera una penalidad diaria calculada mediante fórmula matemática estipulada reglamentariamente.
- Toque o límite crítico (10%): La acumulación de penalidades por mora tiene un tope máximo equivalente al 10% del monto contractual vigente (o del ítem/tramo correspondiente).
- Descuento directo: El monto de la sanción económica se deduce de los pagos a cuenta, de las valorizaciones periódicas o de la liquidación final.

2. Obligación de Implementar un Calendario Acelerado de Obra

- Afectación a la operatividad: Cuando el avance físico acumulado se encuentra por debajo del porcentaje permitido frente al avance programado (atraso significativo), la Entidad exige al contratista presentar un calendario acelerado de obra.
- Sobrecosto operativo: Esto obliga a reestructurar frentes de trabajo, incrementar cuadrillas o turnos a costo del ejecutor para intentar recuperar el ritmo del proyecto.

3. Intervención Económica de la Obra

- Pérdida de control del flujo financiero: Si el contratista no acelera los trabajos o incumple el calendario reajustado, la Entidad puede disponer la intervención económica de la obra.

- Administración directa de fondos: La Entidad pasa a administrar directamente los fondos asignados al proyecto para evitar su paralización total, sin necesidad de resolver el contrato de inmediato.

4. Resolución del Contrato por Incumplimiento Imputable

- Causal directa por mora: Alcanzar el tope del 10% de penalidad por mora otorga a la Entidad la facultad legal de Extinguir el vínculo contractua.
- Causal por paralización: Se habilita la resolución contractual si el retraso o la paralización evidencian la imposibilidad del contratista de culminar la obra en el tiempo previsto.
- Ejecución de garantías: La resolución contractual conlleva la ejecución inmediata de la garantía de fiel cumplimiento por parte de la Entidad.

5. Infracciones Administrative y Sanciones (TCE)

- Inhabilitación para contratar: El incumplimiento del plazo que deriva en resolución contractual se tipifica como infracción grave ante el Tribunal de Contrataciones del Estado (TCE).
- Sanción al proveedor o consorcio: Puede resultar en una inhabilitación temporal (de 3 a 36 meses) o definitiva para participar en procesos de selección y contratar con cualquier entidad del Estado peruano.

2.2.5. Estándares y referencias internacionales de gestión

La gestión del plazo contractual: FIDIC, NEC e ISO

1. FIDIC

Los contratos FIDIC particularmente el Red Book (2017) abordan el plazo desde una estructura legal tradicional y reactiva, centrada en la asignación de riesgos, con el Ingeniero administrando la relación contractual entre el Empleador y el Contratista.

- Inicio del plazo: se computa desde la Commencement Date, notificada formalmente por el Ingeniero una vez cumplidas las condiciones previas.
- Plazo de ejecución (Time for Completion): obligación contractual del Contratista de completar las obras, o sus secciones (Milestones), dentro del período pactado.
- Gestión de demoras:
    - Extension of Time (EOT): el contrato reconoce circunstancias específicas de variaciones solicitadas por el Empleador, condiciones climáticas excepcionalmente adversas, mora de la Entidad que pueden dar derecho a una ampliación del plazo.
    - Cláusula de preclusión (Time-Bar): el Contratista pierde el derecho al reclamo si no notifica el evento dentro de los 28 días siguientes a haberlo detectado.
    - Delay Damages: penalidad pactada de antemano por cada día de retraso imputable al Contratista.

En síntesis: en FIDIC, el plazo contractual no es invariable; puede modificarse cuando ocurren eventos reconocidos contractualmente, siempre que se respeten los procedimientos de notificación establecidos.

2. Engineering and Construction Contract NEC3 - NEC4

El enfoque NEC es colaborativo y preventivo: el cronograma no es un simple anexo, sino una herramienta central de administración contractual y de gestión diaria del proyecto.

- Completion Date: fecha contractual de terminación que el Contratista está obligado a cumplir. Pueden establecerse también fechas de terminación por secciones y Key Dates; su incumplimiento puede generar daños o dar lugar a la recuperación de costos por parte del cliente.
- Programa Aceptado (Accepted Programme): documento central del contrato, que refleja la ruta crítica, los recursos, la flota y las fechas clave. Se actualiza periódicamente (por lo general, mensualmente) y requiere la aprobación formal del Project Manager. Se utiliza como referencia para evaluar el efecto de determinados eventos sobre la fecha de terminación.
- Gestión de demoras:
    - Early Warning Notice: obliga a cualquiera de las partes a notificar de inmediato todo evento que pueda impactar el plazo, antes de que el retraso se materialice.
    - Compensation Events: unifican en un solo procedimiento los reclamos de tiempo y costo; cuando corresponde contractualmente, modifican tanto el precio como la fecha de terminación, evaluando su impacto directo sobre el Accepted Programme.

En síntesis: NEC concibe el plazo como una obligación contractual gestionada de forma dinámica a través de un programa vivo, que vincula explícitamente:

1. El cronograma.
2. Los eventos de obra.

3. Los retrasos.
4. La fecha real de terminación.
5. El cumplimiento o incumplimiento contractual.

3. Estándares ISO (ISO 21502 e ISO 9001)

ISO 21502:2020 (Project, programme and portfolio management - Guidance on project management) ofrece directrices generales de gestión de proyectos, aplicables con independencia del tamaño, la complejidad o la modalidad de ejecución. Aborda el control del tiempo mediante el desglose del trabajo (EDT o WBS), la estimación de duraciones y el monitoreo del avance frente a los hitos planificados. El contrato se enmarca dentro de la gobernanza del proyecto, como la formalización del alcance acordado entre las partes. A diferencia de NEC y FIDIC, no establece derechos contractuales específicos sobre ampliaciones de plazo, penalidades o compensaciones.

ISO 9001:2015 (cláusulas 8.4 y 8.5): el contrato equivale al conjunto de requisitos del cliente, que deben revisarse antes de la provisión del servicio o de la ejecución de la obra. El cumplimiento del plazo de entrega es un criterio directo de calidad, y su incumplimiento se considera una no conformidad.

En síntesis: ISO trata el plazo como un requisito de conformidad y desempeño dentro del sistema de gestión, con un enfoque orientado a la planificación y el control, más que a la asignación contractual de riesgos.

2.2.6. Inteligencia Artificial y Machine Learning

La Inteligencia Artificial (IA) constituye el campo de la informática orientado al diseño de sistemas capaces de exhibir comportamientos que en el ser humano no se asocian a procesos cognitivos como el reconocimiento de patrones, la toma de decisiones y la predicción de

resultados (Moroney, 2020). Dentro de este campo amplio Machine Learning (ML) se define como el subconjunto de técnicas que permiten a un sistema mejorar su desempeño en una tarea específica a partir de la exposición a datos, sin que sus reglas de decisión sean programadas de manera explícita por un desarrollador (Serrano & Thrun, 2021).

Mientras un programa convencional aplica una lógica condicional codificada manualmente por un experto, un modelo de ML infiere dicha lógica a partir de ejemplos históricos, ajustando internamente una función matemática que relaciona un conjunto de variables de entrada con una salida observada (Serrano & Thrun, 2021).

Geron (2026) sostiene que este enfoque resulta particularmente ventajoso frente a la programación tradicional en problemas donde las reglas de decisión son numerosas, cambiantes en el tiempo o difíciles de formalizar de manera explícita mediante heurísticas fijas, condición que se cumple en el sector construcción, donde la duración de ejecución de una partida de obra depende de la interacción simultánea de variables técnicas (metrado, complejidad de la partida), logísticas (disponibilidad de recursos y cuadrillas) y de gestión (planificación, rendimiento del contratista), cuya relación funcional con el tiempo de ejecución no admite una formalización manual exhaustiva.

En términos operativos, el aprendizaje automático puede entenderse como un proceso de aprendizaje inductivo: el algoritmo recibe un conjunto de ejemplos (observaciones históricas) y ajusta los parámetros internos de un modelo hasta que este generaliza el comportamiento observado a casos nuevos no vistos durante el entrenamiento (Moroney, 2020).

2.2.7. Aprendizaje supervisado y el problema de regresión

Dentro de las distintas categorías en que se clasifica el Machine Learning, el aprendizaje supervisado se define como el paradigma en el cual el algoritmo aprende a partir de un conjunto de datos etiquetados, es decir observaciones para las cuales se conoce tanto el vector de

variables de entrada o características (features) como el valor de salida esperado o variable objetivo (target) (Yehoshua, 2026). El objetivo del algoritmo consiste en aproximar una función que relacione las entradas con la salida, de modo que, una vez entrenado, el modelo sea capaz de predecir el valor del target para observaciones nuevas cuya etiqueta real es desconocida. Serrano & Thrun (2021) precisa que esta aproximación se logra mediante un proceso iterativo de minimización de una función de error o función de pérdida (loss function), la cual cuantifica la discrepancia entre los valores predichos por el modelo y los valores reales observados en el conjunto de entrenamiento.

El aprendizaje supervisado se subdivide, a su vez en dos grandes familias en función de la naturaleza de la variable objetivo. En los problemas de clasificación, el target corresponde a una variable categórica o discreta, y el modelo predice la clase a la que pertenece cada observación; en los problemas de regresión, en cambio el target es una variable numérica continua y el modelo predice un valor cuantitativo sobre una escala real (Geron, 2026).

Esta clasificación resulta determinante para el problema abordado en la presente investigación. La variable objetivo del modelo desarrollado, denominada DURACION_TOTAL_DIAS (una variable que representa la duración de una actividad, tarea o en el ámbito peruano de construcción del Perú como partida), corresponde al número de días que insume la ejecución de una partida de obra, expresada como una magnitud numérica continua que puede adoptar cualquier valor positivo dentro de un rango razonable de duraciones, y no un conjunto finito y predefinido de categorías. En consecuencia, el problema abordado se enmarca inequívocamente dentro del aprendizaje supervisado de tipo regresión (Geron, 2026).

2.2.8. El proceso o pipeline de un proyecto de Machine Learning

El desarrollo de un modelo de aprendizaje automático no constituye un procedimiento puntual de ajuste de un algoritmo sobre un conjunto de datos, sino un proceso iterativo compuesto por

múltiples etapas interdependientes, cuya ejecución ordenada resulta determinante para obtener un modelo confiable, generalizable y adecuado al problema de negocio que se pretende resolver (Huyen, 2022). Geron (2026) formaliza este proceso mediante una lista de verificación de ocho pasos ampliamente adoptada como referencia metodológica en proyectos aplicados de ML que comprende:

1. Enmarcar el problema y definir el objetivo de negocio (frame the problem)
2. Obtener los datos (get the data).
3. Explorar los datos para comprender su estructura y detectar patrones (exploratory data analysis).
4. Preparar los datos para exponer mejor los patrones subyacentes a los algoritmos de aprendizaje (prepare the data).
5. Explorar distintas familias de modelos y seleccionar las más prometedoras (explore many different models).
6. Afinar los modelos seleccionados mediante la optimización de sus hiperparámetros (fine-tune).
7. Presentar la solución obtenida, comunicando sus resultados, limitaciones y supuestos.
8. Lanzar, monitorear y mantener el sistema en producción.

Esta secuencia constituye la columna vertebral metodológica sobre la cual se estructura la presente investigación, en la medida en que cada uno de los capítulos posteriores de la tesis se corresponde con una de las etapas descritas por Géron 2022: el planteamiento del problema de estimación de duración de partidas como caso de regresión (Aprendizaje supervisado y el problema de regresión), la recolección y comprensión del histórico de obras (get the data y EDA), el preprocesamiento y la ingeniería de variables (Preparación y preprocesamiento de

datos), la exploración comparativa de familias de algoritmos (Algoritmos de regresión utilizados), la optimización de hiperparámetros mediante validación cruzada agrupada ("Validación cruzada y prevención de sobreajuste" y "Optimización de hiperparámetros"), y finalmente, la evaluación e interpretación del modelo final (Métricas de evaluación para regresión, Interpretabilidad del modelo y Análisis de residuos y validación de supuesto).

(Huyen, 2022) complementa este marco al enfatizar que el proceso de construcción de un sistema de ML es intrínsecamente iterativo y no lineal: los hallazgos obtenidos en etapas posteriores, por ejemplo, la observación de un patrón de subajuste en la etapa de evaluación con frecuencia obligan a retroceder y reformular decisiones tomadas en etapas anteriores, como la ingeniería de variables o la propia definición del problema.

Tranquillin (2024) señalan que, en contextos productivos, este ciclo se inserta dentro de una arquitectura de datos y de plataforma más amplia, que debe garantizar la trazabilidad, reproducibilidad y escalabilidad del proceso de entrenamiento.

2.2.9. Preparación y preprocesamiento de datos

La calidad y la representación de los datos de entrada condicionan, en mayor medida que la sofisticación del algoritmo empleado, el desempeño final de un modelo de Machine Learning (Zheng & Casari, 2018). Por esta razón, la etapa de preparación de datos constituye una fase central del pipeline descrito en El proceso o pipeline de un proyecto de Machine Learning, y comprende, entre otras tareas, el tratamiento de valores faltantes, el escalado de variables numéricas, la codificación de variables categóricas, la construcción de variables derivadas (feature engineering) y la identificación de valores atípicos.

2.2.10. Algoritmos de regresión utilizados

Una vez preparados los datos conforme a lo descrito en la sección precedente, el paso siguiente del pipeline metodológico consiste en la exploración comparativa de distintas familias de algoritmos de regresión (Huyen, 2022).

Con el propósito de identificar aquellas que exhiben el mejor equilibrio entre capacidad predictiva, robustez frente a los supuestos de los datos disponibles y facilidad de interpretación. A continuación, se presenta el sustento teórico de cada familia de algoritmos evaluada en la presente investigación, otorgando mayor profundidad conceptual a aquellas que, por su desempeño empírico, conforman el conjunto final de modelos seleccionados (shortlist) y las estrategias de ensamblado descritas en la sección "Métodos ensemble avanzados".

2.2.10.1. Modelos lineales clásicos

La regresión lineal constituye el algoritmo de referencia dentro de los modelos de regresión, al asumir que la variable objetivo puede expresarse como una combinación lineal ponderada de las variables predictoras, cuyos coeficientes se estiman minimizando La suma de las diferencias al cuadrado entre los valores estimados y los valores reales (Raschka et al., 2022). Su principal virtud reside en la interpretabilidad directa de sus coeficientes; sin embargo, resulta susceptible al sobreajuste cuando el número de variables predictoras es elevado o cuando estas presentan colinealidad entre sí.

Para mitigar dicha limitación, se emplean variantes regularizadas que incorporan un término de penalización sobre la magnitud de los coeficientes dentro de la función objetivo. La regresión Ridge penaliza la suma de los coeficientes al cuadrado (norma L2), reduciendo su magnitud sin llevarlos exactamente a cero, lo que atenúa la varianza del modelo frente a la colinealidad; la regresión Lasso penaliza la suma de los valores absolutos de los coeficientes (norma L1), propiedad que induce coeficientes exactamente nulos y, por tanto, realiza una

selección implícita de variables; y ElasticNet combina ambas penalizaciones, aprovechando simultáneamente la estabilidad de Ridge y la capacidad de selección de variables de Lasso (Smolyakov, 2024).

Adicionalmente, dado que los estimadores de mínimos cuadrados ordinarios son altamente sensibles a la presencia de valores atípicos los cuales, al elevarse al cuadrado en la función de pérdida, ejercen una influencia desproporcionada sobre el ajuste, se consideran variantes de regresión robusta, entre ellas el estimador de Huber, que combina una penalización cuadrática para residuos pequeños con una penalización lineal para residuos grandes, atenuando así la influencia de las observaciones extremas; RANSAC (Random Sample Consensus), que ajusta el modelo iterativamente sobre subconjuntos aleatorios de datos identificados como consistentes (inliers), descartando explícitamente los valores atípicos; y el estimador de Theil-Sen, basado en la mediana de las pendientes calculadas entre todos los pares de observaciones, cuya propiedad de alto punto de ruptura lo hace especialmente resistente frente a la contaminación por outliers (Smolyakov, 2024). Esta familia de modelos robustos resulta particularmente pertinente para el problema de duración de partidas, en el cual la presencia de registros atípicos originados en condiciones de ejecución excepcionales no puede descartarse por completo pese al tratamiento descrito en la sección “Preparación y preprocesamiento de datos”.

2.2.10.2. Modelos basados en vecinos (KNN)

El algoritmo de los k-vecinos más cercanos (K-Nearest Neighbors, KNN) constituye un método de aprendizaje no paramétrico que predice el valor de una nueva observación a partir del promedio o promedio ponderado del valor del target de sus k observaciones más próximas en el espacio de variables, según una métrica de distancia previamente definida, típicamente la distancia euclidiana (Smolyakov, 2024). Al no asumir una forma funcional predeterminada

para la relación entre las variables predictoras y el target, el KNN es capaz de capturar relaciones no lineales complejas; no obstante, su desempeño depende críticamente del escalado previo de las variables justificando la necesidad del preprocesamiento descrito en la sección "Preparación y preprocesamiento de datos" y su costo computacional crece de manera considerable con el tamaño del conjunto de datos, dado que requiere calcular la distancia entre cada nueva observación y la totalidad de los ejemplos de entrenamiento.

2.2.10.3. Máquinas de Vectores de Soporte para regresión (SVR)

Las Máquinas de Vectores de Soporte (SVM), originalmente formuladas para problemas de clasificación, se extienden al caso de regresión (Support Vector Regression, SVR) mediante la definición de un margen de tolerancia ε alrededor de la función de predicción, dentro del cual los errores no se penalizan; únicamente las observaciones cuya predicción se aleja del valor real en más de ε contribuyen a la función de pérdida (Smolyakov, 2024). Esta formulación otorga al SVR una notable robustez frente a pequeñas variaciones en los datos. Mediante el uso de funciones núcleo (kernels) como el núcleo radial (RBF) el SVR puede proyectar implícitamente las variables de entrada a un espacio de mayor dimensionalidad, permitiendo capturar relaciones no lineales entre las variables predictoras y la duración de la partida sin necesidad de especificar explícitamente dicha transformación.

2.2.10.4. Árboles de decisión

Los árboles de decisión aplicados a problemas de regresión particionan de manera recursiva el espacio de variables predictoras en regiones progresivamente más homogéneas respecto de la variable objetivo, seleccionando en cada nodo la variable y el punto de corte que maximizan la reducción de la varianza o del error cuadrático del target dentro de los subconjuntos resultantes; la predicción para una nueva observación corresponde al promedio del target de las observaciones de entrenamiento que caen en la misma región terminal (hoja) del árbol (Geron,

2026). Su principal ventaja radica en la interpretabilidad de la estructura jerárquica resultante y en su capacidad para capturar interacciones y no linealidades sin requerir transformaciones previas de las variables; su principal limitación es una elevada varianza, esto es, una alta sensibilidad de la estructura del árbol a pequeñas variaciones en los datos de entrenamiento, lo que los hace propensos al sobreajuste cuando se permite que crezcan sin restricción de profundidad. Esta limitación constituye la motivación teórica directa de los métodos de ensamblado descritos a continuación.

2.2.10.5. Métodos de ensamblado por Bagging

El bagging (bootstrap aggregating) es una técnica de ensamblado que busca reducir la varianza de un modelo base inestable como el árbol de decisión descrito en la sección anterior mediante el entrenamiento de múltiples instancias de dicho modelo sobre distintas muestras bootstrap (muestras aleatorias con reemplazo) del conjunto de entrenamiento, y la posterior agregación de sus predicciones individuales mediante el promedio (Babushkin & Kravchenko, 2025). El Random Forest constituye la implementación más difundida de este principio aplicada a árboles de decisión, incorporando además una fuente adicional de aleatoriedad: en cada división de cada árbol, el algoritmo evalúa únicamente un subconjunto aleatorio de las variables predictoras disponibles, lo que decorrelaciona los árboles individuales del bosque y potencia la reducción de varianza lograda por el bagging. Los Extra Trees (Extremely Randomized Trees) llevan este principio un paso más allá, al seleccionar de manera aleatoria no solo el subconjunto de variables, sino también el punto de corte dentro de cada variable, lo que incrementa aún más la aleatoriedad del ensamble a cambio de un ligero aumento del sesgo, a la par que reduce el costo computacional de entrenamiento (Babushkin & Kravchenko, 2025).

2.2.10.6.Métodos de ensamblado por Boosting

A diferencia del bagging, que entrena modelos base de manera independiente y en paralelo, el boosting construye una secuencia de modelos débiles de manera aditiva y secuencial, donde cada nuevo modelo se entrena para corregir los errores cometidos por el ensamble acumulado hasta el paso anterior (López de Prado, 2018). En el Gradient Boosting, esta corrección se formaliza como un procedimiento de descenso de gradiente en el espacio de funciones: en cada iteración, un nuevo árbol de decisión típicamente poco profundo se ajusta sobre los residuos o, de manera más general, sobre el gradiente negativo de la función de pérdida del ensamble actual, y su predicción se añade al modelo acumulado ponderada por una tasa de aprendizaje (learning rate) que controla la contribución de cada árbol individual y, con ello, el riesgo de sobreajuste.

López de Prado (2018) señala que los métodos de boosting resultan particularmente eficaces en problemas con relaciones no lineales complejas y con interacciones de alto orden entre variables como las que se presentan en fenómenos financieros y, de manera análoga, en procesos productivos afectados por múltiples factores concurrentes, dado que la naturaleza aditiva y secuencial del algoritmo le permite capturar progresivamente patrones residuales que un único árbol no alcanzaría a modelar.

Sobre esta base conceptual se han desarrollado implementaciones optimizadas ampliamente utilizadas en la práctica: XGBoost incorpora regularización explícita de la complejidad de los árboles dentro de su función objetivo, así como optimizaciones de cómputo mediante aproximaciones de segundo orden (expansión de Taylor) del gradiente, lo que mejora tanto su velocidad de entrenamiento como su capacidad de generalización (Chang, 2024).

LightGBM introduce una estrategia de crecimiento de árboles por hoja (leaf-wise) en lugar de por nivel (level-wise), junto con técnicas de muestreo (Gradient-based One-Side Sampling) y

agrupamiento de variables exclusivas (Exclusive Feature Bundling) que aceleran considerablemente el entrenamiento sobre conjuntos de datos de gran tamaño o alta dimensionalidad; y CatBoost incorpora un tratamiento nativo y estadísticamente robusto de variables categóricas mediante codificación basada en estadísticos ordenados (ordered target statistics) que reduce el riesgo de fuga de información asociado a la codificación categórica tradicional y mitiga el sesgo de predicción característico del boosting (Kanungo, 2023).

Dada su consistente superioridad empírica en problemas tabulares de naturaleza heterogénea como el que aborda la presente investigación, que combina variables numéricas, categóricas y derivadas, los algoritmos de boosting constituyen el eje central de la exploración de modelos realizada en este trabajo.

2.2.10.7. Redes neuronales (Perceptrón Multicapa)

El Perceptrón Multicapa (Multi-Layer Perceptron, MLP) constituye la arquitectura fundamental de las redes neuronales artificiales aplicadas a problemas de regresión, compuesta por una capa de entrada, varias capas ocultas con neuronas interconectadas y una capa de salida, en la cual cada neurona aplica una combinación lineal ponderada de sus entradas seguida de una función de activación no lineal (Moroney, 2020). La presencia de funciones de activación no lineales entre capas permite al MLP aproximar relaciones funcionales arbitrariamente complejas entre las variables predictoras y el target, a costa de una menor interpretabilidad directa respecto de los modelos lineales o de árboles, y de requerir, generalmente, un mayor volumen de datos y un cuidadoso escalado previo de las variables de entrada para converger de manera estable durante el entrenamiento por descenso de gradiente.

2.2.10.8. Modelos gaussianos y probabilísticos

Los modelos de regresión de proceso gaussiano (Gaussian Process Regression) constituyen un enfoque bayesiano no paramétrico que, en lugar de estimar un único conjunto de parámetros

óptimos, define una distribución de probabilidad sobre el espacio de funciones posibles capaces de explicar los datos observados, actualizando dicha distribución conforme se incorpora nueva evidencia (Kanungo, 2023). Una propiedad distintiva de este enfoque, relevante para la presente investigación, es su capacidad de proporcionar de manera nativa una cuantificación de la incertidumbre asociada a cada predicción expresada como la varianza de la distribución posterior, lo que permite no solo predecir la duración esperada de una partida, sino también estimar el grado de confianza de dicha predicción en función de la disponibilidad y similitud de los datos históricos utilizados para el entrenamiento.

2.2.10.9. Modelos Lineales Generalizados (GLM)

Los Modelos Lineales Generalizados (Generalized Linear Models, GLM) extienden el marco de la regresión lineal clásica al permitir que la variable objetivo siga una distribución de probabilidad distinta a la normal, y que la relación entre dicha distribución y el predictor lineal se establezca a través de una función de enlace (link function) (Danka, 2025). Esta generalización resulta especialmente pertinente cuando la variable objetivo, por su naturaleza, no admite valores negativos o presenta una distribución marcadamente asimétrica con condiciones que se cumplen habitualmente en variables de tipo duración o conteo, como la variable DURACION_TOTAL_DIAS empleada en esta investigación. La regresión de Poisson resulta apropiada para variables de conteo con distribución asimétrica hacia la derecha; la regresión Gamma, definida sobre valores estrictamente positivos y con varianza proporcional al cuadrado de la media, resulta adecuada para variables continuas y positivas como tiempos o duraciones; y la distribución Tweedie generaliza ambos casos mediante un parámetro de potencia que permite modelar de manera flexible variables con una masa de probabilidad concentrada en valores bajos y una cola derecha extendida, patrón frecuentemente observado en la duración de partidas de obra, donde la mayoría de las partidas se ejecuta en plazos

relativamente cortos, mientras que un subconjunto reducido se extiende considerablemente en el tiempo.

2.2.10.10. Ensambles combinados: Stacking y Voting Regressor

Como complemento a los métodos de ensamblado homogéneo descritos en las secciones "Métodos de ensamblado por Bagging" y "Métodos de ensamblado por Boosting" que combinan múltiples instancias de un mismo tipo de modelo base, el Voting Regressor y el Stacking Regressor constituyen estrategias de ensamblado heterogéneo, que combinan las predicciones de modelos de naturaleza distinta (por ejemplo, un modelo lineal regularizado, un ensamble de boosting y una red neuronal) con el objetivo de capturar patrones complementarios que un único algoritmo no alcanzaría a modelar por sí solo (Babushkin & Kravchenko, 2025). El desarrollo teórico y la implementación de estas estrategias se profundizan en la sección "Métodos ensemble avanzados", en la medida en que constituyen la etapa final del proceso de modelamiento, aplicada sobre el subconjunto de algoritmos que exhiben el mejor desempeño individual tras las etapas de validación cruzada y optimización de hiperparámetros descritas en las secciones "Validación cruzada y prevención de sobreajuste" y "Optimización de hiperparámetros".

2.2.11. Validación cruzada y prevención de sobreajuste

El desempeño de un modelo de Machine Learning debe evaluarse en función de su capacidad de generalización a datos no observados durante el entrenamiento, y no en función de su ajuste al propio conjunto de entrenamiento. Cuando un modelo captura no solo los patrones genuinos presentes en los datos, sino también el ruido idiosincrático de la muestra de entrenamiento, se dice que incurre en sobreajuste (overfitting), lo que evidencia un rendimiento considerablemente mayor en los datos de entrenamiento que en los datos de prueba; el fenómeno inverso, en el cual el modelo carece de la capacidad suficiente para capturar los

patrones relevantes incluso dentro del propio conjunto de entrenamiento, se denomina subajuste (underfitting) (Huyen, 2022). La adecuada gestión de este equilibrio conocido en la literatura como el compromiso sesgo-varianza (bias-variance tradeoff) constituye uno de los objetivos centrales de la etapa de validación del modelo.

La validación cruzada (cross-validation) constituye la técnica estándar para estimar la capacidad de generalización de un modelo sin comprometer la totalidad de los datos disponibles en una única partición de prueba. En su forma más general la validación cruzada de k particiones (k-fold cross-validation), Los datos se dividen en k subconjuntos similares; en cada iteración, el modelo se entrena con k-1 subconjuntos y se evalúa con el restante. Finalmente, se promedian los resultados para obtener una evaluación más estable y menos dependiente de una única división de los datos (Huyen, 2022).

No obstante, López de Prado (2018) advierte que la validación cruzada convencional puede inducir estimaciones de desempeño excesivamente optimistas y por tanto, engañosas cuando existe dependencia estructural entre observaciones que, en apariencia, resultan independientes, situación que el autor documenta extensamente para el caso de series financieras, en las cuales observaciones temporalmente cercanas comparten información y su distribución no aleatoria entre los conjuntos de entrenamiento y prueba genera fuga de información (leakage).

2.2.12. Optimización de hiperparámetros

A diferencia de los parámetros de un modelo, que se ajustan automáticamente durante el entrenamiento a partir de los datos (por ejemplo, los coeficientes de una regresión lineal), los hiperparámetros son configuraciones del algoritmo que deben definirse antes del entrenamiento y que controlan su comportamiento y su capacidad, por ejemplo, la profundidad máxima de un árbol de decisión, el número de estimadores de un ensamble, o la tasa de aprendizaje de un algoritmo de boosting. La correcta selección de estos hiperparámetros tiene un impacto directo

sobre el equilibrio sesgo-varianza descrito en la sección “, y su búsqueda constituye una etapa formal del pipeline de ML (Huyen, 2022).

La búsqueda exhaustiva en malla (Grid Search) evalúa el desempeño del modelo para la totalidad de las combinaciones posibles dentro de un espacio discreto de hiperparámetros previamente definido; si bien garantiza la exploración completa de dicho espacio, su costo computacional crece de manera exponencial con el número de hiperparámetros considerados y con la granularidad de sus rangos, resultando impracticable para modelos con múltiples hiperparámetros como los algoritmos de boosting descritos en la sección 5.6, que involucran simultáneamente la tasa de aprendizaje, el número de estimadores, la profundidad de los árboles y los términos de regularización, entre otros. La búsqueda aleatoria (Randomized Search) constituye una alternativa que, en lugar de evaluar todas las combinaciones posibles, muestrea de manera aleatoria un número predefinido de combinaciones dentro del espacio de hiperparámetros definido, para cada hiperparámetro, mediante una distribución de probabilidad o un conjunto discreto de valores, lo cual permite explorar un espacio de búsqueda considerablemente más amplio dentro de un presupuesto computacional fijo (Lakshmanan et al., 2020).

La superioridad práctica de la búsqueda aleatoria frente a la búsqueda en malla, en presencia de espacios de alta dimensionalidad, se sustenta en que no todos los hiperparámetros influyen en igual medida sobre el desempeño del modelo: cuando algunos hiperparámetros resultan poco influyentes, la búsqueda en malla desperdicia una proporción considerable de sus evaluaciones explorando variaciones irrelevantes de dichos hiperparámetros, mientras que la búsqueda aleatoria, al muestrear de manera independiente cada dimensión, garantiza una cobertura más eficiente de los hiperparámetros efectivamente relevantes (Lakshmanan et al., 2020). Por esta razón, la presente investigación emplea RandomizedSearchCV, combinando la búsqueda aleatoria de hiperparámetros con el esquema de validación cruzada agrupada

(GroupKFold) descrito en la sección “Validación cruzada y prevención de sobreajuste”, de modo que cada combinación de hiperparámetros evaluada se valida bajo el mismo criterio de independencia entre obras aplicado a la evaluación final del modelo. El espacio de búsqueda se define de manera específica para cada familia de algoritmos, considerando los hiperparámetros de mayor incidencia empírica documentados en la literatura para cada modelo, por ejemplo, la fuerza de regularización (alpha) en los modelos lineales penalizados, el número de vecinos (k) en KNN, o la profundidad máxima y la tasa de aprendizaje en los algoritmos de boosting (Chang, 2024).

2.2.13. Métricas de evaluación para regresión

En los modelos de Machine Learning orientados a problemas de regresión la evaluación del modelo permite medir la precisión de las predicciones en relación con los valores reales observados. Para ello se emplean métricas que cuantifican el error de predicción desde diferentes perspectivas. En la presente investigación se consideran las métricas Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), coeficiente de determinación (R^2) y Mean Absolute Percentage Error (MAPE), debido a que permiten evaluar de manera complementaria la precisión del modelo predictivo utilizado para estimar la duración (Danka, 2025).

Sea y_i el valor real observado, $\hat{y}_i$ el valor estimado por el modelo y n el número total de observaciones evaluadas. El error o residuo de predicción para cada observación se expresa como:

$$e_i = y_i - \hat{y}_i$$

Este residuo representa la diferencia entre el valor real y el valor predicho. Un residuo cercano a cero indica que la predicción se aproxima al valor observado, mientras que un residuo de mayor magnitud evidencia un mayor error de estimación.

1. Error cuadrático medio de la raíz (RMSE)

El Root Mean Squared Error (RMSE), o raíz del error cuadrático medio, mide la magnitud promedio de los errores de predicción expresada en las mismas unidades de la variable objetivo.

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

La expresión se interpreta en tres etapas. Primero, se calcula la diferencia entre el valor real y el valor predicho:

$$y_i - \hat{y}_i$$

Luego, cada diferencia se eleva al cuadrado:

$$(y_i - \hat{y}_i)^2$$

El propósito de elevar los errores al cuadrado es evitar que los errores positivos y negativos se compensen entre sí y, además, otorgar mayor peso a los errores de gran magnitud. Posteriormente, se calcula el promedio de estos errores cuadrados y finalmente se obtiene su raíz cuadrada para retornar a las unidades originales de la variable.

En el contexto de esta investigación, si la variable objetivo corresponde a la duración de una actividad en días, el RMSE también se expresa en días. Por ejemplo, un RMSE de 3 días indica que el modelo presenta, aproximadamente, un nivel de error de predicción de 3 días, considerando el efecto amplificado de los errores grandes.

Por tanto, un RMSE menor representa un mejor desempeño predictivo. Esta métrica resulta especialmente útil cuando se desea penalizar de manera significativa las predicciones que presentan errores elevados.

2. Error absoluto medio (MAE)

El Mean Absolute Error (MAE) o error absoluto medio, representa la magnitud promedio de los errores de predicción sin considerar su signo.

$$MAE = \frac{1}{n} * \sum_{i=1}^{n} |y_i - \hat{y}_i|^2$$

En primer lugar, se obtiene el error entre el valor observado y el valor predicho. Posteriormente, se aplica el valor absoluto, representado por | |, con la finalidad de convertir todos los errores en valores positivos. Finalmente, estos errores absolutos se suman y se dividen entre el número total de observaciones.

A diferencia del RMSE, el MAE no eleva los errores al cuadrado, por lo que todos los errores tienen un peso proporcional a su magnitud. En consecuencia, esta métrica es menos sensible a valores con errores extremadamente elevados.

Por ejemplo, si un modelo presenta un MAE de 2.5 días, significa que, en promedio, sus predicciones se encuentran a aproximadamente 2.5 días de los valores reales, independientemente de si la predicción sobreestima o subestima la duración.

Al igual que en el RMSE, valores menores de MAE indican un mejor desempeño. Su principal ventaja para esta investigación es que proporciona una interpretación directa del error promedio en días.

3. Coeficiente de determinación (R^2)

El coeficiente de determinación R^2 permite determinar qué proporción de la variabilidad observada en la variable objetivo puede ser explicada por el modelo.

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

donde:

y_i: valor real de la observación ii.

$\hat{y}_i$: valor predicho por el modelo.

$\bar{y}$: promedio de los valores reales.

n: número de observaciones.

La fórmula compara dos componentes. El numerador:

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

representa la variabilidad que permanece sin explicar por el modelo, es decir, el error cuadrático total de las predicciones.

El denominador:

$$\sum_{i=1}^{n}(y_i - \bar{y})^2$$

representa la variabilidad total existente en los valores observados, calculada respecto de su promedio.

Por esta razón, R^2 establece una comparación entre el desempeño del modelo y una situación de referencia en la que las predicciones fueran simplemente iguales al promedio de los valores observados.

En términos generales, un valor de R^2 cercano a 1 indica que el modelo explica una proporción elevada de la variabilidad de la variable objetivo. Por ejemplo:

$$R^2 = 0.80 R^2 = 0.80$$

Esto indica que el modelo explica aproximadamente el 80 % de la variabilidad de la variable objetivo en el conjunto de datos evaluado.

Sin embargo, R^2 no representa directamente un porcentaje de precisión ni un porcentaje de error. Por ello, debe analizarse conjuntamente con métricas como RMSE y MAE.

4. Error porcentual absoluto medio (MAPE)

El Mean Absolute Percentage Error (MAPE), o error porcentual absoluto medio, expresa el error promedio de las predicciones en términos porcentuales.

$$MAPE = \frac{100}{n} * \sum_{i=1}^{n} \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

La fórmula divide el error absoluto de cada observación entre su correspondiente valor real yiy_i. De esta manera, el error deja de expresarse en unidades absolutas y pasa a representar una proporción respecto del valor observado. Finalmente, se obtiene el promedio de dichos errores relativos y se multiplica por 100 para expresarlo como porcentaje.

Por ejemplo, un MAPE de:

$$MAPE = 10\%$$

indica que, en promedio, las predicciones presentan un error absoluto equivalente al 10 % del valor real observado.

Una ventaja importante del MAPE es que facilita la interpretación del error y permite comparar el desempeño entre variables o conjuntos de datos con diferentes escalas. Sin embargo, presenta una limitación importante: no es apropiado cuando los valores reales son iguales o muy cercanos a cero, debido a que el valor real aparece en el denominador.

Esta consideración es particularmente importante cuando se trabaja con duraciones de actividades, ya que deben excluirse o tratarse adecuadamente las observaciones cuyo valor real sea cero antes de calcular esta métrica.

2.2.14. Interpretabilidad del modelo

La complejidad de los algoritmos de ensamblado descritos en la sección "Algoritmos de regresión utilizados" en particular, de los métodos de boosting conlleva una reducción de su interpretabilidad directa respecto de un modelo lineal simple, en la medida en que la predicción final resulta de la combinación aditiva de cientos o miles de árboles individuales, lo que impide identificar a simple vista la contribución de cada variable predictora sobre la predicción. Sin embargo, en aplicaciones de ingeniería con implicancias sobre decisiones de planificación de obra, la interpretabilidad del modelo no constituye un aspecto accesorio, sino un requisito para validar que las relaciones aprendidas por el modelo resultan consistentes con el conocimiento técnico del dominio (Lakshmanan et al., 2021).

La importancia de variables (Feature Importance) nativa de los modelos basados en árboles se calcula, típicamente, como la reducción acumulada de la función de pérdida o de la impureza atribuible a cada variable a lo largo de todas las divisiones en las que dicha variable fue utilizada dentro del ensamble. Si bien esta métrica ofrece una primera aproximación computacionalmente económica a la relevancia relativa de cada predictor,

Tan Wei Hao et al. (2026) advierten que tiende a sobrestimar sistemáticamente la importancia de variables numéricas continuas o de alta cardinalidad, dado que estas ofrecen un mayor número de puntos de corte potenciales durante la construcción del árbol, lo que introduce un sesgo en la comparación de importancia entre variables de naturaleza distinta.

Como alternativa más robusta, la importancia por permutación (Permutation Importance) evalúa la relevancia de una variable midiendo la degradación del desempeño del modelo

previamente entrenado cuando los valores de dicha variable se permutan aleatoriamente entre las observaciones del conjunto de evaluación, rompiendo deliberadamente su relación con la variable objetivo mientras se preserva la distribución marginal de la propia variable y de las demás (Jansen, 2020). Este enfoque presenta una ventaja teórica sustantiva frente a la importancia nativa de los árboles: al evaluarse directamente sobre el desempeño predictivo del modelo y no sobre estadísticos internos del proceso de construcción de los árboles resulta agnóstico respecto del algoritmo empleado, aplicable por igual a modelos lineales, de ensamblado o de redes neuronales, y no se encuentra sesgado por la cardinalidad o el tipo de la variable evaluada, constituyendo así una medida más fiel de la contribución real de cada predictor sobre la capacidad de generalización del modelo.

2.2.15. Análisis de residuos y validación de supuestos

El residuo de una observación se define como la diferencia entre el valor real de la variable objetivo y el valor predicho por el modelo para dicha observación. El análisis sistemático de la distribución de los residuos en función de las variables predictoras, de los valores predichos o del orden de las observaciones constituye una herramienta diagnóstica que permite identificar patrones sistemáticos no capturados por el modelo, evidenciar heterocedasticidad (varianza no constante del error a lo largo del rango de la variable objetivo) o detectar subgrupos de observaciones sobre los cuales el modelo exhibe un desempeño sistemáticamente deficiente (Danka, 2025). Idealmente, los residuos de un modelo bien ajustado deberían distribuirse de manera aproximadamente aleatoria y sin patrones discernibles en torno a cero, condición que, de no cumplirse, sugiere la presencia de relaciones no lineales, variables omitidas o heterogeneidad estructural en los datos no adecuadamente representada por el modelo.

Complementariamente, la cuantificación de la incertidumbre asociada a las métricas de evaluación descritas en la sección “Métricas de evaluación para regresión” y no únicamente la

obtención de un valor puntual resulta relevante para comunicar de manera honesta la confiabilidad del modelo. El método de bootstrap, consistente en el remuestreo aleatorio con reemplazo del conjunto de evaluación un número elevado de veces, recalculando en cada réplica la métrica de interés, permite construir empíricamente una distribución de dicha métrica y, a partir de ella, estimar un intervalo de confianza sin necesidad de asumir una forma paramétrica específica para su distribución muestral (Tan Wei Hao et al., 2026). La aplicación de esta técnica en la presente investigación permite reportar, junto con el valor puntual de cada métrica de evaluación, un rango de valores plausibles que refleja la variabilidad inherente al conjunto de prueba disponible, otorgando mayor rigor estadístico a las conclusiones sobre el desempeño del modelo final.

2.2.16. Métodos ensemble avanzados

Una vez identificado, mediante las etapas de validación cruzada y optimización de hiperparámetros descritas en las secciones “Validación cruzada y prevención de sobreajuste” y “Optimización de hiperparámetros”, el subconjunto de algoritmos con mejor desempeño individual, la etapa final del proceso de modelamiento explora la posibilidad de combinar dichos modelos mediante estrategias de ensamblado heterogéneo, con el objetivo de obtener un desempeño predictivo superior al de cualquiera de los modelos individuales que lo componen (Babushkin & Kravchenko, 2025).

El Voting Regressor combina las predicciones de un conjunto de modelos base, previamente entrenados de manera independiente, mediante un promedio simple o ponderado de sus salidas individuales; su fundamento teórico radica en que, si los errores cometidos por los distintos modelos base no están perfectamente correlacionados entre sí condición razonable cuando se combinan algoritmos de naturaleza distinta, como un modelo lineal regularizado, un ensamble de boosting y una red neuronal, el promedio de sus predicciones tiende a cancelar parcialmente

los errores idiosincráticos de cada modelo individual, reduciendo la varianza del error del ensamble resultante sin incrementar significativamente su sesgo (Chang, 2024).

El Stacking Regressor extiende este principio mediante un esquema de dos niveles: en el primer nivel, un conjunto de modelos base heterogéneos se entrena de manera independiente sobre los datos originales; sus predicciones generadas, típicamente, mediante un esquema de validación cruzada para evitar la fuga de información hacia el segundo nivel se emplean como nuevas variables de entrada para entrenar un modelo de segundo nivel, denominado meta-modelo, cuya función consiste en aprender la combinación óptima de las predicciones de los modelos base, en lugar de asumir a priori un esquema de ponderación fijo como el promedio simple del Voting Regressor (Dowling, 2025).

Yehoshua (2026) señalan que esta capacidad del meta-modelo para aprender de manera adaptativa en qué condiciones (o regiones del espacio de variables) resulta más confiable la predicción de cada modelo base constituye la ventaja teórica central del stacking frente a esquemas de combinación más simples, a costa de una mayor complejidad computacional y de un riesgo adicional de sobreajuste en el meta-modelo, que debe controlarse mediante el mismo esquema de validación cruzada agrupada (GroupKFold) descrito en la sección “Validación cruzada y prevención de sobreajuste”.

En síntesis, el fundamento teórico que justifica la superioridad esperada de los métodos de ensamblado heterogéneo tanto el Voting Regressor como el Stacking Regressor sobre cualquier modelo individual, radica en la descomposición del error de predicción en sus componentes de sesgo y varianza: mientras que las familias de algoritmos exploradas en la sección “Algoritmos de regresión utilizados” difieren en la forma en que equilibran ambos componentes (los modelos lineales regularizados tienden a exhibir mayor sesgo y menor varianza; los ensambles de boosting altamente ajustados, el patrón inverso), la combinación de modelos con perfiles de

error complementarios y débilmente correlacionados permite obtener un estimador agregado cuya varianza es inferior a la de sus componentes individuales, sin un incremento proporcional del sesgo (Oliver & Cheneweth, 2025). Esta propiedad fundamenta la decisión metodológica de no limitar la presente investigación a la selección de un único algoritmo óptimo, sino de evaluar, como etapa final del pipeline, la capacidad de las estrategias de ensamblado avanzado para mejorar la precisión de la estimación de la duración de partidas de obra.

2.3. Definición de términos básicos

Cronograma contractual. *Es el instrumento que define la secuencia y los plazos de las actividades de una obra, conforme a las obligaciones y condiciones contractuales (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Cronograma valorizado. *Es la programación de la ejecución que relaciona el avance físico previsto con su correspondiente valorización económica a lo largo del plazo contractual, permitiendo comparar el avance programado con el avance efectivamente ejecutado (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Cronograma acelerado. *Programación de ejecución de obra elaborada cuando se requiere recuperar atrasos mediante una programación de avance superior a la inicialmente prevista, con el propósito de alcanzar los plazos establecidos contractualmente. El Reglamento de la Ley N.° 32069 contempla el calendario de avance de obra valorizado acelerado para el control de avances físicos reprogramados.*

Cronograma reprogramado. *Es la programación actualizada de las actividades de una obra que incorpora las modificaciones producidas durante su ejecución, permitiendo establecer las nuevas fechas y secuencias previstas para completar los trabajos (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Control de obra. *Es el proceso de seguimiento y verificación del avance de la ejecución respecto a la programación establecida, considerando principalmente el cumplimiento de las actividades, plazos y avances valorizados (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Tiempo de ejecución. *Periodo comprendido entre la fecha de inicio y la fecha de culminación de trabajos correspondientes a la ejecución, expresado normalmente en días calendario (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Duración de una actividad. *Es el tiempo necesario para completar el trabajo correspondiente a una actividad programada, considerando los recursos disponibles y las condiciones previstas para su ejecución (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Plazos contractuales. *Son los periodos establecidos en el contrato para el cumplimiento de las prestaciones y obligaciones contractuales, cuyo cumplimiento determina las fechas previstas para la ejecución de las actividades y la culminación de la obra (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Ampliaciones de plazo. *Son modificaciones autorizadas al plazo contractual de una obra cuando se presentan circunstancias previstas por la normativa que afectan su ejecución y, en determinados supuestos, modifican la ruta crítica del programa vigente.*

Deductivos. *Son reducciones de prestaciones o componentes previstos originalmente en el contrato de obra, que implican disminuir el alcance y el correspondiente monto contractual cuando resultan técnica y contractualmente procedentes. En el caso de los deductivos vinculantes, estos pueden relacionarse con prestaciones adicionales de obra (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Hitos. *Son puntos o eventos significativos dentro del cronograma que permiten identificar el cumplimiento de una etapa, entregable o acontecimiento relevante del proyecto. Se utilizan*

como referencias para el seguimiento del avance del proyecto (Porject Management Institute, 2019).

Costo directo. *Es el costo asociado directamente con la ejecución del trabajo de una actividad o partida, incluyendo los recursos necesarios para su realización, como mano de obra, materiales, equipos y servicios directamente aplicables (Project Management Institute, 2017).*

Costo indirecto. *Es el costo necesario para la ejecución y gestión del proyecto que no puede atribuirse directamente a una actividad o partida específica, pudiendo incorporarse en niveles superiores de la estimación de costos del proyecto (Project Management Institute, 2017).*

Cuadrilla. *Es el grupo de trabajadores organizado para ejecutar una determinada actividad constructiva y alcanzar un rendimiento establecido, pudiendo estar conformado por diferentes categorías de trabajadores según las características del trabajo.*

Actividad o tarea. *Es una unidad de trabajo identificada dentro de la programación del proyecto que debe ejecutarse para producir un resultado o contribuir al cumplimiento de un entregable. Las actividades poseen características como duración, recursos y relaciones de precedencia (Project Management Institute, 2019).*

Duración de una actividad. *Periodos de trabajo necesarios para completar una actividad determinada, considerando recursos y las condiciones bajo las cuales se ejecutará el trabajo (Project Management Institute, 2017).*

Diagrama de Gantt. *Es una representación gráfica del cronograma en la que las actividades se muestran mediante barras horizontales ubicadas según sus fechas de inicio, finalización y duración, facilitando la visualización y seguimiento temporal del proyecto (Project Management Institute, 2019).*

Acta de fin de obra. *Es el documento mediante el cual se deja constancia de la culminación de los trabajos correspondientes a la ejecución de una obra, constituyendo un registro formal de la finalización de las prestaciones ejecutadas (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

Supervisión de inicio. *Corresponde al acto mediante el cual se formaliza el comienzo de la ejecución de los trabajos, una vez cumplidas las condiciones establecidas contractualmente y por la normativa aplicable (Ministerio de Economía y Finanzas del Perú MEF, 2024).*

2.4. Formulación de hipótesis

2.4.1. Formulación de Hipótesis general

El modelo predictivo basado en técnicas de machine learning tiene un efecto significativo en la programación de obras en proyectos de infraestructura vial, Arequipa 2025.

2.4.2. Formulación de Hipótesis específicas

HE.1. Los factores y variables de proyectos de infraestructura vial poseen una relación significativa con la precisión de la programación de obras de infraestructura vial, Arequipa 2025.

HE.2. El diseño y entrenamiento de un modelo predictivo basado en técnicas de machine learning, permite optimizar la programación de obras de infraestructura vial, Arequipa 2025.

HE.3. El modelo predictivo desarrollado mediante machine learning presenta un mejor desempeño y mayor confiabilidad que los métodos tradicionales de programación de obra de infraestructura vial, Arequipa 2025.

HE.4. La implementación del modelo predictivo basado en técnicas machine learning reduce significativamente la desviación de plazos y optimiza la programación de obras de infraestructura vial, Arequipa 2025.

CAPITULO III:

METODOLOGIA DE LA INVESTIGACION

3. Metodología de la investigación

3.1. Diseño metodológico

Para este trabajo de investigación orientado a la aplicación machine learning en la optimización de cronogramas de obras de infraestructura vial de Arequipa, buscando la predicción del tiempo de ejecución, identificando factores que conllevan al retraso del tiempo de ejecución.

3.1.1. Enfoque

La investigación se desarrollará bajo un enfoque cuantitativo, dado que busca medir y analizar de manera objetiva las variables relacionadas con el tiempo de ejecución de obras de infraestructura vial de Arequipa, empleando técnicas estadísticas y modelos predictivos de machine learning (Rodríguez Moguel, 2005). Este enfoque permitirá transformar los datos históricos obtenidos en información numérica procesable, con el propósito de identificar patrones, relaciones y tendencias que permitan optimizar la programación de cronogramas durante la etapa de planificación. Asimismo, se sustenta en la utilización de métodos experimentales y computacionales para validar la precisión del modelo propuesto, garantizando resultados verificables y reproducibles (Borja Suárez, 2016).

3.1.2. Tipo

El estudio corresponde a una investigación aplicada, ya que busca generar una solución práctica a un problema real del sector construcción: la imprecisión en la programación de cronogramas y las desviaciones de tiempo en las obras viales (Niño Rojas, 2011). El objetivo es aplicar los conocimientos teóricos y tecnológicos del machine learning para desarrollar un modelo predictivo que pueda implementarse en la gestión de proyectos de infraestructura. Esta

aplicación directa de técnicas de inteligencia artificial en el campo de la ingeniería civil contribuye al mejoramiento de los procesos de planificación y toma de decisiones en entidades públicas y privadas (Borja Suárez, 2016).

3.1.3. Nivel

El nivel de la investigación es explicativo, ya que pretende no solo describir el comportamiento de las variables involucradas, sino también determinar la relación causal entre los factores históricos y el tiempo real de ejecución de las obras(Borja Suárez, 2016). A través del modelo de machine learning, se busca explicar de qué manera variables como el presupuesto, la calidad, el contrato, la localización, las condiciones climáticas y la gestión de riesgos influyen en la duración de los proyectos. Este nivel permitirá validar empíricamente la capacidad predictiva del modelo y su impacto en la optimización de los cronogramas de planificación (Niño Rojas, 2011).

3.1.4. Diseño

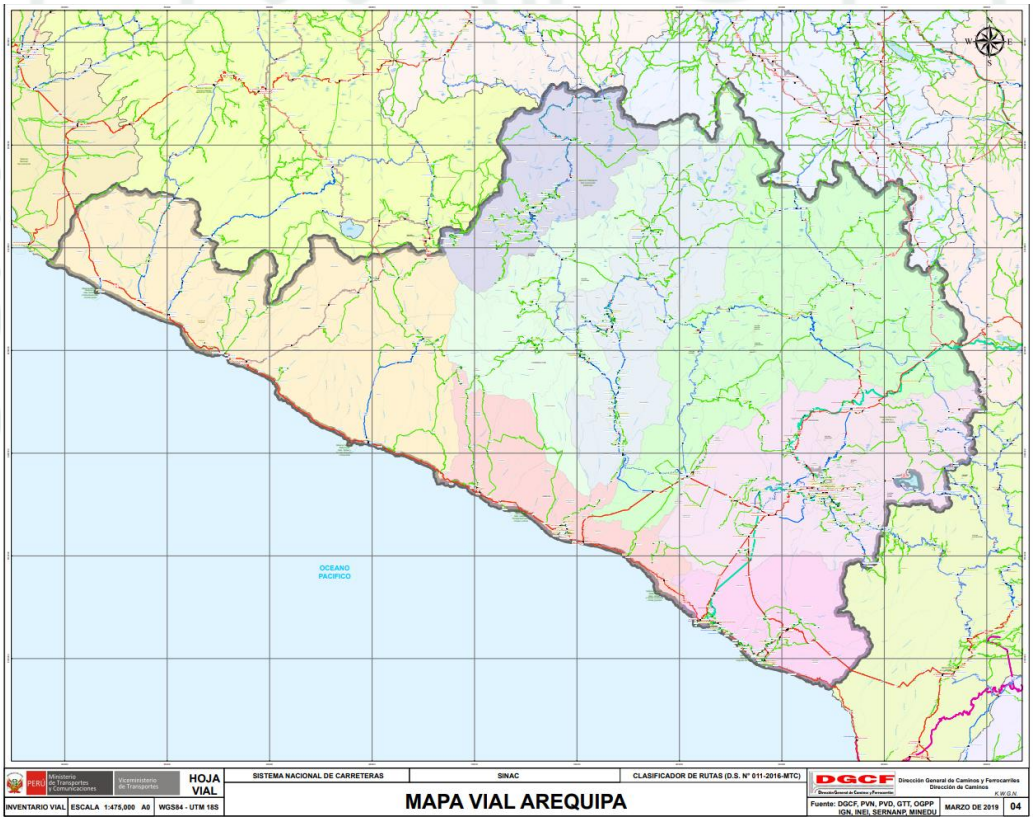
El diseño de la investigación es no experimental, de tipo correlacional-predictivo, debido a que las variables no serán manipuladas deliberadamente, sino observadas y analizadas tal como se presentan en los registros históricos de proyectos(Rodríguez Moguel, 2005). La información se obtendrá de bases de datos oficiales y se emplearán técnicas de minería de datos y aprendizaje supervisado para establecer relaciones entre las variables independientes y la variable dependiente (tiempo de ejecución). El diseño correlacional permitirá identificar la fuerza y dirección de las relaciones entre variables, mientras que el enfoque predictivo posibilitará construir y validar el modelo de machine learning que optimice la programación de cronogramas en la etapa de planificación de obras viales(Niño Rojas, 2011).

3.2. Población y muestra

3.2.1. Población

La población de la investigación está conformada por todos los proyectos de infraestructura vial ejecutados en la región de Arequipa (2022-2025) que cuenten con información histórica registrada en plataformas oficiales del Estado, tales como el Sistema de Seguimiento de Inversiones (SSI) del Ministerio de Economía y Finanzas y el portal InfoObras de la Contraloría General de la República. Esta población incluye obras viales de diversa tipología, como carreteras, vías urbanas, rehabilitaciones, mantenimientos y mejoramientos, ejecutados por la modalidad de contrata, de instituciones públicas del Gobierno Regional, municipalidades provinciales y distritales.

Figura 1:
Mapa Vial de Arequipa.



Fuente: Dirección General de Caminos y Ferrocarriles Dirección de Caminos (DGCF).

3.2.2. Muestra

Para esta investigación, se llevó a cabo un proceso sistemático de identificación, evaluación y selección de proyectos viales con el fin de conformar la muestra final. El procedimiento se desarrolló utilizando información oficial disponible en las plataformas de la Contraloría General de la República, el Sistema de Seguimiento de Inversiones (SSI) y el portal InfObras, lo que garantizó la confiabilidad y trazabilidad de los datos analizados.

En la primera etapa, se identificó el marco muestral, conformado por todas las obras viales registradas entre los años 2022 y 2025 en las region de Arequipa, que contaban con información pública suficiente sobre su planificación y ejecución. Este marco incluyó proyectos reportados en los informes de control concurrente, documentos de obras paralizadas, cronogramas contractuales, ampliaciones de plazo y reportes físico-financieros asociados a cada intervención vial.

Posteriormente, se aplicaron los criterios de inclusión, seleccionándose únicamente aquellas obras que:

a) Información de la obra

- Obras de infraestructura vial ejecutadas en la región Arequipa.
- Obras culminadas y liquidadas, con información verificable de su ejecución.
- Obras que cuenten con información sobre plazo contractual, duración planificada y duración real.
- Obras con documentación suficiente para identificar las partidas y actividades ejecutadas.

b) Información para el modelo predictivo

- Partidas con metrados, rendimientos y duraciones planificadas disponibles.
- Actividades con relaciones de precedencia identificables.
- Registros de ejecución que permitan determinar la duración real de las actividades.
- Datos correspondientes a variables utilizadas como predictores y a la variable objetivo de duración.

c) Información para la validación

- Obras con información suficiente para comparar la duración planificada, duración predicha y duración real.
- Datos consistentes y verificables, evitando registros incompletos, duplicados o inconsistentes que puedan afectar el entrenamiento y evaluación del modelo.

3.2.2.1. Justificación del tamaño de la muestra

El tamaño final de 10 proyectos fue definido considerando la disponibilidad real de datos en las fuentes oficiales, así como la evidencia revisada en la literatura especializada sobre modelos de machine learning aplicados a la construcción. Dicho tamaño resulta adecuado para representar la variabilidad existente en los proyectos viales del sur del Perú y, al mismo tiempo, garantiza la robustez estadística necesaria para entrenar y validar modelos predictivos sin comprometer su desempeño. De esta manera, la muestra seleccionada no es arbitraria, sino el resultado de un proceso riguroso y fundamentado técnica y metodológicamente.

3.3. Definición de variables

La presente investigación considera dos variables principales:

- una variable independiente, Modelo predictivo basado en técnicas de machine learning.
- variable dependiente, Programación de obra en proyectos de infraestructura vial.

Estas variables permiten analizar cómo los datos históricos de proyectos viales influyen en la capacidad de un modelo de machine learning para generar estimaciones más precisas de la duración real y, con ello, mejorar la programación de cronogramas en la etapa de planificación.

3.3.1. Definición conceptual

La variable independiente Modelo predictivo basado en técnicas de machine learning se define como un sistema computacional que utiliza algoritmos de aprendizaje automático para analizar datos históricos de obras viales y aprender patrones de comportamiento entre los cronogramas planificados y los cronogramas ejecutados. Su finalidad es generar predicciones sobre la duración real de las actividades, incorporando tiempos asociados a la calidad, riesgos y factores externos que afectan la programación de obra. Conceptualmente, representa la capacidad de un modelo de inteligencia artificial para anticipar desviaciones y optimizar la programación.

La variable dependiente Programación de obra en proyectos de infraestructura vial es el proceso mediante el cual se planifican, organizan y controlan las actividades necesarias para ejecutar una obra vial dentro de un plazo determinado. Incluye la estimación de duraciones, la secuencia lógica entre actividades, la definición de holguras y la formación de la ruta crítica. Conceptualmente refleja el grado en que la programación se ajusta a los tiempos reales de ejecución, la eficiencia del cronograma y la capacidad de gestión del tiempo durante el proyecto.

3.3.2. Definición operacional

La definición operacional establece la forma en que cada variable del estudio será medida en función de sus dimensiones e indicadores. Para ello, se consideran técnicas de medición cuantitativa basadas en porcentajes, valores numéricos, coeficientes estadísticos y escalas cualitativas, según corresponda a cada indicador. A continuación, se describe la operacionalización de las dos variables del estudio.

- Variable Independiente: Modelo predictivo basado en técnicas de Machine Learning

Esta variable se operacionaliza mediante tres dimensiones que permiten evaluar el funcionamiento y aplicación del modelo predictivo: el desempeño del modelo predictivo, el entrenamiento y validación, y la aplicación del modelo.

- ✓ Dimensión: Desempeño del modelo predictivo

Se mide mediante el indicador de exactitud de las predicciones, expresado a través del error porcentual (%), que permite determinar el grado de aproximación de las predicciones generadas por el modelo respecto a las duraciones reales de las actividades.

- ✓ Dimensión: Entrenamiento y validación

Se operacionaliza mediante el número de modelos evaluados y la selección del modelo con mejor desempeño. El primero se expresa como la cantidad de modelos evaluados, mientras que el segundo se determina mediante los indicadores estadísticos R^2, RMSE, MAE y MAPE, utilizados para comparar el desempeño de los modelos.

- ✓ Dimensión: Aplicación del modelo

Comprende la utilización del modelo seleccionado para estimar la duración de las actividades de ejecución. Se mide mediante la duración predicha, expresada en días, y la diferencia entre la duración real y la duración predicha, también expresada en días.

- Variable Dependiente: Programación de obras en proyectos de infraestructura vial, Arequipa 2025

Esta variable se operacionaliza mediante tres dimensiones que permiten evaluar el comportamiento de los plazos de ejecución de las obras: la duración de ejecución, el cumplimiento del plazo y la desviación del cronograma.

- ✓ Dimensión: Duración de ejecución

Se mide mediante el indicador plazo de ejecución real, expresado en días, que representa el tiempo efectivamente empleado para culminar la ejecución de la obra.

- ✓ Dimensión: Cumplimiento del plazo

Se operacionaliza mediante la diferencia entre el plazo contractual y el plazo real de ejecución, expresada en días, permitiendo determinar si la obra fue ejecutada dentro o fuera del plazo establecido.

- ✓ Dimensión: Desviación del cronograma

Se mide mediante el porcentaje de desviación entre el plazo contractual y el plazo real, expresado en porcentaje (%), permitiendo cuantificar la variación del tiempo real respecto al tiempo establecido contractualmente.

3.4. Operacionalización de variables

Tabla 4:
Operacionalización de las variables

Variable	Definición Conceptual	Definición Operacional	Dimensiones	Indicadores	Herramientas
VI: Modelo predictivo basado en técnicas de machine learning	El modelo predictivo basado en técnicas de Machine Learning es un sistema computacional que analiza datos históricos de obras viales para identificar patrones y predecir la duración real de las actividades, contribuyendo a mejorar la programación de obra.	Se medirá mediante tres dimensiones que permiten evaluar el funcionamiento y aplicación del modelo predictivo: el desempeño del modelo predictivo, el entrenamiento y validación, y la aplicación del modelo.	Desempeño predictivo	Exactitud de las predicciones (error porcentual %)	Phyton y exel
			Entrenamiento y validación	Numero de modelos evaluados (cantidad de modelos °N)	Python
				Selección adecuada del modelo (R^2, RMSE, MAE, MAPE)	Python (Scikit-learn)
			Aplicación del modelo	Duración predicha de actividades (Días)	Interfaz desarrollada
				Diferencia entre real y predicha (Días)	Phyton y exel
VD: Programación de obra en proyectos de infraestructura vial	La programación de obra es el proceso de planificar, organizar y controlar las actividades de un proyecto vial, estableciendo sus duraciones y secuencia para cumplir con el plazo previsto y gestionar adecuadamente el tiempo de ejecución.	Se medirá mediante tres dimensiones que permiten evaluar el comportamiento de los plazos de ejecución de las obras: la duración de ejecución, el cumplimiento del plazo y la desviación del cronograma.	Duración de ejecución	Plazo de ejecución real (Días)	Ficha de análisis documental en Excel
			Cumplimiento del plazo	Diferencia entre plazo contractual y plazo real (Días)	Excel
			Desviación del cronograma	Porcentaje de desviación entre contractual y real. (error porcentual %)	Phyton y exel

Fuente: Elaborado por el autor

3.5. Técnicas e instrumentos de recolección de datos

La recolección de datos en esta investigación se realizó mediante técnicas documentales y análisis de fuentes oficiales, debido a la naturaleza histórica y retrospectiva de los proyectos de infraestructura vial seleccionados. La finalidad fue obtener información confiable, verificable y suficiente para construir la base de datos que alimenta el modelo predictivo de machine learning y permite evaluar la optimización de la programación de cronogramas en la etapa de planificación.

3.5.1. Técnica de recolección de datos

Técnica documental

Se empleó la revisión documental, ya que los datos necesarios corresponden a obras viales ya ejecutadas y registradas en plataformas oficiales. Esta técnica permitió examinar expedientes técnicos, reportes de supervisión, cronogramas valorizados, informes de control concurrente y registros físico-financieros, con el fin de extraer información objetiva sobre las características técnicas, contractuales y de ejecución de cada proyecto.

Esta técnica fue adecuada porque:

- Garantiza la autenticidad y confiabilidad de los datos
- Permite acceder a información histórica completa
- Evita la subjetividad asociada a encuestas o entrevistas

proporciona el nivel de detalle requerido para el entrenamiento del modelo de machine learning.

3.5.2. Instrumentos de recolección de datos

a) Ficha de recolección de datos (estructura de exel)

Se diseñó una ficha estructurada de registro, elaborada especialmente para esta investigación, que permitió recopilar y organizar de forma uniforme las variables seleccionadas. Esta ficha incluyó campos específicos relacionados con:

- Datos generales del proyecto (descripción de la obra, modalidad de ejecución)
- Información contractual (presupuesto, modalidad, plazo contractual)
- Historial de ejecución (ampliaciones, adicionales, desviaciones porcentuales)
- Fechas programadas y reales,
- Observaciones de control concurrente.

La ficha permitió estandarizar la captura de información para las 10 obras analizadas y la población, evitando inconsistencias y favoreciendo la formación de una matriz de datos compatible con modelos predictivos.

b) Matriz de base de datos histórica

Una vez recolectados los datos mediante la ficha, se construyó una matriz digital en formato tabular (Excel), organizada en filas y columnas para su integración en los algoritmos de machine learning. Esta matriz contiene:

Tabla 5:
Contenido de la matriz base de datos históricos.

Variable	Forma de organización
Obra ID	Identificación de la obra que se está utilizando sus datos.
ID partida	Agrupación de partidas.
Número de partida según MS Project	Identifica la posición o número asignado a la actividad dentro del cronograma de Microsoft Project.
Descripción de la partida	Contiene la denominación de la actividad tal como aparece en el cronograma.
Predecesoras	Registra las actividades que deben ejecutarse previamente para que pueda iniciarse la actividad analizada, de acuerdo con la lógica del cronograma.
Código de partida	Corresponde al código estandarizado asignado durante la etapa de limpieza y agrupación de actividades equivalentes.
Metrado total	Representa la cantidad total de trabajo prevista para la actividad.
Rendimiento	Representa la cantidad de trabajo que puede ejecutarse por unidad de tiempo, de acuerdo con la información disponible para la actividad.
Duración total en días	Corresponde al número total de días considerados para la ejecución de la actividad.
Día trabajado	Identifica el día específico de ejecución de la actividad dentro de su periodo total de trabajo.
Metrado diario	Representa la cantidad de trabajo ejecutada durante cada día de trabajo.
Metrado acumulado	Corresponde a la acumulación progresiva del metrado ejecutado hasta cada día de trabajo.
Es el primer día	Variable indicadora que permite identificar si el registro corresponde al primer día de ejecución de la actividad.
Es el último día	Variable indicadora que permite identificar si el registro corresponde al último día de ejecución de la actividad.
Porcentaje completado	Representa el avance acumulado de la actividad respecto al metrado total considerado.

Nota: lo que se muestra a continuación es el contenido de la matriz base de datos históricos, cada uno de ellos representa una columna en la matriz.

Fuente: Elaboración propia.

c) Repositorios oficiales consultados

Para garantizar la validez y confiabilidad de la información, se recurrió exclusivamente a fuentes oficiales:

- InfoObras – Contraloría General de la República: informes de control concurrente, reportes de avance, datos de obras paralizadas y concluidas.
- Sistema de Seguimiento de Inversiones (SSI – MEF): contratos, cronogramas valorizados, plazos, códigos SNIP.
- Expedientes Técnicos y documentos de obra: metrados, planos, especificaciones técnicas, cuadernos de obra, actas de ampliación de plazo.

3.5.3. Justificación de los instrumentos

El uso combinado de la ficha de recolección de datos y la matriz digital permitió contar con información estructurada, consistente y adecuada para:

- construir un modelo predictivo basado en machine learning,
- medir el desempeño de los algoritmos frente a datos reales,
- comparar la precisión del modelo con lo planificado.
- evaluar la optimización del cronograma de obra,
- garantizar la reproducibilidad del proceso de análisis.

3.6. Técnicas e instrumentos de procesamiento de datos

El procesamiento de datos se realizará mediante técnicas de análisis estadístico y análisis de datos, permitiendo organizar, depurar, transformar y analizar la información obtenida de los proyectos de infraestructura vial. Asimismo, se realizará el procesamiento de los datos históricos para el entrenamiento, validación y evaluación del modelo predictivo.

Como instrumentos se emplearán una base de datos estructurada y fichas de registro, donde se organizarán las variables relacionadas con las obras, partidas, duraciones planificadas y reales. Para el procesamiento y análisis se utilizarán Microsoft Excel y Python, empleando bibliotecas especializadas para el tratamiento de datos, desarrollo de modelos de Machine Learning y cálculo de métricas de evaluación.

En síntesis:

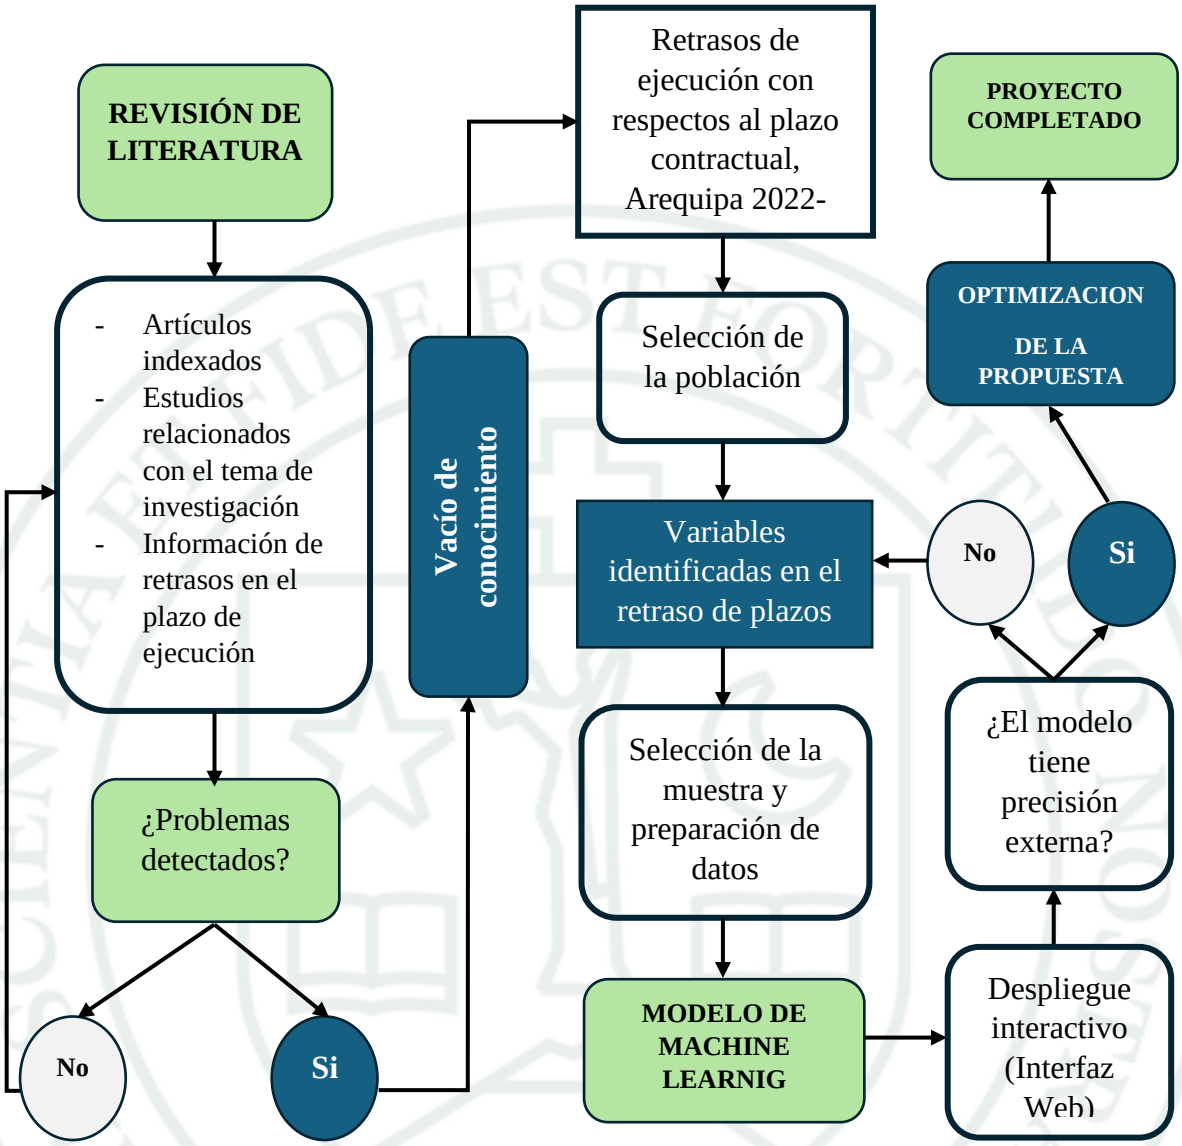
Técnica: Análisis estadístico y procesamiento de datos.

Instrumentos: Base de datos estructurada y fichas de registro.

Software: Microsoft Excel, Python y Ms Project.

Procesamiento: Depuración, transformación, análisis, entrenamiento, validación y evaluación del modelo predictivo.

Figura 2:
Diagrama de flujo - Esquema Metodológico.



CAPITULO IV:

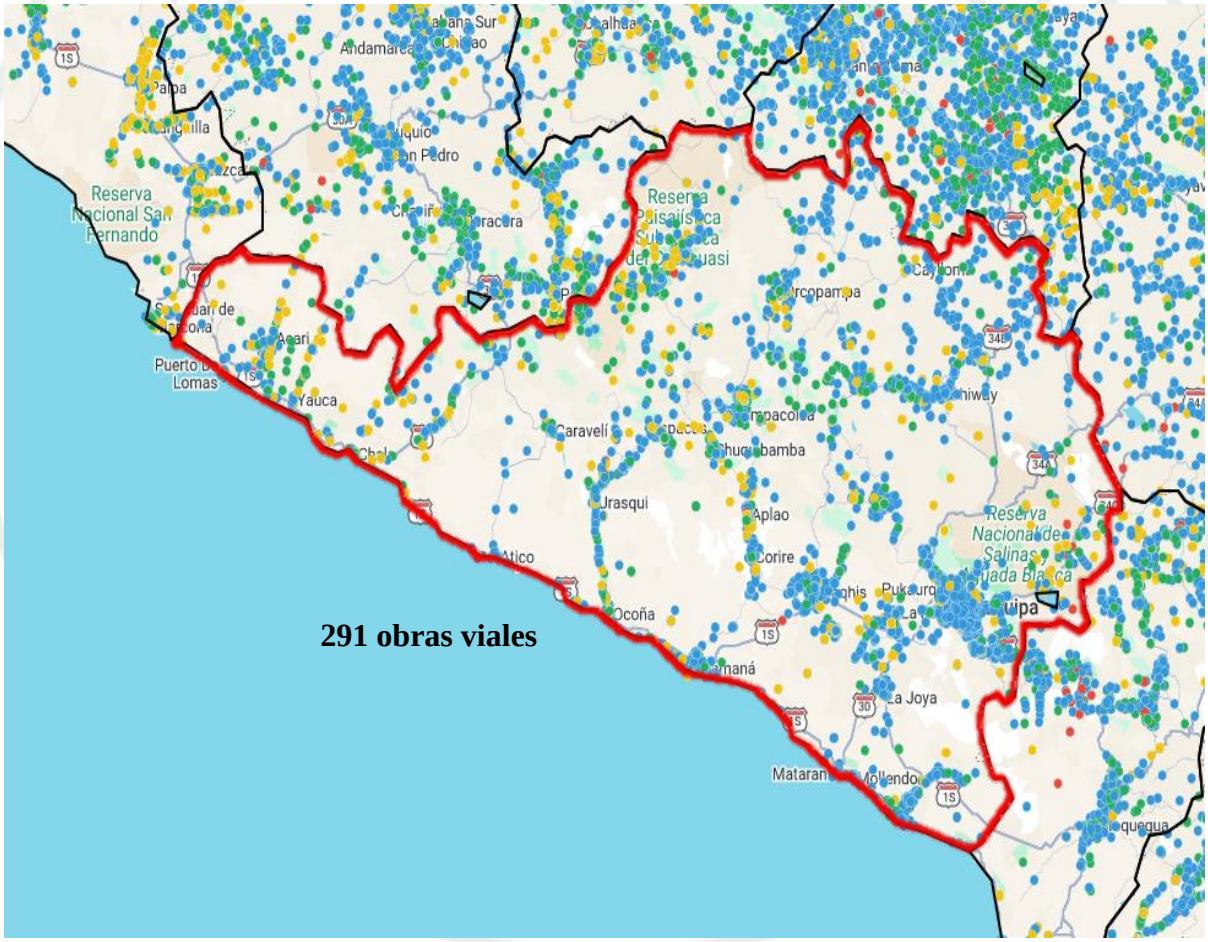
DESARROLLO

4. Desarrollo

4.1. Lugar de la investigación

El departamento elegido para la investigación es Arequipa, por lo cual se muestra un mapa en donde se indica la cantidad de obras viales por contrata realizadas en el periodo 2022 a 2025.

Figura 3:
Mapa de la ubicación de obras de infraestructura vial en Arequipa.



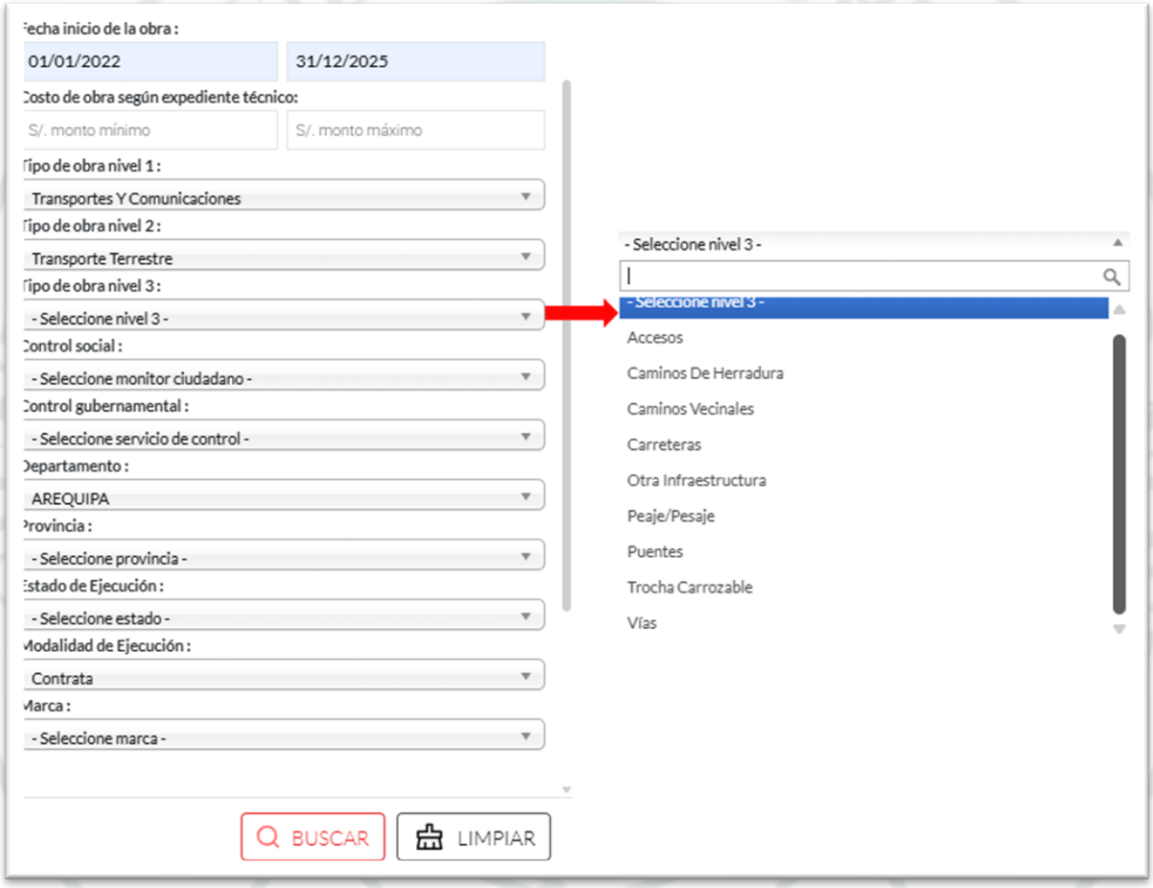
Nota: La figura muestra un mapa con la ubicación de las 291 obras de infraestructura vial en Arequipa en el periodo 2022 – 2025.

Fuente: Infobras – Sistema de información de obras pública.

4.2. Obtención de los datos

Inicialmente se hizo una búsqueda de los proyectos de infraestructura vial en la región de Arequipa mediante los sistemas oficiales del Estado peruano. Para ello se consultó la base de datos de INFOBRAS, dándole las opciones de búsqueda.

Figura 4:
Sistema de búsqueda en INFOBRAS



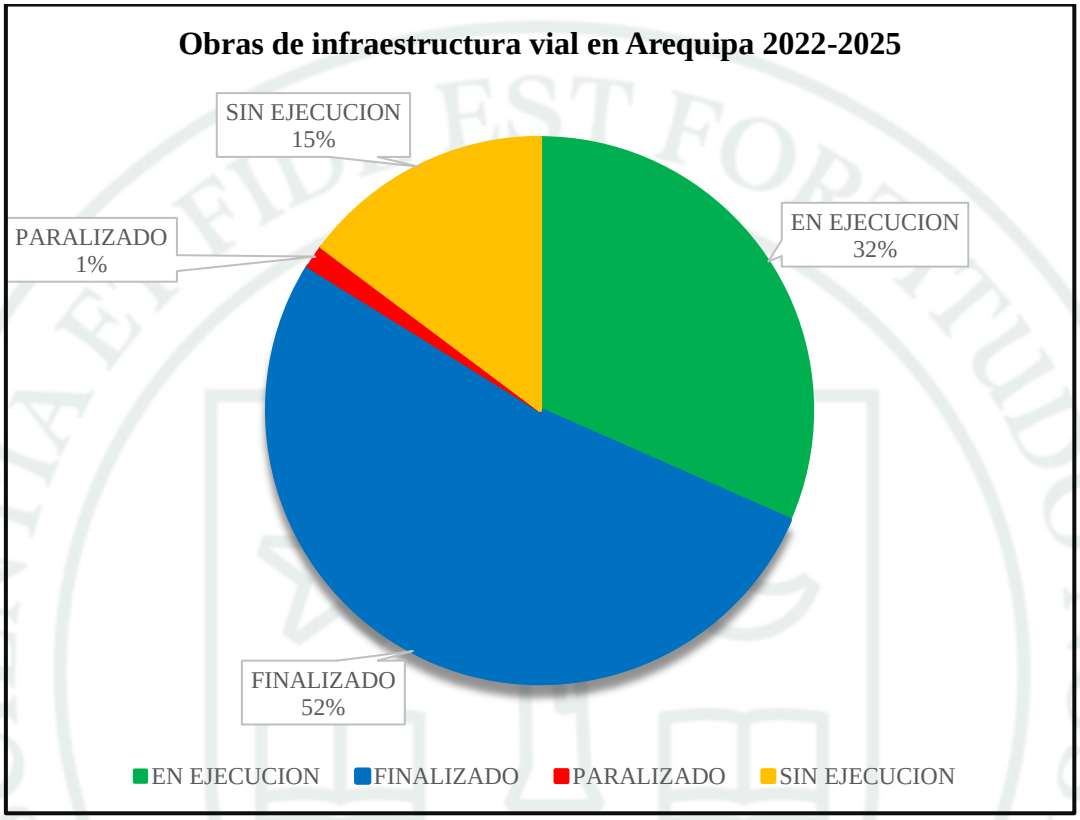
Nota: Operadores de búsqueda avanzada en INFOBRAS para la búsqueda de obras de infraestructura vial en Arequipa 2022-2025

Fuente: Captura del Sistema de búsqueda de INFOBRAS

Cada registro puntual dentro del "Mapa de la ubicación do obras de infraestructura vial en Arequipa" representa la localización espacial de un proyecto de infraestructura vial en la modalidad de contrata en la región Arequipa 2022-2025. Cada color asignado a cada entidad

vectorial determina el estado operacional o situacional (en ejecución, finalizado, paralizado, sin ejecución) dentro del portafolio regional de inversiones:

Figura 5: Representación gráfica del estado de obras viales en Arequipa 2022 - 2025



Nota: La cantidad total es de 291 proyectos de infraestructura vial en la región de Arequipa 2022 – 2025. De acuerdo con la codificación cromática por estado situacional, se registran 152 obras finalizadas (52.23%), 92 en ejecución física (31.62%), 43 sin ejecución (14.78%) y 4 en condición de paralizadas (1.37%).

Fuente: Adaptado de Infobras - Sistema Nacional de Obras Públicas, 2025

Para el desarrollo de la investigación, se estableció como población objetivo un conjunto de 152 obras viales clasificadas como finalizadas, provenientes de un universo de 291 proyectos registrados. La delimitación de esta población respondió a criterios de conformidad técnica y administrativa, priorizando aquellas obras que contaran con la condición de finalizadas con el

acceso al dato de inicio y fin de ejecución y que, además dispusieran del visto bueno correspondiente a la liquidación y conclusión por parte de la entidad competente.

4.3. Obtención de la muestra

4.3.1. Criterios de inclusión

Con el fin de asegurar la información técnica completa y confiable para el desarrollo del modelo predictivo basado en técnicas de Machine Learning, así como para el análisis comparativo entre las condiciones de planificación y los resultados obtenidos durante la realizacion de los proyectos de infraestructura vial, se incluirán en la investigación aquellas obras que cuenten con la siguiente documentación técnica:

a) Información técnica en la etapa de planificación

- Presupuesto de obra, utilizado para identificar las partidas que conforman el proyecto y establecer la correspondencia entre las partidas presupuestales y las actividades programadas para su ejecución.
- Análisis de Precios Unitarios, documento fundamental para obtener los rendimientos y cantidades de trabajo consideradas durante la planificación de cada partida, permitiendo posteriormente compararlas con las condiciones reales de ejecución.
- Cronograma valorizado contractual, empleado para identificar la duración contractual de la obra, la programación temporal de las partidas y la distribución económica prevista durante el periodo de ejecución.
- Programación de obra, elaborada preferentemente en Microsoft Project, incluyendo el diagrama de Gantt, la secuencia lógica de las actividades, las relaciones de precedencia, las duraciones programadas y demás parámetros de planificación. Esta información permitió

reconstruir la programación inicial y evaluar el grado de cumplimiento durante la ejecución del proyecto.

b) Información técnica en la etapa de ejecución

- Obras culminadas y liquidadas, garantizando la disponibilidad de información completa sobre el desarrollo constructivo y los resultados finales del proyecto.
- Presupuesto de ejecución, utilizado para verificar las cantidades realmente ejecutadas y las variaciones respecto al presupuesto contractual.
- Cronogramas valorizados de ejecución, in dispensables para identificar el avance físico y económico real de la obra, así como la duración efectiva de cada actividad durante el proceso constructivo.
- Registro completo de las fechas de inicio y culminación de la obra, permitiendo determinar la duración real del proyecto y evaluar el cumplimiento del plazo contractual.
- Resoluciones e informes de ampliación de plazo, cuando correspondieran, con la finalidad de identificar las causas que originaron modificaciones en el cronograma contractual y cuantificar su incidencia en la duración total de la obra.
- Resoluciones e informes relacionados con prestaciones adicionales, mayores metrados, menores metrados o deductivos, debido a que las modificaciones en las cantidades de obra generan variaciones en los tiempos de ejecución y afectan directamente la programación del proyecto.
- Documentación correspondiente a la entrega del terreno, como actas de entrega u otros documentos equivalentes, utilizada para verificar la fecha efectiva de inicio de los trabajos y las condiciones bajo las cuales se dio comienzo a la ejecución de la obra.

4.3.2. Criterios de exclusión

a) Etapa de planificación

- Ausencia del presupuesto de obra, que impedía identificar las partidas y su correspondencia con las actividades programadas.
- Ausencia del análisis de precios unitarios, que impedía obtener los rendimientos y las cantidades de trabajo planificadas.
- Ausencia del cronograma valorizado contractual, que impedía identificar la duración contractual y la programación temporal de las partidas.
- Ausencia de la programación de obra con diagrama de Gantt, secuencia lógica, relaciones de precedencia y duraciones programadas, que impedía reconstruir la programación inicial.

b) Etapa de ejecución

- Obra no culminada o sin liquidar, es decir, sin acta de recepción (obras en ejecución, paralizadas, resueltas o sin recepcionar).
- Ausencia del presupuesto de ejecución o del cronograma valorizado de ejecución (mensual o diario) que permitiera verificar las cantidades realmente ejecutadas, el avance físico y económico real y la duración efectiva de cada actividad.
- Imposibilidad de determinar las fechas de inicio y culminación por ausencia del acta de inicio de obra, del acta de recepción o del cuaderno de obra.
- Ausencia de resoluciones e informes de ampliación de plazo, cuando estas hubieran existido.
- Ausencia de las resoluciones e informes de prestaciones adicionales, mayores o menores metrados o deductivos, cuando estos hubieran existido.

- Ausencia de la documentación de entrega del terreno (acta u otro documento equivalente) que permitiera verificar la fecha efectiva de inicio.

c) Calidad de la información

- Inconsistencias entre documentos que no pudieron resolverse, como partidas del presupuesto sin correspondencia con las actividades programadas o fechas contradictorias.
- Registros incompletos, duplicados o inconsistentes que afectaran el entrenamiento y la evaluación del modelo.

Tabla 6: Documentación exigida, verificación y causal de exclusión.

Etapa	Criterio de inclusión	Finalidad	Documento de verificación	Plataforma	Dato del modelo que alimenta (confirmar)	Si falta
Planificación	Presupuesto de obra	Identificar las partidas y establecer la correspondencia entre las partidas presupuestales y las actividades programadas	Presupuesto de obra (archivo publicado)	SEACE	Partidas y metrado total	Se excluye la obra
Planificación	Análisis de precios unitarios	Obtener los rendimientos y las cantidades de trabajo consideradas en la planificación de cada partida	Análisis de precios unitarios (archivo publicado)	SEACE	Rendimiento	Se excluye la obra
Planificación	Cronograma valorizado contractual	Identificar la duración contractual, la programación temporal de las partidas y la distribución económica prevista	Cronograma valorizado contractual (archivo publicado)	SEACE	Duración contractual, base de la comparación con el método tradicional	Se excluye la obra

Planificación	Programación de obra (preferentemente en Microsoft Project)	Diagrama de Gantt, secuencia lógica, relaciones de precedencia y duraciones programadas; permite reconstruir la programación inicial	Archivo de programación de obra (publicado)	SEACE	Predecesoras, número de partida (MS Project) y duración programada	Se excluye la obra
Ejecución	Obra culminada y liquidada	Garantizar información completa del proceso constructivo y de los resultados finales	Acta de recepción	Infobras y SSI	Criterio de estado (no alimenta una variable)	Se excluye la obra
Ejecución	Presupuesto de ejecución	Verificar las cantidades realmente ejecutadas y las variaciones respecto al presupuesto contractual	Cronograma valorizado mensual o diario	Infobras y SSI	Verificación del metrado ejecutado	Se excluye la obra
Ejecución	Cronogramas valorizados de ejecución	Identificar el avance físico y económico real y la duración efectiva de cada actividad	Cronograma valorizado mensual o diario	Infobras y SSI	Duración total en días (variable objetivo)	Se excluye la obra
Ejecución	Registro completo de fechas de inicio y culminación	Determinar la duración real del proyecto y evaluar el cumplimiento del plazo contractual	Acta de recepción, acta de inicio de obra y cuaderno de obra	Infobras y SSI	Duración real de la obra (desvío de plazo y casos de estudio)	Se excluye la obra
Ejecución	Resoluciones e informes de ampliación de plazo (cuando correspondan)	Identificar las causas de las modificaciones del cronograma y cuantificar su incidencia en la duración total	Resoluciones e informes de ampliación de plazo	Infobras y SSI	Contexto de la duración real	Se excluye solo si existieron y no están publicados
Ejecución	Resoluciones e informes de adicionales, mayores o menores metrados y deductivos (cuando correspondan)	Considerar las variaciones de cantidades que alteran los tiempos de ejecución y la programación	Resoluciones e informes de prestaciones adicionales, mayores o menores metrados y deductivos	Infobras y SSI	Contexto de las variaciones de metrado	Se excluye solo si existieron y no están publicados
Ejecución	Documentación de entrega del terreno	Verificar la fecha efectiva de inicio y las condiciones del comienzo de la ejecución	Acta de entrega de terreno u otro documento equivalente	Infobras y SSI	Fecha efectiva de inicio	Se excluye la obra

Fuente: Elaboración propia.

Tabla 7: Sesgos derivados de seleccionar la muestra.

Sesgo	Cómo apareció en la selección	Efecto probable en la muestra	Cómo se atiende
Admisión de obras con paralizaciones neutralizadas	Se incluyeron obras con muchas paralizaciones que culminaron, sin contar el tiempo paralizado como retraso	La muestra contiene obras con interrupciones, pero sin el retraso que estas generan; se subestima el desvío de plazo asociado	Se declara el número de obras con paralizaciones y que el alcance es "duración efectiva neta de paralizaciones"
Admisión de expedientes incompletos con registro completado	Obras a las que faltaba el registro de una actividad se admitieron completando el dato con metrado entre rendimiento	Parte de la información viene de la planificación y no de la observación, lo que inclina la muestra hacia la coherencia con lo planificado	Se declara el número y el porcentaje de actividades completadas
Admisión por reconstrucción de la programación	Obras sin archivo de Microsoft Project, pero con PDF del Gantt y precedencias, se reconstruyeron manualmente	Solo ingresan obras cuyo PDF permitía reconstruir la programación; la muestra mezcla programaciones nativas y reconstruidas	Se declara cuántas obras se reconstruyeron y cómo se verificó
Accesibilidad de la documentación (conveniencia)	Obras con documentación solo en PDF se trasladaron manualmente a Excel	La selección depende de la legibilidad de los documentos y de la capacidad de procesamiento manual; las obras de documentación más difícil pueden estar subrepresentadas	Se declara como muestreo por conveniencia dentro de los criterios de inclusión

Fuente: Elaboración propia.

La información técnica correspondiente a la etapa de ejecución fue obtenida principalmente de las plataformas Infobras y del Sistema de Seguimiento de Inversiones (SSI). Por otro lado, la información técnica correspondiente a la etapa de planificación fue obtenida a través de la plataforma del Organismo Supervisor de las Contrataciones del Estado (OSCE), una vez recopilada y verificada la documentación técnica de ambas etapas, se seleccionó la muestra de estudio, considerando únicamente aquellas obras que cumplían con la totalidad de los criterios de inclusión establecidos para la investigación.

Figura 6: Diagrama de flujo de selección de muestra



Nota: Este diagrama muestra como fue el flujo de selección de la muestra

Fuente: Elaboración propia

A diferencia de los enfoques estadísticos tradicionales, donde la selección de la muestra busca obtener una representación de la población para realizar inferencias, en los modelos basados en Machine Learning el criterio principal consiste en disponer de datos completos, consistentes y comparables que permitan identificar patrones de comportamiento entre las variables de estudio. En ese sentido, se procedió a recopilar la información correspondiente a las partidas y actividades que conformaban la programación de cada proyecto. El análisis no se centró únicamente en la cantidad de obras seleccionadas, sino en la información generada por cada actividad durante su periodo de ejecución. Para ello cada actividad fue desagregada en registros de avance real, integrando variables tanto de la etapa de planificación como de la etapa de ejecución. Este procedimiento permitió transformar la información de cada proyecto en una base de datos estructurada, conformada por un elevado número de registros.

Tabla 8: Obras representativas seleccionadas para el entrenamiento del modelo.

Código INFOBRAS	Código Único de Inversión	Código SNIP	Nombre de la obra	N° de partidas
160001	2181482	249386	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DEL AA. HH. VILLA FLORIDA, DISTRITO DE ALTO SELVA ALEGRE - AREQUIPA - AREQUIPA	149
61011	2264981	316061	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL BLOQUE 1 EN EL CENTRO POBLADO SAN JUAN EL ALTO, DISTRITO DE MAJES - CAYLLOMA - AREQUIPA	186
135495	2474725	2474725	MEJORAMIENTO DE LOS SERVICIOS DE MOVILIDAD URBANA DE LAS VÍAS SECUNDARIAS en la Asociación de Vivienda Villa Magisterial DEL DISTRITO DE CERRO COLORADO - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA	95
154024	2305596	344356	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ZONA 2 SECTOR C DE LA ASOCIACIÓN URBANIZADORA CIUDAD DE DIOS DISTRITO DE YURA - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA- I ETAPA	288
500252	2474487	2474487	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA ASOCIACIÓN DE VILLA CHACHANI DEL DISTRITO DE CERRO COLORADO - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA. CUI 2474487	241
513074	2404316	2404316	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL P.J. SAN JOSÉ BLOQUE 1 MARGEN DERECHA - DISTRITO DE TIABAYA - PROVINCIA DE AREQUIPA - REGIÓN AREQUIPA	212
170763	2305596	344356	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ZONA 2 SECTOR C DE LA ASOCIACIÓN URBANIZADORA CIUDAD DE DIOS DISTRITO DE YURA - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA - II ETAPA	242
504419	2444005	2444005	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES JORGE CHAVEZ, JOSE GALVEZ, PAZ SOLDAN, MIGUEL GRAU, FRANCISCO BOLOGNESI, RODRIGUEZ BALLON, RAMON CASTILLA, LINO URQUIETA, CALVARIO, MISTIY TNTE RODRIGUEZ EN EL P.T DE MIRAFLORES DEL DISTRITO DE MIRAFLORES - PROVINCIA DE AREQUIPA - DEPATAMENTO DE AREQUIPA - 2da° ETAPA	131
175705	2339196	378064	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DEL PASAJE TASAHUAYO TRAMO DE LA PROLONGACION AVENIDA DOLORES HASTA LA AVENIDA COLON, DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO - AREQUIPA - AREQUIPA	133

175438	2512753	2512753	MEJORAMIENTO DE LA TRANSITABILIDAD VIAL Y PEATONAL DE LAS CALLES Y PASAJES DEL ANEXO LA BANDA DEL DISTRITO DE YARABAMBA - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA	247

Nota: Las obras que conforman la muestra fueron seleccionadas mediante una búsqueda manual en la plataforma Infobras, priorizando la integridad de los expedientes. Como requisito obligatorio cada proyecto debía contar con la programación contractual, la secuencia real de ejecución física y la documentación de las ampliaciones de plazo aprobadas y adicionales y deductivos. El principal reto radicó en identificar proyectos que dispusieran de la trazabilidad de avance a nivel diario, parámetro crítico para garantizar la precisión en el entrenamiento del modelo predictivo, también se muestran la cantidad de partidas.

Fuente: Elaboración Propia.

La selección inicial consta de 10 proyectos, la capacidad de aprendizaje de un modelo supervisado no depende de la cantidad de obras, sino del número de instancias u observaciones dataset generadas. En este contexto, la unidad de análisis corresponde a cada registro individual y no al proyecto global (Geron, 2026).

Para estructurar la base de datos de entrenamiento, se combinaron las partidas ejecutadas, la secuencia temporal y los atributos técnicos de cada obra.

Tabla 9:
Numero de registros para dataset.

Numero de registros para dataset
$N_{registros} = Partida * N_{dias\ en\ ejecucion}$

Nota: La dimensión del dataset se expresa mediante registros u observaciones generados a partir de la desagregación de las obras en partidas y su seguimiento temporal, incorporando las variables o features de entrada. Cada fila representa una observación utilizada por el modelo para relacionar las características de entrada con la variable objetivo de duración. Los registros

mantienen su pertenencia a la obra de origen, por lo que no representan unidades de análisis independientes.

Fuente: Elaboración propia.

Como resultado del proceso de estructuración del conjunto de datos, la presente investigación obtuvo un total de 8539 registros, los cuales constituyen la base para el entrenamiento, validación y evaluación del modelo de Machine Learning. La generación de este volumen de información responde a la desagregación de cada obra en sus respectivas partidas, su evolución temporal durante la ejecución y las variables técnicas consideradas en el estudio. En los títulos posteriores se describirá el proceso de depuración, integración y validación de los datos, resaltando que la calidad, consistencia y confiabilidad del conjunto de datos son factores determinantes para el desempeño del modelo predictivo. En este sentido, la justificación del tamaño del conjunto de datos no se fundamenta en la aplicación de fórmulas clásicas de cálculo de muestras para estudios de inferencia estadística, sino en la construcción de un *dataset* suficientemente amplio, representativo de las condiciones del problema y conformado por observaciones de alta calidad, conforme a los principios metodológicos del aprendizaje automático.

4.4. Limpieza de datos y preparación de datos

4.4.1. Organización de la información

Se procedió a organizar la información correspondiente a los cronogramas de planificación y ejecución de cada obra. Los cronogramas de ejecución, obtenidos principalmente en formato PDF, fueron trasladados a Microsoft Excel para facilitar la revisión, organización y procesamiento de los registros.

Asimismo, los cronogramas de planificación, disponibles en archivos de Microsoft Project, fueron exportados a Microsoft Excel. De esta manera, ambas fuentes fueron estructuradas bajo

un formato común, permitiendo comparar las actividades planificadas con las actividades ejecutadas.

Como resultado, se obtuvo para cada obra una matriz diferenciada con la información de planificación y ejecución, la cual sirvió como base para las siguientes etapas de limpieza y preparación de los datos.

4.4.2. Verificación de las actividades de planificación y ejecución

Posteriormente, se realizó una revisión individual de las actividades de cada cronograma, con la finalidad de verificar la correspondencia entre las actividades planificadas y las ejecutadas durante el desarrollo de cada obra.

En este proceso se compararon ambos cronogramas, identificándose las actividades que se mantuvieron respecto a la planificación inicial y aquellas que fueron incorporadas durante la ejecución.

Esta comparación permitió determinar las diferencias entre la programación inicial y la ejecución real, constituyendo una base para la posterior homologación y codificación de las actividades.

4.4.3. Estandarización de la nomenclatura de las actividades

Durante la revisión de los cronogramas se identificaron diferentes denominaciones para actividades que correspondían a un mismo proceso constructivo. Mantener estas diferencias habría generado categorías distintas para una misma actividad dentro de la base de datos.

Por ello, se procedió a estandarizar la nomenclatura mediante un sistema de codificación, asignando un código único a las actividades que representaban el mismo concepto o proceso constructivo, independientemente de su denominación original.

a continuación, se mostrará una tabla con la agrupación de dichos códigos:

Tabla 10: Tabla de asignación de códigos por una misma denominación

N°	DENOMINACION ENCONTRADA	CODIGO ASIGNADO
1	CARTEL DE OBRA	CR-001
2	CERCO PERIMETRICO	CP-001
3	MOVILIZACION	MD-001
4	LIMPIEZA TERRENO	LT-001
5	TRANSPORTE Y MOVILIZACION	TP-001
6	DEMOLICION	DL-001
7	TRAZO Y REPLANTEO	TR-001
8	ELIMINACION	EM-001
9	ACARREO	AC-001
10	CURADO	CD-001
11	CORTE DE TERRENO	CT-003
12	JUNTAS	JT-001
13	RELLENO	RL-001
14	ACERO	FY-001
15	ENCOFRADO Y DESENCOFRADO	ED-001
16	EXCAVACION	EX-001
17	PERFILADO Y COMPACTACION	PC-001
18	PINTADO	PP-001
19	SEÑALES TRANSITO	SL-001
20	CAMA DE ADOQUIN	AR-001
21	BARANDA METALICA	BM-001
22	BASE	BS-001
23	CARPETA ASFALTICA	AS-001
24	CONCRETO	CN-001
25	CONCRETO CUNETAS	CN-CU1
26	CONCRETO MUROS	CN-MU1
27	CONCRETO PAVIMENTO RIGIDO	CN-PR1
28	CONCRETO RAMPAS	CN-RA1
29	CONCRETO SARDINELES	CN-SA1
30	CONCRETO VEREDAS	CN-VE1
31	CONCRETO ELEMENTOS ESTRUCTURALES	CN-ZA1
32	CONCRETO SANITARIAS	CN-SN1
33	CONCRETO SOLADO	CN-SO1
34	CONCRETO REJILLAS	CN-RE1
35	ADOQUIN	AQ-001
36	IMPRIMACION	IM-001
37	SANITARIAS	SR-001
38	TARRAJEO	RR-001
39	ACABADO EN CONCRETO	AB-001
40	SEMBRADO	SM-001
41	RIEGO	RO-011
42	ARENADO PARA IMPRIMACION	AI-001
43	BARRIDO	BR-084
44	SELLADO DE ADOQUIN	SQ-001
45	POSTES	PO-001
46	VARIOS	VS-001
47	ARENA PARA CAMA DE DRENAJE	CM-001

Nota: cada actividad fue agrupada y se le asigno un código equivalente.

Fuente: Elaboración propia.

La asignación de los códigos se realizó considerando la equivalencia técnica y el proceso constructivo de las actividades, y no únicamente la similitud entre sus denominaciones. De esta manera, se estableció una clasificación uniforme de las actividades presentes en las diferentes obras. La agrupación de las actividades y sus respectivos códigos se presenta en los Anexos.

4.4.4. Estructuración de la información

Una vez concluido el proceso de limpieza y estandarización de las actividades, se procedió a estructurar la información en una matriz de datos. El propósito de esta etapa fue organizar las características de cada actividad de manera uniforme, estableciendo una estructura que permitiera relacionar la información correspondiente a la planificación con el comportamiento observado durante la ejecución.

Para ello, cada actividad fue identificada y organizada mediante un conjunto de variables que describen sus características, su relación dentro del cronograma y su comportamiento diario durante la ejecución. La estructura adoptada permitió desagregar la información de cada partida en registros correspondientes a los días en los que esta fue trabajada.

Las variables utilizadas para estructurar la información fueron las siguientes:

Tabla 11: Tabla de variables para el modelo de machine learning.

Variable	Forma de organización	Fuente
Obra ID	Identificación de la obra que se está utilizando sus datos.	planificación/ejecución
ID partida	Agrupación de partidas.	planificación/ejecución
Número de partida según MS Project	Identifica la posición o número asignado a la actividad dentro del cronograma de Microsoft Project.	planificación
Descripción de la partida	Contiene la denominación de la actividad tal como aparece en el cronograma.	planificación
Predecesoras	Registra las actividades que deben ejecutarse previamente para que pueda iniciarse la actividad analizada, de acuerdo con la lógica del cronograma.	planificación/ejecución
Código de partida	Corresponde al código estandarizado asignado durante la etapa de limpieza y agrupación de actividades equivalentes.	planificación/ejecución
Metrado total	Representa la cantidad total de trabajo prevista para la actividad.	planificación
Rendimiento	Representa la cantidad de trabajo que puede ejecutarse por unidad de tiempo, de acuerdo con la información disponible para la actividad.	planificación
Duración total en días	Corresponde al número total de días considerados para la ejecución de la actividad.	ejecución
Día trabajado	Identifica el día específico de ejecución de la actividad dentro de su periodo total de trabajo.	ejecución
Metrado diario	Representa la cantidad de trabajo ejecutada durante cada día de trabajo.	ejecución
Metrado acumulado	Corresponde a la acumulación progresiva del metrado ejecutado hasta cada día de trabajo.	ejecución
Es el primer día	Variable indicadora que permite identificar si el registro corresponde al primer día de ejecución de la actividad.	ejecución
Es el último día	Variable indicadora que permite identificar si el registro corresponde al último día de ejecución de la actividad.	ejecución
Porcentaje completado	Representa el avance acumulado de la actividad respecto al metrado total considerado.	ejecución

Nota: Esta tabla muestra las variables y la forma de organización.

Fuentes: Elaboración propia.

4.4.5. Organización de las actividades con las variables identificadas

Una característica importante de la estructura desarrollada fue que la información no se mantuvo únicamente a nivel de actividad completa, sino que cada actividad fue desagregada en función de los días en los que se desarrolló.

Tabla 12: Ejemplo de la estructuración de la información.

DESCRIPCION_PARTIDA	PREDECESORAS	CODIGO_PARTIDA	METRADO_TOTAL	RENDIMIENTO	DURACION_TOTAL_DIAS	DIA_TRABAJADO	METRADO_DIARIO	METRADO_ACOMULADO	ES_PRIMER_DIA	ES_ULTIMO_DIA	PORCENTAJE COMPLETADO
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	1	2112	2112	1	0	6%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	2	2120	4232	0	0	11%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	3	2114	6346	0	0	17%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	4	2108	8454	0	0	22%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	5	2110	10564	0	0	28%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	6	2107	12671	0	0	33%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	7	2123	14794	0	0	39%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	8	2103	16897	0	0	44%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	9	2105	19002	0	0	50%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	10	2113	21115	0	0	55%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	11	2125	23240	0	0	61%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	12	2100	25340	0	0	66%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	13	2107	27447	0	0	72%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	14	2124	29571	0	0	77%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	15	2103	31674	0	0	83%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	16	2124	33798	0	0	88%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	17	2113	35911	0	0	94%
PERFILADO Y COMPACTACION	54	PC-001	38334.55	1200	18	18	2423.55	38334.55	0	1	100 %

Nota: Tabla de cómo se está organizando cada actividad con los datos de planificación y ejecución.

Fuente: Elaboración propia.

Una vez homologadas las actividades, se procedió a estructurar las variables que conformaron la matriz de datos. La variable predecesora fue obtenida de los cronogramas de planificación y ejecución. Previamente, se verificó que la secuencia de las actividades planificadas se mantuviera durante la ejecución de las obras, comprobándose su correspondencia.

El metrado total y el rendimiento fueron obtenidos de la planificación. La duración total y los días trabajados correspondieron a los registros de ejecución. El día trabajado permitió desagregar la actividad en registros diarios. Asimismo, el metrado diario y el metrado acumulado fueron obtenidos de los cronogramas de ejecución, permitiendo observar que la cantidad de trabajo ejecutada podía variar entre días.

Las variables primer día y último día permitieron identificar el inicio y término de cada actividad dentro de su periodo de ejecución, mientras que el porcentaje completado permitió representar el avance de la actividad a lo largo de su ejecución.

4.5. Análisis exploratorio de los datos

Desde este apartado se inicia el desarrollo del cuaderno de Machine Learning, cuyo propósito inicial fue conocer el comportamiento de las variables que conforman la base de datos. En esta etapa se buscó identificar las principales características de la información, reconocer posibles patrones y detectar situaciones que pudieran afectar posteriormente el entrenamiento y desempeño del modelo predictivo.

Como primer paso, se realizó la carga de las librerías necesarias para el procesamiento, análisis y visualización de los datos. Asimismo, se comenzó a estructurar la base de datos bajo los conceptos propios de Machine Learning, diferenciando las variables predictoras o características (features), que contienen la información utilizada por el modelo para realizar las predicciones, y la variable objetivo (target), que corresponde al resultado que se busca estimar mediante el modelo predictivo.

Código para la importación de librerías, manejo y análisis de datos.

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from scipy import stats
```

Nota: pandas: permite trabajar con tablas de datos, como los registros obtenidos de las obras; numpy: permite realizar operaciones numéricas y matemáticas; matplotlib: gráficos básicos; seaborn: gráficos estadísticos más elaborados; scipy: Importa funciones estadísticas.

Fuente: Elaboración propia.

Una vez definida la muestra y consolidada la información correspondiente a las obras seleccionadas, los datos se encontraban organizados en un archivo de Excel bajo una estructura previamente establecida. Para el desarrollo del modelo de Machine Learning, fue necesario trasladar esta información a una estructura de datos compatible con Python, por lo que se desarrolló un código destinado a la carga e integración del conjunto de datos (dataset).

Código para cargar el datase desde un archivo Excel.

```
def load_data(filepath):
    """Carga el dataset desde un archivo Excel."""
    df = pd.read_excel(filepath)
    df.columns = df.columns.str.strip().str.upper().str.replace(' ', '_')

    numeric_coerce = ['ID_PARTIDA', 'PREDECESORAS', 'RENDIMIENTO',
                      'METRADO_TOTAL', 'METRADO_DIARIO', 'METRADO_ACOMULADO']
    for col in numeric_coerce:
        if col in df.columns:
            df[col] = pd.to_numeric(df[col], errors='coerce')

    print(f"Dataset cargado: {df.shape[0]:,} filas x {df.shape[1]} columnas")
    return df
```

Nota: El código define la función load_data(filepath), cuya finalidad es cargar y preparar inicialmente el dataset, permite leer archivos exel, elimina espacios innecesarios al inicio y al

final de los nombres de las columnas, identifica las variables que deben ser tratadas como datos numéricos.

Fuente: Elaboración propia.

Una vez cargado y estandarizado el dataset, se realizó una inspección general de la estructura y calidad de la información. Esta etapa permitió verificar las dimensiones del dataset, identificar el tipo de información que contiene en cada variable, revisar los primeros registros y obtener estadísticas descriptivas de las variables cuantitativas. Asimismo, se realizó una revisión de los valores nulos para detectar posibles datos faltantes que pudieran afectar las etapas posteriores de preparación y modelamiento.

Código para hacer una revisión inicial del dataset.

```
def inspect_data(df):
    """Inspección general del dataset."""
    print("=" * 60)
    print("INSPECCIÓN GENERAL DEL DATASET")
    print("=" * 60)

    print(f"\nDimensiones: {df.shape[0]:,} filas x {df.shape[1]} columnas")

    print("\n--- Tipos de datos ---")
    print(df.dtypes)

    print("\n--- Primeras 5 filas ---")
    display(df.head())

    print("\n--- Estadísticas descriptivas ---")
    display(df.describe().round(2))

    print("\n--- Valores nulos por columna ---")
    nulls = df.isnull().sum()
    print(nulls[nulls > 0] if nulls.sum() > 0 else "No hay valores nulos.")
```

Nota: La función inspect_data() realiza una inspección general del conjunto de datos mediante la revisión de sus dimensiones, tipos de variables, primeros registros, estadísticas descriptivas y valores nulos. Esta evaluación permitió verificar la estructura y calidad inicial de la

información antes de continuar con las etapas de preparación y modelamiento mediante técnicas de Machine Learning.

Fuente: Elaboración propia.

Al ejecutar la función de inspección, se obtuvo inicialmente la clasificación del tipo de dato correspondiente a cada variable del dataset, permitiendo diferenciar aquellas variables de naturaleza numérica de las variables textuales o categóricas. Esta identificación fue necesaria para determinar el tratamiento que posteriormente debía aplicarse a cada variable durante la preparación de los datos, considerando que los algoritmos de Machine Learning requieren que las características de entrada presenten formatos compatibles con los procedimientos de procesamiento y modelamiento.

Tabla 13: Tipos de datos según su formato.

Variable	Tipo	Descripción
OBRA_ID	object	Identificador categórico de la obra civil (10 obras)
ID_PARTIDA	float64	Identificador numérico de la partida
NUMERO_DE_PARTIDA_(MS_PROJECT)	int64	Número de partida según cronograma de MS Project
DESCRIPCION_PARTIDA	object	Descripción textual de la actividad
PREDECESORAS	float64	Código(s) de partidas predecesoras en el cronograma
CODIGO_PARTIDA	object	Código estructurado de la partida
METRADO_TOTAL	float64	Cantidad total de obra programada
RENDIMIENTO	float64	Rendimiento de ejecución (unidades/día)
DURACION_TOTAL_DIAS	int64	Variable objetivo: duración total planificada (días)
DIA_TRABAJADO	int64	Día de ejecución dentro de la partida
METRADO_DIARIO	float64	Metrado ejecutado en el día
METRADO_ACOMULADO	float64	Metrado acumulado hasta el día
ES_PRIMER_DIA	int64	Indicador binario de primer día de ejecución
ES_ULTIMO_DIA	int64	Indicador binario de último día de ejecución
PORCENTAJE_COMPLETADO	float64	Porcentaje de avance acumulado
DURACION_ACOMULADA_DEL_TOTAL_DE_OBRA	int64	Duración acumulada de la obra completa

Nota: object: Texto o caracteres; float64: Números con decimales; int64: Números enteros sin decimales.

Fuente: Elaboración propia a partir de la salida de df.dtypes e inspect_data().

Posteriormente, la función generó una tabla de estadística descriptiva para las variables cuantitativas del dataset, mediante la cual se obtuvieron medidas como el número de observaciones, la desviación estándar, la media, los valores mínimo y máximo y los percentiles de cada variable. Esta información permitió caracterizar inicialmente la distribución de los

datos, evaluar su tendencia central y variabilidad, y realizar una identificación preliminar de posibles valores anómalos o extremos que pudieran representar inconsistencias en los registros o comportamientos particulares de las variables. Esta revisión constituyó un primer mecanismo de control de calidad de los datos antes de continuar con las etapas de preparación y modelamiento predictivo.

Tabla 14: Tabla de estadística descriptiva.

VARIABLES	N° DE DATOS	MEDIA	DESVIACION ESTANDAR	MIN	25%	50%	75%	MAX
ID_PARTIDA	1809	157.59	330.52	0	7.02	12.01	17.02	1542
NUMERO DE PARTIDA_(MS_PROJECT)	8539	98.94	67.3	1	47	79	141	294
PREDECESORAS	8539	88.07	64.85	0	41	72	130	293
METRADO TOTAL	8539	4210.51	8390.3	0	85.09	559.8	3675	64006.97
RENDIMIENTO	8539	228.11	431.72	0	10	50	250	10000
DURACION TOTAL DIAS	8539	21.09	17.82	0	6	16	35	71
DIA TRABAJADO	8539	11.04	11.95	0	2	6	16	71
METRADO DIARIO	8539	232.58	724.88	0	8	41	232	21400
METRADO ACOMULADO	8539	2235.07	5202.87	0	40	259	1582.5	64006.97
ES PRIMER DIA	8539	0.17	0.37	0	0	0	0	1
ES ULTIMO DIA	8539	0.17	0.37	0	0	0	0	1
PORCENTAJE COMPLETADO	8539	0.69	0.31	0	0.33	0.6	0.88	1
DURACION ACOMULADA DEL TOTAL DE OBRA	8539	92.13	60.7	0	47	84	130	374

Notas: Se observa que tenemos 8539 datos, pero para nosotros son la cantidad de filas, en la variable de predecesoras se observa que se tiene un máximo anómalo esto producto de codificaciones concatenadas (66cc; 128,123; etc. Esto debida a la exportación del MS Project), en la columna de mínimos aparece como METRADO TOTAL y RENDIMIENTO con valores de cero esto debido a las actividades con inicio y fin que en si son consideradas como hitos), ES PRIMER DIA Y ES ULTIMO DIA solo tienen dos valores 0 y 1.

Fuente: Elaboración propia a partir de la salida de df.dtypes e inspect_data().

Después de realizar la inspección general del dataset, se efectuó una evaluación de la calidad de los datos, identificando posibles problemas que pudieran afectar el desarrollo del modelo predictivo. Para ello, se verificó la existencia de registros duplicados, se determinó la cantidad de valores únicos de cada variable y se revisaron los rangos de las variables numéricas (MIN y MAX). Esta evaluación permitió obtener una primera percepción sobre la consistencia y variabilidad de la información disponible.

Código para realizar una revisión de la calidad del conjunto de datos.

```
def check_data_quality(df):
    """Verifica la calidad de los datos."""
    print("=" * 60)
    print("CALIDAD DE DATOS")
    print("=" * 60)

    n_duplicates = df.duplicated().sum()
    print(f"\nFilas duplicadas: {n_duplicates}
({100*n_duplicates/len(df):.2f}%)")
    print("\nValores únicos por columna:")
    for col in df.columns:
        print(f"  {col}: {df[col].nunique()} únicos")

    print("\nRango de valores numéricos:")
    for col in df.select_dtypes(include=[np.number]).columns:
        print(f"  {col}: [{df[col].min():.2f}, {df[col].max():.2f}]")

    return {
        'n_duplicates': n_duplicates,
        'n_nulls': df.isnull().sum().sum(),
        'shape': df.shape
    }
```

Nota: La función check_data_quality() evalúa la calidad del conjunto de datos mediante la identificación de registros duplicados, valores únicos, rangos de las variables numéricas y cantidad total de valores nulos. Esta revisión permitió detectar posibles inconsistencias y características anómalas de la información antes de continuar con el procesamiento y modelamiento predictivo.

Fuente: Elaboración propia.

Posteriormente, se realizó un análisis de la distribución de los registros por obra, con la finalidad de conocer cómo se encontraba conformado el conjunto de datos según cada proyecto. Para ello, se contabilizaron los registros asociados a cada obra y se generaron representaciones gráficas que permitieron visualizar tanto la cantidad de observaciones como su proporción respecto al total. Este procedimiento permitió evaluar la composición de la base de datos antes de continuar con el análisis exploratorio.

Código para analizar y representar la cantidad de registros de cada obra.

```
def show_obra_distribution(df, id_col='OBRA_ID'):
    """Muestra distribución de registros por obra."""
    counts = df[id_col].value_counts().sort_index()
    fig, axes = plt.subplots(1, 2, figsize=(14, 5))

    counts.plot(kind='bar', ax=axes[0], color=sns.color_palette('husl',
len(counts)))
    axes[0].set_title('Registros por Obra', fontweight='bold')
    axes[0].set_xlabel('Obra')
    axes[0].set_ylabel('Cantidad de registros')
    axes[0].tick_params(axis='x', rotation=45)

    axes[1].pie(counts, labels=counts.index, autopct='%1.1f%%',
                colors=sns.color_palette('husl', len(counts)))
    axes[1].set_title('Proporción por Obra', fontweight='bold')

    plt.tight_layout()
    plt.show()
    print(f"\nTotal de obras: {len(counts)}")
    print(counts.to_string())
```

Nota: La función show_obra_distribution() muestra la distribución de los registros por obra mediante un gráfico de barras y un gráfico circular, permitiendo visualizar la cantidad de observaciones y la proporción que representa cada obra dentro del conjunto de datos.

Fuente: Elaboración propia.

El análisis permitió conocer la composición y distribución de las observaciones entre las diferentes obras. Esta información resulta relevante porque el modelo de Machine Learning

utiliza los registros disponibles para buscar relaciones entre las variables y la duración de ejecución. Si determinadas obras concentran una cantidad considerablemente mayor de registros, podrían tener una mayor influencia durante el proceso de aprendizaje. Por ello, esta evaluación permitió identificar posibles diferencias en la representación de las obras y considerar su distribución durante las etapas posteriores de preparación, división y validación de los datos.

Tabla 15: Numero de filas por obra.

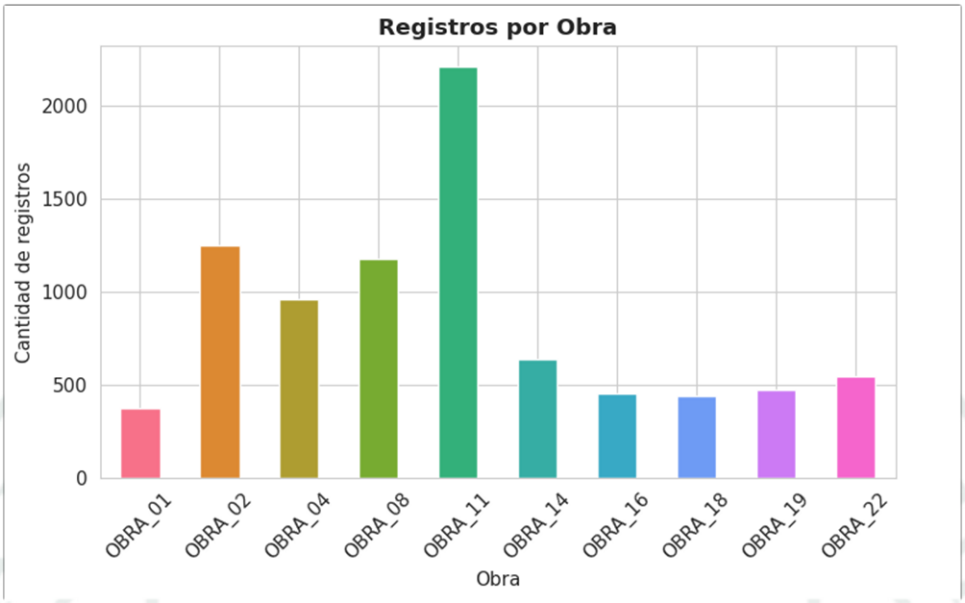
ID OBRA	N° DE DATOS
OBRA_01	373
OBRA_02	1249
OBRA_04	964
OBRA_08	1177
OBRA_11	2215
OBRA_14	641
OBRA_16	454
OBRA_18	443
OBRA_19	475
OBRA_22	548

Nota: Tabla donde se muestra el número de filas por obra, donde la OBRA_11 tiene la mayor cantidad de datos.

Fuente: Elaboración propia a partir de la función show_obra_distribution().

Con la finalidad de facilitar la visualización de la distribución de los datos, se generaron representaciones gráficas que permitieron observar de manera más clara cómo se encuentran distribuidos los registros correspondientes a las diferentes variables del dataset.

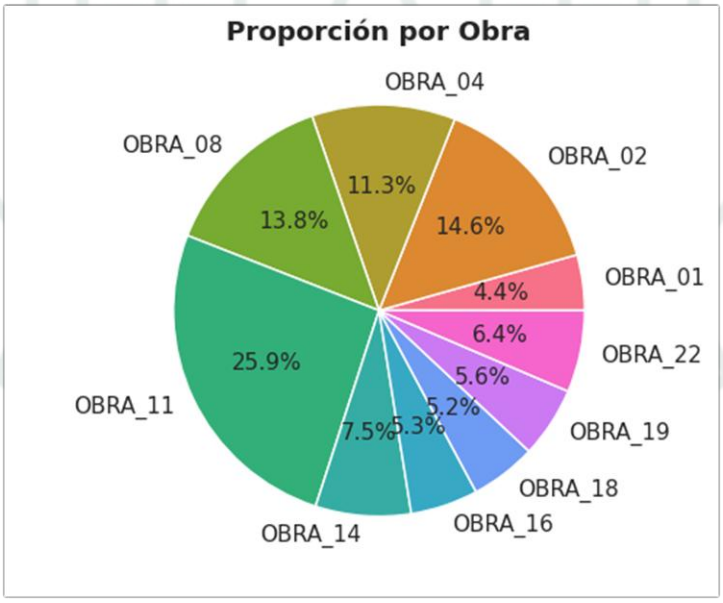
Figura 7: Cantidad de registros por obra.



Nota: Grafico de barras que representa la tabla anterior.

Fuente: Elaboración propia a partir de la función show_obra_distribution().

Figura 8: Porción por Obra.



Nota: Grafica de distribución en porcentaje de datos, de 8539.

Fuente: Elaboración propia a partir de la función show_obra_distribution().

seguidamente, se realizó un análisis de distribución de variables numéricas mediante la representación gráfica de histogramas. El objetivo fue observar cómo se distribuían los valores de cada variable, identificar su concentración y reconocer posibles diferencias entre la media y la mediana. Este procedimiento permitió obtener una primera aproximación al comportamiento estadístico de las variables que posteriormente serían consideradas en el desarrollo del modelo predictivo.

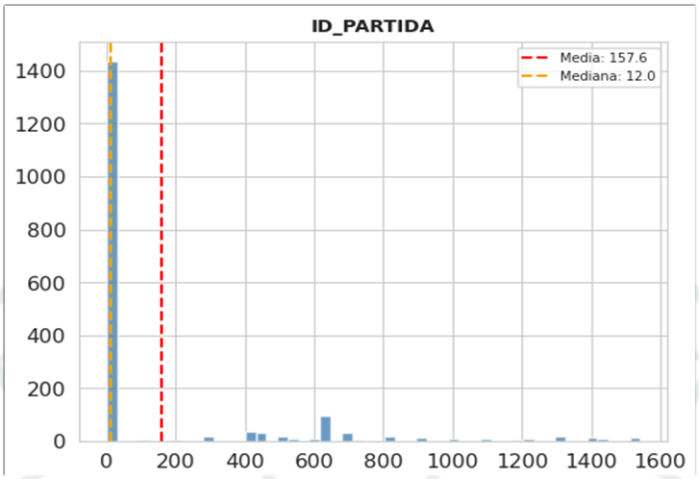
Código para generar histogramas.

```
def plot_numeric_distributions(df, cols, target, ncols=3):
    """Histogramas de todas las variables numéricas."""
    n = len(cols)
    nrows = (n + ncols - 1) // ncols
    fig, axes = plt.subplots(nrows, ncols, figsize=(5*ncols, 4*nrows))
    axes = axes.flatten()
    for i, col in enumerate(cols):
        ax = axes[i]
        data = df[col].dropna()
        ax.hist(data, bins=50, color='steelblue', edgecolor='white',
alpha=0.8)
        ax.axvline(data.mean(), color='red', linestyle='--', label=f'Media:
{data.mean():.1f}')
        ax.axvline(data.median(), color='orange', linestyle='--',
label=f'Mediana: {data.median():.1f}')
        ax.set_title(col, fontsize=10, fontweight='bold')
        ax.legend(fontsize=7)
    for j in range(i+1, len(axes)):
        axes[j].set_visible(False)
    plt.suptitle('Distribución de Variables Numéricas', fontsize=14,
fontweight='bold', y=1.02)
    plt.tight_layout()
    plt.show()
```

Nota: La función plot_numeric_distributions() genera histogramas de las variables numéricas seleccionadas, incorporando la media y la mediana como referencias estadísticas. La representación permite visualizar la distribución, concentración, dispersión y posible asimetría de los datos antes del proceso de modelamiento.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

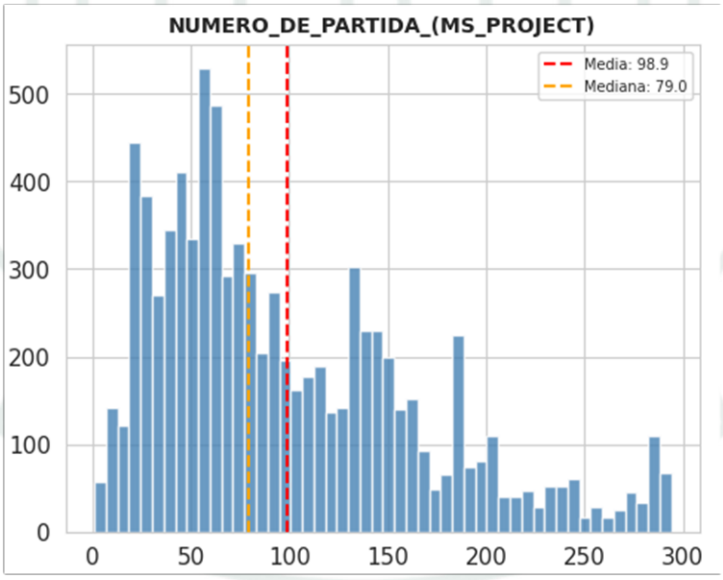
Figura 9: Histograma de ID_PARTIDA de media y la mediana.



Nota: Se evidencio una alta concentración de registros en valores bajos y una distribución extendida hacia valores superiores.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

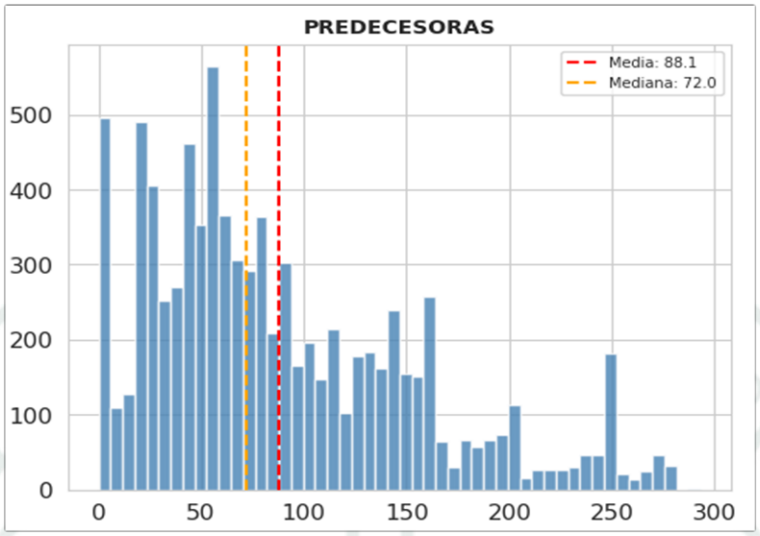
Figura 10: Histograma de NUMERO_DE_PARTIDA_(MS_PROJECT).



Nota: El histograma representa la distribución del número de partida registrado en MS Project, observándose una mayor concentración de registros en los valores iniciales.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

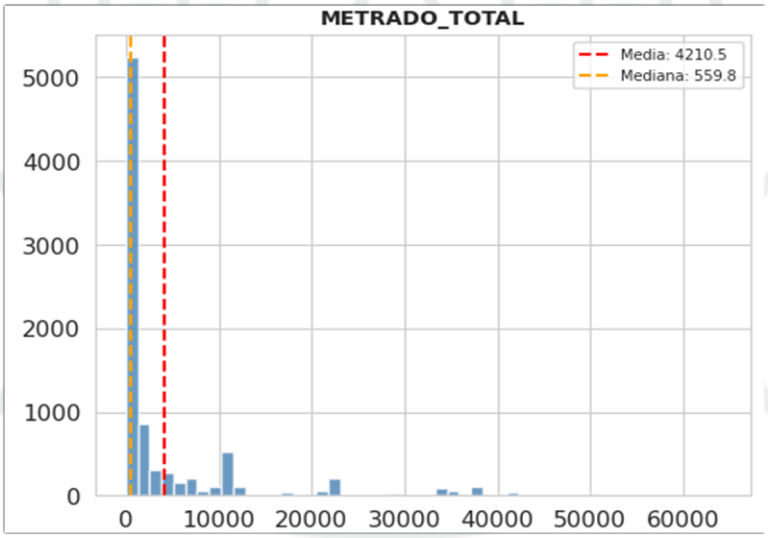
Figura 11: Histograma de PREDECESORAS.



Nota: Se observa una concentración de registros en valores bajos y una menor frecuencia en valores elevados.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

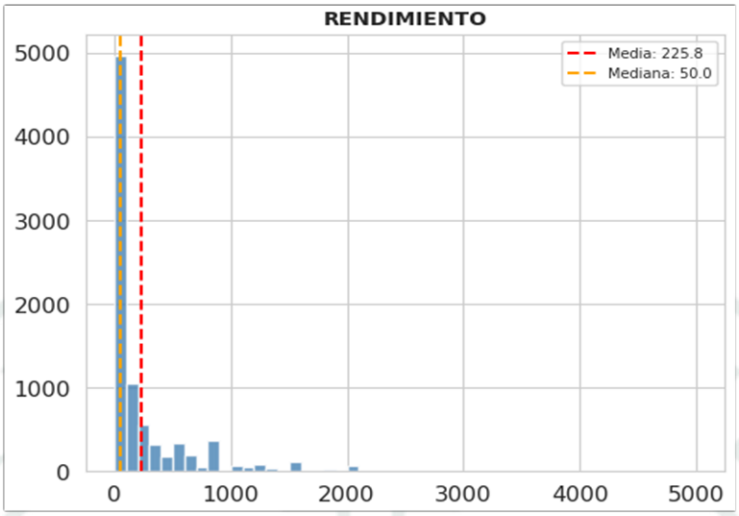
Figura 12: Histograma de METRADO_TOTAL.



Nota: Grafica asimétrica positiva debido a la presencia de metrados elevados en X se representa la cantidad de trabajo y en la Y la frecuencia.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

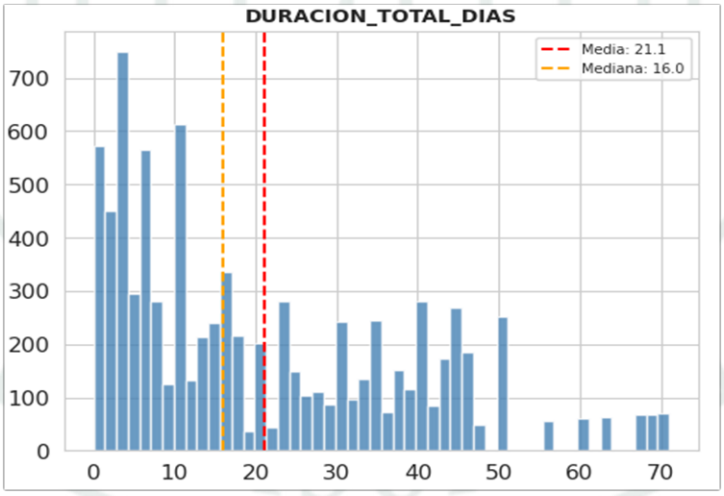
Figura 13: Histograma de RENDIMIENTO.



Nota: Una concentración de registros en valores bajos y una cola extendida hacia rendimientos superiores, en X se representa la velocidad de trabajo y en Y la frecuencia.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

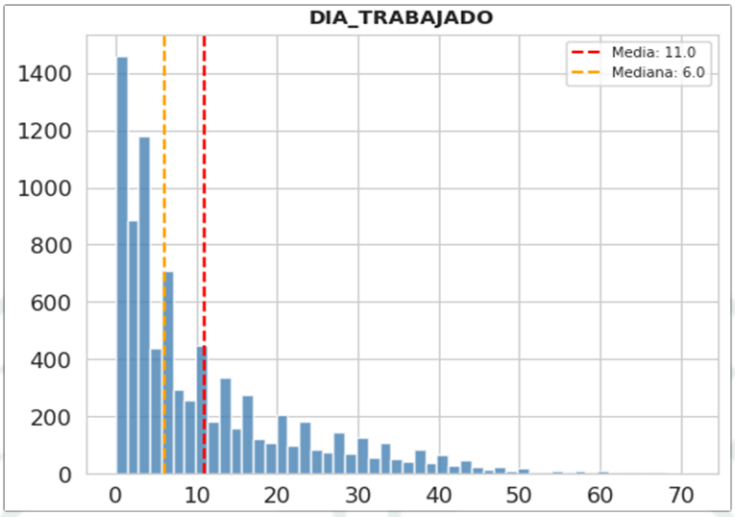
Figura 14: Histograma de DURACION_TOTAL_DIAS.



Nota: Distribución asimétrica hacia valores de mayor duración, en X se representa la duración de de las actividades y en las Y se representa la frecuencia de estas.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

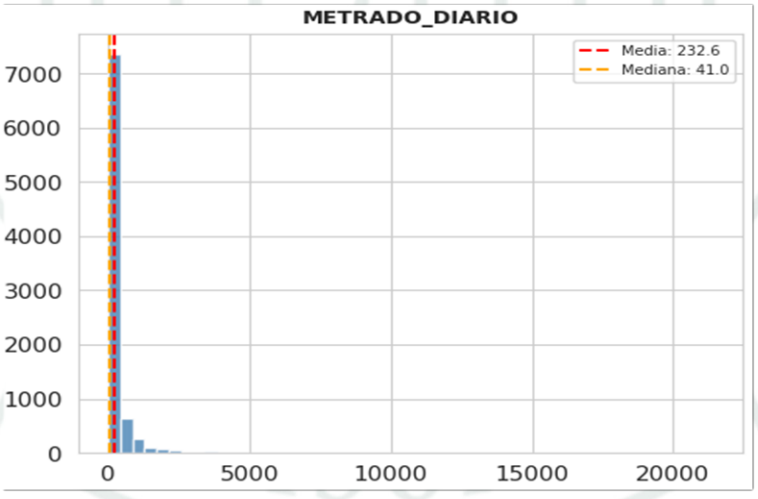
Figura 15: Histograma DIA_TRABAJADO.



Nota: Mayor concentración de registros en los primeros días de ejecución, en X se representa días y en Y la frecuencia de estas.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

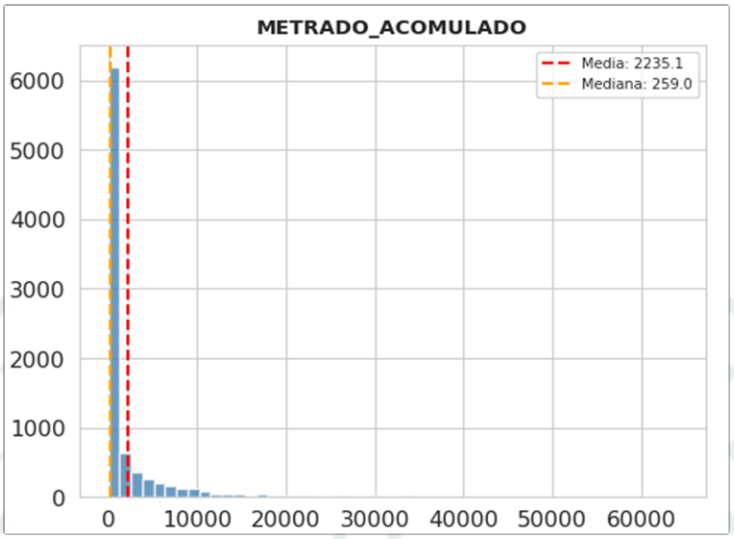
Figura 16: Histograma METRADO_DIARIO



Nota: Una fuerte concentración en valores bajos y una extensión hacia valores elevados en X se representa la cantidad de trabajo y en la Y la frecuencia.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

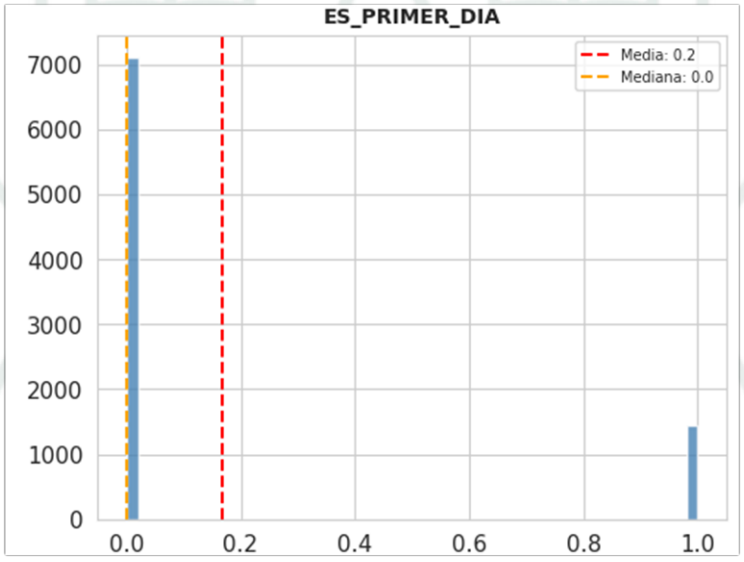
Figura 17: Histograma de METRADO_ACOMULADO.



Nota: Una fuerte asimetría positiva asociada a la presencia de valores acumulados elevados en X se representa la cantidad de trabajo y en la Y la frecuencia.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

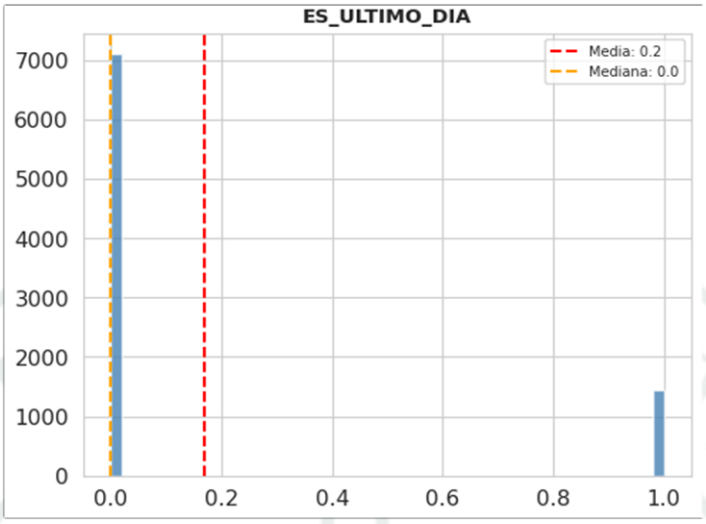
Figura 18: Histograma de ES_PRIMER_DIA.



Nota: Representación de una variable binaria donde 0 es el dato más frecuente.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

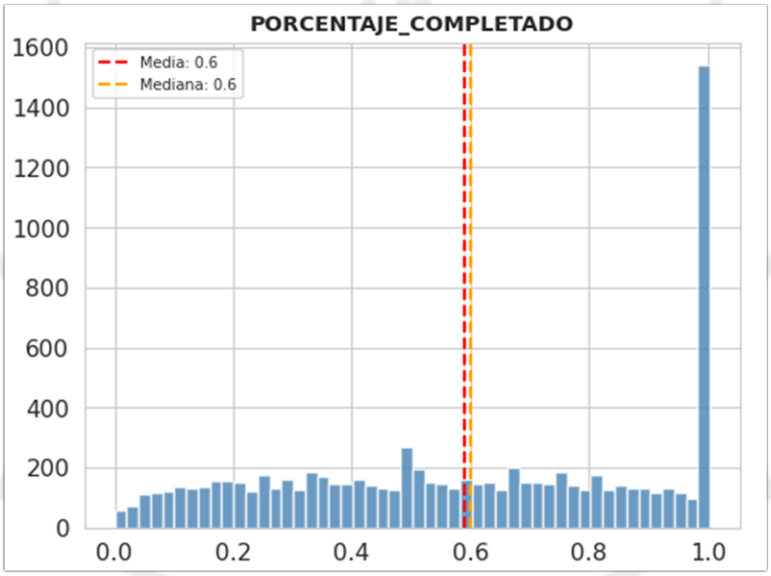
Figura 19: Histograma de ES_ULTIMO_DIA.



Nota: Representación de una variable binaria donde 0 es el dato más frecuente.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

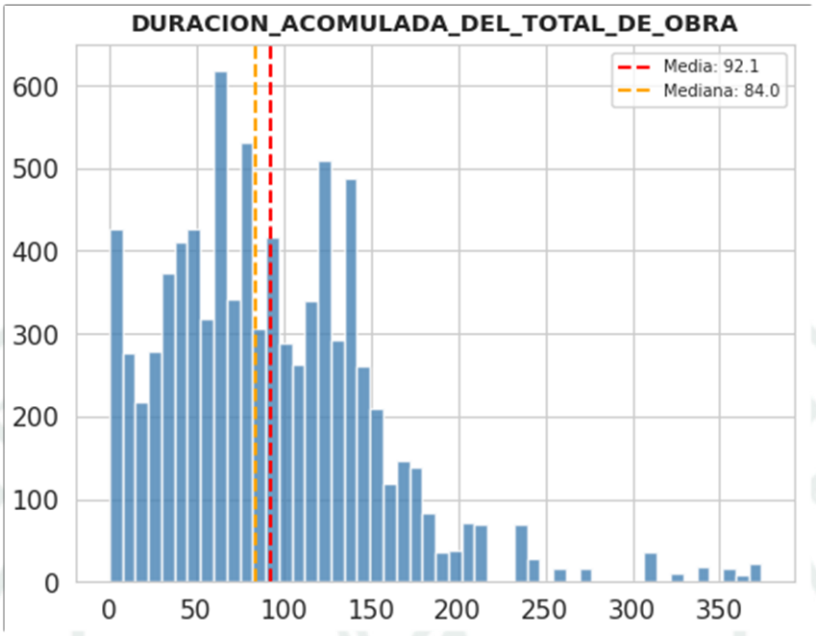
Figura 20: Histograma de PORCENTAJE_COMPLETADO.



Nota: Registros distribuidos a lo largo del proceso de avance y una concentración importante en el valor correspondiente a la culminación, en X se representa el porcentaje de avance.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

Figura 21: Histograma de DURACION_ACOMULADA_DEL_TOTAL_DE_OBRA.



Nota: Concentración en valores intermedios y una extensión hacia duraciones mayores, acumulación de días de ejecución de las obras.

Fuente: Elaboración propia a partir de la función plot_numeric_distributions(df).

4.5.1. Distribución de la variable objetivo

Una vez caracterizada la distribución de las variables mediante el análisis estadístico y su representación gráfica a través de histogramas, se procedió a evaluar la relación existente entre las variables del dataset con la variable objetivo (target) mediante el análisis de correlación.

Código para hacer la correlación de las variables.

```
def plot_correlation_matrix(df, cols):
    """Heatmap de correlación entre variables numéricas."""
    corr = df[cols].corr()
    mask = np.triu(np.ones_like(corr, dtype=bool))
    fig, ax = plt.subplots(figsize=(12, 10))
    sns.heatmap(corr, mask=mask, annot=True, fmt='.2f', cmap='RdBu_r',
                center=0, square=True, linewidths=0.5, ax=ax,
                vmin=-1, vmax=1, cbar_kws={'shrink': 0.8})
    ax.set_title('Matriz de Correlación', fontsize=14, fontweight='bold')
```

```
    plt.tight_layout()
    plt.show()

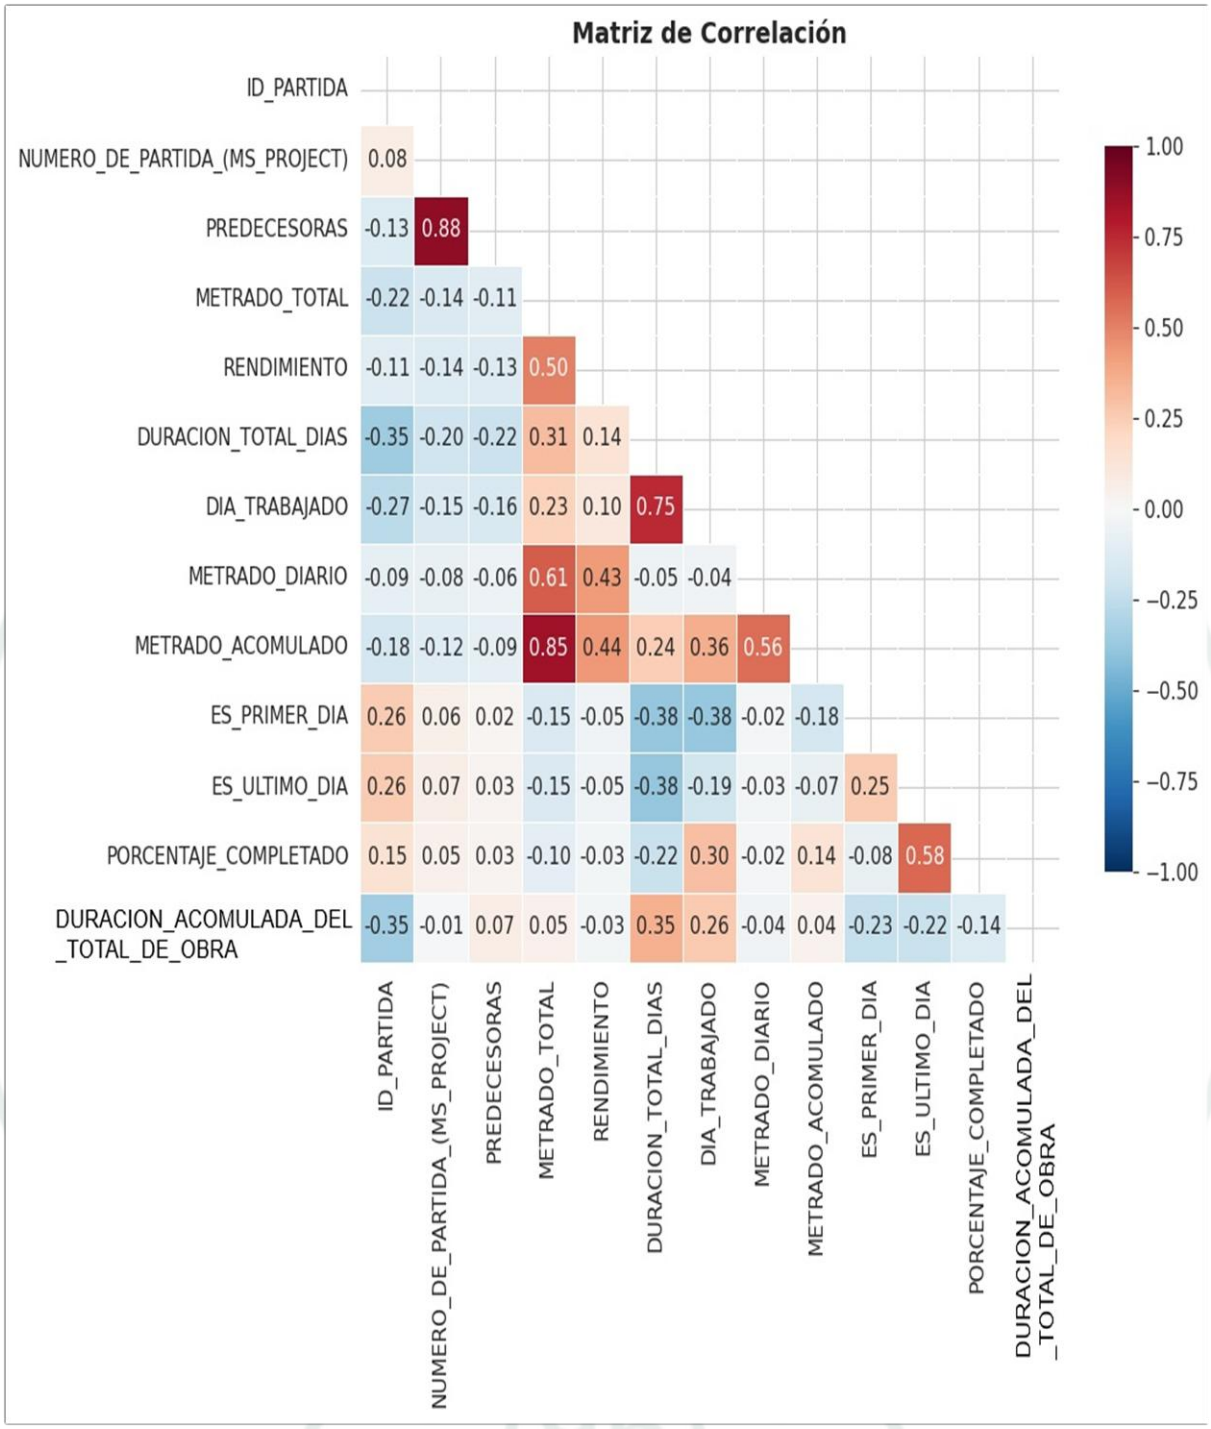
    print(f"\nCorrelaciones con {TARGET}:")
    target_corr = corr[TARGET].drop(TARGET).sort_values(ascending=False)
    for feat, val in target_corr.items():
        bar = '' * int(abs(val) * 30)
        sign = '+' if val > 0 else '-'
        print(f"  {feat:45s} {sign}{abs(val):.3f} {bar}")
```

Nota: El código define la función plot_correlation_matrix(), cuya finalidad es calcular y representar gráficamente las correlaciones entre las variables numéricas seleccionadas.

Fuentes: Elaboración Propia

La matriz de correlación presenta los coeficientes de correlación entre cada par de variables cuantitativas los cuales permiten medir la intensidad y dirección de la relación lineal. Los valores de correlación se encuentran comprendidos entre −1 y 1, donde los valores próximos a 1 representan una relación lineal positiva, los valores próximos a −1 indican una relación lineal negativa y los valores cercanos a 0 evidencian una relación lineal débil o inexistente

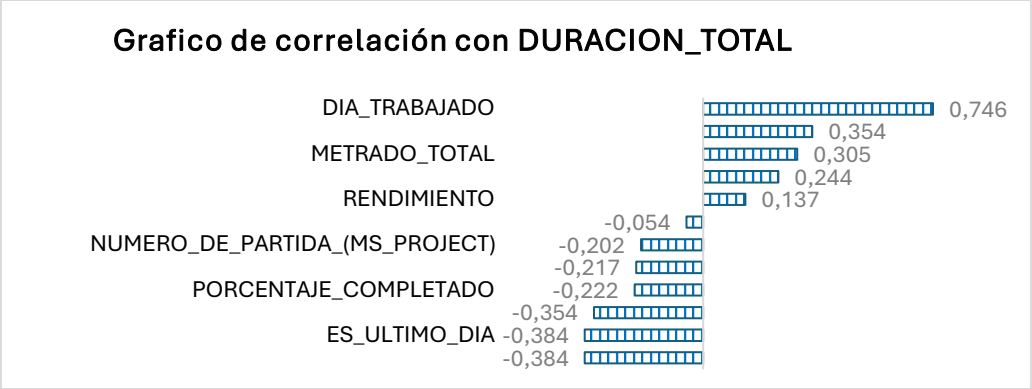
Figura 22: Matriz de correlación.



Nota: Entre más rojo es el cuadrado más relación tienen las variables.

Fuente: Elaboración Propia a partir de la función plot_correlation_matrix().

Figura 23: Correlación de target con feactures.



Nota: relación features con target.

Fuente: Elaboración Propia a partir de la función plot_correlation_matrix().

Comportamiento conjunto de cada variable respecto a la DURACION_TOTAL, identificando posibles tendencias, patrones de asociación, dispersión y presencia de valores extremos.

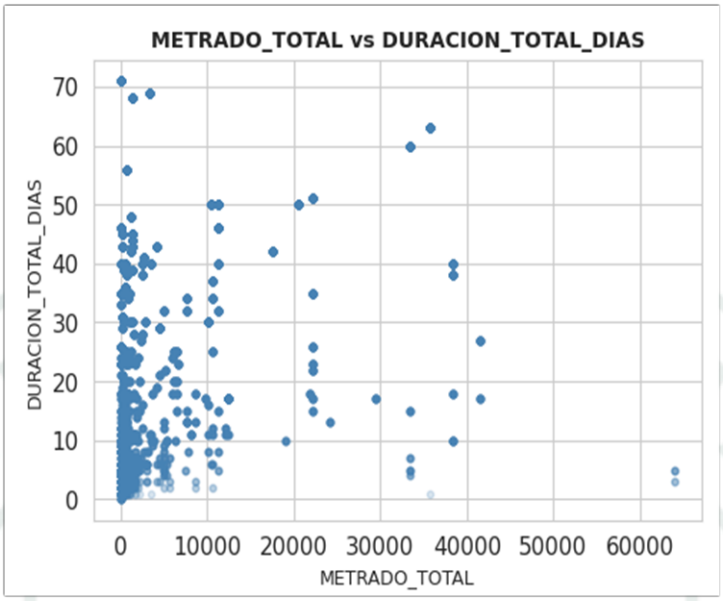
Código para generar diagramas de dispersión.

```
def plot_scatter_vs_target(df, features, target, ncols=3):
    """Scatter plots de features vs target."""
    n = len(features)
    nrows = (n + ncols - 1) // ncols
    fig, axes = plt.subplots(nrows, ncols, figsize=(5*ncols, 4*nrows))
    axes = axes.flatten()
    for i, feat in enumerate(features):
        ax = axes[i]
        ax.scatter(df[feat], df[target], alpha=0.2, s=10, color='steelblue')
        ax.set_xlabel(feat, fontsize=9)
        ax.set_ylabel(target, fontsize=9)
        ax.set_title(f'{feat} vs {target}', fontsize=10, fontweight='bold')
    for j in range(i+1, len(axes)):
        axes[j].set_visible(False)
    plt.suptitle(f'Relación de Features con {target}', fontsize=14,
fontweight='bold', y=1.02)
    plt.tight_layout()
    plt.show()
```

Nota: Este código permite identificar tendencias, dispersión, posibles relaciones no lineales.

Fuente: Elaboración Propia.

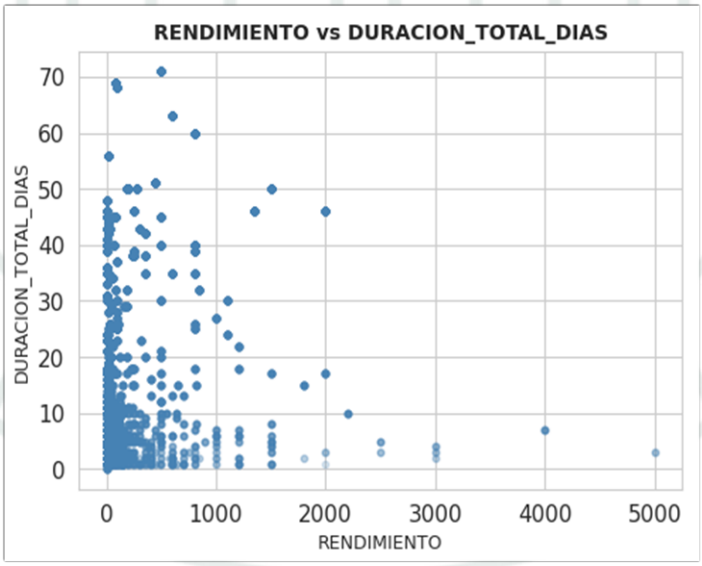
Figura 24: METRADO_TOTAL VS DURACION_TOTAL_DIAS



Nota: No existe una relacion evidente entre las varibales.

Fuente: Elaboración Propia a partir de la función plot_scatter_vs_target.

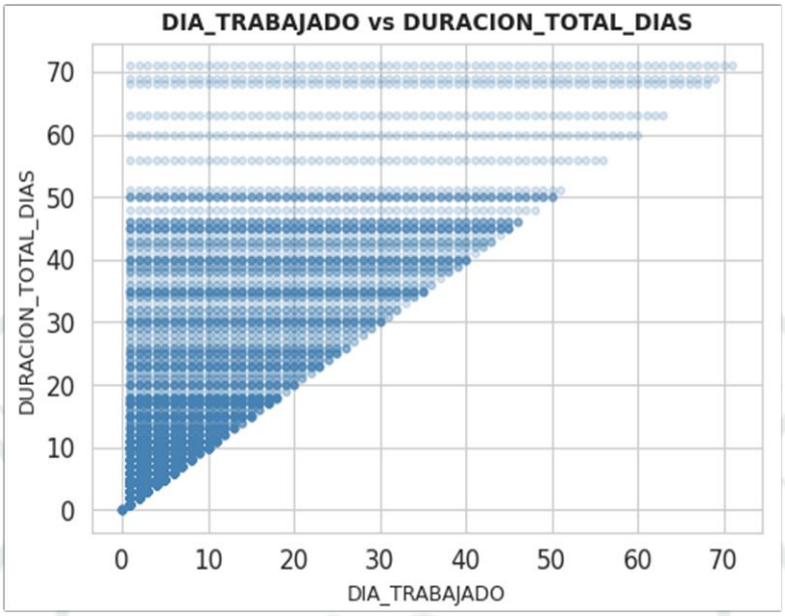
Figura 25: RENDIMIENTO VS DURACION_TOTAL_DIAS.



Nota: No existe una relacion evidente entre las varibales.

Fuente: Elaboración Propia a partir de la función plot_scatter_vs_target.

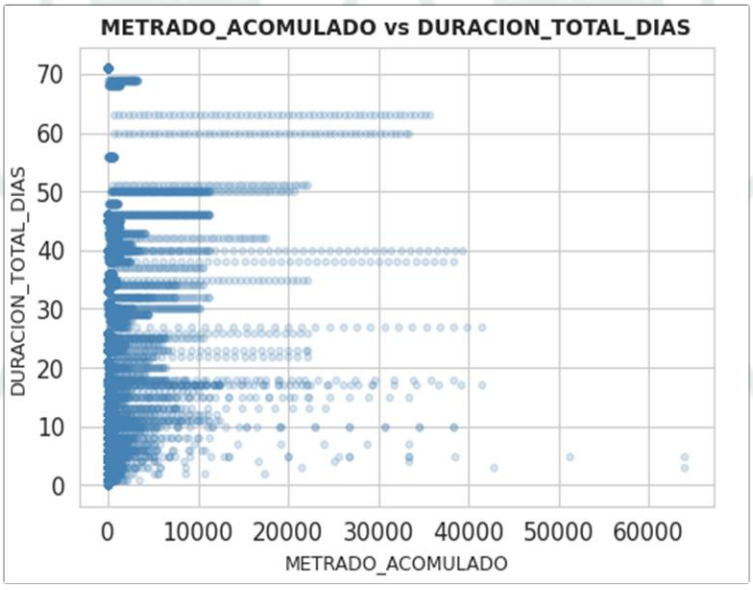
Figura 26: DIA_TRABAJADO VS DURACION_TOTAL_DIAS.



Nota: Existe una relacion lineal con el target..

Fuente: Elaboración Propia a partir de la función plot_scatter_vs_target.

Figura 27: METRADO_ACOMULADO VS DURACION_TOTAL_DIAS.



Nota: No existe una relacion evidente entre las varibales.

Fuente: Elaboración propia a partir de la función plot_scatter_vs_target.

Luego de analizar la relación entre las variables numéricas (feature) y la duración total (target), se procedió a estudiar el comportamiento de la variable objetivo según diferentes categorías. Para ello, se desarrolló una función que representa la distribución de DURACION_TOTAL_DIAS mediante diagramas de caja (box plot) y diagramas de violín (violin plot). Además, se calcularon estadísticas descriptivas para cada categoría, permitiendo comparar las diferencias existentes en la duración de las actividades entre los distintos grupos.

Código cuya finalidad es analizar cómo se distribuye el target.

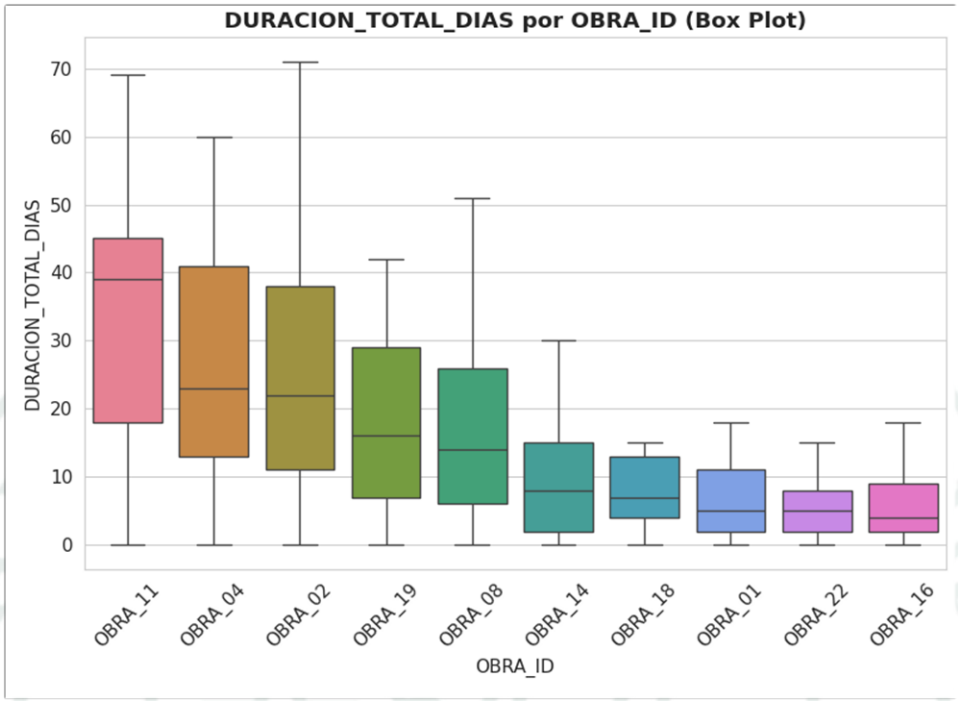
```
def plot_target_by_category(df, cat_col, target):
    """Box plots y violin plots del target por categoría."""
    fig, axes = plt.subplots(1, 2, figsize=(16, 6))
    order =
df.groupby(cat_col)[target].median().sort_values(ascending=False).index
    sns.boxplot(data=df, x=cat_col, y=target, ax=axes[0], order=order,
                palette='husl', showfliers=False)
    axes[0].set_title(f'{target} por {cat_col} (Box Plot)',
fontweight='bold')
    axes[0].tick_params(axis='x', rotation=45)
    sns.violinplot(data=df, x=cat_col, y=target, ax=axes[1], order=order,
                   palette='husl', inner='box', cut=0)
    axes[1].set_title(f'{target} por {cat_col} (Violin Plot)',
fontweight='bold')
    axes[1].tick_params(axis='x', rotation=45)

    plt.tight_layout()
    plt.show()
    print(f"\nEstadísticas de {target} por {cat_col}:")
    stats_df = df.groupby(cat_col)[target].agg(['mean', 'median', 'std',
'count'])
    display(stats_df.sort_values('median', ascending=False).round(2))
```

Nota: Los diagramas de caja y violín representan la distribución de DURACION_TOTAL_DIAS según las categorías de la variable analizada. El eje X corresponde a las categorías y el eje Y a la duración total en días. La tabla complementaria presenta la media, mediana, desviación estándar y cantidad de observaciones de cada grupo, permitiendo comparar el comportamiento de la duración entre categorías.

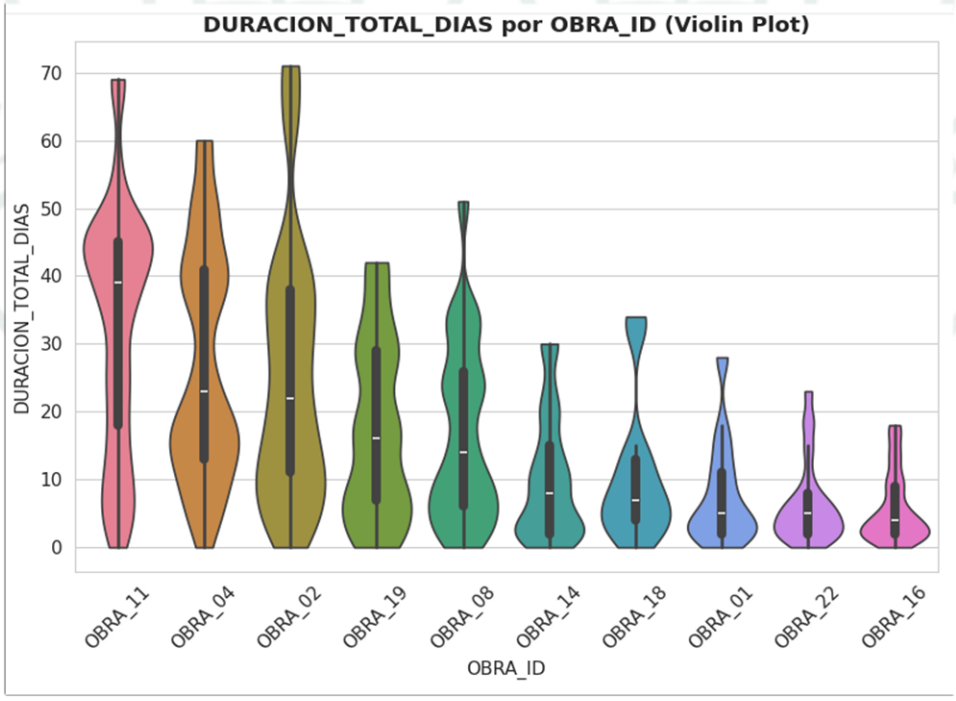
Fuente: Elaboración propia.

Figura 28: Gráfico caja del target (DURACION_TOTAL_DIAS).



Fuente: Elaboración propia a partir de la función plot_target_by_category.

Figura 29: Grafico violín del target (DURACION_TOTAL_DIAS).



Fuente: Elaboración propia a partir de la función plot_target_by_category.

Tabla 16: Estadística del target por grupo.

OBRA_ID	Media	Mediana	Desviación estándar	Cantidad de datos
OBRA_11	32.94	39	18.14	2215
OBRA_04	26.98	23	16.92	964
OBRA_02	25.88	22	19.28	1249
OBRA_19	17.53	16	13.02	475
OBRA_08	17.03	14	13.17	1177
OBRA_14	10.34	8	9.07	641
OBRA_18	10.6	7	10.16	443
OBRA_01	7.91	5	7.53	373
OBRA_22	6.43	5	5.92	548
OBRA_16	5.81	4	5.1	454

Nota: La tabla estadística complementa la representación gráfica mediante el cálculo de la media, mediana, desviación estándar y cantidad de observaciones de cada grupo.

Fuente: Elaboración propia a partir de la función plot_target_by_category.

Un análisis detallado de la distribución de la variable objetivo DURACION_TOTAL_DIAS, con el propósito de evaluar sus características estadísticas y determinar si presentaba condiciones que pudieran afectar el desarrollo del modelo predictivo. Para ello, se comparó la distribución original de la duración con una transformación logarítmica y se utilizó un gráfico Q-Q para evaluar visualmente su aproximación a una distribución normal.

Código de gráfico de variable target.

```
def analyze_target_distribution(df, target):
    """Análisis detallado de la distribución del target."""
    data = df[target].dropna()

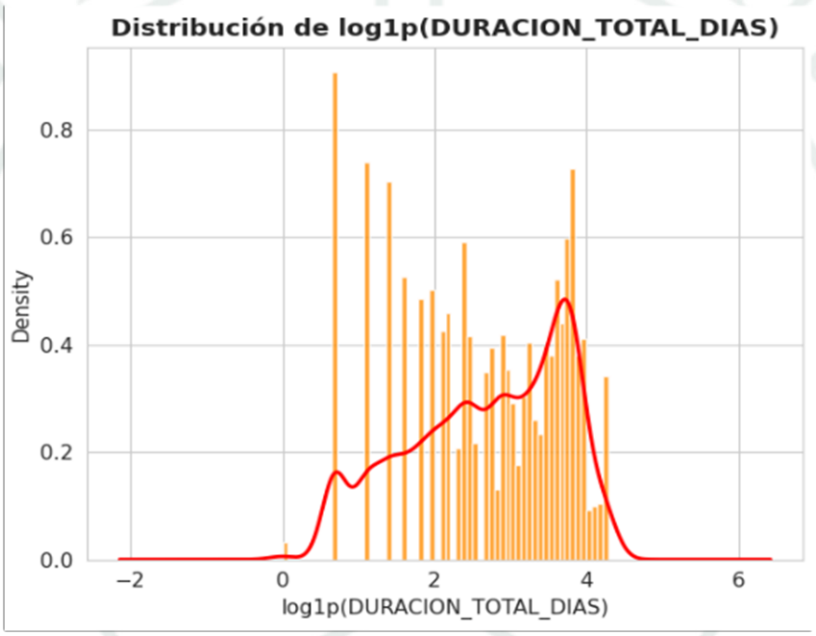
    fig, axes = plt.subplots(1, 3, figsize=(18, 5))
```

```
    axes[0].hist(data, bins=60, color='steelblue', edgecolor='white',
alpha=0.8, density=True)
    data.plot.kde(ax=axes[0], color='red', linewidth=2)
    axes[0].set_title(f'Distribución de {target}', fontweight='bold')
    axes[0].set_xlabel(target)
```

Nota: Transformación mediante log1p() y el gráfico Q-Q respecto a una distribución normal.

Fuente: Elaboración propia.

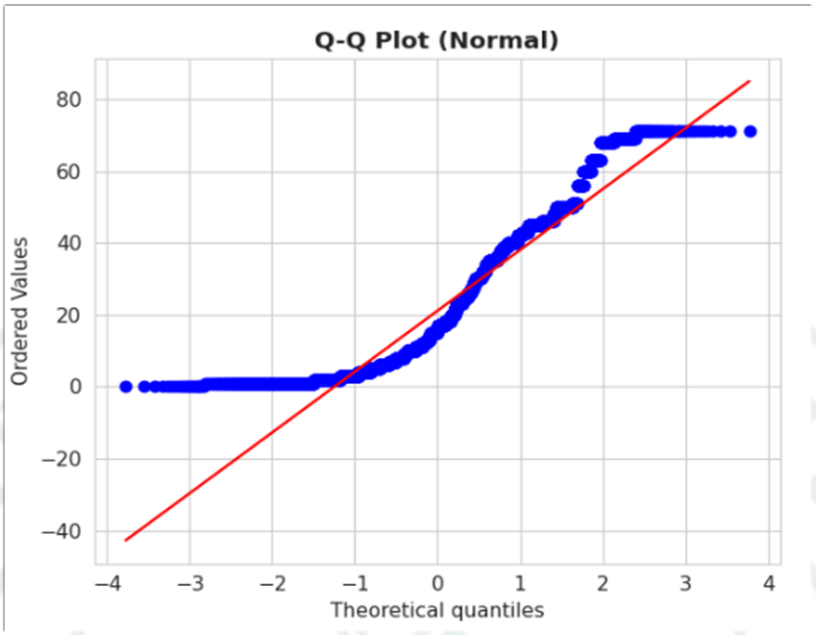
Figura 30: Distribución de log(DURACION_TOTAL_DIAS).



Nota: El log() complementa este análisis al permitir observar si la distribución del target.

Fuente: Elaboración propia a partir de la función analyze_target_distribution.

Figura 31: Q-Q Plot (Normal).



Nota: El Q-Q complementa este análisis al permitir observar si la distribución del target.

Fuente: Elaboración propia a partir de la función analyze_target_distribution.

Tabla 17: Estadística de DURACION_TOTAL_DIAS.

Estadísticas de DURACION_TOTAL_DIAS		
Media:	21.09	días
Mediana:	16	días
Std:	17.82	días
Min:	0	días
Max:	71	días
Skewness:	0.79	factor
Kurtosis:	-0.28	factor

Nota: Se calcularon medidas estadísticas como la media, mediana, desviación estándar, valores mínimo y máximo, asimetría y curtosis.

Fuente: Elaboración propia a partir de la función analyze_target_distribution.

4.5.2. Detección de valores atípicos

Luego realizó la detección de valores atípicos (outliers), con el propósito de identificar observaciones que presentaran comportamientos alejados del resto de los datos. Se implementó una función que permite utilizar dos métodos estadísticos el rango intercuartílico (IQR) y el puntaje Z (Z-score).

Código que permite identificar valores atípicos.

```
def detect_outliers(df, col, method='iqr'):
    """Detecta outliers usando IQR o Z-score."""
    data = df[col].dropna()
    if method == 'iqr':
        Q1 = data.quantile(0.25)
        Q3 = data.quantile(0.75)
        IQR = Q3 - Q1
        lower = Q1 - 1.5 * IQR
        upper = Q3 + 1.5 * IQR
        outliers = data[(data < lower) | (data > upper)]
    elif method == 'zscore':
        z = np.abs(stats.zscore(data))
        outliers = data[z > 3]
    else:
        raise ValueError("method debe ser 'iqr' o 'zscore'")

    pct = 100 * len(outliers) / len(data)
    print(f"  {col} ({method}): {len(outliers)} outliers ({pct:.1f}%)")
    return outliers
```

Nota: La función detect_outliers() identifica posibles valores atípicos.

Fuente: Elaboración propia.

Tabla 18: Detección de outliers.

Variables	Outliers (iqr)	de un conjunto de datos
ID_PARTIDA	371	20.50%
NUMERO_DE_PARTIDA_(MS_PROJECT)	177	2.10%
PREDECESORAS	104	1.20%
METRADO_TOTAL	1402	16.40%
RENDIMIENTO	949	11.10%
DURACION_TOTAL_DIAS	0	0.00%
DIA_TRABAJADO	392	4.60%
METRADO_DIARIO	888	10.40%
METRADO_ACOMULADO	1333	15.60%
ES_PRIMER_DIA	1441	16.90%
ES_ULTIMO_DIA	1440	16.90%
PORCENTAJE_COMPLETADO	0	0.00%
DURACION_ACOMULADA_DEL_TOTAL_DE_OBRA	145	1.70%

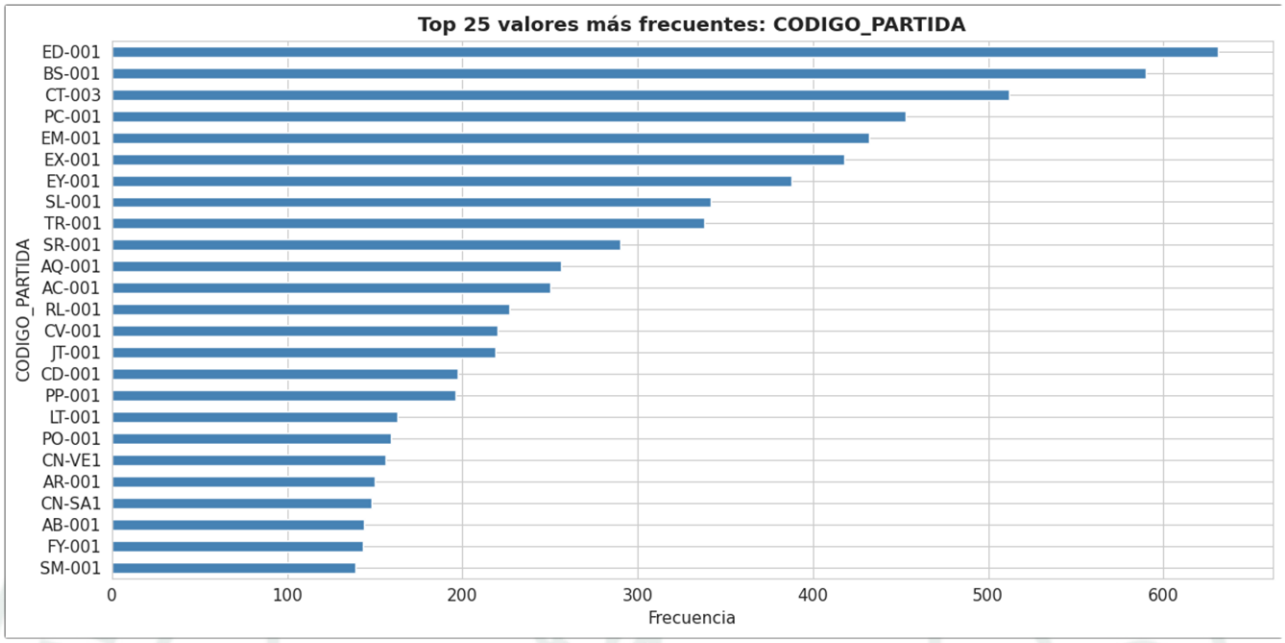
Nota: En este caso se identificó con el método de (iqr), los valores de porcentaje son con respecto a la cantidad de valores únicos.

Figura: Elaboración propia a partir de la función detect_outliers().

4.5.3. Frecuencia de variable categoricas

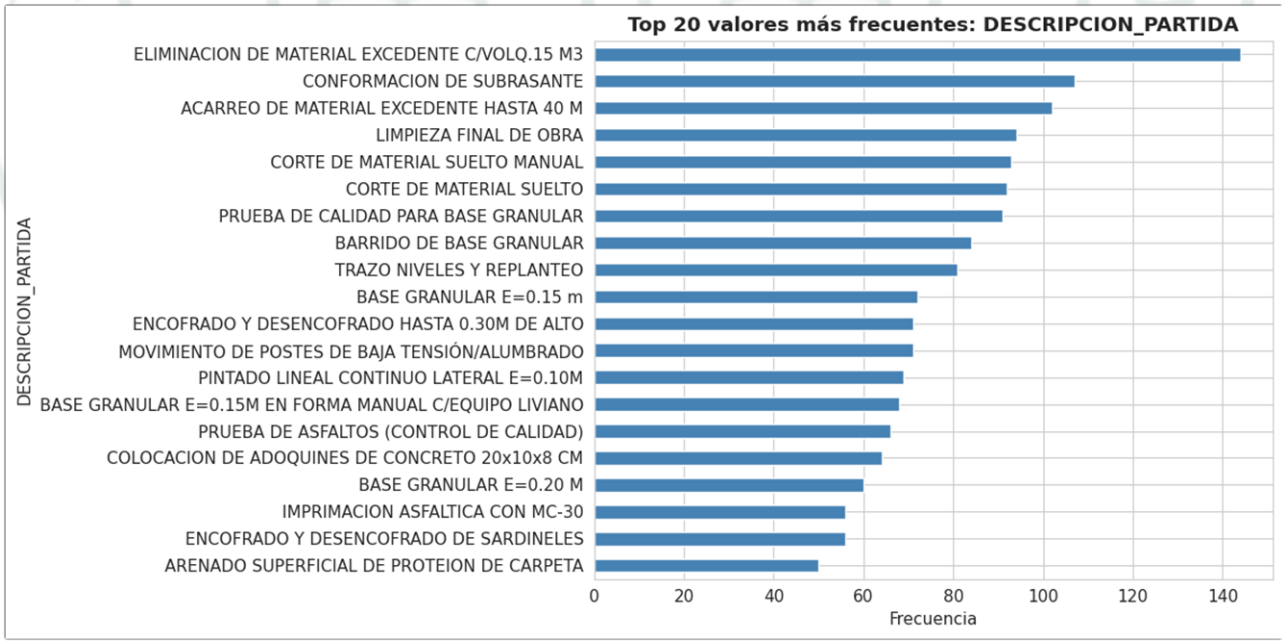
Asimismo, se consideró necesario analizar la frecuencia de aparición de las variables categóricas dentro del dataset.

Figura 32: Frecuencias de CODIGO_PARTIDA.



Fuente: Elaboración propia.

Figura 33: Frecuencia de DESCRIPCION_PARTIDA.



Fuente: Elaboración propia.

4.5.4. Hallazgos clave del EDA

Con el conjunto de datos previamente cargado y estandarizado, se definió la variable objetivo DURACION_TOTAL_DIAS, correspondiente al tiempo total de ejecución de cada partida. Asimismo, se estableció un conjunto de 13 variables numéricas para realizar el análisis exploratorio de los datos (EDA). Este análisis se estructuró en diferentes procedimientos orientados a caracterizar la distribución de las variables, evaluar sus relaciones, identificar posibles valores atípicos y reconocer características relevantes para el posterior desarrollo del modelo predictivo.

En primer lugar, se generaron histogramas de distribución mediante la función plot_numeric_distributions(), con el propósito de visualizar el comportamiento de las variables numéricas. Posteriormente, se construyó una matriz de correlación de Pearson mediante plot_correlation_matrix(), para analizar la intensidad y dirección de las relaciones lineales entre las variables. Asimismo, se generaron diagramas de dispersión entre la variable objetivo y variables relacionadas con el proceso constructivo, tales como METRADO_TOTAL, RENDIMIENTO, PREDECESORAS, DIA_TRABAJADO, METRADO_DIARIO y METRADO_ACUMULADO.

Adicionalmente, se analizó la distribución de la variable objetivo según las diferentes obras de la muestra, con la finalidad de identificar diferencias en los patrones de duración. Se realizó también un análisis estadístico detallado de DURACION_TOTAL_DIAS y una detección de posibles valores atípicos mediante el criterio del rango intercuartílico (IQR). Finalmente, se evaluó la frecuencia de las variables categóricas CODIGO_PARTIDA y DESCRIPCION_PARTIDA, con el propósito de conocer su distribución y cardinalidad.

El análisis de la variable DURACION_TOTAL_DIAS, mediante la función analyze_target_distribution(), permitió caracterizar el comportamiento de la duración de las

partidas. Se obtuvo una media de 21.09 días, una mediana de 16 días y una desviación estándar de 17.82 días, con valores comprendidos entre 0 y 71 días.

El coeficiente de asimetría (skewness = 0.79) evidencia una distribución con asimetría positiva, indicando una mayor concentración de partidas con duraciones relativamente cortas y una menor proporción de partidas con duraciones prolongadas. Esta distribución genera una cola hacia la derecha, asociada principalmente a partidas que presentan mayores tiempos de ejecución. Por su parte, la curtosis de -0.28 indica una distribución ligeramente menos concentrada en torno a su centro respecto a una distribución normal.

Este comportamiento resulta relevante para el modelamiento predictivo, debido a que la variabilidad de la duración puede influir en el ajuste de los algoritmos de regresión y en la capacidad del modelo para representar adecuadamente tanto las partidas de corta duración como aquellas con tiempos de ejecución mayores.

La aplicación del criterio IQR sobre las 13 variables numéricas permitió identificar diferentes proporciones de valores considerados atípicos. Entre las variables con mayor presencia destacaron ID_PARTIDA (20.5 %), METRADO_TOTAL (16.4 %), METRADO_ACUMULADO (15.6 %), ES_PRIMER_DIA y ES_ULTIMO_DIA (16.9 % cada una) y RENDIMIENTO (11.2 %).

En el caso de ES_PRIMER_DIA y ES_ULTIMO_DIA, la identificación de valores atípicos mediante IQR debe interpretarse con precaución, debido a que corresponden a variables binarias y, por su naturaleza, pueden generar clasificaciones atípicas bajo este criterio estadístico sin representar necesariamente errores o inconsistencias en los datos.

Por otro lado, la variable objetivo DURACION_TOTAL_DIAS no presentó valores atípicos según el criterio IQR, registrándose una proporción de 0%. Este resultado permitió diferenciar el tratamiento de la variable objetivo respecto de las variables predictoras y considerar

posteriormente estrategias específicas para controlar los valores extremos de la distribución del target, sin eliminar registros únicamente por su clasificación mediante IQR.

El análisis exploratorio permitió identificar los siguientes aspectos relevantes para el desarrollo del modelo predictivo:

La variable objetivo DURACION_TOTAL_DIAS presenta una distribución asimétrica positiva, con predominio de partidas de corta duración y una menor cantidad de partidas con tiempos de ejecución prolongados.

Las variables METRADO_ACUMULADO, DIA_TRABAJADO y METRADO_DIARIO presentan una asociación importante con la duración. Sin embargo, debido a que estas variables se encuentran relacionadas con el avance temporal de las partidas, su utilización como variables predictoras debe evaluarse cuidadosamente para evitar posibles problemas de fuga de información (data leakage).

Se identificó una variabilidad significativa en los patrones de duración entre las diferentes obras, evidenciando que las características propias de cada proyecto pueden influir en el comportamiento de las partidas.

Se detectaron valores atípicos en variables relacionadas con los metrados, particularmente en METRADO_TOTAL y METRADO_ACUMULADO, por lo que su tratamiento fue considerado en la etapa posterior de preparación de los datos.

La variable CODIGO_PARTIDA presentó una cardinalidad de 65 valores únicos, mientras que DESCRIPCION_PARTIDA alcanzó 954 valores únicos. Esta elevada cardinalidad evidenció la conveniencia de utilizar estrategias de transformación y agrupación de variables antes del entrenamiento de los modelos, en lugar de aplicar directamente una codificación one-hot que pudiera generar un número excesivo de características.

4.6. Preparación de los datos para el modelamiento

Una vez concluido el análisis exploratorio de los datos, se procedió a preparar la información para su utilización en los algoritmos de Machine Learning. Esta etapa correspondió al bloque "Prepare the Data" del cuaderno desarrollado y tuvo como finalidad transformar la base de datos previamente depurada en un conjunto de variables adecuado para el entrenamiento de modelos de regresión.

Código para extraer la parte alfabética.

```
def extract_code_prefix(codigo):
    """Extrae el prefijo alfabético del código de partida (ej. 'CR-001' ->
'CR')."""
    if pd.isna(codigo) or not isinstance(codigo, str):
        return 'UNKNOWN'
    parts = str(codigo).split('-')
    prefix = parts[0].strip()
    prefix = ''.join(c for c in prefix if c.isalpha())
    return prefix if prefix else 'UNKNOWN'
```

Fuente: Elaboración propia.

Esta transformación permitió convertir información contenida dentro del código de cada partida en una característica categórica. En lugar de utilizar únicamente el código individual de cada actividad, se obtuvo un prefijo que puede representar un grupo o tipo general de partida.

Esta variable puede aportar información al modelo porque diferentes tipos de trabajo pueden presentar comportamientos distintos en términos de metrados, rendimientos y duración de ejecución. Por ejemplo, las actividades pertenecientes a un determinado grupo de partidas pueden presentar características de ejecución diferentes respecto a otro grupo.

Además, la transformación evita utilizar directamente el código completo como si fuera una variable numérica, lo que podría generar una interpretación incorrecta de los valores. El prefijo

obtenido puede ser tratado posteriormente como una variable categórica, mediante el proceso de codificación correspondiente dentro del pipeline de preparación de datos.

4.6.1. Construcción de nuevas variables (créate feature)

Como parte de la ingeniería de características (feature engineering), se generaron nuevas variables derivadas de la base de datos. El objetivo fue enriquecer el conjunto de variables utilizadas por el modelo, incorporando relaciones entre el metrado, el rendimiento, el tipo de trabajo y la frecuencia de aparición de las partidas. Asimismo, se aplicaron transformaciones logarítmicas y términos cuadráticos para representar posibles relaciones no lineales entre las características y la duración de las actividades.

Código para generar nuevas variables.

```
def create_features(df):
    """
    Crea features derivadas para el modelo.
    Retorna un nuevo DataFrame con las features originales más las nuevas.
    """
    df = df.copy()

    df['TIPO_TRABAJO'] = df['CODIGO_PARTIDA'].apply(extract_code_prefix)

    df['RATIO_METRADO_REND'] = np.where(
        df['RENDIMIENTO'] > 0,
        df['METRADO_TOTAL'] / df['RENDIMIENTO'],
        0
    )

    df['LOG_METRADO'] = np.log1p(df['METRADO_TOTAL'].clip(lower=0))
    df['LOG_RENDIMIENTO'] = np.log1p(df['RENDIMIENTO'].clip(lower=0))

    desc_freq = df['DESCRIPCION_PARTIDA'].value_counts()
    df['DESC_FREQ'] = df['DESCRIPCION_PARTIDA'].map(desc_freq)

    code_freq = df['CODIGO_PARTIDA'].value_counts()
    df['CODE_FREQ'] = df['CODIGO_PARTIDA'].map(code_freq)

    tipo_freq = df['TIPO_TRABAJO'].value_counts()
    df['TIPO_FREQ'] = df['TIPO_TRABAJO'].map(tipo_freq)
```

```
    df['METRADO_X_REND'] = df['METRADO_TOTAL'] * df['RENDIMIENTO']
    df['METRADO_SQ'] = df['METRADO_TOTAL'] ** 2
    df['REND_SQ'] = df['RENDIMIENTO'] ** 2

    print(f"Features creadas. Nuevo shape: {df.shape}")
    print(f"  - TIPO_TRABAJO: {df['TIPO_TRABAJO'].nunique()} tipos únicos")
    print(f"  - RATIO_METRADO_REND: rango
[{df['RATIO_METRADO_REND'].min():.2f},
{df['RATIO_METRADO_REND'].max():.2f}]")
    print(f"  - DESC_FREQ: rango [{df['DESC_FREQ'].min()},
{df['DESC_FREQ'].max()}]")

    return df
```

Nota: La función create_features() realiza un proceso de ingeniería de características mediante la creación de variables categóricas, relaciones entre metrado y rendimiento, transformaciones logarítmicas, frecuencias de aparición, interacciones y términos cuadráticos.

Fuente: Elaboración propia

Explicación del código:

Mediante la función create_features() se generaron diez variables derivadas a partir de las características originales del dataset.

Mediante la función auxiliar extract_code_prefix(), se extrajo el prefijo alfabético de la variable CODIGO_PARTIDA; por ejemplo, el código *CR-001* fue transformado en *CR*. A partir de esta transformación se generó la variable categórica TIPO_TRABAJO, que permitió agrupar las partidas según el tipo de actividad constructiva identificado, registrándose 50 categorías únicas.

Posteriormente, se generó la variable RATIO_METRADO_REND, calculada a partir de la relación entre METRADO_TOTAL y RENDIMIENTO, con el propósito de representar una relación de eficiencia entre la magnitud de trabajo prevista y el rendimiento asociado a su ejecución. Asimismo, se incorporaron las transformaciones logarítmicas LOG_METRADO y LOG_RENDIMIENTO, mediante la función log1p, con la finalidad de reducir el efecto de las distribuciones altamente asimétricas y mejorar la representación de variables con valores elevados.

Adicionalmente, se generaron las variables DESC_FREQ, CODE_FREQ y TIPO_FREQ, correspondientes a codificaciones por frecuencia de variables categóricas con elevada cardinalidad. Estas transformaciones permitieron representar la frecuencia de aparición de determinadas categorías mediante valores numéricos.

Finalmente, se incorporaron términos derivados de segundo orden, específicamente METRADO_X_REND, METRADO_SQ y REND_SQ, con el objetivo de representar posibles interacciones y relaciones no lineales entre el metrado y el rendimiento. En conjunto, la ingeniería de características permitió ampliar la información disponible para los algoritmos de Machine Learning y proporcionar representaciones más adecuadas de las relaciones potencialmente existentes entre las características de las partidas y su duración de ejecución.

Tabla 19: Variables derivadas creadas en la ingeniería de características.

Variable derivada	Tipo	Definición
TIPO_TRABAJO	Categórica	Prefijo alfabético extraído de CODIGO_PARTIDA (50 categorías)
RATIO_METRADO_REND	Numérica	METRADO_TOTAL / RENDIMIENTO (0 si el rendimiento es nulo)
LOG_METRADO	Numérica	log(1 + METRADO_TOTAL), transformación logarítmica
LOG_RENDIMIENTO	Numérica	log(1 + RENDIMIENTO), transformación logarítmica
DESC_FREQ	Numérica	Frecuencia absoluta de la descripción de partida
CODE_FREQ	Numérica	Frecuencia absoluta del código de partida
TIPO_FREQ	Numérica	Frecuencia absoluta del tipo de trabajo
METRADO_X_REND	Numérica	Interacción METRADO_TOTAL × RENDIMIENTO
METRADO_SQ	Numérica	METRADO_TOTAL al cuadrado (término polinómico)
REND_SQ	Numérica	RENDIMIENTO al cuadrado (término polinómico)

Fuente: elaboración propia a partir de la función create_features().

Tras la creación de estas variables, el conjunto de datos aumentó de 16 a 26 columnas (8539 registros), reportándose 50 categorías únicas para TIPO_TRABAJO y un rango de [0; 655.90] para RATIO_METRADO_REND.

4.6.2. Selección del conjunto final de variables predictoras

Selección y organización de las variables que serían utilizadas como características de entrada del modelo predictivo.

Código para establecer las variables de entrada.

```
def get_feature_columns():
    """Define las columnas de features numéricas y categóricas para el
modelo."""
    numeric_features = [
        'METRADO_TOTAL', 'RENDIMIENTO', 'PREDECESORAS',
        'RATIO_METRADO_REND', 'LOG_METRADO', 'LOG_RENDIMIENTO',
        'DESC_FREQ', 'CODE_FREQ', 'TIPO_FREQ',
        'METRADO_X_REND', 'METRADO_SQ', 'REND_SQ',
        'NUMERO_DE_PARTIDA_(MS_PROJECT)'
    ]
    categorical_features = ['OBRA_ID', 'TIPO_TRABAJO']
    return numeric_features, categorical_features
```

Nota: La función get_feature_columns() organiza las variables predictoras en dos grupos: numéricas y categóricas.

Fuente: Elaboración propia.

Mediante la función get_feature_columns() se definió el conjunto final de 15 variables predictoras (features) que fueron incorporadas al pipeline de modelamiento. Este conjunto estuvo conformado por 13 variables numéricas: METRADO_TOTAL, RENDIMIENTO, PREDECESORAS, RATIO_METRADO_REND, LOG_METRADO, LOG_RENDIMIENTO, DESC_FREQ, CODE_FREQ, TIPO_FREQ, METRADO_X_REND, METRADO_SQ, REND_SQ y NUMERO_DE_PARTIDA_(MS_PROJECT); y 2 variables categóricas: OBRA_ID y TIPO_TRABAJO.

La selección de estas características se realizó considerando su disponibilidad como información previa al desarrollo de la actividad y su potencial capacidad para contribuir a la estimación de la duración de las partidas. En contraste, se excluyeron deliberadamente las variables DIA_TRABAJADO, METRADO_DIARIO, METRADO_ACUMULADO, ES_PRIMER_DIA, ES_ULTIMO_DIA, PORCENTAJE_COMPLETADO y DURACION_ACUMULADA_DEL_TOTAL_DE_OBRA, debido a que contienen información generada durante el proceso de ejecución o posterior al inicio de la partida.

La exclusión de estas variables permitió evitar un posible problema de fuga de información (data leakage), que se produciría si el modelo utilizara información relacionada con el avance real de la actividad para predecir una duración que en condiciones reales de planificación, aún no se conoce. Por tanto, la selección final de características buscó garantizar que las variables utilizadas por el modelo representaran información disponible en la etapa de planificación, manteniendo la validez del proceso predictivo y su aplicabilidad al contexto de programación de obras.

Tabla 20: Predictores utilizados en el entrenamiento (15 variables)

Variable	Definición	Fuente	Disponible en	Uso en el entrenamiento	Riesgo de fuga y observación
METRADO_TOTAL	Cantidad total de trabajo prevista para la actividad.	Planificación	Planificación (antes de iniciar la partida)	Sí (numérica)	**Bajo.** Verificar que corresponda al metrado contractual y no al ejecutado final.
RENDIMIENTO	Cantidad de trabajo que puede ejecutarse por unidad de tiempo, según la información disponible.	Planificación	Planificación	Sí (numérica)	**Bajo.**
PREDECESORAS	Actividades que deben ejecutarse previamente, según la lógica del cronograma.	Planificación y ejecución	Planificación, si proviene del cronograma contractual	Sí (numérica)	**Medio.** La fuente declarada es mixta; precisar que se tomó del cronograma contractual. Además, es un código identificador tratado como número.
NUMERO_DE_PARTIDA_(MS_PROJECT)	Posición o número asignado a la actividad dentro del cronograma de Microsoft Project.	Planificación y ejecución	Planificación	Sí (numérica)	**Alto (identidad).** Junto con OBRA_ID identifica de forma única cada partida y no tiene significado fuera de su obra. Declarar como limitación.
OBRA_ID	Identificación de la obra cuyos datos se utilizan.	Planificación y ejecución	Planificación (es un identificador)	Sí (categórica)	**Alto (identidad).** No describe características de la obra, solo la nombra. Una obra nueva sería una categoría desconocida. Explica por qué el conjunto de prueba, con partición aleatoria, contiene obras ya vistas en el entrenamiento.

TIPO_TRABAJO	Prefijo alfabético extraído de CODIGO_PARTIDA (50 categorías).	Homologación propia por equivalencia técnica y proceso constructivo	Planificación (deriva de la descripción de la partida)	Sí (categórica)	**Bajo.** No usa la variable objetivo. Requiere que las partidas de una obra nueva puedan asignarse al catálogo de códigos.
RATIO_METRADO_REND	METRADO_TOTAL / RENDIMIENTO; 0 si el rendimiento es nulo.	Derivada de planificación	Planificación	Sí (numérica)	**Bajo.** Aproxima la duración planificada por rendimiento; conviene mencionarlo al comparar con el método tradicional.
LOG_METRADO, LOG_RENDIMIENTO, METRADO_X_REND, METRADO_SQ, REND_SQ	Transformaciones logarítmicas, interacción y términos polinómicos de METRADO_TOTAL y RENDIMIENTO.	Derivadas de planificación	Planificación	Sí (numéricas)	**Bajo.** No agregan información nueva; generan colinealidad, no fuga.
DESC_FREQ, CODE_FREQ, TIPO_FREQ	Frecuencia absoluta de la descripción, del código y del tipo de partida.	Derivadas del dataset (create_features)	No disponible como tal para una obra nueva: depende de la composición del dataset	Sí (numéricas)	**Alto. Verificar.** Se calculan sobre las 8 539 filas antes de la partición. Si cuentan filas actividad-día, una actividad de D días suma al menos D filas y la frecuencia refleja su duración. DESC_FREQ figura como la variable más importante de AdaBoost.

Fuente: Elaboración propia (data leakage)

Tabla 21: Variables excluidas y variable objetivo

Variable	Definición	Fuente	Disponible en	Uso en el entrenamiento	Riesgo de fuga y observación
DIA_TRABAJADO	Día específico de ejecución de la actividad dentro de su periodo total.	Ejecución (seguimiento diario)	Ejecución (durante y después del inicio)	No (excluida)	Alto si se usara: su valor máximo por partida coincide con la duración objetivo.
METRADO_DIARIO	Cantidad de trabajo ejecutada durante cada día de trabajo.	Ejecución	Ejecución	No (excluida)	Alto si se usara: el avance diario permite reconstruir la duración.
METRADO_ACUMULADO	Acumulación progresiva del metrado ejecutado hasta cada día.	Ejecución	Ejecución	No (excluida)	Alto si se usara.
ES_PRIMER_DIA, ES_ULTIMO_DIA	Indicadoras de que el registro corresponde al primer o al último día de ejecución.	Ejecución	Ejecución	No (excluidas)	Alto si se usaran: ES_ULTIMO_DIA señala el cierre de la actividad.
PORCENTAJE_COMPLETADO	Avance acumulado de la actividad respecto al metrado total.	Ejecución	Ejecución	No (excluida)	Alto si se usara: indica cuánto falta para terminar.
DURACION_ACUMULADA_DEL TOTAL_DE_OBRA	Días acumulados de la obra hasta el registro.	Ejecución (no figura en la Tabla 7; precisar su definición)	Ejecución	No (excluida)	Alto si se usara.
DURACION_TOTAL_DIAS	Número total de días considerados para la ejecución de la actividad.	Ejecución	Ejecución (se conoce al terminar)	Variable objetivo	No aplica. El recorte al percentil 99 se aplicó sobre esta variable.
ID_PARTIDA, DESCRIPCION_PARTIDA, CODIGO_PARTIDA	Agrupación de partidas, denominación de la actividad y código estandarizado.	Planificación	Planificación	No directamente	Bajo. Solo sirven para derivar TIPO_TRABAJO y las frecuencias.

Fuente: Elaboración propia (data leakage)

4.6.3. Pipeline de preprocesamiento (ColumnTransformer)

Una vez definidas las variables predictoras, se construyó el pipeline de preprocesamiento de los datos, con el propósito de preparar de manera uniforme las variables antes de incorporarlas a los modelos de Machine Learning. Para las variables numéricas se estableció un proceso de imputación de valores faltantes mediante la mediana y posteriormente un escalamiento robusto.

Para las variables categóricas se implementó la imputación de valores faltantes y su transformación a valores numéricos mediante codificación ordinal. Finalmente, ambos procesos fueron integrados mediante un ColumnTransformer, permitiendo aplicar automáticamente el tratamiento correspondiente a cada tipo de variable.

Código para la construcción de la estructura de procesamiento.

```
def get_feature_columns():
    """Define las columnas de features numéricas y categóricas para el
modelo."""
    numeric_features = [
        'METRADO_TOTAL', 'RENDIMIENTO', 'PREDECESORAS',
        'RATIO_METRADO_REND', 'LOG_METRADO', 'LOG_RENDIMIENTO',
        'DESC_FREQ', 'CODE_FREQ', 'TIPO_FREQ',
        'METRADO_X_REND', 'METRADO_SQ', 'REND_SQ',
        'NUMERO_DE_PARTIDA_(MS_PROJECT)'
    ]
    categorical_features = ['OBRA_ID', 'TIPO_TRABAJO']
    return numeric_features, categorical_features

def build_preprocessing_pipeline(numeric_features, categorical_features):
    """
    Construye el ColumnTransformer con pipelines de preprocesamiento.
    - Numérico: imputar mediana + RobustScaler
    - Categórico: imputar constante + OrdinalEncoder
    """
    numeric_pipeline = Pipeline([
        ('imputer', SimpleImputer(strategy='median')),
        ('scaler', RobustScaler())
    ])

    categorical_pipeline = Pipeline([
        ('imputer', SimpleImputer(strategy='constant',
fill_value='UNKNOWN')),
        ('encoder', OrdinalEncoder(handle_unknown='use_encoded_value',
unknown_value=-1))
    ])
    preprocessor = ColumnTransformer(
        transformers=[
            ('num', numeric_pipeline, numeric_features),
            ('cat', categorical_pipeline, categorical_features)
        ],
        remainder='drop'
    )
```

```
    print("Pipeline de preprocesamiento construido:")
    print(f"  - {len(numeric_features)} features numéricas:
{numeric_features}")
    print(f"  - {len(categorical_features)} features categóricas:
{categorical_features}")

    return preprocessor
```

Nota: La función build_preprocessing_pipeline() construye un proceso automatizado de preparación de datos mediante imputación y escalamiento de las variables numéricas, e imputación y codificación de las variables categóricas. El ColumnTransformer integra ambos procedimientos para generar un conjunto de características compatible y consistente con los modelos de Machine Learning.

Fuente: Elaboración propia.

Explicación del código:

La función build_preprocessing_pipeline() construyó un ColumnTransformer de scikit-learn compuesto por dos ramas paralelas. La rama numérica aplicó, en secuencia, una imputación de valores faltantes mediante la mediana (SimpleImputer(strategy='median')) y un escalado robusto (RobustScaler), seleccionado explícitamente frente al escalado estándar debido a la elevada proporción de valores atípicos detectada en la etapa de EDA, dado que el RobustScaler basa su escalado en la mediana y el rango intercuartílico, resultando menos sensible a valores extremos. La rama categórica aplicó una imputación por constante (valor 'UNKNOWN') seguida de una codificación ordinal (OrdinalEncoder) con manejo explícito de categorías no vistas (unknown_value = -1), estrategia adecuada dado el uso posterior de modelos basados en árboles y de boosting, para los cuales la codificación ordinal resulta computacionalmente más eficiente que la codificación one-hot sin penalizar el desempeño.

4.6.4. División de los datos en entrenamiento y prueba

Esta etapa permitió establecer conjunto de datos necesarios para el entrenamiento y la evaluación independiente del modelo predictivo. El filtrado de la variable objetivo permitió trabajar con duraciones válidas y limitar la influencia de las observaciones situadas por encima del percentil 99.

La división 80% entrenamiento y 20% evaluación permitió reservar una parte de los registros para evaluar el comportamiento del modelo sobre datos que no fueron utilizados directamente durante su entrenamiento. Asimismo, la estratificación por OBRA_ID buscó mantener la representación de las diferentes obras en ambos conjuntos.

Finalmente, la comparación de la media y mediana de DURACION_TOTAL_DIAS entre entrenamiento y prueba permite verificar que ambos subconjuntos mantengan características similares respecto a la variable objetivo.

Código para dividir los datos en conjuntos de entrenamiento.

```
def split_data(df, target_col, test_size=0.2):
    """
    Divide en train/test con estratificación por OBRA_ID.
    Retorna X_train, X_test, y_train, y_test, groups_train.
    """
    df_clean = df[df[target_col] > 0].copy()
    df_clean = df_clean[df_clean[target_col] <=
df_clean[target_col].quantile(0.99)]

    print(f"Registros después de filtrar target > 0 y < p99:
{len(df_clean):,}")

    X = df_clean.drop(columns=[target_col])
    y = df_clean[target_col].values

    X_train, X_test, y_train, y_test = train_test_split(
        X, y, test_size=test_size, random_state=RANDOM_STATE,
        stratify=df_clean['OBRA_ID']
    )
    groups_train = X_train['OBRA_ID'].values
```

```
    print(f"\nDivisión train/test:")
    print(f"  Train: {X_train.shape[0]:,} registros ({100*(1-
test_size):.0f}%)")
    print(f"  Test:  {X_test.shape[0]:,} registros ({100*test_size:.0f}%)")
    print(f"  Target (train) — Media: {y_train.mean():.2f}, Mediana:
{np.median(y_train):.2f}")
    print(f"  Target (test)  — Media: {y_test.mean():.2f}, Mediana:
{np.median(y_test):.2f}")

    return X_train, X_test, y_train, y_test, groups_train
```

Nota: La función split_data() filtra los registros de la variable objetivo, excluye valores superiores al percentil 99 y divide los datos en agrupacion de entrenamiento y prueba en una proporción de 80 % y 20 %, respectivamente. La estratificación por OBRA_ID permite conservar la representación de las obras en ambos conjuntos, mientras que la identificación de grupos prepara los datos para posteriores procesos de validación cruzada agrupada.

Fuente: Elaboración propia.

Explicación del código:

La función split_data() aplicó dos filtros previos a la partición: se conservaron únicamente los registros con DURACION_TOTAL_DIAS > 0 y se recortó la cola superior de la distribución del target al percentil 99, reduciendo el conjunto de 8539 a 8448 registros. Posteriormente, se ejecutó una partición train_test_split() con test_size = 0.2, semilla fija (random_state = 42) y estratificación por la variable OBRA_ID, a fin de preservar en ambos subconjuntos la proporción relativa de registros de cada obra.

Tabla 22: Resultado de la partición de datos.

Conjunto	N.º de registros	% del total	Media del target (días)	Mediana del target (días)
Entrenamiento (train)	6758	80%	20.69	15.00
Prueba (test)	1690	20%	20.85	16.00
Total (tras filtrado)	8448	100%	---	---

Nota: La similitud entre las medias y medianas del target en ambos subconjuntos (20.69 frente a 20.85 días; 15.00 frente a 16.00 días) confirma que la estratificación por obra logró preservar una distribución comparable de la variable objetivo entre el conjunto de entrenamiento y el de prueba, condición necesaria para una evaluación no sesgada del modelo final.

Fuente: Elaboración propia a partir de la salida de split_data().

4.7. Exploración y Preselección de Modelos Candidatos

Una vez definido el conjunto de variables predictoras y construido el pipeline de preprocesamiento, se procedió a establecer la estructura para la exploración y comparación de diferentes algoritmos de regresión. Para ello, se creó un pipeline general que integra el preprocesamiento con cada modelo y, posteriormente, se construyó un catálogo amplio de algoritmos de Machine Learning organizados según su naturaleza.

Código para integración del modelo.

```
def create_model_pipeline(preprocessor, model):
    """Crea un Pipeline completo: preprocesamiento + modelo."""
    return Pipeline([
        ('preprocessor', preprocessor),
        ('model', model)
    ])
```

Nota: La primera etapa corresponde al preprocesamiento de los datos, mientras que la segunda corresponde al algoritmo de Machine Learning, cada modelo recibe automáticamente los datos después de aplicar las transformaciones definidas anteriormente.

Fuente: Elaboración propia.

Código para registrar los modelos.

```
def get_all_models():
    """
    Retorna un diccionario con TODOS los modelos de regresión organizados
por grupo.
    Cada entrada: nombre -> (estimator, grupo)
    """
    from sklearn.linear_model import (
        LinearRegression, Ridge, Lasso, ElasticNet,
        Lars, LassoLars, BayesianRidge, ARDRegression,
        OrthogonalMatchingPursuit, PassiveAggressiveRegressor,
        HuberRegressor, RANSACRegressor, TheilSenRegressor,
        QuantileRegressor, SGDRegressor
    )
    from sklearn.neighbors import KNeighborsRegressor,
RadiusNeighborsRegressor
    from sklearn.svm import SVR, NuSVR, LinearSVR
    from sklearn.tree import DecisionTreeRegressor, ExtraTreeRegressor
    from sklearn.ensemble import (
        RandomForestRegressor, ExtraTreesRegressor,
        BaggingRegressor, AdaBoostRegressor,
        GradientBoostingRegressor, HistGradientBoostingRegressor,
        VotingRegressor, StackingRegressor
    )
    from sklearn.neural_network import MLPRegressor
    from sklearn.gaussian_process import GaussianProcessRegressor
    from sklearn.gaussian_process.kernels import RBF, Matern
    from sklearn.kernel_ridge import KernelRidge
```

Nota: El codigo tiene como objetivo crear un diccionario que contiene los diferentes modelos de regresión que serán evaluados. Los modelos se organizan en grupos según su naturaleza.

Fuente: Fuente: Elaboración propia.

Tabla 23: Catálogo de modelos de regresión evaluados, por grupo.

Grupo	Familia de modelos	N.º de modelos entrenados
A	Modelos Lineales Clásicos	16
B	Basados en Vecinos (KNN, Radius Neighbors)	2
C	Support Vector Machines	5
D	Árboles de Decisión	2
E	Ensemble Bagging	4
F	Ensemble Boosting	5
G	Redes Neuronales (MLP)	2
H	Procesos Gaussianos	2
I	GLM y Otros Modelos Lineales Generalizados	4
	Total, efectivamente entrenado	42

Fuente: Elaboración propia.

Con la finalidad de verificar la disponibilidad de las bibliotecas requeridas para los diferentes algoritmos de Machine Learning, se implementó un mecanismo de comprobación de dependencias.

Cuando una biblioteca se encontraba disponible, el modelo correspondiente era incorporado automáticamente al catálogo de algoritmos considerado para la evaluación. En caso contrario, el código omitía dicho modelo y continuaba su ejecución sin generar interrupciones ni errores.

Esta estrategia permitió mantener un proceso de evaluación flexible y adaptable a las características del entorno computacional, posibilitando comparar la mayor cantidad de algoritmos disponibles sin comprometer la ejecución general del cuaderno de Machine Learning.

Código para el control y disponibilidad de modelos.

```
    try:
        from xgboost import XGBRegressor
        has_xgb = True
    except Exception:
        has_xgb = False
```

```
try:
    from lightgbm import LGBMRegressor
    has_lgbm = True
except Exception:
    has_lgbm = False

try:
    from catboost import CatBoostRegressor
    has_catboost = True
except Exception:
    has_catboost = False

try:
    from ngboost import NGBRegressor
    has_ngboost = True
except Exception:
    has_ngboost = False

try:
    from pytorch_tabnet.tab_model import TabNetRegressor as _TabNet
    has_tabnet = True
except Exception:
    has_tabnet = False
```

Fuente: Elaboración propia.

Se utiliza una semilla aleatoria común para los modelos que poseen componentes aleatorios. Esto favorece la reproducibilidad de los resultados, ya que permite repetir los experimentos bajo condiciones equivalentes.

Esta etapa constituye la fase de exploración y comparación de algoritmos de Machine Learning. En lugar de seleccionar inicialmente un único algoritmo, se estableció un conjunto amplio de modelos pertenecientes a diferentes familias, permitiendo determinar empíricamente cuáles presentan mejor capacidad para predecir DURACION_TOTAL_DIAS.

La utilización de un pipeline común garantiza que los diferentes algoritmos sean evaluados bajo un mismo esquema de preparación de datos. La diversidad de modelos también permite comprobar diferentes hipótesis sobre la estructura de los datos. Los modelos lineales permiten

establecer una referencia inicial; los árboles y métodos de ensamble permiten capturar relaciones no lineales; los métodos SVM exploran relaciones mediante kernels; y las redes neuronales permiten evaluar estructuras de mayor complejidad. En particular, los modelos de Bagging y Boosting adquieren importancia debido a que las relaciones entre variables como metrado, rendimiento, tipo de trabajo y duración pueden no ser estrictamente lineales.

4.7.1. Estrategia de validación cruzada.

Debido a que los registros pertenecientes a una misma obra pueden compartir características asociadas a la gestión, organización de las cuadrillas, condiciones de campo y procedimientos constructivos, se consideró necesario controlar la dependencia existente entre las observaciones durante la evaluación de los modelos. Para ello, la función evaluate_model_cv() implementó un esquema de validación cruzada agrupada mediante GroupKFold, utilizando 3 particiones (n_splits = 3) y OBRA_ID como variable de agrupación.

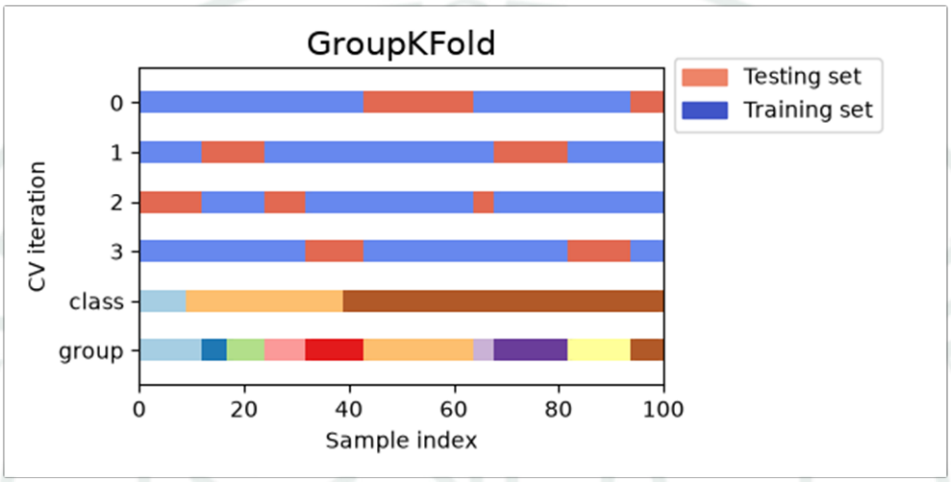
Este procedimiento permitió que, en cada iteración de la validación, los registros correspondientes a determinadas obras fueran destinados exclusivamente al conjunto de validación, mientras que las obras restantes fueran utilizadas para el entrenamiento. De esta manera, se evitó que partidas pertenecientes a una misma obra estuvieran simultáneamente en los conjuntos de entrenamiento y validación, reduciendo el riesgo de sobreestimar el desempeño del modelo.

La estrategia adoptada permitió aproximar de manera más realista la capacidad de generalización del modelo frente a obras no utilizadas durante el entrenamiento, aspecto particularmente relevante para una aplicación orientada a la predicción de duraciones en nuevos proyectos de infraestructura vial.

Para cada partición se calcularon las métricas RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), R^2 (coeficiente de determinación) y MAPE (Mean Absolute Percentage

Error). Finalmente, se obtuvo el promedio y la desviación estándar de cada métrica a través de las tres particiones, permitiendo evaluar tanto el desempeño promedio como la estabilidad de cada algoritmo frente a diferentes conjuntos de obras.

Figura 34: Diagrama de comportamiento de validación cruzada.



Nota: (n_splits=3) En este caso las filas del 0 al 3 representan la muestra (6758 registros de entrenamiento), Training set es las muestras utilizadas para entrenar el modelo en esa iteración y Testing set es las muestras reservadas exclusivamente para evaluar o probar el modelo, class representa los códigos para agrupar las partidas o actividades y group representan las OBRA_ID.

Fuente: scikit learn - Guía del usuario - (3.1.2.4.1. Grupo K-fold)

GroupKFold Es una variante de la validación cruzada K-fold que garantiza que el mismo grupo no esté representado tanto en el conjunto de prueba como en el de entrenamiento. Por ejemplo, si los datos se obtienen de diferentes sujetos con varias muestras por sujeto y si el modelo es lo suficientemente flexible como para aprender de características muy específicas de cada persona, podría fallar al generalizar a nuevos sujetos. GroupKFoldEsto permite detectar este tipo de situaciones de sobreajuste(scikit learn, 2026) .

Se seleccionaron tres particiones debido a que la unidad independiente de análisis corresponde a la obra y no al registro individual. Al disponer de un número limitado de obras, utilizar un número elevado de particiones reduciría considerablemente la cantidad de obras disponibles en cada conjunto de validación y podría generar estimaciones inestables. Con tres particiones se mantiene un equilibrio entre disponer de suficientes obras para entrenar el modelo y evaluar su comportamiento sobre obras completamente excluidas del entrenamiento.

Código de técnicas de regularización de modelos.

```
def evaluate_model_cv(pipeline, X, y, groups, n_splits=3,
timeout_per_model=120):
    """
    Evalúa un pipeline con cross-validation (GroupKFold por OBRA_ID).
    Retorna dict con métricas promedio y desviación estándar.
    """
    gkf = GroupKFold(n_splits=min(n_splits, len(np.unique(groups))))

    rmse_scores = []
    mae_scores = []
    r2_scores = []
    mape_scores = []

    for train_idx, val_idx in gkf.split(X, y, groups):
        X_tr, X_val = X.iloc[train_idx], X.iloc[val_idx]
        y_tr, y_val = y[train_idx], y[val_idx]

        pipeline.fit(X_tr, y_tr)
        y_pred = pipeline.predict(X_val)
        y_pred = np.maximum(y_pred, 0)

        rmse_scores.append(np.sqrt(mean_squared_error(y_val, y_pred)))
        mae_scores.append(mean_absolute_error(y_val, y_pred))
        r2_scores.append(r2_score(y_val, y_pred))

        mask = y_val > 0
        if mask.sum() > 0:
            mape_scores.append(mean_absolute_percentage_error(y_val[mask],
y_pred[mask]))

    return {
        'RMSE_mean': np.mean(rmse_scores),
        'RMSE_std': np.std(rmse_scores),
        'MAE_mean': np.mean(mae_scores),
```

```
        'MAE_std': np.std(mae_scores),
        'R2_mean': np.mean(r2_scores),
        'R2_std': np.std(r2_scores),
        'MAPE_mean': np.mean(mape_scores) if mape_scores else np.nan,
        'MAPE_std': np.std(mape_scores) if mape_scores else np.nan,
    }
```

Nota: La función evaluate_model_cv() evalúa los modelos mediante validación cruzada agrupada por OBRA_ID, utilizando tres particiones por defecto. En cada iteración, el modelo es entrenado y validado con grupos de obras diferenciados, y su desempeño se cuantifica mediante RMSE, MAE, R^2 y MAPE. Los resultados se resumen mediante la media y desviación estándar de cada métrica, permitiendo comparar tanto la precisión como la estabilidad de los modelos evaluados.

Fuente: Elaboración propia

4.7.2. Ejecución del entrenamiento comparativo.

La función train_and_evaluate_all() orquestó el entrenamiento secuencial de los 42 modelos, encapsulando cada ejecución dentro de un ThreadPoolExecutor con un límite de tiempo de 120 segundos por modelo, a fin de evitar que algoritmos computacionalmente costosos (por ejemplo, Support Vector Regression con kernel no lineal o Gaussian Process Regression) bloquearan la ejecución completa del experimento. El proceso completo finalizó sin incidencias: los 42 modelos registrados fueron entrenados y evaluados exitosamente (0 fallos, 0 timeouts), consolidándose los resultados en un DataFrame ordenado de forma descendente según el coeficiente de determinación R^2 promedio.

Código de entrenamiento secuencial.

```
def train_and_evaluate_all(models_dict, preprocessor, X_train, y_train,
groups, max_time_per_model=120):
    """
    Entrena y evalúa TODOS los modelos con cross-validation.
    Maneja errores individualmente. Timeout multiplataforma (Windows/Linux).
    Retorna DataFrame con resultados.
    """
```

```
    import time
    from concurrent.futures import ThreadPoolExecutor, TimeoutError as
FuturesTimeout
```

Nota: Models_dict: catálogo de modelos previamente definido; preprocessor: pipeline de preprocesamiento; X_train: variables predictoras de entrenamiento; y_train: variable objetivo; groups: identificador de las obras; max_time_per_model: tiempo máximo permitido para evaluar cada modelo, establecido en 120 segundos.

from concurrent.futures import ThreadPoolExecutor, TimeoutError as FuturesTimeout

Se utiliza ThreadPoolExecutor para ejecutar la evaluación de cada modelo en un proceso independiente dentro de un hilo y establecer un límite de tiempo. Esto es importante porque algunos algoritmos, especialmente los de mayor complejidad computacional, pueden requerir un tiempo considerable para completar la validación cruzada.

Fuente: Elaboración propia

Dentro del proceso de entrenamiento automático de los modelos, se definió la función interna run_model(), cuya finalidad es preparar correctamente el pipeline de procesamiento para cada algoritmo antes de ejecutar su evaluación mediante validación cruzada. Esta función permite diferenciar entre modelos simples y aquellos que ya contienen una estructura interna de procesamiento, como el modelo de regresión polinómica, asegurando que todos reciban previamente el mismo preprocesamiento de las variables.

Código para preparar correctamente el pipeline.

```
    def _run_model(model, preprocessor, X_train, y_train, groups):
        if isinstance(model, Pipeline):
            pipeline = Pipeline([
                ('preprocessor', preprocessor),
                ('poly_and_model', model)
            ])
        else:
            pipeline = create_model_pipeline(preprocessor, model)
        return evaluate_model_cv(pipeline, X_train, y_train, groups)
```

Nota: La función _run_model() integra el preprocesamiento general con cada modelo candidato, considerando de manera particular aquellos algoritmos que poseen un Pipeline interno. Esta estructura garantiza que las transformaciones de los datos se ejecuten antes del modelamiento y permite evaluar de forma uniforme tanto los modelos individuales como los modelos compuestos, como la regresión polinómica con Ridge.

Fuente: Elaboración propia.

Código para inicio evaluación y medición.

```
    results = []

    total = len(models_dict)
    for i, (name, (model, group)) in enumerate(models_dict.items(), 1):
        print(f"[{i:2d}/{total}] Entrenando {name}...", end=' ', flush=True)
        start = time.time()

        try:
            with ThreadPoolExecutor(max_workers=1) as executor:
                future = executor.submit(_run_model, model, preprocessor,
X_train, y_train, groups)
                metrics = future.result(timeout=max_time_per_model)

            elapsed = time.time() - start

            results.append({
                'Model': name,
                'Group': group,
                'RMSE': metrics['RMSE_mean'],
                'RMSE_std': metrics['RMSE_std'],
                'MAE': metrics['MAE_mean'],
                'MAE_std': metrics['MAE_std'],
                'R2': metrics['R2_mean'],
                'R2_std': metrics['R2_std'],
                'MAPE': metrics['MAPE_mean'],
                'Time_s': elapsed,
                'Status': 'OK'
            })
            print(f"R²={metrics['R2_mean']:.4f} |
RMSE={metrics['RMSE_mean']:.4f} | {elapsed:.1f}s")
```

Nota: Se crea una lista vacía donde se almacenarán los resultados obtenidos para cada modelo. se determina el número total de algoritmos que serán evaluados. El código recorre todos los

modelos almacenados en el diccionario. Esto permite conocer qué modelo se está procesando y cuánto falta para completar la evaluación.

Fuente: Elaboración propia

Código para capturar errores específicos.

```
        except Exception as e:
            elapsed = time.time() - start
            results.append({
                'Model': name,
                'Group': group,
                'RMSE': np.nan, 'RMSE_std': np.nan,
                'MAE': np.nan, 'MAE_std': np.nan,
                'R2': np.nan, 'R2_std': np.nan,
                'MAPE': np.nan,
                'Time_s': elapsed,
                'Status': f'ERROR: {str(e)[:60]}'
            })
            print(f"ERROR: {str(e)[:80]} | {elapsed:.1f}s")
```

Fuente: Elaboración propia

Código para modelos que exceden más de 120 segundos.

```
        except FuturesTimeout:
            elapsed = time.time() - start
            results.append({
                'Model': name,
                'Group': group,
                'RMSE': np.nan, 'RMSE_std': np.nan,
                'MAE': np.nan, 'MAE_std': np.nan,
                'R2': np.nan, 'R2_std': np.nan,
                'MAPE': np.nan,
                'Time_s': elapsed,
                'Status': f'TIMEOUT ({max_time_per_model}s)'
            })
            print(f"TIMEOUT ({max_time_per_model}s) | {elapsed:.1f}s")
```

Fuente: Elaboración propia

Tabla 24: Resultados comparativos de validación cruzada GroupKFold 42 modelos.

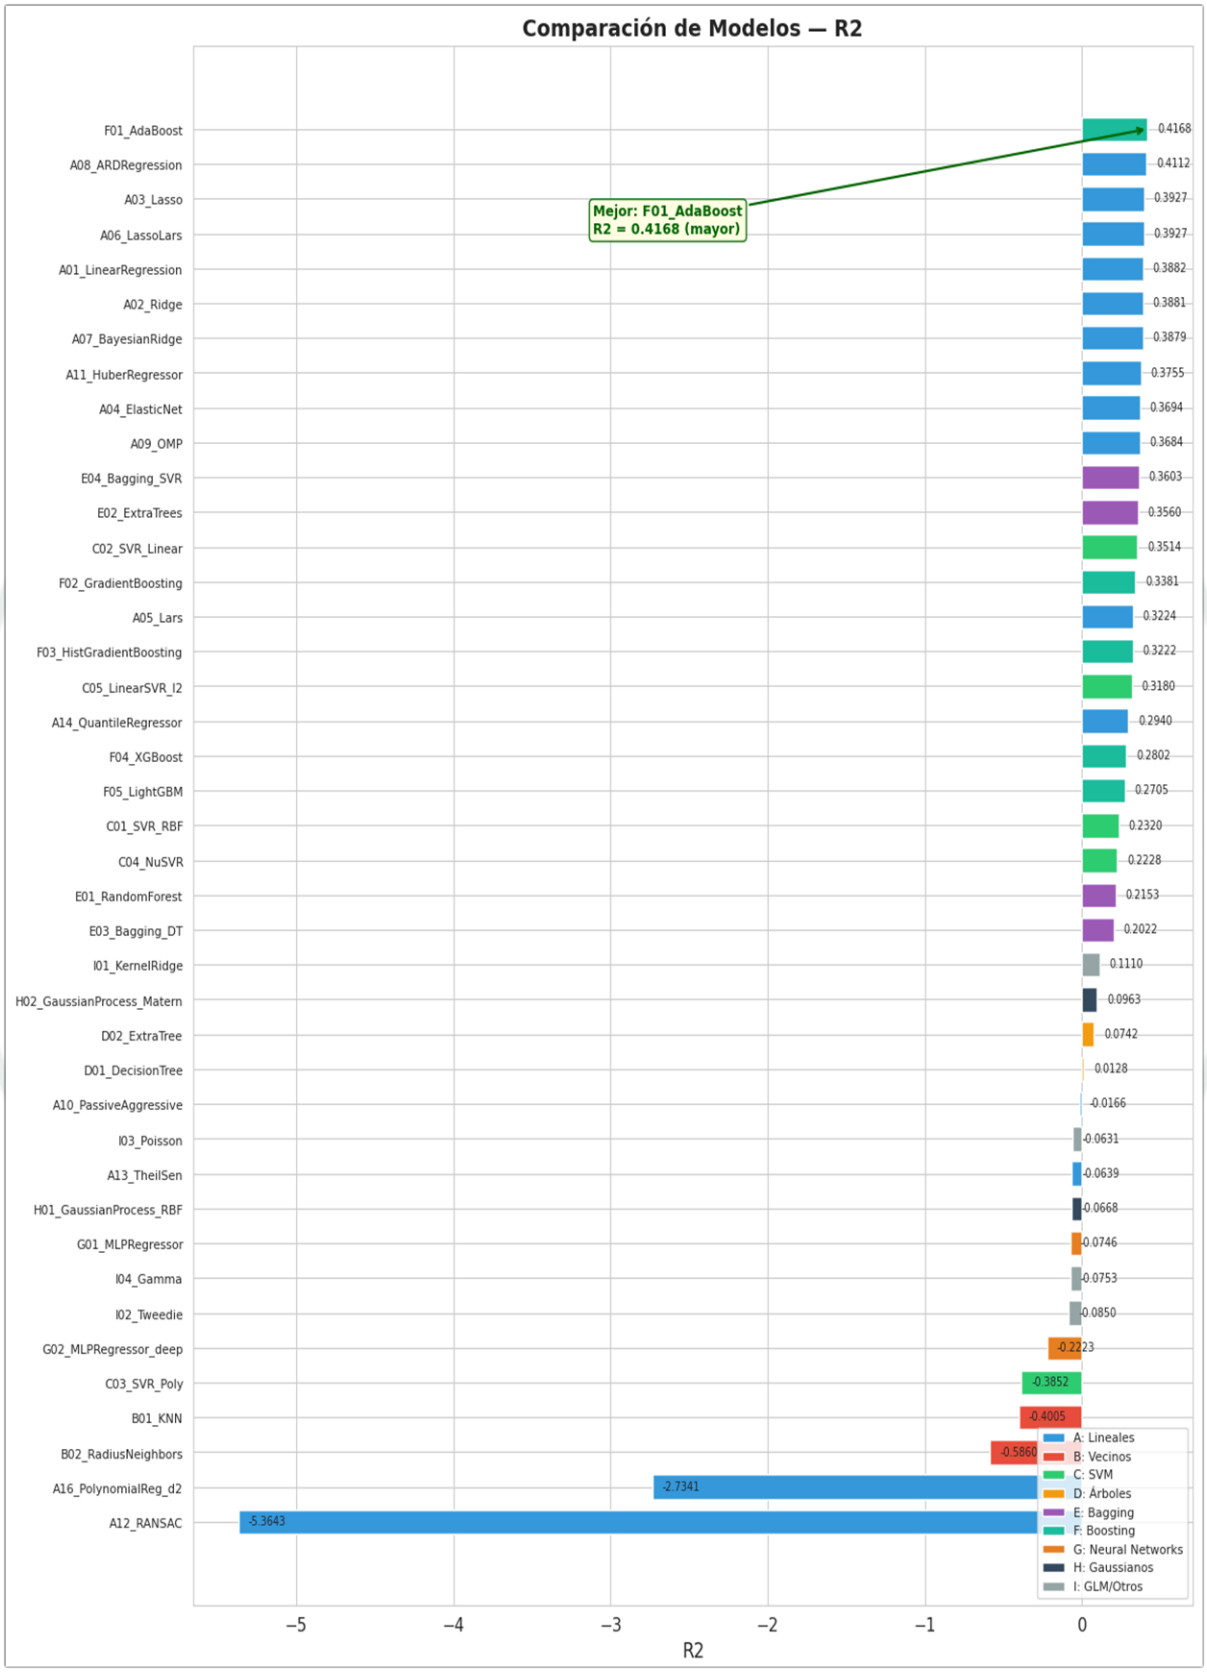
Model	Grupo	RMSE	MAE	R2	MAPE
F01_AdaBoost	F: Boosting	12.63	8.85	0.42	0.87
A08_ARDRegression	A: Lineales	12.67	9.83	0.41	1.23
A03_Lasso	A: Lineales	12.84	10.01	0.39	1.29
A06_LassoLars	A: Lineales	12.84	10.01	0.39	1.29
A01_LinearRegression	A: Lineales	12.89	9.99	0.39	1.24
A02_Ridge	A: Lineales	12.89	9.99	0.39	1.24
A07_BayesianRidge	A: Lineales	12.89	10.00	0.39	1.24
A11_HuberRegressor	A: Lineales	12.96	9.79	0.38	1.12
A04_ElasticNet	A: Lineales	13.07	10.35	0.37	1.46
A09_OMP	A: Lineales	13.08	10.19	0.37	1.39
E04_Bagging_SVR	E: Bagging	13.09	9.39	0.36	0.97
E02_ExtraTrees	E: Bagging	13.27	8.87	0.36	0.57
C02_SVR_Linear	C: SVM	13.15	9.35	0.35	0.96
F02_GradientBoosting	F: Boosting	13.31	8.63	0.34	0.59
A05_Lars	A: Lineales	13.59	11.15	0.32	2.00
F03_HistGradientBoosting	F: Boosting	13.62	8.85	0.32	0.59
C05_LinearSVR_l2	C: SVM	13.44	9.51	0.32	0.94
A14_QuantileRegressor	A: Lineales	13.82	10.60	0.29	1.71
F04_XGBoost	F: Boosting	13.96	9.54	0.28	0.62
F05_LightGBM	F: Boosting	14.16	9.63	0.27	0.66
C01_SVR_RBF	C: SVM	14.54	10.76	0.23	1.22
C04_NuSVR	C: SVM	14.60	11.53	0.22	1.78
E01_RandomForest	E: Bagging	14.68	9.33	0.22	0.59
E03_Bagging_DT	E: Bagging	14.80	9.48	0.20	0.59
I01_KernelRidge	I: GLM/Otros	15.64	12.03	0.11	0.84
H02_GaussianProcess_Matern	H: Gaussianos	15.78	12.35	0.10	1.58
D02_ExtraTree	D: Árboles	15.74	9.52	0.07	0.61
D01_DecisionTree	D: Árboles	16.49	10.61	0.01	0.65
A10_PassiveAggressive	A: Lineales	16.32	11.62	-0.02	0.85
I03_Poisson	I: GLM/Otros	16.43	12.57	-0.06	1.75
A13_TheilSen	A: Lineales	16.59	11.05	-0.06	1.15
H01_GaussianProcess_RBF	H: Gaussianos	17.11	13.99	-0.07	2.23
G01_MLPRegressor	G: Neural Networks	16.95	11.84	-0.07	0.90
I04_Gamma	I: GLM/Otros	16.72	12.85	-0.08	2.13
I02_Tweedie	I: GLM/Otros	16.53	12.52	-0.08	1.86
G02_MLPRegressor_deep	G: Neural Networks	18.32	12.35	-0.22	0.86
C03_SVR_Poly	C: SVM	19.38	15.02	-0.39	2.25
B01_KNN	B: Vecinos	19.61	14.54	-0.40	1.11
B02_RadiusNeighbors	B: Vecinos	20.76	16.81	-0.59	2.62
A16_PolynomialReg_d2	A: Lineales	28.87	17.14	-2.73	1.79
A12_RANSAC	A: Lineales	31.84	14.20	-5.36	2.31
A15_SGDRegressor	A: Lineales	4.58E+11	1.47E+11	-1.24E+21	1.43E+10

Fuente: Elaboración propia a partir de train_and_evaluate_all(). RMSE y MAE expresados en días.

Los resultados de la Tabla “Resultados comparativos de validación cruzada GroupKFold=3 de 42 modelos” muestran un desempeño moderado y relativamente homogéneo entre los modelos mejor posicionados, con valores de R^2 comprendidos entre 0.39 y 0.42 para el conjunto de los cinco primeros lugares, todos ellos pertenecientes al grupo de modelos lineales (Grupo A) o de boosting adaptativo (AdaBoost, Grupo F). En el extremo opuesto, se observa un comportamiento numéricamente inestable en modelos sensibles a la escala y a la configuración de hiperparámetros por defecto: SGDRegressor produjo una divergencia numérica extrema (R^2 del orden de -7.9×10^{23}, producto de una tasa de aprendizaje inadecuada para la escala de las variables no estandarizadas dentro de su propio proceso iterativo) y la regresión polinómica de grado 2 (A16) sobreajustó de forma severa en presencia de un elevado número de interacciones, generando un RMSE de validación de 282.25 días, muy por encima de la escala natural de la variable objetivo (0 - 71 días). Estos dos casos evidencian la importancia de una regularización adecuada y de un tratamiento cuidadoso de la escala de variables al emplear modelos basados en descenso de gradiente o expansión polinómica en datos con outliers.

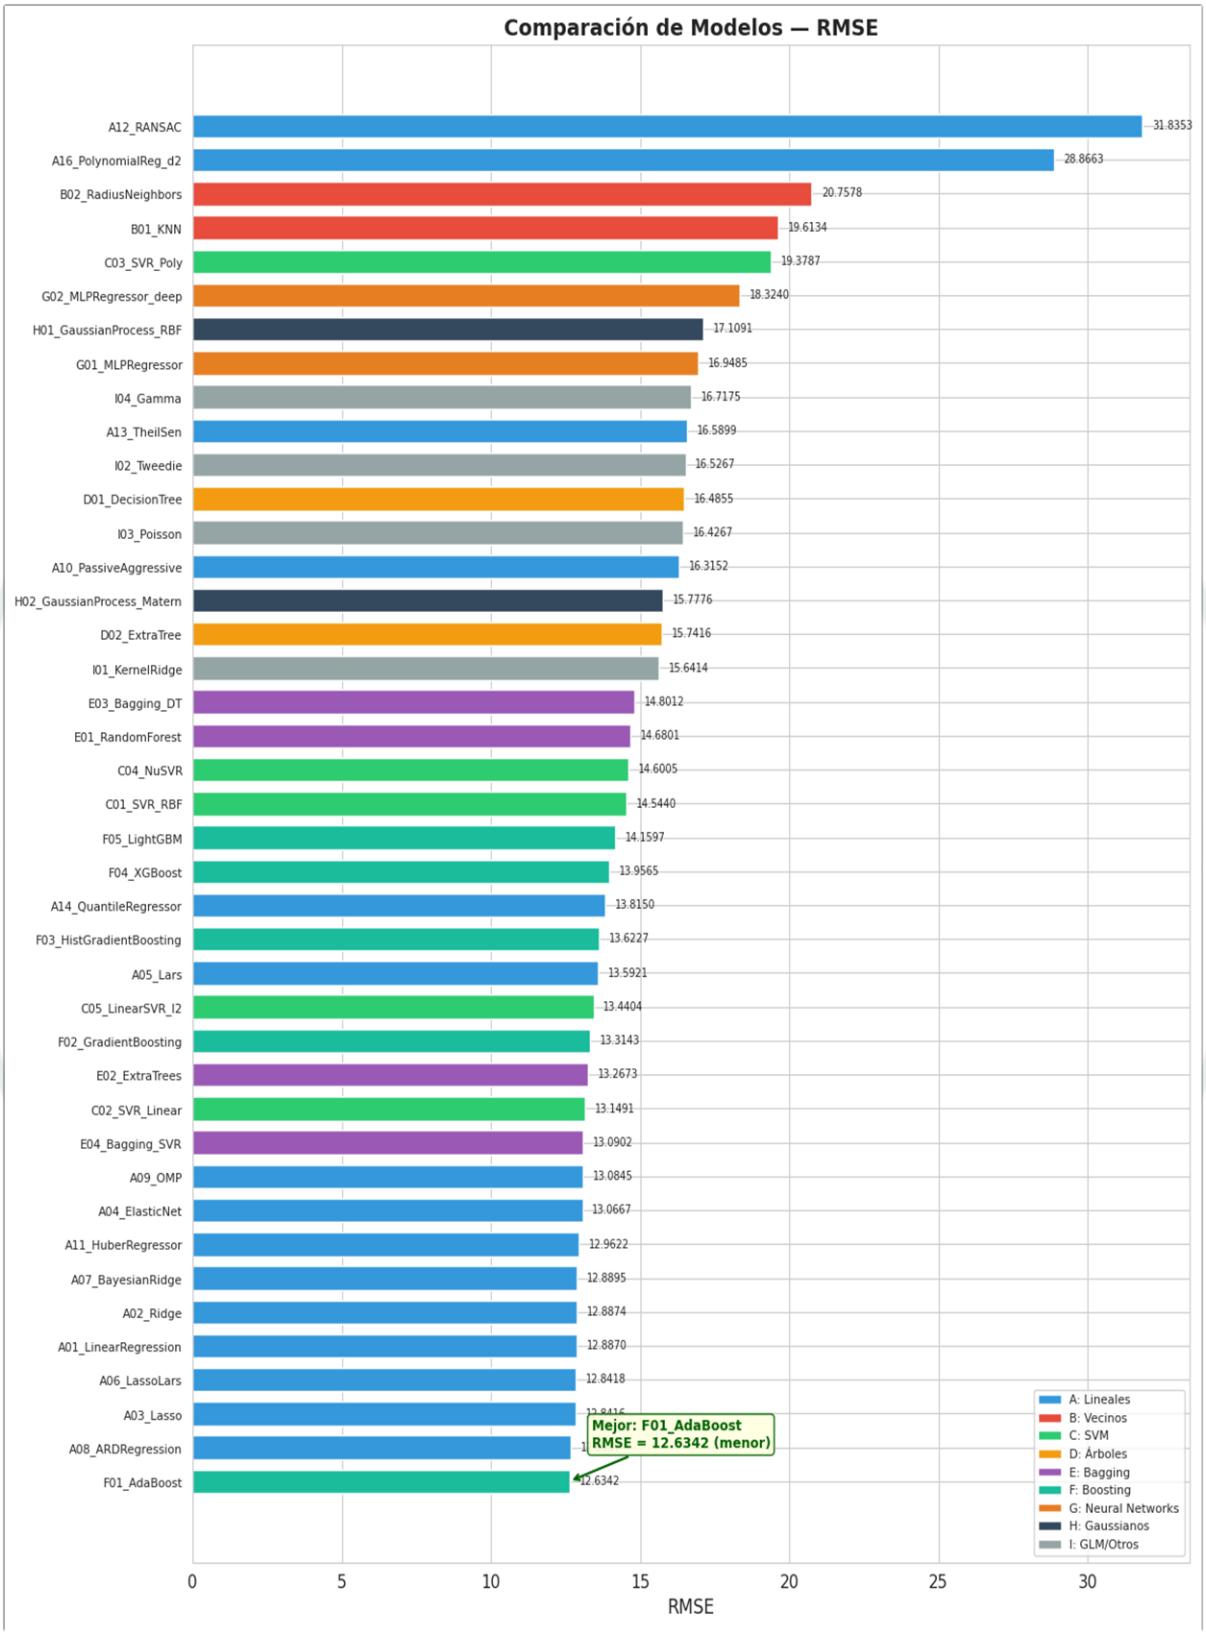
Es igualmente relevante notar que los modelos de boosting más sofisticados XGBoost ($R^2 = 0.2656$) y LightGBM ($R^2 = 0.2584$) no lograron superar en esta etapa exploratoria a los modelos lineales regularizados ni a AdaBoost con hiperparámetros por defecto, lo que sugiere que, con el conjunto reducido de características disponible (15 variables) y el tamaño moderado de la muestra (6758 registros de entrenamiento), la capacidad adicional de estos modelos no estaba siendo aprovechada bajo su configuración inicial, y que la optimización de hiperparámetros resultaba necesaria antes de descartarlos.

Figura 35: Comparación de modelos R2.



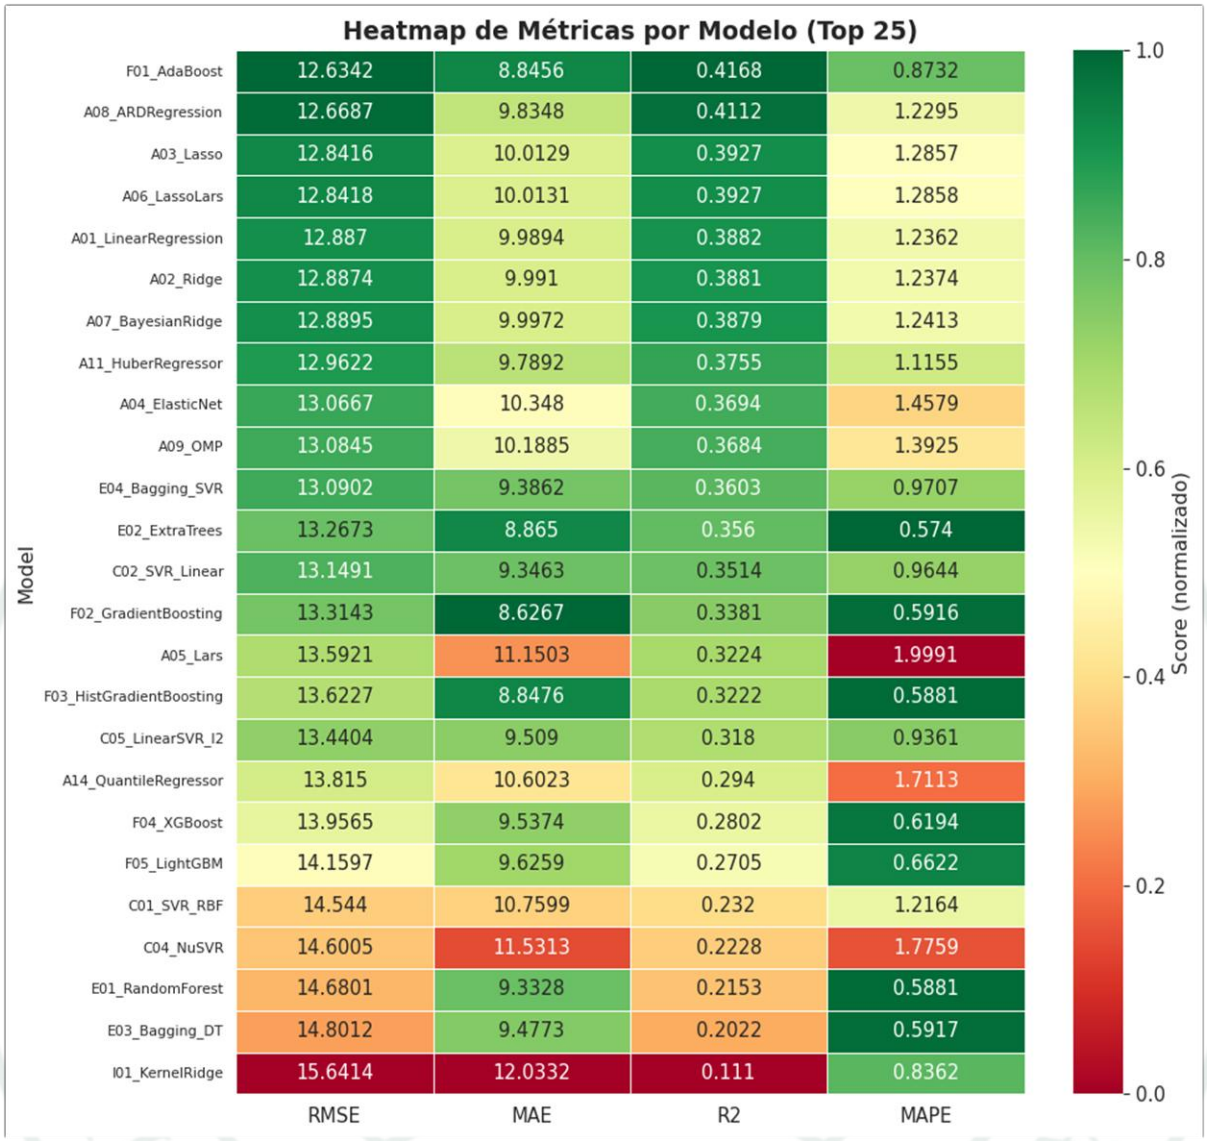
Fuente: Elaboración propia a partir de la función plot_model_comparison.

Figura 36: Comparación de modelos RMSE.



Fuente: Elaboración propia a partir de la función plot_model_comparison.

Figura 37: Heatmap de todas las métricas normalizadas por modelo.



Fuente: Elaboración propia a partir de la función plot_model_heatmap.

4.7.3. Modelos preseleccionados

A partir de la tabla de resultados comparativos de la validación cruzada mediante GroupKFold con 3 particiones, correspondiente a los 42 modelos evaluados, se procedió a realizar una selección preliminar de los algoritmos con mejor desempeño. Para ello, la función shortlist_top_models() ordenó los modelos de acuerdo con su coeficiente de determinación (R^2) promedio y seleccionó los cinco modelos con los valores más elevados.

Esta selección permitió reducir el conjunto inicial de algoritmos y concentrar la siguiente etapa del desarrollo en los modelos que mostraron una mayor capacidad explicativa durante la validación cruzada. Los cinco modelos seleccionados fueron posteriormente considerados para la optimización de hiperparámetros, el propósito es mejorar el desempeño predictivo y determinar la configuración más adecuada para el problema de estimación de la duración de las partidas.

Tabla 25: Modelos preseleccionados top 5 por R^2.

Posición	Modelo	R^2 promedio	Desviación. estándar R^2	RMSE (días)	Grupo
1	F01_AdaBoost	0.4168	± 0.2174	12.6342	F: Boosting
2	A08_ARDRegression	0.4112	± 0.1591	12.6687	A: Lineales
3	A03_Lasso	0.3927	± 0.1700	12.8416	A: Lineales
4	A06_LassoLars	0.3927	± 0.1700	12.8418	A: Lineales
5	A01_LinearRegression	0.3882	± 0.1709	12.8870	A: Lineales

Fuente: elaboración propia a partir de shortlist_top_models().

Los resultados de la validación cruzada muestran que AdaBoost obtuvo el mejor desempeño promedio entre los modelos preseleccionados, de acuerdo con el valor medio del coeficiente de determinación (R^2). Sin embargo, presentó una desviación estándar de ±0.2174 entre las tres particiones de validación, lo que evidencia una variabilidad considerable en su desempeño dependiendo de las obras incluidas en cada partición.

Por otro lado, ARDRegression (Automatic Relevance Determination) ocupó la segunda posición en términos de R^2 promedio, aunque presentó una desviación estándar de ±0.1591, siendo el modelo con mayor variabilidad entre los folds dentro del conjunto preseleccionado. Este comportamiento indica que su capacidad predictiva puede verse influenciada por la composición particular de las obras utilizadas durante cada iteración de la validación cruzada.

En consecuencia, si bien AdaBoost y ARDRegression presentaron los mejores valores promedio de R^2, la variabilidad observada entre las particiones constituye un aspecto

importante para la evaluación posterior. Por ello, la selección definitiva no debe basarse únicamente en el desempeño promedio, sino también en la estabilidad del modelo frente a diferentes conjuntos de obras, aspecto que será considerado durante la optimización y evaluación final de los algoritmos.

4.8. Optimización de Hiperparámetros y Construcción del Ensamble (Fine-tune)

La sexta etapa del desarrollo tuvo por objetivo refinar el desempeño de los cinco modelos preseleccionados mediante búsqueda de hiperparámetros, analizar la importancia relativa de las variables predictoras y explorar estrategias de combinación de modelos (ensamble) que capitalizaran las fortalezas individuales de cada algoritmo.

4.8.1. Espacio de búsqueda de hiperparámetros

Después de realizar la comparación inicial de los modelos, se estableció un procedimiento para optimizar los hiperparámetros de los algoritmos que presentaron mayor potencial predictivo. Para ello, la función get_param_grid() define diferentes combinaciones de hiperparámetros para modelos seleccionados de las familias de boosting, bagging, árboles de decisión y redes neuronales. Estos espacios de búsqueda serán utilizados posteriormente mediante RandomizedSearchCV, con el propósito de encontrar configuraciones que mejoren el desempeño predictivo de cada modelo.

Hiperparametros para mejorar el modelo de Adaboost.

```
        'F01_AdaBoost': {
            'model__n_estimators': [50, 100, 200, 300],
            'model__learning_rate': [0.01, 0.05, 0.1, 0.5, 1.0],
```

Nota: Con ello se busca determinar la cantidad adecuada de estimadores y la velocidad con la que cada nuevo modelo contribuye al ensamble.

Fuente: Elaboración propia.

Después de definir los espacios de búsqueda de hiperparámetros, se implementó la función fine_tune_model() para realizar el ajuste de los modelos seleccionados mediante RandomizedSearchCV. Esta función permite explorar diferentes combinaciones de hiperparámetros utilizando validación cruzada agrupada por OBRA_ID, con el propósito de identificar la configuración que minimiza el error cuadrático medio de la raíz (RMSE).

Ajustes para modelos seleccionados.

```
def fine_tune_model(model_name, model, preprocessor, X, y, groups,
n_iter=40):
    """
    Fine-tune un modelo con RandomizedSearchCV + GroupKFold.
    Retorna best_params, best_score, best_pipeline.
    """
    param_grid = get_param_grid(model_name)
    if param_grid is None:
        print(f"  No hay grid definido para {model_name}, usando parámetros
por defecto.")
        pipeline = create_model_pipeline(preprocessor, model)
        pipeline.fit(X, y)
        return {}, None, pipeline
    pipeline = create_model_pipeline(preprocessor, model)
    gkf = GroupKFold(n_splits=min(3, len(np.unique(groups))))

    search = RandomizedSearchCV(
        pipeline, param_grid, n_iter=min(n_iter, 20),
        cv=gkf, scoring='neg_root_mean_squared_error',
        random_state=RANDOM_STATE, n_jobs=-1, verbose=0,
        return_train_score=True
    )
    search.fit(X, y, groups=groups)

    print(f"  Mejor score (neg_RMSE): {search.best_score_:.4f}")
    print(f"  Mejores parámetros:")
    for k, v in search.best_params_.items():
        print(f"    {k}: {v}")

    return search.best_params_, search.best_score_, search.best_estimator_
```

Nota: El objetivo es encontrar una configuración del modelo que presente el mejor desempeño predictivo.

Fuente: Elaboración propia.

De los cinco modelos preseleccionados, únicamente AdaBoost contaba con un espacio de búsqueda definido en el código; los cuatro modelos lineales restantes (ARDRegression, Lasso, LassoLars y LinearRegression) fueron ajustados con sus hiperparámetros por defecto de scikit-learn, dado que su reducido número de hiperparámetros libres y su naturaleza convexa hacen que la búsqueda aleatoria aporte una ganancia marginal limitada frente al costo computacional adicional.

Tabla 26: Mejores hiperparámetros para AdaBoost (RandomizedSearchCV).

Hiperparámetro	Valor óptimo
model__n_estimators	100
model__learning_rate	0.01

Fuente: elaboración propia. Mejor score de validación (neg-RMSE)

4.8.2. Curvas de aprendizaje, importancia de variables y análisis de residuos

Una vez realizado el ajuste de hiperparámetros, se implementó la función plot_learning_curve_fn() para analizar el comportamiento del modelo a medida que aumenta la cantidad de datos utilizados para su entrenamiento.

Función de las curvas de aprendizaje: Evalúan la estabilidad y generalización del modelo analizando su desempeño (RMSE) a medida que aumenta el volumen de datos de entrenamiento.

Interpretación de los 4 casos:

Sobreajuste: Brecha amplia entre un RMSE de entrenamiento bajo y uno de validación alto. El modelo memoriza, pero no generaliza a nuevas obras.

Subajuste: Ambas curvas permanecen altas y muy cercanas. El modelo es demasiado simple para capturar la relación entre variables y duraciones.

Buen comportamiento: Ambas curvas convergen en valores bajos de RMSE. Indica alta capacidad de generalización.

Beneficio de más datos: La curva de validación mantiene una tendencia decreciente. El modelo se beneficiaría de un dataset más grande.

Aporte clave: Complementa la evaluación del RMSE promedio verificando que el modelo mantenga su precisión en escenarios con distinta disponibilidad de datos.

Código para analizar el comportamiento del modelo.

```
def plot_learning_curve_fn(pipeline, X, y, title, groups=None, cv=5):
    """Genera curva de aprendizaje para un pipeline."""
    if groups is not None:
        cv_obj = GroupKFold(n_splits=min(cv, len(np.unique(groups))))
        train_sizes, train_scores, val_scores = learning_curve(
            pipeline, X, y, cv=cv_obj, groups=groups,
            train_sizes=np.linspace(0.1, 1.0, 10),
            scoring='neg_root_mean_squared_error', n_jobs=-1
        )
    else:
        train_sizes, train_scores, val_scores = learning_curve(
            pipeline, X, y, cv=cv,
            train_sizes=np.linspace(0.1, 1.0, 10),
            scoring='neg_root_mean_squared_error', n_jobs=-1
        )

    train_mean = -train_scores.mean(axis=1)
    train_std = train_scores.std(axis=1)
    val_mean = -val_scores.mean(axis=1)
    val_std = val_scores.std(axis=1)

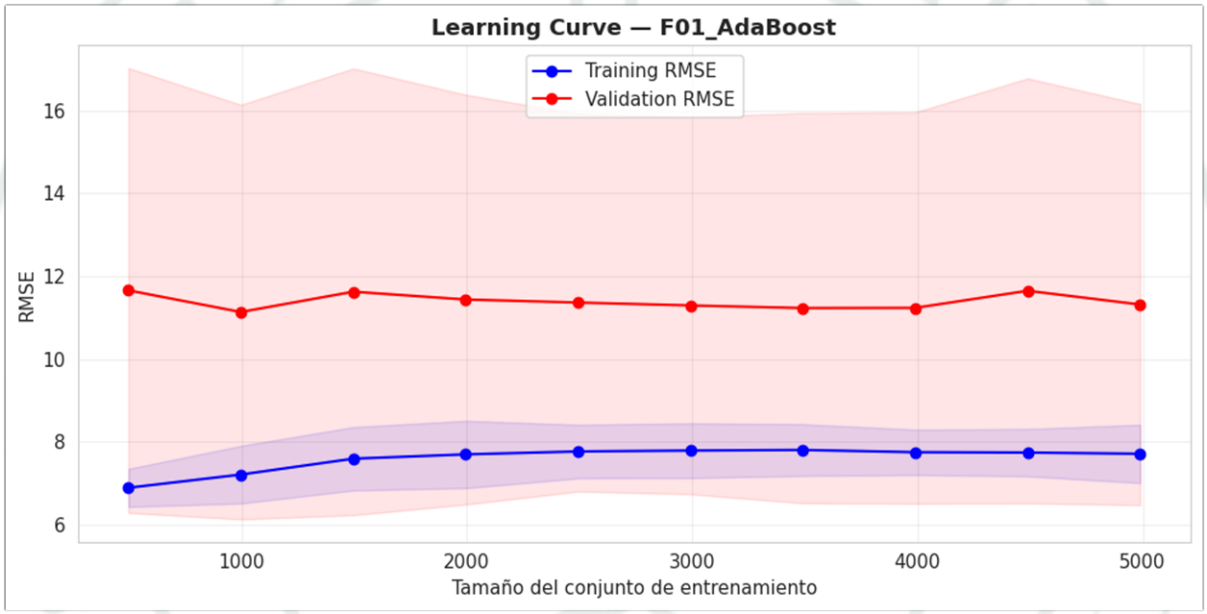
    fig, ax = plt.subplots(figsize=(10, 5))
    ax.fill_between(train_sizes, train_mean - train_std, train_mean +
train_std, alpha=0.1, color='blue')
    ax.fill_between(train_sizes, val_mean - val_std, val_mean + val_std,
alpha=0.1, color='red')
    ax.plot(train_sizes, train_mean, 'o-', color='blue', label='Training
RMSE')
    ax.plot(train_sizes, val_mean, 'o-', color='red', label='Validation
RMSE')
    ax.set_xlabel('Tamaño del conjunto de entrenamiento')
    ax.set_ylabel('RMSE')
    ax.set_title(f'Learning Curve – {title}', fontweight='bold')
```

```
    ax.legend()
    ax.grid(True, alpha=0.3)
    plt.tight_layout()
    plt.show()
```

Nota: Genera curvas de aprendizaje mediante validación cruzada, utilizando el RMSE como métrica de evaluación.

Fuente: elaboración propia.

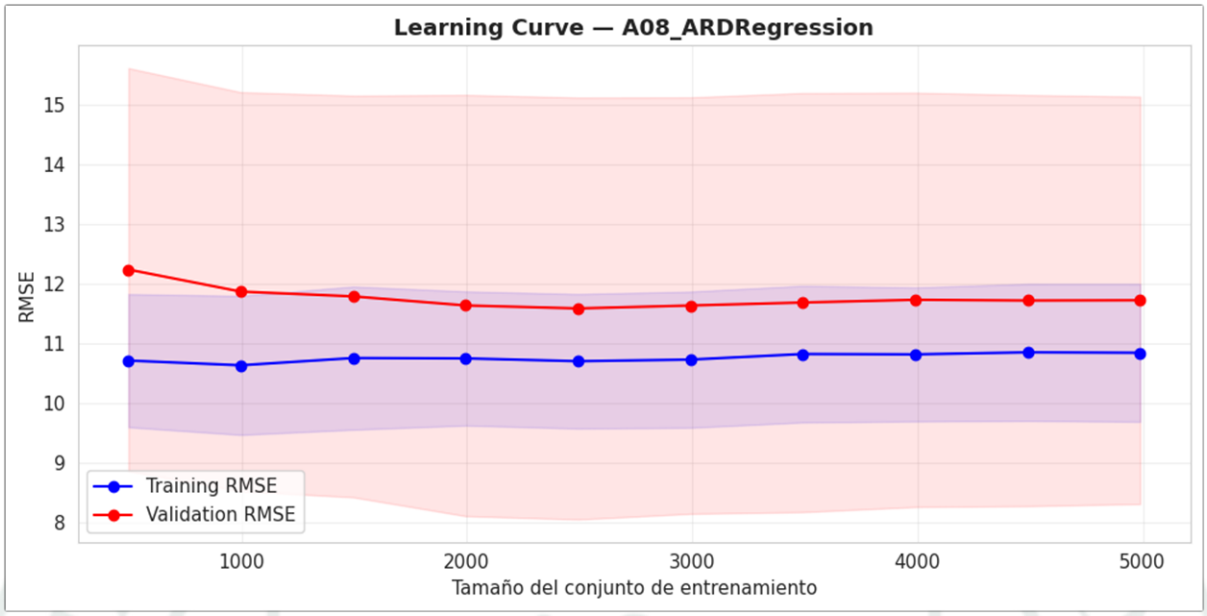
Figura 38: Learning Curve - F01_AdaBoost



Nota: El modelo esta sobreajuste.

Fuente: Elaboración propia a partir de plot_learning_curve_fn().

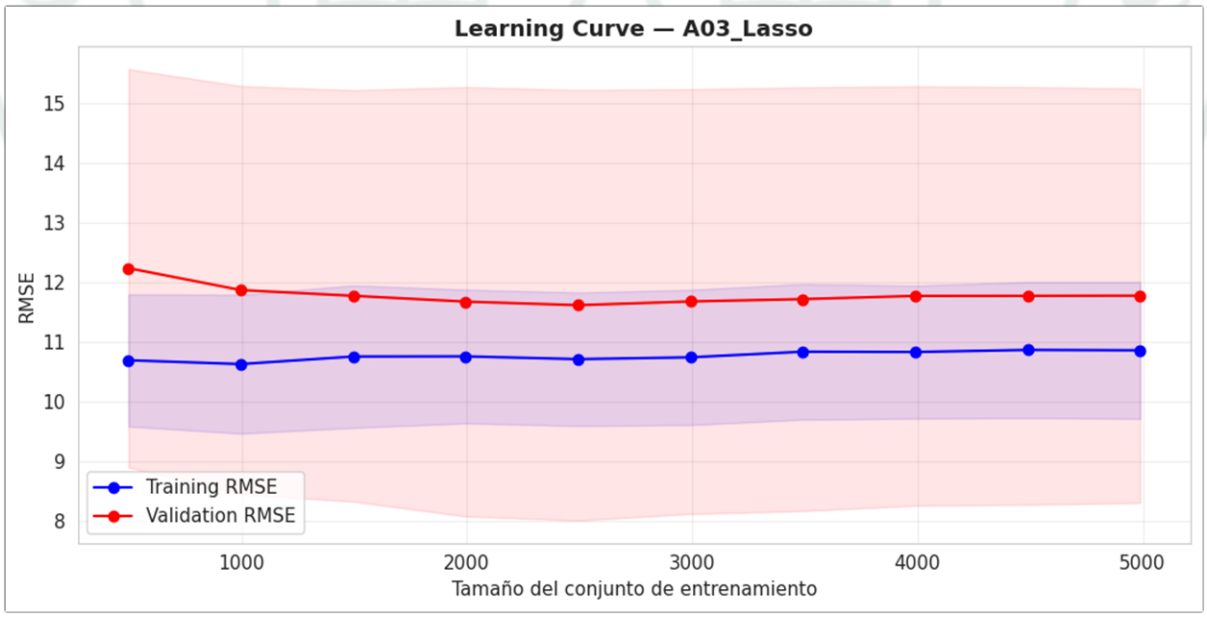
Figura 39: Learning Curve - A08_ARDRegression



Nota: El modelo esta subajuste.

Fuente: Elaboración propia a partir de plot_learning_curve_fn().

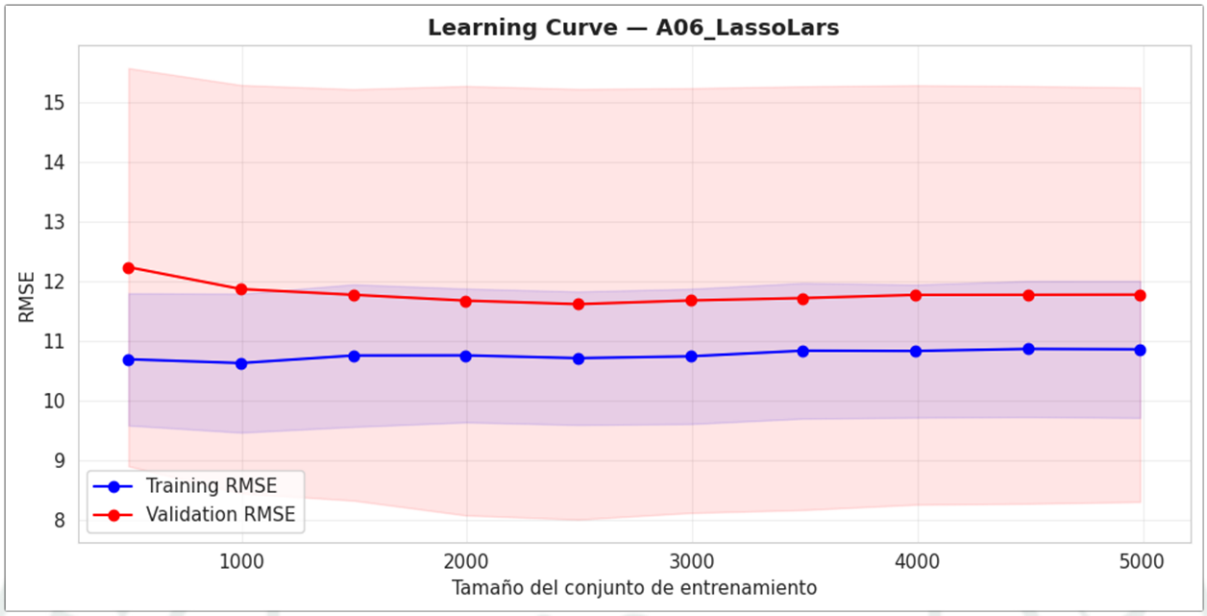
Figura 40: Learning Curve - A03_Lasso



Nota: El modelo esta subajuste.

Fuente: Elaboración propia a partir de plot_learning_curve_fn().

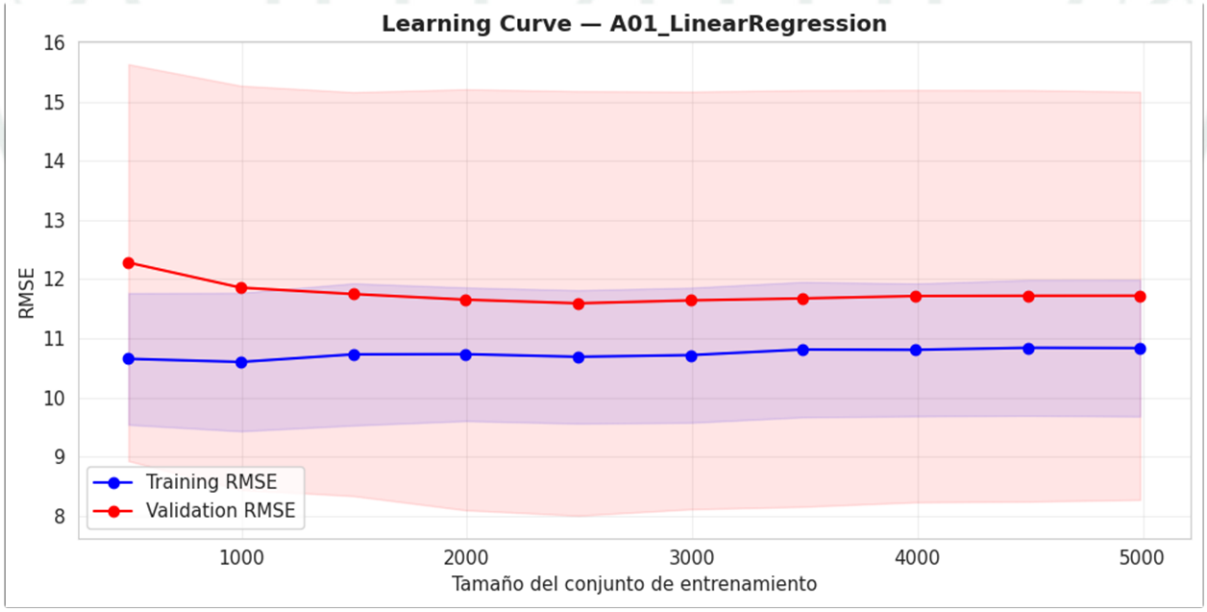
Figura 41: Learning Curve - A06_LassoLars



Nota: El modelo esta subajuste.

Fuente: Elaboración propia a partir de plot_learning_curve_fn().

Figura 42: Learning Curve - A01_LinearRegression



Nota: El modelo esta subajuste.

Fuente: elaboración propia a partir de plot_learning_curve_fn().

Como parte del análisis de los modelos ajustados, se implementó la función plot_permutation_importance_fn() para determinar la importancia relativa de las variables predictoras en el desempeño del modelo.

Código de importancia relativa de las variables.

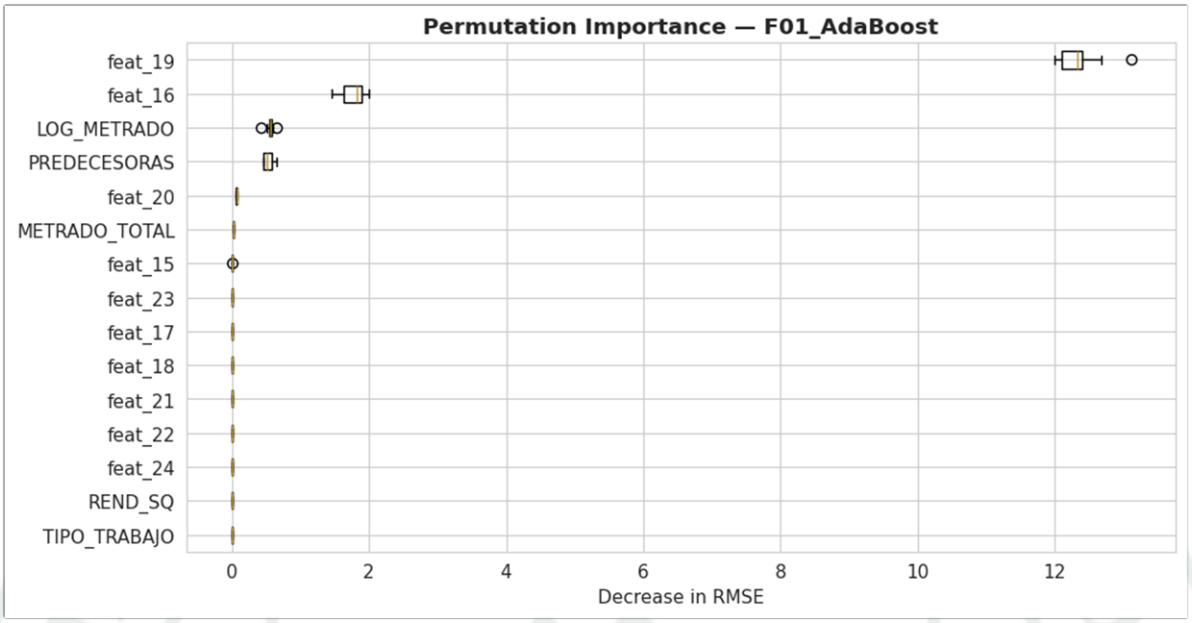
```
def plot_permutation_importance_fn(pipeline, X_val, y_val, feature_names,
top_n=15, title=''):
    """Permutation importance para cualquier modelo."""
    from sklearn.inspection import permutation_importance
    result = permutation_importance(pipeline, X_val, y_val, n_repeats=10,
                                    random_state=RANDOM_STATE, n_jobs=-1,
                                    scoring='neg_root_mean_squared_error')
    sorted_idx = result.importances_mean.argsort()[-top_n:]

    fig, ax = plt.subplots(figsize=(10, max(4, top_n * 0.35)))
    ax.boxplot(result.importances[sorted_idx].T, vert=False,
               labels=[feature_names[i] if i < len(feature_names) else
f'feat_{i}' for i in sorted_idx])
    ax.set_title(f'Permutation Importance — {title}', fontweight='bold')
    ax.set_xlabel('Decrease in RMSE')
    plt.tight_layout()
    plt.show()
```

Nota: La función plot_permutation_importance_fn() determina la relevancia de las variables predictoras mediante el método de permutación, evaluando el cambio en el RMSE producido al alterar aleatoriamente cada característica.

Fuente: Elaboración propia.

Figura 43: Permutation Importance del mejor modelo.



Nota: Se realizan 10 permutaciones por variable y se representan las 15 características con mayor importancia promedio mediante diagramas de caja. Los resultados permiten identificar las variables con mayor contribución predictiva al modelo de estimación de la duración de las partidas, sin que dicha importancia implique necesariamente una relación causal.

Fuente: Elaboración propia a partir la función plot_permutation_importance_fn().

Se implementó la función plot_feature_importance() para identificar y visualizar las variables que presentan mayor importancia dentro de los modelos que proporcionan directamente medidas de importancia de características o coeficientes.

Su principal aporte consiste en identificar qué variables tienen mayor peso dentro de determinados algoritmos. Esto permite complementar las métricas de evaluación con una interpretación de las características utilizadas por el modelo para estimar la duración de las partidas.

Por ejemplo, si en un modelo como Random Forest METRADO_TOTAL presenta una barra considerablemente mayor que las demás variables, significa que esta característica tuvo una participación importante en las decisiones internas de los árboles que conforman el modelo

Código para identificar variables con mayor participación.

```
def plot_feature_importance(model, feature_names, top_n=15, title=''):
    """Feature importance para modelos tree-based."""
    if hasattr(model, 'feature_importances_'):
        importances = model.feature_importances_
    elif hasattr(model, 'coef_'):
        importances = np.abs(model.coef_)
    else:
        print("  El modelo no tiene feature_importances_ ni coef_")
        return

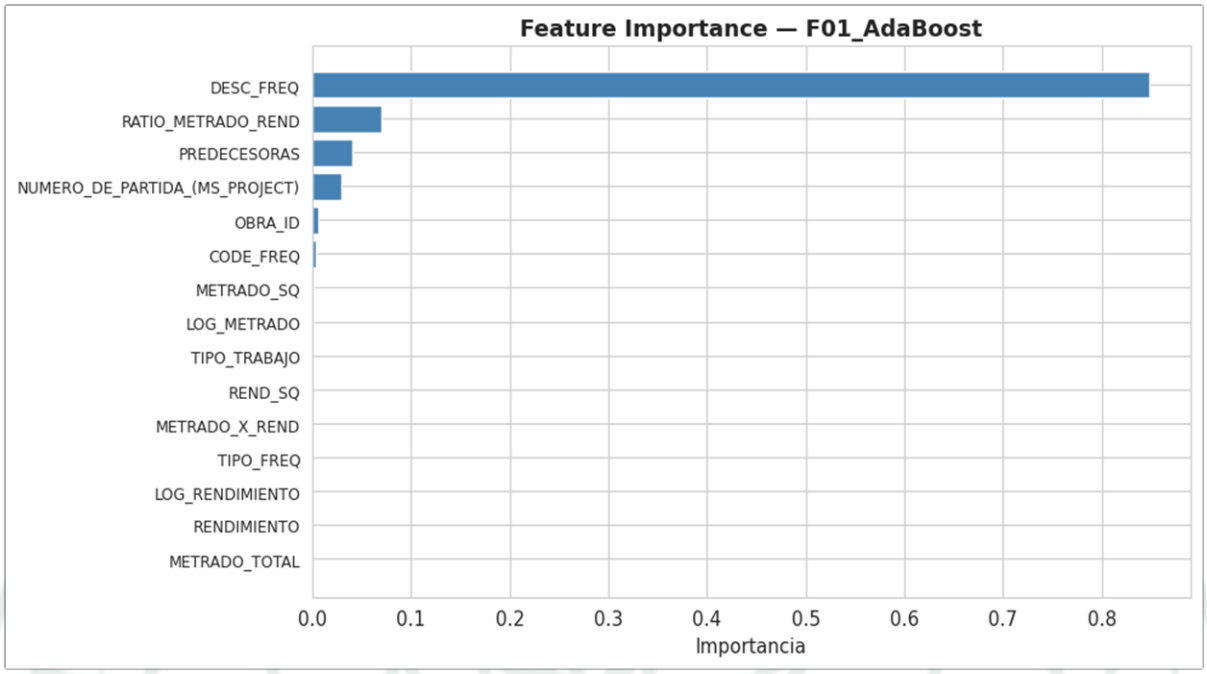
    n = min(top_n, len(feature_names), len(importances))
    indices = np.argsort(importances)[-n:]

    fig, ax = plt.subplots(figsize=(10, max(4, n * 0.35)))
    ax.barh(range(n), importances[indices], color='steelblue',
edgecolor='white')
    ax.set_yticks(range(n))
    ax.set_yticklabels([feature_names[i] for i in indices], fontsize=9)
    ax.set_xlabel('Importancia')
    ax.set_title(f'Feature Importance — {title}', fontweight='bold')
    plt.tight_layout()
    plt.show()
```

Nota: La función plot_feature_importance() permite visualizar las características con mayor importancia según la medida proporcionada directamente por el modelo.

Fuente: Elaboración propia.

Figura 44: Feature Importance - F01_AdaBoost



Nota: el feacture más importante en el modelo de AdaBoost es DESC_FREQ, la frecuencia de partidas.

Fuente: elaboración propia a partir de plot_feature_importance().

Una vez seleccionado y evaluado el modelo predictivo, se implementó la función analyze_residuals() para realizar un análisis de los residuos de las predicciones. Este procedimiento permite determinar si existen patrones sistemáticos entre los valores reales y las predicciones del modelo, así como evaluar la distribución y variabilidad de los errores. De esta manera, se complementa la evaluación mediante métricas como RMSE, MAE y R^2 con un análisis gráfico del comportamiento de los errores de predicción.

Código para análisis de residuos.

```
def analyze_residuals(y_true, y_pred, title=''):
    """Análisis completo de residuos."""
    residuals = y_true - y_pred

    fig, axes = plt.subplots(1, 3, figsize=(18, 5))
```

```
    axes[0].scatter(y_pred, residuals, alpha=0.3, s=10, color='steelblue')
    axes[0].axhline(y=0, color='red', linestyle='--')
    axes[0].set_xlabel('Predicciones')
    axes[0].set_ylabel('Residuos')
    axes[0].set_title(f'Residuos vs Predicciones — {title}',
fontweight='bold')

    axes[1].hist(residuals, bins=50, color='steelblue', edgecolor='white',
alpha=0.8, density=True)
    mu, sigma = residuals.mean(), residuals.std()
    x = np.linspace(residuals.min(), residuals.max(), 100)
    axes[1].plot(x, stats.norm.pdf(x, mu, sigma), 'r-', linewidth=2)
    axes[1].set_title('Distribución de Residuos', fontweight='bold')
    axes[1].set_xlabel('Residuos')

    stats.probplot(residuals, dist='norm', plot=axes[2])
    axes[2].set_title('Q-Q Plot de Residuos', fontweight='bold')

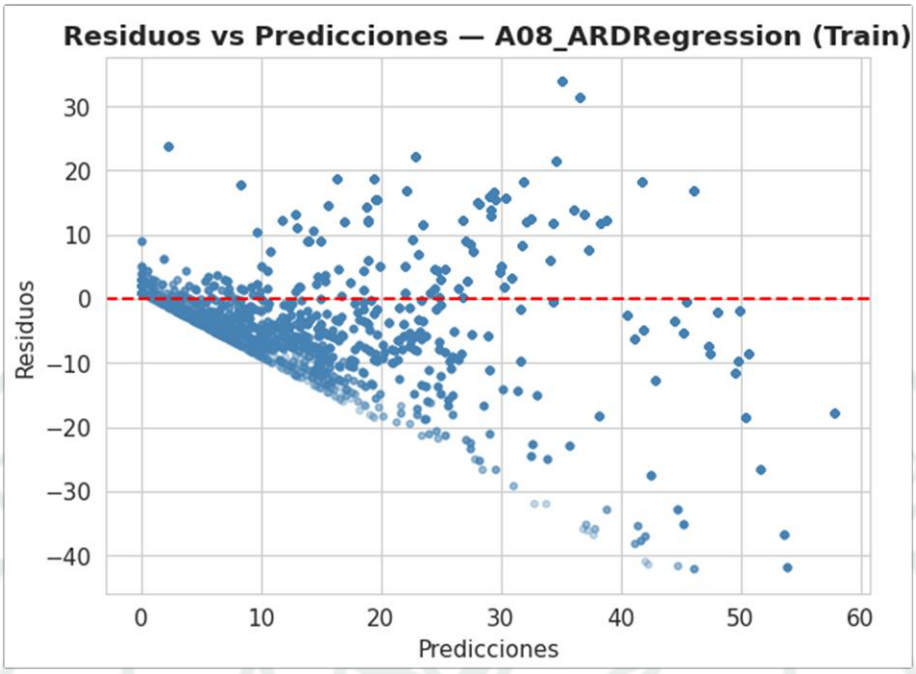
    plt.suptitle(f'Análisis de Residuos — {title}', fontsize=14,
fontweight='bold', y=1.02)
    plt.tight_layout()
    plt.show()

    print(f"  Media de residuos:    {residuals.mean():.4f}")
    print(f"  Std de residuos:      {residuals.std():.4f}")
    print(f"  Mediana de residuos:  {np.median(residuals):.4f}")
```

Nota: La función analyze_residuals() evalúa el comportamiento de los errores de predicción mediante tres representaciones: residuos frente a valores predichos, distribución de los residuos y Q-Q Plot.

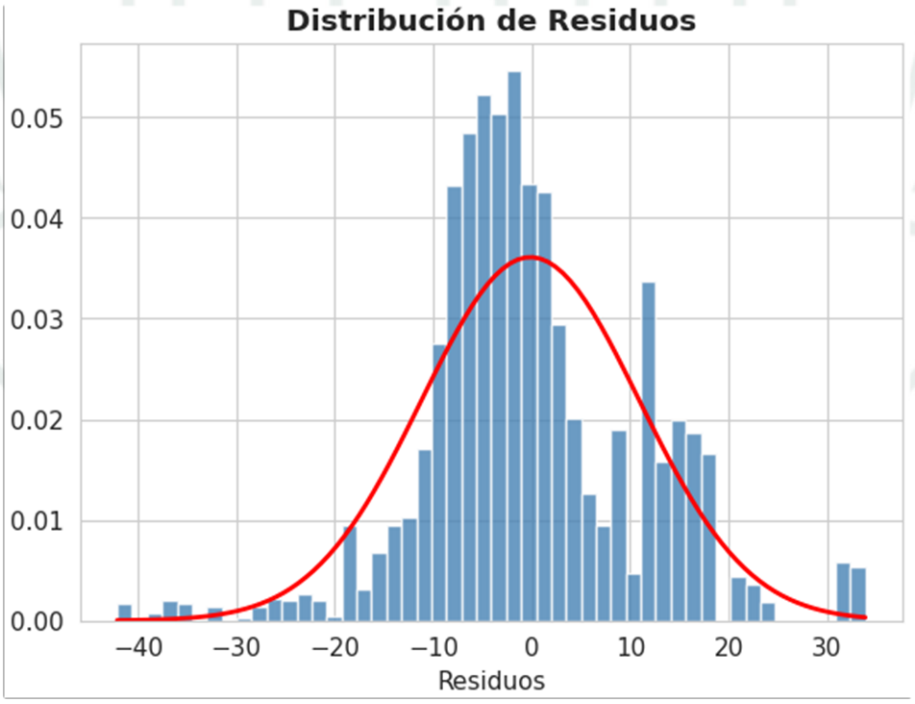
Fuente: Elaboración propia.

Figura 45: Residuos vs predicciones - A08_ARDRegression.



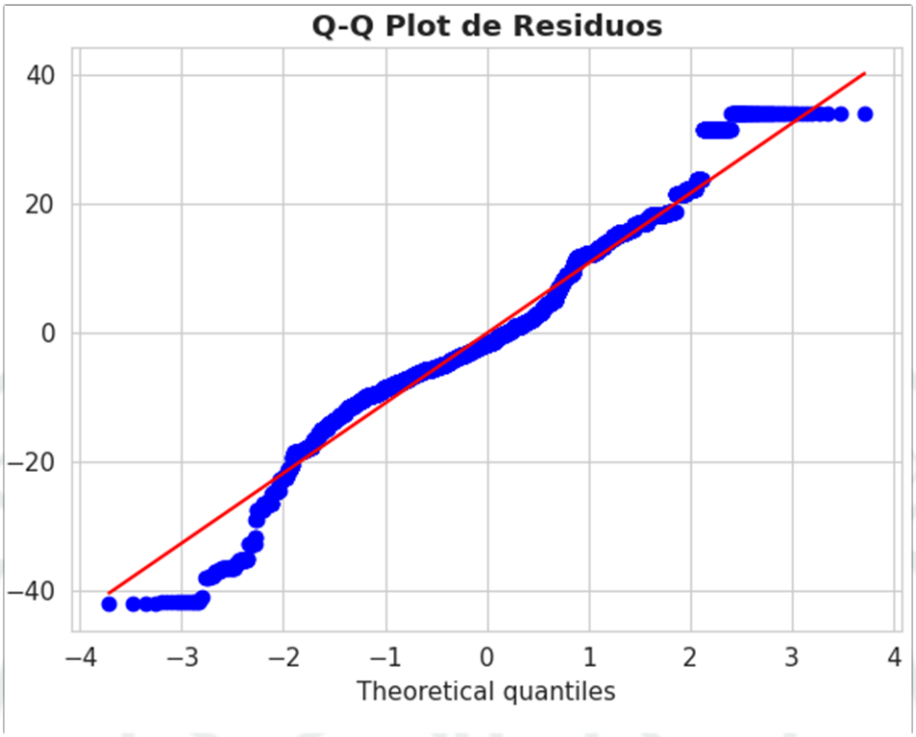
Fuente: Elaboración propia a partir de la función analyze_residuals().

Figura 46: Distribución de Residuos - A08_ARDRegression.



Fuente: Elaboración propia a partir de la función analyze_residuals().

Figura 47: Q-Q Plot de Residuos - A08_ARDRegression.



Fuente: Elaboración propia a partir de la función analyze_residuals().

Este análisis corresponde a una etapa de diagnóstico del comportamiento del modelo, posterior a la evaluación de sus métricas predictivas.

Su finalidad es verificar si los errores de predicción presentan un comportamiento aleatorio o si existe algún patrón que indique que el modelo todavía no representa adecuadamente determinadas relaciones presentes en los datos.

Residuos alrededor de cero

Si los residuos se encuentran distribuidos aproximadamente alrededor de cero, sin patrones evidentes, esto indica que el modelo no presenta un sesgo sistemático importante.

Patrones en los residuos

Si aparecen tendencias o estructuras en el gráfico de residuos frente a predicciones, puede indicar que el modelo no está capturando completamente alguna relación entre las variables predictoras y la duración.

Variabilidad creciente

Si los residuos presentan una dispersión pequeña para duraciones cortas y una dispersión mayor para duraciones largas, podría existir heterocedasticidad, es decir, una variabilidad del error que cambia según el nivel de duración estimado.

Esto es particularmente relevante en este estudio porque la variable DURACION_TOTAL_DIAS presenta una distribución con cierta asimetría y diferentes niveles de dispersión.

Media de residuos cercana a cero

Una media próxima a cero es favorable porque indica que, en términos generales, el modelo no tiende sistemáticamente a sobreestimar o subestimar las duraciones.

Por ejemplo:

$$\bar{e} \approx 0$$

sugiere ausencia de un sesgo global significativo.

Desviación estándar

Una desviación estándar menor indica que los residuos están más concentrados alrededor de su valor medio, lo que representa errores más consistentes.

Sin embargo, esta medida debe analizarse conjuntamente con RMSE y MAE, ya que por sí sola no determina qué modelo es mejor.

Q-Q Plot

El Q-Q Plot permite complementar el análisis de la distribución de los residuos. Una desviación respecto a la línea de referencia no necesariamente significa que el modelo sea inadecuado, especialmente en modelos de Machine Learning, donde la normalidad de los residuos no constituye un requisito universal para obtener buenas predicciones.

Por ello, en esta investigación el análisis debe utilizarse principalmente como una herramienta de diagnóstico y no como un criterio único para aceptar o rechazar el modelo.

Por ejemplo, las gráficas mostradas anteriormente pertenecen al modelo A08_ARDRegression, nos indican los siguientes datos para diagnosticar el modelo.

Tabla 27: Análisis Residual del modelo A08_ARDRegression.

Análisis Residual del modelo A08_ARDRegression.	
Media de residuos	-0.1363
Std de residuo	11.0501
Mediana de residuos	-1.7878

Nota: el modelo A08_ARDRegression no está sobrestimando duraciones, todavía no se está determinando si este modelo es mejor, el modelo está tendiendo un correcto comportamiento con los residuos.

Fuente: Elaboración propia a partir de la función analyze_residuals().

4.8.3. Construcción del modelo de ensamble final

En esta etapa se construye un ensamble final de modelos de Machine Learning, utilizando las técnicas de Stacking y Voting. Para ello, se seleccionan los cuatro modelos con mejor desempeño obtenidos en la etapa anterior de evaluación y ajuste. El propósito es combinar las predicciones de diferentes modelos para determinar si la integración de sus capacidades permite mejorar la precisión en la estimación de la duración de las partidas.

Código de la construcción del ensamble final.

```
print("\nConstruyendo Ensemble Final (Stacking + Voting)")
print("=" * 70)

from sklearn.ensemble import StackingRegressor, VotingRegressor
from sklearn.linear_model import Ridge
import copy

estimators_for_stack = []
estimators_for_vote = []
for name in top_model_names[:4]:
    if name in tuned_pipelines:
        est = copy.deepcopy(tuned_pipelines[name])
        clean_name = name.replace(' ', '_').lower()
        estimators_for_stack.append((clean_name, est))
        estimators_for_vote.append((clean_name,
copy.deepcopy(tuned_pipelines[name])))

if len(estimators_for_stack) >= 2:
    stacking = StackingRegressor(
        estimators=estimators_for_stack,
        final_estimator=Ridge(alpha=1.0),
        cv=3,
        n_jobs=-1
    )
```

Nota: StackingRegressor: combina varios modelos mediante un modelo final; VotingRegressor: combina las predicciones de varios modelos mediante un promedio; Ridge: actúa como modelo final del Stacking; copy: permite generar copias independientes de los modelos previamente ajustados; Se toman los cuatro primeros modelos de top_model_names, que corresponden a los modelos que obtuvieron los mejores resultados en la etapa comparativa; Se realiza una copia independiente de cada modelo ajustado.

Fuente: Elaboración propia.

Construcción del Stacking.

```
    print("Entrenando StackingRegressor...")
    try:
        stacking.fit(X_train, y_train)
        tuned_pipelines['J01_StackingEnsemble'] = stacking
        y_pred_stack = np.maximum(stacking.predict(X_test), 0)
        r2_stack = r2_score(y_test, y_pred_stack)
        rmse_stack = np.sqrt(mean_squared_error(y_test, y_pred_stack))
        print(f"  Stacking — R²={r2_stack:.4f}, RMSE={rmse_stack:.4f}")
    except Exception as e:
        print(f"  Error en Stacking: {e}")
```

Nota: Los cuatro modelos seleccionados generan predicciones sobre los datos, Estas predicciones son utilizadas como entradas para un modelo adicional.

Fuente: Elaboración propia.

Construcción del Voting.

```
    voting = VotingRegressor(estimators=estimators_for_vote, n_jobs=-1)
    print("Entrenando VotingRegressor...")
    try:
        voting.fit(X_train, y_train)
        tuned_pipelines['J02_VotingEnsemble'] = voting
        y_pred_vote = np.maximum(voting.predict(X_test), 0)
        r2_vote = r2_score(y_test, y_pred_vote)
        rmse_vote = np.sqrt(mean_squared_error(y_test, y_pred_vote))
        print(f"  Voting  — R²={r2_vote:.4f}, RMSE={rmse_vote:.4f}")
    except Exception as e:
        print(f"  Error en Voting: {e}")
```

Nota: A diferencia del Stacking, el VotingRegressor no utiliza un modelo adicional para aprender cómo combinar las predicciones; En términos generales, cada modelo produce una predicción y el ensamble obtiene una predicción conjunta mediante el promedio de las predicciones de los modelos base.

Fuente: Elaboración propia.

Como estrategia final de esta etapa, se combinaron los cuatro primeros modelos afinados (ARDRegression, AdaBoost, Lasso y LassoLars) mediante dos técnicas de ensamble de scikit-learn: un StackingRegressor, que empleó una regresión Ridge (alpha = 1.0) como metaestimador entrenado sobre las predicciones de los modelos base con validación cruzada interna de 3 particiones, y un VotingRegressor, que promedió de forma no ponderada las predicciones de los mismos cuatro modelos base. Ambos ensambles se entrenaron sobre el conjunto de entrenamiento completo (X_train, y_train) y se evaluaron directamente sobre el conjunto de prueba.

Tabla 28: Desempeño de los modelos de ensamble en el conjunto de prueba.

Estrategia de ensamble	R^2	RMSE (días)
Stacking	0.8061	7.4555
Voting	0.6792	9.5889

Fuente: elaboración propia a partir de la ejecución de StackingRegressor y VotingRegressor.

4.9. Evaluación final de la solución

La última etapa del desarrollo consistió en evaluar, sobre el conjunto de prueba (1 690 registros, no utilizados en ninguna etapa previa de entrenamiento ni de optimización), a los siete modelos disponibles al cierre del experimento: los cinco modelos afinados de la preselección y los dos ensambles construidos. La función final_evaluation() calculó, para cada modelo, las métricas RMSE, MAE, R^2, MAPE y el error absoluto mediano (MedAE), este último menos sensible a la presencia de residuos extremos que el MAE.

Código de evaluación final.

```
def final_evaluation(pipeline, X_test, y_test, name=''):
    """Evaluación final completa en test set."""
    y_pred = pipeline.predict(X_test)
    y_pred = np.maximum(y_pred, 0)

    rmse = np.sqrt(mean_squared_error(y_test, y_pred))
    mae = mean_absolute_error(y_test, y_pred)
    r2 = r2_score(y_test, y_pred)
    medae = median_absolute_error(y_test, y_pred)

    mask = y_test > 0
    mape = mean_absolute_percentage_error(y_test[mask], y_pred[mask]) if
mask.sum() > 0 else np.nan

    metrics = {
        'Model': name,
        'RMSE': rmse,
        'MAE': mae,
        'R²': r2,
        'MAPE': mape,
        'MedAE': medae,
    }

    print(f"\n{'='*50}")
    print(f"Evaluación Final: {name}")
    print(f"{'='*50}")
    for k, v in metrics.items():
        if k != 'Model':
            print(f"  {k:8s}: {v:.4f}")

    return metrics, y_pred
```

Nota: La función final_evaluation() realiza la evaluación definitiva del modelo sobre el conjunto de prueba mediante las métricas RMSE, MAE, R^2, MAPE y MedAE. Estas métricas permiten analizar de manera complementaria la magnitud del error, la precisión relativa y la capacidad explicativa del modelo en la predicción de la duración de las partidas. Las predicciones negativas fueron restringidas a cero debido a la naturaleza no negativa de la duración. Los resultados obtenidos constituyen la base cuantitativa para la selección y presentación de la solución predictiva final.

Fuente: Elaboración propia.

Tabla 29: Evaluación final comparativa en el conjunto de prueba (test set).

Posición	Modelo	RMSE (días)	MAE (días)	R^2	MAPE	MedAE (días)
1	J01_StackingEnsemble (Stacking)	7.455	4.90	0.8061	0.621	3.27
2	F01_AdaBoost (optimizado)	7.688	5.29	0.7938	0.710	3.50
3	J02_VotingEnsemble (Voting)	9.589	7.19	0.6792	0.834	5.36
4	A01_LinearRegression	10.744	8.26	0.5973	0.925	6.26
5	A08_ARDRegression	10.751	8.26	0.5967	0.923	6.27
6	A03_Lasso	10.786	8.28	0.5941	0.940	6.32
7	A06_LassoLars	10.786	8.28	0.5941	0.940	6.32

Fuente: elaboración propia a partir de final_evaluation(). Modelos ordenados de mayor a menor R^2 en el conjunto de prueba.

El StackingRegressor (J01_StackingEnsemble) se confirmó como el modelo final del desarrollo, al obtener el mejor desempeño en las cinco métricas evaluadas sobre el conjunto de prueba: RMSE = 7.455 días, MAE = 4.90 días, R^2 = 0.8061, MAPE = 62.1 % y MedAE = 3.27 días. En términos prácticos, esto significa que, en promedio, la predicción del modelo se desvía en poco menos de 5 días de la duración real planificada de una partida, y que la mitad de las predicciones presenta un error absoluto inferior a 3.3 días. Cabe destacar que el desempeño del modelo de Stacking sobre el conjunto de prueba (R^2 = 0,8061) resultó incluso superior al observado durante la validación cruzada sobre el conjunto de entrenamiento para los modelos base individuales ($R^2 \approx 0.39 – 0.42$), lo que confirma el valor añadido de la estrategia de combinación de modelos frente al uso de un único algoritmo.

Para complementar la evaluación final del modelo, se implementó la función plot_predictions_vs_actual() con el propósito de comparar visualmente las duraciones reales con las duraciones estimadas por el modelo. El análisis permite determinar qué tan próximas se encuentran las predicciones respecto de los valores observados y, adicionalmente, examinar la distribución de los errores de predicción.

Código de comprobación visual.

```
def plot_predictions_vs_actual(y_true, y_pred, title=''):
    """Scatter plot de predicciones vs valores reales con línea de
identidad."""
    fig, axes = plt.subplots(1, 2, figsize=(16, 6))

    axes[0].scatter(y_true, y_pred, alpha=0.3, s=15, color='steelblue')
    lim_max = max(y_true.max(), y_pred.max()) * 1.05
    axes[0].plot([0, lim_max], [0, lim_max], 'r--', linewidth=2,
label='Identidad (y=x)')
    axes[0].set_xlabel('Valor Real (días)', fontsize=11)
    axes[0].set_ylabel('Predicción (días)', fontsize=11)
    axes[0].set_title(f'Predicciones vs Valores Reales — {title}',
fontweight='bold')
    axes[0].legend()
    axes[0].set_xlim(0, lim_max)
    axes[0].set_ylim(0, lim_max)
    axes[0].set_aspect('equal')

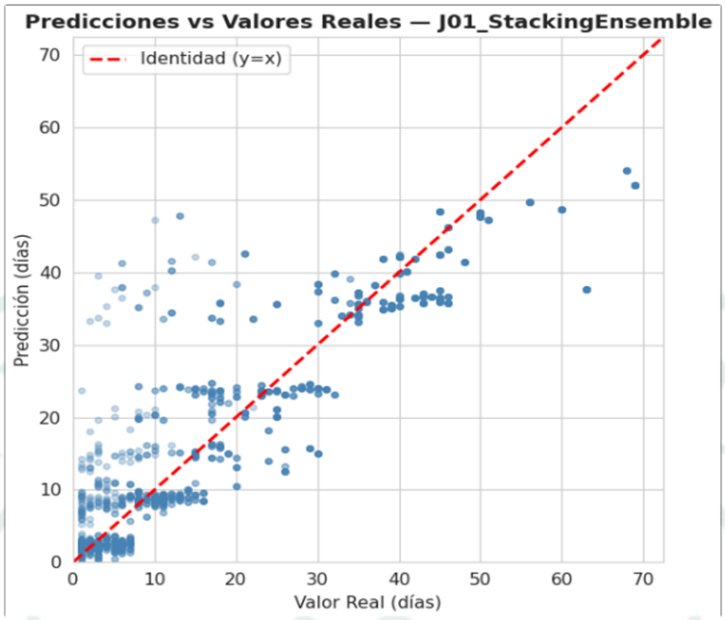
    errors = y_true - y_pred
    axes[1].hist(errors, bins=50, color='steelblue', edgecolor='white',
alpha=0.8, density=True)
    mu, sigma = errors.mean(), errors.std()
    x = np.linspace(errors.min(), errors.max(), 100)
    axes[1].plot(x, stats.norm.pdf(x, mu, sigma), 'r-', linewidth=2)
    axes[1].axvline(0, color='black', linestyle='--', alpha=0.5)
    axes[1].set_title('Distribución de Errores', fontweight='bold')
    axes[1].set_xlabel('Error (días)')

    plt.tight_layout()
    plt.show()
```

Nota: La función plot_predictions_vs_actual() permite evaluar visualmente la correspondencia entre las duraciones reales y las predicciones generadas por el modelo mediante un diagrama de dispersión y una línea de identidad. Asimismo, representa la distribución de los errores de predicción para identificar su concentración alrededor de cero y posibles tendencias de sobreestimación o subestimación. Este análisis complementa las métricas de evaluación final y permite valorar gráficamente la capacidad del modelo para reproducir las duraciones observadas en las partidas de obra.

Fuente: Elaboración propia.

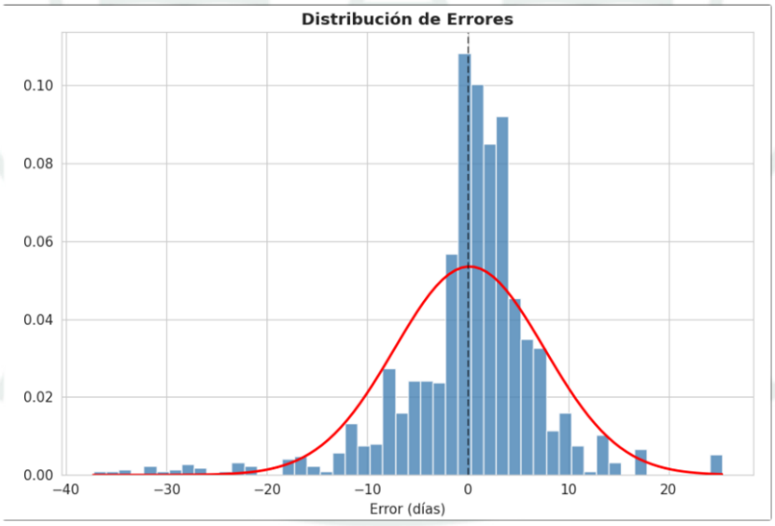
Figura 48: Grafico de Predicciones vs Valores Reales - J01_stackingEnsemble.



Nota: Se observar la relación y=x; mantienen una dispersión relativamente reducida.

Fuente: elaboración propia a partir de la funcio plot_predictions_vs_actual().

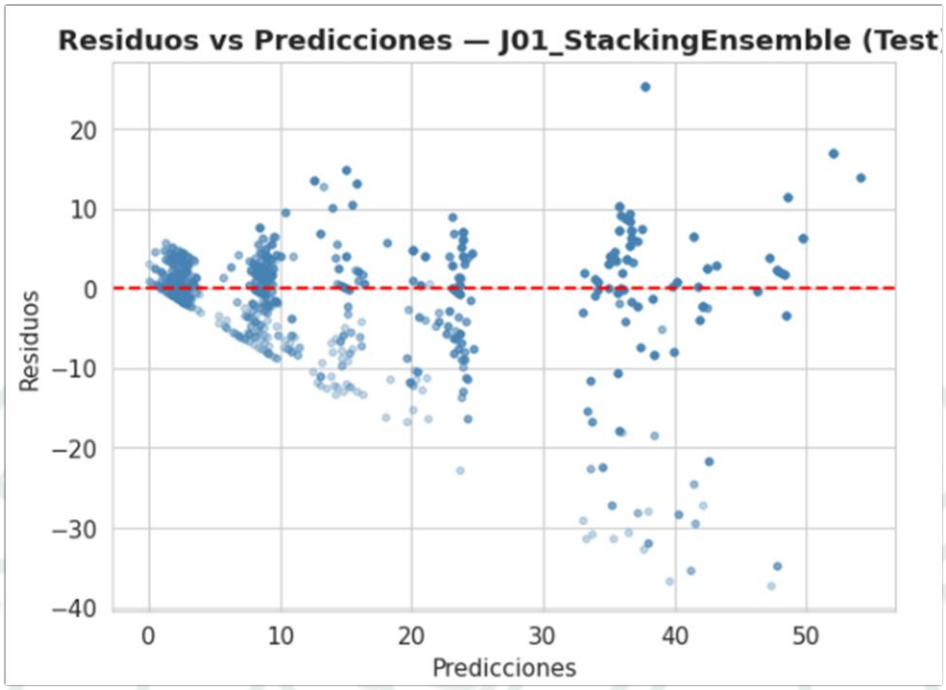
Figura 49: Distribución de errores - J01_stackingEnsemble.



Nota: La distribución centrada aproximadamente alrededor de cero indica que no existe un sesgo global importante.

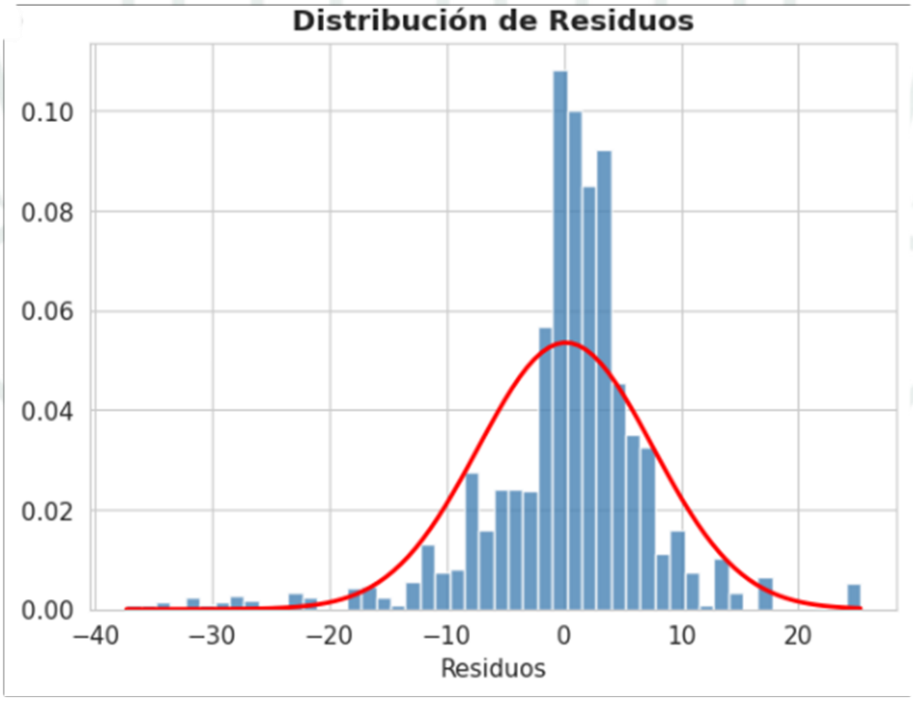
Fuente: elaboración propia a partir de la funcio plot_predictions_vs_actual().

Figura 50: Residuos vs predicciones J01_stackingEnsemble.



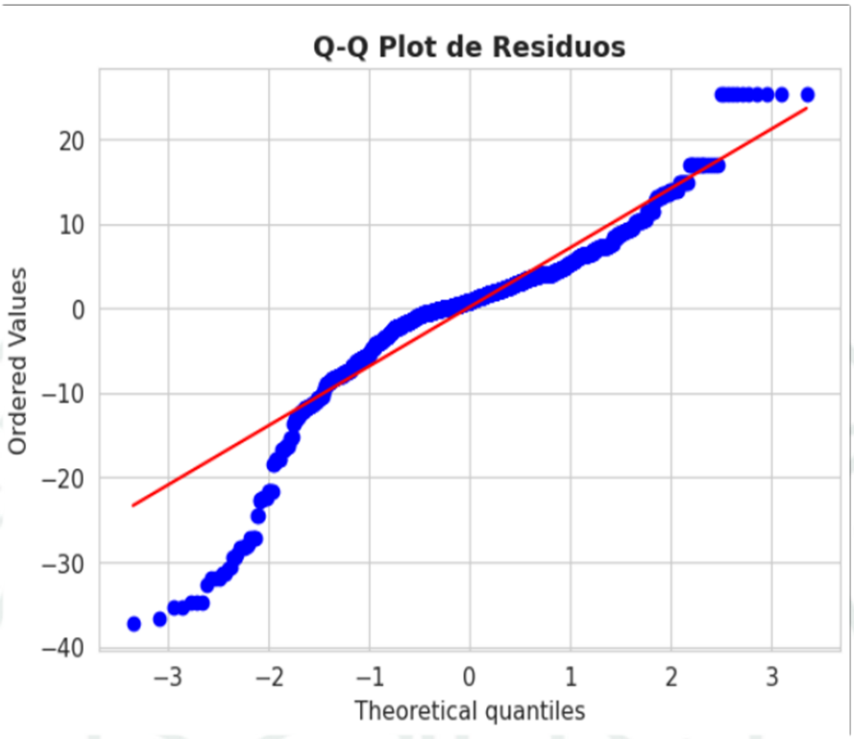
Fuente: Elaboración propia a partir de la función analyze_residuals().

Figura 51: Distribución de residuos J01_stackingEnsemble



Fuente: Elaboración propia a partir de la función analyze_residuals().

Figura 52: Q-Q J01_stackingEnsemble



Fuente: Elaboración propia a partir de la función analyze_residuals().

4.9.1. Intervalo de confianza del error mediante bootstrap

Para fortalecer la evaluación estadística del modelo predictivo, se implementó la función bootstrap_confidence_interval(), cuyo objetivo es estimar un intervalo de confianza para la métrica RMSE mediante la técnica de bootstrap.

A fin de cuantificar la incertidumbre asociada a la estimación puntual del RMSE del modelo final, se aplicó un procedimiento de remuestreo bootstrap con reemplazo sobre las predicciones del conjunto de prueba (1000 iteraciones), calculando en cada iteración el RMSE sobre la muestra remuestreada y construyendo el intervalo de confianza empírico al 95 % a partir de los percentiles.

Código para estimar un intervalo de confianza en el modelo.

```
def bootstrap_confidence_interval(y_true, y_pred, n_boot=1000, ci=95):
    """Calcula intervalo de confianza del RMSE por bootstrap."""
    rmse_scores = []
    n = len(y_true)
    for _ in range(n_boot):
        idx = np.random.randint(0, n, size=n)
        rmse_b = np.sqrt(mean_squared_error(y_true[idx], y_pred[idx]))
        rmse_scores.append(rmse_b)
    lower = np.percentile(rmse_scores, (100 - ci) / 2)
    upper = np.percentile(rmse_scores, 100 - (100 - ci) / 2)
    mean_rmse = np.mean(rmse_scores)

    print(f"\nIntervalo de Confianza del RMSE ({ci}%):")
    print(f"  RMSE medio:     {mean_rmse:.4f}")
    print(f"  IC {ci}%:        [{lower:.4f}, {upper:.4f}]")

    fig, ax = plt.subplots(figsize=(10, 4))
    ax.hist(rmse_scores, bins=50, color='steelblue', edgecolor='white',
alpha=0.8)
    ax.axvline(lower, color='red', linestyle='--', label=f'IC {ci}%
inferior: {lower:.4f}')
    ax.axvline(upper, color='red', linestyle='--', label=f'IC {ci}%
superior: {upper:.4f}')
    ax.axvline(mean_rmse, color='black', linestyle='-', label=f'Media:
{mean_rmse:.4f}')
    ax.set_title(f'Bootstrap Distribution — RMSE (n={n_boot})',
fontweight='bold')
    ax.set_xlabel('RMSE')
    ax.legend()
    plt.tight_layout()
    plt.show()

    return lower, upper, mean_rmse
```

Nota: La función bootstrap_confidence_interval() estima la incertidumbre asociada al RMSE mediante 1000 remuestreos aleatorios con reemplazo del conjunto de evaluación. A partir de la distribución obtenida se calcula un intervalo de confianza del 95 % mediante los percentiles 2.5 y 97.5. Este procedimiento permite complementar la evaluación puntual del modelo mediante una estimación de la variabilidad del RMSE, proporcionando evidencia adicional sobre la estabilidad del desempeño predictivo.

Fuente: Elaboración propia.

Tabla 30: Intervalo de confianza bootstrap del RMSE (modelo final, 95 %)

Estadístico	Valor (días)
RMSE medio (bootstrap)	7.4587
Límite inferior IC 95 %	6.9809
Límite superior IC 95 %	7.9216
N.º de remuestreos (bootstrap)	1000

Fuente: elaboración propia a partir de bootstrap_confidence_interval() (n = 1 000 remuestreos).

4.9.2. Evaluación del error por rangos de duración

Como parte de la evaluación final del modelo predictivo, se realizó un análisis del desempeño según rangos de duración de las partidas. El objetivo es determinar si el modelo mantiene un comportamiento consistente para actividades de corta, media y larga duración, debido a que un modelo puede presentar un buen desempeño global y, al mismo tiempo, cometer errores mayores en determinados rangos de duración.

Codigo por evaluacion de rangos.

```
print("\nEvaluación por rangos de duración")
print("=" * 70)

bins = [0, 2, 5, 10, 20, 50, np.inf]
labels = ['0-2', '3-5', '6-10', '11-20', '21-50', '50+']

y_test_bins = pd.cut(y_test, bins=bins, labels=labels)
range_results = []
for label in labels:
    mask = y_test_bins == label
    if mask.sum() > 0:
        rmse_r = np.sqrt(mean_squared_error(y_test[mask],
y_pred_final[mask]))
        mae_r = mean_absolute_error(y_test[mask], y_pred_final[mask])
        r2_r = r2_score(y_test[mask], y_pred_final[mask]) if mask.sum() > 1
else np.nan
        range_results.append({
            'Rango (días)': label,
            'N': mask.sum(),
            'RMSE': rmse_r,
            'MAE': mae_r,
```

```
            'R²': r2_r,
        })
range_df = pd.DataFrame(range_results)
display(range_df)
fig, ax = plt.subplots(figsize=(10, 5))
x_pos = range(len(range_df))
ax.bar(x_pos, range_df['RMSE'], color='steelblue', edgecolor='white',
alpha=0.8)
ax.set_xticks(x_pos)
ax.set_xticklabels(range_df['Rango (días)'])
ax.set_xlabel('Rango de duración (días)')
ax.set_ylabel('RMSE')
ax.set_title('RMSE por Rango de Duración', fontweight='bold')
for i, v in enumerate(range_df['RMSE']):
    ax.text(i, v + 0.1, f'{v:.2f}', ha='center', fontsize=9)
plt.tight_layout()
plt.show()
```

Nota: La evaluación por rangos de duración permite analizar el desempeño del modelo en seis intervalos de DURACION_TOTAL_DIAS: 0–2, 3–5, 6–10, 11–20, 21–50 y más de 50 días. Para cada grupo se calcularon RMSE, MAE y R^2, considerando además el número de observaciones. El análisis permite identificar diferencias en la precisión predictiva según la duración de las partidas y determinar los rangos en los que el modelo presenta mayores o menores errores. El RMSE por rango se representa gráficamente para facilitar la comparación del desempeño entre los diferentes intervalos.

Fuente: Elaboración propia.

Tabla 31: Desempeño del modelo final por rango de duración de la partida

Rango (días)	N.º de casos	RMSE (días)	MAE (días)	R^2
0-2	180	5.291123	3.053914	-111.875804
3-5	203	6.641727	3.738399	-65.18004
6-10	264	8.303296	4.775873	-31.082604
11-20	327	8.800632	6.174293	-8.418574
21-50	653	5.784356	4.340228	0.536811
50+	63	15.205465	13.506071	-5.101525

Fuente: elaboración propia a partir de la evaluación por rangos sobre el conjunto de prueba (n = 1690).

La tabla revela una limitación relevante del modelo: si bien el R^2 global sobre el conjunto de prueba es alto (0.8061), este resultado está fuertemente influenciado por el rango de duraciones más numeroso (21 -50 días, con 653 casos y $R^2 = 0.536$), mientras que en los rangos de menor duración (0 - 2, 3 - 5, 6 - 10 y 11 - 20 días) el R^2 resulta negativo, lo que indica que, dentro de esos subgrupos específicos, el modelo se comporta peor que una predicción constante igual a la media del subgrupo. No obstante, es importante señalar que el R^2 pierde interpretabilidad como métrica de bondad de ajuste cuando se calcula sobre subgrupos con rango de valores estrecho condición que se cumple en los rangos de corta duración, dado que su cálculo depende de la varianza del subgrupo en el denominador. En términos de error absoluto en la escala original (días), el modelo mantiene un desempeño más estable, con un MAE que oscila entre 3.26 y 6.15 días en los primeros cuatro rangos, y se deteriora de forma más marcada en el rango de partidas de mayor duración (> 50 días: MAE = 14.17 días), donde el reducido número de casos disponibles (63 partidas) limita la capacidad del modelo para aprender el patrón asociado a proyectos de gran magnitud.

4.10. Síntesis del Desarrollo Experimental

El desarrollo experimental realizado en este capítulo permitió construir, de manera sistemática y reproducible, un modelo de Machine Learning orientado a la predicción de la duración de partidas en obras civiles, siguiendo las etapas establecidas en la metodología de ciencia de datos de extremo a extremo. A partir de un conjunto de 8539 registros correspondientes a 10 obras, se desarrolló un proceso de ingeniería de características que permitió ampliar el conjunto inicial de 16 a 26 variables. De estas, se seleccionaron finalmente 15 variables predictoras, excluyendo deliberadamente aquellas características que presentaban riesgo de fuga de información temporal, debido a que contenían información generada durante o después de la ejecución de las partidas.

El incremento observado entre el R^2 obtenido durante la validación cruzada mediante GroupKFold (0.39 - 0.42) y el R^2 obtenido por el modelo final (0.8061) se explica, en primer lugar, porque ambos valores corresponden a etapas y condiciones de evaluación diferentes. El R^2 obtenido mediante GroupKFold corresponde al desempeño de los modelos durante la etapa de comparación y selección, en la cual cada iteración mantiene separadas las obras utilizadas para entrenamiento y validación. Por tanto, constituye una evaluación exigente de la capacidad del modelo para generalizar hacia obras no utilizadas durante el entrenamiento.

Posteriormente, a partir de los resultados del GroupKFold se seleccionaron los cinco modelos con mejor comportamiento, los cuales fueron sometidos a un análisis de residuos y posteriormente a procesos de ajuste y combinación mediante técnicas de Stacking y Voting. Por consiguiente, el modelo que finalmente alcanzó un R^2 de 0.8061 no corresponde necesariamente al mismo modelo ni a las mismas condiciones de evaluación de los modelos individuales inicialmente evaluados mediante GroupKFold. El incremento puede estar asociado a la mejora producida por la selección de modelos, el ajuste posterior y la combinación de predictores.

Sin embargo, para evitar que este proceso genere una estimación optimista del desempeño, se mantuvo desde el inicio un 20 % de los datos completamente separado del proceso de desarrollo. Este conjunto no intervino en la validación GroupKFold, selección del Top 5, análisis de residuos, ajuste de los modelos ni construcción de los ensambles. Su utilización se realizó únicamente después de finalizar el proceso de selección, constituyéndose como un conjunto de evaluación independiente.

Esta separación es importante debido a que el desempeño de un modelo puede sobreestimarse cuando los mismos datos son utilizados repetidamente para seleccionar, ajustar y evaluar modelos. Amer y Golparvar-Fard (2021) señalan que la selección de modelos puede producir

sesgo en la evaluación cuando el conjunto utilizado para seleccionar el modelo también se utiliza para estimar su desempeño final. Por ello, reservar previamente un conjunto independiente permite obtener una estimación más objetiva de la capacidad de generalización.

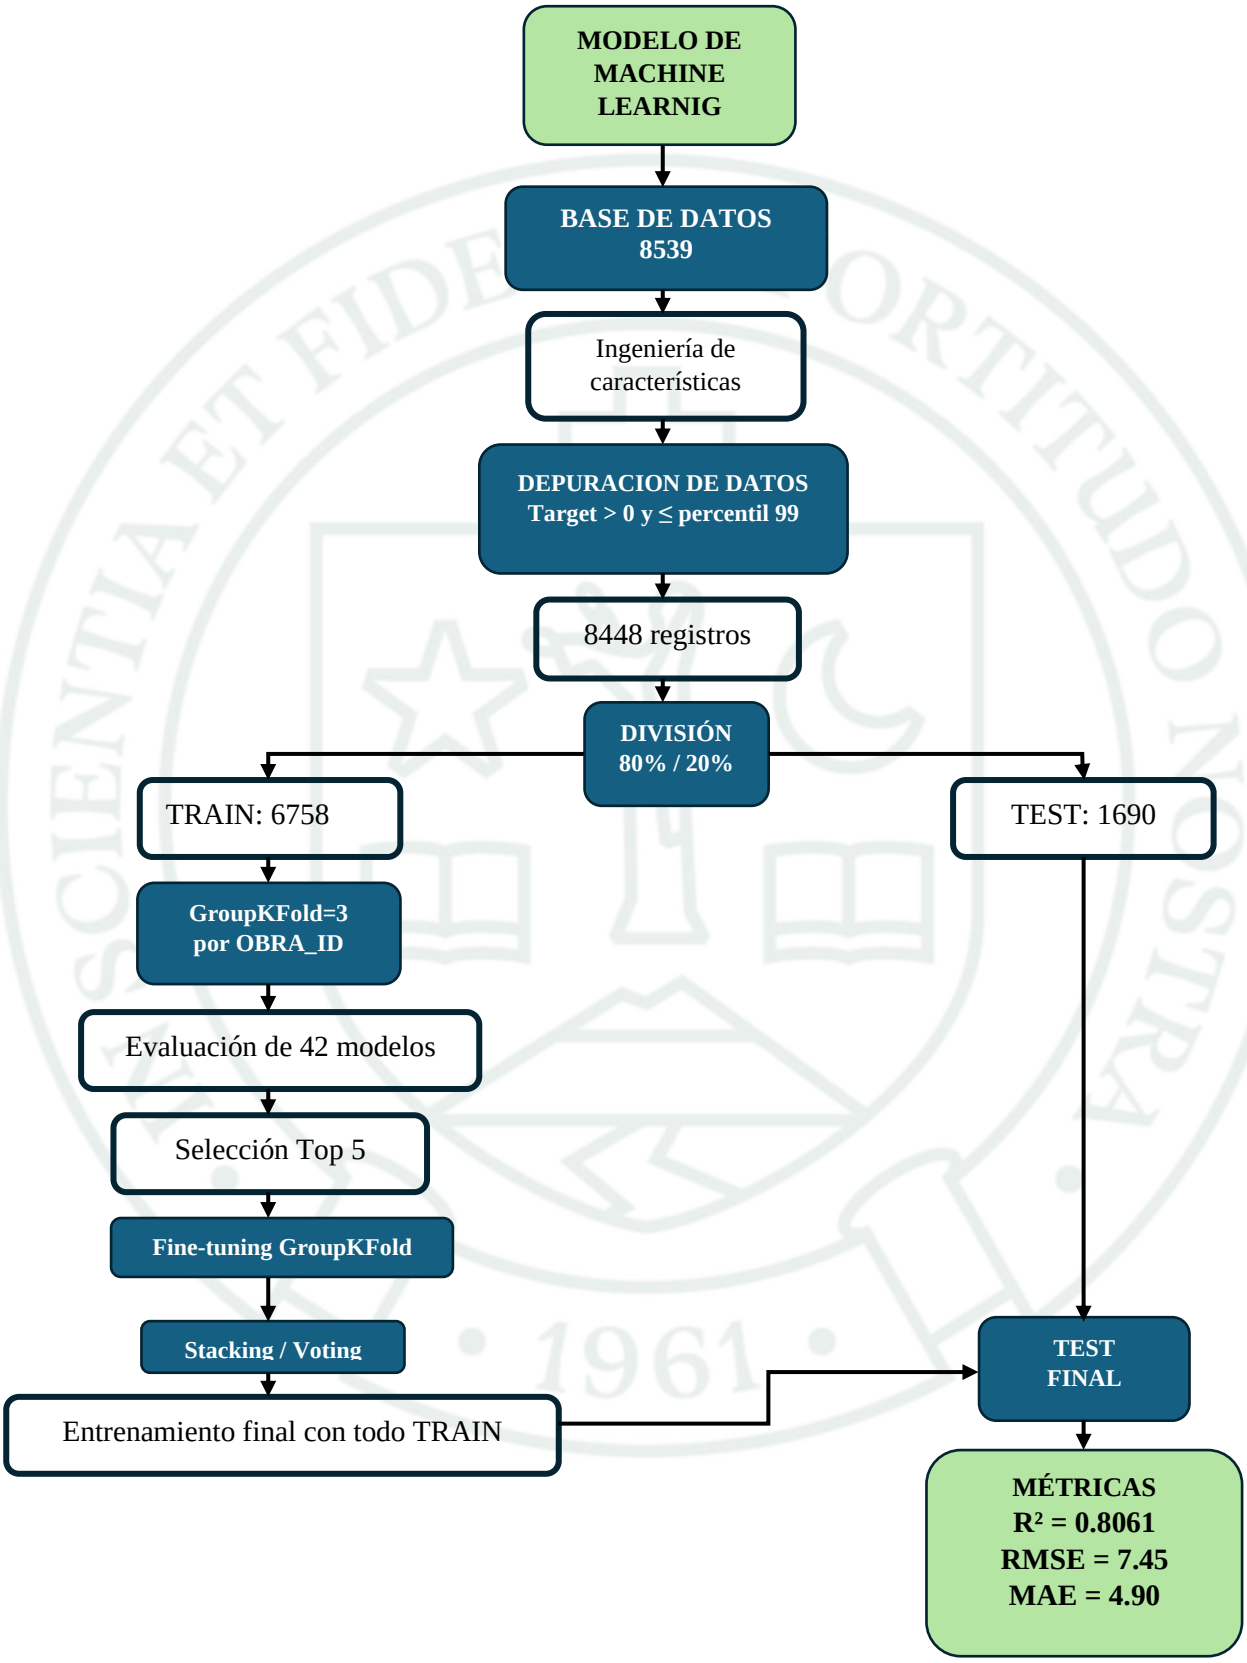
En consecuencia, el R^2 de 0.8061 no debe interpretarse como una continuación directa del R^2 de 0.39 - 0.42, sino como el resultado de una etapa posterior en la que se evaluó el modelo final después de un proceso de selección y mejora, utilizando un conjunto de datos que permaneció fuera de dicho proceso. La diferencia observada fue, por tanto, investigada considerando la metodología de particionamiento y selección empleada, y no se atribuye únicamente a una supuesta mejora automática del algoritmo.

Tabla 32: Controles de fuga en el procesamiento de datos.

Etapa	Qué se hizo	Estado	Observación
Imputación, escalado y codificación	Integrados en el Pipeline / ColumnTransformer y ajustados con los datos de entrenamiento.	Controlado	Sin observación.
Cálculo de frecuencias	DESC_FREQ, CODE_FREQ y TIPO_FREQ se calculan en create_features() sobre las 8539 registros.	Riesgo	Se calculan antes de la partición, por lo que incorporan información del conjunto de prueba.
Recorte del percentil 99 de la variable objetivo	Se recortó la cola superior de DURACION_TOTAL_DIAS (8539 → 8448 registros.	Riesgo	Se aplicó antes de la partición, también al conjunto de prueba: la evaluación excluye las duraciones más largas.
Partición entrenamiento / prueba	train_test_split aleatorio estratificado por OBRA_ID.	Riesgo	Partidas y obras aparecen en entrenamiento y prueba (ver observaciones sobre el R^2 y la unidad de análisis).
Stacking	cv = 3 interno, sin agrupar por obra.	Riesgo	El metamodelo se entrena con predicciones de partidas de las mismas obras.
Homologación de códigos de partida	Realizada sobre todas las obras por equivalencia técnica.	Bajo	No utiliza la variable objetivo.
Validación cruzada	GroupKFold agrupado por OBRA_ID.	Controlado	Evalúa el desempeño sobre obras no vistas.

Fuente: Elaboración propia (data leakage)

Figura 53: Diagrama de flujo del modelo de machine learning.



CAPITULO V:

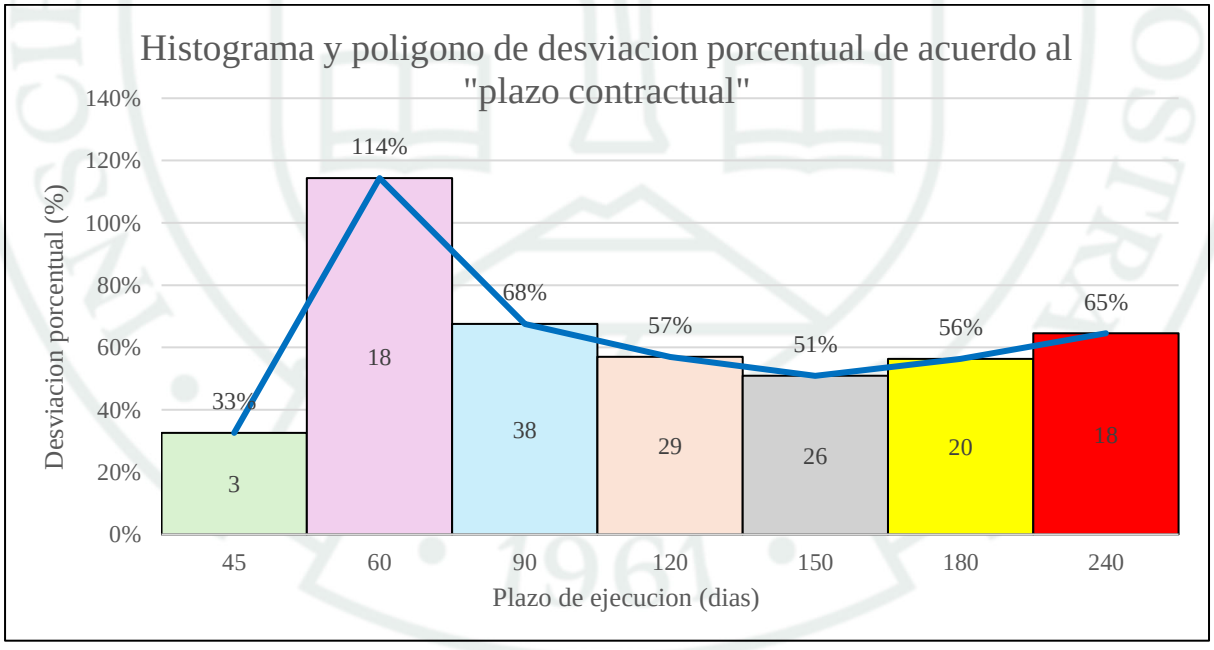
RESULTADOS

5. Resultados

5.1. Comportamiento de obras de infraestructura vial en Arequipa 2022-2025

Para realizar un análisis más exhaustivo de los factores y variables asociadas que afectan la programación de obras de infraestructura vial, el estudio no se limitó solo a las 10 obras utilizadas para el modelo predictivo. Por eso se recurrió al censo poblacional previamente definido que son 152 obras, se analizó el desvío entre el plazo contractual (planificado) y el plazo de ejecución real, permitiendo caracterizar el comportamiento de las desviaciones de duración en las obras de infraestructura vial.

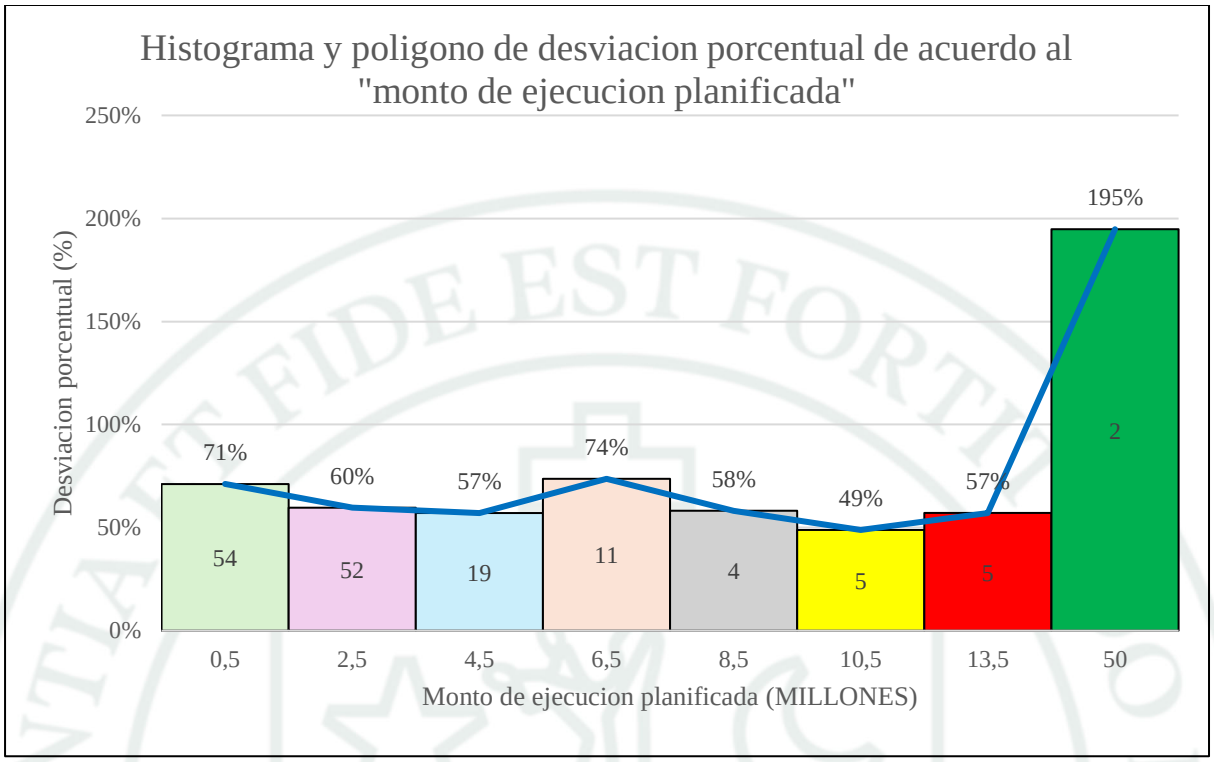
Figura 54: Histograma y polígono de desviación y plazo contractual.



Nota: El histograma muestra la distribución del desvío porcentual entre el plazo contractual y el plazo de ejecución real, permitiendo identificar el comportamiento de las desviaciones respecto al tiempo planificado dentro de cada barra se encuentra la cantidad de obras.

Fuente: Elaboración Propia

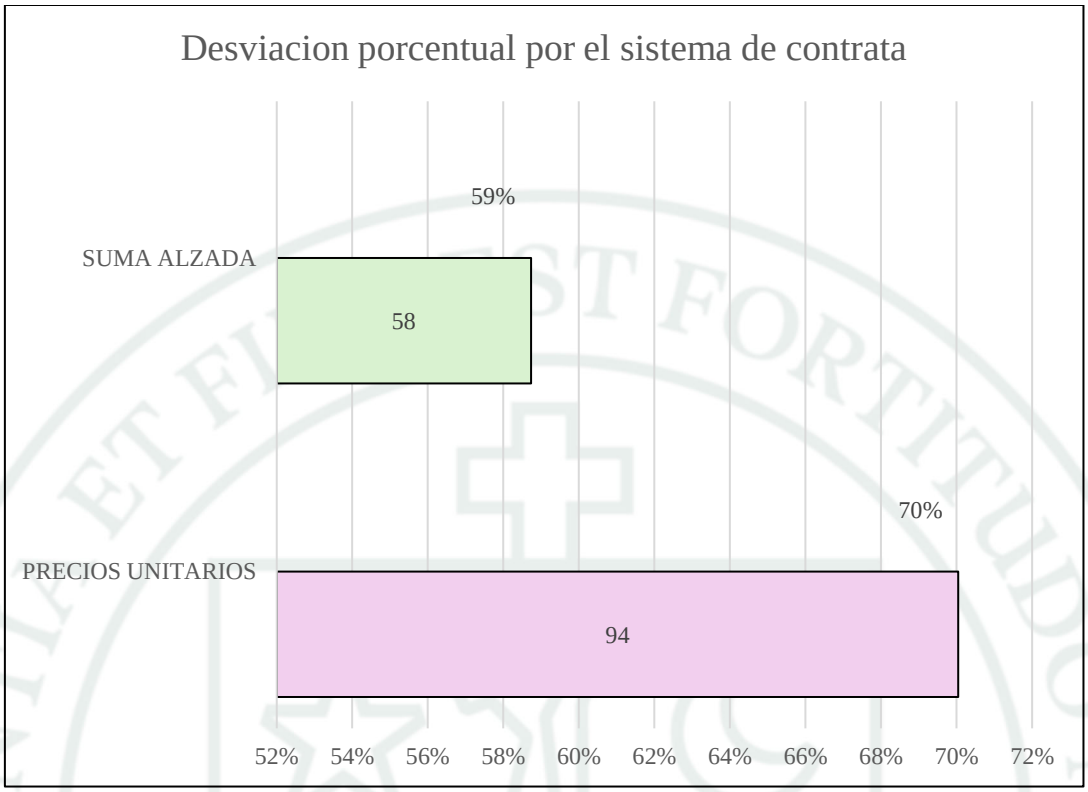
Figura 55: Histograma de desviación porcentual y monto de ejecución planificada.



Nota: El histograma muestra la distribución de la desviación del tiempo de ejecución tomando como referencia el tiempo de planificación, representado en este caso mediante el monto contractual de la obra igual que el anterior grafico en cada barra se mustra la cantidad de obras.

Fuente: Elaboración propia.

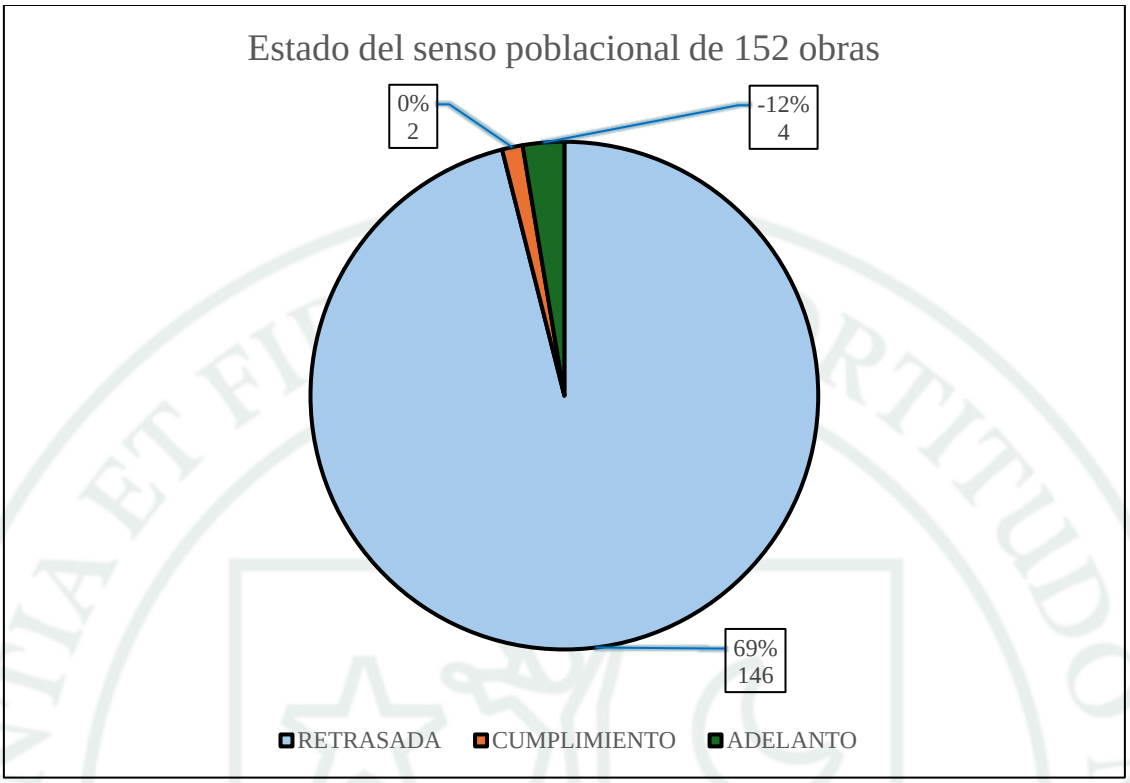
Figura 56: Desviación porcentual por el sistema de contrata.



Nota: En esta gráfica de barras se muestra el promedio de la desviación del tiempo de ejecución según el sistema de contratación, en cada barra se muestra la cantidad de obras.

Fuente: Elaboración propia.

Figura 57: Estado del censo poblacional y desvió porcentual.



Nota: En esta gráfica se observa que de 152 obras del censo poblacional la mayoría de las obras del censo poblacional presentaron un retraso superior al 50 % respecto al plazo contractual de ejecución.

Fuente: Elaboración propia.

De las gráficas presentadas, se observa que las obras viales de Arequipa, correspondientes al periodo 2022–2025, presentan desviaciones superiores al 50 % respecto al plazo contractual. Este comportamiento se evidencia al analizar la desviación en función del tiempo de ejecución planificado, el monto contractual de planificación y el sistema de contratación.

Esta desviación porcentual se debe principalmente a los retrasos presentados durante la ejecución de las obras, los cuales, de acuerdo con la bibliografía revisada, se clasifican en tres grupos principales:

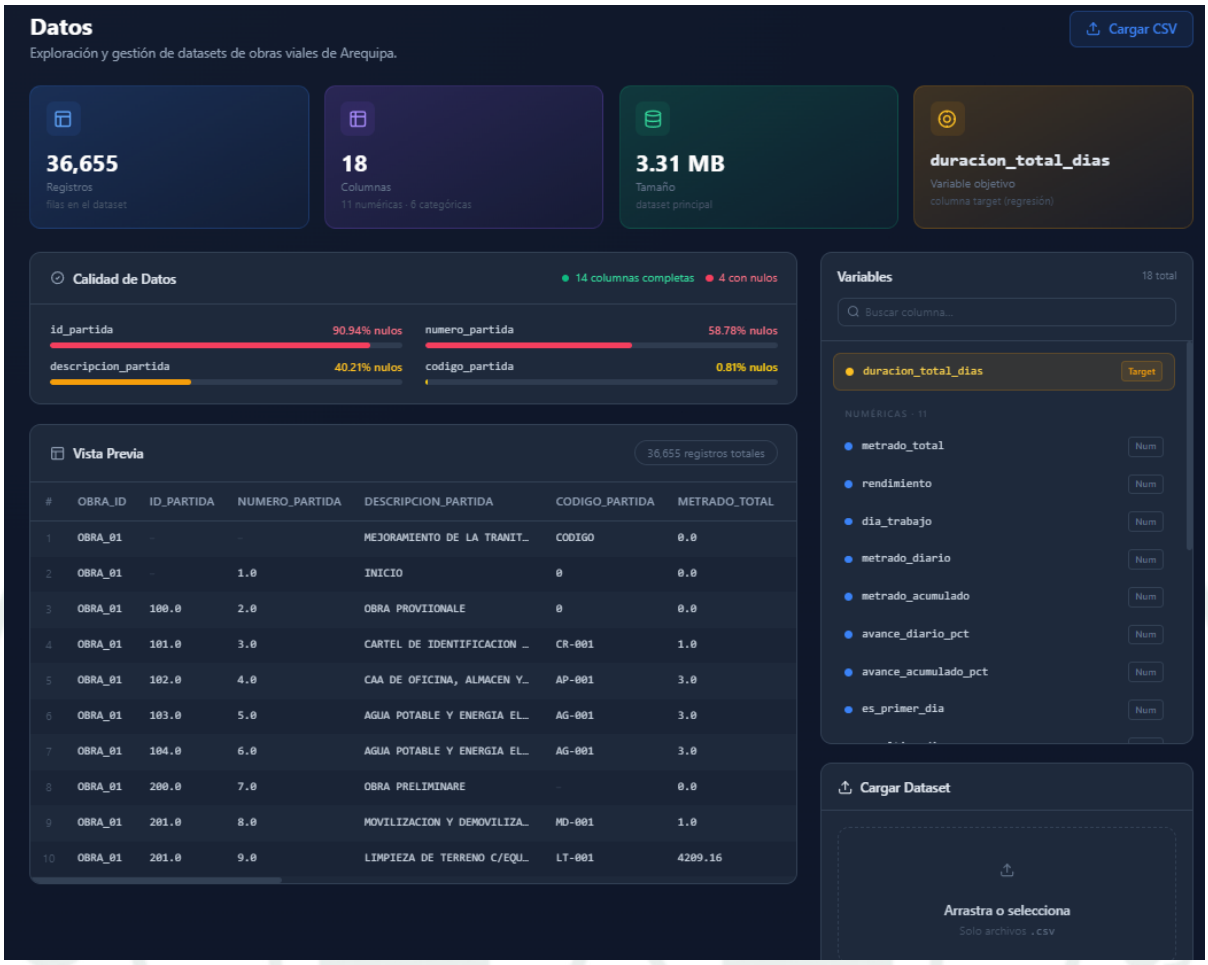
- ✓ Retrasos asociados a la gestión de riesgos (Amer & Golparvar-Fard, 2021).

- ✓ Retrasos asociados a problemas contractuales (Hriday & Rehman, 2025).
- ✓ Retrasos asociados a problemas de calidad (Lotfi et al., 2025).

5.2. Modelo de interfaz web

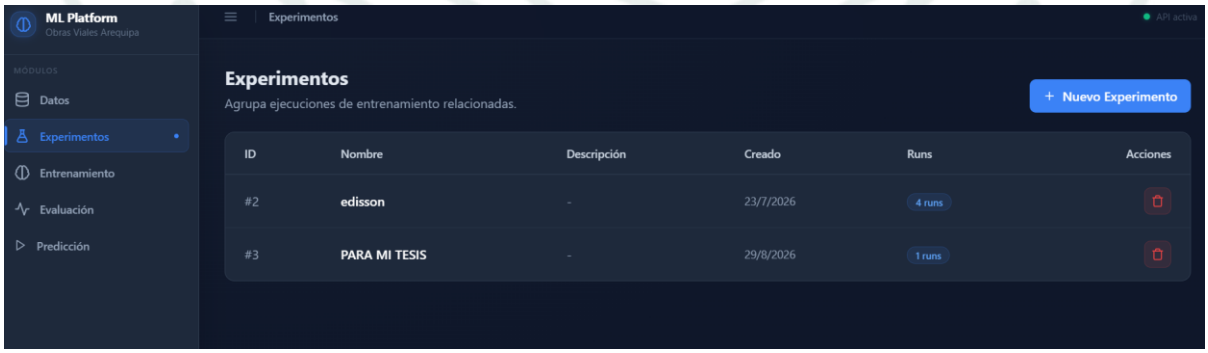
El modelo funcional de la interfaz web fue complementado con una interfaz amigable para facilitar su utilización. Asimismo, se incorporaron herramientas adicionales para mejorar el análisis, como el historial de resultados, que permite almacenar y revisar posteriormente las predicciones realizadas.

Figura 58: Interfaz de entrada de la WEB



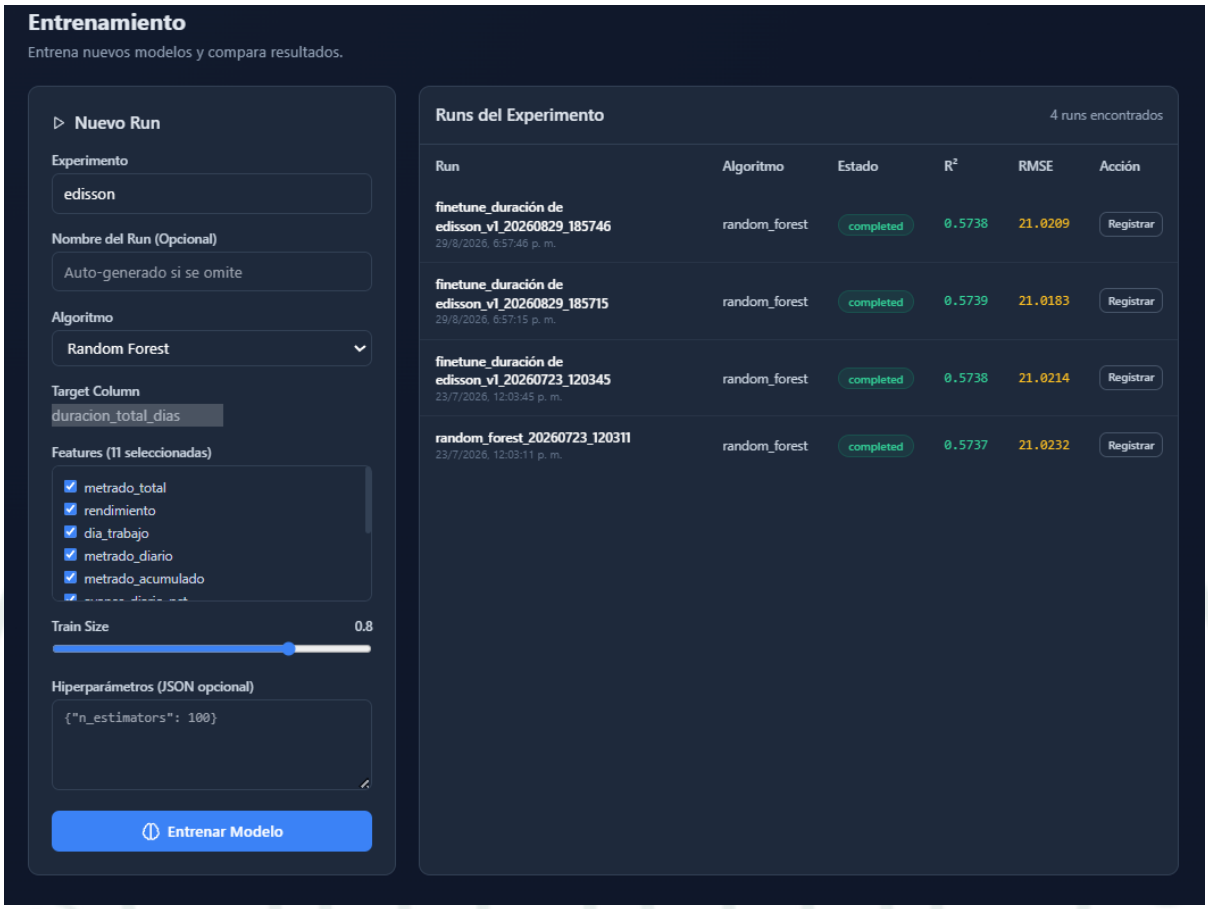
Nota. Fuente Propia, Resultado de Programa.

Figura 59: Interfaz de entrenamiento de datos.



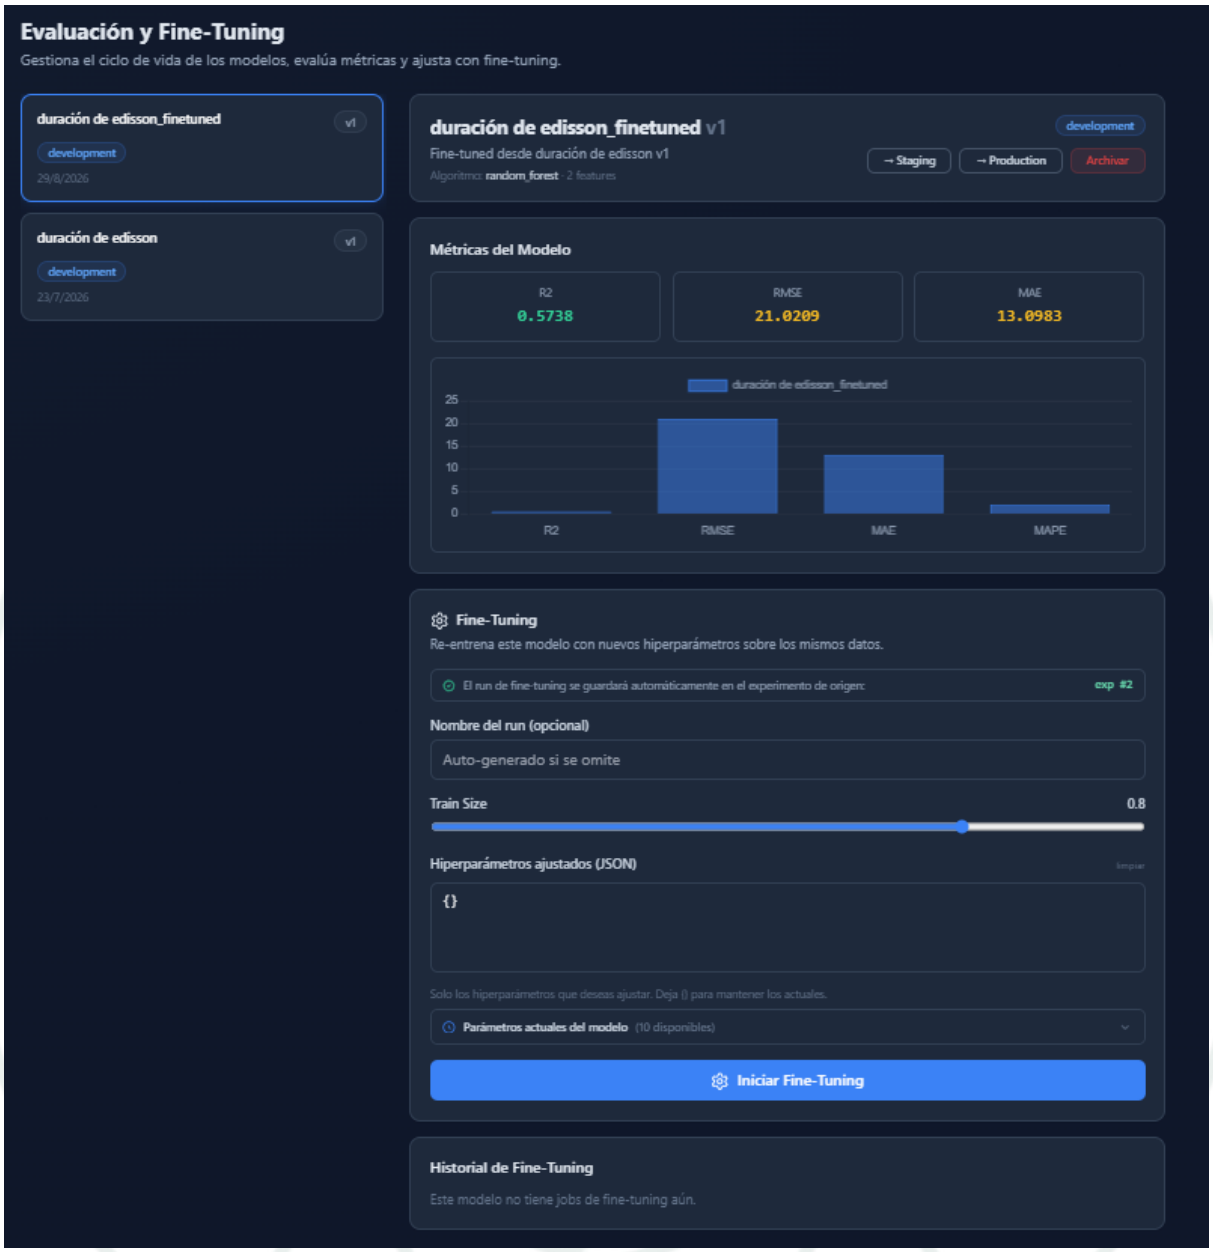
Nota. Fuente Propia, Resultado de Programa.

Figura 60: Interfaz de elección modelo y tamaño de datos.



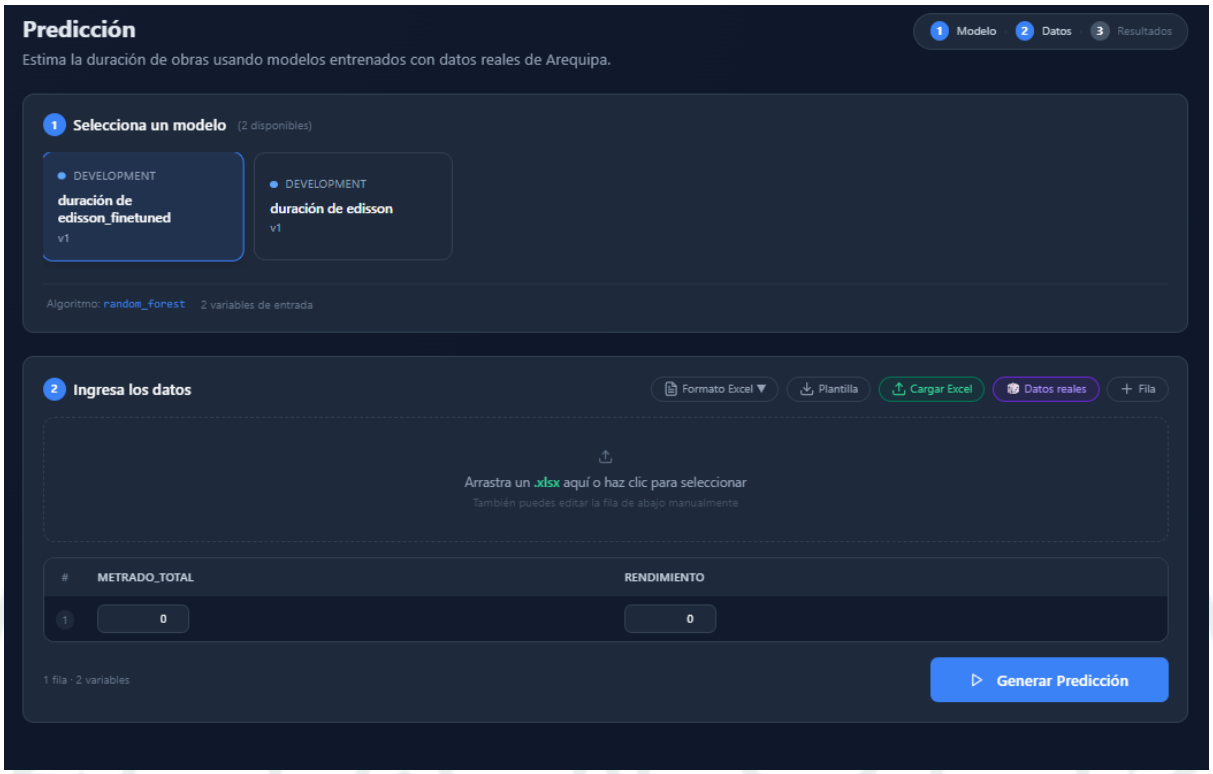
Nota. Fuente Propia, Resultado de Programa.

Figura 61: Interfaz de ingeniería de caracterización.



Nota. Fuente Propia, Resultado de Programa.

Figura 62: Interfaz para predecir.



Nota. Fuente Propia, Resultado de Programa.

5.3. Caso de estudio

Si bien el modelo predictivo basado en Machine Learning cuenta con métricas propias para evaluar su desempeño, resulta necesario validar su capacidad predictiva mediante obras ejecutadas y culminadas, que dispongan de información suficiente para contrastar las duraciones reales con las estimaciones generadas por el modelo.

Tabla 33: Obras escogidas para el análisis.

Código INFOBRAS	Código Único de Inversión	Código SNIP	Nombre de la obra
169730	2164317	228773	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES EN LOS AA.HH. UNION COSTANERA, EL PALMO, PROGRESO EL VALLE Y EL FRISCO, DISTRITO DE DEAN VALDIVIA - ISLAY - AREQUIPA
169592	2248353	308062	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS VIAS: VIA DE INGRESO Y AV. N 2 DE LA ASOCIACIÓN DE VIVIENDAS SAN LÁZARO, CALLE N 4 DE LA ASOCIACIÓN DE VIVIENDA BALCONES DE CHILINA, AV. N 1 DEL AGRUPAMIENTO DE FAMILIAS VILLA CONFRATERNIDAD, AV. N 1 DEL A.H. ASOCIACIÓN DE VIVIENDA VILLA ECOLÓGICA, DISTRITO DE ALTO SELVA ALEGRE - AREQUIPA - AREQUIPA
500532	2286405	328367	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ASOCIACIÓN DE VIVIENDA FRANCISCO GARCÍA CALDERÓN, DISTRITO DE CERRO COLORADO - AREQUIPA - AREQUIPA. II ETAPA CUI 2286405

Fuente: elaboración Propia.

Para el caso de estudio se seleccionaron obras de infraestructura vial con características y tipología similares a las obras utilizadas en el entrenamiento del modelo predictivo. Esta selección permitió aplicar el modelo en obras con condiciones comparables y contrastar la duración predicha con la duración planificada y la duración real de ejecución.

Tipología de las obras

Las obras seleccionadas corresponden a la tipología de mejoramiento de la transitabilidad vehicular y peatonal, orientadas a mejorar las condiciones de circulación y funcionalidad de la infraestructura vial urbana. Las intervenciones comprenden componentes relacionados con la calzada, pavimentación, veredas y otros elementos complementarios de la infraestructura vial y peatonal, de acuerdo con las características de cada proyecto.

Tabla 34: Tipología de caso de estudio.

ASPECTO	DESCRIPCIÓN
Tipo de obra	Infraestructura vial urbana
Tipología	Mejoramiento de la transitabilidad vehicular y peatonal
Ámbito	Vías urbanas
Tipo de intervención	Mejoramiento de infraestructura existente
Componentes principales	Calzadas, pavimentos, veredas, drenaje, sardineles, señalización, áreas verdes, muros, etc.
Finalidad	Mejorar las condiciones de circulación vehicular y peatonal

Fuente: Elaboración propia.

Características de las obras:

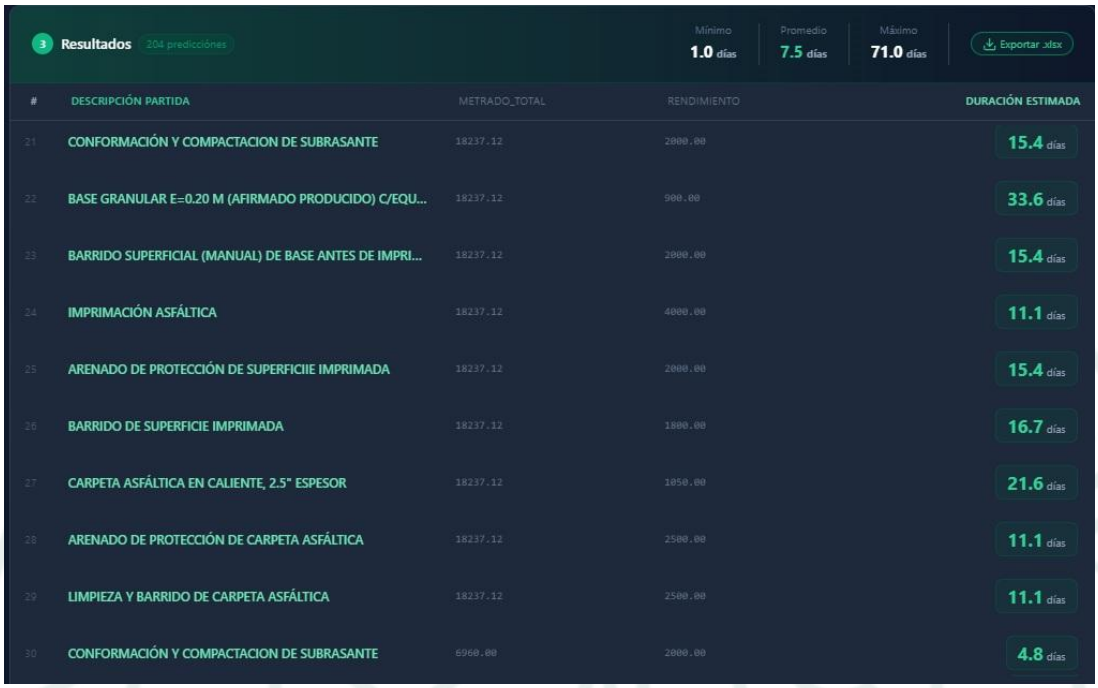
Las obras seleccionadas presentan características comparables con las obras utilizadas para el entrenamiento del modelo, principalmente en cuanto al tipo de intervención, componentes, partidas ejecutadas, metrados, rendimientos, actividades y disponibilidad de información de planificación y ejecución.

5.4. Evaluación del modelo predictivo

Para facilitar el uso del modelo de Machine Learning, se implementó una interfaz web que permite al usuario ingresar los datos requeridos y obtener la predicción de duración. A continuación, se presentan los resultados obtenidos mediante el modelo y su aplicación en la optimización de la programación de obras.

5.4.1. Evaluación de la duración de la obra mediante la ruta crítica

Figura 63: Obra "169730", predicción de la duración de actividades.



3 Resultados 204 predicciones

Mínimo 1.0 días | Promedio 7.5 días | Máximo 71.0 días | Exportar .xlsx

#	DESCRIPCIÓN PARTIDA	METRADO_TOTAL	RENDIMIENTO	DURACIÓN ESTIMADA
21	CONFORMACIÓN Y COMPACTACION DE SUBRASANTE	18237.12	2000.00	15.4 días
22	BASE GRANULAR E=0.20 M (AFIRMADO PRODUCIDO) C/EQU...	18237.12	900.00	33.6 días
23	BARRIDO SUPERFICIAL (MANUAL) DE BASE ANTES DE IMPRI...	18237.12	2000.00	15.4 días
24	IMPRIMACIÓN ASFÁLTICA	18237.12	4000.00	11.1 días
25	ARENADO DE PROTECCIÓN DE SUPERFICIIE IMPRIMADA	18237.12	2000.00	15.4 días
26	BARRIDO DE SUPERFICIE IMPRIMADA	18237.12	1800.00	16.7 días
27	CARPETA ASFÁLTICA EN CALIENTE, 2.5" ESPESOR	18237.12	1050.00	21.6 días
28	ARENADO DE PROTECCIÓN DE CARPETA ASFÁLTICA	18237.12	2500.00	11.1 días
29	LIMPIEZA Y BARRIDO DE CARPETA ASFÁLTICA	18237.12	2500.00	11.1 días
30	CONFORMACIÓN Y COMPACTACION DE SUBRASANTE	6960.00	2000.00	4.8 días

Nota: La predicción de la duración de actividades, en esta imagen solo se muestra una parte de la predicción de la obra “169730”.

Fuente: Elaboración propia, captura de la interfaz WEB.

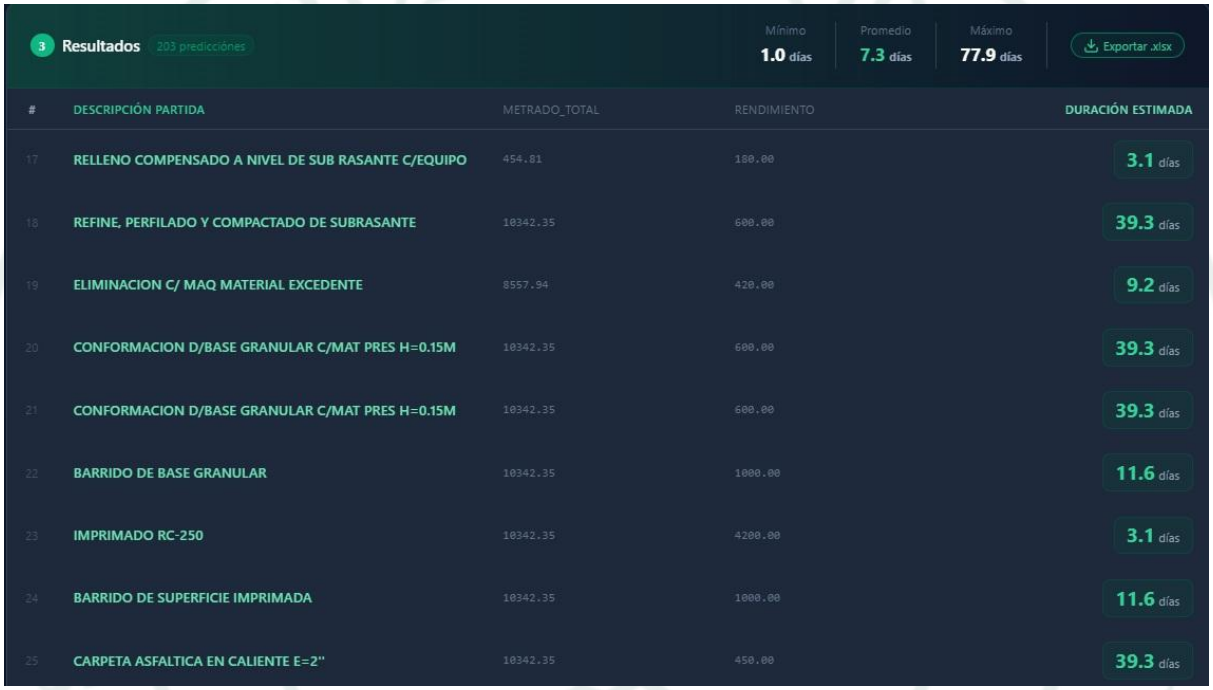
A continuación, se presenta una tabla correspondiente a las actividades críticas que conforman la ruta crítica de la obra. Debido a criterios de presentación, se muestran únicamente las actividades críticas, incluyendo su duración planificada y duración predicha por el modelo, a fin de facilitar la comparación de ambos resultados.

Tabla 35: Tabla de comparación de Duración "169730".

Numeración Ms Project	Descripción	Duración Planificada	Duración Predicha	Predecesoras
4	**OBRAS PROVISIONALES**	**147 días**	**147 días**	
6	CARTEL DE OBRA 3.60 x 2.40 M. UNA CARA	1 días	2 días	6CC
10	**OBRAS PRELIMINARES**	**147 días**	**148 días**	
11	MOVILIZACION Y DESMOVILIZACIÓN DE EQUIPOS	1 día	2 días	6CC
12	TRAZO Y REPLANTEO DE EJES Y NIVELES	65 días	58 días	11FC-1 día
16	**SEGURIDAD Y SALUD**	**3 días**	**3 días**	
17	ELABORACIÓN, IMPLEMENTACIÓN Y ADMINISTRACIÓN DEL PLAN DE SEGURIDAD Y SALUD EN EL TRABAJO	1 día	1 día	239
22	**PAVIMENTO ASFÁLTICO**	**79 días**	**215 días**	
23	CORTE DE TERRENO A NIVEL DE SUBRASANTE, C/TRACTOR, T. NORMAL	6 días	8 días	27FC-6 días
27	ESCARIFICADO DE SUBRASANTE E=0.25 m., C/MAQUINARIA	7 días	18 días	38FC-3 días
30	BARRIDO DE SUPERFICIE IMPRIMADA	6 días	16 días	32FC-2 días,147FC-3 días
34	CARPETA ASFÁLTICA EN CALIENTE, 2.5" ESPESOR	11 días	18 días	33FC-4 días
37	**VÍA ALTERNA - DESVÍO TRÁNSITO VEHICULAR**	**7 días**	**11 días**	
38	CONFORMACIÓN Y COMPACTACION DE SUBRASANTE	5 días	6 días	89FC-2 días
59	**VEREDAS Y MARTILLOS**	**52 días**	**110 días**	
60	CORTE DE TERRENO SUPERFICIAL, MANUAL, T. NORMAL	18 días	19 días	12CC
61	CONFORMACIÓN DE SUBRASANTE PARA VEREDAS Y MARTILLOS	8 días	25 días	60
62	BASE GRANULAR P/VEREDAS Y MARTILLOS E=0.10 M., FACTOR DE COMPACTACIÓN 1.20	10 días	24 días	61
63	ENCOFRADO Y DESENCOFRADO CARAVISTA EN VEREDAS Y MARTILLOS	12 días	23 días	62FC-6 días
64	VEREDA DE CONCRETO F´C=175 KG/CM2, E=0.10M., ACAB. SUPERF. FROTCH. C/PASTA 1:2, INC. SARDINEL	12 días	21 días	63FC-7 días
68	**BERMA DE ADOQUÍN DE CONCRETO**	**23 días**	**52 días**	
69	CORTE DE TERRENO SUPERFICIAL, MANUAL, T. NORMAL	11 días	11 días	34
70	CONFORMACIÓN DE SUBRASANTE PARA BERMAS	6 días	18 días	69FC-5 días
71	BASE GRANULAR P/BERMAS E=0.10 M., FACTOR DE COMPACTACIÓN 1.20	10 días	19 días	70FC-3 días
72	BERMA CON ADOQUÍN DE CONCRETO F´C=420 KG/CM2, 0.20x0.10x0.08 M.	9 días	17 días	71FC-5 días
86	**SARDINEL SUMERGIDO**	**13 días**	**13 días**	
87	EXCAVACION MANUAL DE ZANJAS P/SARDINEL SUMERGIDO	7 días	7 días	64FC-4 días
88	SARDINEL SUMERGIDO TIPO BURBUJA F´C=175 KG/CM2 (0.15 M. x 0.314 M.), ACAB. SUPERF. FROTCH. C/PASTA 1:2, INC. ENCOF.	7 días	6 días	87FC-4 días
89	SARDINEL SUMERGIDO TIPO RECTO F´C=175 KG/CM2 (0.15 M. x 0.30 M.), ACAB. SUPERF. FROTCH. C/PASTA 1:2, INC. ENCOF.	2 días	3 días	88FC-1 día
109	**JARDINERAS CUADRADAS**	**9 días**	**16 días**	
110	JARDINERAS CUADRADAS 0.90 x 0.90 m, F´C=175 KG/CM2	9 días	16 días	72FC-3 días
111	**PLANTONES**	**6 días**	**6 días**	
112	SIEMBRA DE PLANTONES INCLUY TAPADO DE HOYOS	6 días	6 días	110FC-4 días
120	**VARIOS**	**114 días**	**303 días**	
124	PLACA RECORDATORIA	1 día	8 días	112FC-1 día
125	**PUENTE VEHICULAR DE CONCRETO ARMADO**	**68 días**	**170 días**	
126	**MOVIMIENTOS DE TIERRA**	**53 días**	**143 días**	
127	EXCAVACION C/EXCAVADORA EN T. NORMAL, EN CAUCE QUEBRADA	3 días	3 días	23FC-2 días
128	EXCAVACIÓN C/EQUIPO T. SEMIROCOSO (IGNIMBRITA) EN CAUCE DE QUEBRADA (SIN EMPLEAR EXPLOSIVOS)	7 días	31 días	127FC-1 día
131	REFINE, NIVELACION Y COMPACTACIÓN P/ESTRUCTURAS	3 días	3 días	128FC-2 días
132	**ESTRIBOS Y ALEROS**	**36 días**	**103 días**	
133	CONCRETO f'c=100 kg/cm2 PARA SOLADOS	1 día	1 día	131
134	ACERO fy=4200 kg/cm2 GRADO 60, ZAPATA CORRIDA	8 días	24 días	133
135	ENCOFRADO Y DESENCOFRADO NORMAL, ZAPATA CORRIDA	7 días	6 días	134FC-2 días
136	CONCRETO PREMEZCLADO F'C=280 KGF/CM2, ZAPATA CORRIDA	3 días	3 días	135FC-1 día
137	ACERO fy=4200 kg/cm2 GRADO 60, ESTRIBOS Y ALEROS	14 días	49 días	136FC-1 día

138	ENCOFRADO Y DESENCOFRADO CARAVISTA, ESTRIBOS Y ALEROS	14 días	13 días	137FC-8 días
139	CONCRETO PREMEZCLADO F'C=280 KGF/CM2, ESTRIBOS Y ALEROS	5 días	5 días	138FC-3 días
140	**VIGAS**	**11 días**	**24 días**	
141	ACERO fy=4200 kg/cm2 GRADO 60, VIGAS	8 días	13 días	139FC-3 días
142	ENCOFRADO Y DESENCOFRADO CARAVISTA, VIGAS	4 días	10 días	141FC-2 días
143	CONCRETO PREMEZCLADO F'C=280 KGF/CM2, VIGAS	1 día	3 días	142
144	**LOSA MACIZA**	**11 días**	**23 días**	
147	CONCRETO PREMEZCLADO F'C=280 KGF/CM2, LOSA MACIZA Y VEREDAS	1 día	2 días	146,143CC
		240	***360***	***D. Real=336***

Figura 64: Obra "169592", predicción de la duración de actividades.



Nota: La predicción de la duración de actividades, en esta imagen solo se muestra una parte de la predicción de la obra “169592”.

Fuente: Elaboración propia, captura de la interfaz WEB.

Tabla 36: Tabla de comparación de Duración "169592".

Numeración Ms Project	Descripción	Duración Planificada	Duración Predicha	Predecesoras
8	**OBRAS PRELIMINARES**	**131 días**	**131 días**	
11	TRAZO Y REPLANTEO INICIAL	15 días	15 días	1
20	**INGRESO Y ASOC. 11 MAYO (PISTAS VEREDAS BERMAS) KM0+000 AL KM 0+960**	**120 días**	**147 días**	
21	**PAVIMENTO FLEXIBLE**	**68 días**	**68 días**	
22	**MOVIMIENTO DE TIERRA**	**53 días**	**53 días**	
23	CORTE A NIVEL DE SUB RASANTE C/EQUIPO	35 días	35 días	60FC-5 días

35	**SISTEMA DE DRENAJE**	**31 días**	**58 días**	
36	**ESTRUCTURA DE CAPTACION, REGISTRO Y DESCARGA**	**28 días**	**51 días**	
37	**MOVIMIENTO DE TIERRAS**	**28 días**	**51 días**	
38	EXCAVACION DE ZANJA EN TERR. NORMAL	2 días	2 días	11FC-5 días
39	EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	2 días	15 días	38CC
40	PERFILADO Y COMPACTADO MANUAL	2 días	2 días	39
43	**CONCRETO**	**22 días**	**33 días**	
44	CONCRETO SOLADO E=2"	1 día	1 día	40
45	ACERO DE REFUERZO F'Y=4200KG/CM2	8 días	9 días	44
46	ENCOFRADO Y DESENCOFRADO NORMAL	11 días	20 días	45FC-5 días
54	**RED DE DRENAJE**	**16 días**	**20 días**	
55	**MOVIMIENTO DE TIERRAS**	**16 días**	**20 días**	
56	EXCAVACION DE ZANJA EN TERR. NORMAL	5 días	12 días	46FC-3 días
57	EXCAVACION EN SUELO COMPACTO	5 días	5 días	56CC
58	REFINE Y PERFILADO	6 días	5 días	57FC-3 días
59	CAMA Y SOBRECAMA DE APOYO (E=0.10M, E=0.15M)	6 días	5 días	63
60	RELLENO COMPACTADO CON MATERIAL PROPIO	7 días	10 días	59FC-5 días
62	**TUBERIA**	**8 días**	**8 días**	
63	SUMINISTRO E INSTAL. DE TUB. PVC DESAGUE 200 MM	6 días	5 días	58FC-4 días
179	**ASOC SR. D/MILAGROS (PAV Y SARDINEL CONFIN) KM0+960 AL KM 1+790**	**121 días**	**219 días**	
180	**PAVIMENTO FLEXIBLE**	**39 días**	**114 días**	
181	**PAVIMENTO FLEXIBLE**	**39 días**	**114 días**	
182	**MOVIMIENTO DE TIERRA**	**27 días**	**53 días**	
183	CORTE A NIVEL DE SUB RASANTE C/EQUIPO	18 días	30 días	205FC-8 días,23
185	REFINE, PERFILADO Y COMPACTADO DE SUBRASANTE	18 días	40 días	183FC-15 días
187	**BASE GRANULAR**	**21 días**	**62 días**	
188	CONFORMACION D/BASE GRANULAR C/MAT PRES H=0.15M	19 días	40 días	185FC-15 días
189	CONFORMACION D/BASE GRANULAR C/MAT PRES H=0.15M	19 días	40 días	188FC-15 días
224	**VEREDAS**	**13 días**	**26 días**	
225	**UÑA VEREDA, UÑA MARTILLO**	**13 días**	**26 días**	
226	**MOVIMIENTO DE TIERRAS**	**13 días**	**26 días**	
227	EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	3 días	15 días	189FC-5 días
234	**LOSA VEREDA, LOSA MARTILLO**	**12 días**	**13 días**	
235	**MOVIMIENTO DE TIERRAS**	**12 días**	**13 días**	
236	EXCAVACION DE ZANJA EN TERR. NORMAL	3 días	4 días	227CC
237	PERFILADO Y COMPACTADO A NIVEL DE SUB RASANTE	2 días	2 días	236
239	**BASE GRANULAR**	**1 día**	**1 día**	
240	CONFORM D/BASE GRANULAR C/MAT PRES H=0.15M VEREDA	1 día	1 día	237
241	**CONCRETO SIMPLE**	**5 días**	**6 días**	
242	ENCOFRADO Y DESENCOFRADO NORMAL H=0.10M	4 días	5 días	240
248	**BERMAS**	**44 días**	**70 días**	
249	**BERMA LATERAL**	**41 días**	**41 días**	
250	**SARDINEL TIPO BURBUJA**	**41 días**	**41 días**	
251	**MOVIMIENTO DE TIERRAS**	**41 días**	**41 días**	
252	EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	30 días	30 días	242

262	**BERMA CENTRAL**	**37 días**	**63 días**	
263	**SARDINEL TIPO CUADRADO**	**37 días**	**63 días**	
264	**MOVIMIENTO DE TIERRAS**	**37 días**	**63 días**	
265	EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	30 días	39 días	252FC-20 días
266	PERFILADO Y COMPACTADO MANUAL	31 días	41 días	265FC-25 días
269	**CONCRETO SIMPLE**	**32 días**	**36 días**	
270	ENCOFRADO Y DESENCOFRADO NORMAL	30 días	36 días	266FC-25 días
275	**SEÑALIZACIÓN Y SEGURIDAD VIAL**	**15 días**	**15 días**	
276	**PAVIMENTO**	**15 días**	**15 días**	
277	**PINTURA**	**6 días**	**7 días**	
278	PINTURA D/PASO PEATONAL Y SIMBOLOS DIRECCIONALES	6 días	7 días	270
279	**GIBAS (02 UND)**	**13 días**	**13 días**	
280	EXCAVACION EN SUELO COMPACTO	6 días	6 días	278CC
281	PERFILADO Y COMPACTADO MANUAL	6 días	5 días	280FC-3 días
283	CONCRETO FC=210 KG/CM2 EN GIBA	5 días	6 días	281FC-3 días
284	PINTURA EN GIBA	6 días	6 días	283FC-3 días
285	**OTROS**	**6 días**	**5 días**	
286	SEÑALIZACION INFORMATIVA Y PREVENTIVA EN VIA	6 días	5 días	284FC-3 días
293	**IMPACTO AMBIENTAL**	**150 días**	**278 días**	
296	ACCION DE CIERRE AMBIENTAL	1 día	1 día	
		150	***278***	***D. Real=286***

Figura 65: Obra " 500532", predicción de la duración de actividades.



Nota: La predicción de la duración de actividades, en esta imagen solo se muestra una parte de la predicción de la obra “500532”.

Fuente: Elaboración propia, captura de la interfaz WEB.

Tabla 37: Tabla de comparación de Duración "500532".

Numeración Ms Project	Descripción	Duración Planificada	Duración Predicha	Predecesoras
3	**OBRAS PROVISIONALES**	**11 días**	**11 días**	
4	CARTEL DE OBRA (BANNER 3.60 x 2.40 M.)	2 días	3 días	1
19	**PAVIMENTOS FLEXIBLES**	**120 días**	**232 días**	
20	**TRABAJOS PRELIMINARES**	**10 días**	**10 días**	
21	TRAZO NIVELES Y REPLANTEO PRELIMINAR	10 días	10 días	4CC
23	**MOVIMIENTO DE TIERRAS**	**20 días**	**50 días**	
24	CORTE DE MATERIAL SUELTO DE SUBRASANTE PARA BASE	10 días	30 días	21CC
25	RELLENO COMPENSADO CON MATERIAL PROPIO	10 días	20 días	24
26	ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	20 días	20 días	25FF,24FF
28	**PAVIMENTOS**	**80 días**	**162 días**	
29	CONFORMACION DE SUBRASANTE	15 días	72 días	27,26
30	CONFORMACION DE BASE GRANULAR (E=0.20M)	15 días	60 días	29
31	BARRIDO DE SUPERFICIE PARA BASE GRANULAR	30 días	10 días	30
32	IMPRIMACION ASFALTICA CON MC-30	10 días	12 días	31FF
33	CARPETA ASFALTICA EN FRIO E=2"	10 días	17 días	32
34	ARENADO SUPERFICIAL DE PROTECCION DE CARPETA	20 días	20 días	33CC
37	**PINTURA EN PAVIMENTO**	**20 días**	**20 días**	
40	SEÑALIZACION VERTICAL	20 días	20 días	34
166	**VARIOS**	**21 días**	**90 días**	
167	PRUEBA DE CALIDAD DE CONCRETO (DISEÑO DE MEZCLAS)	2 días	2 días	19FF
168	PRUEBA DE CALIDAD DE CONCRETO (ROTURA DE PROBETAS)	20 días	90 días	167FF
169	MEDIDAS DE MITIGACION AMBIENTAL	2 días	2 días	168FF
170	LIMPIEZA FINAL DE OBRA	21 días	77 días	168FF
		120	***232***	***D. Real=239***

Primero, se verificó que las duraciones predichas no modificaran la ruta crítica de las obras analizadas. Posteriormente, se calculó la duración total predicha de cada obra. A continuación, se presenta una tabla para evaluar la efectividad del modelo predictivo mediante la comparación entre las duraciones predichas y las duraciones reales.

Tabla 38: Tabla de error (%).

Codigo INFOBRAS	Tiempo Planificado (TPl)	Tiempo Predicho (TPr)	Tiempo Real	Error porcentual (TPl)	Error porcentual (TPr)
169730	240	360	336	29%	7%
169592	150	278	286	48%	3%
500532	120	232	239	50%	3%

El modelo de Machine Learning desarrollado estima la duración de ejecución con un menor error en comparación con el tiempo planificado contractualmente.

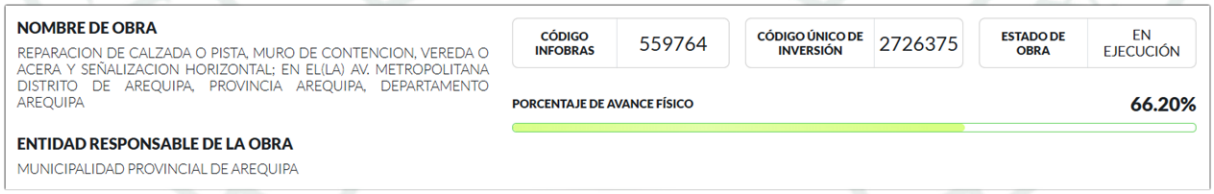
Para realizar una verificación complementaria del modelo propuesto, se visitaron obras que no formaron parte del conjunto de datos utilizado para su entrenamiento y que se encontraban próximas a ejecutar determinadas partidas. En dichas partidas se aplicó el modelo para estimar su duración y, posteriormente, se realizó el seguimiento de su ejecución, permitiendo contrastar la duración predicha con la duración real registrada en campo.

Tabla 39: Obras en la que se probó el modelo.

Código INFOBRAS	Código Único de Inversión	Código SNIP	Nombre de la obra
559764	2726375	2726375	REPARACION DE CALZADA O PISTA, MURO DE CONTENCION, VEREDA O ACERA Y SEÑALIZACION HORIZONTAL; EN EL(LA) AV. METROPOLITANA DISTRITO DE AREQUIPA, PROVINCIA AREQUIPA, DEPARTAMENTO AREQUIPA" con CUI Nº 2726375
557503	2565969	2565969	MEJORAMIENTO DEL SERVICIO DE MOVILIDAD URBANA EN LA URBANIZACIÓN LEÓN XIII DEL DISTRITO DE CAYMA - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA" con CUI Nº 2565969

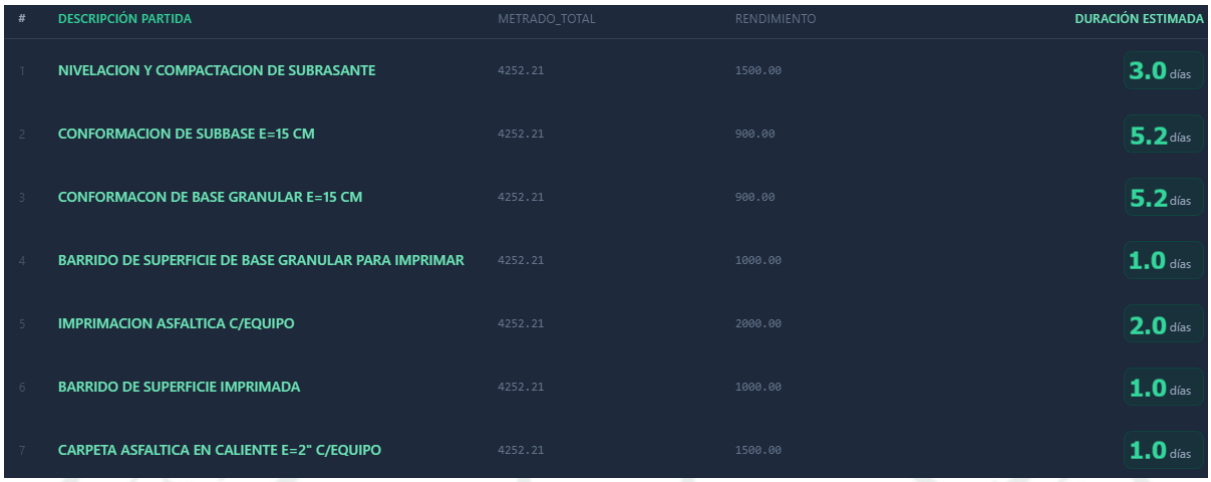
Fuente: Elaboración propia.

Figura 66: Datos de ejecución "559764".



Fuente: Captura de la plataforma de Infobras 30/09/2026.

Figura 67: Obra "559764"predicción de la duración de actividades.



#	DESCRIPCIÓN PARTIDA	METRADO_TOTAL	RENDIMIENTO	DURACIÓN ESTIMADA
1	NIVELACION Y COMPACTACION DE SUBRASANTE	4252.21	1500.00	3.0 días
2	CONFORMACION DE SUBBASE E=15 CM	4252.21	900.00	5.2 días
3	CONFORMACON DE BASE GRANULAR E=15 CM	4252.21	900.00	5.2 días
4	BARRIDO DE SUPERFICIE DE BASE GRANULAR PARA IMPRIMAR	4252.21	1000.00	1.0 días
5	IMPRIMACION ASFALTICA C/EQUIPO	4252.21	2000.00	2.0 días
6	BARRIDO DE SUPERFICIE IMPRIMADA	4252.21	1000.00	1.0 días
7	CARPETA ASFALTICA EN CALIENTE E=2" C/EQUIPO	4252.21	1500.00	1.0 días

Fuente: Elaboración propia, captura de la interfaz WEB.

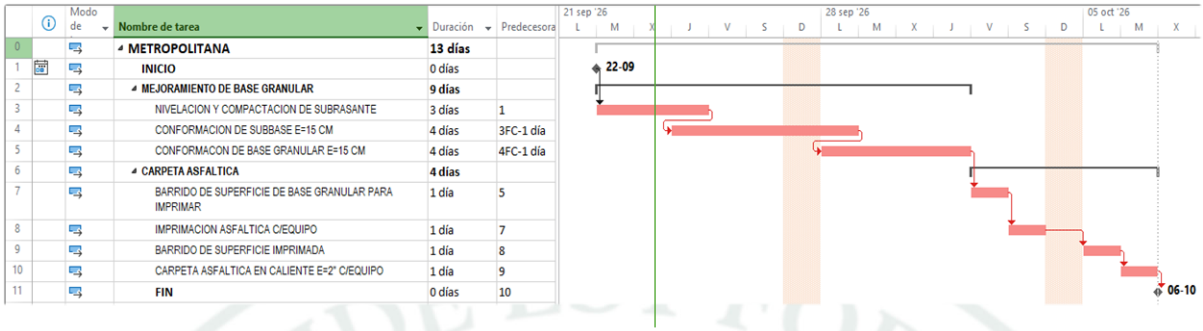
Tabla 40: Comparación de Duración "559764".

Numeración Ms Project	Descripción	Duración Planificada	Duración Predicha	Duración Real	Predecesoras
0	**METROPOLITANA**	**20 días**	**16 días**	**13 días**	
1	INICIO	0 días	0 días	0 días	
2	**MEJORAMIENTO DE BASE GRANULA**	**13 días**	**11 días**	**9 días**	
3	NIVELACION Y COMPACTACION DE SUBRASANTE	3 días	3 días	3 días	1
4	CONFORMACION DE SUBBASE E=15 CM	6 días	5 días	4 días	3FC-1 día
5	CONFORMACON DE BASE GRANULAR E=15 CM	6 días	5 días	4 días	4FC-1 día
6	**CARPETA ASFALTICA**	**7 días**	**5 días**	**4 días**	
7	BARRIDO DE SUPERFICIE DE BASE GRANULAR PARA IMPRIMAR	1 día	1 día	1 día	5
8	IMPRIMACION ASFALTICA C/EQUIPO	3 días	2 días	1 día	7
9	BARRIDO DE SUPERFICIE IMPRIMADA	1 día	1 día	1 día	8
10	CARPETA ASFALTICA EN CALIENTE E=2" C/EQUIPO	2 días	1 día	1 día	9
11	FIN	0 días	0 días	0 días	10

Nota: La secuencia de las predecesoras la tome en base como comenzaban las actividades reales, en anexos se encuentra la constancia de la aplicación del modelo.

Fuente: Elaboración propia.

Figura 68: Cronograma de las partidas en ejecución "559764".



	Modo de	Nombre de tarea	Duración	Predecesora
0		METROPOLITANA	13 días	
1		INICIO	0 días	
2		MEJORAMIENTO DE BASE GRANULAR	9 días	
3		NIVELACION Y COMPACTACION DE SUBRASANTE	3 días	1
4		CONFORMACION DE SUBBASE E=15 CM	4 días	3FC-1 día
5		CONFORMACON DE BASE GRANULAR E=15 CM	4 días	4FC-1 día
6		CARPETA ASFALTICA	4 días	
7		BARRIDO DE SUPERFICIE DE BASE GRANULAR PARA IMPRIMAR	1 día	5
8		IMPRIMACION ASFALTICA C/EQUIPO	1 día	7
9		BARRIDO DE SUPERFICIE IMPRIMADA	1 día	8
10		CARPETA ASFALTICA EN CALIENTE E=2" C/EQUIPO	1 día	9
11		FIN	0 días	10

Nota: El presente Diagrama de Gantt refleja la secuencia y ejecución real de las actividades.

Fuente: Elaboración propia.

Figura 69: Datos de ejecución "557503".



NOMBRE DE OBRA

MEJORAMIENTO DEL SERVICIO DE MOVILIDAD URBANA EN LA URBANIZACIÓN LEÓN XIII DEL DISTRITO DE CAYMA - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA

ENTIDAD RESPONSABLE DE LA OBRA

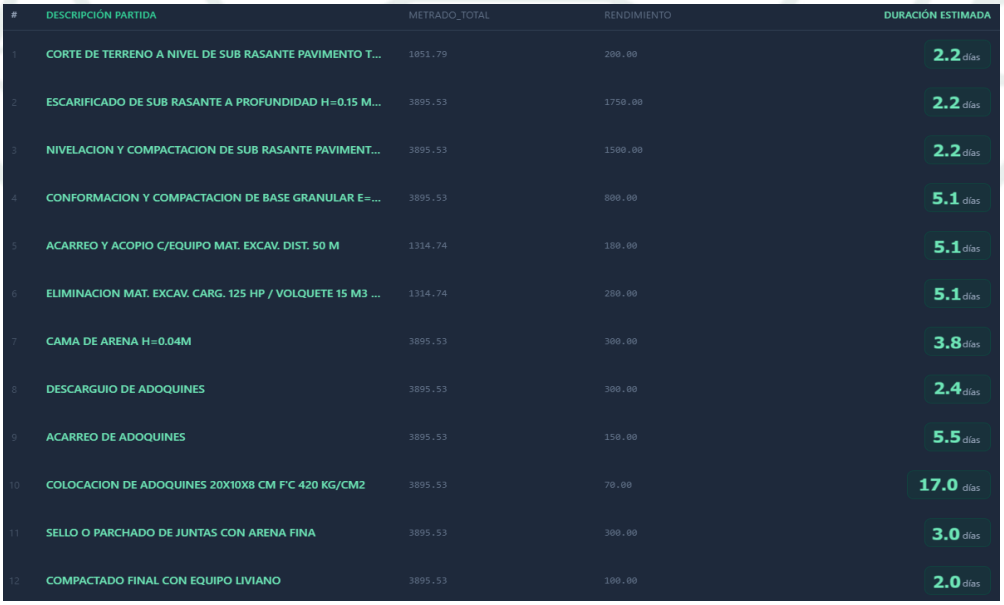
MUNICIPALIDAD DISTRITAL DE CAYMA

CÓDIGO INFOBRAS	557503	CÓDIGO ÚNICO DE INVERSIÓN	2565969	ESTADO DE OBRA	EN EJECUCIÓN

PORCENTAJE DE AVANCE FÍSICO 29.18%

Fuente: Captura de la plataforma de Infobras 30/09/2026.

Figura 70: Obra "557503"predicción de la duración de actividades.



#	DESCRIPCIÓN PARTIDA	METRADO_TOTAL	RENDIMIENTO	DURACIÓN ESTIMADA
1	CORTE DE TERRENO A NIVEL DE SUB RASANTE PAVIMENTO T...	1051.79	200.00	2.2 días
2	ESCARIFICADO DE SUB RASANTE A PROFUNDIDAD H=0.15 M...	3895.53	1750.00	2.2 días
3	NIVELACION Y COMPACTACION DE SUB RASANTE PAVIMENT...	3895.53	1500.00	2.2 días
4	CONFORMACION Y COMPACTACION DE BASE GRANULAR E=...	3895.53	800.00	5.1 días
5	ACARREO Y ACOPIO C/EQUIPO MAT. EXCAV. DIST. 50 M	1314.74	180.00	5.1 días
6	ELIMINACION MAT. EXCAV. CARG. 125 HP / VOLQUETE 15 M3 ...	1314.74	200.00	5.1 días
7	CAMA DE ARENA H=0.04M	3895.53	300.00	3.8 días
8	DESCARGUIO DE ADOQUINES	3895.53	300.00	2.4 días
9	ACARREO DE ADOQUINES	3895.53	150.00	5.5 días
10	COLOCACION DE ADOQUINES 20X10X8 CM F'C 420 KG/CM2	3895.53	70.00	17.0 días
11	SELLO O PARCHADO DE JUNTAS CON ARENA FINA	3895.53	300.00	3.0 días
12	COMPACTADO FINAL CON EQUIPO LIVIANO	3895.53	100.00	2.0 días

Fuente: Elaboración propia, captura de la interfaz WEB.

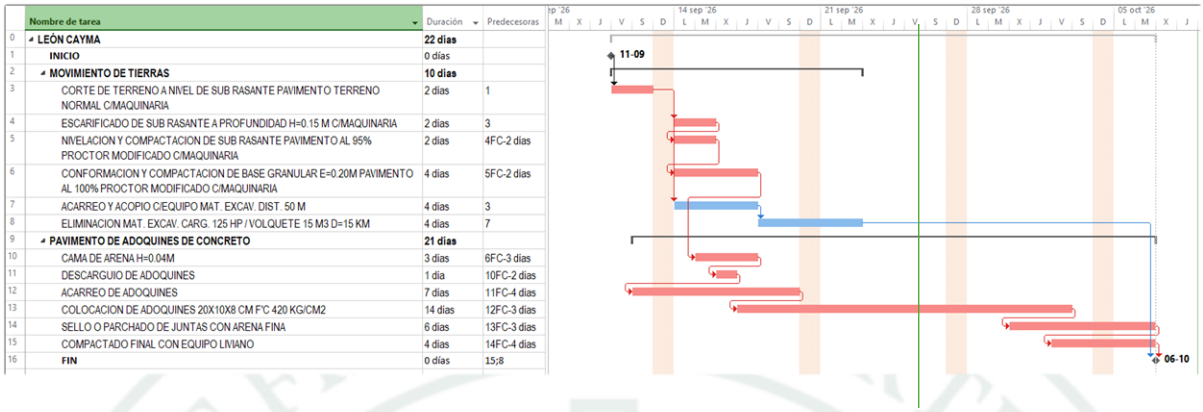
Tabla 41: Tabla de comparación de Duración "557503".

Numeración Ms Project	Descripción	Duración Planificada	Duración Predicha	Duración Real	Predecesoras
0	**LEÓN CAYMA**	**45 días**	**24 días**	**22 días**	
1	**INICIO**	0 días	0 días	0 días	
2	**MOVIMIENTO DE TIERRAS**	**11 días**	**12 días**	**10 días**	
3	CORTE DE TERRENO A NIVEL DE SUB RASANTE PAVIMENTO TERRENO NORMAL C/MAQUINARIA	3 días	2 días	2 días	1
4	ESCARIFICADO DE SUB RASANTE A PROFUNDIDAD H=0.15 M C/MAQUINARIA	3 días	2 días	2 días	3
5	NIVELACION Y COMPACTACION DE SUB RASANTE PAVIMENTO AL 95% PROCTOR MODIFICADO C/MAQUINARIA	3 días	2 días	2 días	4FC-2 días
6	CONFORMACION Y COMPACTACION DE BASE GRANULAR E=0.20M PAVIMENTO AL 100% PROCTOR MODIFICADO C/MAQUINARIA	6 días	5 días	4 días	5FC-2 días
7	ACARREO Y ACOPIO C/EQUIPO MAT. EXCAV. DIST. 50 M	4 días	5 días	4 días	3
8	ELIMINACION MAT. EXCAV. CARG. 125 HP / VOLQUETE 15 M3 D=15 KM	4 días	5 días	4 días	7
9	**PAVIMENTO DE ADOQUINES DE CONCRETO**	**37 días**	**20 días**	**21 días**	
10	CAMA DE ARENA H=0.04M	5 días	4 días	3 días	6FC-3 días
11	DESCARGUIO DE ADOQUINES	5 días	2 días	1 día	10FC-2 días
12	ACARREO DE ADOQUINES	7 días	6 días	7 días	11FC-4 días
13	COLOCACION DE ADOQUINES 20X10X8 CM F'C 420 KG/CM2	22 días	17 días	14 días	12FC-3 días
14	SELLO O PARCHADO DE JUNTAS CON ARENA FINA	6 días	3 días	6 días	13FC-3 días
15	COMPACTADO FINAL CON EQUIPO LIVIANO	8 días	2 días	4 días	14FC-4 días
16	**FIN**	0 días	0 días	0 días	15;8

Nota: La secuencia de las predecesoras la tome en base como comenzaban las actividades reales, en anexos se encuentra la constancia de la aplicación del modelo.

Fuente: Elaboración propia.

Figura 71: Cronograma de las partidas en ejecución "559764".



	Nombre de tarea	Duración	Predecesoras
0	LEÓN CAYMA	22 días	
1	INICIO	0 días	
2	MOVIMIENTO DE TIERRAS	10 días	
3	CORTE DE TERRENO A NIVEL DE SUB RASANTE PAVIMENTO TERRENO NORMAL C/MAQUINARIA	2 días	1
4	ESCARIFICADO DE SUB RASANTE A PROFUNDIDAD H=0.15 M C/MAQUINARIA	2 días	3
5	NIVELACION Y COMPACTACION DE SUB RASANTE PAVIMENTO AL 95% PROCTOR MODIFICADO C/MAQUINARIA	2 días	4FC-2 días
6	CONFORMACION Y COMPACTACION DE BASE GRANULAR E=0.20M PAVIMENTO AL 100% PROCTOR MODIFICADO C/MAQUINARIA	4 días	5FC-2 días
7	ACARREO Y ACOPIO C/EQUIPO MAT. EXCAV. DIST. 50 M	4 días	3
8	ELIMINACION MAT. EXCAV. CARG. 125 HP / VOLQUETE 15 M3 D=15 KM	4 días	7
9	PAVIMENTO DE ADOQUINES DE CONCRETO	21 días	
10	CAMA DE ARENA H=0.04M	3 días	6FC-3 días
11	DESCARGUIO DE ADOQUINES	1 día	10FC-2 días
12	ACARREO DE ADOQUINES	7 días	11FC-4 días
13	COLOCACION DE ADOQUINES 20X10X8 CM F'C 420 KG/CM2	14 días	12FC-3 días
14	SELLO O PARCHADO DE JUNTAS CON ARENA FINA	6 días	13FC-3 días
15	COMPACTADO FINAL CON EQUIPO LIVIANO	4 días	14FC-4 días
16	FIN	0 días	15;8

Nota: El presente Diagrama de Gantt refleja la secuencia y ejecución real de las actividades.

Fuente: Elaboración propia.

5.4.2. Comparación del modelo Machine Learning frente a PERT

Se comparó el desempeño del modelo de Machine Learning con el método PERT mediante las duraciones estimadas para los mismos casos de estudio, utilizando la duración real como referencia. La comparación se realizó a partir del error absoluto de cada método, con el propósito de determinar cuál presenta una mayor precisión.

Tabla 42: Comparación de errores PERT y ML obra "169730".

DESCRIPCION	Duración Planificada	Duración Predicha	Duración Real	Error Pert	Error ML	Diferencia De Errores	Comparación
CARTEL DE OBRA 3.60 x 2.40 M. UNA CARA	1	2	4	3	2	1	ML menor error
MOVILIZACION Y DESMOVILIZACIÓN DE EQUIPOS	1	2	3	2	1	1	ML menor error
TRAZO Y REPLANTEO DE EJES Y NIVELES	65	58	60	5	2	3	ML menor error
CONTROL TOPOGRÁFICO DURANTE LA EJECUCION DE LA OBRA	10	8	7	3	1	2	ML menor error
DEMOLICION DE VEREDAS DE CONCRETO C/EQ.	3	10	10	7	0	7	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DE LAS DEMOLICIONES, INC. ACARREO INT., D=5 KM.	1	1	4	3	3	0	Igual
ELABORACIÓN, IMPLEMENTACIÓN Y ADMINISTRACIÓN DEL PLAN DE SEGURIDAD Y SALUD EN EL TRABAJO	1	1	3	2	2	0	Igual
CORTE DE TERRENO A NIVEL DE SUBRASANTE, C/TRACTOR, T. NORMAL	6	8	9	3	1	2	ML menor error

CORTE DE TERRENO A NIVEL DE SUBRASANTE, CON MAQUINARIA, TERRENO SEMIROCOSO (SIN EMPLEO DE EXPLOSIVOS)	4	13	12	8	1	7	ML menor error
RELLENO COMPACTADO A NIVEL DE SUBRASANTE CON MATERIAL PROPIO, C/MAQUINARIA	1	2	3	2	1	1	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DEL CORTE, INC. ACARREO INT., D=5 KM.	3	6	3	0	3	-3	PERT menor error
ESCARIFICADO DE SUBRASANTE E=0.25 m., C/MAQUINARIA	7	18	19	12	1	11	ML menor error
CONFORMACIÓN Y COMPACTACION DE SUBRASANTE	5	16	19	14	3	11	ML menor error
BASE GRANULAR E=0.20 M (AFIRMADO PRODUCIDO) C/EQUIPO	13	34	33	20	1	19	ML menor error
BARRIDO SUPERFICIAL (MANUAL) DE BASE ANTES DE IMPRIMADO	6	16	16	10	0	10	ML menor error
IMPRIMACIÓN ASFÁLTICA	6	12	13	7	1	6	ML menor error
ARENADO DE PROTECCIÓN DE SUPERFICIIE IMPRIMADA	6	16	17	11	1	10	ML menor error
BARRIDO DE SUPERFICIE IMPRIMADA	6	17	15	9	2	7	ML menor error
CARPETA ASFÁLTICA EN CALIENTE, 2.5" ESPESOR	11	18	22	11	4	7	ML menor error
ARENADO DE PROTECCIÓN DE CARPETA ASFÁLTICA	6	12	16	10	4	6	ML menor error
LIMPIEZA Y BARRIDO DE CARPETA ASFÁLTICA	6	12	15	9	3	6	ML menor error
CONFORMACIÓN Y COMPACTACION DE SUBRASANTE	5	6	4	1	2	-1	PERT menor error
RIEGO EN VÍA ALTERNA PARA MIITIGAR CONTAMINACIÓN (POLVO)	1	10	10	9	0	9	ML menor error
EXCAVACION C/RETROEXCAVADORA EN T. NORMAL	2	4	3	1	1	0	Igual
RELLENO COMPACTADO C/COMPACTADORA 7 HP, MAT. PROPIO, C/AGUA	5	35	35	30	0	30	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DE LA EXCAVACION, INC. ACARREO INT., D=5 KM.	1	2	1	0	1	-1	PERT menor error
REFINE, NIVELACION Y COMPACTACIÓN P/ESTRUCTURAS	2	4	4	2	0	2	ML menor error
SUB ZAPATA, CONCRETO CICLOPEO 1:12 (CEMENTO:HORMIGÓN) + 30% PIEDRA GRANDE 8"	4	4	3	1	1	0	Igual
ACERO fy=4200 kg/cm2 GRADO 60, ZAPATA CORRIDA	5	10	12	7	2	5	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL, ZAPATA CORRIDA	3	4	6	3	2	1	ML menor error
CONCRETO F'c=210Kg/cm2, ZAPATA CORRIDA	3	3	5	2	2	0	Igual
ACERO fy=4200 kg/cm2 GRADO 60, MURO DE CONTENCIÓN	5	8	8	3	0	3	ML menor error
ENCOFRADO Y DESENCOFRADO CARAVISTA, MURO DE CONTENCIÓN (LADO EXPUESTO)	4	8	12	8	4	4	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL, MUROS DE CIMENTACIÓN (LADO INTERNO)	3	6	5	2	1	1	ML menor error
CONCRETO F'c=210Kg/cm2, MURO DE CONTENCIÓN	1	3	5	4	2	2	ML menor error
SOLAQUEADO DE MUROS CARAVISTA	2	7	10	8	3	5	ML menor error
JUNTAS DE DILATACION EN MUROS	1	5	2	1	3	-2	PERT menor error
ACERO F'y=4200 Kg/cm2, PARAPETO DE CONCRETO	2	3	5	3	2	1	ML menor error
ENCOFRADO Y DESENCOFRADO CARAVISTA DE PARAPETO DE CONCRETO	4	9	11	7	2	5	ML menor error
PARAPETO DE CONCRETO, CONCRETO F´C=210 KG/CM2, E=0.20M., ACAB. SUPERF. SOLAQUEADO	1	2	4	3	2	1	ML menor error
CORTE DE TERRENO SUPERFICIAL, MANUAL, T. NORMAL	18	19	21	3	2	1	ML menor error
CONFORMACIÓN DE SUBRASANTE PARA VEREDAS Y MARTILLOS	8	25	24	16	1	15	ML menor error
BASE GRANULAR P/VEREDAS Y MARTILLOS E=0.10 M., FACTOR DE COMPACTACIÓN 1.20	10	24	24	14	0	14	ML menor error

ENCOFRADO Y DESENCOFRADO CARAVISTA EN VEREDAS Y MARTILLOS	12	23	24	12	1	11	ML menor error
VEREDA DE CONCRETO F´C=175 KG/CM2, E=0.10M., ACAB. SUPERF. FROTCH. C/PASTA 1:2, INC. SARDINEL	12	21	20	8	1	7	ML menor error
JUNTAS DE DILATACIÓN ASFÁLTICAS	5	16	14	9	2	7	ML menor error
PINTADO DE SARDINELES EN VEREDAS Y MARTILLOS	4	5	9	5	4	1	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DEL CORTE EN VEREDAS, INC. ACARREO INT., D=5 KM.	2	5	6	4	1	3	ML menor error
CORTE DE TERRENO SUPERFICIAL, MANUAL, T. NORMAL	11	11	15	4	4	0	Igual
CONFORMACIÓN DE SUBRASANTE PARA BERMAS	6	18	16	10	2	8	ML menor error
BASE GRANULAR P/BERMAS E=0.10 M., FACTOR DE COMPACTACIÓN 1.20	10	19	18	8	1	7	ML menor error
BERMA CON ADOQUÍN DE CONCRETO F´C=420 KG/CM2, 0.20x0.10x0.08 M. (GRIS NATURAL)	9	17	14	5	3	2	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DEL CORTE EN BERMAS, INC. ACARREO INT., D=5 KM.	3	3	5	2	2	0	Igual
CORTE DE TERRENO SUPERFICIAL, MANUAL, T. NORMAL	8	10	9	1	1	0	Igual
CONFORMACIÓN DE SUBRASANTE PARA RAMPAS	2	5	7	5	2	3	ML menor error
BASE GRANULAR P/RAMPAS, E=0.10 M., FACTOR DE COMPACTACIÓN 1.20	3	5	7	4	2	2	ML menor error
RAMPAS PEATONALES DE CONCRETO F´C=175 KG/CM2, E=0.10M., ACAB. SUPERF. BRUÑADO, C/PASTA 1:2, INC. SARDINEL	5	4	7	2	3	-1	PERT menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DEL CORTE EN RAMPAS, INC. ACARREO INT., D=5 KM.	1	1	2	1	1	0	Igual
CORTE DE TERRENO SUPERFICIAL, MANUAL, T. NORMAL	3	3	3	0	0	0	Igual
CONFORMACIÓN DE SUBRASANTE PARA RAMPAS	2	2	2	0	0	0	Igual
BASE GRANULAR P/RAMPAS, E=0.10 M., FACTOR DE COMPACTACIÓN 1.20	1	3	6	5	3	2	ML menor error
RAMPAS VEHICULARES DE CONCRETO F´C=175 KG/CM2, E=0.10M., ACAB. SUPERF. BRUÑADO, C/PASTA 1:2, INC. SARDINEL	2	2	4	2	2	0	Igual
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DEL CORTE EN RAMPAS, INC. ACARREO INT., D=5 KM.	1	1	4	3	3	0	Igual
EXCAVACION MANUAL DE ZANJAS P/SARDINEL SUMERGIDO	7	7	8	1	1	0	Igual
SARDINEL SUMERGIDO TIPO BURBUJA F´C=175 KG/CM2 (0.15 M. x 0.314 M.), ACAB. SUPERF. FROTCH. C/PASTA 1:2, INC. ENCOF.	7	6	8	1	2	-1	PERT menor error
SARDINEL SUMERGIDO TIPO RECTO F´C=175 KG/CM2 (0.15 M. x 0.30 M.), ACAB. SUPERF. FROTCH. C/PASTA 1:2, INC. ENCOF.	2	3	7	5	4	1	ML menor error
PINTADO DE SARDINEL SUMERGIDO E=0.15 M. (CARA SUPERIOR EXPUESTA)	5	10	12	7	2	5	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DE LA EXCAV. DE ZANJAS P/SARDINEL SUMERGIDO, INC. ACARREO INT., 5 KM.	1	2	4	3	2	1	ML menor error
CONFORMACIÓN DE SUBRASANTE PARA GRADAS	1	4	7	6	3	3	ML menor error
BASE GRANULAR P/GRADAS, E=0.10 M., FACTOR DE COMPACTACIÓN 1.20	1	2	4	3	2	1	ML menor error
ENCOFRADO Y DESENCOFRADO CARAVISTA EN CONTRAPASO DE GRADAS	1	2	3	2	1	1	ML menor error
CONCRETO F'C=175 KG/CM2 EN GRADAS	1	2	5	4	3	1	ML menor error
CURADO ACRILICO DE CONCRETO COLOCADO	1	3	6	5	3	2	ML menor error
ACABADO FROTACHADO EN SUPEF. PASOS DE GRADA	1	2	3	2	1	1	ML menor error
JUNTAS DE DILATACIÓN ASFÁLTICAS	1	2	2	1	0	1	ML menor error

CORTE Y REMOCIÓN DE CARPETA ASFÁLTICA EN CALIENTE E=2.5"	1	2	5	4	3	1	ML menor error
CORTE DE TERRENO SUPERFICIAL, MANUAL, T. NORMAL	8	15	19	11	4	7	ML menor error
CONFORMACION DE SUB-RASANTE PARA GIBA DE CONCRETO	2	2	5	3	3	0	Igual
CONCRETO f'c=100 kg/cm2 PARA SOLADOS	1	2	5	4	3	1	ML menor error
ACERO fy=4200 kg/cm2 GRADO 60, GIBA DE CONCRETO	4	6	7	3	1	2	ML menor error
CONCRETO f'c=280 kg/cm2, EN GIBA DE CONCRETO	3	3	4	1	1	0	Igual
ACABADO FROTACHADO SUPERF. DE GIBA DE CONCRETO (S/MATER.)	2	3	3	1	0	1	ML menor error
CURADO ACRILICO DE CONCRETO COLOCADO	1	3	5	4	2	2	ML menor error
JARDINERAS CUADRADAS 0.90 x 0.90 m, F´C=175 KG/CM2 (inc. encof sard., secc. e=0.10 x h=0.35 y tarrajeo)	9	16	14	5	2	3	ML menor error
SIEMBRA DE PLANTONES INCLUY TAPADO DE HOYOS	6	6	9	3	3	0	Igual
SEÑALIZACIÓN HORIZONTAL (PINTADO DE LÍNEAS DISCONTINUAS EN EJE DE PAVIMENTO), PINTURA AMARILLA	2	3	6	4	3	1	ML menor error
SEÑALIZACIÓN HORIZONTAL (MARCAS EN PAVIMENTO), PINTURA BLANCA	8	7	8	0	1	-1	PERT menor error
SEÑALIZACIÓN HORIZONTAL (MARCAS EN GIBAS), PINTURA AMARILLA	5	5	9	4	4	0	Igual
SEÑALES REGLAMENTARIA - SUMINISTRO Y COLOCACIÓN	2	3	7	5	4	1	ML menor error
SEÑALES PREVENTIVAS - SUMINISTRO Y COLOCACIÓN	7	9	9	2	0	2	ML menor error
SEÑALES INFORMATIVAS - SUMINISTRO Y COLOCACIÓN	5	3	4	1	1	0	Igual
ENCIMADO DE FUSTE P/NIVELACION DE TECHO DE BUZON	1	2	6	5	4	1	ML menor error
REDUCCION DE FUSTE P/NIVELACION DE TECHO DE BUZON	1	2	1	0	1	-1	PERT menor error
NIVELACIÓN CONEXIÓN DOMICILIARIA DE AGUA Y DESAGUE	8	10	14	6	4	2	ML menor error
PLACA RECORDATORIA	1	8	12	11	4	7	ML menor error
EXCAVACION C/EXCAVADORA EN T. NORMAL, EN CAUCE QUEBRADA	3	3	7	4	4	0	Igual
EXCAVACIÓN C/EQUIPO T. SEMIROCOSO (IGNIMBRITA) EN CAUCE DE QUEBRADA (SIN EMPLEAR EXPLOSIVOS)	7	31	35	28	4	24	ML menor error
RELLENO COMPACTADO C/COMPACTADORA 7 HP, MAT. PROPIO, C/AGUA	7	29	28	21	1	20	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DE LA EXCAVACION, INC. ACARREO INT., D=5 KM.	3	5	7	4	2	2	ML menor error
REFINE, NIVELACION Y COMPACTACIÓN P/ESTRUCTURAS	3	3	6	3	3	0	Igual
CONCRETO f'c=100 kg/cm2 PARA SOLADOS	1	1	2	1	1	0	Igual
ACERO fy=4200 kg/cm2 GRADO 60, ZAPATA CORRIDA	8	24	27	19	3	16	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL, ZAPATA CORRIDA	7	6	6	1	0	1	ML menor error
CONCRETO PREMEZCLADO F'C=280 KGF/CM2, ZAPATA CORRIDA	3	3	2	1	1	0	Igual
ACERO fy=4200 kg/cm2 GRADO 60, ESTRIBOS Y ALEROS	14	49	52	38	3	35	ML menor error
ENCOFRADO Y DESENCOFRADO CARAVISTA, ESTRIBOS Y ALEROS	14	13	15	1	2	-1	PERT menor error
CONCRETO PREMEZCLADO F'C=280 KGF/CM2, ESTRIBOS Y ALEROS	5	5	2	3	3	0	Igual
ACERO fy=4200 kg/cm2 GRADO 60, VIGAS	8	13	16	8	3	5	ML menor error
ENCOFRADO Y DESENCOFRADO CARAVISTA, VIGAS	4	10	9	5	1	4	ML menor error
CONCRETO PREMEZCLADO F'C=280 KGF/CM2, VIGAS	1	3	2	1	1	0	Igual
ACERO fy=4200 kg/cm2 GRADO 60, LOSA MACIZA Y VEREDAS	4	8	9	5	1	4	ML menor error

ENCOFRADO Y DESENCOFRADO CARAVISTA, LOSA MACIZA Y VEREDAS	3	13	10	7	3	4	ML menor error
CONCRETO PREMEZCLADO F'C=280 KGF/CM2, LOSA MACIZA Y VEREDAS	1	2	3	2	1	1	ML menor error
TUBERIA C-10 PVC 2"	1	2	2	1	0	1	ML menor error
FALSO PUENTE	5	3	6	1	3	-2	PERT menor error
CONFORMACIÓN Y COMPACTACION DE SUBRASANTE	1	2	2	1	0	1	ML menor error
BASE GRANULAR E=0.20 M (AFIRMADO PRODUCIDO) C/EQUIPO	1	22	21	20	1	19	ML menor error
ACERO F'y=4200 Kg/cm2, LOSA DE APROXIMACIÓN	3	3	4	1	1	0	Igual
ENCOFRADO Y DESENCOFRADO NORMAL, LOSA DE APROXIMACIÓN	2	2	3	1	1	0	Igual
LOSA DE APROXIMACIÓN, CONCRETO F´C=210 KG/CM2, E=0.20M., ACAB. SUPERF. FROTCH, INC. SARDINEL PERIM.	1	1	3	2	2	0	Igual
VEREDA DE CONCRETO F´C=210 KG/CM2, E=0.10M., ACAB. SUPERF. FROTCH. C/PASTA 1:2	1	1	5	4	4	0	Igual
ACERO F'y=4200 Kg/cm2, BARRERA DE CONCRETO	3	2	6	3	4	-1	PERT menor error
ENCOFRADO Y DESENCOFRADO CARAVISTA DE BARRERA DE CONCRETO	3	4	1	2	3	-1	PERT menor error
BARRERA DE CONCRETO, CONCRETO F´C=210 KG/CM2, E=0.20M., ACAB. SUPERF. SOLAQUEADO	1	1	2	1	1	0	Igual
APOYO DE NEOPRENE 250x250x52mm, DENSIDAD 60	2	3	3	1	0	1	ML menor error
BARANDA METALICA PEATONAL S/DETALLE	5	3	1	4	2	2	ML menor error
REUBICACION DE ALCANTARILLA METÁLICA D=2.00 M.	2	3	2	0	1	-1	PERT menor error
RELLENO COMPACTADO PROVISIONAL C/COMPACTADORA 7 HP, MAT. PROPIO, C/AGUA, EN CAUCE DE QUEBRADA	8	18	17	9	1	8	ML menor error
CONFORMACIÓN Y COMPACTACION DE SUBRASANTE	1	2	5	4	3	1	ML menor error
ENROCADO EN TALUD DE RELLENO COMPACTADO PROVISIONAL	2	2	1	1	1	0	Igual
EXCAVACION C/EXCAVADORA EN T. NORMAL (RETIRO MATERIAL DE RELLENO EN CAUCE DE QUEBRADA)	4	7	10	6	3	3	ML menor error
RETIRO DE ALCANTARILLA METÁLICA D=2.00 M.	1	5	3	2	2	0	Igual
LIMPIEZA Y ENCAUZAMIENTO DE CAUCE, LUEGO DE RETIRO MATERIAL DE RELLENO	1	1	4	3	3	0	Igual
EXCAVACION MANUAL EN T. NORMAL, H=2.00 M. (EN ZONAS DE REDES Y CONEX. EXIST.).	7	10	13	6	3	3	ML menor error
EXCAVACION EN T. NORMAL C/CARGADOR RETROEXCAVADOR, H=2.00 M.	6	5	2	4	3	1	ML menor error
EXCAVACION EN T. SEMIROCOSO C/CARGADOR RETROEXCAVADOR, H=2.00 M.	1	2	6	5	4	1	ML menor error
EXCAVACION MANUAL EN T. NORMAL, H=2.50 M. (EN ZONAS DE REDES Y CONEX. EXIST.).	12	22	21	9	1	8	ML menor error
EXCAVACION EN T. NORMAL C/CARGADOR RETROEXCAVADOR, H=2.50 M.	6	24	25	19	1	18	ML menor error
EXCAVACION EN T. SEMIROCOSO C/CARGADOR RETROEXCAVADOR, H=2.50 M.	3	6	9	6	3	3	ML menor error
EXCAVACION MANUAL EN T. NORMAL, H=3.00 M. (EN ZONAS DE REDES Y CONEX. EXIST.).	7	10	11	4	1	3	ML menor error
EXCAVACION EN T. NORMAL C/CARGADOR RETROEXCAVADOR, H=3.00 M.	5	24	19	14	5	9	ML menor error
EXCAVACION EN T. SEMIROCOSO C/CARGADOR RETROEXCAVADOR, H=3.00 M.	2	2	4	2	2	0	Igual
REFINE Y NIVELACION DE ZANJA EN T. NORMAL, P/TODA PROFUNDIDAD	6	15	14	8	1	7	ML menor error
REFINE Y NIVELACION DE ZANJA EN T. SEMIROCOSO, P/TODA PROFUNDIDAD	6	10	14	8	4	4	ML menor error
CAMA DE ARENA P/TUBERIA E=0.10 M.	5	16	18	13	2	11	ML menor error
RELLENO PROTECTOR DE TUBERÍA 450 mm, C/MATERIAL PROPIO ZARANDEADO HASTA 0.30 M. POR ENCIMA DE CLAVE DE TUBERÍA	3	4	4	1	0	1	ML menor error

RELLENO PROTECTOR DE TUBERÍA 600 mm, C/MATERIAL PROPIO ZARANDEADO HASTA 0.30 M. POR ENCIMA DE CLAVE DE TUBERÍA	3	3	6	3	3	0	Igual
RELLENO PROTECTOR DE TUBERÍA 900 mm, C/MATERIAL PROPIO ZARANDEADO HASTA 0.30 M. POR ENCIMA DE CLAVE DE TUBERÍA	6	16	20	14	4	10	ML menor error
RELLENO PROTECTOR DE TUBERÍA 1,200 mm, C/MATERIAL PROPIO ZARANDEADO HASTA 0.30 M. POR ENCIMA DE CLAVE DE TUBERÍA	3	6	7	4	1	3	ML menor error
RELLENO SUPERIIOR (FINAL) COMPACTADO DE ZANJAS, C/MATERIAL PROPIO HASTA NIVEL DE SUBRASANTE	7	16	20	13	4	9	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE, PROVENIENTE DE LA EXCAVACION, INC. ACARREO INT., D=5 KM.	3	5	4	1	1	0	Igual
SUMINISTRO E INSTALACION DE TUB. HDPE, SERIE 3, DN 450 MM x 6 M., INC. + 2% DESPEDICIOS	1	2	2	1	0	1	ML menor error
SUMINISTRO E INSTALACION DE TUB. HDPE, SERIE 5, DN 600 MM x 6 M., INC. + 2% DESPEDICIOS	1	2	4	3	2	1	ML menor error
SUMINISTRO E INSTALACION DE TUB. HDPE, SERIE 4, DN 900 MM x 6 M., INC. + 2% DESPEDICIOS	4	4	1	3	3	0	Igual
SUMINISTRO E INSTALACION DE TUB. HDPE, SERIE 4, DN 1,200 MM x 6 M., INC. + 2% DESPEDICIOS	2	3	1	1	2	-1	PERT menor error
SUMIDERO (SUM-1) 8.00 x 1.20 M., CON TAPA PREFABRICADA F´C=280 Kg/cm2, T. NORMAL, EXCAV. MANUAL, ENCOF. INT., C/ELIMIN. MAT. EXCED.	1	2	2	1	0	1	ML menor error
SUMIDERO (SUM-2) 8.00 x 1.20 M., CON TAPA PREFABRICADA F´C=280 Kg/cm2, T. NORMAL, EXCAV. C/EQUIPO, ENCOF. INT., C/ELIMIN. MAT. EXCED.	1	2	4	3	2	1	ML menor error
SUMIDERO (SUM-3) 8.00 x 2.40 M., CON TAPA PREFABRICADA F´C=280 Kg/cm2, T. NORMAL, EXCAV. C/EQUIPO, ENCOF. INT., C/ELIMIN. MAT. EXCED.	1	2	1	0	1	-1	PERT menor error
SUMIDERO (SUM-4) 8.00 x 2.40 M., CON TAPA PREFABRICADA F´C=280 Kg/cm2, T. NORMAL, EXCAV. C/EQUIPO, ENCOF. INT., C/ELIMIN. MAT. EXCED.	1	2	2	1	0	1	ML menor error
SUMIDERO (SUM-5 y SUM-6) 8.00 x 1.20 M., CON TAPA PREFABRICADA F´C=280 Kg/cm2, T. NORMAL, EXCAV. C/EQUIPO, ENCOF. INT., C/ELIMIN. MAT. EXCED.	2	3	3	1	0	1	ML menor error
CÁMARA DE INSPECCIÓN H=1.76 M. A 2.00 M., D=1.50 M., T. NORMAL, EXCAV. MANUAL, ENCOF. INT., C/ELIMIN. MAT. EXCED.	5	8	6	1	2	-1	PERT menor error
CÁMARA DE INSPECCIÓN H=2.01 M. A 2.25 M., D=1.50 M., T. NORMAL, EXCAV. MANUAL, ENCOF. INT., C/ELIMIN. MAT. EXCED.	2	4	6	4	2	2	ML menor error
CÁMARA DE INSPECCIÓN H=2.26 M. A 2.50 M., D=1.50 M., T. NORMAL, EXCAV. MANUAL, ENCOF. INT., C/ELIMIN. MAT. EXCED.	5	9	11	6	2	4	ML menor error
CÁMARA DE INSPECCIÓN H=2.51 M. A 2.75 M., D=1.50 M., T. NORMAL, EXCAV. MANUAL, ENCOF. INT., C/ELIMIN. MAT. EXCED.	2	3	5	3	2	1	ML menor error
CÁMARA DE INSPECCIÓN H=2.76 M. A 3.00 M., D=1.50 M., T. NORMAL, EXCAV. MANUAL, ENCOF. INT., C/ELIMIN. MAT. EXCED.	1	2	4	3	2	1	ML menor error
CÁMARA DE INSPECCIÓN H=3.51 M. A 3.75 M., D=1.50 M., T. NORMAL, EXCAV. MANUAL, ENCOF. INT., C/ELIMIN. MAT. EXCED.	1	2	6	5	4	1	ML menor error
EXCAVACION EN T. NORMAL, MANUAL	3	3	6	3	3	0	Igual
ACERO fy=4200 kg/cm2 GRADO 60, LOSA ANTISOCAVANTE	3	2	3	0	1	-1	PERT menor error
ENCOFRADO Y DESENCOFRADO NORMAL, LOSA ANTISOCAVANTE	3	4	6	3	2	1	ML menor error
CONCRETO f'c=210 kg/cm2, EN LOSA ANTISOCAVANTE	1	2	5	4	3	1	ML menor error
CONCRETO f'c=140 kg/cm2 PARA SOLADOS Y/O SUB-BASES	1	2	1	0	1	-1	PERT menor error
RELLENO COMPACTADO, MATERIAL PROPIO, COMPACTADORA 5.8 HP	1	13	16	15	3	12	ML menor error
CONFORMACION DE SUB-RASANTE PARA LOSA ANTISOCAVANTE	1	3	6	5	3	2	ML menor error

ACABADO BRUÑADO SUPERF. DE LOSA ANTISOCAVANTE	1	2	5	4	3	1	ML menor error
DESCARGA DE DRENAJE PLUVIAL T. SEMIROCOSO, EXCAV. C/EQUIPO, ENCOF. INT. Y EXT., C/ELIMIN. MAT EXCED.	1	9	13	12	4	8	ML menor error

Nota: La cantidad de "ML menor error" fue de 119 y la cantidad "PERT menor error" fue de 18, las actividades de color rojo son las actividades críticas.

Fuente: Elaboración propia.

Tabla 43: Comparación de errores PERT y ML obra " 169592".

DESCRIPCION	Duración Planificada	Duración Predicha	Duración Real	Error Pert	Error ML	Diferencia De Errores	Comparación
CARTEL DE OBRA	1	2	5	4	3	1	ML menor error
CAMPAMENTO PROVISIONAL DE OBRA	5	4	3	2	1	1	ML menor error
MOVILIZACION Y DESMOVILIZACION DE MAQUINARIA	1	2	6	5	4	1	ML menor error
PASOS Y SERVIDUMBRE	1	2	5	4	3	1	ML menor error
LIMPIEZA DE TERRENO MANUAL	4	26	25	21	1	20	ML menor error
REGADO DE VIAS DE ACCESO	4	3	5	1	2	-1	PERT menor error
TRAZO Y REPLANTEO INICIAL	15	15	12	3	3	0	Igual
REPLANTEO DE ALTIMETRIA EN BUZONES	10	3	6	4	3	1	ML menor error
REUBICACION DE PILETAS DE AGUA	3	2	5	2	3	-1	PERT menor error
REPLANTEO ALTIMETRIA EN CAJA CONCRETO KM 0+017.50	4	3	6	2	3	-1	PERT menor error
DEMOLICION DE ESTRUCTURAS DE CONCRETO	3	4	5	2	1	1	ML menor error
REUBICACION DE POSTES ALUMBRADO PUBLICO	4	4	1	3	3	0	Igual
MEJORAMIENTO DE ACCESO - DESVIO	2	3	6	4	3	1	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	1	0	0	0	Igual
CORTE A NIVEL DE SUB RASANTE C/EQUIPO	35	35	32	3	3	0	Igual
RELLENO COMPENSADO A NIVEL DE SUB RASANTE C/EQUIPO	35	4	3	32	1	31	ML menor error
REFINE, PERFILADO Y COMPACTADO DE SUBRASANTE	35	40	43	8	3	5	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	11	10	10	1	0	1	ML menor error
CONFORMACION D/BASE GRANULAR C/MAT PRES H=0.15M	15	40	40	25	0	25	ML menor error
CONFORMACION D/BASE GRANULAR C/MAT PRES H=0.15M	15	40	44	29	4	25	ML menor error
BARRIDO DE BASE GRANULAR	11	12	12	1	0	1	ML menor error
IMPRIMADO RC-250	11	4	1	10	3	7	ML menor error
BARRIDO DE SUPERFICIE IMPRIMADA	11	12	12	1	0	1	ML menor error
CARPETA ASFALTICA EN CALIENTE E=2"	12	40	38	26	2	24	ML menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	2	2	2	0	0	0	Igual

EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	2	15	18	16	3	13	ML menor error
PERFILADO Y COMPACTADO MANUAL	2	2	6	4	4	0	Igual
RELLENO COMPACTADO CON MATERIAL PROPIO	1	1	4	3	3	0	Igual
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	2	5	4	3	1	ML menor error
CONCRETO SOLADO E=2"	1	1	2	1	1	0	Igual
ACERO DE REFUERZO F'Y=4200KG/CM2	8	9	12	4	3	1	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL	11	20	18	7	2	5	ML menor error
MARCO DE F°F° INCLUYE TAPA DE CONCRETO	6	3	5	1	2	-1	PERT menor error
SUMINISTRO E INST. DE RIEL EN DRENAJE	6	5	6	0	1	-1	PERT menor error
CONCRETO FC=210 KG/CM2	6	10	8	2	2	0	Igual
CONCRETO MEDIA CAÑA FC=175 KG/CM2	2	3	2	0	1	-1	PERT menor error
DADO DE ANCLAJE TUBERIA - BUZON, FC=175 KG/CM2	2	3	3	1	0	1	ML menor error
SOLAQUEO INTERIOR DE FUSTE BUZON	6	12	16	10	4	6	ML menor error
MAMPOSTERIA DE PIEDRA 70% PM FC'=210KG/CM2	1	8	6	5	2	3	ML menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	5	12	11	6	1	5	ML menor error
EXCAVACION EN SUELO COMPACTO	5	5	9	4	4	0	Igual
REFINE Y PERFILADO	6	5	6	0	1	-1	PERT menor error
CAMA Y SOBRECAMA DE APOYO (E=0.10M, E=0.15M)	6	5	2	4	3	1	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	7	10	11	4	1	3	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	4	3	3	0	Igual
SUMINISTRO E INSTAL. DE TUB. PVC DESAGUE 200 MM	6	5	5	1	0	1	ML menor error
SUMINISTRO E INSTAL. DE TUB. PVC DESAGUE 250 MM	6	4	2	4	2	2	ML menor error
PRUEBA HIDRAULICA RED DRENAJE DN= 200MM A 250MM	5	7	5	0	2	-2	PERT menor error
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	17	30	31	14	1	13	ML menor error
PERFILADO Y COMPACTADO MANUAL	18	5	4	14	1	13	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	17	2	4	13	2	11	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	3	1	2	1	1	0	Igual
ENCOFRADO Y DESENCOFRADO NORMAL	23	15	12	11	3	8	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	17	6	3	14	3	11	ML menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	17	78	75	58	3	55	ML menor error
PERFILADO Y COMPACTADO A NIVEL DE SUB RASANTE	17	7	9	8	2	6	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	5	5	3	2	2	0	Igual
CONFORM D/BASE GRANULAR C/MAT PRES H=0.15M VEREDA	18	4	8	10	4	6	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL H=0.10M	23	5	5	18	0	18	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	17	8	12	5	4	1	ML menor error
ALISADO, ACABADO Y CURADO	4	9	13	9	4	5	ML menor error
JUNTAS ASFALTICAS	11	12	15	4	3	1	ML menor error
BRUÑADO Y PULIDO DE RAMPAS PEATONALES	17	6	3	14	3	11	ML menor error
CONSTRUCCION DE RAMPAS VEHICULARES	17	4	8	9	4	5	ML menor error
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	23	26	25	2	1	1	ML menor error

PERFILADO Y COMPACTADO MANUAL	23	5	2	21	3	18	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	23	4	1	22	3	19	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	2	1	1	0	Igual
ENCOFRADO Y DESENCOFRADO NORMAL	23	18	19	4	1	3	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	17	6	7	10	1	9	ML menor error
ALISADO, ACABADO Y CURADO	23	2	4	19	2	17	ML menor error
JUNTAS ASFALTICAS	11	6	7	4	1	3	ML menor error
PERFILADO Y COMPACTADO A NIVEL DE SUB RASANTE	23	10	12	11	2	9	ML menor error
CONFORM. PISO BLANDO C/MAT PRES. H=0.10M	23	8	11	12	3	9	ML menor error
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	17	10	9	8	1	7	ML menor error
PERFILADO Y COMPACTADO MANUAL	18	3	2	16	1	15	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	1	2	3	2	1	1	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	3	2	2	0	Igual
ENCOFRADO Y DESENCOFRADO NORMAL	18	20	22	4	2	2	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	11	7	7	4	0	4	ML menor error
ALISADO, ACABADO Y CURADO	11	1	1	10	0	10	ML menor error
JUNTAS ASFALTICAS	2	2	4	2	2	0	Igual
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	6	4	3	3	1	2	ML menor error
PERFILADO Y COMPACTADO MANUAL	5	2	4	1	2	-1	PERT menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	6	3	7	1	4	-3	PERT menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	2	5	4	3	1	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL	7	6	3	4	3	1	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	6	3	4	2	1	1	ML menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	6	1	2	4	1	3	ML menor error
RELLENO COMPACT C/MAT PROPIO A NIVEL DE SUBRASANTE	6	2	5	1	3	-2	PERT menor error
PERFILADO Y COMPACTADO A NIVEL DE SUB RASANTE	5	3	4	1	1	0	Igual
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	3	2	2	0	Igual
CONFORM D/BASE GRANULAR C/MAT PRES H=0.15M VEREDA	6	2	5	1	3	-2	PERT menor error
ENCOFRADO Y DESENCOFRADO NORMAL H=0.10M	7	5	3	4	2	2	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	5	4	6	1	2	-1	PERT menor error
ALISADO, ACABADO Y CURADO	5	1	1	4	0	4	ML menor error
JUNTAS ASFALTICAS	3	2	5	2	3	-1	PERT menor error
BRUÑADO Y PULIDO DE RAMPAS PEATONALES	5	4	7	2	3	-1	PERT menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	5	5	8	3	3	0	Igual
RELLENO COMPACT C/MAT PROPIO	12	4	7	5	3	2	ML menor error
REFINE, PERFILADO Y COMPACTADO FONDO ZANJA	6	3	1	5	2	3	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	3	1	0	2	-2	PERT menor error
CONCRETO SOLADO E=2"	6	3	5	1	2	-1	PERT menor error
ENCOFRADO Y DESENCOFRADO NORMAL	17	6	8	9	2	7	ML menor error
MAMPOSTERIA DE PIEDRA 70% PM FC'=210KG/CM2	12	13	13	1	0	1	ML menor error

CONCRETO CICLOPIO 1:10 C-H + 30% PG.	1	3	3	2	0	2	ML menor error
SOLAQUEO DE MUROS	8	6	7	1	1	0	Igual
ACERO DE REFUERZO F'Y=4200KG/CM2	18	12	12	6	0	6	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL	17	20	22	5	2	3	ML menor error
CONCRETO FC=210 KG/CM2	11	5	5	6	0	6	ML menor error
LAGRIMERAS DIAM 1 PULG	17	3	6	11	3	8	ML menor error
SUMINISTRO E INST BARANDA METALICA	12	5	2	10	3	7	ML menor error
JUNTAS ASFALTICAS	2	2	5	3	3	0	Igual
PINTURA D/PASO PEATONAL Y SIMBOLOS DIRECCIONALES	12	11	11	1	0	1	ML menor error
EXCAVACION EN SUELO COMPACTO	6	2	4	2	2	0	Igual
PERFILADO Y COMPACTADO MANUAL	2	2	2	0	0	0	Igual
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	2	1	4	2	3	-1	PERT menor error
CONCRETO FC=210 KG/CM2 EN GIBA	2	3	1	1	2	-1	PERT menor error
PINTURA EN GIBA	2	2	5	3	3	0	Igual
SEÑALIZACION INFORMATIVA Y PREVENTIVA EN VIA	6	3	2	4	1	3	ML menor error
CORTE A NIVEL DE SUB RASANTE C/EQUIPO	18	30	27	9	3	6	ML menor error
RELLENO COMPENSADO A NIVEL DE SUB RASANTE C/EQUIPO	18	2	3	15	1	14	ML menor error
REFINE, PERFILADO Y COMPACTADO DE SUBRASANTE	18	40	41	23	1	22	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	23	40	39	16	1	15	ML menor error
CONFORMACION D/BASE GRANULAR C/MAT PRES H=0.15M	19	40	44	25	4	21	ML menor error
CONFORMACION D/BASE GRANULAR C/MAT PRES H=0.15M	19	40	39	20	1	19	ML menor error
BARRIDO DE BASE GRANULAR	23	12	12	11	0	11	ML menor error
IMPRIMADO RC-250	23	4	6	17	2	15	ML menor error
BARRIDO DE SUPERFICIE IMPRIMADA	23	12	13	10	1	9	ML menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	2	2	6	4	4	0	Igual
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	2	10	11	9	1	8	ML menor error
PERFILADO Y COMPACTADO MANUAL	2	2	2	0	0	0	Igual
RELLENO COMPACTADO CON MATERIAL PROPIO	1	1	2	1	1	0	Igual
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	2	1	1	0	Igual
CONCRETO SOLADO E=2"	3	1	1	2	0	2	ML menor error
ACERO DE REFUERZO F'Y=4200KG/CM2	5	7	11	6	4	2	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL	14	9	13	1	4	-3	PERT menor error
MARCO DE F°F° INCLUYE TAPA DE CONCRETO	2	3	6	4	3	1	ML menor error
SUMINISTRO E INST. DE RIEL EN DRENAJE	2	4	2	0	2	-2	PERT menor error
CONCRETO FC=210 KG/CM2	5	5	5	0	0	0	Igual
CONCRETO MEDIA CAÑA FC=175 KG/CM2	2	8	8	6	0	6	ML menor error
DADO DE ANCLAJE TUBERIA - BUZON, FC=175 KG/CM2	2	2	6	4	4	0	Igual
SOLAQUEO INTERIOR DE FUSTE BUZON	2	4	6	4	2	2	ML menor error
MAMPOSTERIA DE PIEDRA 70% PM FC'=210KG/CM2	2	8	8	6	0	6	ML menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	4	4	4	0	0	0	Igual

EXCAVACION EN SUELO COMPACTO	4	2	4	0	2	-2	PERT menor error
REFINE Y PERFILADO	2	3	1	1	2	-1	PERT menor error
CAMA Y SOBRECAMA DE APOYO (E=0.10M, E=0.15M)	2	6	7	5	1	4	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	2	4	2	0	2	-2	PERT menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	4	3	3	0	Igual
SUMINISTRO E INSTAL. DE TUB. PVC DESAGUE 200 MM	2	6	7	5	1	4	ML menor error
PRUEBA HIDRAULICA RED DRENAJE DN= 200MM A 250MM	2	24	27	25	3	22	ML menor error
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	3	15	16	13	1	12	ML menor error
PERFILADO Y COMPACTADO MANUAL	2	2	5	3	3	0	Igual
RELLENO COMPACTADO CON MATERIAL PROPIO	1	3	5	4	2	2	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	2	1	0	1	-1	PERT menor error
ENCOFRADO Y DESENCOFRADO NORMAL	6	5	5	1	0	1	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	2	4	4	2	0	2	ML menor error
EXCAVACION DE ZANJA EN TERR. NORMAL	3	4	8	5	4	1	ML menor error
PERFILADO Y COMPACTADO A NIVEL DE SUB RASANTE	2	2	3	1	1	0	Igual
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	5	4	4	0	Igual
CONFORM D/BASE GRANULAR C/MAT PRES H=0.15M VEREDA	1	1	1	0	0	0	Igual
ENCOFRADO Y DESENCOFRADO NORMAL H=0.10M	4	5	8	4	3	1	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	2	4	7	5	3	2	ML menor error
ALISADO, ACABADO Y CURADO	1	1	4	3	3	0	Igual
JUNTAS ASFALTICAS	1	2	5	4	3	1	ML menor error
BRUÑADO Y PULIDO DE RAMPAS PEATONALES	2	3	4	2	1	1	ML menor error
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	30	30	30	0	0	0	Igual
PERFILADO Y COMPACTADO MANUAL	31	9	13	18	4	14	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	6	5	7	1	2	-1	PERT menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	1	2	1	1	0	Igual
ENCOFRADO Y DESENCOFRADO NORMAL	34	29	26	8	3	5	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	29	5	7	22	2	20	ML menor error
ALISADO, ACABADO Y CURADO	29	1	4	25	3	22	ML menor error
JUNTAS ASFALTICAS	2	2	5	3	3	0	Igual
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	30	39	40	10	1	9	ML menor error
PERFILADO Y COMPACTADO MANUAL	31	41	43	12	2	10	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	3	4	8	5	4	1	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	1	2	5	4	3	1	ML menor error
ENCOFRADO Y DESENCOFRADO NORMAL	30	36	39	9	3	6	ML menor error
CONCRETO SIMPLE F'C=175 KG/CM2	31	14	14	17	0	17	ML menor error
ALISADO, ACABADO Y CURADO	29	4	2	27	2	25	ML menor error
JUNTAS ASFALTICAS	6	4	1	5	3	2	ML menor error
PINTURA D/PASO PEATONAL Y SIMBOLOS DIRECCIONALES	6	7	10	4	3	1	ML menor error
EXCAVACION EN SUELO COMPACTO	6	6	4	2	2	0	Igual

PERFILADO Y COMPACTADO MANUAL	6	5	5	1	0	1	ML menor error
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	5	1	2	3	1	2	ML menor error
CONCRETO FC=210 KG/CM2 EN GIBA	5	6	6	1	0	1	ML menor error
PINTURA EN GIBA	6	6	8	2	2	0	Igual

Nota: La cantidad de "ML menor error" fue de 121 y la cantidad "PERT menor error" fue de 26, las actividades de color rojo son las actividades críticas.

Fuente: Elaboración propia.

Tabla 44: Comparación de errores PERT y ML obra "500532".

DESCRIPCION	Duración Planificada	Duración Predicha	Duración Real	Error Pert	Error ML	Diferencia De Errores	Comparación
CARTEL DE OBRA (BANNER 3.60 x 2.40 M.)	2	3	7	5	4	1	ML menor error
CASETA DE GUARDIANIA, OFICINA Y ALMACEN PROVISIONAL DE OBRA	3	4	7	4	3	1	ML menor error
CERCO PROVICIONAL CON PUNTAL Y ESTERA	5	5	3	2	2	0	Igual
AGUA PROVISIONAL PARA LA OBRA	8	4	4	4	0	4	ML menor error
ENERGIA ELECTRICA PROVICIONAL	8	4	6	2	2	0	Igual
COMEDOR PROVISIONAL P/PERSONAL	1	2	4	3	2	1	ML menor error
SERVICIOS HIGIENICOS PORTATILES	8	4	8	0	4	-4	PERT menor error
VESTUARIOS PROVISIONALES P/PERSONAL	1	2	4	3	2	1	ML menor error
MOVILIZACION Y DESMOVILIZACION DE EQUIPO	1	2	2	1	0	1	ML menor error
TRAZO NIVELES Y REPLANTEO PRELIMINAR	10	10	13	3	3	0	Igual
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	10	7	5	5	2	3	ML menor error
CORTE DE MATERIAL SUELTO DE SUBRASANTE PARA BASE	10	30	34	24	4	20	ML menor error
RELLENO COMPENSADO CON MATERIAL PROPIO	10	20	20	10	0	10	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	20	20	17	3	3	0	Igual
ELIMINACION DE ESCOMBROS EN T.N. C/E (D<=5 KM)	1	2	2	1	0	1	ML menor error
CONFORMACION DE SUBRASANTE	15	72	70	55	2	53	ML menor error
CONFORMACION DE BASE GRANULAR (E=0.20M)	15	60	58	43	2	41	ML menor error
BARRIDO DE SUPERFICIE PARA BASE GRANULAR	30	10	7	23	3	20	ML menor error
IMPRIMACION ASFALTICA CON MC130	10	12	13	3	1	2	ML menor error
CARPETA ASFALTICA EN FRIO E=2"	10	17	19	9	2	7	ML menor error
ARENADO SUPERFICIAL DE PROTECCION DE CARPETA	20	20	17	3	3	0	Igual
NIVELACION DE BUZONES	14	15	12	2	3	-1	PERT menor error
MARCAS EN EL PAVIMENTO (LINEA CONTINUA)	17	7	10	7	3	4	ML menor error
MARCAS EN EL PAVIMENTO (SIMBOLOS y LETRAS)	16	15	15	1	0	1	ML menor error
SEÑALIZACION VERTICAL	20	20	20	0	0	0	Igual

PRUEBA DE CALIDAD PARA BASE GRANULAR	1	2	5	4	3	1	ML menor error
PRUEBA DE ASFALTOS (CONTROL DE CALIDAD)	1	2	4	3	2	1	ML menor error
ROMPEMUELLES	1	2	5	4	3	1	ML menor error
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	10	9	10	0	1	-1	PERT menor error
CORTE DE MATERIAL SUELTO DE SUBRASANTE PARA BASE	4	8	12	8	4	4	ML menor error
NIVELACION Y COMPACTACION PARA BERMAS	18	20	22	4	2	2	ML menor error
CONFORMACION DE BASE GRANULAR (E=0.10M)	18	15	14	4	1	3	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	4	6	10	6	4	2	ML menor error
CAMA DE ASIENTO CON ARENA E=0.04M	13	30	34	21	4	17	ML menor error
ADOQUIN DE CONCRETO E=8CM	12	25	27	15	2	13	ML menor error
EXCAVACION MANUAL PARA SARDINELES	17	15	18	1	3	-2	PERT menor error
ACARREO DE MATERIAL EXCAVADO A ZONA QUE PERMITA ELIMINAR	18	10	11	7	1	6	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	1	5	5	4	0	4	ML menor error
CONCRETO F'C=175 KG/CM2 PARA SARDINELES	13	11	15	2	4	-2	PERT menor error
JUNTAS ASFALTICA DE E=1" EN SARDINELES	5	3	5	0	2	-2	PERT menor error
PINTURA DE TRAFICO EN SARDINEL	13	11	15	2	4	-2	PERT menor error
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	13	8	7	6	1	5	ML menor error
CORTE SUPERFICIAL MANUAL	13	20	21	8	1	7	ML menor error
EXCAVACION MANUAL PARA TALON PROTECTOR DE VEREDAS	15	15	17	2	2	0	Igual
NIVELACION Y COMPACTACION PARA VEREDAS	17	30	34	17	4	13	ML menor error
DEMOLICION DE VEREDAS EXISTENTES CON EQUIPO	3	2	6	3	4	-1	PERT menor error
CONFORMACION DE BASE GRANULAR (E=0.10M)	14	11	15	1	4	-3	PERT menor error
ACARREO DE MATERIAL EXCAVADO A ZONA QUE PERMITA ELIMINAR	28	20	19	9	1	8	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	11	15	16	5	1	4	ML menor error
CONCRETO F'C=175 KG/CM2 EN VEREDAS DE E=10 CM ACAB. C.A. 1:2 E=1 CM	10	30	30	20	0	20	ML menor error
CONCRETO F'C=175 KG/CM2 EN VEREDAS PODOTACTIL DE E=10 CM ACAB. C.A. 1:2 E=1 CM	10	20	17	7	3	4	ML menor error
CONCRETO EN GRADERIAS F'C=175 KG/CM2 INC ACAB.	1	4	5	4	1	3	ML menor error
SARDINEL DE BORDE CONCRETO F'c = 175 kg/cm2	22	8	11	11	3	8	ML menor error
ENCOFRADO Y DESENCOFRADO DE BORDES Y FILOS	26	7	11	15	4	11	ML menor error
CURADO DE VEREDAS	15	38	42	27	4	23	ML menor error
BRUÑADO EN VEREDAS	15	30	29	14	1	13	ML menor error
NIVELACION Y RECONEXION DE MEDIDORES DE AGUA	1	15	17	16	2	14	ML menor error
NIVELACION Y RECONEXION DE CAJAS DE DESAGUE	10	30	33	23	3	20	ML menor error
JUNTAS ASFALTICA EN VEREDAS E=1"	10	19	19	9	0	9	ML menor error
PINTURA DE TRAFICO EN BORDES DE VEREDA	14	15	16	2	1	1	ML menor error
CONSTRUCCION DE PARADEROS	1	5	4	3	1	2	ML menor error
EXCAVACION MANUAL PARA JARDINERAS	16	23	27	11	4	7	ML menor error
RELLENO CON MATERIAL PROPIO MANUAL	24	4	1	23	3	20	ML menor error
ENCOFRADO Y DESENCOFRADO DE JARDINERAS	24	26	26	2	0	2	ML menor error
CONCRETO F'c 175 kg/cm2 PARA JARDINERAS	9	19	20	11	1	10	ML menor error

TARRAJEO DE MUROS ACABADO CON C1A 1:4	20	13	14	6	1	5	ML menor error
CURADO DE JARDINERAS	12	10	7	5	3	2	ML menor error
JUNTAS ASFALTICA EN JARDINERAS E=1"	2	4	3	1	1	0	Igual
PINTURA DE TRAFICO EN JARDINERA	13	13	17	4	4	0	Igual
SEMBRADO DE PLANTONES (ARBOLES ORNAMENTALES)	25	10	10	15	0	15	ML menor error
RELLENO DE AREA DE PLANTONES CON TIERRA VEGETAL	8	4	6	2	2	0	Igual
SEMBRADO DE GRASS EN AREAS VERDES	10	9	8	2	1	1	ML menor error
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	2	2	2	0	0	0	Igual
EXCAVACION DE ZANJAS EN TERRENO NORMAL	11	14	16	5	2	3	ML menor error
RELLENO COMPENSADO CON MATERIAL PROPIO	1	3	7	6	4	2	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	8	4	3	5	1	4	ML menor error
SOLADO DE CONCRETO DE 2"	15	32	31	16	1	15	ML menor error
CONCRETO F'C=175 KG/CM2 PARA MUROS CONTENCION	11	7	7	4	0	4	ML menor error
CONCRETO F'C=210 KG/CM2 PARA MUROS CONTENCION	16	6	8	8	2	6	ML menor error
ENCOFRADO Y DESENCOFRADO CARAVISTA EN MURO DE CONTENCION	18	15	16	2	1	1	ML menor error
ACERO ESTRUCTURAL FY=4200 KG/CM2 GRADO 60	6	42	44	38	2	36	ML menor error
CURADO DE MUROS DE CONTENCION	4	5	5	1	0	1	ML menor error
JUNTAS DE CONSTRUCCION EN MUROS DE CONTENCION E=1"	6	7	4	2	3	-1	PERT menor error
BARANDA METALICA C/TUBO REDONDO 2.5" H=1.0 M	1	3	2	1	1	0	Igual
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	1	2	4	3	2	1	ML menor error
EXCAVACION DE ZANJAS EN TERRENO NORMAL	4	3	2	2	1	1	ML menor error
RELLENO COMPENSADO CON MATERIAL PROPIO	1	2	4	3	2	1	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	1	2	2	1	0	1	ML menor error
SUMINISTRO Y COLOCACION DE GAVIONES DE PIEDRA	6	4	3	3	1	2	ML menor error
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	2	3	3	1	0	1	ML menor error
EXCAVACION DE ZANJAS EN TERRENO NORMAL	7	5	2	5	3	2	ML menor error
REFINE Y NIVELACION DE ZANJA T.N. A= 1.0 M	9	3	3	6	0	6	ML menor error
CAMA DE ARENA A= 1.0 1 1.5 M MAT. ZARANDEADO	8	4	8	0	4	-4	PERT menor error
RELLENO PROTECTOR H = 0.30 MTS A= 1 1 1.5 M	8	7	4	4	3	1	ML menor error
RELLENO APISONADO DE.ZANJA T.N. T.S.R. H = 1.50	8	5	3	5	2	3	ML menor error
BUZON TIPO I HASTA H=1.50 M TERRENO NORMAL COMPACTO	2	2	5	3	3	0	Igual
BUZON TIPO II HASTA H=3.00 M TERRENO NORMAL COMPACTO	5	3	2	3	1	2	ML menor error
SUMINISTRO E INSTALACION DE TUBERIA HDP D=400 MM	3	3	3	0	0	0	Igual
PRUEBA HIDRAULICA EN TUBERIA DE DRENAJE D=0.8 1 1.2 M	4	2	5	1	3	-2	PERT menor error
EXCAVACION MANUAL PARA BOCATORMENTA	7	34	38	31	4	27	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	1	2	6	5	4	1	ML menor error
SOLADO DE CONCRETO DE 2"	6	5	5	1	0	1	ML menor error
CONCRETO EN ALCANTARILLA F'C=210 KG/CM2	4	7	7	3	0	3	ML menor error
ENCOFRADO Y DESENCOFRADO EN ALCANTARILLAS	10	43	40	30	3	27	ML menor error

ACERO ESTRUCTURAL FY=4200 KG/CM2 GRADO 60	6	9	6	0	3	-3	PERT menor error
REJILLA DE CONCRETO	4	3	2	2	1	1	ML menor error
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	4	2	4	0	2	-2	PERT menor error
EXCAVACION MANUAL PARA CUNETAS	13	30	32	19	2	17	ML menor error
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	1	2	2	1	0	1	ML menor error
NIVELACION Y COMPACTACION PARA BERMAS	6	5	8	2	3	-1	PERT menor error
CONFORMACION DE BASE GRANULAR (E=0.10M)	4	5	4	0	1	-1	PERT menor error
CONCRETO F'C=175 KG/CM2 PARA CUNETAS	7	6	4	3	2	1	ML menor error
ENCOFRADO Y DESENCOFRADO DE CUNETAS	7	7	6	1	1	0	Igual
CURADO DE CUNETAS	8	3	2	6	1	5	ML menor error
JUNTAS ASFALTICA EN CUNETAS E=1"	6	3	2	4	1	3	ML menor error
RELLENO COMPACTADO CON MATERIAL PROPIO	4	2	6	2	4	-2	PERT menor error
ENCOFRADO Y DESENCOFRADO PAREDES DE CANAL	6	15	24	18	9	9	ML menor error
CONCRETO SIMPLE F´C=175 KG/CM2 DE PAREDES DE CANAL	18	6	9	9	3	6	ML menor error
CONCRETO SIMPLE F´C=175 KG/CM2 DE FONDO DE CANAL	12	5	8	4	3	1	ML menor error
LOZA DE TECHO DE CONCRETO ARMADO F´C=210 KG/CM2 PREFABRICADA 1X0.50X0.20 LOSA	0	77	75	75	2	73	ML menor error
LOZA DE TECHO DE CONCRETO ARMADO F´C=210 KG/CM2 PREFABRICADA 1X0.50X0.20 LOSA	8	2	4	4	2	2	ML menor error
LOZA DE TECHO FIJO CONCRETO ARMADO F´C =210 Kg/cm2	6	28	31	25	3	22	ML menor error
ACERO ESTRUCTURAL FY=4200 KG/CM2 PARA ESTRUCTURA DE CANAL	6	0	1	5	1	4	ML menor error
PRUEBA DE CALIDAD DE CONCRETO (DISEÑO DE MEZCLAS)	2	2	5	3	3	0	Igual
PRUEBA DE CALIDAD DE CONCRETO (ROTURA DE PROBETAS)	20	90	94	74	4	70	ML menor error
MEDIDAS DE MITIGACION AMBIENTAL	2	2	6	4	4	0	Igual
LIMPIEZA FINAL DE OBRA	21	77	74	53	3	50	ML menor error

Nota: La cantidad de “ML menor error” fue de 93 y la cantidad “PERT menor error” fue de 17, las actividades de color rojo son las actividades críticas.

Fuente: Elaboración propia.

Tabla 45: Comparación de errores PERT y ML obra "559764".

DESCRIPCION	Duración Planificada	Duración Predicha	Duración Real	Error Pert	Error ML	Diferencia De Errores	Comparación
NIVELACION Y COMPACTACION DE SUBRASANTE	3	3	3	0	0	0	Igual
CONFORMACION DE SUBBASE E=15 CM	6	5	4	2	1	1	ML menor error
CONFORMACON DE BASE GRANULAR E=15 CM	6	5	4	2	1	1	ML menor error
BARRIDO DE SUPERFICIE DE BASE GRANULAR PARA IMPRIMAR	1	1	1	0	0	0	Igual

IMPRIMACION ASFALTICA C/EQUIPO	3	2	1	2	1	1	ML menor error
BARRIDO DE SUPERFICIE IMPRIMADA	1	1	1	0	0	0	Igual
CARPETA ASFALTICA EN CALIENTE E=2" C/EQUIPO	2	1	1	1	0	1	ML menor error

Nota: La cantidad de "ML menor error" fue de 4 y la cantidad "PERT menor error" fue de 0, las actividades de color rojo son las actividades críticas.

Fuente: Elaboración propia.

Tabla 46:
Comparación de errores PERT y ML obra "557503"

DESCRIPCION	Duración Planificada	Duración Predicha	Duración Real	Error Pert	Error ML	Diferencia De Errores	Comparación
CORTE DE TERRENO A NIVEL DE SUB RASANTE PAVIMENTO TERRENO NORMAL C/MAQUINARIA	3	2	2	1	0	1	ML menor error
ESCARIFICADO DE SUB RASANTE A PROFUNDIDAD H=0.15 M C/MAQUINARIA	3	2	2	1	0	1	ML menor error
NIVELACION Y COMPACTACION DE SUB RASANTE PAVIMENTO AL 95% PROCTOR MODIFICADO C/MAQUINARIA	3	2	2	1	0	1	ML menor error
CONFORMACION Y COMPACTACION DE BASE GRANULAR E=0.20M PAVIMENTO AL 100% PROCTOR MODIFICADO C/MAQUINARIA	6	5	4	2	1	1	ML menor error
ACARREO Y ACOPIO C/EQUIPO MAT. EXCAV. DIST. 50 M	4	5	4	0	1	-1	PERT menor error
ELIMINACION MAT. EXCAV. CARG. 125 HP / VOLQUETE 15 M3 D=15 KM	4	5	4	0	1	-1	PERT menor error
CAMA DE ARENA H=0.04M	5	4	3	2	1	1	ML menor error
DESCARGUIO DE ADOQUINES	5	2	1	4	1	3	ML menor error
ACARREO DE ADOQUINES	7	6	7	0	1	-1	PERT menor error
COLOCACION DE ADOQUINES 20X10X8 CM F'C 420 KG/CM2	22	17	14	8	3	5	ML menor error
SELLO O PARCHADO DE JUNTAS CON ARENA FINA	6	3	6	0	3	-3	PERT menor error
COMPACTADO FINAL CON EQUIPO LIVIANO	8	2	4	4	2	2	ML menor error

Nota: La cantidad de "ML menor error" fue de 8 y la cantidad "PERT menor error" fue de 4, las actividades de color rojo son las actividades críticas.

Fuente: Elaboración propia.

5.4.3. Análisis estadístico de los errores pareados

Se realizó un análisis estadístico de los errores pareados para comparar el desempeño del modelo de Machine Learning frente al método PERT. Para ello, se analizaron los errores obtenidos por ambos métodos en los mismos casos de estudio y, según la distribución de las diferencias, se aplicó la prueba estadística correspondiente para determinar si la diferencia observada era estadísticamente significativa.

Tabla 47: Estadísticos descriptivos de la obra "169730".

Estadísticos descriptivos		Error Pert	Error ML	Diferencia de Errores
Media (Promedio)		5,263	1,960	3,303
95% de intervalo de confianza para la media	**Límite inferior**	4,414	1,774	2,472
	Límite superior	6,111	2,146	4,134
Media recortada al 5%		4,533	1,949	2,530
Mediana		4,000	2,000	1,000
Varianza		32,333	1,556	31,028
Desv. estándar		5,686	1,247	5,570
Mínimo		0,0	0,0	-3,0
Máximo		38,0	5,0	35,0
Asimetría		2,554	0,166	2,740
Curtosis		8,925	-0,926	9,624

Nota: Estadísticos descriptivos se trabajó en SPSS, pero igual se hizo la verificación de la media, mediana, deviación estándar, asimetría y curtosis en una hoja de Excel.

Fuente: Elaboración propia.

Tabla 48: Pruebas de normalidad de la obra "169730".

	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	**gl**	**Sig.**	**Estadístico**	**gl**	**Sig.**
Error Pert	0,221	175	<0,001	0,745	175	<0,001
Error ML	0,191	175	<0,001	0,916	175	<0,001
Diferencia de Errores	0,250	175	<0,001	0,697	175	<0,001

Nota: Se elije la significancia de la diferencia no porque queremos compáralos si no porque queremos saber cuál de ellos se aproxima mejor a la duración real.

Fuente: Elaboración Propia.

HIPOTESIS

Nivel de confiabilidad de $\alpha=0.05$

- H_0: los datos siguen una distribución normal.
- H_1: los datos no siguen una distribución normal.
- Si $p > 0.05$, no rechazas H_0: no hay evidencia contra la normalidad.
- Si $p < 0.05$, rechazas H_0: los datos se desvían de la normalidad.

En la obra “"169730" obtenemos que la significancia es de $p<0.05$ por lo tanto, las diferencias entre los errores absolutos de PERT y Machine Learnimg no siguen una distribución compatible con la normalidad según esta prueba, se rechazó la normalidad, por lo que se utilizó Wilcoxon.

Tabla 49: Estadísticos de Prueba Wilcoxon "169730".

Estadísticos de prueba	
Error ML - Error Pert	
Z	-8,824
Sig. asin. (bilateral)	<,001

Nota: El valor de Z y la significación no bastan para determinar cuál método tiene menor error. Necesitamos revisar las medias o medianas de los errores absolutos.

Fuente: Elaboración propia.

INTERPRETACION DE WILCOXON

- Si $p < 0.05$, existe evidencia estadística de una diferencia entre los errores de PERT y ML.
- Si $p \geq 0.05$, no hay evidencia suficiente para afirmar que los errores difieren estadísticamente.

Como ($p < 0.001 < 0.05$), se rechaza la hipótesis nula. Existe una diferencia estadísticamente significativa entre los errores absolutos de PERT y Machine Learning.

Tabla 50: Comparación de resultados obra"169730".

	Error Pert	**Error ML**	**Reducción Media del error**
Media (Promedio)	5,263	1,960	62,76%

Nota: Elegimos la media porque no es una distribución normal.

Fuente: Elaboración propia.

Esto representa una reducción del 62.74 % en el error absoluto medio al utilizar Machine Learning respecto a PERT, los resultados favorecen al modelo de Machine Learning por presentar menores errores de predicción.

Tabla 51: Estadísticos descriptivos de la obra "169592".

Estadísticos descriptivos		Error Pert	Error ML	Diferencia de Errores
Media (Promedio)		6,439	1,915	4,524
95% de intervalo de confianza para la media	**Límite inferior**	5,321	1,734	3,418
	Límite superior	7,557	2,097	5,630
Media recortada al 5%		5,495	1,906	3,616
Mediana		4	2	1
Varianza		60,716	1,599	59,410
Desv. estándar		7,792	1,265	7,708
Mínimo		0	0	-3
Máximo		58	4	55
Asimetría		2,607	-0,047	2,597
Curtosis		10,472	-1,126	10,123

Nota: Estadísticos descriptivos se trabajó en SPSS, pero igual se hizo la verificación de la media, mediana, deviación estándar, asimetría y curtosis en una hoja de Excel.

Fuente: Elaboración propia.

Tabla 52: Pruebas de normalidad de la obra "169592".

	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	**gl**	**Sig.**	**Estadístico**	**gl**	**Sig.**
Error Pert	0,251	189,000	<0,001	0,727	189,000	<0,001
Error ML	0,191	189,000	<0,001	0,902	189,000	<0,001
Diferencia de Errores	0,247	189,000	<0,001	0,715	189,000	<0,001

Nota: Estamos tomando la significancia de la diferencia no porque queremos compáralos si no porque queremos saber cuál de ellos se aproxima mejor a la duración real.

Fuente: Elaboración Propia.

HIPOTESIS

Nivel de confiabilidad de $\alpha=0.05$

- H_0: los datos siguen una distribución normal.
- H_1: los datos no siguen una distribución normal.
- Si $p > 0.05$, no rechazas H_0: no hay evidencia contra la normalidad.
- Si $p < 0.05$, rechazas H_0: los datos se desvían de la normalidad.

En la obra "169592" obtenemos que la significancia es de $p<0.05$ por lo tanto, las diferencias entre los errores absolutos de PERT y ML no siguen una distribución compatible con la normalidad según esta prueba, se rechazó la normalidad, por lo que se utilizó Wilcoxon.

Tabla 53: Estadísticos de Prueba Wilcoxon "169592".

Estadísticos de prueba	
	Error ML - Error Pert
Z	-8,541
Sig. asin. (bilateral)	<0,001

Nota: El valor de Z y la significación no bastan para determinar cuál método tiene menor error. Necesitamos revisar las medias o medianas de los errores absolutos.

Fuente: Elaboración propia.

INTERPRETACION DE WILCOXON

- Si $p < 0.05$, existe evidencia estadística de una diferencia entre los errores de PERT y ML.
- Si $p \geq 0.05$, no hay evidencia suficiente para afirmar que los errores difieren estadísticamente.

Como ($p < 0.001 < 0.05$), se rechaza la hipótesis nula. Existe una diferencia estadísticamente significativa entre los errores absolutos de PERT y Machine Learning.

Tabla 54: Comparación de resultados obra"169592".

	Error Pert	Error ML	Reducción Media del error
Media (Promedio)	6,439	1,915	70,255%

Nota: Elegimos la media porque no es una distribución normal.

Fuente: Elaboración propia.

Esto representa una reducción del 70.25 % en el error absoluto medio al utilizar Machine Learning respecto a PERT, los resultados favorecen al modelo de Machine Learning por presentar menores errores de predicción.

Tabla 55: Estadísticos descriptivos de la obra "500532".

Estadísticos descriptivos		Error Pert	Error ML	Diferencia de Errores
Media		8,638	2,063	6,575
95% de intervalo de confianza para la media	**Límite inferior**	6,350	1,802	4,331
	Límite superior	10,926	2,324	8,818
Media recortada al 5%		6,545	2,026	4,560
Mediana		4	2	2
Varianza		169,773	2,202	163,215
Desv. estándar		13,030	1,484	12,776
Mínimo		0	0	-4
Máximo		75	9	73
Asimetría		3,111	0,734	3,158
Curtosis		11,176	2,186	11,566

Nota: Estadísticos descriptivos se trabajó en SPSS, pero igual se hizo la verificación de la media, mediana, deviación estándar, asimetría y curtosis en una hoja de Excel.

Fuente: Elaboración propia.

Tabla 56: Pruebas de normalidad de la obra "500532".

	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	**Gl**	**Sig.**	**Estadístico**	**gl**	**Sig.**
Error Pert	0,273	127,000	<0,001	0,610	127,000	<0,001
Diferencia de Errores	0,265	127,000	<0,001	0,616	127,000	<0,001
Error ML	0,157	127,000	<0,001	0,889	127,000	<0,001

Nota: Estamos tomando la significancia de la diferencia no porque queremos compáralos si no porque queremos saber cuál de ellos se aproxima mejor a la duración real.

Fuente: Elaboración Propia.

INTERPRETACION DE WILCOXON

- Si $p < 0.05$, existe evidencia estadística de una diferencia entre los errores de PERT y ML.
- Si $p \geq 0.05$, no hay evidencia suficiente para afirmar que los errores difieren estadísticamente.

Como ($p < 0.001 < 0.05$), se rechaza la hipótesis nula. Existe una diferencia estadísticamente significativa entre los errores absolutos de PERT y Machine Learning.

Tabla 57: Estadísticos de Prueba Wilcoxon "500532".

Estadísticos de prueba	
	Error ML - Error Pert
Z	-7,254
Sig. asin. (bilateral)	<0,001

Nota: El valor de Z y la significación no bastan para determinar cuál método tiene menor error. Necesitamos revisar las medias o medianas de los errores absolutos.

Fuente: Elaboración propia.

INTERPRETACION DE WILCOXON

- Si $p < 0.05$, existe evidencia estadística de una diferencia entre los errores de PERT y ML.
- Si $p \geq 0.05$, no hay evidencia suficiente para afirmar que los errores difieren estadísticamente.

Como ($p < 0.001 < 0.05$), se rechaza la hipótesis nula. Existe una diferencia estadísticamente significativa entre los errores absolutos de PERT y Machine Learning.

Tabla 58: Comparación de resultados obra"500532".

	Error Pert	**Error ML**	**Reducción Media del error**
Media	8,638	2,063	76,117%

Nota: Elegimos la media porque no es una distribución normal.

Fuente: Elaboración propia.

Esto representa una reducción del 76.12 % en el error absoluto medio al utilizar Machine Learning respecto a PERT, los resultados favorecen al modelo de Machine Learning por presentar menores errores de predicción.

Tabla 59: Estadísticos descriptivos de la obra "559764".

Estadísticos descriptivos		Error Pert	Error ML	Diferencia de Errores
Media (Promedio)		1,000	0,429	0,571
95% de intervalo de confianza para la media	**Límite inferior**	0,075	-0,066	0,077
	Límite superior	1,925	0,923	1,066
Media recortada al 5%		1,000	0,421	0,579
Mediana		1	0	1,000
Varianza		1,000	0,286	0,286
Desv. estándar		1,000	0,535	0,535
Mínimo		0	0	0
Máximo		2	1	1
Asimetría		0,000	0,374	-0,374
Curtosis		-2,600	-2,800	-2,800

Nota: Estadísticos descriptivos se trabajó en SPSS, pero igual se hizo la verificación de la media, mediana, deviación estándar, asimetría y curtosis en una hoja de Excel.

Fuente: Elaboración propia.

Tabla 60: Pruebas de normalidad de la obra "559764".

	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	**gl**	**Sig.**	**Estadístico**	**gl**	**Sig.**
Error Pert	0,270	7,000	0,133	0,759	7,000	0,016
Error ML	0,360	7,000	0,007	0,664	7,000	0,001
Diferencia de Errores	0,360	7,000	0,007	0,664	7,000	0,001

Nota: Estamos tomando la significancia de la diferencia no porque queremos compáralos si no porque queremos saber cuál de ellos se aproxima mejor a la duración real.

Fuente: Elaboración Propia.

HIPOTESIS

Nivel de confiabilidad de α=0.05

- H_0: los datos siguen una distribución normal.
- H_1: los datos no siguen una distribución normal.
- Si $p > 0.05$, no rechazas H_0: no hay evidencia contra la normalidad.
- Si $p < 0.05$, rechazas H_0: los datos se desvían de la normalidad.

En la obra "559764" me sale que la significancia es de $p<0.05$ por lo tanto, las diferencias entre los errores absolutos de PERT y ML no siguen una distribución compatible con la normalidad según esta prueba, se rechazó la normalidad, por lo que se utilizó Wilcoxon.

Tabla 61: Estadísticos de Prueba Wilcoxon "559764".

Estadísticos de prueba	
	Error ML - Error Pert
Z	-2,000
Sig. asin. (bilateral)	0,125

Nota: El valor de Z y la significación no bastan para determinar cuál método tiene menor error. Necesitamos revisar las medias o medianas de los errores absolutos.

Fuente: Elaboración propia.

INTERPRETACION DE WILCOXON

- Si $p < 0.05$, existe evidencia estadística de una diferencia entre los errores de PERT y ML.
- Si $p \geq 0.05$, no hay evidencia suficiente para afirmar que los errores difieren estadísticamente.

La significación exacta da $p=0.125$, superior a 0.05. Con solo cuatro diferencias distintas de cero, conviene priorizar la prueba exacta y reconocer que la evidencia estadística es limitada.

Tabla 62: Comparación de resultados obra"559764".

	Error Pert	Error ML	Reducción Media del error
Media (Promedio)	1,0	0,429	57,143%

Nota: Elegimos la media porque no es una distribución normal.

Fuente: Elaboración propia.

Esto representa una reducción del 57.14 % en el error absoluto medio al utilizar Machine Learning respecto a PERT, los resultados favorecen al modelo de Machine Learning por presentar menores errores de predicción.

Tabla 63: Estadísticos descriptivos de la obra "557503"

Estadísticos descriptivos		Error Pert	Error ML	Diferencia de Errores
Media		1,917	1,167	0,750
95% de intervalo de confianza para la media	**Límite inferior**	0,397	0,512	-0,581
	Límite superior	3,436	1,821	2,081
Media recortada al 5%		1,685	1,130	0,722
Mediana		1	1	1,000
Varianza		5,720	1,061	4,386
Desv. estándar		2,392	1,030	2,094
Mínimo		0,000	0,000	-3,000
Máximo		8,000	3,000	5,000
Asimetría		1,697	0,810	0,254
Curtosis		3,015	-0,022	0,719

Nota: Estadísticos descriptivos se trabajó en SPSS, pero igual se hizo la verificación de la media, mediana, deviación estándar, asimetría y curtosis en una hoja de Excel.

Fuente: Elaboración propia.

Tabla 64: Pruebas de normalidad de la obra "557503".

	Kolmogorov-Smirnov			Shapiro-Wilk		
	Estadístico	**Gl**	**Sig.**	**Estadístico**	**gl**	**Sig.**
Error Pert	0,236	12,000	0,063	0,792	12,000	0,008
Error ML	0,314	12,000	0,002	0,829	12,000	0,020
Diferencia de Errores	0,214	12,000	0,001	0,939	12,000	0,001

Nota: Estamos tomando la significancia de la diferencia no porque queremos compáralos si no porque queremos saber cuál de ellos se aproxima mejor a la duración real.

Fuente: Elaboración Propia.

HIPOTESIS

Nivel de confiabilidad de $\alpha=0.05$

- H_0: los datos siguen una distribución normal.
- H_1: los datos no siguen una distribución normal.
- Si $p > 0.05$, no rechazas H_0: no hay evidencia contra la normalidad.
- Si $p < 0.05$, rechazas H_0: los datos se desvían de la normalidad.

En la obra "557503" me sale que la significancia es de $p<0.05$ por lo tanto, las diferencias entre los errores absolutos de PERT y ML no siguen una distribución compatible con la normalidad según esta prueba, se rechazó la normalidad, por lo que se utilizó Wilcoxon.

Tabla 65: Estadísticos de Prueba Wilcoxon "557503".

Estadísticos de prueba	
	Error ML - Error Pert
Z	-1,217
Sig. asin. (bilateral)	0,224

Nota: El valor de Z y la significación no bastan para determinar cuál método tiene menor error. Necesitamos revisar las medias o medianas de los errores absolutos.

Fuente: Elaboración propia.

INTERPRETACION DE WILCOXON

- Si $p < 0.05$, existe evidencia estadística de una diferencia entre los errores de PERT y ML.
- Si $p \geq 0.05$, no hay evidencia suficiente para afirmar que los errores difieren estadísticamente.

La significación exacta da p=0.224, superior a 0.05. Con solo cuatro diferencias distintas de cero, conviene priorizar la prueba exacta y reconocer que la evidencia estadística es limitada.

Tabla 66: Comparación de resultados obra"557503".

	Error Pert	**Error ML**	**Reducción Media del error**
Media (Promedio)	1,917	1,167	39,130%

Nota: Elegimos la media porque no es una distribución normal.

Fuente: Elaboración propia.

Esto representa una reducción del 39.13 % en el error absoluto medio al utilizar Machine Learning respecto a PERT, los resultados favorecen al modelo de Machine Learning por presentar menores errores de predicción.

Tabla 67: Tabla resumen de errores por obra.

Obra	N	Error PERT: media	Error ML: media	Error PERT: mediana	Error ML: mediana	Prueba	Z	Sig. bilateral	Decisión	Reducción Media del error
169730	175	5,263	1,96	4	2	Wilcoxon	-8,824	<,001	diferencia significativa	62,76%
169592	189	6,439	1,915	4	2	Wilcoxon	-8,541	<,001	diferencia significativa	70,26%
500532	127	8,638	2,063	4	2	Wilcoxon	-7,254	<,001	diferencia significativa	76,12%
559764	7	1	0,429	1	0	Wilcoxon	-2	0,125	falta de evidencia estadística	57,14%
557503	12	1,917	1,167	1	1	Wilcoxon	-1,217	0,224	falta de evidencia estadística	39,13%

Fuente: Elaboración propia

La prueba de rangos con signo de Wilcoxon mostró que el error absoluto del modelo ML fue significativamente menor que el de PERT en las tres obras con mayor número de observaciones (169730, 169592 y 500532; $p < 0,001$ en todos los casos), con reducciones medias del error entre 62.76% y 76.12%. En las obras 559764 ($n = 7$) y 557503 ($n = 12$), ML también presentó menores errores medios (reducciones de 57.14% y 39.13%), aunque las diferencias no resultaron estadísticamente significativas ($p = 0.125$ y $p = 0.224$), lo cual puede atribuirse al reducido tamaño muestral y la consecuente baja potencia de la prueba. En conjunto, los resultados indican una ventaja consistente de ML sobre PERT en todas las obras, con evidencia inferencial robusta cuando el tamaño de muestra es suficiente.

Los valores del estadístico Z (entre -7.25 y -8.82 en las obras con mayor número de observaciones) indican una diferencia sistemática a favor de Machine Learnig, con tamaños de efecto grandes. En las obras de menor tamaño muestral, $Z = -2.00$ y $Z = -1.22$ no alcanzaron significancia (p exacto = 0.125 y 0.224), aunque la dirección del efecto fue la misma.

Se utilizó la prueba de Shapiro-Wilk para evaluar la normalidad de las diferencias pareadas de errores absolutos, por ser la que presenta mayor potencia estadística frente a desviaciones de la normalidad y por ser válida tanto en las obras con menos de 50 observaciones como en las

de mayor tamaño, lo que permitió aplicar un criterio uniforme. La prueba de Kolmogorov-Smirnov se descartó porque, con parámetros estimados a partir de la muestra, requiere la corrección de Lilliefors y presenta menor potencia, en particular en las colas de la distribución.

CAPITULO VI:

DISCUSIÓN

6. Discusión

6.1. Respecto a los objetivos específicos

El objetivo específico uno corresponde a identificar los factores y variables de proyectos de infraestructura vial que afectan la programación de obras de infraestructura vial, Arequipa 2025, investigación que se soporta en la tesis de (Banda Salas & Melendez Huañec, 2025).

Con los resultados presentados en el apartado “Comportamiento de las obras de infraestructura vial en Arequipa, 2022–2025”, se determinó que las obras ejecutadas durante el periodo presentan desviaciones superiores al 50 % respecto al tiempo planificado. Este resultado evidencia la presencia de retrasos significativos en la ejecución de las obras viales en Arequipa y permite identificar el retraso en el tiempo de ejecución como un factor relevante para el análisis de la programación.

La desviación media supera el 50 % en casi todos los plazos contractuales (33 % solo en el grupo de 45 días, con n = 3), alcanza 114 % en las obras de 60 días y es mayor en contratos por precios unitarios (70 %) que en suma alzada (59 %). Que el exceso se repita en distintos plazos y sistemas sugiere un sesgo optimista estructural de los plazos contractuales, y no solo eventos aleatorios de la ejecución, lo que justifica construir un estimador que aprenda de la ejecución real.

Respecto a las variables asociadas al retraso de las obras, estas han sido identificadas previamente en investigaciones como la de Bedregal Yabarrena et al. (2025) y en diversos estudios relacionados con el sector construcción. Los retrasos no se limitan a las obras de infraestructura vial, sino que también se presentan en diferentes tipos de proyectos de

construcción. A continuación, se presentan los autores que respaldan las principales categorías de retraso consideradas en la investigación:

- ✓ Retrasos asociados a la gestión de riesgos: Amer & Golparvar-Fard (2021).
- ✓ Retrasos asociados a problemas contractuales: Hriday & Rehman (2025).
- ✓ Retrasos asociados a problemas de calidad: Lotfi et al. (2025).

El objetivo específico dos del trabajo de investigación corresponde a diseñar y entrenar un modelo predictivo en técnicas de machine learning, que permita optimizar la programación de obras de infraestructura vial, Arequipa 2025, que principalmente de sustenta en el artículo de Jung et al. (2022) que hace sustento de que un modelo de machine learnig es capaz de superar a métodos conocidos.

Para el diseño del modelo predictivo, inicialmente se estructuró la base de datos tomando como referencia la propuesta de Seyisoglu et al. (2025). Posteriormente, se determinaron las variables necesarias para el entrenamiento del modelo, considerando lo expuesto por Fitzsimmons et al. (2022). Se evaluó la relación de estas variables con la predicción de la duración de las actividades; sin embargo, no se identificó una relación significativa, resultado que coincide con lo señalado por Gondia et al. (2020).

A partir de ello, se desarrolló un cuaderno de Machine Learning siguiendo la estructura propuesta por Géron (2026), incorporando las etapas de preparación de datos, entrenamiento, selección del modelo y evaluación. Finalmente, el cuaderno permitió entrenar los modelos con la base de datos y evaluar su desempeño mediante métricas de regresión, determinando el modelo con las características predictivas requeridas.

Por qué no hay relación individual significativa. La duración de una actividad no depende de una sola variable, sino de interacciones: el mismo metrado exige tiempos distintos según el

rendimiento de la cuadrilla, la partida y las condiciones de la obra. Una correlación lineal bivariada no captura estas interacciones, por lo que su ausencia no implica ausencia de información predictiva. Esto es coherente con el comportamiento observado: los modelos lineales explicaron una proporción moderada de la varianza, mientras que los modelos basados en árboles y el ensamble alcanzaron mayor desempeño, lo que indica estructura no lineal.

Por qué se seleccionó el ensamble. Se compararon 42 modelos con validación cruzada agrupada por obra (GroupKFold, 3 pliegues), se preseleccionaron los cinco mejores y AdaBoost se afinó con RandomizedSearchCV. El Stacking (ARD, AdaBoost, Lasso y LassoLars, con meta-modelo Ridge) combina estimadores con sesgos distintos: los lineales regularizados aportan estabilidad y AdaBoost aporta no linealidad. En la prueba final alcanzó $R^2 = 0.8061$, RMSE = 7.455, MAE = 4.90 y MAPE = 62.1 % (n = 1690), con intervalo bootstrap del RMSE (6.98; 7.92). La amplitud estrecha del intervalo indica estabilidad frente al remuestreo de la prueba, pero no frente a obras nuevas.

Qué revela la comparación entre validación agrupada y prueba aleatoria. El R^2 de validación cruzada agrupada por obra fue 0.39 – 0.42, y el de la prueba aleatoria 0.59 – 0.81. Incluso los modelos lineales sin ajuste, que apenas pueden memorizar, pasaron de ≈0.39 a ≈0.59 al cambiar de esquema de evaluación. Esa mejora no se debe al aprendizaje, sino a que la partición aleatoria deja filas de la misma obra y de la misma partida en entrenamiento y prueba, y la duración total de una partida es constante entre sus filas diarias. Los modelos no lineales explotan esta redundancia aún más: AdaBoost y Stacking pasaron de 0.42 a 0.79 y 0.81.

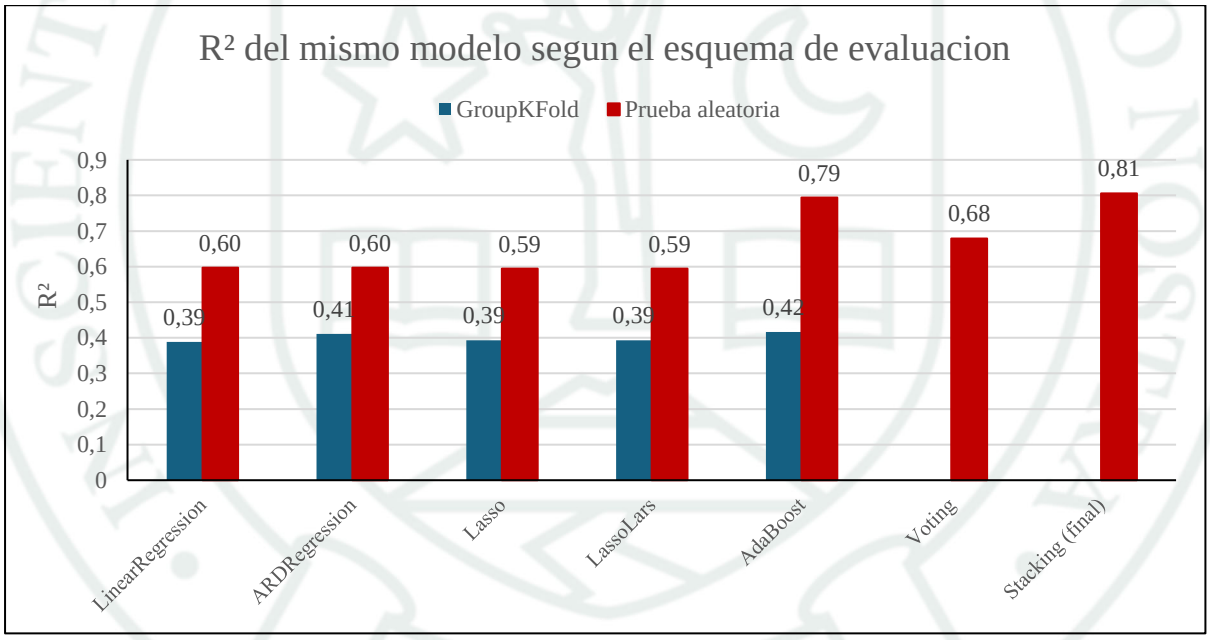
Tabla 68: Desempeño R^2

Modelo	R^2 GroupKFold (media ± DE)	R^2 prueba aleatoria	Diferencia
LinearRegression	0,3882	0,5973	0,209
ARDRegression	0,4112	0,5967	0,186
Lasso	0,3927	0,5941	0,201
LassoLars	0,3927	0,5941	0,201
AdaBoost	0,4168	0,7938	0,377
Voting	-	0,6792	-
Stacking (final)	-	0,8061	-

Nota: GroupKFold agrupa por OBRA_ID (3 pliegues). La prueba aleatoria corresponde a la partición final (n = 1690). Las celdas "-" indican valores no reportados bajo ese esquema.

Fuente: Elaboración propia.

Figura 72: Validación agrupada por obra frente a prueba aleatoria



Nota: Las barras de error muestran la desviación estándar entre pliegues de GroupKFold.

Fuente: Elaboración propia.

Esta brecha no invalida el modelo, pero sí define qué puede afirmarse: el R^2 de 0.81 describe el desempeño en actividades de obras cuyas partidas ya fueron observadas; el rango 0.39 - 0.41 es la estimación conservadora para obras totalmente nuevas.

El tercer objetivo específico corresponde a evaluar el desempeño y la confiabilidad del modelo predictivo frente a los métodos tradicionales de programación de obras de infraestructura vial. Este enfoque se relaciona con la estimación mediante puntos de historia (story points), que plantea el uso de información histórica de eventos similares para estimar el trabajo requerido. Asimismo, este principio es considerado en el PMBOK 7.ª edición y se aplica en la presente investigación mediante el uso de datos históricos para la predicción de la duración de las actividades.

Los resultados presentados en la tabla de error muestran que el modelo predictivo desarrollado presenta un menor error respecto al tiempo planificado, cuya duración fue estimada mediante PERT. Este resultado es consistente con lo reportado por Cheng et al. (2019) y Jiang et al. (2023; Mostofi et al., 2025), quienes obtuvieron errores porcentuales similares, lo que respalda el desempeño del modelo desarrollado. Sin embargo, Jiang et al. (2023) señala que las técnicas tradicionales para determinar la duración de las actividades continúan siendo necesarias, debido a que no siempre se dispone de información histórica suficiente para aplicar modelos predictivos. Asimismo, Lagos et al. (2024) sostiene que los modelos de Machine Learning no necesariamente proporcionan una duración exacta, debido a que cada proyecto de construcción presenta características particulares.

Tabla 69: Error medio del análisis estadístico.

Obra	N	Error PERT: media	Error ML: media	Error PERT: mediana	Error ML: mediana	Reducción Media del error
169730	175	5,263	1,96	4	2	62,76%
169592	189	6,439	1,915	4	2	70,26%
500532	127	8,638	2,063	4	2	76,12%
559764	7	1	0,429	1	0	57,14%
557503	12	1,917	1,167	1	1	39,13%

Nota: Los errores son absolutos, por actividad. Se aplicó la prueba de rangos con signo de Wilcoxon tras rechazarse la normalidad (Shapiro-Wilk). Datos de la Tabla "Tabla resumen de errores por obra".

Fuente: Elaboración propia.

Por qué el modelo supera al plazo planificado. Primero, el plazo planificado no es un estimador estadístico: la duración "PERT" es una estimación contractual paramétrica derivada del metrado y el rendimiento de los análisis de precios unitarios. Los plazos contractuales presentan un sesgo optimista sistemático, mientras que el modelo se entrena con duraciones reales y por construcción corrige ese sesgo medio. Segundo, el error de PERT tiene cola pesada: pocas partidas con ejecuciones muy superiores a lo previsto concentran gran parte del error absoluto, mientras que el modelo, al promediar sobre actividades históricas similares, atenúa esos extremos. Tercero, el modelo no parte de cero respecto a PERT: la variable RATIO_METRADO_REND aproxima la estimación contractual, de modo que el modelo aprende una corrección empírica a ese estimador, en lugar de competir con una fuente de información independiente.

Qué tan generalizable es esta ventaja. Las tres obras con diferencias significativas ($p < 0.001$) tienen n entre 127 y 189 actividades, pero esas actividades pertenecen a una misma obra y no son independientes entre sí: comparten cuadrilla, frente de trabajo, clima y gestión. La prueba

de Wilcoxon trata cada actividad como una observación independiente, por lo que sus p-valores sobrestiman la evidencia (tal cual como se entrenó el modelo las actividades se hicieron independientes con los códigos), aunque la dirección del efecto sea uniforme. Las dos obras pequeñas (n = 7 y n = 12) no alcanzaron significancia por baja potencia, tal como se indica en el Capítulo V, pero también confirman la misma dirección, de que machine learnig tiene mejores resultados.

El cuarto objetivo específico corresponde a determinar en qué medida la implementación del modelo predictivo basado en Machine Learning contribuye a optimizar la programación de obras y disminuir la desviación de los plazos. En este sentido, el modelo no busca reemplazar los métodos tradicionales, sino proporcionar una estimación de la duración basada en el comportamiento histórico de actividades previamente ejecutadas. Las obras utilizadas para el entrenamiento compartieron características y magnitudes de retraso similares con las obras empleadas para la validación, lo que permitió obtener predicciones cercanas a las duraciones reales y menores porcentajes de error.

Este resultado coincide con Timalsina et al. (2025), quienes señalan que estos modelos permiten obtener una referencia de la duración esperada de una actividad. Asimismo, Feng et al. (2025) indican que la precisión de los modelos predictivos mejora cuando se aplican a obras con características similares. En la misma línea, Sawma Awad et al. (2022) señalan que, para predecir la duración de nuevas construcciones, es necesario disponer de proyectos con características comparables. Sin embargo, Gondia et al. (2020) plantea que la incorporación continua de nuevos datos permite ampliar la capacidad de generalización de los modelos hacia diferentes tipos de construcciones.

Por qué la similitud entre obras determina el desempeño. El modelo es un interpolador de la experiencia: su error es bajo cuando la obra nueva se parece a las del entrenamiento en tipo

de partida, rendimiento y rango de metrado, y se degrada cuando se extrapola. Esto se observa en la propia tesis: el R^2 cae de 0.81 a 0.41 al evaluar con obras no vistas. Con diez obras, la cobertura de combinaciones partida condiciones es parcial, por lo que la condición de similitud que señalan Feng et al. (2025) y Sawma Awad et al. (2022) no es una salvedad menor, sino el principal determinante del alcance del modelo.

El error de predicción obtenido por el modelo no debe interpretarse únicamente como una medida de precisión, sino como un instrumento para mejorar la gestión contractual de los plazos de ejecución, debido a que una estimación más próxima al tiempo real permite establecer cronogramas contractuales con una menor desviación respecto al comportamiento esperado de la obra. En este sentido, la utilización de la predicción como referencia complementaria en la planificación podría contribuir a reducir el riesgo de incumplimiento injustificado de los plazos y, consecuentemente, la exposición a penalidades por mora, siempre que su aplicación se integre con el análisis técnico, contractual y de riesgos del proyecto. Esta perspectiva es compatible con enfoques contractuales orientados a una gestión más preventiva de los riesgos, como los empleados en contratos del Estado y en modelos internacionales como FIDIC y NEC, donde resulta relevante la identificación temprana de desviaciones, la actualización de programas y la gestión anticipada de eventos que puedan afectar el plazo. Por tanto, el modelo no sustituye el plazo contractual ni determina por sí mismo una ampliación de plazo, sino que proporciona evidencia predictiva para formular cronogramas más realistas, activar mecanismos de alerta temprana y sustentar oportunamente medidas de mitigación antes de que una desviación se convierta en incumplimiento contractual.

En función de ello, se desarrolló una interfaz web que permite registrar y almacenar información de nuevas obras viales, con el propósito de ampliar progresivamente la base de datos y alimentar el modelo con nuevos casos. De esta manera, el modelo puede fortalecerse

con información histórica adicional y constituirse como una herramienta de apoyo para la programación de obras.

6.2. Respecto al objetivo general

El objetivo general de este trabajo de investigación corresponde a determinar en qué medida el modelo predictivo basado en técnicas de machine learning optimiza la programación de obra en proyectos de infraestructura vial, Arequipa 2025, investigación que se soporta y fue inspirada por los investigadores Amer & Golparvar-Fard (2021)

Los resultados evidenciaron que el modelo presentó menores errores de estimación que el plazo planificado, con predicciones más cercanas al tiempo real. En las tres obras del estudio de caso, el error de la duración total pasó de 29 %, 48 % y 50 % con el plan a 7 %, 3 % y 3 % con el modelo, y la reducción del error absoluto medio por actividad fue de 39 % a 76 % en las cinco obras.

La aplicación del modelo no implica reemplazar los métodos tradicionales, sino complementarlos con una estimación basada en actividades similares. La capacidad predictiva depende de la disponibilidad y similitud de los datos, y puede mejorar a medida que se incorporen nuevos registros. Se determina así que el modelo contribuye a optimizar la programación, al proporcionar estimaciones con menor desviación respecto a la ejecución real, como herramienta de apoyo para programaciones más confiables y menor incertidumbre en los plazos. Dado el tamaño muestral y el esquema de evaluación, esta contribución se acota a obras con características comparables a las del conjunto de entrenamiento.

En consecuencia, se determina que el modelo predictivo contribuye a optimizar la programación de obras de infraestructura vial, principalmente al proporcionar estimaciones de duración con menor desviación respecto a la ejecución real. Por tanto, su implementación

constituye una herramienta de apoyo para generar programaciones más confiables y reducir la incertidumbre asociada a la estimación de los plazos de ejecución.

Aporte del modelo respecto de estudios previos

Tabla 70: Comparación entre esta tesis y los antecedentes.

Estudio	Unidad - tamaño	R^2 reportado	Observación
Liu & Luo (2026)	140 378 tareas	0,97	Unidad: tarea; mayor volumen de datos
Lagos et al. (2024)	164 proyectos	0,96	Unidad: proyecto completo
Jiang et al. (2023)	30 proyectos	0,94	Unidad: proyecto
Sawma Awad et al. (2022)	1 serie, 8 meses	0,94	Serie temporal única de 8 meses
Esta tesis (prueba aleatoria)	10 obras, 8539 registros	0,81	Actividad-día en obras viales
Esta tesis (GroupKFold)	10 obras, 8539 registros	0,42	Evaluación sobre obras no vistas

Nota: La comparación es referencial: la unidad de análisis y el esquema de validación difieren entre estudios.

Fuente: Elaboración propia

Frente a estos estudios, el aporte de la presente investigación es:

- Una base de datos de duraciones reales por actividad de obras viales peruanas, en un contexto donde la literatura se concentra en proyectos completos o en otros tipos de construcción;
- La validación agrupada por obra, que expone la brecha entre interpolar y generalizar, rara vez reportada en los antecedentes;
- La comparación con la estimación contractual en obras no vistas, y no solo con otros algoritmos;
- Una auditoría explícita de fuga de información y de sesgo de evaluación, que permite interpretar con rigor el R^2.

- Una interfaz web para ampliar progresivamente la base de datos, que atiende la condición de similitud señalada por Feng et al. (2025), Sawma Awad et al. (2022) y Gondia et al. (2020).

En síntesis, el modelo muestra que, con los datos actualmente disponibles, la información histórica reduce el error de estimación respecto al plazo planificado en obras comparables, y que su alcance a obras nuevas es moderado ($R^2 = 0.42$), condicionado por el número de obras. Esta lectura coincide con Lagos et al. (2024) y Jiang et al. (2023): los modelos complementan, y no sustituyen, a las técnicas tradicionales de programación.

CONCLUSIÓN

Se determinó que las obras de infraestructura vial ejecutadas en la región Arequipa durante el periodo 2022–2025 presentan desviaciones superiores al 50 % respecto al tiempo planificado, lo cual constituye evidencia empírica de retrasos significativos en la ejecución y permite establecer el retraso temporal como una variable dependiente relevante para el análisis de la programación de obras. Asimismo, mediante el contraste con la literatura especializada, se identificaron y validaron tres categorías de variables independientes asociadas al retraso: gestión de riesgos, problemas contractuales y problemas de calidad, las cuales constituyeron la base conceptual para la estructuración del modelo predictivo.

Se diseñó y entrenó un modelo de machine learning mediante un proceso metodológico estructurado en las fases de preparación de datos, entrenamiento, selección y evaluación del modelo, lográndose desarrollar un algoritmo con capacidad predictiva sobre la duración de las actividades de obra. Un hallazgo relevante del proceso fue la ausencia de relación estadísticamente significativa entre las variables inicialmente propuestas y la duración de las actividades, resultado consistente con estudios previos, lo que sugiere que la estimación de la duración responde de manera más eficiente al comportamiento histórico agregado de las obras que a la influencia directa de variables individuales.

El modelo predictivo desarrollado presentó un menor margen de error de estimación en comparación con el método tradicional PERT, con resultados congruentes con los reportados en investigaciones previas en términos de error porcentual. No obstante, se concluye que el modelo no sustituye a las técnicas tradicionales de programación, en tanto su desempeño se encuentra condicionado por la disponibilidad de información histórica suficiente y por la variabilidad de las características particulares de cada proyecto, factores que limitan su aplicabilidad generalizada.

Se concluye que la implementación del modelo predictivo contribuye a la optimización de la programación de obras en la medida en que existe correspondencia entre las características de las obras empleadas para el entrenamiento y aquellas utilizadas para la validación, lo que se traduce en predicciones con mayor proximidad a la duración real de ejecución. El modelo no reemplaza los métodos tradicionales de programación, sino que opera como una herramienta complementaria fundamentada en el análisis de información histórica. Complementariamente, se desarrolló una interfaz web orientada al registro sistemático de nuevas obras, mecanismo que posibilitará la ampliación progresiva de la base de datos y el fortalecimiento de la capacidad de generalización del modelo, se plantea la prestación del modelo para su uso por parte del Estado, con el propósito de estimar con mayor rigor las duraciones durante la etapa de planificación y contribuir a una adecuada contratación entre cliente y contratista.

Se concluye que el modelo predictivo basado en técnicas de machine learning optimiza la programación de obras de infraestructura vial en la región Arequipa, 2025, al reducir el error de estimación respecto a los métodos tradicionales y aproximar las predicciones al tiempo real de ejecución. Dicha optimización no implica la sustitución de los métodos convencionales de programación, sino su complementación mediante la incorporación de información histórica como insumo predictivo. Finalmente, se establece que la efectividad del modelo se encuentra condicionada por la cantidad y la similitud de los datos disponibles, por lo que su capacidad predictiva es susceptible de mejora continua conforme se incorporen nuevos registros al sistema de información.

RECOMENDACIONES

Se recomienda que las entidades incorporen la gestión de riesgos, el control contractual y el aseguramiento de la calidad desde la etapa de programación, con el fin de identificar anticipadamente factores que puedan generar desviaciones superiores al plazo planificado y adoptar medidas preventivas.

Se recomienda priorizar el uso de información histórica de obras ejecutadas para el entrenamiento y actualización del modelo predictivo, incorporando progresivamente nuevos registros que permitan mejorar su capacidad de estimación de la duración de las actividades.

Se recomienda utilizar el modelo predictivo como herramienta complementaria al método PERT, respaldando su aplicación con una base de datos histórica amplia y representativa de las características de cada proyecto para mejorar la confiabilidad de las estimaciones.

Se recomienda implementar progresivamente la interfaz web para registrar nuevas obras y actualizar la base de datos, utilizando esta información para recalibrar periódicamente el modelo y mejorar su capacidad de generalización en futuros proyectos.

REFERENCIAS

Amer, F., & Golparvar-Fard, M. (2021). Modeling dynamic construction work template from existing scheduling records via sequential machine learning. *Advanced Engineering Informatics*, *47*, 101198. https://doi.org/10.1016/j.aei.2020.101198

American Association of State Highway and Transportation Officials. (1993). *American Association of State Highway and Transportation Officials AASHTO* (AASHTO Joint Task Force on Pavements, Ed.; 1st ed., Vol. 1). American Association of State Highway and Transportation Officials.

Awada, M., Srour, F. J., & Srour, I. M. (2021). Data-Driven Machine Learning Approach to Integrate Field Submittals in Project Scheduling. *Journal of Management in Engineering*, *37*(1). https://doi.org/10.1061/(ASCE)ME.1943-5479.0000873

Ayhan, M., Dikmen, I., & Talat Birgonul, M. (2021). Predicting the Occurrence of Construction Disputes Using Machine Learning Techniques. *Journal of Construction Engineering and Management*, *147*(4). https://doi.org/10.1061/(ASCE)CO.1943-7862.0002027

Babushkin, Valerii., & Kravchenko, Arseny. (2025). *Machine learning system design : with end-to-end examples*. Manning Publications.

Banda Salas, V. A., & Melendez Huañec, R. Y. (2025). *Propuesta metodológica enfocada en la evaluación de riesgos para evitar la modificación contractual en proyectos de infraestructura vial bajo la modalidad de contrata en la ciudad de Arequipa* [Universidad Católica de Santa María]. https://hdl.handle.net/20.500.12920/14697

Banerjee Chattapadhyay, D., Putta, J., & Rao P, R. M. (2021). Risk Identification, Assessments, and Prediction for Mega Construction Projects: A Risk Prediction Paradigm Based on Cross Analytical-Machine Learning Model. *Buildings*, *11*(4), 172. https://doi.org/10.3390/buildings11040172

Bedregal Yabarrena, I. I., Malaga Cardenas, K. F., & Montoya Villanueva, F. R. (2025). *Evaluación del manejo de la gestión de riesgos en proyectos de infraestructura vial bajo la modalidad de ejecución por contrata, en municipios distritales, caso de estudio: Municipalidad Distrital de Cerro Colorado, periodo (2022-2024)* [Universidad Católica de Santa María]. https://hdl.handle.net/20.500.12920/14696

Borja Suárez, M. (2016). *Metodología de Investigación Científica para ingeniería Civil* (1st ed.). Ingenieros civiles. https://www.academia.edu/33692697/Metodolog%C3%ADa_de_Investigaci%C3%B3n_Cient%C3%ADfica_para_ingenier%C3%ADa_Civil

Cáceres Loayza, F., Ramos Butrón, A. G., & Calderón Ugarte, E. A. (2023). *Uso de redes neuronales artificiales para determinar una nueva alternativa de método de diseño de mezcla de concreto de resistencias convencionales en la ciudad de Arequipa 2022* [Universidad Católica de Santa María]. https://repositorio.ucsm.edu.pe/handle/20.500.12920/12366

Chang, S. Shu. (2024). *Machine learning interviews : kickstart your machine learning career and data career* (1st ed.). O'Reilly Media, Inc.

Cheng, M.-Y., Chang, Y.-H., & Korir, D. (2019). Novel Approach to Estimating Schedule to Completion in Construction Projects Using Sequence and Nonsequence Learning. *Journal of Construction Engineering and Management*, *145*(11). https://doi.org/10.1061/(ASCE)CO.1943-7862.0001697

Chio, Clarence., & Freeman, David. (2018). *Machine learning and security : protecting systems with data and algorithms* (1st ed.). O'Reilly Media.

Contraloría General de la República del Perú. (2025). *Informe de obras públicas paralizadas en el territorio nacional a marzo 2025*. https://cdn.www.gob.pe/uploads/document/file/8102466/6792710-informe-de-obras-paralizadas-en-el-territorio-nacional-a-marzo-2025.PDF?v=1747867116

Danka, Tivadar. (2025). *Mathematics of machine learning : master linear algebra, calculus, and probability for machine learning* (1st ed.). Packt Publishing.

Dowling, Jim. (2025). *Building machine learning systems with a feature store* (1st ed.). O'Reilly Media, Inc.

Eastman, C., Teicholz, P., Sacks, R., & Liston, K. (20011). *BIM handbook : a guide to building information modeling for owners, managers, designers, engineers, and contractors* (John Wiley & Sons, Ed.; 2nd ed., Vol. 1). Wiley.

Fan, C.-L. (2025). Optimization and performance evaluation of machine learning classifiers for predicting construction quality and schedule. *Automation in Construction*, *179*, 106470. https://doi.org/10.1016/j.autcon.2025.106470

Federación Panamericana de Consultores. (2023, August 23). *Retrasos en las obras varían entre 6 y 24 meses, según estudios de FEPAC | Asociación Peruana de Consultoría (APC)*. https://www.apcperu.org/retrasos-en-las-obras-varian-entre-6-y-24-meses-segun-estudios-de-fepac/

Feng, X., Cao, J., Liu, L., & Liu, C. (2025). Predicting Performance of Organizations in Project Networks Using Machine Learning: Evidence from China's PPP Industry. *Journal of Management in Engineering*, *41*(6). https://doi.org/10.1061/JMENEA.MEENG-6888

Fitzsimmons, J. P., Lu, R., Hong, Y., & Brilakis, I. (2022). Construction schedule risk analysis a hybrid machine learning approach. *Journal of Information Technology in Construction*, *27*, 70–93. https://doi.org/10.36680/j.itcon.2022.004

Geron, A. (2026). *Hands-on machine learning with Scikit-Learn and PyTorch : concepts, tools, and techniques to build intelligent systems* (1st ed.). O'Reilly Media, Inc.

Gobierno del Perú. (2019). *Plan nacional de infraestructura para la competitividad*. https://www.mef.gob.pe/contenidos/inv_privada/planes/PNIC_2019.pdf

Gondia, A., Siam, A., El-Dakhakhni, W., & Nassar, A. H. (2020). Machine Learning Algorithms for Construction Projects Delay Risk Prediction. *Journal of Construction*

Engineering and Management, *146*(1). https://doi.org/10.1061/(ASCE)CO.1943-7862.0001736

Hriday, Md. S. H., & Rehman, A. (2025). Artificial Intelligence and Machine Learning Applications in Construction Project Management: Enhancing Scheduling, Cost Estimation, and Risk Mitigation. *International Journal of Business and Economics Insights*, *05*(03), 30–64. https://doi.org/10.63125/jrpjje59

Huyen, Chip. (2022). *Designing Machine Learning Systems : an iterative process for production-ready applications* (1st ed.). O'Reilly Media, Inc.

International Federation of Consulting Engineers. (2017). *Conditions of Contract for Construction: For Building and Engineering Works Designed by the Employer (2nd ed.)* (2nd ed.). FIDIC.

Jansen, Stefan. (2020). *Machine learning for algorithmic trading : predictive models to extract signals from market and alternative data for systematic trading strategies with Python* (2nd ed.). Packt Publishing.

Jiang, X., Li, B., Fang, Y., Liu, F., & Zhao, G. (2023). Construction Duration Forecasting Based on Machine Learning Method. *ICCREM 2023*, 1154–1164. https://doi.org/10.1061/9780784485217.114

Juarez Racchumi, V. A., & Corimanya Mauricio, J. A. (2023). *Construcción de un modelo predictivo de productividad de las palas aplicando el aprendizaje automático random forest regressor de machine learning* [Universidad Nacional de Ingeniería]. http://hdl.handle.net/20.500.14076/27171

Jung, Y., Amer, F., & Golparvar-Fard, M. (2022). Feasibility of an Integrated Heuristic and Machine Learning Approach for Schedule Health Monitoring in Construction. *Construction Research Congress 2022*, 351–360. https://doi.org/10.1061/9780784483978.037

Kanungo, D. K. . (2023). *Probablistic machine learning for finance and investing : a primer to generative AI with Python* (1st ed.). O'Reilly Media, Inc.

Kerzner, H. (2022). *Project management: A systems approach to planning* (John Wiley & Sons, Ed.; 13th ed., Vol. 1). www.wiley.com.

Lagos, C. I., Herrera, R. F., Mac Cawley, A. F., & Alarcón, L. F. (2024). Predicting construction schedule performance with last planner system and machine learning. *Automation in Construction*, *167*, 105716. https://doi.org/10.1016/j.autcon.2024.105716

Lakshmanan, Valliappa., Robinson, Sara., & Munn, Michael. (2021). *Machine Learning Design Patterns: Solutions to Common Challenges in Data Preparation, Model Building, and MLOps* (1st ed.). O'Reilly Media, Inc.

Last Planner System® | Lean Construction Institute. (2024). *Introduction to the Last Planner System®*. https://leanconstruction.org/lean-topics/last-planner-system/

Lean Construction Institute. (2023). *An Introduction to Lean Construction*. https://leanconstruction.org/lean-topics/lean-construction/

Liu, Y., & Luo, H. (2026). An efficient machine learning-based model for duration prediction of construction tasks with large-scale datasets. *Advanced Engineering Informatics*, *69*, 103820. https://doi.org/10.1016/j.aei.2025.103820

López de Prado, M. Mailoc. (2018). *Advances in financial machine learning* (1st ed.). John Wiley & Sons, Inc.

Lotfi, R., Sadeghi, S., Ali, S. S., Ramyar, F., Ghafourian, E., & Farbod, E. (2025). A Robust, Resilience Machine Learning With a Risk Approach for Project Scheduling. *Engineering Reports*, *7*(6). https://doi.org/10.1002/eng2.70161

Ministerio de Economía y Finanzas del Perú MEF. (2024). *Ley General de Contrataciones Públicas - LEY Nº 32069*.

Ministerio de Transportes y Comunicaciones. (2025, June 20). *Ministerio de Transportes y Comunicaciones impulsa y destraba obras por más de 400 millones de soles*. https://www.gob.pe/institucion/mtc/noticias/1191549-mtc-impulsa-y-destraba-obras-por-mas-de-400-millones-de-soles

Ministerio de Transportes y Comunicaciones MTC. (2013). *Manual de carreteras - Especificaciones Técnicas generales para la construcción EG-2013* (Ministerio de Transportes y Comunicaciones MTC & Dirección de Normatividad de Infraestructura Vial, Eds.; 1st ed., Vol. 1). Ministerio de Transportes y Comunicaciones.

Ministerio de Transportes y Comunicaciones MTC. (2014). Manual de Carreteras: Suelos, Geología, Geotecnia y Pavimentos (Sección suelos y pavimentos). In Ministerio de Transportes y Comunicaciones MTC & Dirección de Normatividad de Infraestructura Vial (Eds.), *Ministerio de Transportes y Comunicaciones MTC* (1st ed., Vol. 1). Ministerio de Transportes y Comunicaciones MTC.

Ministerio de Transportes y Comunicaciones MTC. (2018). *Manual de Carreteras: Diseño Geométrico DG-2018* (Ministerio de Transportes y Comunicaciones MTC & Dirección de Normatividad de Infraestructura Vial, Eds.; 1st ed., Vol. 1). Ministerio de Transportes y Comunicaciones MTC.

Moroney, Laurence. (2020). *AI and Machine Learning for Coders: A Programmer's Guide to Artificial Intelligence* (1st ed.). O'Reilly Media, Incorporated.

Mostofi, F., Tokdemir, O. B., & Toğan, V. (2025). Construction Delay Prediction Model Using a Relationship-Aware Multihead Graph Attention Network. *Journal of Management in Engineering*, *41*(3). https://doi.org/10.1061/JMENEA.MEENG-6639

Niño Rojas, V. Mi. (2011). *Metodología de la Investigación* (A. Gutiérrez, Ed.; 1st ed.). Ediciones de la U. https://gc.scalahed.com/recursos/files/r161r/w24802w/Nino-Rojas-Victor-Miguel_Metodologia-de-la-Investigacion_Diseno-y-ejecucion_2011.pdf

Oliver, B., & Cheneweth, N. (2025). *Designing Cloud Native Delivery Systems: Architectural Patterns for Highly-Distributed Software Delivery* (1st ed.). O'Reilly Media.

Perales Apaza, V. M., & Espinoza Vigil, A. J. (2025). *Modelo para la gestión eficiente de sistemas de alcantarillado basado en Machine Learning y Gis* [Universidad Católica de Santa María]. https://hdl.handle.net/20.500.12920/15053

Porject Management Institute. (2019). *Practice Standard for Sheduling - Thrid Edition* (Project Management Institute, Ed.; 3rd ed., Vol. 1). Project Management Institute. https://www.pmi.org/standards/scheduling-third-edition

Project Management Institute. (2017). *A Guide to the Project Management Body of Knowledge PMBOK GUIDE* (Project Management Institute, Ed.; 6th ed., Vol. 1). Project Management Institute. https://www.pmi.org/shop/p-/book/a-guide-to-the-project-management-body-of-knowledge-(pmbok-guide)-%E2%80%94-sixth-edition-and-agile-practice-guide-(english)/00101602400

Project Management Institute. (2021). *A Guide to the Project Management Body of Knowledge PMBOK Guide* (7th ed.). Project Management Institute.

Raschka, Sebastian., Liu, Yuxi., Mirjalili, Vahid., & Dzhulgakov, Dmytro. (2022). *Machine learning with Pytorch and Scikit-Learn : develop machine learning and deep learning models with scikit-learn and PyTorch* (1st ed.). Packt Publishing, Limited.

Rodríguez Moguel, E. A. (2005). *Metodología de la Investigación* (E. Rodríguez Sandoval & A. Sandoval Valenzuela, Eds.; 1st ed.). Universidad Juárez Autónoma de Tabasco. https://www.academia.edu/37714580/Metodolog%C3%ADa_de_la_investigaci%C3%B3n_Ernesto_A_Rodr%C3%ADguez_Moguel_LIBROSVIRTUAL

Sawma Awad, J., Assaf, S., Safa, B., & Srour, I. (2022). Forecasting Field Production Using Machine Learning Time Series. *Construction Research Congress 2022*, 77–86. https://doi.org/10.1061/9780784483961.009

Serrano, L. G. ., & Thrun, Sebastian. (2021). *Grokking machine learning*. Manning Publications Co.

Seyisoglu, B., Shahpari, A., & Talebi, M. (2025). Predictive Project Management in Construction: A Data-Driven Approach to Project Scheduling and Resource Estimation Using Machine Learning. *Plan Estatal de Investigación Sobre Ciencia y Tecnología e Innovación 2022-2024*. https://doi.org/10.2139/ssrn.5077301

Smolyakov, Vadim. (2024). *Machine learning algorithms in depth* (1st ed.). Manning Publications.

Tan Wei Hao, Benjamin., Padmanabhan, Shanoop., & Mallya, Varun. (2026). *Machine learning platform engineering : build an internal developer platform for ML and AI systems* (1st ed.). Manning Publications Co. LLC.

Timalsina, S., Zhang, C., Quapp, U., Demirkesen, S., & Olorunnishola, A. (2025). Machine Learning–Based Predictive Model for Dispute Occurrence and Resolution Strategies in Pipeline Projects. *Journal of Legal Affairs and Dispute Resolution in Engineering and Construction*, *17*(3). https://doi.org/10.1061/JLADAH.LADR-1334

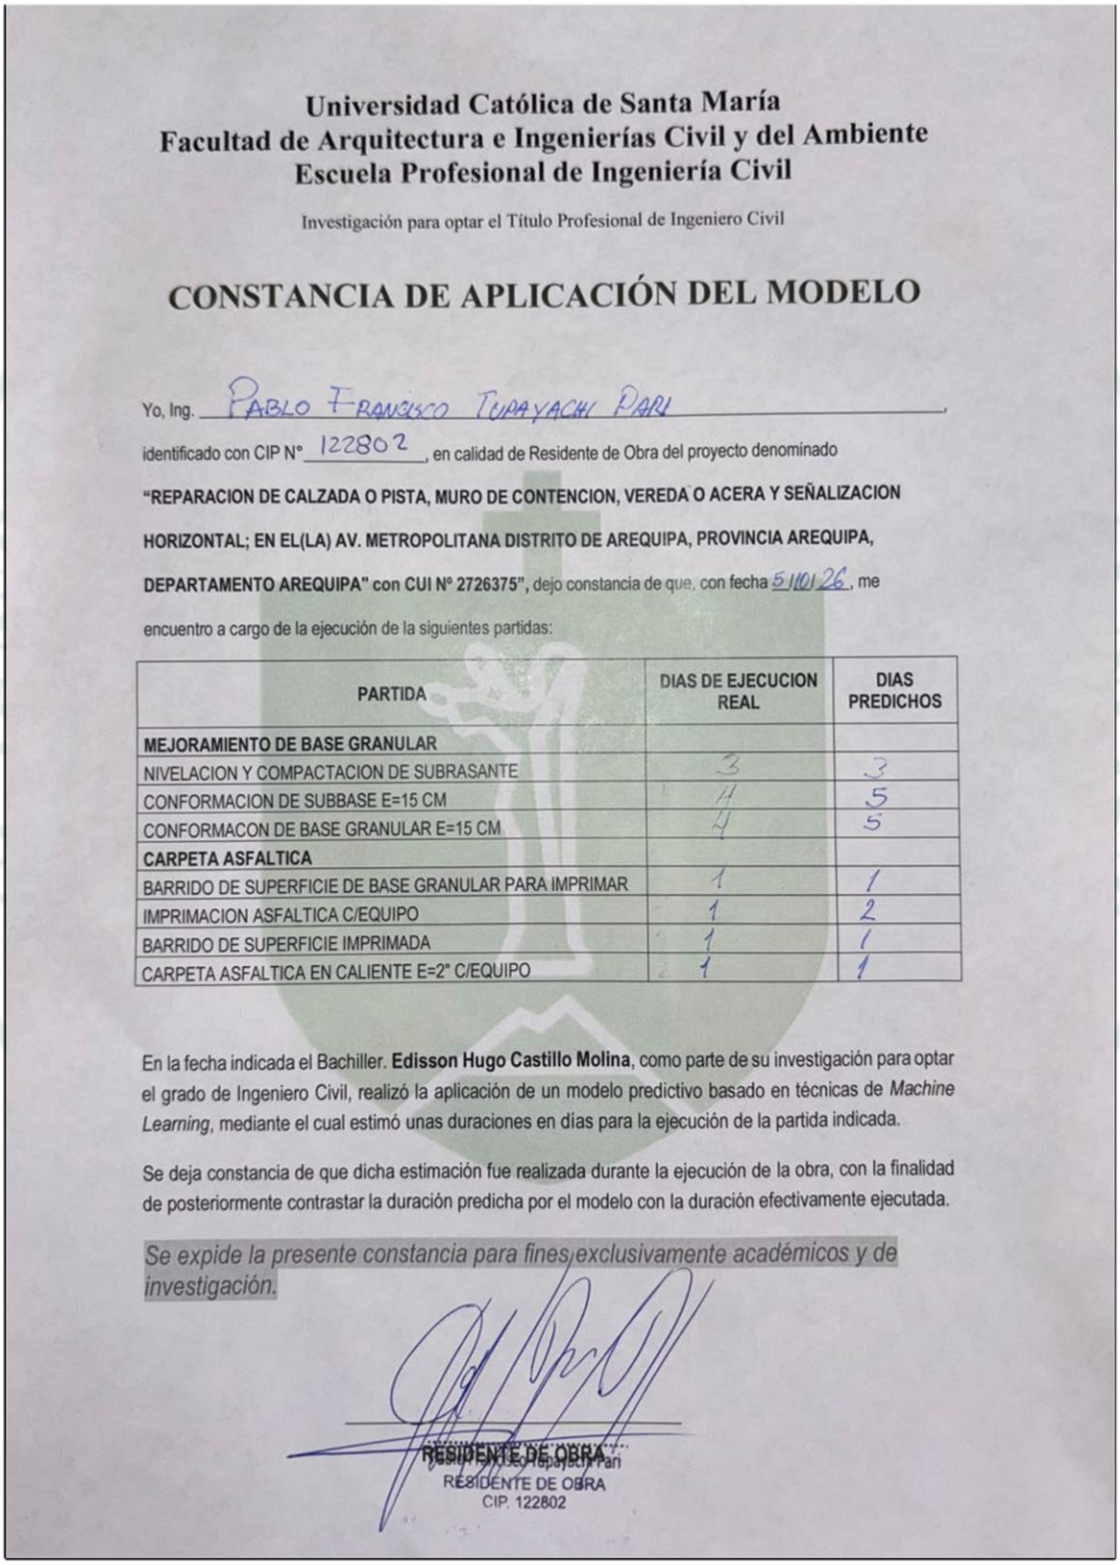
Tranquillin, Marco., Lakshmanan, Valliappa., & Tekiner, Firat. (2024). *Architecting data and machine learning platforms : enable analytics and AI-driven innovation in the cloud* (1st ed.). O'Reilly Media, Inc.

Yehoshua, Roi. (2026). *MACHINE LEARNING FOUNDATIONS. Volume 1, Supervised learning* (1st ed., Vol. 1). ADDISON WESLEY.

Zheng, Alice., & Casari, Amanda. (2018). *Feature engineering for machine learning : principles and techniques for data scientists* (1st ed.). O'Reilly Media.

ANEXOS

ANEXOS 1:
Vista para verificar mi modelo “559764”.



Universidad Católica de Santa María
Facultad de Arquitectura e Ingenierías Civil y del Ambiente
Escuela Profesional de Ingeniería Civil

Investigación para optar el Título Profesional de Ingeniero Civil

CONSTANCIA DE APLICACIÓN DEL MODELO

Yo, Ing. PABLO FRANCISCO TUPAYACHI PARI,
identificado con CIP N° 122802, en calidad de Residente de Obra del proyecto denominado **“REPARACION DE CALZADA O PISTA, MURO DE CONTENCION, VEREDA O ACERA Y SEÑALIZACION HORIZONTAL; EN EL(LA) AV. METROPOLITANA DISTRITO DE AREQUIPA, PROVINCIA AREQUIPA, DEPARTAMENTO AREQUIPA” con CUI N° 2726375”,** dejo constancia de que, con fecha 5/10/26, me encuentro a cargo de la ejecución de la siguientes partidas:

PARTIDA	DIAS DE EJECUCION REAL	DIAS PREDICHOS
MEJORAMIENTO DE BASE GRANULAR		
NIVELACION Y COMPACTACION DE SUBRASANTE	3	3
CONFORMACION DE SUBBASE E=15 CM	4	5
CONFORMACON DE BASE GRANULAR E=15 CM	4	5
CARPETA ASFALTICA		
BARRIDO DE SUPERFICIE DE BASE GRANULAR PARA IMPRIMAR	1	1
IMPRIMACION ASFALTICA C/EQUIPO	1	2
BARRIDO DE SUPERFICIE IMPRIMADA	1	1
CARPETA ASFALTICA EN CALIENTE E=2" C/EQUIPO	1	1

En la fecha indicada el Bachiller. **Edisson Hugo Castillo Molina**, como parte de su investigación para optar el grado de Ingeniero Civil, realizó la aplicación de un modelo predictivo basado en técnicas de *Machine Learning*, mediante el cual estimó unas duraciones en días para la ejecución de la partida indicada.

Se deja constancia de que dicha estimación fue realizada durante la ejecución de la obra, con la finalidad de posteriormente contrastar la duración predicha por el modelo con la duración efectivamente ejecutada.

Se expide la presente constancia para fines exclusivamente académicos y de investigación.

RESIDENTE DE OBRA
Pablo Francisco Tupayachi Pari
RESIDENTE DE OBRA
CIP. 122802

ANEXOS 2:

Vista para verificar mi modelo “557503”.

Universidad Católica de Santa María
Facultad de Arquitectura e Ingenierías Civil y del Ambiente
Escuela Profesional de Ingeniería Civil

Investigación para optar el Título Profesional de Ingeniero Civil

CONSTANCIA DE APLICACIÓN DEL MODELO

Yo, Ing. Jorge Artemio Ccari Zamata,

identificado con CIP N° 82432, en calidad de Supervisor de Obra del proyecto denominado

“MEJORAMIENTO DEL SERVICIO DE MOVILIDAD URBANA EN LA URBANIZACIÓN LEÓN XIII DEL DISTRITO DE CAYMA - PROVINCIA DE AREQUIPA - DEPARTAMENTO DE AREQUIPA” con CUI N° 2565969”, dejo constancia de que, con fecha 7/10/2021 me encuentro a cargo de la supervisión de la siguientes partidas:

PARTIDA	DIAS DE EJECUCION REAL	DIAS PREDICHOS
MOVIMIENTO DE TIERRAS		
CORTE DE TERRENO A NIVEL DE SUB RASANTE PAVIMENTO TERRENO NORMAL C/MAQUINARIA	2	2
ESCARIFICADO DE SUB RASANTE A PROFUNDIDAD H=0.15 M C/MAQUINARIA	2	2
NIVELACION Y COMPACTACION DE SUB RASANTE PAVIMENTO AL 95% PROCTOR MODIFICADO C/MAQUINARIA	2	2
CONFORMACION Y COMPACTACION DE BASE GRANULAR E=0.20M PAVIMENTO AL 100% PROCTOR MODIFICADO C/MAQUINARIA	4	5
ACARREO Y ACOPIO C/EQUIPO MAT. EXCAV. DIST. 50 M	4	5
ELIMINACION MAT. EXCAV. CARG. 125 HP / VOLQUETE 15 M3 D=15 KM	4	5
PAVIMENTO DE ADOQUINES DE CONCRETO		
CAMA DE ARENA H=0.04M	3	4
DESCARGUIO DE ADOQUINES	1	2
ACARREO DE ADOQUINES	7	6
COLOCACION DE ADOQUINES 20X10X8 CM F'C 420 KG/CM2	14	17
SELLO O PARCHADO DE JUNTAS CON ARENA FINA	6	3
COMPACTADO FINAL CON EQUIPO LIVIANO	4	2

En la fecha indicada el Bachiller. **Edisson Hugo Castillo Molina**, como parte de su investigación para optar el grado de Ingeniero Civil, realizó la aplicación de un modelo predictivo basado en técnicas de *Machine Learning*, mediante el cual estimó unas duraciones en días para la ejecución de la partida indicada.

Se deja constancia de que dicha estimación fue realizada durante la ejecución de la obra, con la finalidad de posteriormente contrastar la duración predicha por el modelo con la duración efectivamente ejecutada.

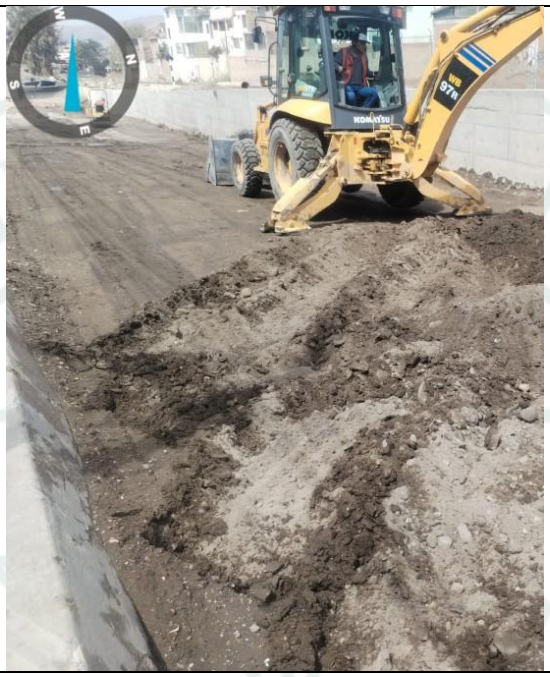
Se expide la presente constancia para fines exclusivamente académicos y de investigación.

Ing. Jorge A. Ccari Zamata
INGENIERO CIVIL
CIP N° 82432

SUPERVISOR DE OBRA

ANEXOS 3:

Panel fotográfico "559764".

METROPOLITANA
MEJORAMIENTO DE BASE GRANULA

NIVELACION Y COMPACTACION DE SUBRASANTE

CONFORMACION DE SUBBASE E=15 CM



CONFORMACON DE BASE GRANULAR E=15 CM

CARPETA ASFALTICA



BARRIDO DE SUPERFICIE DE BASE GRANULAR PARA IMPRIMAR





IMPRIMACION ASFALTICA C/EQUIPO



BARRIDO DE SUPERFICIE IMPRIMADA





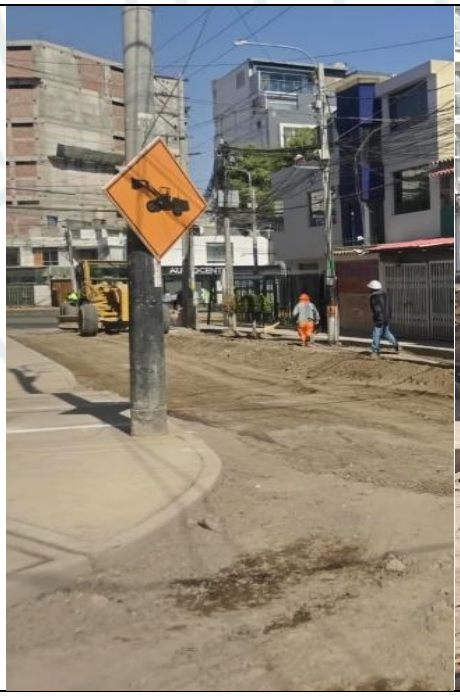




CARPETA ASFALTICA EN CALIENTE E=2" C/EQUIPO

ANEXOS 4:

Panel fotografico"557503".

Descripción
LEÓN CAYMA
MOVIMIENTO DE TIERRAS
 
CORTE DE TERRENO A NIVEL DE SUB RASANTE PAVIMENTO TERRENO NORMAL C/MAQUINARIA
 
ESCARIFICADO DE SUB RASANTE A PROFUNDIDAD H=0.15 M C/MAQUINARIA



NIVELACION Y COMPACTACION DE SUB RASANTE PAVIMENTO AL 95% PROCTOR MODIFICADO C/MAQUINARIA



CONFORMACION Y COMPACTACION DE BASE GRANULAR E=0.20M PAVIMENTO AL 100% PROCTOR MODIFICADO C/MAQUINARIA



ACARREO Y ACOPIO C/EQUIPO MAT. EXCAV. DIST. 50 M



ELIMINACION MAT. EXCAV. CARG. 125 HP / VOLQUETE 15 M3 D=15 KM

PAVIMENTO DE ADOQUINES DE CONCRETO



CAMA DE ARENA H=0.04M



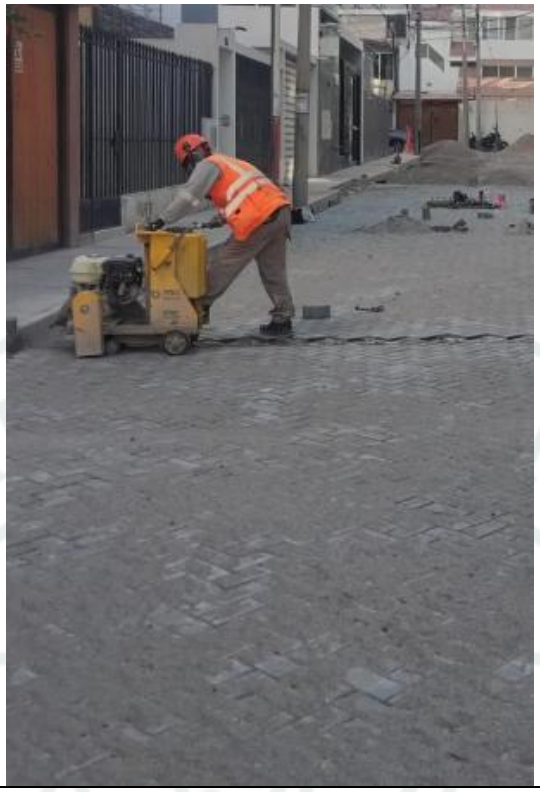
DESCARGUIO DE ADOQUINES



ACARREO DE ADOQUINES



COLOCACION DE ADOQUINES 20X10X8 CM F'C 420 KG/CM2



SELLO O PARCHADO DE JUNTAS CON ARENA FINA



COMPACTADO FINAL CON EQUIPO LIVIANO

ANEXO 5: Matriz de Consistencia.

Modelo predictivo basado en técnicas de machine learning para optimizar la programación de obra en proyectos de infraestructura vial, Arequipa 2025

Formulación del Problema	Objetivos	Hipótesis	Variables e Indicadores			Metodología
Problema General	**Objetivo General**	**Hipótesis General**	**Variable independiente**			**Diseño Metodológico**
¿En qué medida el modelo predictivo basado en técnicas de machine learning Optimiza la programación de obras de infraestructura vial en Arequipa 2025?	Determinar en qué medida el modelo predictivo basado en técnicas de machine learning optimiza la programación de obra en proyectos de infraestructura vial, Arequipa 2025.	El modelo predictivo basado en técnicas de machine learning tiene un efecto significativo en la programación de obras en proyectos de infraestructura vial, Arequipa 2025.	**Modelo predictivo basado en técnicas de machine learning**			Enfoque: Cuantitativo Nivel: Investigación Aplicada Diseño: la investigación es no experimental, de tipo correlacional-predictivo
Problemas Específicos	**Objetivos Específicos**	**Hipótesis Específicos**	**Dimensión**	**Indicador**	**Medición**	**Técnica de recolección de datos**
¿Cuáles son los factores y variables de proyectos de infraestructura vial que afectan la programación de obras de infraestructura vial, Arequipa 2025?	Identificar los factores y variables de proyectos de infraestructura vial que afectan la programación de obras de infraestructura vial, Arequipa 2025.	Los factores y variables de proyectos de infraestructura vial poseen una relación significativa con la precisión de la programación de obras de infraestructura vial, Arequipa 2025.	Desempeño del modelo predictivo	Exactitud de las predicciones	error porcentual %	Se empleó la revisión documental, mediante la recopilación y análisis de información oficial proveniente de plataformas públicas como InfoObras, el Sistema de Seguimiento de Inversiones (SSI), así como de expedientes técnicos y cronogramas valorizados de obras viales ejecutadas.
			Entrenamiento y validación	Numero de modelos evaluados	cantidad de modelos °N	
				Selección adecuada del modelo	R^2, RMSE, MAE, MAPE	
¿Cómo diseñar y entrenar un modelo predictivo con técnicas de machine learning, que permita Optimizar la programación de obras de infraestructura vial, Arequipa 2025?	Diseñar y entrenar un modelo predictivo en técnicas de machine learning, que permita optimizar la programación de obras de infraestructura vial, Arequipa 2025.	El diseño y entrenamiento de un modelo predictivo basado en técnicas de machine learning, permite optimizar la programación de obras de infraestructura vial, Arequipa 2025.	Aplicación del modelo	Duración predicha de actividades	Días	
				Diferencia entre real y predicha	Días	
			Variable dependiente			**Población y Muestra**
¿Cómo evaluar el desempeño del modelo predictivo desarrollando su confiabilidad frente a métodos tradicionales en la programación de obras de infraestructura vial, Arequipa 2025?	Evaluar el desempeño del modelo predictivo desarrollado y su confiabilidad frente a métodos tradicionales de programación de obra de infraestructura vial, Arequipa 2025	El modelo predictivo desarrollado mediante machine learning presenta un mejor desempeño y mayor confiabilidad que los métodos tradicionales de programación de obra de infraestructura vial, Arequipa 2025.	**Programación de obras en proyectos de infraestructura vial, Arequipa 2025**			La población está conformada por todos los proyectos de infraestructura vial ejecutados en la región de Arequipa. La muestra seran obras ya ejecutadas y finalizadas con datos completos.
			Dimensión	**Indicador**	**Medición**	**Procedimiento**
¿En qué medida la implementación de modelo predictivo basado en machine learning optimiza la programación de obras y disminución de la desviación de plazos?	Determinar en qué medida la implementación del modelo predictivo basado en machine learning optimiza la programación de obras y disminución de la desviación de plazos.	La implementación del modelo predictivo basado en técnicas machine learning reduce significativamente la desviación de plazos y optimiza la programación de obras de infraestructura vial, Arequipa 2025.	Duración de ejecución	Plazo de ejecución real	Días	Se recopiló información sobre la duración planificada y la duración real de las obras, para posteriormente compararlas con la duración predicha por el modelo.
			Cumplimiento del plazo	Diferencia entre plazo contractual y plazo real	Días	
			Desviación del cronograma	Porcentaje de desviación entre contractual y real.	error porcentual %	

ANEXO 6: Obras finalizadas periodo 2022-2025 Arequipa.

N°	Código INFOBRAS	Código Único de Inversión	Código SNIP	Nombre de la obra	Modalidad de ejecución	Sistema de contrata	Estado de obra	Plazo de ejecucion contractual	Plazo de ejcucion real	Monto Expediente Técnico
1	38535	2181482	249386	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DEL AA HH VILLA FLORIDA DISTRITO DE ALTO SELVA ALEGRE AREQUIPA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	104	S/ 1,387,564.79
2	61011	2264981	316061	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL BLOQUE 1 EN EL CENTRO POBLADO SAN JUAN EL ALTO DISTRITO DE MAJES CAYLLOMA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	214	S/ 11,604,917.27
3	91135	2281340	324502	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS AVENIDAS Y CALLES DEL ASENTAMIENTO HUMANO MATARANI 2000 DISTRITO DE ISLAY ISLAY AREQUIPA PRIMERA ETAPA	Contrata	SUMA ALZADA	Finalizado	150	233	S/ 3,141,354.43
4	113083	2457349	2457349	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS PRINCIPALES CALLES DE LA ASOCIACIÓN DE VIVIENDA VIRGEN DE LA CANDELARIA ASOVICH DISTRITO DE CHARACATO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	152	S/ 2,052,675.24
5	113084	2456656	2456656	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LAS CALLES LOCALES DEL A H JUVENTUD CHARACATO DISTRITO DE CHARACATO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	109	S/ 2,565,499.46
6	116682	2454435	2454435	MEJORAMIENTO DE LA INFRAESTRUCTURA VIAL URBANA EN EL AA HH VILLA SAN ANTONIO DISTRITO DE SANTA RITA DE SIGUAS PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	247	S/ 3,947,118.66
7	119114	2457901	2457901	MEJORAMIENTO DEL CAMINO VECINAL EMP AR 598 SIPIA QUECHUALLA 4 DISTRITOS DE LA PROVINCIA DE LA UNION DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	210	334	S/ 11,473,507.93

8	120221	2330691	2330691	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL SECTOR 3 4 Y 5 DEL ASENTAMIENTO URBANO MUNICIPAL HORACIO ZEBALLOS GÁMEZ DEL DISTRITO DE SOCABAYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA SECTOR IV	Contrata	SUMA ALZADA	Finalizado	120	237	S/ 5,613,990.04
9	124126	2371025	2371025	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ASOCIACIÓN CENTRO POBLADO VIRGENCITA DE CHAPI VILLA VICTORIA EX LA GONZALES Y ASOCIACIÓN DE VIVIENDA LA POSADA EN LA LOCALIDAD DE PAMPAS VIEJAS DEL DISTRITO DE SOCABAYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	229	S/ 1,228,009.24
10	124825	2454294	2454294	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA CALLE GOLGOTA CALLE SANTO DOMINGO CALLE OLIMPICA CALLE 6 CALLE 7 CALLE 8 CALLE 10 CALLE 11 CALLE 12 Y PASAJE 3 DE LA ZONA D DEL PUEBLO JOVEN GENERALISISMO SAN MARTIN DEL DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	180	214	S/ 6,192,828.75
11	128694	2432448	2432448	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA VIA DE INGRESO PLAYA SECTOR SOMBRERO GRANDE DEL DISTRITO DE MEJIA PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	60	79	S/ 1,465,244.62
12	129413	2335299	374394	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL PUEBLO TRADICIONAL LA PAMPA DISTRITO DE SOCABAYA AREQUIPA AREQUIPA IV ETAPA	Contrata	SUMA ALZADA	Finalizado	105	144	S/ 1,429,674.17
13	130144	2262053	296856	MEJORAMIENTO DE LA INFRAESTRUCTURA VIAL INTEGRAL VEREDAS BERMAS Y PASAJE EN EL CENTRO POBLADO SEMI RURAL PACHACUTEC DISTRITO DE CERRO COLORADO AREQUIPA AREQUIPA ETAPA III FRENTE I	Contrata	PRECIOS UNITARIOS	Finalizado	240	1174	S/ 66,619,398.60

14	131372	2479645	2479645	MEJORAMIENTO DEL SERVICIO DE DRENAJE PLUVIAL EN EL PUEBLO TRADICIONAL DE YARABAMBA DEL DISTRITO DE YARABAMBA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	105	163	S/ 3,104,732.20
15	135495	2474725	2474725	MEJORAMIENTO DE LOS SERVICIOS DE MOVILIDAD URBANA DE LAS VÍAS SECUNDARIAS en la Asociación de Vivienda Villa Magisterial DEL DISTRITO DE CERRO COLORADO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	240	413	S/ 10,783,667.19
16	138479	2403403	2403403	MEJORAMIENTO DE SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA CALLE N 21 ENTRE LA URBANIZACION LA FLORIDA Y PUEBLO JOVEN MI PERU DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA REGION AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	146	S/ 2,164,745.74
17	139288	2450868	2450868	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA VIA PRINCIPAL DE INGRESO AL CENTRO DE SERVICIOS DEL ASENTAMIENTO D4 EN EL CENTRO POBLADO JUAN VELASCO ALVARADO DEL DISTRITO DE MAJES PROVINCIA DE CAYLLOMA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	210	324	S/ 10,970,622.20
18	140630	2494652	2494652	MEJORAMIENTO DEL SERVICIO DE TRANSITABLIDAD VEHICULAR Y PEATONAL EN LA AVENIDA SAN MARTIN TRAMO DESDE LA CALLE MANUEL MUÑOZ NAJAR HASTA LA CALLE RAMO CASTILLA DISTRITO DE MIRAFORES PROVINCIA DE AREQUIPA REGION DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	135	150	S/ 3,006,450.20
19	142871	2494323	2494323	MEJORAMIENTO DEL SERVICIOS DE MOVILIDAD URBANA EN LA AVENIDA VILLA HERMOSA TRAMO CALLE J M CUADROS TERMINAL DEL RIO SECO DISTRITO DE CERRO COLORADO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	225	707	S/ 13,533,815.67
20	142925	2197926	2197926	MEJORAMIENTO DEL SISTEMA VIAL DE LAS VIAS LOCALES EN LA ASOCIACION DE TRABAJADORES DEL MERCADO MAYORISTA ZONA B CONO NORTE DISTRITO DE CERRO COLORADO AREQUIPA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	258	S/ 4,576,234.00

21	144449	2508711	2508711	MEJORAMIENTO DEL SERVICIO DE PONTON VEHICULAR Y PEATONAL EN LA IRRIGACION PUNTA BOMBON DEL C P PUNTA DE BOMBON Y DEL ANEXO SAN JUAN DE CATAS DEL DISTRITO DE PUNTA DE BOMBON PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	75	80	S/ 779,362.53
22	145197	2502406	2502406	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AV LOS ALPES EN EL PUEBLO JOVEN AUGUSTO FREYRE GARCIA MONTERRROSO LOS ALPES DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	192	S/ 3,135,060.89
23	145198	2475629	2475629	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA CALLE NAZARENO PROLONGACION CALLE EMILIANO HUAMANTICA Y PROLONGACION CALLE UMACHIRI DEL ASENTAMIENTO HUMANO AMPLIACION CIUDAD BLANCA II Y LA ZONA A DEL PUEBLO JOVEN CIUDAD BLANCA DEL DISTRITO DE PAUCARPATA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	181	S/ 2,756,271.31
24	145204	2211319	206557	MEJORAMIENTO DE LA INFRAESTRUCTURA VIAL EN LOS AAHH HABITAD LA PAMPA Y PUEBLO NUEVO DEL DISTRITO DE SAMUEL PASTOR PROVINCIA DE CAMANA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	212	S/ 3,293,312.28
25	145208	2342736	381459	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA VIA DE CIRCUNVALACION DEL CENTRO POBLADO DE CHIVAY DISTRITO DE CHIVAY PROVINCIA DE CAYLLOMA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	152	S/ 13,232,376.57
26	147589	2500615	2500615	MEJORAMIENTO DE LA AVENIDA EL BOSQUE Y AVENIDA AREQUIPA EN EL SECTOR DE LA CAMPIÑA DISTRITO DE SOCABAYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	202	S/ 2,757,221.61
27	148257	2508682	2508682	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VIAL INTERURBANA EN LA VÍA DESDE EL BADÉN SOGAY QUEQUEÑA HASTA EL INGRESO AL PUEBLO TRADICIONAL DE SOGAY DEL DISTRITO DE YARABAMBA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	488	S/ 2,346,289.62

28	148997	2519788	2519788	MEJORAMIENTO DEL SERVICIO DE TRASITABILIDAD VEHICULAR Y PEATONAL DE LA VIA DEL CIRCUITO DE PLAYAS TRAMO PLAYA 3 PLAYA ALBATROS Y PLAYA LAS ROCA DISTRITO DE MOLLENDO PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	135	229	S/ 5,629,553.84
29	149679	2194794	245281	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA VIA CONECTORA DE LOS CENTROS POBLADOS NUEVA ISRAEL VIRGEN DEL ROSARIO VIRGEN DE CHAPI SEÑOR DE HUANCA HEROES DEL CENEPA LOS OLIVOS NUEVO MILENIO CERRITO BELEN PUEBLO LIBRE AMPLIACION ATALAYA I ZONA A Y AMPLIACION ATALAYA I ZONA B LOS ALPES LOS BALCONES DEL DISTRITO DE MARIANO MELGAR CENTRO POBLADO DE MARIANO MELGAR DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA REGIÓN AREQUIPA III ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	247	S/ 4,036,101.14
30	149891	2507397	2507397	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL PUEBLO DE QUICACHA DEL DISTRITO DE QUICACHA PROVINCIA DE CARAVELI DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	144	S/ 2,135,267.49
31	150327	2435648	2435648	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA CALLE 20 UPIS PAISAJISTA DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	120	127	S/ 998,590.10
32	151336	2417406	2417406	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA ASOCIACION EL BOSQUE Y 11 DE SETIEMBRE DEL DISTRITO DE TIABAYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	224	S/ 4,061,589.28
33	151441	2343157	381845	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL AA HH PUEBLO VIEJO DISTRITO PROVINCIA DE AREQUIPA DEPARTAMENTO AREQUIPA	Contrata	SUMA ALZADA	Finalizado	180	280	S/ 4,771,461.90

34	151467	2479064	2479064	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DE LAS CALLES JOSE OLAYA Y VIRGEN DEL ROSARIO EN EL ASENTAMIENTO HUMANO VILLA ASUNCION DISTRITO DE ALTO SELVA ALEGRE PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	91	S/ 1,057,458.19
35	151547	2166266	239252	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR EN LA ASOCIACION DE VIVIENDA AMPLIACION SOCABAYA DISTRITO DE SOCABAYA AREQUIPA AREQUIPA VI ETAPA	Contrata	SUMA ALZADA	Finalizado	120	167	S/ 1,876,737.37
36	152123	2508649	2508649	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL JIRON N 1 2 3 4 5 Y CALLE N 15 EN LA ASOCIACION CAPITAN FAP JOSE ABELARDO QUIÑONES 1RA ETAPA DISTRITO DE YURA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA I ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	182	S/ 3,421,153.81
37	152176	2284114	325942	RECUPERACION Y MEJORAMIENTO DE LA INFRAESTRUCTURA VIAL Y PEATONAL DE LA AVENIDA SAN FERNANDO EN EL PUEBLO TRADICIONAL LA PAMPA DISTRITO DE SOCABAYA AREQUIPA AREQUIPA II ETAPA	Contrata	SUMA ALZADA	Finalizado	75	100	S/ 929,649.31
38	152313	2516435	2516435	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AV CARACAS DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	180	227	S/ 5,229,008.43
39	152314	2513307	2513307	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AV CEMENTERIO DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	166	S/ 1,874,482.56
40	152315	2506230	2506230	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AVENIDA INGLATERRA EN LA URB 13 DE ENERO DEL DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	105	246	S/ 2,099,314.15

41	153541	2527063	2527063	MEJORAMIENTO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL ASENTAMIENTO HUMANO LA RINCONADA DEL DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA I ETAPA	Contrata	SUMA ALZADA	Finalizado	120	347	S/ 1,049,428.17
42	153741	2461879	2461879	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA ASOCIACION DE VIVIENDA LOS ANGELES DEL DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	60	63	S/ 1,158,660.76
43	154024	2305596	344356	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ZONA 2 SECTOR C DE LA ASOCIACIÓN URBANIZADORA CIUDAD DE DIOS DISTRITO DE YURA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA I ETAPA	Contrata	SUMA ALZADA	Finalizado	150	177	S/ 6,718,766.38
44	154296	2512516	2512516	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA CALLE 06 EN LOS AAHH ASOCIACION PRO VIVIENDA LOS BALCONES DE CHILINA Y JR MARIANO MELGAR TRAMO INTERSECCION CALLE 05 JR PEDRO GARZON EN EL P J INDEPENDENCIA ZONA A DEL DISTRITO DE ALTO SELVA ALEGRE PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	60	90	S/ 975,059.72
45	154719	2419510	2419510	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DEL AA HH JUAN VELASCO ALVARADO DEL DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	139	S/ 6,240,348.71
46	155050	2440068	2440068	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LAS CALLES MALVINAS URUGUAY Y AV AREQUIPA DEL DISTRITO DE ORCOPAMPA PROVINCIA DE CASTILLA DEPARTAMENTO DE AREQUIPA III ETAPA con CUI 2440068	Contrata	SUMA ALZADA	Finalizado	90	121	S/ 924,790.35

47	155440	2314622	352190	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA AVENIDA LOS COLONIZADORES DISTRITO DE MAJES CAYLLOMA AREQUIPA II ETAPA	Contrata	SUMA ALZADA	Finalizado	270	271	S/ 23,141,160.82
48	155931	2419575	2419575	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA URB LA EXPLANADA Y BUEN AMANECER DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	150	182	S/ 1,248,177.54
49	155932	2418169	2418169	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR EN EL A H VILLA CONTINENTAL II ETAPA Y CESAR VALLEJO DEL DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	193	S/ 3,184,765.13
50	156035	2530495	2530495	REMODELACION DE CIRCULACION VEHICULAR Y O ESTACIONAMIENTO EN EL MIRADOR DEL DISTRITO DE SACHACA	Contrata	SUMA ALZADA	Finalizado	90	91	S/ 811,442.95
51	156047	2508681	2508681	CREACION DE LOS SERVICIOS DE DRENAJE PLUVIAL TRAMO CARRETERA CERRO VERDE P J VIRGEN DE LA CANDELARIA P J AMPLIACION CERRO VERDE P J CERRO VERDE Y P J ALTO CERRO VERDE DEL DISTRITO DE UCHUMAYO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	272	S/ 3,812,647.43
52	156254	2237004	258879	CONSTRUCCIÓN MEJORAMIENTO DE LA INFRAESTRUCTURA VIAL Y PEATONAL DE APROMA RAMIRO PRIALE Y VILLA EL SOL DEL SECTOR DE PAMPAS DE POLANCO DISTRITO DE ALTO SELVA ALEGRE AREQUIPA AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	93	S/ 1,375,589.88
53	156383	2444005	2444005	EJECUCIÓN DE OBRA MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES JORGE CHAVEZ JOSE GALVEZ PAZ SOLDAN MIGUEL GRAU FRANCISCO BOLOGNESI RODRIGUEZ BALLON RAMON CASTILLA LINO URQUIETA CALVARIO MISTI Y TNTE RODRÍGUEZ EN EL P T DE MIRAFLORES DEL DISTRITO DE MIRAFLORES PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA 1RA ETAPA CON CUI 2444005	Contrata	PRECIOS UNITARIOS	Finalizado	210	213	S/ 14,041,302.00

54	156712	2536678	2536678	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL POR LA PANAMERICANA SUR EN LA LOCALIDAD EL PUENTE DEL DISTRITO DE OCOÑA PROVINCIA DE CAMANA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	75	75	S/ 772,719.31
55	156826	2473816	2473816	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DEL ASENTAMIENTO HUMANO AMPLIACION ALTO CENEPA Y EL ASENTAMIENTO HUMANO VILLA ALTO CENEPA DEL DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	169	S/ 2,823,325.95
56	157695	2468092	2468092	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLE 22 DE AGOSTO Y CALLE ROSAPATA DISTRITO DE MIRAFLORES PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA CON CUI 2468092	Contrata	PRECIOS UNITARIOS	Finalizado	120	158	S/ 2,853,268.67
57	157724	2541485	2541485	MEJORAMIENTO Y AMPLIACION DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL AL INGRESO DE LA AV LAS TORRES CRUCE CON LA AV CHARACATO YARABAMBA DEL DISTRITO DE CHARACATO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	109	S/ 1,597,289.99
58	158675	2531294	2531294	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR DE INTERCONEXIÓN ENTRE LOS ASENTAMIENTOS B1 Y C1 EN EL CENTRO POBLADO BELLO HORIZONTE DISTRITO DE MAJES PROVINCIA DE CAYLLOMA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	165	189	S/ 4,284,018.56
59	158678	2517965	2517965	MEJORAMIENTO DEL SERVICIO DEL TRANSITABILIDAD VEHICULAR Y PEATONAL DEL PUENTE ENTRE EL CENTRO POBLADO EL PIONERO Y ASOCIACIÓN SAN FRANCISCO DE ASÍS DEL DISTRITO DE MAJES PROVINCIA DE CAYLLOMA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	123	S/ 672,099.75
60	158681	2198004	278003	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES SECUNDARIAS SECTOR ESTE CENTRO POBLADO SANTA MARIA DE LA COLINA DISTRITO DE MAJES CAYLLOMA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	240	308	S/ 13,636,355.17

61	158708	2526610	2526610	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA CALLE PROLONGACION JIRÓN MARTÍNEZ APETEC ADEMIC Y APIDEC DEL DISTRITO DE CAMANÁ PROVINCIA DE CAMANÁ DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	150	233	S/ 6,335,337.93
62	158954	2158578	219477	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR EN EL PUEBLO JOVEN LA TOMILLA DISTRITO DE CAYMA PROVINCIA DE AREQUIPA REGION AREQUIPA IX ETAPA	Contrata	SUMA ALZADA	Finalizado	90	153	S/ 624,513.37
63	158957	2150975	193066	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR EN EL PUEBLO JOVEN VILLA CONTINENTAL DISTRITO DE CAYMA AREQUIPA AREQUIPA IIETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	431	S/ 4,516,539.46
64	158962	2419510	2419510	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DEL AA HH JUAN VELASCO ALVARADO DEL DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	180	S/ 1,293,756.55
65	160001	2181482	249386	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DEL AA HH VILLA FLORIDA DISTRITO DE ALTO SELVA ALEGRE AREQUIPA AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	106	S/ 1,527,278.38
66	161157	2540551	2540551	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA VIA PRINCIPAL DESDE EL CRUCE DE LA ENTRADA DE MEJÍA HASTA LA SALIDA EN EL CRUCE CON LA PLAYA LOS MEDANOS DISTRITO DE MEJIA PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	279	S/ 3,086,235.32
67	161982	2460526	2460526	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LOS CENTROS POBLADOS DE VILLA LINARES Y VILLA DON JORGE DEL DISTRITO DE SAMUEL PASTOR PROVINCIA DE CAMANA DEPARTAMENTO DE AREQUIPA ETAPA 1	Contrata	SUMA ALZADA	Finalizado	150	171	S/ 2,799,888.02

68	162097	2328384	364744	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL A H PROGRAMA DE HABILITACION URBANA EL MIRADOR DE AREQUIPA ZONA A DISTRITO DE ALTO SELVA ALEGRE AREQUIPA AREQUIPA SEGUNDA ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	111	S/ 1,275,304.63
69	162458	2463158	2463158	CREACION DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL COMITE 3 PUEBLO JOVEN 8 DE DICIEMBRE DISTRITO DE TIABAYA PROVINCIA DE AREQUIPA Y DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	336	S/ 5,081,203.04
70	162495	2328169	2328169	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL CENTRO POBLADO EL PUENTE HUACAPUY SECTOR EL PUENTE DE FIERRO DISTRITO DE JOSE MARIA QUIMPER PROVINCIA DE CAMANÁ AREQUIPA	Contrata	SUMA ALZADA	Finalizado	240	386	S/ 8,561,181.49
71	165190	2496234	2496234	MEJORAMIENTO DE LA TRANSITABILIDAD VIAL QUE SE UBICA ENTRE LA VÍA VEHICULAR QUICHINIHUAYA Y LA ZONA DENOMINADA EL INGENIO Y MOLINO VIEJO EN EL PUEBLO TRADICIONAL QUICHINIHUAYA DEL DISTRITO DE YARABAMBA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	150	220	S/ 3,682,407.44
72	166306	2544817	2544817	MEJORAMIENTO DE ELEMENTOS REDUCTORES DE VELOCIDAD GIBAS Y SEÑALES DE TRAFICO DE LA INFRAESTRUCTURA VIAL DE LOS ANEXOS DEL DISTRITO DE APLAO PROVINCIA DE CASTILLA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	60	61	S/ 371,319.48
73	166422	2471195	2471195	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA CALLE ATICO Y CALLE AREQUIPA DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA JACOBO HUNTER DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	105	S/ 820,076.53

74	166573	2194794	245281	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA VIA CONECTORA DE LOS CENTROS POBLADOS NUEVA ISRAEL VIRGEN DEL ROSARIO VIRGEN DE CHAPI SEÑOR DE HUANCA HEROES DEL CENEPA LOS OLIVOS NUEVO MILENIO CERRITO BELEN PUEBLO LIBRE AMPLIACION ATALAYA I ZONA A Y AMPLIACION ATALAYA I ZONA B LOS ALPES LOS BALCONES DEL DISTRITO DE MARIANO MELGAR CENTRO POBLADO DE MARIANO MELGAR DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA REGIÓN AREQUIPA IV ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	271	S/ 6,804,501.49
75	166604	2454268	2454268	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR EN EL ASENTAMIENTO HUAMANO CERRITO BELEN DEL DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA I ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	274	S/ 2,890,617.12
76	166655	2546147	2546147	CREACION DEL SERVICIO DE CIRCULACION VIAL EN LA INTERCONECCION DE LOS ASENTAMIENTOS HUMANOS VIRGEN DE LA CANDELARIA JOSE ABELARDO QUIÑONES JOSE CARLOS MARIATEGUI Y MANUEL A ODRIA DEL DISTRIO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	189	723	S/ 7,921,305.31
77	166662	2196552	279962	MEJORAMIENTO DEL SISTEMA VIAL PEATONAL ADECUANDO EL SISTEMA DE DRENAJE PLUVIAL Y SEÑALIZACION DE TRANSITO EN LA URB MANUEL PRADO DISTRITO DE PAUCARPATA AREQUIPA AREQUIPA III ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	170	S/ 2,953,603.85
78	167368	2461308	2461308	MEJORAMIENTO DEL SERVICIO DE TRANSTABILIDAD VEHICULAR Y PEATONAL DE LA VIA DE CONEXIÓN ENTRE EL ASENTAMIENTO HUMANO PATASAGUA Y EL PUEBLO TRADICIONAL ALTO TUNALES DISTRITO DE TIABAYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	195	S/ 4,300,425.45

79	167424	2540868	2540868	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL TRAMO INTERSECCION AV 3 A H PRIMERO DE JUNIO Y EL JORIN 15 CON LA AV 1 DE LA ASOC DE VIV Y NICROEMPRESARIOS ONCE DE MAYO ASOC DE INDUSTRIALES SR DE LOS MILAGROS Y PARTE ALTA DSITRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA I ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	192	S/ 7,867,862.28
80	168094	2309769	331277	MEJORAMIENTO DE LA INFRAESTRUCTURA VEHICULAR Y PEATONAL EN EL SECTOR 2 DEL ASENTAMIENTO URBANO MUNICIPAL HORACIO ZEBALLOS GÁMEZ DISTRITO DE SOCABAYA AREQUIPA AREQUIPA II ETAPA COMPONENTE 2	Contrata	SUMA ALZADA	Finalizado	150	232	S/ 3,629,241.63
81	168469	2198535	271893	MEJORAMIENTO INTEGRAL DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DE LAS CALLES FALTANTES EN EL P J BUENOS AIRES DISTRITO DE CAYMA AREQUIPA AREQUIPA III ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	344	459	S/ 6,710,288.55
82	168950	2460526	2460526	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LOS CENTROS POBLADOS DE VILLA LINARES Y VILLA DON JORGE DEL DISTRITO DE SAMUEL PASTOR PROVINCIA DE CAMANA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	186	S/ 3,889,553.06
83	169467	2243789	290839	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DEL PUEBLO JOVEN SANTO DOMINGO DEL DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	322	S/ 1,458,264.54
84	169520	2540925	2540925	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AV CORTADERAS EN LA ASOCIACION DE VIVIENDA LAS CORTADERAS DE CAYMA Y ALEDAÑOS DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	75	166	S/ 1,643,581.38

85	169592	2248353	308062	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS VIAS VIA DE INGRESO Y AV NRO 2 DE LA ASOCIACION DE VIVIENDA SAN LAZARO CALLE NRO 4 DE LA ASOCIACION DE VIVIENDA BALCONES DE CHILINA AV NRO 1 DEL AGRUPAMIENTO DE FAMILIAS VILLA CONFRATERNIDAD AV N 1 DEL A H ASOCIACION DE VIVIENDA VILLA ECOLOGICA DISTRITO DE ALTO SELVA ALEGRE AREQUIPA AREQUIPA SEGUNDA ETAPA	Contrata	SUMA ALZADA	Finalizado	150	286	S/ 8,534,142.33
86	169669	2403318	2403318	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA URB POPULAR LOURDES DISTRITO DE MOLLENDO PROVINCIA DE ISLAY REGIÓN AREQUIPA	Contrata	SUMA ALZADA	Finalizado	210	322	S/ 2,828,291.47
87	169730	2164317	228773	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES EN LOS AA HH UNION COSTANERA EL PALMO PROGRESO EL VALLE Y EL FRISCO DISTRITO DE DEAN VALDIVIA ISLAY AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	240	336	S/ 11,843,540.37
88	170012	2520485	2520485	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA 8VA CUADRA DE LA CALLE AYACUCHO DEL DISTRITO DE CARAVELI PROVINCIA DE CARAVELI DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	133	S/ 1,003,076.89
89	170763	2305596	344356	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ZONA 2 SECTOR C DE LA ASOCIACIÓN URBANIZADORA CIUDAD DE DIOS DISTRITO DE YURA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	97	S/ 2,845,963.76
90	171514	2455618	2455618	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ASENTAMIENTO HUMANO MIRADOR EL TRIUNFO DEL DISTRITO DE LA JOYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA I ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	351	S/ 3,515,247.34
91	171666	2432659	2432659	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES DE LA URB JOSE CARLOS MARIATEGUI DEL DISTRITO DE MEJIA PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	83	S/ 1,338,136.26

92	171965	2558365	2558365	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL ENTRE LA PROLONGACION DOS DE MAYO Y URB GRANDA DISTRITO DE CAMANA PROVINCIA DE CAMANA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	120	121	S/ 479,144.04
93	172624	2287808	329581	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL PASAJE MICAELA BASTIDAS DE UPIS FRAY MARTIN DE PORRES DISTRITO DE JACOBO HUNTER AREQUIPA AREQUIPA	Contrata	SUMA ALZADA	Finalizado	60	138	S/ 948,935.76
94	172763	2337405	2337405	MEJORAMIENTO DE LA INFRAESTRUCTURA VIAL EN LA IRRIGACIÓN BAJO CURAL DISTRITO DE UCHUMAYO AREQUIPA AREQUIPA III ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	165	203	S/ 6,120,480.53
95	172767	2512060	2512060	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA CALLE TUCUMAN DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	90	112	S/ 1,219,902.81
96	173073	2534242	2534242	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA LOCALIDAD DE LA FLORIDA AAHH PLAYA HERMOSA EN EL DISTRITO DE ATICO PROVINCIA DE CARAVELÍ DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	238	S/ 3,675,685.12
97	173720	2454268	2454268	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR EN EL ASENTAMIENTO HUMANO CERRITO BELÉN DEL DISTRITO DE MARIANO MELGAR PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	278	S/ 2,890,617.12
98	173831	2517114	2517114	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA CALLE COLON TRAMO PUENTE COLON HASTA CALLE TRES ACEQUIAS DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	211	263	S/ 5,444,719.90
99	174057	2322302	359239	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL PUEBLO JOVEN JERUSALEN ZONA A DISTRITO DE MARIANO MELGAR AREQUIPA AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	231	S/ 1,562,102.43

100	175438	2512753	2512753	MEJORAMIENTO DE LA TRANSITABILIDAD VIAL Y PEATONAL DE LAS CALLES Y PASAJES DEL ANEXO LA BANDA DEL DISTRITO DE YARABAMBA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	120	184	S/ 1,468,952.58
101	175703	2408914	2408914	MEJORAMIENTO DEL SERVICIO URBANO EN EL ASENTAMIENTO HUMANO LA MERCED DISTRITO DE JACOBO HUNTER PROVINCIA AREQUIPA DEPARTAMENTO AREQUIPA CUI Nro 2408914 CUARTA ETAPA componente MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL JIRON PRINCIPAL MANZANAS A B B C D E F G Y PASAJES DEL ASENTAMIENTO HUMANO LA MERCED DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	30	50	S/ 256,205.54
102	175705	2339196	378064	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DEL PASAJE TASAHUAYO TRAMO DE LA PROLONGACION AVENIDA DOLORES HASTA LA AVENIDA COLON DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO AREQUIPA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	152	S/ 2,663,545.55
103	176724	2562584	2562584	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AVENIDA Y CALLES DEL ASENTAMIENTO HUMANO PUERTO NUEVO DISTRITO DE ISLAY PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	100	S/ 2,826,338.83
104	177849	2433692	2433692	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR UPIS AMPLIACION LA MERCED DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA SEGUNDA ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	248	S/ 2,121,796.67
105	179106	2295534	335804	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL MODULO B DE CIUDAD MAJES DISTRITO DE MAJES CAYLLOMA AREQUIPA I ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	240	276	S/ 15,894,647.31
106	500252	2474487	2474487	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA ASOCIACIÓN DE VILLA CHACHANI DEL DISTRITO DE CERRO COLORADO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA CUI 2474487	Contrata	PRECIOS UNITARIOS	Finalizado	180	352	S/ 4,443,760.99

107	500532	2286405	328367	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ASOCIACIÓN DE VIVIENDA FRANCISCO GARCÍA CALDERÓN DISTRITO DE CERRO COLORADO AREQUIPA AREQUIPA II ETAPA CUI 2286405	Contrata	PRECIOS UNITARIOS	Finalizado	120	403	S/ 7,857,517.13
108	500558	2464687	2464687	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA CALLE SACSAYHUAMAN DE UPIS SAN JUAN BAUTISTA CALLE 2 DEL AA HH SEÑOR DE HUANCA CALLE GRAN MARCELO Y CAMINITO VERDE DEL AA HH LOMA VERDE DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA PRIMERA ETAPA	Contrata	SUMA ALZADA	Finalizado	75	214	S/ 1,486,325.86
109	500606	2461274	2461274	MEJORAMIENTO DE LA INFRAESTRUCTURA VEHICULAR Y PEATONAL EN LA AVENIDA BELLAVISTA AV FRANCISCO MOSTAJO AV AREQUIPA DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	150	325	S/ 3,714,432.92
110	500972	2568475	2568475	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ASOCIACION PRO VIVIENDA VILLA UNION DEL DISTRITO DE UCHUMAYO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	170	S/ 2,295,873.37
111	501080	2507401	2507401	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL CENTRO POBLADO DE TIERRAS BLANCAS DEL DISTRITO DE QUICACHA PROVINCIA DE CARAVELI DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	150	277	S/ 4,906,508.87
112	501177	2552010	2552010	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VIAL INTERURBANA DE LA VIA VECINAL AR 827 TRAMO PE1SD EL CRUCERO EN EL C P PUNTA DE BOMBON DISTRITO DE PUNTA DE BOMBON PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	162	S/ 2,591,703.81
113	501235	2328169	364546	MEJORAMIENTO DEL SERVICIO TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL CENTRO POBLADO EL PUENTE HUACAPUY SECTOR EL PUENTE DE FIERRO DISTRITO JOSE MARIA QUIMPER PROVINCIA DE CAMANA REGION AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	240	387	S/ 9,411,724.05

114	502172	2435172	2435172	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE AV PARIS HASTA LA INTERSECCION CALLE FRANCIA PUEBLO JOVEN HUNTER DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA Y DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	124	S/ 3,046,199.42
115	502303	2532387	2532387	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DEL PUEBLO TRADICIONAL DE CAYMA Y ALEDAÑOS DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA CUI 2532387	Contrata	PRECIOS UNITARIOS	Finalizado	90	232	S/ 2,320,511.62
116	503203	2508995	2508995	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA CALLE GAMANIEL CHURATA DE UPIS PAISAJISTA Y ASOCIACION URBANIZADORA ALTO LA ALIANZA DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	397	S/ 1,947,457.03
117	503216	2408908	2408908	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL JIRON PRINCIPAL MANZANAS A B B C D E F G Y PASAJES DEL ASENTAMIENTO HUMANO LA MERCED DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA CUARTA ETAPA	Contrata	SUMA ALZADA	Finalizado	75	387	S/ 415,375.65
118	504035	2567377	2567377	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA ASOCIACIÓN PRO VIVIENDA EL TREBOL DEL DISTRITO DE UCHUMAYO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	134	S/ 1,932,427.18
119	504302	2525874	2525874	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL SECTOR DEL OLIVAR DEL ANEXO DE HUACAPUY DEL DISTRITO DE JOSÉ MARÍA QUIMPER PROVINCIA DE CAMANA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	191	232	S/ 3,761,713.63

120	504419	2444005	2444005	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES JORGE CHAVEZ JOSE GALVEZ PAZ SOLDAN MIGUEL GRAU FRANCISCO BOLOGNESI RODRIGUEZ BALLON RAMON CASTILLA LINO URQUIETA CALVARIO MISTIY TNTE RODRIGUEZ EN EL P T DE MIRAFLORES DEL DISTRITO DE MIRAFLORES PROVINCIA DE AREQUIPA DEPATAMENTO DE AREQUIPA 2da ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	125	S/ 2,796,724.42
121	505623	2523932	2523932	CREACION DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR EN A U I S JUAN XXIII DEL DISTRITO DE MIRAFLORES PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA ETAPA I	Contrata	PRECIOS UNITARIOS	Finalizado	150	217	S/ 2,788,455.91
122	505838	2329624	2329624	MEJORAMIENTO DE LA TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AVENIDA NRO 1 EN LOS AA HH SAN ANTONIO ABAD MIRADOR DE JESUS Y LA ISLA DISTRITO DE PAUCARPATA AREQUIPA AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	150	180	S/ 8,334,132.54
123	506576	2523331	2523331	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR EN EL PUEBLO JOVEN TAHUANTINSUYO DEL DISTRITO DE MIRAFLORES PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	270	263	S/ 4,130,558.26
124	509263	2473793	2473793	CREACIÓN DEL SISTEMA DE DRENAJE PLUVIAL EN LOS SECTORES URB LOS ALAMOS URB FUNDO LA TEJADA FRANK MICHEL URB QUINTA EL SOL EL ROSARIO I Y OTROS COMPRENDIDOS DENTRO DE LA CUENCA Y AFLUENTES DE LA QUEBRADA DE CHULLO DISTRITO DE CERRO COLORADO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA CUI 2473793	Contrata	PRECIOS UNITARIOS	Finalizado	60	363	S/ 1,758,826.20
125	509301	2513696	2513696	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DEL PSJ LA RONDA PSJ PROLONGACIÓN LAS BEATAS CALLE URUBAMBA PSJ LA CANOA PSJ ALARIFES CALLE CUSCO TRAMO LIMITES ENTRE P T CARMEN ALTO P T TRONCHADERO Y P T ACEQUIA ALTA CALLE LAS AZUCENAS CALLES FALTANTES AA HH MARÍA PARADO DE BELLIDO BLOQUE 2 5 LOCALIDADES DEL DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA CUI N 2513696	Contrata	PRECIOS UNITARIOS	Finalizado	180	253	S/ 4,734,764.64

126	510157	2403317	2403317	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR MALECON DOLORES DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA REGIÓN AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	120	S/ 2,026,052.98
127	510293	2199361	2199361	MEJORAMIENTO DE LA INFRAESTRUCTURA VIAL VÍAS Y VEREDAS EN LA ASOC DE VIVIENDA GUARDIA REPUBLICANA DISTRITO DE CERRO COLORADO AREQUIPA AREQUIPA III ETAPA CUI 2199361	Contrata	SUMA ALZADA	Finalizado	180	301	S/ 1,415,061.14
128	510335	2330691	2330691	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL SECTOR 3 4 Y 5 DEL ASENTAMIENTO URBANO MUNICIPAL HORACIO ZEBALLOS GÁMEZ DEL DISTRITO DE SOCABAYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA III ETAPA	Contrata	SUMA ALZADA	Finalizado	105	254	S/ 2,875,446.93
129	511049	2501643	2501643	MEJORAMIENTO EL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA AVIS PORTO ALEGRE DISTRITO DE ISLAY PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	122	S/ 1,382,051.34
130	511391	2469054	2469054	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AVENIDA DOLORES TRAMO AVENIDA ESTADOS UNIDOS HASTA EL PUENTE DOLORES DEL DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	144	S/ 3,279,365.09
131	511953	2596592	2596592	CREACION DEL SERVICIO DE DRENAJE PLUVIAL EN LA ZONA A Y B DE LA ASOCIACION DE VIVIENDA TALLER GRANJA LOS GIRASOLES DISTRITO DE MIRAFLORES PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	149	S/ 1,046,850.45
132	513074	2404316	2404316	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL P J SAN JOSÉ BLOQUE 1 MARGEN DERECHA DISTRITO DE TIABAYA PROVINCIA DE AREQUIPA REGIÓN AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	243	S/ 2,960,919.63

133	513780	2244440	2244440	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA AV JUAN VELAZCO ALVARADO AV ALFONSO UGARTE Y CALLE KOLQUE PARQUE EN LA AVTIS EL ALTIPLANO DISTRITO DE YURA AREQUIPA AREQUIPA II ETAPA	Contrata	SUMA ALZADA	Finalizado	75	148	S/ 2,086,644.46
134	514178	2317484	2317484	MEJORAMIENTO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL ASENTAMIENTO HUMANO VILLA MILAGROS DISTRITO DE YURA AREQUIPA AREQUIPA II ETAPA	Contrata	SUMA ALZADA	Finalizado	120	154	S/ 3,437,848.44
135	515179	2474919	2474919	CREACION DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DEL ANILLO VIAL EN EL ASENTAMIENTO HUMANO VIRGEN DE LAS PEÑAS DISTRITO DE TIABAYA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	210	313	S/ 7,400,797.88
136	516247	2551744	2551744	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA CALLE 2 Y 3 DEL PUEBLO TRADICIONAL TINGO GRANDE DISTRTIO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA CUI 2551744	Contrata	PRECIOS UNITARIOS	Finalizado	90	119	S/ 889,612.83
137	517000	2561513	2561513	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LA CALLE N 07 CALLE N 05 Y CALLE N 03 DE LA URBANIZACION ESPERANZA ADEPA DEL DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	SUMA ALZADA	Finalizado	120	78	S/ 1,685,796.03
138	517035	2480694	2480694	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR DE LAS CALLES 30 Y CALLE MORRO DE ARICA EN EL PUEBLO JOVEN INDEPENDENCIA ZONA A DISTRITO DE ALTO SELVA ALEGRE PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	105	140	S/ 1,876,404.66
139	517316	2158578	2158578	MEJORAMIENTO DE LA TRANSITABILIDAD PEATONAL Y VEHICULAR EN EL PUEBLO JOVEN LA TOMILLA DISTRITO DE CAYMA AREQUIPA AREQUIPA X ETAPA	Contrata	SUMA ALZADA	Finalizado	150	349	S/ 5,637,010.44

140	517824	2457349	2457349	SALDO DE OBRA MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS PRINCIPALES CALLES DE LA ASOCIACIÓN DE VIVIENDA VIRGEN DE LA CANDELARIA ASOVICH DISTRITO DE CHARACATO PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA IERA ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	65	324	S/ 1,690,114.30
141	519692	2508521	2508521	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA CALLE CESAR ATAHULPA Y CALLE 1 DE ASOCIACION URBANIZADORA ALTO LA ALIANZA Y AA HH LEON DEL SUR DEL DISTRITO DE JACOBO HUNTER PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	75	96	S/ 1,247,803.17
142	520447	2540551	2540551	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD PEATONAL Y VEHICULAR DE LA VIA PRINCIPAL DESDE EL CRUCE DE LA ENTRADA DE MEJÍA HASTA LA SALIDA EN EL CRUCE CON LA PLAYA LOS MEDANOS DISTRITO DE MEJIA PROVINCIA DE ISLAY DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	60	71	S/ 1,119,727.31
143	521298	2466450	2466450	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS CALLES LOPEZ Y NATEZ PLAZA PRINCIPAL Y CALLE LORETO EN EL DISTRITO DE HUANCARQUI PROVINCIA DE CASTILLA DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	240	260	S/ 3,230,570.06
144	521553	2618321	2618321	AMPLIACION DEL SERVICIO DE DRENAJE PLUVIAL EN LA CALLE 14 DE URB SANTA CATALINA Y CALLE 11 DE COOP DANIEL ALCIDES CARRION HASTA LA AV ANDRES AVELINO CACERES DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO DE LA PROVINCIA DE AREQUIPA DEL DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	75	82	S/ 1,178,979.02
145	522608	2309849	2309849	MEJORAMIENTO DE LA INFRAESTRUCTURA VEHICULAR Y PEATONAL EN EL ASENTAMIENTO HUMANO LA MANSIÓN DE SOCABAYA II DISTRITO DE SOCABAYA AREQUIPA AREQUIPA II ETAPA	Contrata	SUMA ALZADA	Finalizado	120	168	S/ 2,812,557.56

146	523880	2281340	2281340	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL DE LAS AVENIDAS Y CALLES DEL ASENTAMIENTO HUMANO MATARANI 2000 DISTRITO DE ISLAY ISLAY AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	180	199	S/ 5,466,000.00
147	537309	2531366	2531366	REPARACION DE VIAS VECINALES EN EL LA TRAMO DE LA CALLE LA OROYA EN UN TRAMO DE LA CALLE HUAMACHUCO Y EN UN TRAMO DE LA CALLE LA UNION DE LA URBANIZACIÓN SAN MARTIN DE SOCABAYA DISTRITO DE SOCABAYA PROVINCIA AREQUIPA DEPARTAMENTO AREQUIPA I ETAPA CALLE OROYA	Contrata	PRECIOS UNITARIOS	Finalizado	75	91	S/ 922,912.90
148	525522	2520202	2520202	CREACION DEL SERVICIO DE MOVILIDAD URBANA EN LAS VÍAS LOCALES DEL LAS CALLES PERPENDICULARES ENTRE LA CALLE N Y L EN EL CENTRO POBLADO CIUDAD DE DIOS ASOCIACIÓN URBANIZADORA CIUDAD DE DIOS DISTRITO DE YURA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA I ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	134	S/ 5,657,154.93
149	523175	2638946	2638946	REPARACION DE PAVIMENTO EN EL LA CALLES DE URB LA ESTRELLA DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA AREQUIPA DEPARTAMENTO AREQUIPA	Contrata	SUMA ALZADA	Finalizado	45	44	S/ 423,458.06
150	522373	2644324	2644324	REPARACION DE PAVIMENTO RENOVACION DE SEÑALES DE TRÁFICO EN EL LA CALLE N 1 DE LA URB CASA BELLA DISTRITO DE JOSE LUIS BUSTAMANTE Y RIVERO PROVINCIA AREQUIPA DEPARTAMENTO AREQUIPA	Contrata	SUMA ALZADA	Finalizado	45	60	S/ 460,491.25
151	517392	2615245	2615245	MEJORAMIENTO DEL SERVICIO DE MOVILIDAD URBANA EN CALLE JUAN MANUEL POLAR DEL P T URB MARIANO MELGAR Y PJ SANTA ROSA DISTRITO DE MARIANO MELGAR DE LA PROVINCIA DE AREQUIPA DEL DEPARTAMENTO DE AREQUIPA	Contrata	PRECIOS UNITARIOS	Finalizado	120	180	S/ 3,147,505.96
152	516757	2525700	2525700	MEJORAMIENTO DEL SERVICIO DE MOVILIDAD URBANA TRAMO INTERSECCIÓN VÍA NORTE CALLE 2 AA HH CÉSAR VALLEJO CON LA CALLE 6 AV SOL DE ORO HASTA LA VÍA ESTE DISTRITO DE CAYMA PROVINCIA DE AREQUIPA DEPARTAMENTO DE AREQUIPA II ETAPA	Contrata	PRECIOS UNITARIOS	Finalizado	90	106	S/ 3,178,795.29

ANEXO 7: Tabla de agrupación de partidas de cartel CR-001

PARTIDA	CODIGO
CARTEL DE IDENTIFICACION DE LA OBRA (BANNER 3.60x2.40 M.)	CR-001
CARTEL DE IDENTIFICACION DE LA OBRA 3.60X2.40 CON GIGANTOGRAFIA	CR-001
CARTEL DE IDENTIFICACION DE LA OBRA DE 3.60 X 2.40 m	CR-001
CARTEL DE IDENTIFICACION DE LA OBRA DE 3.60X2.40M	CR-001
CARTEL DE IDENTIFICACION DE LA OBRA DE 3.6x2.4m (BIENES)	CR-001
CARTEL DE IDENTIFICACION DE LA OBRA DE 5.40 X 3.60 m	CR-001
CARTEL DE IDENTIFICACIÓN DE OBRA	CR-001
CARTEL DE IDENTIFICACIÓN DE OBRA 2.40 x 3.60	CR-001
CARTEL DE IDENTIFICACIÓN DE OBRA 2.40 X 3.60M	CR-001
CARTEL DE IDENTIFICACION DE OBRA DE 3.60m x 2.40m	CR-001
CARTEL DE OBRA	CR-001
CARTEL DE OBRA (3.60 X 2.40M - C/BANNER)	CR-001
CARTEL DE OBRA (3.60 X 2.40M C/BANER)	CR-001
CARTEL DE OBRA (BANNER 3.60 x 2.40 M.)	CR-001
CARTEL DE OBRA 3.60 x 2.40M	CR-001
CARTEL DE OBRA DE 2.40mx3.60m INCL. COLOCACION	CR-001

ANEXO 8: Tabla agrupación de partidas de cerco perimétrico CP-001

PARTIDA	CODIGO
ADECUACION CERCO PROVISIONAL DE MALLA ARPILLERA Y PUNTALES h=2.50m	CP-001
CERCO PERIMETRICO	CP-001
CERCO PERIMETRICO - MALLA ARPILLERA	CP-001
CERCO PERIMETRICO - PALOS EUCALIPTO- MALLA ARPILLERA	CP-001
CERCO PERIMETRICO DE TELA ARPILLERA	CP-001
CERCO PERIMETRICO PROVISIONAL	CP-001
CERCO PERIMETRICO PROVISIONAL CON MALLA ARPILLERA	CP-001
CERCO PERIMETRICO PROVISIONAL DE ARPILLERA H=2.00M	CP-001
CERCO PERIMETRICO PROVISIONAL DE MALLA ARPILLERA	CP-001
CERCO PROVICIONAL CON PUNTAL Y ESTERA	CP-001
CERCO PROVISIONAL	CP-001
CERCO PROVISIONAL CON ARPILLERA Y PARANTES DE MADERA	CP-001
CERCO PROVISIONAL DE ESTERAS	CP-001
CERCO PROVISIONAL DE MALLA ARPILLERA H=2.0 M.	CP-001

ANEXO 9: Tabla de agrupación de partidas de movilización MD-001

PARTIDA	CODIGO
DESMOVILIZACION DE EQUIPOS, MAQUINARIAS Y HERRAMIENTAS	MD-001
FLETE TERRESTRE	MD-001
FLETE TERRESTRE PARA TRANSPORTE DE MATERIALES DE CONSTRUCCION	MD-001
MOVILIZACION DE EQUIPOS, MAQUINARIAS Y HERRAMIENTAS	MD-001

MOVILIZACION DE HERRAMIENTAS Y EQUIPOS	MD-001
MOVILIZACION DE MAQUINARIAS Y EQUIPOS	MD-001
MOVILIZACION Y DESMOVILIZACION DE EQUIPO	MD-001
MOVILIZACION Y DESMOVILIZACION DE EQUIPO Y MATERIALES	MD-001
MOVILIZACION Y DESMOVILIZACION DE EQUIPOS	MD-001
MOVILIZACION Y DESMOVILIZACIÓN DE EQUIPOS	MD-001
MOVILIZACION Y DESMOVILIZACION DE EQUIPOS Y MAQUINARIAS	MD-001
MOVILIZACION Y DESMOVILIZACION DE EQUIPOS Y MATERIALES	MD-001
MOVILIZACION Y DESMOVILIZACION DE MAQUINARIA	MD-001
MOVILIZACION Y DESMOVILIZACION DE MAQUINARIA, HERRAMIENTAS Y EQUIPO	MD-001
MOVILIZACION Y DESMOVILIZACION MAQUINARIA Y/O EQUIPO	MD-001
MOVILIZACIÓN Y DESMOVILIZACIÓN DE EQUIPO PESADO	MD-001

ANEXO 10: Tabla de agrupación de partidas de limpieza LT-001

PARTIDA	CODIGO
LIMPIEZA AL INICIO DE LA OBRA	LT-001
LIMPIEZA CON AIRE COMPRIMIDO	LT-001
LIMPIEZA DE TERRENO	LT-001
LIMPIEZA DE TERRENO C/EQUIPO	LT-001
LIMPIEZA DE TERRENO MANUAL	LT-001
LIMPIEZA DE VIA PREVIO A COLOCACION CARPETA	LT-001
LIMPIEZA DEL TERRENO EN FORMA MANUAL	LT-001
LIMPIEZA DEL TERRENO MANUAL	LT-001
LIMPIEZA FINAL	LT-001
LIMPIEZA FINAL DE LA OBRA	LT-001
LIMPIEZA FINAL DE OBRA	LT-001
LIMPIEZA MANUAL DE TERRENO A INTERVENIR	LT-001
LIMPIEZA PERMANENTE DE LA OBRA	LT-001
LIMPIEZA PERMANENTE DURANTE LA EJECUCION DE LA OBRA	LT-001

ANEXO 11: Tabla de agrupación de partidas de transporte TP-001

PARTIDA	CODIGO
CARGUIO Y TRANSPORTE DE MEZCLA ASFALTO	TP-001
TRANSPORTE DE BLOQUES DE PIEDRA	TP-001
TRANSPORTE DE EQUIPO Y MATERIALES A LAS ZONAS DE TRABAJO DURANTE LA OBRA	TP-001
TRANSPORTE DE MATERIAL Y EQUIPOS	TP-001
TRANSPORTE DE MATERIALES	TP-001
TRANSPORTE DE MATERIALES A OBRA	TP-001
TRANSPORTE DE MEZCLA ASFALTICA A OBRA	TP-001
TRANSPORTE DE MEZCLA ASFALTICA EN CALIENTE	TP-001
TRANSPORTE DEL MATERIAL EXCEDENTE DE CORTE INC. CARGADO	TP-001

TRASPORTE DE MATERIAL A OBRA	TP-001

ANEXO 12: Tabla de agrupación de partidas de demolición DL-001

PARTIDA	CODIGO
CORTE Y DEMOLICION	DL-001
CORTE Y DEMOLICION DE SARDINELES DE VEREDAS, C/EQUIPO LIVIANO	DL-001
DEMOLICION DE ASFALTO PARA CONSTRUCCION DE REDUCTOR DE VELOCIDAD	DL-001
DEMOLICION DE BADEN EXISTENTE	DL-001
DEMOLICION DE BERMAS	DL-001
DEMOLICION DE CANAL CONCRETO CICLOPEO EXISTENTE	DL-001
DEMOLICION DE CIMENTACIONES	DL-001
DEMOLICION DE CONCRETO SIMPLE MANUAL	DL-001
DEMOLICION DE ELEMENTOS DE CONCRETO SIMPLE	DL-001
DEMOLICION DE ESTRUCTURAS DE CONCRETO	DL-001
DEMOLICION DE ESTRUCTURAS DE CONCRETO SIMPLE	DL-001
DEMOLICION DE ESTRUCTURAS EXISTENTES	DL-001
DEMOLICION DE GRADAS Y VEREDAS	DL-001
DEMOLICION DE GRDAS	DL-001
DEMOLICION DE JARDINERAS DE CONCRETO SIMPLE	DL-001
DEMOLICION DE JARDINERAS EXISTENTES, C/EQUIPO LIVIANO	DL-001
DEMOLICION DE MARTILLOS	DL-001
DEMOLICION DE MURO DE PIEDRA PIRCADA	DL-001
DEMOLICION DE MUROS	DL-001
DEMOLICION DE MUROS DE PIEDRA PIRCADA	DL-001
DEMOLICION DE PAVIMENTO	DL-001
DEMOLICION DE PAVIMENTO ASFALTICO DE 2"	DL-001
DEMOLICION DE PAVIMENTO ASFALTICO DE 2"	DL-001
DEMOLICION DE PAVIMENTO ASFALTICO, INC/RAMPAS	DL-001
DEMOLICION DE PISO DE CONCRETO	DL-001
DEMOLICION DE PISOS DE CONCRETO	DL-001
DEMOLICION DE PISOS, VEREDAS, RAMPAS Y BERMAS DE CONCRETO SIMPLE	DL-001
DEMOLICION DE RAMPAS	DL-001
DEMOLICION DE RAMPAS VEHICULARES E=0.15 M DE CONCRETO SIMPLE C/EQUIPO	DL-001
DEMOLICION DE RAMPAS VEHICULARES Y PEATONALES	DL-001
DEMOLICION DE SARDINEL EN JARDINERAS	DL-001
DEMOLICION DE SARDINELES	DL-001
DEMOLICION DE TAPA DE CANAL EXITENTE	DL-001
DEMOLICION DE TAPAS DE BUZON	DL-001
DEMOLICION DE VEREDA DE CONCRETO C/EQUIPO E=0.10M	DL-001
DEMOLICION DE VEREDA EXISTENTE	DL-001
DEMOLICION DE VEREDA, RAMPA Y SARDINEL EXISTENTE	DL-001

DEMOLICION DE VEREDA, RAMPAS Y BERMA DE CONCRETO C/MARTILLO NEUMATICO	DL-001
DEMOLICION DE VEREDAS	DL-001
DEMOLICION DE VEREDAS DE 0.10 m	DL-001
DEMOLICION DE VEREDAS DE CONCRETO, INC/RAMPAS	DL-001
DEMOLICION DE VEREDAS E= 0.15 M C/EQUIPO	DL-001
DEMOLICION DE VEREDAS EXISTENTES CON EQUIPO	DL-001
DEMOLICION DE VEREDAS Y ESTRUCTURAS EXISTENTES	DL-001
DEMOLICION ESTRUCTURA DE CONCRETO	DL-001
REMOCION DE CARPETA ASFALTICA	DL-001
RETIRO Y DEMOLICION DE TAPAS DE BUZONES	DL-001

ANEXO 13: Tabla de agrupación de partidas de trazo y replanteo TR-001

PARTIDA	CODIGO
REPLANTEO ALTIMETRIA EN CAJA CONCRETO KM 0+017.50	TR-001
REPLANTEO DE ALTIMETRIA EN BUZONES	TR-001
REPLANTEO DURANTE EL PROCESO	TR-001
TRAZO, NIVELACION Y REPLANTEO	TR-001
TRAZO DE NIVELES Y REPLANTEO	TR-001
TRAZO DURANTE LA EJECUCION DE LA OBRA	TR-001
TRAZO NIVEL Y REPLANTEO DURANTE EL PROCESO	TR-001
TRAZO NIVELACION REPLANTEO	TR-001
TRAZO NIVELACIÓN Y REPLANTEO	TR-001
TRAZO NIVELACIÓN Y REPLANTEO DURANTE EJECUCION DE OBRA	TR-001
TRAZO NIVELACION Y REPLANTEO DURANTE LA OBRA	TR-001
TRAZO NIVELES Y REPLANTEO	TR-001
TRAZO NIVELES Y REPLANTEO DURANTE EL PROCESO	TR-001
TRAZO NIVELES Y REPLANTEO PRELIMINAR	TR-001
TRAZO Y REPLANTEO	TR-001
TRAZO Y REPLANTEO DE VIAS	TR-001
TRAZO Y REPLANTEO DURANTE EL PROCESO DE EJECUCION	TR-001
TRAZO Y REPLANTEO DURANTE LA OBRA	TR-001
TRAZO Y REPLANTEO INICIAL	TR-001
TRAZO Y REPLANTEO INICIAL DE OBRA	TR-001
TRAZO Y REPLANTEO PERMANENTE	TR-001
TRAZO Y REPLANTEO PERMANENTE EN OBRA	TR-001
TRAZO Y REPLANTEO PRELIMINAR	TR-001
TRAZO Y REPLANTEO PRELIMINARES	TR-001
TRAZO Y REPLANTEO TOPOGRAFICO	TR-001
TRAZO, NIVELES Y REPLANTEO	TR-001
TRAZO, NIVELES Y REPLANTEO DURANTE EL PROCESO	TR-001
TRAZO, NIVELES Y REPLANTEO DURANTE EL PROCESO DE CONSTRUCCION	TR-001
TRAZO, NIVELES Y REPLANTEO PRELIMINAR	TR-001
TRAZO, NIVELES Y REPLANTEO	TR-001

TRAZO, NIVELES Y REPLATEO	TR-001
TRAZOS, NIVEL Y REPLANTEO (Obras Civiles)	TR-001

ANEXO 14: Tabla de agrupación de partidas de eliminación EM-001

PARTIDA	CODIGO
ELIMINACION C/ MAQ MATERIAL EXCEDENTE	EM-001
ELIMINACION DE DESMONTE EN VIA C/EQUIPO	EM-001
ELIMINACION DE ESCOMBROS D=7 KM	EM-001
ELIMINACION DE ESCOMBROS EN T.N. C/E (D<=5 KM)	EM-001
ELIMINACION DE MATERIAL	EM-001
ELIMINACION DE MATERIAL C/CARG FRONTAL Y VOLQUETE	EM-001
ELIMINACION DE MATERIAL EXCDENTE	EM-001
ELIMINACION DE MATERIAL EXCEDENTE	EM-001
ELIMINACION DE MATERIAL EXCEDENTE (D=5 Km)	EM-001
ELIMINACION DE MATERIAL EXCEDENTE (Dist = 10 km)	EM-001
ELIMINACION DE MATERIAL EXCEDENTE (PLUVIAL)	EM-001
ELIMINACION DE MATERIAL EXCEDENTE C/ MAQUINA	EM-001
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=10 KM)	EM-001
ELIMINACION DE MATERIAL EXCEDENTE C/E (D<=5 KM)	EM-001
ELIMINACION DE MATERIAL EXCEDENTE C/EQUIPO	EM-001
ELIMINACION DE MATERIAL EXCEDENTE C/EQUIPO DISTANCIA 10 A 15 KM	EM-001
ELIMINACION DE MATERIAL EXCEDENTE C/VOLQ 10 m3 D = 5 km	EM-001
ELIMINACION DE MATERIAL EXCEDENTE C/VOLQ.15 M3	EM-001
ELIMINACION DE MATERIAL EXCEDENTE CON EQUIPO	EM-001
ELIMINACION DE MATERIAL EXCEDENTE CON VOLQUETE, CARGUI C/EQUIPO A 5KM	EM-001
ELIMINACION DE MATERIAL EXCEDENTE DE EXCAVACIÓN (DPROM=5KM)	EM-001
ELIMINACION DE MATERIAL EXCEDENTE DM= 5 KM	EM-001
ELIMINACION DE MATERIAL EXCEDENTE DM=15KM(aqp)	EM-001
ELIMINACION DE MATERIAL EXEDENTE C/E (D<=5KM)	EM-001
RECOLECCION, CLASIFICACION Y ELIMINACION DE RESIDUOS DOMESTICOS E INDUSTRIALES	EM-001
ELIMINACION DE MATERIAL DE DEMOLICION C/ MAQUINA	EM-001
ELIMINACIÓN DE MATERIAL EXCEDENTE	EM-001
ELIMINACION DE MATERIAL EXCEDENTE DE DEMOLICIONES	EM-001
ELIMINACION MATERIAL EXCEDENTE DE DEMOLICION	EM-001

ANEXO 15: Tabla de agrupación de partidas de acarreo AC-001

PARTIDA	CODIGO
ACARREO DE ADOQUIINES	AC-001
ACARREO DE ADOQUIN	AC-001
ACARREO DE ADOQUIN C/EQUIPO	AC-001
ACARREO DE ARBOLES ORNAMENTALES	AC-001

ACARREO DE BASE GRANULAR C/EQUIPO	AC-001
ACARREO DE BASE GRANULAR C/MAQUINARIA	AC-001
ACARREO DE BLOQUES DE PIEDRA PARA MAMPOSTERIA C/EQUIPO	AC-001
ACARREO DE GRANALLA DE COLORES C/EQUIPO	AC-001
ACARREO DE MATERIAL A ELIMINAR	AC-001
ACARREO DE MATERIAL DE ADOQUIN	AC-001
ACARREO DE MATERIAL DE DESMONTE D=40M.	AC-001
ACARREO DE MATERIAL EXCAVADO A ZONA QUE PERMITA ELIMINAR	AC-001
ACARREO DE MATERIAL EXCEDENTE	AC-001
ACARREO DE MATERIAL EXCEDENTE C/MAQUINARIA	AC-001
ACARREO DE MATERIAL EXCEDENTE D=30M	AC-001
ACARREO DE MATERIAL EXCEDENTE EN CARRETILLA (50 M)	AC-001
ACARREO DE MATERIAL EXCEDENTE HASTA 40 M	AC-001
ACARREO DE MATERIAL PROVENIENTE DE CORTE	AC-001
ACARREO DE MATERIALES EN OBRA (DMAX=100 M.)	AC-001
ACARREO DE PIEDRA PARA MAMPOSTERIA C/EQUIPO	AC-001
ACARREO DE SARDINEL DE PIEDRA GRANODIORITA C/EQUIPO	AC-001
ACARREO INTERNO DE MATERIAL DE DEMOLICION	AC-001
ACARREO INTERNO DE MATERIALES	AC-001
ACARREO MANUAL DED MATERIAL EXCEDENTE	AC-001
CORTE MANUAL Y ACARREO DE ESCOMBROS	AC-001
JUNTADO Y ACARREO DE BLOQUES DE PIEDRA EN CANTERA	AC-001

ANEXO 16: Tabla de agrupación de partidas de curado CD-001

PARTIDA	CODIGO
ALISADO, ACABADO Y CURADO	CD-001
CURADO DE CONCRETO	CD-001
CURADO DE CONCRETO CON ADITIVO	CD-001
CURADO DE CONCRETO CON ARENA	CD-001
CURADO DE CONCRETO EN GRADERIAS	CD-001
CURADO DE CONCRETO EN VEREDAS	CD-001
CURADO DE CONCRETO EN VEREDAS Y RAMPAS	CD-001
CURADO DE CONCRETO PARA SARDINEL	CD-001
CURADO DE CUNETAS	CD-001
CURADO DE ELEMENTOS DE CONCRETO	CD-001
CURADO DE JARDINERAS	CD-001
CURADO DE LOSAS DE PAVIMENTO RIGIDO	CD-001
CURADO DE MUROS DE CONTENCION	CD-001
CURADO DE MUROS DE MAMPOSTERÍA DE PIEDRA	CD-001
CURADO DE RAMPAS DE CONCRETO	CD-001
CURADO DE RAMPAS VEHICULARES	CD-001
CURADO DE SARDINEL DE CONCRETO	CD-001
CURADO DE SARDINELES	CD-001
CURADO DE SARDINELES Y JARDINERAS	CD-001

CURADO DE SUPERFICIES DE CONCRETO EN LOSA	CD-001
CURADO DE SUPERFICIES HORIZONTALES	CD-001
CURADO DE VEREDA	CD-001
CURADO DE VEREDAS	CD-001
CURADO DE VEREDAS CON ADITIVO	CD-001

ANEXO 17: Tabla de agrupación de partidas de corte CT-003

PARTIDA	CODIGO
CORTE A NIVEL DE SUB RASANTE C/EQUIPO	CT-003
CORTE DE MATERIAL A NIVEL DE SUB RASANTE C/MAQUINARIA	CT-003
CORTE DE MATERIAL A NIVEL DE SUBRASANTE C/MAQUINARIA	CT-003
CORTE DE MATERIAL A NIVEL SE SUB RASANTE	CT-003
CORTE DE MATERIAL CON MAQUINARIA HASTA SUBRASANTE	CT-003
CORTE DE MATERIAL PARA BERMAS	CT-003
CORTE DE MATERIAL PARA VEREDAS	CT-003
CORTE DE MATERIAL SUELTO	CT-003
CORTE DE MATERIAL SUELTO CON EQUIPO	CT-003
CORTE DE MATERIAL SUELTO DE SUBRASANTE PARA BASE	CT-003
CORTE DE MATERIAL SUELTO H= 10 CM	CT-003
CORTE DE MATERIAL SUELTO MANUAL	CT-003
CORTE DE ROCA FIJA	CT-003
CORTE DE ROCA FRAGMENTADA	CT-003
CORTE DE TERRENO A -0.20 MTS DE RASANTE ACTUAL, MATERIAL COMPACTO	CT-003
CORTE DE TERRENO A NIVEL DE SUB RASANTE DE ROCA FIJA	CT-003
CORTE DE TERRENO A NIVEL DE SUB RASANTE DE TERRENO SEMIDURO	CT-003
CORTE DE TERRENO A NIVEL DE SUBRASANTE	CT-003
CORTE DE TERRENO CON MAQUINARIA PESADA	CT-003
CORTE DE TERRENO EN FORMA MANUAL	CT-003
CORTE DE TERRENO EN MATERIAL SUELTO CON MAQUINARIA PESADA	CT-003
CORTE DE TERRENO HASTA SUBRASANTE, MATERIAL COMPACTO	CT-003
CORTE DE TERRENO MANUAL A -0.10 MTS DE RASANTE ACTUAL, MATERIAL COMPACTO P/BERMAS	CT-003
CORTE DE TERRENO MANUAL A -0.10 MTS DE RASANTE ACTUAL, MATERIAL COMPACTO P/RAMPAS VEHICULARES	CT-003
CORTE DE TERRENO MANUAL E=0.10 M PARA MARTILLOS	CT-003
CORTE DE TERRENO MANUAL E=0.10 M PARA VEREDAS	CT-003
CORTE DE TERRENO MANUAL HASTA NIVEL DE SUBRASANTE	CT-003
CORTE DE TERRENO NATURAL	CT-003
CORTE DE TERRENO NIVEL SUBRASANTE	CT-003
CORTE DE TERRENO NIVEL SUBRASANTE/MATERIAL SUELTO	CT-003
CORTE DE TERRENO NORMAL EN FORMA MANUAL	CT-003
CORTE DE TERRENO PARA VEREDAS, RAMPAS Y MARTILLOS)	CT-003
CORTE DE TERRENO SEMI-ROCOSO CON MAQUINARIA	CT-003
CORTE DE TERRENO SEMIRROCOSO	CT-003

CORTE DE TERRENOHASTA NIVEL DE SUBRASANTE	CT-003
CORTE EN TERRENO ROCOSO	CT-003
CORTE MASIVO DE MATERIAL PARA NIVELACION	CT-003
CORTE MASIVO DE TERRENO A MAQUINA	CT-003
CORTE MASIVO DE TERRENO C/MAQUINA	CT-003
CORTE O EXCAVACION EN TERRENO NORMAL	CT-003
CORTE ROCA SUELTA	CT-003
CORTE SUPERFICIAL DE TERRENO	CT-003
CORTE SUPERFICIAL MANUAL	CT-003
CORTE SUPERFICIAL MANUAL HASTA 0.10 m. EN TERRENO	CT-003

ANEXO 18: Tabla de agrupación de partidas de junta JT-001

PARTIDA	CODIGO
FRAGUADO DE BLOQUES DE PIEDRA IRREGULAR: JUNTA 1 A 4CM	JT-001
JUNTA DE CONTRACCION	JT-001
JUNTA DE DILATACION C/3 METROS (e=1.5") MEZCLA ASFALTO-ARENA	JT-001
JUNTA DE DILATACION C/3 METROS (e=1.5") MEZCLA ASFALTO-ARENA PARA SARDINEL DE CONCRETO	JT-001
JUNTA DE DILATACION C/3.00 METROS (e=1.5") MEZCLA ASFALTO-ARENA PARA CUNETAS DE CONCRETO	JT-001
JUNTA DE DILATACION C/3.00 METROS (e=1.5") MEZCLA ASFALTO-ARENA PARA MUROS DE CONTENCION	JT-001
JUNTA DE DILATACION C/3.00 METROS (e=1.5") MEZCLA ASFALTO-ARENA PARA SARDINEL DE CONCRETO	JT-001
JUNTA DE DILATACION C/4.00 METROS (e=1.5") MEZCLA ASFALTO-ARENA PARA MUROS DE CONTENCION	JT-001
JUNTA DE DILATACION CADA 3m (e=1.5") MEZCLA ASFALTO-ARENA PARA PAVIMENTO	JT-001
JUNTA DE DILATACION CON SELLO ELASTOMÉRICO	JT-001
JUNTA DE DILATACION EN SARDINEL TIPO BURBUJA	JT-001
JUNTA DE DILATACION EN VEREDA	JT-001
JUNTA DE DILATACION PARA MARTILLOS	JT-001
JUNTA DE DILATACION PARA RAMPA	JT-001
JUNTA ELASTOMERICA E= 3/4"	JT-001
JUNTA RELLENO EMULSION ASFALTICA EN PISOS 1/2"	JT-001
JUNTAS ASFALTICA DE E=1" EN SARDINELES	JT-001
JUNTAS ASFALTICA EN CUNETAS E=1"	JT-001
JUNTAS ASFALTICA EN JARDINERAS E=1"	JT-001
JUNTAS ASFALTICA EN VEREDAS E=1"	JT-001
JUNTAS ASFALTICAS	JT-001
JUNTAS ASFALTICAS DE 3/4"	JT-001
JUNTAS ASFALTICAS DE DILATACION PARA VEREDAS	JT-001
JUNTAS ASFALTICAS DE E=1" EN JARDINERAS	JT-001
JUNTAS ASFALTICAS DE E=1" EN SARDINELES	JT-001
JUNTAS ASFALTICAS e=1"	JT-001
JUNTAS ASFALTICAS E=1.0", MEZCLA 1:3	JT-001

JUNTAS ASFALTICAS E=1/2"	JT-001
JUNTAS ASFALTICAS EN RAMPAS DE E=1"	JT-001
JUNTAS ASFALTICAS EN SARDINELES TIPO BURBUJA	JT-001
JUNTAS ASFALTICAS EN VEREDAS	JT-001
JUNTAS ASFALTICAS PARA VEREDAS E=1"	JT-001
JUNTAS ASFALTICAS RC-250	JT-001
JUNTAS DE DILATACION RELLENAS C/MEZCLA ASFALTICA E=1"	JT-001
SELLADO DE JUNTAS EN SARDINELES, e=3/4"	JT-001

ANEXO 19: Tabla de agrupación de partidas de relleno RL-001

PARTIDA	CODIGO
RELLENO APISONADO DE.ZANJA T.N. T.S.R. H = 1.40 M	RL-001
RELLENO APISONADO DE.ZANJA T.N. T.S.R. H = 1.50	RL-001
RELLENO C/MAT DE PRESTAMO MATERIAL GRANULAR	RL-001
RELLENO CC/MATERIAL DE PRESTAMO CON MAQUINARIA	RL-001
RELLENO COMPACT C/MAT PROPIO	RL-001
RELLENO COMPACT C/MAT PROPIO A NIVEL DE SUBRASANTE	RL-001
RELLENO COMPACTADO	RL-001
RELLENO COMPACTADO C/EQUIPO MATERIAL PROPIO	RL-001
RELLENO COMPACTADO C/EQUIPO, MATERIAL PROPIO Y AGUA	RL-001
RELLENO COMPACTADO C/MAT PROPIO	RL-001
RELLENO COMPACTADO C/MATERIAL PROPIO	RL-001
RELLENO COMPACTADO CON AFIRMADO E=0.20 m	RL-001
RELLENO COMPACTADO CON MAT. PROPIO EQ/	RL-001
RELLENO COMPACTADO CON MATERIAL DE PRESTAMO	RL-001
RELLENO COMPACTADO CON MATERIAL DE PRESTAMO C/MAQUINARIA	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO EN BERMAS	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO EN GRADAS	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO EN MARTILLOS	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO EN RAMPAS	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO EN VEREDAS	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO HASTA SUBRASANTE	RL-001
RELLENO COMPACTADO CON MATERIAL PROPIO SOBRE TUBERIA	RL-001
RELLENO COMPENSADO A NIVEL DE SUB RASANTE C/EQUIPO	RL-001
RELLENO COMPENSADO CON MATERIAL PROPIO	RL-001
RELLENO CON MATERIAL PROPIO	RL-001
RELLENO CON MATERIAL PROPIO CON EQUIPO	RL-001
RELLENO CON MATERIAL PROPIO CON EQUIPO - E1	RL-001
RELLENO CON MATERIAL PROPIO MANUAL	RL-001
RELLENO CON MATERIAL PROPIO PARA CANAL	RL-001
RELLENO CON MATERIAL PROPIO SELECCIONADO	RL-001
RELLENO CON TIERRA DE CHACRA	RL-001
RELLENO DE AREA DE PLANTONES CON TIERRA VEGETAL	RL-001

RELLENO DE TERRAPLEN CON MATERIAL PROPIO	RL-001
RELLENO DE ZANJA CON MATERIAL DE PRESTAMO, SOBRE CLAVE DE TUBERIA, H=0.60 M	RL-001
RELLENO DE ZANJAS C/MAT PROPIO	RL-001
RELLENO NIVEL SUBRASANTE/MATERIAL SUELTO	RL-001
RELLENO PROTECTOR DE ARENA SOBRE TUBERIA	RL-001
RELLENO PROTECTOR H = 0.30 MTS A= 1 - 1.20 M	RL-001
RELLENO PROTECTOR H = 0.30 MTS A= 1 - 1.5 M	RL-001
RELLENO PROTECTOR P/TUBERIA PVC	RL-001
RELLENO Y COMPACTACION A NIVEL DE SUB RASANTE CON MATERIAL PROPIO C/MAQUINARIA	RL-001
RELLENO Y COMPACTACION C/MATERIAL PROPIO PARA CAJAS DE AGUA Y DESAGUE	RL-001
RELLENO Y COMPACTACION CON MATERIAL PROPIO MEJORADO	RL-001
RELLENO Y COMPACTACION EN ZANJAS CON MATERIAL FINO	RL-001
RELLENO Y COMPACTADO A NIVEL DE SUB RASANTE CON MATERIAL PROPIO C/MAQUINARIA	RL-001
RELLENO Y COMPACTADO CON MATERIAL PROPIO	RL-001
RELLENO Y COMPACTADO CON MATERIALPROPIO	RL-001
RELLENO Y COMPACTADO CON PLANCHA CON MATERIAL DE PRESTAMO PARA MUROS	RL-001
RELLENO, NIVELACION Y COMPACTACION CON MATERIAL DE PRESTAMO	RL-001
SEGUNDO RELLENO CON MAT PROPIO	RL-001
RELLENO DE TERRAPLEN CON MATERIAL EXCEDENTE DE CORTE	RL-001
TERRAPLEN PARA VEREDAS E=0.10 M	RL-001

ANEXO 20: Tabla de agrupación de partidas acero FY-001

PARTIDA	CODIGO
ACERO CORRUGADO	FY-001
ACERO CORRUGADO FY= 4200 kg/cm2 GRADO 60	FY-001
ACERO CORRUGADO FY= 4200 KG/CM2 GRADO 60 PARA ZAPATAS DE MUROS DE CONTENCION	FY-001
ACERO CORRUGADO fy=4200 kg/cm2	FY-001
ACERO CORRUGADO FY=4200 KG/CM2 GRADO 60	FY-001
ACERO CORRUGADO fy=4200 kg/cm2 PARA ALCANTARILLA	FY-001
ACERO DE REFUERZO fy=4,200 kg/cm2 PARA DRENAJE PLUVIAL	FY-001
ACERO DE REFUERZO FY=4200 Kg/cm2	FY-001
ACERO DE REFUERZO Fy=4200 Kg/cm2 EN GRADERIAS	FY-001
ACERO DE REFUERZO Fy=4200 Kg/cm2 EN MUROS	FY-001
ACERO DE REFUERZO F'Y=4200KG/CM2	FY-001
ACERO ESTRUCTURAL FY=4200 KG/CM2 GRADO 60	FY-001
ACERO ESTRUCTURAL FY=4200 KG/CM2 PARA ESTRUCTURA DE CANAL	FY-001
ACERO Fy = 4200 KG/CM2 EN GIBAS	FY-001
ACERO fy= 4200 kg/cm2 GRADO 60	FY-001
ACERO FY=4200 KG/CM2	FY-001
ACERO Fy=4200 KG/CM2 EN MUROS	FY-001

ACERO Fy=4200 KG/CM2 EN SARDINELES	FY-001
ACERO fy=4200 kg/cm2 GRADO 60	FY-001
ACERO fy=4200 kg/cm2 GRADO 60 PARA CANAL	FY-001
ACERO FY=4200 Kg/Cm2 GRADO 60.	FY-001
ACERO fy=4200 kg/cm2 PARA MURO DE CONCRETO	FY-001
ACERO fy=4200 kg/cm2 PARA VIGAS	FY-001
ACERO GRADO 36 FY= 2520 kg/cm2 LISO 1", L=0.70m @ 0.30m, C/TUB + PINT., BASTONES EN JUNTAS, DOWEL	FY-001
ACERO LISO 1/2"	FY-001
CAPTACIÓN DRENAJE, RIEL DE ACERO	FY-001
CAPTACION PLUVIAL, ACERO CORRUGADO FY= 4200 kg/cm2 GRADO 60	FY-001
COLUMNA, ACERO CORRUGADO FY= 4200 kg/cm2 GRADO 60	FY-001
ESCALERAS, ACERO CORRUGADO FY= 4200 kg/cm2 GRADO 60	FY-001
MURO DE CONTENCION, ACERO CORRUGADO FY= 4200 kg/cm2 GRADO 60	FY-001
MUROS DE CONTENCION, ACERO DE REFUERZO FY= 4200 kg/cm2	FY-001
ZAPATAS - ACERO Fy=4200 KG/CM2 EN MUROS	FY-001
ZAPATAS, ACERO CORRUGADO FY= 4200 kg/cm2 GRADO 60	FY-001
ZAPATAS, ACERO DE REFUERZO FY= 4200 kg/cm2	FY-001

ANEXO 21: Tabla de agrupamiento de partidas de encofrado y desencofrado ED-001

PARTIDA	CODIGO
CAPTACION PLUVIAL, ENCOFRADO Y DESENCOFRADO	ED-001
COLUMNA, ENCOFRADO Y DESENCOFRADO	ED-001
ENCOFRADO Y DESENC.DE LOSA CONTINUA - PAVIMENTACION	ED-001
ENCOFRADO Y DESENCOFRADO	ED-001
ENCOFRADO Y DESENCOFRADO CANAL DE REGADIO	ED-001
ENCOFRADO Y DESENCOFRADO CARAVISTA	ED-001
ENCOFRADO Y DESENCOFRADO CARAVISTA DE MUROS	ED-001
ENCOFRADO Y DESENCOFRADO CARAVISTA EN MURO DE CONTENCION	ED-001
ENCOFRADO Y DESENCOFRADO DE ALCANTARILLA	ED-001
ENCOFRADO Y DESENCOFRADO DE BORDES Y FILOS	ED-001
ENCOFRADO Y DESENCOFRADO DE BUZONES DE INSPECCION	ED-001
ENCOFRADO Y DESENCOFRADO DE CONCRETO SIMPLE	ED-001
ENCOFRADO Y DESENCOFRADO DE CUNETAS	ED-001
ENCOFRADO Y DESENCOFRADO DE GIBAS	ED-001
ENCOFRADO Y DESENCOFRADO DE GRADERIAS	ED-001
ENCOFRADO Y DESENCOFRADO DE GRADERÍS SOBRE TERRENO	ED-001
ENCOFRADO Y DESENCOFRADO DE JARDINERAS	ED-001
ENCOFRADO Y DESENCOFRADO DE MUROS	ED-001
ENCOFRADO Y DESENCOFRADO DE MUROS DE CONCRETO	ED-001
ENCOFRADO Y DESENCOFRADO DE RAMPAS	ED-001
ENCOFRADO Y DESENCOFRADO DE RAMPAS VEHICULARES	ED-001
ENCOFRADO Y DESENCOFRADO DE REGILLA DE CAPTACION	ED-001
ENCOFRADO Y DESENCOFRADO DE SARDINEL	ED-001

ENCOFRADO Y DESENCOFRADO DE SARDINEL Y JARDINERA	ED-001
ENCOFRADO Y DESENCOFRADO DE SARDINELES	ED-001
ENCOFRADO Y DESENCOFRADO DE SARDINELES P/MARTILLOS	ED-001
ENCOFRADO Y DESENCOFRADO DE VEREDA	ED-001
ENCOFRADO Y DESENCOFRADO DE VEREDAS	ED-001
ENCOFRADO Y DESENCOFRADO DE VEREDAS Y RAMPAS	ED-001
ENCOFRADO Y DESENCOFRADO DRENAJE	ED-001
ENCOFRADO Y DESENCOFRADO EN ALCANTARILLAS	ED-001
ENCOFRADO Y DESENCOFRADO EN CAJA DE INSPECCION	ED-001
ENCOFRADO Y DESENCOFRADO EN GRADAS	ED-001
ENCOFRADO Y DESENCOFRADO EN GRADERIAS	ED-001
ENCOFRADO Y DESENCOFRADO EN JARDINERA	ED-001
ENCOFRADO Y DESENCOFRADO EN MUROS	ED-001
ENCOFRADO Y DESENCOFRADO EN RAMPAS	ED-001
ENCOFRADO Y DESENCOFRADO EN SARDINELES	ED-001
ENCOFRADO Y DESENCOFRADO EN VEREDAS	ED-001
ENCOFRADO Y DESENCOFRADO HASTA 0.30M DE ALTO	ED-001
ENCOFRADO Y DESENCOFRADO MARTILLOS.	ED-001
ENCOFRADO Y DESENCOFRADO NORMAL	ED-001
ENCOFRADO Y DESENCOFRADO NORMAL DE MUROS DE CONTENCION	ED-001
ENCOFRADO Y DESENCOFRADO NORMAL GRADERIAS	ED-001
ENCOFRADO Y DESENCOFRADO NORMAL H=0.10M	ED-001
ENCOFRADO Y DESENCOFRADO NORMAL PARA MUROS DE CONTENCION	ED-001
ENCOFRADO Y DESENCOFRADO NORMAL PARA VEREDAS	ED-001
ENCOFRADO Y DESENCOFRADO NORMAL PAVIMENTO	ED-001
ENCOFRADO Y DESENCOFRADO P/BUZON	ED-001
ENCOFRADO Y DESENCOFRADO PARA CANAL	ED-001
ENCOFRADO Y DESENCOFRADO PARA COLUMNAS	ED-001
ENCOFRADO Y DESENCOFRADO PARA CUNETAS DE CONCRETO	ED-001
ENCOFRADO Y DESENCOFRADO PARA DRENAJE PLUVIAL	ED-001
ENCOFRADO Y DESENCOFRADO PARA ESCALERAS	ED-001
ENCOFRADO Y DESENCOFRADO PARA JARDINERA	ED-001
ENCOFRADO Y DESENCOFRADO PARA JARDINERAS	ED-001
ENCOFRADO Y DESENCOFRADO PARA JARDINERAS DE CONCRETO	ED-001
ENCOFRADO Y DESENCOFRADO PARA LOSAS DE CONCRETO	ED-001
ENCOFRADO Y DESENCOFRADO PARA MARTILLOS	ED-001
ENCOFRADO Y DESENCOFRADO PARA MUROS	ED-001
ENCOFRADO Y DESENCOFRADO PARA MUROS DE CONTENCION	ED-001
ENCOFRADO Y DESENCOFRADO PARA PAVIMENTO	ED-001
ENCOFRADO Y DESENCOFRADO PARA PAVIMENTO RIGIDO	ED-001
ENCOFRADO Y DESENCOFRADO PARA RAMPA	ED-001
ENCOFRADO Y DESENCOFRADO PARA REDUCTOR DE VELOCIDAD	ED-001
ENCOFRADO Y DESENCOFRADO PARA SARDINEL DE CONCRETO	ED-001
ENCOFRADO Y DESENCOFRADO PARA SARDINELES TIPO BURBUJA	ED-001
ENCOFRADO Y DESENCOFRADO PARA VEREDAS	ED-001

ENCOFRADO Y DESENCOFRADO PARA VIGAS	ED-001
ENCOFRADO Y DESENCOFRADO PAREDES DE CANAL	ED-001
ENCOFRADO Y DESENCOGFRADO DE SARDINELES	ED-001
ENCOFRADO Y DESENCOGFRADO DE SARDINELES PARA CONFINAMIENTO DE ADOQUINES	ED-001
ESCALERAS, ENCOFRADO Y DESENCOFRADO	ED-001
GRADAS, ENCOFRADO Y DESENCOFRADO	ED-001
JARDINERA: ENCOFRADO Y DESENCOFRADO CARAVISTA	ED-001
MURO DE CONTENCION, ENCOFRADO Y DESENCOFRADO	ED-001
MURO DE CONTENCION, ENCOFRADO Y DESENCOFRADO CARAVISTA	ED-001
RAMPAS, ENCOFRADO Y DESENCOFRADO	ED-001
SARDINEL DE CONFINAMIENTO: ENCOFRADO Y DESENCOFRADO	ED-001
SARDINEL, ENCOFRADO Y DESENCOFRADO	ED-001
VEREDAS, ENCOFRADO Y DESENCOFRADO	ED-001
ENCOFRADO DE BORDE EN VEREDAS h = 0.10 m	ED-001
ENCOFRADO DE BUZONES	ED-001
ENCOFRADO DE GRADAS	ED-001
ENCOFRADO DE MURO	ED-001
ENCOFRADO DE MURO DE UNA CARA	ED-001
ENCOFRADO DE RAMPAS	ED-001
ENCOFRADO EN REJILLA	ED-001
ENCOFRADO Y DESNCOFRADO	ED-001
ENCOFRADO Y DESNCOIFRADO	ED-001
ENCOFRADO, DESNCOFRADO	ED-001
ENCONFRADO Y DESENCOFRADO DE SARDINEL	ED-001
ENCONFRADO Y DESENCOFRADO DE SARDINEL DE JARDINERA	ED-001
ENCOFRADO Y DESENCOFRADO DE GRADERÍAS SOBRE TERRENO	ED-001
ENTIBADO DE ZANJAS	ED-001

ANEXO 22: Tabla de agrupación de partidas de excavación EX-001

PARTIDA	CODIGO
EXCAVACION A MANO EN TERRENO NORMAL	EX-001
EXCAVACION DE HOYOS PARA PLANTACION DE ARBOL	EX-001
EXCAVACION DE HUECO P/POSTE C.A.C. 8 M.	EX-001
EXCAVACION DE HUECO P/RETENIDA	EX-001
EXCAVACION DE MATERIAL SUELTO C/EQUIPO	EX-001
EXCAVACION DE TERRENO MANUAL	EX-001
EXCAVACION DE TERRENO MANUAL PARA SARDINELES DE JARDINERIA	EX-001
EXCAVACION DE ZANJA EN TERR. NORMAL	EX-001
EXCAVACION DE ZANJA EN TERRENO NORMAL	EX-001
EXCAVACION DE ZANJA MANUAL EN TERR. NORMAL	EX-001
EXCAVACION DE ZANJA PARA TUBERIAS• A C/EQUIPO	EX-001
EXCAVACION DE ZANJA TN C/EQUIPO	EX-001
EXCAVACION DE ZANJA TRR.NORMAL C/EQUIPO	EX-001

EXCAVACION DE ZANJAS	EX-001
EXCAVACION DE ZANJAS CON EQUIPO T.	EX-001
EXCAVACION DE ZANJAS EN TERRENO CONGLOMERADO	EX-001
EXCAVACION DE ZANJAS EN TERRENO NORMAL	EX-001
EXCAVACION DE ZANJAS EN TERRENO ROCOSO	EX-001
EXCAVACION DE ZANJAS EN TERRENO ROCOSO – MUROS DE CONTENCION	EX-001
EXCAVACION DE ZANJAS EN TERRENO SEMIROCOSOEN – MUROS DE CONTENCION	EX-001
EXCAVACION DE ZANJAS MANUAL	EX-001
EXCAVACION DE ZANJAS MANUAL PARA JARDINERAS	EX-001
EXCAVACION DE ZANJAS P/SARDINEL	EX-001
EXCAVACION DE ZANJAS PARA BASE DE POSTE METALICO	EX-001
EXCAVACION DE ZANJAS PARA CAJAS DE AGUA Y DESAGUE	EX-001
EXCAVACION DE ZANJAS PARA CIMENTACIÓN SARDINELES Y JARDINERAS	EX-001
EXCAVACION DE ZANJAS PARA CUNETAS DE CONCRETO	EX-001
EXCAVACION DE ZANJAS PARA DRENAJE PLUVIAL	EX-001
EXCAVACION DE ZANJAS PARA JARDINERAS DE CONCRETO	EX-001
EXCAVACION DE ZANJAS PARA MUROS DE CONTECION C/EQUIPO	EX-001
EXCAVACION DE ZANJAS PARA MUROS DE CONTENCION	EX-001
EXCAVACION DE ZANJAS PARA REDES DE ALCANTARILLADO (HASTA 1.4 M)	EX-001
EXCAVACION DE ZANJAS PARA SARDINEL DE CONCRETO	EX-001
EXCAVACION DE ZANJAS PARA SARDINEL SUMERGIDO	EX-001
EXCAVACION EN SUELO COMPACTO	EX-001
EXCAVACION MANUAL	EX-001
EXCAVACION MANUAL DE TERRENO PARA SARDINEL Y VEREDA	EX-001
EXCAVACION MANUAL DE TERRENO SEMIROCOSO HASTA 1.5M DE ALTURA	EX-001
EXCAVACION MANUAL DE ZANJAS	EX-001
EXCAVACION MANUAL DE ZANJAS PARA JARDINERAS	EX-001
EXCAVACION MANUAL DE ZANJAS PARA SARDINEL BURBUJA	EX-001
EXCAVACION MANUAL DE ZANJAS PARA SARDINEL DE MARTILLO	EX-001
EXCAVACION MANUAL DE ZANJAS PARA SARDINEL SUMERGIDO	EX-001
EXCAVACION MANUAL EN TERRENO COMPACTO P/GIBA	EX-001
EXCAVACION MANUAL EN TERRENO NORMAL	EX-001
EXCAVACION MANUAL P/CIMENTACION DE POSTES	EX-001
EXCAVACION MANUAL PARA BOCATORMENTA	EX-001
EXCAVACION MANUAL PARA CUNETAS	EX-001
EXCAVACION MANUAL PARA JARDINERAS	EX-001
EXCAVACION MANUAL PARA SARDINELES	EX-001
EXCAVACION MANUAL PARA TALON PROTECTOR DE VEREDAS	EX-001
EXCAVACION MANUAL SUPERFICIAL EN TERRENO NORMAL	EX-001
EXCAVACION MASIVA CON MAQUINA	EX-001
EXCAVACION PARA BUZONES DE INSPECCION EN TERRENO NORMAL	EX-001
EXCAVACION PARA CAJA DE CANAL DE DRENAJE	EX-001
EXCAVACION PARA DRENAJES	EX-001
EXCAVACION PARA MURO DE CONTENCION	EX-001

EXCAVACION PARA MUROS DE CANAL	EX-001
EXCAVACION PARA REJILLA DE CAPTACION EN TERRENO NORMAL	EX-001
EXCAVACION PARA SARDINELES	EX-001
EXCACACION EN TERRENO COMPACTADO	EX-001
EXCAV. ZANJAS P/TUBERIA TN H<3.00m	EX-001
EXCAV. ZANJAS PARA BUZONES DE INSPECCION (1.0 M.* 1.0 M.) H<3.00m	EX-001
EXCAV. ZANJAS PARA SUMIDERO H<3.00m	EX-001
EXCAVACIÓN DE TERRENO NORMAL C/EQUIPO	EX-001
EXCAVACIÓN PARA SARDINEL	EX-001
EXCAVACIÓN PARA SARDINEL DE JARDINERAS	EX-001
EXCAVACIÓN PARA SARDINEL DE PIEDRA GRANODIORITA	EX-001
EXCAVACION DE ZANJA PARA TUBERÍA C/EQUIPO	EX-001

ANEXO 23: Tabla de agrupación de partidas de perfilado y compactación PC-001

PARTIDA	CODIGO
PERFILADO Y COMPACTACION DE SUBRASANTE	PC-001
PERFILADO Y COMPACTACION DE SUB-RASANTE	PC-001
PERFILADO Y COMPACTACION DE SUBRASANTE BERMAS	PC-001
PERFILADO Y COMPACTACION DE SUBRASANTE- E1	PC-001
PERFILADO Y COMPACTADO	PC-001
PERFILADO Y COMPACTADO A NIVEL DE SUB RASANTE	PC-001
PERFILADO Y COMPACTADO CON EQUIPO LIVIANO	PC-001
PERFILADO Y COMPACTADO DE LA SUB RASANTE EN ZONAS DE CORTE EN MARTILLOS	PC-001
PERFILADO Y COMPACTADO DE LA SUB RASANTE EN ZONAS DE CORTE EN RAMPAS	PC-001
PERFILADO Y COMPACTADO DE LA SUB RASANTE EN ZONAS DE CORTE EN VEREDAS	PC-001
PERFILADO Y COMPACTADO DE SUB RASANTE EN ZONAS DE CORTE	PC-001
PERFILADO Y COMPACTADO DE SUB-RASANTE	PC-001
PERFILADO Y COMPACTADO MANUAL	PC-001
PERFILADO Y COMPACTADO MANUAL DE FONDO DE CIMENTACION	PC-001
PERFILADO Y COMPACTADO PARA BERMAS	PC-001
PERFILADO Y COMPACTADO PARA PARADERO	PC-001
PERFILADO Y COMPACTADO PARA RAMPA	PC-001
PERFILADO Y COMPACTADO PARA VEREDAS Y MARTILLOS	PC-001
REFINE, PERFILADO Y COMPACTADO DE SUBRASANTE	PC-001
REFINE, PERFILADO Y COMPACTADO FONDO ZANJA	PC-001
COMPACTACION DE RASANTE	PC-001
COMPACTACION DE SUB RASANTE	PC-001
COMPACTACION DE TERRENO MANUAL	PC-001
NIVELACION Y COMPACTACION CON EQUIPO	PC-001
NIVELACION Y COMPACTACION CON EQUIPO LIVIANO	PC-001
NIVELACION Y COMPACTACION CON EQUIPO LIVIANO.	PC-001
NIVELACION Y COMPACTACION DE DRENAJE PLUVIAL	PC-001

NIVELACION Y COMPACTACION DE SUBRASANTE	PC-001
NIVELACION Y COMPACTACION DE SUBRASANTE CON EQUIPO	PC-001
NIVELACION Y COMPACTACION DE TERRENO C/EQUIPO LIVIANO	PC-001
NIVELACION Y COMPACTACION EN VEREDAS	PC-001
NIVELACION Y COMPACTACION PARA BERMAS	PC-001
NIVELACION Y COMPACTACION PARA RAZANTE	PC-001
NIVELACION Y COMPACTACION PARA VEREDAS	PC-001
NIVELACION Y COMPACTACO PARA CONFORMACION DE SUB RAZANTE	PC-001
NIVELACION Y COMPACTADO DE TERRENO	PC-001
NIVELACION Y COMPACTADO MANUAL	PC-001
PERFILADO COMPACTADO DE LA SUB RASANTE EN ZONAS DE CORTE EN BERMAS	PC-001
PERFILADO COMPACTADO DE LA SUB RASANTE EN ZONAS DE CORTE EN GRADAS	PC-001
PERFILADO DE CERRO PARA CUNETAS DE CONCRETO	PC-001
PERFILADO Y CONFORMACIÓN DE LA SUB RASANTE	PC-001
PERFILADO, COMPACTACION DE SUBRASANTE	PC-001
PERFILADO, COMPACTACION DE SUBRASANTE EN VEREDAS (C/EM)	PC-001
PERFILADO, COMPACTADO DE SUB RASANTE EN PISOS VEREDAS Y RAMPAS	PC-001
PERFILADO, COMPACTADO Y CONFORMACION DE SUB RASANTE	PC-001
PERFILADO, COMPACTADO Y CONFORMACION DE SUB RASANTE EN BERMAS	PC-001
PERFILADO, NIVELACION Y COMPACTACION DE SUB-RASANTE	PC-001
PERFILADO, NIVELACION Y COMPACTACION DE SUB-RASANTE PARA BERMAS	PC-001
PERFILADO, NIVELACION Y COMPACTACION DE SUB-RASANTE PARA RAMPAS VEHICULARES	PC-001
PERFILADO, NIVELACION Y COMPACTACION DE SUB-RASANTE PARA VEREDAS	PC-001
PERFILADO, NIVELACIÓN Y COMPACTADO DE SUBRASANTE	PC-001
PERFILADO,COMPACTADO	PC-001
REFINE Y NIVELACION	PC-001
REFINE Y NIVELACION DE FONDO DE CANAL	PC-001
REFINE Y NIVELACION DE TERRENO	PC-001
REFINE Y NIVELACION DE ZANJA T.N. A= 1.0 M	PC-001
REFINE Y NIVELACION DE ZANJA T.N. AV= 1.2-1.4 M	PC-001
REFINE Y NIVELACION DE ZANJAS	PC-001
REFINE Y PERFILADO	PC-001
REFINE, NIVELACION Y COMPACTADO C/EQUIPO	PC-001
REFINE,NIVELACION Y COMPACTACION	PC-001
REFINE NIVEL Y FONDOS P/TUB PVC TN	PC-001
REFINE Y COMPACTADO DE TERRAZAS	PC-001
NIVELACION-COMPACTACION Y PERFILADO DE GRADERIAS	PC-001
NIVELACION-COMPACTACION Y PERFILADO DE RASANTE	PC-001
ESCARIFICADO, CONFORMACION Y COMPACTACION DE SUBRASANTE	PC-001
DESQUINCHE Y PERFILADO DE TALUDES	PC-001
CONFORMACION Y COMPACTACION DE LA SUBRASANTE	PC-001

CONFORMACION Y COMPACTACION DE SUB-RASANTE	PC-001
CONFORMACION DE SUB RASANTE	PC-001
CONFORMACION DE SUBRASANTE	PC-001
CONFORMACION DE SUB-RASANTE CON MATERIAL PROPIO	PC-001
CONFORMACION DE SUBRASANTE PARA LOSA	PC-001
CONFORMACION DE SUB-RASANTE PARA VEREDAS	PC-001

ANEXO 24: Tabla de agrupación de partidas de pintado PP-001

PARTIDA	CODIGO
PINTADO DE BORDE DE VEREDAS Y MARTILLOS C/PINTURA ESMALTE	PP-001
PINTADO DE FILO DE VEREDAS Y SARDINELES	PP-001
PINTADO DE MUROS DE CONTENCION	PP-001
PINTADO DE MUROS DE SARDINEL DE CONCRETO	PP-001
PINTADO DE MUROS PARA JARDINERAS DE CONCRETO	PP-001
PINTADO DE SARDINELES	PP-001
PINTADO DE SARDINELES EN BORDES DE VIA.	PP-001
PINTADO EN SARDINEL	PP-001
PINTURA DE JARDINERAS	PP-001
PINTURA DE PAVIMENTO	PP-001
PINTURA DE SARDINELES	PP-001
PINTURA DE TRAFICO EN BORDE DE VEREDAS	PP-001
PINTURA DE TRAFICO EN BORDES DE VEREDA	PP-001
PINTURA DE TRAFICO EN ELEMENTOS	PP-001
PINTURA DE TRAFICO EN GRADERIAS	PP-001
PINTURA DE TRAFICO EN JARDINERA	PP-001
PINTURA DE TRAFICO EN JARDINERAS	PP-001
PINTURA DE TRAFICO EN SARDINEL	PP-001
PINTURA DE TRAFICO EN SARDINELES TIPO BURBUJA	PP-001
PINTURA DE TRAFICO EN VEREDAS/SARDINELES	PP-001
PINTURA DE TRAFICO PARA SARDINELES	PP-001
PINTURA DE TRAFICO PARA VEREDA	PP-001
PINTURA DE VEREDAS Y MARTILLOS	PP-001
PINTURA EN BARANDAS Y PASAMANOS METALICOS (INCLUYE BASE ANTICORROSIVA)	PP-001
PINTURA EN CARA EXPUESTA DE SARDINEL DE JARDINERA	PP-001
PINTURA EN CARA EXPUESTA DE SARDINEL TIPO BURBUJA A=0.15 M	PP-001
PINTURA EN ESCALERAS	PP-001
PINTURA EN MUROS	PP-001
PINTURA EN MUROS BAJOS Y SARDINELES	PP-001
PINTURA EN SARDINEL DE MARTILLOS	PP-001
PINTURA EN SARDINEL DE VEREDAS	PP-001
PINTURA EN SARDINELES P/TRAFICO	PP-001
PINTURA EN SARDINELES Y VIAS	PP-001
PINTURA EN VEREDAS, RAMPAS	PP-001

PINTURA ESMALTE 2 MANOS EN BORDES VEREDAS	PP-001
PINTURA ESMALTE EN BARANDAS METALICAS	PP-001
PINTURA ESMALTE EN JARDINERAS	PP-001
PINTURA ESMALTE EN SARDINEL DE CONCRETO	PP-001
PINTURA LATEX 2 MANOS EN EXTERIORES	PP-001
PINTURA LATEX EN MUROS	PP-001
PINTURA SOBRE EL PAVIMENTO	PP-001
PINTURA TRAFICO EN JARDINERAS	PP-001
PINTURA TRAFICO EN SARDINELES	PP-001

ANEXO 25: Tabla de agrupación de partidas de señales de tránsito SL-001

PARTIDA	CODIGO
EXCAVACION Y COLOCACION DE SEÑALES DE TRANSITO	SL-001
FABRICACION DE SEÑALES INFORMATIVAS	SL-001
FABRICACION DE SEÑALES PREVENTIVAS	SL-001
FABRICACION DE SEÑALES REGULADORAS	SL-001
FABRICACION DE TRANQUERA PARA SEÑALIZACION	SL-001
MARCAS EN EL PAVIMENTO (LINEA CONTINUA)	SL-001
MARCAS EN EL PAVIMENTO (SIMBOLOS y LETRAS)	SL-001
MARCAS EN EL PAVIMENTO A=10 CMS	SL-001
MARCAS EN EL PAVIMENTO Y OTROS	SL-001
MARCAS EN EL PAVIMENTO, A= 10 CMS (CONTINUAS Y DISCONTINUAS)	SL-001
MARCAS EN LAS GIBAS	SL-001
PANELES DE SEÑALIZACION PREVENTIVO	SL-001
PINTADO DE SEÑALES DE TRANSITO EN EL PAVIMENTO	SL-001
PINTURA EN SEÑALIZACION VIAL	SL-001
R-30 SEÑAL VELOCIDAD MAXIMA (INC. COLOCACION)	SL-001
SEÑAL AMBIENTAL TEMPORAL	SL-001
SEÑAL DE PREVENCION (P-2A)	SL-001
SEÑAL DE PREVENCION (P-56)	SL-001
SEÑAL DE REGLAMENTACION (R-19)	SL-001
SEÑALES DE SEGURIDAD 40X60CM INC.MARCO	SL-001
SEÑALES INFORMATIVAS	SL-001
SEÑALES INFORMATIVAS (1.26 X 0.67M)	SL-001
SEÑALES PREVENTIVAS	SL-001
SEÑALES PREVENTIVAS (0.60 X 0.60M)	SL-001
SEÑALES PREVENTIVAS 600 X 600 mm	SL-001
SEÑALES PREVENTIVAS 75X75CM CON POSTE	SL-001
SEÑALES PREVENTIVAS DE DESVIO	SL-001
SEÑALES REGLAMENTARIA 75X75CM CON POSTE	SL-001
SEÑALES REGLAMENTARIAS	SL-001
SEÑALES REGLAMENTARIAS 600 X 900 mm	SL-001

SEÑALES REGULADORAS (0.60 X 0.90M)	SL-001
SEÑALIZACIÓN TEMPORAL DE SEGURIDAD	SL-001
SEÑALIZACION AMBIENTAL	SL-001
SEÑALIZACION EN EL PAVIMENTO	SL-001
SEÑALIZACION HORIZONTAL	SL-001
SEÑALIZACION HORIZONTAL EN VIAS (LINEA DISCONTINUA)	SL-001
SEÑALIZACION HORIZONTAL EN VIAS (PINTADO DE VEREDA)	SL-001
SEÑALIZACION HORIZONTAL EN VIAS (SIMBOLOS)	SL-001
SEÑALIZACION INFORMATIVA Y PREVENTIVA EN VIA	SL-001
SEÑALIZACION PARA IDENTIFICACION DE ZONAS	SL-001
SEÑALIZACION TEMPORAL AMBIENTAL	SL-001
SEÑALIZACION TEMPORAL DE LA OBRA	SL-001
SEÑALIZACION TEMPORAL DE SEGURIDAD	SL-001
SEÑALIZACION TEMPORAL DE SEGURIDAD DE OBRA	SL-001
SEÑALIZACION VERTICAL	SL-001
SEÑALIZACION VERTICAL EN VIAS	SL-001
SUMIN. Y COLOCACION DE SEÑALES VERTICALES INFORMATIVAS	SL-001
SUMIN. Y COLOCACION DE SEÑALES VERTICALES PREVENTIVAS	SL-001
SUMIN. Y COLOCACION DE SEÑALES VERTICALES REGULADORAS	SL-001
SUMINISTRO E INSTALACION DE SEÑALES INFORMATIVAS	SL-001
SUMINISTRO E INSTALACION DE SEÑALES PREVENTIVAS	SL-001
SUMINISTRO E INSTALACION DE SEÑALES REGULADORAS	SL-001
SUMINISTRO Y COLOCACION DE SEÑALES INFORMATIVAS	SL-001
SUMINISTRO Y COLOCACION DE SEÑALES VERTICALES	SL-001
P -2B CURVA A LA IZQUIERDA (INC. COLOCACION)	SL-001
P-2A CURVA ALA DERECHA (INC. COLOCACION)	SL-001
P-21 INCORPORACION DE TRANSITO IZQUIERDA (INC. COLOCACION)	SL-001
P-22 INCORPORACION DE TRANSITO DERECHA (INC. COLOCACION)	SL-001
P-33 RESALTO (INC. COLOCACION)	SL-001
P-48 CRUCE DE PEATONES (INC. COLOCACION)	SL-001
P-55 INICIACION DE VIAS CON SEPARADOR DOBLE SENTIDO (INC. COLOCACION)	SL-001
P-56 TERMINACION DE VIAS CON SEPARADOR DOBLE SENTIDO (INC. COLOCACION)	SL-001
R-1 PARE (INC. COLOCACION)	SL-001
PINTADO DE LÍNEA CENTRAL (AMARILLA)	SL-001
PINTADO DE LINEA E=10CM (AMARILLO)	SL-001
PINTADO DE LÍNEAS DE PASO PEATONAL (BLANCO)	SL-001
PINTADO DE LINEAS DE PASO PEATONALES (BLANCO)	SL-001
PINTADO DE LINEAS SOBRE PAVIMENTO.	SL-001
PINTADO DE MARCAS EN EL PAVIMENTO	SL-001
PINTADO DE PAVIMENTO DISCONTINUO EN EJE DE VIA (VER COLOR EN DETALLE), E=0.10 M	SL-001
PINTADO DE PAVIMENTO EJE DE VIA DISC, E=0.10 M.	SL-001
PINTADO DE PAVIMENTOS SIMBOLOS Y LETRAS	SL-001
PINTADO DE REDUCTOR DE VELOCIDAD	SL-001

PINTADO DE SIMBOLOS - FLECHAS (BLANCO)	SL-001
PINTADO DE SIMBOLOS Y LETRAS	SL-001
PINTADO LINEAL CONTINUO LATERAL E=0.10M	SL-001
PINTADO LINEAL INTERMITENTE CENTRAL E=0.10M.	SL-001
PINTADO LINEAS CONTINUAS EN EL PAVIMENTO	SL-001
PINTURA D/PASO PEATONAL Y SIMBOLOS DIRECCIONALES	SL-001
PINTURA EN GIBA	SL-001
PINTURA EN PAVIMENTO DE LETRAS Y SIMBOLOS	SL-001
PINTURA TRAFICO	SL-001
PINTURA TRAFICO EN EXTERIORES - SARDINELES	SL-001
REPINTADO DE LINEA INTERMITENTE CENTRAL E=.10 M	SL-001
PINTADO DE SÍMBOLOS Y LETRAS	SL-001
CORTE DE CARPETA ASFALTICA PARA ANCLAR GIBA	SL-001
I-20 PARADERO DE BUSES (INC. COLOCACION)	SL-001
FRANJA TACTIL ALERTA CON BALDOSAS PODODACTILES	SL-001
FRANJA TACTIL ALERTA, CON BALDOSAS PODOTACTILES, A= 40 CM.	SL-001
FRANJA TACTIL DIRECCIONAL, CON BALDOSAS PODOTACTILES, A= 40 CM.	SL-001

ANEXO 26: Tabla de agrupación de cama de adoquín AR-001

PARTIDA	CODIGO
CAMA DE ARENA (H=0.03)	AR-001
CAMA DE ARENA (h=5cm)	AR-001
CAMA DE ARENA H= 0.04 M	AR-001
CAMA DE ARENA PARA ADOQUIN DE CONCRETO e=5 cm	AR-001
CAMA DE ARENA E=2"	AR-001
CAMA DE ARENA H=5 CM PARA ADOQUINES	AR-001
CONFORMACION DE CAMA DE ARENA PARA ASENTADO DE ADOQUINES E=0.05M	AR-001
ARENA CAMA DE SOPORTE E=4.0 CM	AR-001
CAMA DE ASIENTO CON ARENA E=0.04M	AR-001
COLOCACION DE CAMA DE ARENA E=0.05 M.	AR-001
COLOCACION Y NIVELACION DE CAMA DE ARENA DE SOPORTE E=4.0 CM	AR-001
CAMA DE ASIENTO (PARA ADOQUINES)	AR-001

ANEXO 27: Tabla de agrupación de partidas de baranda metálica BM-001

PARTIDA	CODIGO
BARANDA METALICA	BM-001
BARANDA DE TUBO	BM-001
BARANDA DE TUBO 2" x 2.00mm F° NEGRO STANDARD H = 1.00m	BM-001
BARANDA DE TUBO METALICO S/ DISEÑO	BM-001
BARANDA METALICA C/TUBO REDONDO 2.5" H=1.0 M	BM-001
BARANDA METALICA h 1.00 TUBO ø 2 " Y 1 1/4"	BM-001
BARANDA METALICA H=0.70M. INCL. PINTADO	BM-001

BARANDA METALICA H=1.00M. INCL. PINTADO	BM-001
BARANDA METALICA INCL. PINTADO	BM-001
BARANDA METALICAS	BM-001
BARANDAS METÁLICAS DE 2" INC. PINTADO DOS MANOS	BM-001
BARANDAS METALICAS DIVISORIAS DE TUBO REDONDO 2"	BM-001
BARANDAS METALICAS EN MUROS	BM-001
ANGULAR 2 1/2"X2 1/2"X3/8"	BM-001
INSTALACION DE BOLARDO METALICO	BM-001
MANTENIMIENTO Y PINTURA DE BARANDAS METÁLICAS	BM-001
BARANDA DE ACERO NEGRO H=0.90m.	BM-001
SUMINISTRO E INST BARANDA METALICA	BM-001
PASAMANO METALICO INCL. PINTADO	BM-001
DESMONTAJE DE BARANDAS METALICAS	BM-001

ANEXO 28: Tabla de agrupación de partidas de base BS-001

PARTIDA	CODIGO
BASE DE 0.20 m	BS-001
BASE DE PUZOLAMA E=0.10 m	BS-001
BASE GRANULAR	BS-001
BASE GRANULAR CLASIFICADO E=0.15 m PARA VEREDA	BS-001
BASE GRANULAR COMPACTADA E=0.10 M	BS-001
BASE GRANULAR COMPACTADA E=0.10 M.	BS-001
BASE GRANULAR COMPACTADA EN VEREDAS h= 10 cm	BS-001
BASE GRANULAR E=0.10 M EN VEREDAS, RAMPAS	BS-001
BASE GRANULAR E=0.10 M.	BS-001
BASE GRANULAR E=0.10m	BS-001
BASE GRANULAR E=0.15 m	BS-001
BASE GRANULAR E=0.15M	BS-001
BASE GRANULAR E=0.15M EN FORMA MANUAL C/EQUIPO LIVIANO	BS-001
BASE GRANULAR e=0.20	BS-001
BASE GRANULAR E=0.20 m	BS-001
BASE GRANULAR e=0.20 m.	BS-001
BASE GRANULAR E=0.20 MTS	BS-001
BASE GRANULAR PARA BERMAS E=0.10 MTS	BS-001
BASE GRANULAR PARA MARTILLOS E=0.10 MTS	BS-001
BASE GRANULAR PARA PARCHADO	BS-001
BASE GRANULAR PARA RAMPA E=0.15 m	BS-001
BASE GRANULAR PARA RAMPA P/DISCAPACITADOS E=0.10 MTS	BS-001
BASE GRANULAR PARA RAMPAS VEHICULARES E=0.10 MTS	BS-001
BASE GRANULAR PARA VEREDAS E=0.10 MTS	BS-001
BASE GRANULAR PARA VEREDAS E=10M	BS-001
BASE GRANULAR PARA VEREDAS, MARTILLOS Y RAMPAS, E=0.10 MTS	BS-001
CONFORM D/BASE GRANULAR C/MAT PRES H=0.15M VEREDA	BS-001
CONFORM. PISO BLANDO C/MAT PRES. H=0.10M	BS-001

CONFORMACION D/BASE GRANULAR C/MAT PRES H=0.15M	BS-001
CONFORMACION DE BASE (E=0.20M)	BS-001
CONFORMACION DE BASE CON MATERIAL DE PRESTAMO	BS-001
CONFORMACION DE BASE GRANULAR (E=0.10M)	BS-001
CONFORMACION DE BASE GRANULAR (e=0.15m), CON MATERIAL DE PRESTAMO	BS-001
CONFORMACION DE BASE GRANULAR (E=0.20M)	BS-001
CONFORMACION DE BASE GRANULAR H=0.10m	BS-001
CONFORMACION DE BASE GRANULAR H=0.20 M	BS-001
CONFORMACION DE BASE GRANULAR H=20 CM	BS-001
CONFORMACION DE BASE GRANULAR PARA ADOQUIN E=0.15M	BS-001
CONFORMACION DE BASE GRANULAR PARA VEREDAS E=4"	BS-001
CONFORMACION DE BASE PARA TRANSITO PEATONAL	BS-001
EXTRACCION Y PREPARACION DE MATERIAL DE BASE	BS-001
EXTRACCION Y PREPARACION DE MATERIAL DE SUB-BASE	BS-001
BARRIDO DE BASE GRANULAR	BS-001
MATERIAL PARA BASE GRANULAR e=0.20 m	BS-001
ESCARIFICAR Y REMOVER BASE EXISTENTE h=0.15m	BS-001
NIVELACION RIEGO Y COMPACTACION PARA RASANTE	BS-001
CONFORMACIÓN DE LOS BADENES	BS-001
EXTENDIDO Y COMPACTACION DE BASE	BS-001
EXTENDIDO Y COMPACTACION DE BASE GRANULAR E=0.15 M C/MAQUINARIA	BS-001
EXTENDIDO Y COMPACTACION DE BASE GRANULAR E=0.20M C/MAQUINARIA	BS-001
EXTENDIDO Y COMPACTACION DE SUB-BASE	BS-001
BASE COMPACTADA MANUAL PARA BERMAS DE 0.10 M.	BS-001
BASE COMPACTADA MANUAL PARA RAMPAS DE 0.10 M.	BS-001
BASE COMPACTADA MANUAL PARA VEREDAS DE 0.10 M.	BS-001

ANEXO 29: Tabla de agrupación de partidas de carpeta asfáltica AS-001

PARTIDA	CODIGO
CARPETA ASFALTICA	AS-001
CARPETA ASFALTICA E=2"	AS-001
CARPETA ASFALTICA E=2" EN FRIO	AS-001
CARPETA ASFALTICA EN CALIENTE DE 2"	AS-001
CARPETA ASFALTICA EN CALIENTE E= 5CMS	AS-001
CARPETA ASFALTICA EN CALIENTE E=2"	AS-001
CARPETA ASFALTICA EN FRIO 2" - E1	AS-001
CARPETA ASFALTICA EN FRIO DE 2"	AS-001
CARPETA ASFALTICA EN FRIO DE E=2"	AS-001
CARPETA ASFALTICA EN FRIO E=2"	AS-001
EXTENDIDO Y COMPACTADO DE MEZCLA ASFALTICA EN FRIO	AS-001
EXTENDIDO Y COMPACTADO DE MEZCLA ASFALTICA EN FRIO e=2"	AS-001
COLOCADO DE CARPETA ASFALTICA EN CALIENTE DE 2"	AS-001

ESPARCIDO Y COMPACTADO CARPETA ASFALTICA EN FRIO e=2"	AS-001
PREPARACION DE MEZCLA ASFALTICA EN FRIO	AS-001
REPOSICION DE PAVIMENTO ASFALTICO	AS-001
CARGUIO DE MEZCLA ASFALTICA EN FRIO	AS-001
CARGUIO MEZCLA ASFALTICA EN FRIO	AS-001

ANEXO 30: Tabla de agrupación de partidas de concreto CN-XXX

PARTIDA	CODIGO
CONCRETO f´c = 210 kg/cm2	CN-001
CONCRETO f´c=175 Kg/cm2	CN-001
CONCRETO FC=175	CN-001
CONCRETO FC=175 KG/CM2	CN-001
CONCRETO f'c=175 kg/cm2	CN-001
CONCRETO CICLOPEO F'C=175KG/CM2 + 30% P.G.	CN-001
CONCRETO F'C=175 KG/CM2) ACAB. FROTACH. C/PASTA 1:2 INC BRUÑADO	CN-001
CONCRETO FC=175 KG/CM2, e=10cm, ACABADO PULIDO E=3.00mm Y BRUÑADO 1/2"	CN-001
CONCRETO F'C=175 KG/CM2.	CN-001
CONCRETO F'C=175 KG/CM2 PARA CUNETAS	CN-CU1
CONCRETO f"c=175 kg/cm2 PARA CUNETAS DE CONCRETO	CN-CU1
CONCRETO CICLOPEO EN MUROS F'c = 175kg/cm2	CN-MU1
CONCRETO CICLOPIO 1:10 C-H + 30% PG.	CN-MU1
CONCRETO EN MUROS DE CONTENCION f'c=210 kg/cm2	CN-MU1
CONCRETO f 'c=175 kg/cm2 PARA MUROS BAJOS Y SARDINELES	CN-MU1
CONCRETO F'C'= 210 kg/cm2 PARA MUROS	CN-MU1
CONCRETO f'c= 210 kg/cm2 PARA MUROS DE CONCRETO	CN-MU1
CONCRETO F'C=175 KG/CM2 PARA MUROS CONTENCION	CN-MU1
CONCRETO F'C=210 KG/CM2 PARA MUROS CONTENCION	CN-MU1
CONCRETO f"c=210 kg/cm2 PARA MUROS DE CONTENCION	CN-MU1
CONCRETO MUROS ARMADOS f'c=210kg/cm2	CN-MU1
CONCRETO MUROS CICLOPEO f'c=210kg/cm2 + 30%PG	CN-MU1
MURO DE CONTENCION, CONCRETO f'c=210 kg/cm2	CN-MU1
MUROS DE CONTENCION f'c= 210 kg/cm2	CN-MU1
MUROS DE MAPOSTERIA DE PIEDRA F'C=175 KG/CM2	CN-MU1
CONCRETO EN PAVIMENTO RIGIDO f'c=210 kg/cm2	CN-PR1
CONCRETO F´c=175 kg/cm2 PARA PAVIMENTO	CN-PR1
CONCRETO F'C'= 280 kg/cm2 PARA GIBAS	CN-PR1
CONCRETO F'C'= 280 kg/cm2 PARA PAVIMENTO RIGIDO	CN-PR1
CONCRETO FC=210 KG/CM2	CN-PR1
CONCRETO f'c=210 kg/cm2	CN-PR1
CONCRETO FC=210 KG/CM2 EN GIBA	CN-PR1
CONCRETO f'c=210 kg/cm2 PARA PAVIMENTO RIGIDO	CN-PR1
CONCRETO F'C=280 KG/CM2 (GIBAS)	CN-PR1
CONCRETO f"c=280 kg/cm2 PARA REDUCTOR DE VELOCIDAD	CN-PR1

CONCRETO F'C=280 KG/CM2 PAVIMENTO RIGIDO ACABADO FROTACHADO	CN-PR1
ROMPEMUELLE DE CONCRETO	CN-PR1
ROMPEMUELLES	CN-PR1
BERMAS DE CONCRETO FC=175 KG/CM2 E=4" SEMIPULIDO Y BRUÑADO	CN-PR1
CONCRETO 175 KG/CM2 PARA RAMPAS DISCAPACITADOS, E=10 CM, INC. BRUÑADO Y FROTACHADO	CN-RA1
CONCRETO 210 KG/CM2 PARA RAMPAS VEHICULARES E=10 CM, INC. ENLUCIDO Y BRUÑADO	CN-RA1
CONCRETO EN RAMPAS F'C=175 KG/CM2 H=0.10 M ACABADO FROTACHADO Y BRUÑADO	CN-RA1
CONCRETO F'C= 175 KG/CM2 PARA RAMPAS	CN-RA1
CONCRETO f'c=175 kg/cm2 PARA RAMPA	CN-RA1
CONCRETO FC=175 KG/CM2, RAMPAS	CN-RA1
CONCRETO PARA RAMPAS	CN-RA1
RAMPA DE CONCRETO f'c=175 kg/cm2	CN-RA1
RAMPA DE CONCRETO FC=175 KG/CM2 E=4" SEMIPULIDO Y BRUÑADO	CN-RA1
RAMPAS DE CONCRETO f'c=175 kg/cm2 e=10 cm FROT. Y BRUÑADO	CN-RA1
RAMPAS P/ DISCAPACITADOS DE CONCRETO 175 KG/CM2, E=10 CM INC. BRUÑADO Y FROTACHADO	CN-RA1
RAMPAS, CONCRETO F'C=175KG/CM2 INCLUYE BRUÑADO C/10CM	CN-RA1
RAMPAS DE CONCRETO 210 kg/cm2 P/ VEHICULOS INC. BRUÑADO S/DISEÑO	CN-RA1
RAMPA C°S° F'C =175KG/CM2 ACABADO CEMENTO PULIDO Y BRUÑADO	CN-RA1
CONCRERO PARA SARDINEL BURBUJA	CN-SA1
CONCRETO EN SADINELES f'c=175 kg/cm2	CN-SA1
CONCRETO f 'c=175 kg/cm2 PARA SARDINELES	CN-SA1
CONCRETO F'C= 175 KG/CM2 PARA SARDINEL BURBUJA	CN-SA1
CONCRETO FC=175 KG/CM2 EN SARDINELES	CN-SA1
CONCRETO F'C=175 KG/CM2 P/SARDINEL	CN-SA1
CONCRETO f'c=175 kg/cm2 PARA MARTILLOS	CN-SA1
CONCRETO f"c=175 kg/cm2 PARA SARDINEL DE CONCRETO	CN-SA1
CONCRETO F'C=175 KG/CM2 PARA SARDINELES	CN-SA1
CONCRETO F'C=175 KG/CM2 PARA SARDINELES REFORZADOS Y GRADAS	CN-SA1
CONCRETO f'c=175 kg/cm2 PARA SARDINELES TIPO BURBUJA	CN-SA1
CONCRETO f'c=210 kg/cm2 PARA SARDINEL PARA CONFINAR ADOQUIN	CN-SA1
CONCRETO MEDIA CAÑA FC=175 KG/CM2	CN-SA1
CONCRETO SIMPLE FC=175KG/CM2 EN MARTILLOS E=4"INC. PULIDO Y BRUÑADO	CN-SA1
SARDINEL BURBUJA DE CONCRETO 175 kg/cm2	CN-SA1
SARDINEL DE BORDE CONCRETO F'c = 175 kg/cm2	CN-SA1
SARDINEL DE CONCRETO DE F'C=210 KG/CM2	CN-SA1
SARDINEL DE CONFINAMIENTO	CN-SA1
SARDINEL DE CONFINAMIENTO: CONCRETO F´C=175 KG/CM2	CN-SA1
SARDINEL SUMERGIDO DE CONCRETO 175 kg/cm2	CN-SA1
SARDINEL SUMERGIDO P/RAMPAS C/CONCRETO F´C=175 KG/CM2	CN-SA1
SARDINEL SUMERGIDO: CONCRETO FC=175 KG/CM2	CN-SA1
SARDINEL, CONCRETO f'c=175 kg/cm2	CN-SA1

SARDINEL TIPO BURBUJA F'C=210 KG/CM2	CN-SA1
CONCRETO f'c=175 kg/cm2 PARA JARDINERAS	CN-SA1
CONCRETO f"c=175 kg/cm2 PARA JARDINERAS DE CONCRETO	CN-SA1
CONCRETO F'C=175 KG/CM2. EN JARDINERAS	CN-SA1
CAPTACION PLUVIAL, CONCRETO f'c= 210 kg/cm2	CN-SA1
JARDINERA: CONCRETO 175 KG/CM2	CN-SA1
JARDINERA: CONCRETO F'C=175 KG/CM2 C/ADITIVO IMPERMEABILIZANTE ACABADO CEMENTO PULIDO	CN-SA1
JARDINERAS, CONCRETO F´C= 175 KG/CM2	CN-SA1
SARDINELES DE CONCRETO DE F'C=210 KG/CM2	CN-SA1
SARDINELES Y JARDINERAS, CONCRETO F´C= 175 KG/CM2	CN-SA1
SARDINEL DE CONCRETO 175 kg/cm2 e=4", SEGUN DISEÑO P/MARTILLOS	CN-SA1
CONCRETO EN ALCANTARILLA F'C=210 KG/CM2	CN-SN1
CONCRETO f 'c=210 kg/cm2 PARA ALCANTARILLA	CN-SN1
CONCRETO f 'c=210 kg/cm2 PARA DRENAJE	CN-SN1
CONCRETO FC= 210 KG/CM2 PARA REGILLA DE CAPTACION	CN-SN1
CONCRETO FC=175 KG/CM2 EN CANALES	CN-SN1
CONCRETO f'c=210 kg/cm2 PARA CANAL	CN-SN1
CONCRETO F'C=210 KG/CM2 PARA DRENAJE PLUVIAL	CN-SN1
CONCRETO SIMPLE F´C=175 KG/CM2 DE FONDO DE CANAL	CN-SN1
CONCRETO BUZON DE INSPECCION f´c=210 KG/CM2	CN-SN1
CONCRETO FC= 210 KG/CM2 PARA BUZON	CN-SN1
CONCRETO MURO DE BUZON	CN-SN1
CONCRETO PARA ENCUADRE DE BUZONES EXISTENTES f'c=210 kg/cm2	CN-SN1
CONCRETO SIMPLE F´C=175 KG/CM2 DE PAREDES DE CANAL	CN-SN1
CONCRETO C:H 1:12 E=2" - SOLADO	CN-SO1
CONCRETO PARA SOLADOS C:H, 1:12	CN-SO1
CONCRETO SOLADO E=2"	CN-SO1
CONCRETO EN GRADERIAS F'C=175 KG/CM2 INC ACAB.	CN-VE1
CONCRETO EN GRADERIAS f'c=175 kg/cm2, E=0.10m BRUÑADO PULIDO	CN-VE1
CONCRETO EN VEREDAS f'c=175 kg/cm2	CN-VE1
CONCRETO EN VEREDAS f'c=175 kg/cm2, E=0.10m BRUÑADO PULIDO	CN-VE1
CONCRETO f 'c=175 kg/cm2 PARA GRADERIAS	CN-VE1
CONCRETO f 'c=175 kg/cm2 PARA VEREDAS	CN-VE1
CONCRETO f'c = 175 kg/cm2 PARA GRADERIAS	CN-VE1
CONCRETO F'c 175 kg/cm2 PARA JARDINERAS	CN-VE1
CONCRETO F'C= 175 KG/CM2 PARA JARDINERA	CN-VE1
CONCRETO F'C= 175 KG/CM2 PARA VEREDAS	CN-VE1
CONCRETO f'c= 210 kg/cm2 PARA ESCALERA	CN-VE1
CONCRETO f"c=175 kg/cm2 EN GRADERIAS	CN-VE1
CONCRETO FC=175 KG/CM2 EN JARDINERAS	CN-VE1
CONCRETO f"c=175 kg/cm2 EN PISOS DE VEREDAS (e=12 cm)	CN-VE1
CONCRETO f"c=175 kg/cm2 EN PISOS DE VEREDAS Y RAMPAS (e=12 cm)	CN-VE1
CONCRETO F'C=175 KG/CM2 EN VEREDAS DE E=10 CM ACAB. C.A. 1:2 E=1 CM	CN-VE1

CONCRETO F'C=175 KG/CM2 EN VEREDAS PODOTACTIL DE E=10 CM ACAB. C.A. 1:2 E=1 CM	CN-VE1
CONCRETO F'C=175 KG/CM2 PARA GRADAS SOBRE TERRENO	CN-VE1
CONCRETO f'c=175 kg/cm2 PARA VEREDAS	CN-VE1
CONCRETO GRADAS	CN-VE1
CONCRETO PISOS, RAMPAS Y GRADAS f'c=210 kg/cm2, PULIDO 1:2x1cm	CN-VE1
CONCRETO SIMPLE FC=175KG/CM2 EN VEREDA E=4"INC. PULIDO Y BRUÑADO	CN-VE1
CONCRETO SIMPLE FC=175 KG/CM2	CN-VE1
CONCRETO SIMPLE F'C=175 KG/CM2	CN-VE1
CONCRETO VEREDAS	CN-VE1
VEREDA DE CONCRETO E=0.10 FC =175 KGCM2	CN-VE1
VEREDA DE PIEDRA LAVADA F'C=175 KG/CM2, E=4"	CN-VE1
VEREDAS	CN-VE1
VEREDAS CONCRETO F'C=175 KG/CM2 (INCLUYE FROTACHADO Y BRUÑADO)	CN-VE1
VEREDAS DE CONCRETO 175 KG/CM2 E = 4" FROT. Y BRUÑADO	CN-VE1
VEREDAS DE CONCRETO 175 kg/cm2 e=4", FROT. Y BRUÑADO	CN-VE1
GRADAS DE CONCRETO FC=175 KG/CM2	CN-VE1
GRADAS, CONCRETO F'C=175 KG/CM2	CN-VE1
ESCALERAS, CONCRETO f'c=210 kg/cm2	CN-VE1
CONCRETO f'c= 210 kg/cm2 EN ZAPATAS	CN-ZA1
CONCRETO F'C'= 210 kg/cm2 PARA ZAPATAS	CN-ZA1
ZAPATA, CONCRETO PREMEZCLADO f'c=210 kg/cm2	CN-ZA1
ZAPATAS - CONCRETO 210 KG/CM2	CN-ZA1
ZAPATAS, CONCRETO f'c=210 kg/cm2	CN-ZA1
CONCRETO F´c=175 kg/cm2 PARA BASE DE POSTE METALICO	CN-ZA1
CONCRETO f'c=100 kg/cm2 + 30% P.G. PARA CIMIENTOS	CN-ZA1
CONCRETO f'c=100 kg/cm2 CIMIENTOS CORRIDOS	CN-ZA1
CONCRETO F'C=140 KG/CM2 C/IMPERMEABILIZANTE EN CIMENTACION DE SR	CN-ZA1
CONCRETO F'C=140 KG/CM2 C/IMPERMEABILIZANTE EN POLVO P/CIMENTACION BASE DE POSTES	CN-ZA1
CONCRETO f'c= 210 kg/cm2 PARA COLUMNAS	CN-ZA1
CONCRETO f'c= 210 kg/cm2 PARA VIGAS	CN-ZA1
COLUMNAS, CONCRETO F'C=210 KG/CM2 IP	CN-ZA1
LOZA DE TECHO DE CONCRETO ARMADO F´C=210 KG/CM2 PREFABRICADA 1X0.50X0.20 LOSA	CN-ZA1
LOZA DE TECHO FIJO CONCRETO ARMADO F´C =210 Kg/cm2	CN-ZA1
SOLADO DE CONCRETO DE 2"	CN-SO1
SOLADO DE CONCRETO E=5 CM, MEZCLA C:H 1:12	CN-SO1
SOLADO DE CONCRETO FC = 100 KG/CM2	CN-SO1
SOLADO DE CONCRETO f'c = 100 kg/cm2 e=0.10 m	CN-SO1
SOLADO DE CONCRETO, E=4 "	CN-SO1
SOLADO DE E=2" CON MEZCLA 1:12	CN-SO1
SOLADO E=5 CM, MEZCLA C:H 1:12	CN-SO1
SOLADO F'C= 100 KG/CM2 PARA DRENAJE PLUVIAL (e=10cm)	CN-SO1

SOLADO F'C=100 KG/CM2 PARA ZAPATAS DE MUROS DE CONTENCION (e=10cm)	CN-SO1
SOLADO FC=100 KGF/CM2	CN-SO1
SOLADO PARA ZAPATAS DE MUROS DE CONTENCION (e=10cm)	CN-SO1
SOLADO PARA ZAPATAS e=2", 1:12 CEM/HORM	CN-SO1
SOLADOS CONCRETO PARA MUROS f'c=100 kg/cm2 h=2"	CN-SO1
SOLADOS PARA ZAPATAS DE 4" MEZCLA 1:12 C:H	CN-SO1
CONSTRUCCION DE RAMPAS VEHICULARES	CN-RA1
REJILLA DE CONCRETO	CN-RE1
REGILLA DE PROTECCION	CN-RE1
REJILLA DE DRENAJE	CN-RE1
FALSO PISO E=2" CONCRETO 1:10	CN-001
REJILLA DE ALCANTARILLA	CN-RE1
REJILLA DE CONCRETO ARMADO L=12.00 M F`C=280KG/CM2	CN-RE1
REJILLA DE PROTECCION	CN-RE1
CONCRETO EN REJILA	CN-RE1

ANEXO 31: Tabla de agrupación de partidas de adoquín AQ-001

PARTIDA	CODIGO
COLOCACION DE ADOQUIN DE CONCRETO	AQ-001
COLOCACION DE ADOQUIN DE CONCRETO 20X10X6cm. f'c=420kg/cm2	AQ-001
COLOCACION DE ADOQUIN DE CONCRETO 20X10X8cm. f'c=420kg/cm2	AQ-001
COLOCACION DE ADOQUINES 20x10x6 cm, GRIS	AQ-001
COLOCACION DE ADOQUINES 20x10x6 cm, ROJO	AQ-001
COLOCACION DE ADOQUINES DE CONCRETO 20x10x8 CM	AQ-001
COLOCACION DE ADOQUINES DE CONCRETO 20X10X8CM	AQ-001
COLOCACION DE ADOQUINES RECTANGULARES H=8CM	AQ-001
PISO DE ADOQUIN COLOR GRIS	AQ-001
PISO DE ADOQUIN COLOR ROJO H=8.0 CM, 10X20 CM.	AQ-001
PISO DE ADOQUINES COLOR NATURAL	AQ-001
SUMINISTRO Y COLOCACION DE ADOQUIN 20x10x8 cm	AQ-001
SUMINISTRO Y COLOCACION DE ADOQUINES DE CONCRETO COLOR E=8CM	AQ-001
ADOQUIN DE CONCRETO COLOR NATURAL f'c= 561 kg/cm2 DE 10 x 20 x 8 cm	AQ-001
ADOQUIN DE CONCRETO COLOR ROJO f'c= 420 kg/cm2 DE 10 x 20 x 6 cm	AQ-001
ADOQUIN DE CONCRETO E=8CM	AQ-001
ADOQUIN DE CONCRETO H=0.06M	AQ-001
ADOQUIN DE CONCRETO H=0.08M	AQ-001
BERMA DE ADOQUIN DE CONCRETO	AQ-001
BERMA DE ADOQUIN DE CONCRETO DE COLOR GRIS (0.20X0.10X0.06 M) f'c=320 kgr/cm2	AQ-001
BERMA DE CONCRETO F'C=175 KG/CM2	AQ-001
BERMA DE PISO ADOQUINADO F'C=420 kg/cm2,ALTO TRANSITO 10X20X6	AQ-001
PAVIMENTO DE ADOQUIN DE CONCRETO PREFABRICADO DE 0.20X0.10X0.08 M.	AQ-001
ASENTADO DE ADOQUINES DE CONCRETO DE 0.20 x 0.10 x 0.06	AQ-001

CORTE DE ADOQUINES	AQ-001

ANEXO 32: Tabla de agrupación de partidas de imprimación IM-001

PARTIDA	CODIGO
IMPRIMACION	IM-001
IMPRIMACION ,ASFALTO DILUIDO	IM-001
IMPRIMACION ASFALTICA	IM-001
IMPRIMACION ASFALTICA - E1	IM-001
IMPRIMACION ASFALTICA CON MC-30	IM-001
IMPRIMACION CON MC-30 (INC. BARRIDO)	IM-001
IMPRIMACION MC-30.30 GLN / M2 INC. BARRIDO	IM-001
IMPRIMACION Y COLOCADO DE ASFALTO EN CICLO VIA	IM-001
IMPRIMACION,ASFALTO DILUIDO	IM-001
IMPRIMADO	IM-001
IMPRIMADO RC-250	IM-001
RIEGO DE LIGA (CEM ASF)	IM-001

ANEXO 33: Tabla de agrupación de partidas de sanitarias SR-001

PARTIDAS	CODIGO
SUM. E INST. DE TUBERIA PVC S-25 DN 300mm T.N.	SR-001
SUMIN.E INST. TUBERIA PVC S-20 DN -16 Ø 450 mm	SR-001
SUMIN.E INST. TUBERIA PVC S-25 DN -12"" Ø 315 mm	SR-001
SUMINISTRO E INSTAL. DE TUB. PVC DESAGUE 200 MM	SR-001
SUMINISTRO E INSTAL. DE TUB. PVC DESAGUE 250 MM	SR-001
SUMINISTRO DE TUBERÍA HDPE 18"	SR-001
SUMINISTRO DE TUBERÍA HDPE 24"	SR-001
SUMINISTRO E INSTALACION DE ACCESORIOS PARA RED DE AGUA	SR-001
SUMINISTRO E INSTALACION DE CAJA DE REGISTRO CON TAPA	SR-001
SUMINISTRO E INSTALACION DE CAJA Y TAPA PARA MEDIDOR DE AGUA	SR-001
SUMINISTRO E INSTALACION DE CAJAS DE AGUA Y DESAGUE	SR-001
SUMINISTRO E INSTALACION DE RED PRINCIPAL	SR-001
SUMINISTRO E INSTALACION DE TUBERIA	SR-001
SUMINISTRO E INSTALACION DE TUBERIA HDP D=400 MM	SR-001
SUMINISTRO E INSTALACION DE TUBERIA HDP D=600 MM	SR-001
SUMINISTRO E INSTALACION DE TUBERIA PVC A10 2"	SR-001
SUMINISTRO E INSTALACION DE TUBERIA PVC Ø 6"	SR-001
TUBERIA PVC DN= 200 MM X 6 M, S-25 UF	SR-001
TUBERIA PVC SDR 51 - SN2 S-25 DN=500MM	SR-001
ACONDICIONAMIENTO DE BUZON DE DESAGUE	SR-001
ACONDICIONAMIENTO DE BUZONES	SR-001
ACONDICIONAMIENTO DE CAJAS DE AGUA/DESAGUE EN VIVIENDAS	SR-001
BUZON DE DRENAJE PLUVIAL D=1.20	SR-001
BUZON TIPO I HASTA H=1.50 M TERRENO NORMAL COMPACTO	SR-001

BUZON TIPO I HASTA H=1.80 M TERRENO NORMAL COMPACTO	SR-001
BUZON TIPO II HASTA H=3.00 M TERRENO NORMAL COMPACTO	SR-001
COLOCACION DE TUBERIA DE DRENAJE PVC 2"	SR-001
COLOCACION DE TUBERIA PVC SDR 51 - SN2 S-25 DN=500MM	SR-001
CONEXION DOMICILIARIA DE AGUA	SR-001
PRUEBA HIDRAULICA	SR-001
PRUEBA HIDRAULICA EN TUBERIA DE ALCANTARILLADO	SR-001
PRUEBA HIDRAULICA EN TUBERIA DE DRENAJE	SR-001
PRUEBA HIDRAULICA EN TUBERIA DE DRENAJE D=0.8 - 1.2 M	SR-001
PRUEBA HIDRAULICA RED DRENAJE DN= 200MM A 250MM	SR-001
NIVELACION DE BUZONES	SR-001
NIVELACION DE BUZONES DE DESAGUE	SR-001
NIVELACION DE BUZONES DE DESAGUE Y REPOSICION	SR-001
NIVELACION DE BUZONES DE DESAGUE Y REPOSICION DE TAPAS DE CONCRETO	SR-001
NIVELACION DE BUZONES EN GENERAL	SR-001
NIVELACION DE BUZONES Y ALCANTARILLA EXISTENTES	SR-001
NIVELACION DE CAJAS DE DESAGUE	SR-001
NIVELACION DE REGISTROS DE AGUA	SR-001
NIVELACIÓN DE TAPAS DE BUZON	SR-001
NIVELACION Y RECONEXION DE CAJA DE CONCRETO P/ MEDIDOR DE AGUA	SR-001
NIVELACION Y RECONEXION DE CAJA DE REGISTRO DE DESAGUE	SR-001
NIVELACION Y RECONEXION DE CAJAS DE DESAGUE	SR-001
NIVELACION Y RECONEXION DE MEDIDORES DE AGUA	SR-001
MOVIMIENTO DE CAJA DE AGUA EXISTENTE	SR-001
MOVIMIENTO DE CAJA DE DESAGUE EXISTENTE	SR-001
EMPALME A RED EXISTENTE	SR-001
ENCIMADO DE BUZONES DE DESAGUE	SR-001
INSTALACIÓN DE LA TUBERÍA CORRUGADA HDPE DE 18"	SR-001
INSTALACIÓN DE LA TUBERÍA CORRUGADA HDPE DE 24"	SR-001
MEDIDOR DE AGUA	SR-001
VALVULA DE COMPUERTA DE 1"	SR-001
VALVULA DE DESCARGA DE AIRE	SR-001
CONTINGENCIA CONEXION DOMICILIARIA DE DESAGUE	SR-001
CONTINGENCIA DE CONEXION DOMICILIARIA DE AGUA POTABLE	SR-001
REACONDICIONAMIENTO DE ACOMETIDAS	SR-001
TRAMITE DE CONEXION DE AGUA A RED EXISTENTE	SR-001
SERVICIO DE AGUA POTABLE	SR-001
REPOCION DE CAJA DE AGUA	SR-001
REPOCION DE CAJA DE DESAGUE	SR-001
REPOSICION DE CAJA Y TAPA PARA MEDIDOR AGUA POTABLE	SR-001
REPOSICION DE CAJAS DE INSTALACION DOMICILIARIAS DE AGUA POTABLE	SR-001
REPOSICION DE CAJAS DE INSTALACION DOMICILIARIAS DE DESAGUE	SR-001
REPOSICION DE CAJAS DE INSTALACIONES DOMICILIARIAS DE AGUA POTABLE	SR-001

REPOSICION DE CAJAS DE REGISTRO DE AGUA	SR-001
REPOSICION DE CAJAS DE REGISTRO DE DESAGUE	SR-001
REPOSICION DE CAJAS DE REGISTRO DESAGUE	SR-001
REPOSICION DE CONEXIONES DOMICILIARIAS	SR-001
REPOSICION DE INSTALACIONES SANITARIAS	SR-001
RETIRO Y REPOSICION CAJAS DE REGISTRO DE DESAGUE	SR-001
RETIRO Y REPOSICION CAJAS P/MEDIDORE DE AGUA	SR-001
RETIRO Y REPOSICION DE CAJAS DE REGISTRO DE AGUA	SR-001
RETIRO Y REPOSICION DE CAJAS DE REGISTRO DE DESAGUE	SR-001
REUBICACION DE PILETAS DE AGUA	SR-001
REFORZAMIENTO DE CAJAS DE AGUA Y DESAGUE PARA PASO VEHICULAR	SR-001
SUMINISTRO E INST. DE RIEL EN DRENAJE	SR-001
SUMINISTRO E INSTALACION DE REJILLA	SR-001
SUMINISTRO E INSTALACION DE RIEL EN REJILLA	SR-001
SUMNISTRO E INSTALACION DE MARCO Y TAPA	SR-001
TAPA DE TECHO DE BUZONES DE INSPECCIÓN	SR-001
TAPA DE TECHO DE REJILLA DE CAPTACION	SR-001
TAPAS DE CONCRETO	SR-001
VALVULA DE DESCARGA FINAL PURGA	SR-001
REGILLA DE PROTECCION	SR-001
REJILLA DE ALCANTARILLA	SR-001
REJILLA DE CONCRETO	SR-001
REJILLA DE CONCRETO ARMADO L=12.00 M F`C=280KG/CM2	SR-001
REJILLA DE DRENAJE	SR-001
DADO DE ANCLAJE TUBERIA - BUZON, FC=175 KG/CM2	SR-001
DADO DE CONCRETO, F'c=100 kg/cm2	SR-001
TUBERIA DE DRENAJE EN MURO	SR-001
PLATINAS DE 2 1/2" X 1/2"	SR-001
JUNTAS WATER STOP	SR-001
DADO DE CONCRETO f'c=140 kg/cm2	SR-001

ANEXO 34: Tabla de agrupación de partidas de tarrajeo RR-001

PARTIDAS	CODIGO
TARRAJEO C:A 1:4 E=1.5CM EN CARAS VISIBLES DE JARDINERAS	RR-001
TARRAJEO DE BUZONES DE INSPECCION	RR-001
TARRAJEO DE MUROS ACABADO CON C-A 1:4	RR-001
TARRAJEO DE REJILLA DE CAPTACION	RR-001
TARRAJEO DE SARDINELES	RR-001
TARRAJEO DE SARDINELES EN JARDINERAS	RR-001
TARRAJEO DE SARDINELES TIPO BURBUJA	RR-001
TARRAJEO EN ESCALERAS	RR-001
TARRAJEO EN EXTERIORES (MORTERO 1:5)	RR-001
TARRAJEO EN GRADERIAS	RR-001
TARRAJEO EN MUROS	RR-001

TARRAJEO EN MUROS BAJOS Y SARDINELES	RR-001
TARRAJEO EN MUROS DE CONTENCION	RR-001
TARRAJEO FROTACHADO DE LOSAS DE PAVIMENTO RIGIDO	RR-001
TARRAJEO SEMIPULIDO S/GRADERÍAS E=1.5CM	RR-001
TARRAJEO SEMIPULIDO S/MUROS E=1.5CM	RR-001

ANEXO 35: Tabla de agrupación de partidas de acabados de concreto AB-001

PARTIDA	CODIGO
BRUÑADO DE VEREDAS	AB-001
BRUÑADO EN GRADAS	AB-001
BRUÑADO EN RAMPAS	AB-001
BRUÑADO EN VEREDAS	AB-001
BRUÑADO Y PULIDO DE RAMPAS PEATONALES	AB-001
BRUÑAS DE 1 CM EN PISO	AB-001
BRUÑAS DE E=1 cm	AB-001
FROTACHADO EN GRADERIAS	AB-001
FROTACHADO Y BRUÑADO EN VEREDAS	AB-001
MAMPOSTERIA DE PIEDRA (COLOCACIÓN DE BLOQUES Y CONCRETO F'C=175 KG/CM2)	AB-001
MAMPOSTERIA DE PIEDRA (e=0.15m)	AB-001
MAMPOSTERIA DE PIEDRA 70% PM FC'=210KG/CM2	AB-001
MARCO DE F°F° INCLUYE TAPA DE CONCRETO	AB-001
ACABADO FROTACHADO EN VEREDAS	AB-001
ENLUCIDO Y BRUÑADO EN GRADERIAS	AB-001
ENLUCIDO Y BRUÑADO EN PISOS DE VEREDAS	AB-001
ENLUCIDO Y BRUÑADO EN PISOS DE VEREDAS Y RAMPAS	AB-001
PISO TEXTURIZADO PODO TACTIL EN FORMA MANUAL P/VEREDAS Y MARTILLOS	AB-001
SOLAQUEADO CEMENTO-ARENA PARA JARDINERAS	AB-001
SOLAQUEADO DE BORDE DE VEREDA Y MARTILLOS	AB-001
SOLAQUEADO DE CANAL	AB-001
SOLAQUEADO DE ELEMENTOS ESTRUCTURALES CARAVISTA	AB-001
SOLAQUEADO DE JARDINERAS	AB-001
SOLAQUEADO DE MUROS C/MEZCLA C:A	AB-001
SOLAQUEADO DE SARDINELES	AB-001
SOLAQUEADO DE SUPERFICIES C/MEZCLA C:A	AB-001
SOLAQUEADO EN MUROS CEMENTO-ARENA	AB-001
SOLAQUEADO EN MUROS DE CONTENCION	AB-001
SOLAQUEADO EN SARDINELES CEMENTO-ARENA	AB-001
SOLAQUEO DE JARDINERAS DE CONCRETO	AB-001
SOLAQUEO DE MUROS	AB-001
SOLAQUEO DE MUROS DE MUROS DE CONTENCION	AB-001
SOLAQUEO DE REDUCTOR DE VELOCIDAD	AB-001
SOLAQUEO DE SARDINEL C/MORTERO 1:5 X 0.5 CM.	AB-001

SOLAQUEO DE SARDINEL DE CONCRETO	AB-001
SOLAQUEO DE SARDINELES	AB-001
SOLAQUEO DE SARDINELES Y JARDINERA C/MORTERO 1:5 X 0.5 CM.	AB-001
SOLAQUEO INTERIOR DE FUSTE BUZON	AB-001
SOLAQUEO PARA DRENAJE PLUVIAL	AB-001
SOLAQUEO PARA SARDINEL DE CONCRETO	AB-001
REVESTIMIENTO DE CANAL CON BLOQUES DE PIEDRA	AB-001
COLOCACIÓN DE GRANALLA DE COLORES	AB-001
COLOCACIÓN DE SARDINEL DE PIEDRA GRANODIORITA 0.10X0.25XVAR	AB-001
CONCRETO MAMPOSTERIA f'c=210kg/cm2 + 30%P.M	AB-001
FRAGUADO DE SARDINEL DE PIEDRA	AB-001
SUMINISTRO DE GRANALLA DE COLORES DE BOLSA DE 10KG	AB-001

ANEXO 36: Tabla de agrupación de partidas de sembrado SM-001

PARTIDA	CODIGO
SEMBRADO DE ARBOL FICUS BENJAMINA	SM-001
SEMBRADO DE ARBOLES	SM-001
SEMBRADO DE ÁRBOLES	SM-001
SEMBRADO DE AREAS VERDES	SM-001
SEMBRADO DE CESPED	SM-001
SEMBRADO DE GRASS	SM-001
SEMBRADO DE GRASS EN AREAS VERDES	SM-001
SEMBRADO DE GRASS EN CHAMPA	SM-001
SEMBRADO DE GRASS NATURAL	SM-001
SEMBRADO DE PLANTONES	SM-001
SEMBRADO DE PLANTONES (ARBOLES ORNAMENTALES)	SM-001
FERTILIZACION, SUMINISTRO E INSTALACION DE ARBOL	SM-001
PLANTA EN JARDIN	SM-001
PLANTACION DE FICUS	SM-001
PLANTADO DE ARBOLES MORAS H:1.00m.	SM-001
PLANTAS	SM-001
PLANTONES DE ARBOLES EN JARDINERAS	SM-001
COLOCACION DE TIERRA DE CHACRA	SM-001
COLOCACIÓN DE TIERRA DE CHACRA	SM-001
BATIDO DE TIERRA DE CHACRA CON ABONO ORGANICO	SM-001
SUMINISTRO Y ESPARCIDO DE TIERRA DE CHACRA	SM-001
PREPARACION DEL TERRENO CON TIERRA DE CHACRA	SM-001
TIERRA FERTILIZADA	SM-001
PREPARACION DE TERRENO PARA JARDINERA	SM-001
ARBORIZACION	SM-001
REMOCION DE ARBOLES EXISTENTES	SM-001
SUMINISTRO Y PLANTADO DE ARBOL	SM-001
SUMINISTRO Y SEMBRADO DE ARBOLES PARA AREA VERDE	SM-001
SUMINISTRO Y COLOCACION DE ESPECIES FORESTALES	SM-001

PREPARACION Y/O TRATAMIENTO DEL TERRENO PARA EL SEMBRADO DE ARBOL	SM-001
JARDINERAS CUADRADAS	SM-001
CONFORMACION DE AREAS VERDES	SM-001
SUMINISTRO DE ARBOLES ORNAMENTALES	SM-001
REVEGETACÓN DE ÁREAS INTERVENIDAS.	SM-001
REHUBICACION DE ARBOLES	SM-001
PREPARACIÓN DE SUPERFICIE	SM-001
CAMA TIERRA DE CHACRA h=0.15cm	SM-001
EXTRACCION DE ARBOLES	SM-001

ANEXO 37: Tabla de agrupación de partidas de riego RO-001

PARTIDA	CODIGO
RIEGO	RO-001
RIEGO DE AGUA	RO-001
RIEGO DURANTE LA EJECUCION DE LA OBRA	RO-001
RIEGO PERMANENTE DE ZONA DE TRABAJO	RO-001
RIEGO PERMANENTE EN OBRA	RO-001
HUMEDECIMIENTO DE LA ZONA DE TRABAJO	RO-001
HUMEDECIMIENTO DE MATERIAL Y AREA DE TRABAJO	RO-001
REGADO DE VIAS DE ACCESO	RO-001
REGADO DE VIAS DE ACCESO	RO-001

ANEXO 38: Tabla de agrupación de partidas de arenado para pavimento flexible AI-002

PARTIDA	CODIGO
ARENADO BASE IMPRIMIDA	AI-001
ARENADO DE BASE IMPRIMADA	AI-001
ARENADO DE BASE IMPROMIDA	AI-001
ARENADO DE IMPRIMACION	AI-001
ARENADO EN BASE IMPRIMIDA	AI-001
ARENADO DE CARPETA ASFALTICA	AI-002
ARENADO DE SUPERFICIE ASFÁLTICA	AI-002
ARENADO SUPERFICIAL DE PROTECCION DE CARPETA	AI-002
ARENADO SUPERFICIAL P/CARPETA ASFALTICA	AI-002
ARENADO SUPERFICIAL PARA CARPETA ASFALTICA	AI-002
ARENADO SUPERFICIE CARPETAEADA	AI-002
ARENADO SUPERFICIE CARPETEADA	AI-002

ANEXO 39: Tabla de agrupación de partidas de Barrido BR-084

PARTIDA	CODIGO
BARRIDO DE SUPERFICIE IMPRIMADA	BR-084
BARRIDO DE SUPERFICIE PARA BASE GRANULAR	BR-084

BARRIDO DE SUPERFIICIE IMPRIMIDA	BR-084

ANEXO 40: Tabla de agrupación de partidas de sellado de arena SQ-001

PARTIDA	CODIGO
ARENADO Y COMPACTADO DESPUES DE COLOCACION	SQ-001
SELLO DE ARENA ENTRE ADOQUINES	SQ-001
COMPACTADO Y SELLADO CON ARENA FINA	SQ-001
APLICACION DE IMPRIMANTE EPOXICO PARA PROTECCION DE PISO DE ADOQUIN	SQ-001
SELLADO Y COMPACTADO FINAL DEL ADOQUIN	SQ-001
COMPACTADO INICIAL DE ADOQUIN	SQ-001
ARENA Y SELLADO DE COMPACTACION	SQ-001
SELLADO DE JUNTAS BERMA CENTRAL	SQ-001
COMPACTADO INICIAL DEL ADOQUIN	SQ-001
SELLADO Y COMPACTACION FINAL DEL ADOQUIN	SQ-001
SELLADO Y COMPACTACION DE JUNTAS DE ADOQUINES CON ARENA	SQ-001
ARENA Y SELLO DE COMPACTACION	SQ-001
SELLADO DE JUNTAS	SQ-001
ARENADO Y SELLADO DE JUNTAS	SQ-001
SELLADO DE JUNTAS EN ADOQUINES	SQ-001
SELLADO DE JUNTAS DE ADOQUINES	SQ-001
SELLO O PARCHADO DE JUNTAS CON ARENA FINA	SQ-001

ANEXO 41: Tabla de agrupación de partidas de varios VS-001

PARTIDAS	CODIGO
BALDOSA PODOTACTIL	VS-001
MURETE PARA PLACA RECORDATORIA	VS-001
PERGOLA PROTECTORA DE SOL INC. INSTALACION	VS-001
BANCA SEGÚN DETALLE INC. INSTALACION	VS-001
PASOS Y SERVIDUMBRE	VS-001
MEJORAMIENTO DE ACCESO - DESVIO	VS-001
CONSTRUCCION DE PARADEROS	VS-001
REJILLA DE CONCRETO	VS-001
ZONAS DE CANTERAS	VS-001
TALLER DE MANTENIMIENTO DE MAQUINARIA Y EQUIPO	VS-001
PARADERO SEGUN DETALLES	VS-001
IMPERMEABILIZACION INTERIOR DE JARDINERAS	VS-001
DESMONTAJE DE INSTALACIONES TEMPORALES	VS-001
CONTROL TOPOGRAFICO C/EQUIPO	VS-001
IMPERMEABILIZACION INTERIOR DE SARDINELES	VS-001
ELABORACION EXPEDIENTE TECNICO REUBICACION	VS-001
ESCALERA PROVISIONAL METAL-MADERA	VS-001
COBERTURA LONA	VS-001

BANDEROLAS DE AVISO	VS-001
RIELES 1.00 M. 4"	VS-001
PLACA RECORDATORIA	VS-001
IMPERMEABILIZACION DE MUROS	VS-001
SUMINISTRO Y CONEXION DE GOTEROS	VS-001
PAPEL Y OTROS	VS-001
SERVICIO DE ALIMENTACION	VS-001
CARGADO DE BLOQUES DE PIEDRA EN CANTERA	VS-001
MANTENIMIENTO DE TRANSITO Y SEGURIDAD VIAL	VS-001
CAPACITACION AL PERSONAL DE OBRA, TECNICO Y ADMINISTRATIVO	VS-001
PERFORACION DE CONCRETO PARA ANCLAJE DE FIERRO DE 3/4"	VS-001
TUBERIA DE DRENAJE PVC-SAL 2" EN MURO D/CONCRETO L=0.50 m	VS-001
SELL-PARCHADO Y COMPACTADO	VS-001
CONTROL TOPOGRAFICO DURANTE EL PROCESO	VS-001
REPARACION DE MUROS DE CONTENCIÓN	VS-001

ANEXO 42: Tabla de agrupación de partidas de cama de arena para tuberías CM-001

PARTIDA	CODIGO
CAMA Y SOBRECAMA DE APOYO (E=0.10M, E=0.15M)	CM-001
CAMA DE ARENA A= 1.0 - 1.5 M MAT. ZARANDEADO	CM-001
CAMA DE APOYO TUBERIA E=0.10 m	CM-001
CAMA DE ARENA E=10CMS PARA TUBERIA	CM-001
CAMA DE ARENA A= 0.10 - 0.15 M MAT. ZARANDEADO	CM-001
CAMA DE APOYO MAT. ZARANDEADO	CM-001
CAMA DE APOYO TUBERIA e=0.10m b=0.50	CM-001
COLOCACION Y NIVELACION DE CAMA DE ARENA DE SOPORTE	CM-001
CAMA DE APOYO DE ARENA	CM-001
CAMA DE APOYO	CM-001
CAMA DE ARENA	CM-001
CAMA DE ARENA E=0.10M + PROTECCION EN ZANJA C/MATERIAL PROPIO P/TUBERIA	CM-001