



**ESCUELA UNIVERSITARIA DE POSGRADO**

**MODELO DE INTELIGENCIA ARTIFICIAL CON FINES DE PREDICCIÓN DEL CBR  
EN OBRAS VIALES EN LA REGIÓN HUÁNUCO, 2024**

**Línea de investigación:**  
**Desarrollo urbano-rural, catastro, prevención de riesgos, hidráulica y  
geotecnia**

Tesis para optar el Grado Académico de Doctor en Ingeniería Civil

**Autor**

Matto Pablo, Edgar Grimaldo

**Asesora**

Pastrana Diaz, Nérida del Carmen

ORCID: 0000-0001-8357-3012

**Jurado**

Malpartida Canta, Rommel

Cancho Zuñiga, Gerardo Enrique

García Urrutia Olavarría, Roque Jesús Leonardo

**Lima - Perú**

**2025**



# MODELO DE INTELIGENCIA ARTIFICIAL CON FINES DE PREDICCIÓN DEL CBR EN OBRAS VIALES EN LA REGIÓN HUÁNUCO, 2024

## INFORME DE ORIGINALIDAD

12%	9%	4%	5%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

## FUENTES PRIMARIAS

1	hdl.handle.net	1%
	Fuente de Internet	
2	Submitted to Universidad Internacional de la Rioja	1%
	Trabajo del estudiante	
3	www.coursehero.com	<1%
	Fuente de Internet	
4	repositorio.unajma.edu.pe	<1%
	Fuente de Internet	
5	repositorio.unfv.edu.pe	<1%
	Fuente de Internet	
6	Submitted to Universidad Nacional Federico Villarreal	<1%
	Trabajo del estudiante	
7	repositorio.unh.edu.pe	<1%
	Fuente de Internet	
8	Submitted to UNIBA	<1%
	Trabajo del estudiante	
9	Submitted to Universidad Anahuac México Sur	<1%
	Trabajo del estudiante	
10	Submitted to ITESM: Instituto Tecnológico y de Estudios Superiores de Monterrey	<1%
	Trabajo del estudiante	



## ESCUELA UNIVERSITARIA DE POSGRADO

# **MODELO DE INTELIGENCIA ARTIFICIAL CON FINES DE PREDICCIÓN DEL CBR EN OBRAS VIALES EN LA REGIÓN HUÁNUCO, 2024**

Línea de Investigación:

Desarrollo urbano-rural, catastro, prevención de riesgos,  
hidráulica y geotecnia

Tesis para optar el Grado Académico de  
Doctor en Ingeniería Civil

Autor

Matto Pablo, Edgar Grimaldo

Asesor(a)

Pastrana Diaz, Nérida del Carmen

ORCID: 0000-0001-8357-3012

Jurado

Malpartida Canta, Rommel

Cancho Zuñiga, Gerardo Enrique

García Urrutia Olavarría, Roque Jesús Leonardo

Lima – Perú

2025

### **Dedicatoria**

A Dios, por su infinita bondad y ejemplo en esta vida. A mi familia, razones y motivación de mi vida y para concretar metas. A la Ingeniería Civil en el contexto de la inteligencia artificial.



### **Agradecimiento**

A la Universidad Nacional Federico Villarreal.

A mis catedráticos de la Escuela de Posgrado de la  
Universidad Nacional Federico Villarreal.

A mi asesora Dra. Nérída del Carmen Pastrana Diaz.

A los profesionales que contribuyeron en la  
cristalización de esta investigación.

## ÍNDICE

<b>RESUMEN.....</b>	<b>xvi</b>
<b>ABSTRACT.....</b>	<b>xvii</b>
<b>I. INTRODUCCIÓN.....</b>	<b>1</b>
<b>1.1. Planteamiento del problema .....</b>	<b>2</b>
<b>1.2. Descripción del problema.....</b>	<b>4</b>
<i>1.2.1. A nivel global.....</i>	<i>4</i>
<i>1.2.2. A nivel local .....</i>	<i>4</i>
<b>1.3. Formulación del problema.....</b>	<b>5</b>
<i>1.3.1. Problema general.....</i>	<i>5</i>
<i>1.3.2. Problemas específicos .....</i>	<i>5</i>
<b>1.4. Antecedentes .....</b>	<b>5</b>
<i>1.4.1. A nivel internacional.....</i>	<i>5</i>
<i>1.4.2. A nivel nacional .....</i>	<i>9</i>
<i>1.4.3. A nivel local .....</i>	<i>12</i>
<b>1.5. Justificación de la investigación .....</b>	<b>12</b>
<b>1.6. Limitaciones de la investigación .....</b>	<b>13</b>
<b>1.7. Objetivos .....</b>	<b>13</b>
<i>1.7.1. Objetivo general .....</i>	<i>13</i>
<i>1.7.2. Objetivos específicos .....</i>	<i>13</i>
<b>1.8. Hipótesis.....</b>	<b>13</b>
<i>1.8.1. Hipótesis general.....</i>	<i>13</i>
<i>1.8.2. Hipótesis específicas.....</i>	<i>13</i>
<b>II. MARCO TEÓRICO.....</b>	<b>15</b>
<b>2.1. Marco conceptual .....</b>	<b>15</b>

2.1.1. Machine Learning.....	15
2.1.2. Inteligencia artificial .....	15
2.1.3. Deep Learning .....	16
2.1.4. Big Data.....	16
2.1.5. Algoritmo .....	17
2.1.6. Redes Neuronales .....	17
2.1.7. California Bearing Ratio (CBR).....	18
2.1.8. Conjunto de datos .....	19
2.1.9. Algoritmo de predicción .....	19
2.1.10. Capacidad de soporte.....	19
2.1.11. Rendimiento del modelo .....	19
2.1.12. Coeficiente de correlación.....	19
2.1.13. Datos de entrenamiento.....	20
2.1.14. Datos de validación .....	20
2.1.15. Datos de prueba.....	20
2.1.16. Número de entradas.....	20
2.1.17. Número de salidas .....	20
2.1.18. Estructura de las redes neuronales artificiales (RNA).....	21
2.1.19. Las redes neuronales recurrentes (RNN):.....	21
2.1.20. Las Máquinas de Soporte Vectorial (SVMs) .....	23
2.1.21. Random Forest Algorithm in Machine Learning (RF).....	23
2.1.22. Características de la redes neuronales y algoritmos .....	24
<b>III. MÉTODO.....</b>	<b>25</b>
<b>3.1. Tipo de investigación .....</b>	<b>25</b>
3.1.1. Nivel de Investigación .....	25

<b>3.2. Población y muestra</b>	25
3.2.1. Población	25
3.2.2. Muestra	26
<b>3.3. Operacionalización de variables</b>	27
<b>3.4. Instrumentos</b>	29
<b>3.5. Procedimientos</b>	29
<b>3.6. Análisis de datos</b>	30
<b>3.7. Consideraciones éticas</b>	31
<b>IV. RESULTADOS</b>	32
<b>4.1. Entendimiento del problema</b>	32
4.1.1. Recopilar datos históricos de ensayos de laboratorio y mediciones de campo	32
4.1.2. Identificar variables predictoras	33
4.1.3. Entrenar un modelo de red neuronal	33
4.1.4. En la presente investigación	34
<b>4.2. Recopilación y procesamiento de datos</b>	36
<b>4.3. Preprocesamiento</b>	40
4.3.1. Limpieza de datos	40
4.3.2. Normalización/Estandarización:	44
4.3.3. División de datos:	44
<b>4.4. Entrenamiento del modelo</b>	45
4.4.1. Respecto al objetivo específico 1:	45
4.4.2. Respecto al objetivo específico 2:	49
4.4.3. Respecto al objetivo específico 3:	51
<b>4.4. Procesamiento de datos</b>	52
4.4.1. Red Neuronal ANN	52

<b>4.5. Presentación de resultados .....</b>	<b>56</b>
4.5.1. <i>Red Neuronal artificial ANN .....</i>	<i>56</i>
4.5.2. <i>Red Neuronal Recurente LSTM (RNN-LSTM).....</i>	<i>57</i>
4.5.3. <i>Red Neuronal Recurrente GRU (RNN-GRU) .....</i>	<i>58</i>
4.5.4. <i>Ramdom Forest (RF) .....</i>	<i>60</i>
4.5.5. <i>Máquina de Soporte Vectorial (MSV).....</i>	<i>61</i>
<b>V. DISCUSIÓN DE RESULTADOS .....</b>	<b>63</b>
<b>5.1. Análisis descriptivo .....</b>	<b>63</b>
5.1.1. <i>Análisis de la base de datos inicial.....</i>	<i>63</i>
<b>5.2. Evaluación de modelos analizados.....</b>	<b>82</b>
5.2.1. <i>Métricas de evaluación Modelo de Red Neuronal Artificial (ANN): .....</i>	<i>82</i>
5.2.2. <i>Métricas de evaluación Modelo de RNN-LSTM: .....</i>	<i>86</i>
5.2.3. <i>Métricas de evaluación Modelo de RNN-GRU: .....</i>	<i>91</i>
5.2.4. <i>Métricas de evaluación del algoritmo de Ramdom Forest (RF):.....</i>	<i>95</i>
5.2.5. <i>Métricas de evaluación del algoritmo SVM: .....</i>	<i>99</i>
<b>5.3. Análisis estadístico inferencial de los modelos de predicción.....</b>	<b>103</b>
5.3.1. <i>Análisis de sensibilidad .....</i>	<i>103</i>
5.3.2. <i>Comportamiento de los modelos e intervalos de confianza .....</i>	<i>111</i>
<b>5.3. Evaluación del Sistema de recolección de datos nuevos y la predicción del CBR</b>	
.....	123
<b>5.4. Contrastación de Hipótesis.....</b>	<b>125</b>
5.4.1. <i>Contrastación de Hipótesis de los resultados de predicción del CBR: .....</i>	<i>125</i>
5.4.2. <i>Contrastación de Hipótesis de las Hipótesis de Investigación:.....</i>	<i>130</i>
<b>5.5. Evaluación del análisis realizado con el ArcGis de la data real.....</b>	<b>132</b>
5.5.1. <i>Respecto a los valores CBR:.....</i>	<i>132</i>

5.5.2.	<i>Respecto a los valores del Limite Liquido:</i>	133
5.5.3.	<i>Respecto a los valores Limite Plástico:</i>	134
5.5.4.	<i>Respecto a los valores del Índice Plastico:</i>	135
5.5.5.	<i>Respecto a los valores de la densidad máxima seca:</i>	136
5.5.6.	<i>Respecto a los valores del contenido óptimo de humead:</i>	137
5.5.7.	<i>Respecto a los valores de la Litoestratigrafía:</i>	139
<b>VI.</b>	<b>CONCLUSIONES</b>	141
<b>VII.</b>	<b>RECOMENDACIONES</b>	145
<b>VIII.</b>	<b>REFERENCIAS</b>	147
<b>IX.</b>	<b>ANEXOS</b>	152
	<b>Anexo A. Matriz de Consistencia</b>	152
	<b>Anexo B.</b> Base de datos de propiedades físicas, mecánicas y geológicas – proyectos reales	153
	<b>Anexo C.</b> Códigos en Python de redes neuronales, algoritmos de predicción y recopilación de datos.	179
	<i>Anexo C1. Código de Red Neuronal Artificial (ANN)</i>	179
	<i>Anexo C2. Código de Red Neuronal Recurrente LSTM (RNN-LSTM)</i>	183
	<i>Anexo C3. Código de Red Neuronal Recurrente GRU (RNN-GRU)</i>	187
	<i>Anexo C4. Código del Algoritmo de Random Forest (RF)</i>	191
	<i>Anexo C5. Código de Algoritmo de Maquina de Soporte Vectorial (SVM)</i>	195
	<i>Anexo C6. Código de Interfase WEB de almacenamiento y predicción de CBR</i>	198
	<b>Anexo D.</b> Mapas Temáticos de propiedades físicas, mecánicas y geológicas en función de la data real inicial – Proyectos estudiados.	201
	<i>Anexo D1. Distribución de Granulometría de la región Huánuco</i>	201
	<i>Anexo D2. Distribución de Limite Liquido de la región Huánuco</i>	202

<i>Anexo D3. Distribución de Limite Plástico de la región Huánuco .....</i>	<i>203</i>
<i>Anexo D4. Distribución de Índice Plástico de la región Huánuco.....</i>	<i>204</i>
<i>Anexo D5. Distribución de la Máxima Densidad Seca de la región Huánuco.....</i>	<i>205</i>
<i>Anexo D6. Distribución del Contenido Optimo de Humedad de la región Huánuco....</i>	<i>206</i>
<i>Anexo D7. Mapa de distribución de la Litoestratigrafía de la región Huánuco .....</i>	<i>207</i>

## ÍNDICE DE TABLAS

<b>Tabla 1</b>	Diferencias, ventajas y desventajas en el contexto de predicción del CBR.....	24
<b>Tabla 2</b>	Matriz de operacionalización de variables.....	28
<b>Tabla 3</b>	Datos recopilados a nivel de la región Huánuco de propiedades físicas. ....	36
<b>Tabla 4</b>	Datos recopilados a nivel de la región Huánuco de propiedades mecánicas. ....	37
<b>Tabla 5</b>	Datos de unidades litoestratigráficas del suelo a nivel de subrasante en carreteras ..	39
<b>Tabla 6</b>	Extracto de los datos obtenidos luego de la limpieza de datos .....	42
<b>Tabla 7</b>	Métricas del modelo red neuronal artificial ANN para datos normalizados .....	56
<b>Tabla 8</b>	Métricas del modelo red neuronal artificial ANN para datos aleatorizados .....	56
<b>Tabla 9</b>	Métricas del modelo red neuronal artificial ANN para datos sintetizados .....	57
<b>Tabla 10</b>	Parámetros óptimos resultado del Modelo ANN de predicción. ....	57
<b>Tabla 11</b>	Métricas del modelo red neuronal recurrente RNN-LSTM para datos normalizados .....	57
<b>Tabla 12</b>	Métricas del modelo red neuronal recurrente RNN-LSTM para datos aleatorizados .....	58
<b>Tabla 13</b>	Métricas del modelo red neuronal recurrente RNN-LSTM para datos sintetizados	58
<b>Tabla 14</b>	Parámetros óptimos resultado del Modelo RNN-LSTM de predicción.....	58
<b>Tabla 15</b>	Métricas del modelo red neuronal recurrente RNN-GRU para datos normalizados	59
<b>Tabla 16</b>	Métricas del modelo red neuronal recurrente RNN-GRU para datos aleatorizados	59
<b>Tabla 17</b>	Métricas del modelo red neuronal recurrente RNN-GRU para datos sintetizados ..	59
<b>Tabla 18</b>	Parámetros óptimos resultado del Modelo RNN-GRU de predicción.....	59
<b>Tabla 19</b>	Métricas del modelo algorítmico Random Forest (RF) para datos normalizados ..	60
<b>Tabla 20</b>	Métricas del modelo algorítmico Random Forest (RF) para datos aleatorizados...	60
<b>Tabla 21</b>	Métricas del modelo algorítmico Random Forest (RF) para datos sintetizados.....	60
<b>Tabla 22</b>	Parámetros óptimos resultado del Modelo de Random Forest (RF).....	61



<b>Tabla 23</b>	Métricas del modelo algorítmico SVM para datos normalizados.....	61
<b>Tabla 24</b>	Métricas del modelo algorítmico SVM para datos aleatorizados .....	61
<b>Tabla 25</b>	Métricas del modelo algorítmico SVM para datos sintetizados .....	62
<b>Tabla 26</b>	Parámetros óptimos del algoritmo SVM de predicción. ....	62
<b>Tabla 27</b>	Datos reales para alimentar interfaz y predecir CBR.....	123
<b>Tabla 28</b>	Métricas obtenidas por cada modelo de red neuronal y algoritmos de predicción	125
<b>Tabla 29</b>	Valores de Estadísticos y el valor de "p", comparando pares de modelos .....	127
<b>Tabla 30</b>	Intervalos de confianza por modelo .....	128

## ÍNDICE DE FIGURAS

<b>Figura 1</b> Esquema característico de una red neuronal artificial.....	21
<b>Figura 2</b> Esquema del funcionamiento de la neurona en el tiempo .....	22
<b>Figura 3</b> Esquema del funcionamiento por capas de neuronas recurrentes .....	22
<b>Figura 4</b> Idea de la utilización de un kernel para transformación del espacio de los datos ....	23
<b>Figura 5</b> Esquema de funcionamiento del algoritmo del Ramdom Forest .....	24
<b>Figura 6</b> Delimitación de la población de estudio .....	26
<b>Figura 7</b> Delimitación de la muestra de estudio .....	26
<b>Figura 8</b> Diagrama de flujo de la investigación.....	30
<b>Figura 9</b> Ubicación geográfica de la región Huánuco - Perú.....	32
<b>Figura 10</b> Fases de la determinación del modelo de predicción del valor de CBR .....	35
<b>Figura 11</b> Datos de propiedades físicas del suelo a nivel de subrasante en carreteras .....	36
<b>Figura 12</b> Datos de propiedades mecánicas del suelo a nivel de subrasante en carreteras.....	37
<b>Figura 13</b> Propiedades litoestratigráficas del suelo a nivel de subrasante en carreteras.....	39
<b>Figura 14</b> Extracto del algoritmo PYTHON utilizado para hacer la limpieza de los outliers	41
<b>Figura 15</b> Algoritmo que posibilita aleatorizar la división de los datos .....	45
<b>Figura 16</b> Diagrama de flujo de entrenamiento de una Red Neuronal Recurrente LSTM .....	46
<b>Figura 17</b> Diagrama de flujo de entrenamiento de una Red Neuronal Recurrente GRU .....	47
<b>Figura 18</b> Esquema del proceso de entrenamiento de una Red Neuronal Artificial.....	48
<b>Figura 19</b> Diagrama de flujo de entrenamiento de una Máquina de Soporte Vectorial (SVM) .....	48
<b>Figura 20</b> Diagrama de flujo de entrenamiento de una Ramdom Forest (RF) .....	49
<b>Figura 21</b> Diagrama de barras de valores CBR en el universo de proyectos.....	63
<b>Figura 22</b> Correlación con respecto al rango de contenido de humedad .....	65
<b>Figura 23</b> Influencia granulométrica en los valores de CBR.....	66

<b>Figura 24</b> Valores atípicos en la muestra respecto al CBR.....	68
<b>Figura 25</b> Variabilidad del valor del CBR con respecto a la litoestratigrafía.....	69
<b>Figura 26</b> Valores del CBR por zonas de ubicación geográficas .....	70
<b>Figura 27</b> Características de la densidad seca máxima en el universo de proyectos analizados .....	71
<b>Figura 28</b> Variabilidad de la Máxima densidad seca con respecto a su ubicación geográfica.....	72
<b>Figura 29</b> Correlación entre los límites de consistencia y el valor de CBR .....	73
<b>Figura 30</b> Relación de la proporción de grava con el CBR. ....	74
<b>Figura 31</b> Correlación de los límites de Atterberg con respecto a la presencia de la arena.....	75
<b>Figura 32</b> Relación entre los porcentajes de Limo y Arcilla y las propiedades mecánicas del suelo .....	76
<b>Figura 33</b> Variabilidad de la densidad con respecto a su ubicación geográfica .....	77
<b>Figura 34</b> Correlación entre las propiedades mecánicas-Proctor Modificado y el valor de CBR.....	78
<b>Figura 35</b> Visualización de correlaciones entre las propiedades del suelo y el CBR.....	79
<b>Figura 36</b> Relación Litoestratigráfica y las propiedades del suelo .....	81
<b>Figura 37</b> Pérdida durante el entrenamiento - Error Cuadrático Medio (MSE) .....	82
<b>Figura 38</b> Error Absoluto Medio durante el entrenamiento.....	83
<b>Figura 39</b> Evolución del RMSE en el Entrenamiento del Modelo de Red Neuronal. ....	84
<b>Figura 40</b> Evolución del $R^2$ en el Entrenamiento del Modelo de Red Neuronal. ....	85
<b>Figura 41</b> Pérdida (MSE) durante el entrenamiento de la RNN-LSTM .....	86
<b>Figura 42</b> Error absoluto medio (MAE) durante el entrenamiento de la RNN_LSTM.....	87
<b>Figura 43</b> Comportamiento del RMSE durante el entrenamiento de la red RNN-LSTM .....	89
<b>Figura 44</b> Comportamiento del coeficiente de determinación durante el entrenamiento .....	90
<b>Figura 45</b> Pérdida (MSE - Error Cuadrático Medio) durante el entrenamiento .....	91

<b>Figura 46</b> Comportamiento del MAE durante el entrenamiento .....	92
<b>Figura 47</b> Comportamiento del RMSE durante el entrenamiento .....	93
<b>Figura 48</b> Evolución del $R^2$ en la Predicción del CBR utilizando una Red Neuronal GRU ..	94
<b>Figura 49</b> Gráfico Q-Q (Quantile-Quantile) para evaluar la normalidad de residuos .....	95
<b>Figura 50</b> Curva de Aprendizaje para la predicción del CBR usando Random Forest (RF) ..	96
<b>Figura 51</b> Gráfico de Error Absoluto por Muestra en el Modelo Random Forest (RF) .....	97
<b>Figura 52</b> Pérdida (Loss) y Métricas por Número de Árboles en el Modelo (RF) .....	99
<b>Figura 53</b> Gráfico Q-Q de Residuos en el Marco de la Predicción del CBR (Modelo SVM) .....	100
<b>Figura 54</b> Gráfico de Error Absoluto por Muestra en el Marco de la Predicción del CBR (Modelo SVM).....	101
<b>Figura 55</b> Gráfico de Curva de Aprendizaje (Modelo SVM) .....	102
<b>Figura 56</b> Análisis de la Matriz de Correlación para la Predicción del CBR .....	103
<b>Figura 57</b> Análisis de la Matriz de Correlación y su impacto en la predicción del CBR usando LSTM.....	105
<b>Figura 58</b> Matriz de Correlación de Variables de Predicción del CBR con Red Neuronal GRU .....	107
<b>Figura 59</b> Matriz de Correlación para la Predicción del CBR con Random Forest (RF) .....	109
<b>Figura 60</b> Matriz de Correlación en el Marco de la Predicción del CBR (Modelo SVM) ...	110
<b>Figura 61</b> Relación entre valores reales del CBR y valores predichos por la red neuronal artificial .....	111
<b>Figura 62</b> Comparación del CBR Real vs. Predicho (LSTM) .....	112
<b>Figura 63</b> Dispersión: CBR Real vs. Predicho (LSTM) .....	114
<b>Figura 64</b> Comparación del CBR Real vs. CBR Predicho .....	115
<b>Figura 65</b> Relación entre los valores reales del CBR y los valores predichos.....	116

<b>Figura 66</b> Relación entre el CBR Real y el CBR Predicho .....	117
<b>Figura 67</b> Gráfico de residuos para evaluar la calidad del modelo Random Forest (RF).....	119
<b>Figura 68</b> Gráfico de Predicción del CBR utilizando el algoritmo SVM optimizado .....	120
<b>Figura 69</b> Gráfico de Dispersión: CBR Real vs CBR Predicho (Modelo SVM).....	121
<b>Figura 70</b> Gráfico de Residuos en el Marco de la Predicción del CBR (Modelo SVM).....	122
<b>Figura 71</b> Interfaz de recolección de datos y predicción de CBR .....	124
<b>Figura 72</b> Interfaz creada para recolectar datos nuevos de parámetros predictores .....	124
<b>Figura 73</b> Distribución métrica en los modelos (Prueba de Friedman) .....	126
<b>Figura 74</b> Comparación de modelos de mejor desempeño ANN y SVM con otros modelos .....	128
<b>Figura 75</b> Intervalos de confianza (IC 95%) por cada modelo .....	129
<b>Figura 76</b> Mapa de distribución del CBR real a nivel de la región Huánuco, en base a la data obtenida.....	132
<b>Figura 77</b> Distribución geoespacial del Límite Líquido (LL) en la región Huánuco, de acuerdo a la data en análisis.....	133
<b>Figura 78</b> Mapa de distribución del Límite Plástico (LP) en la Región Huánuco, en función a la data analizada.....	134
<b>Figura 79</b> Mapa de distribución espacial del Índice Plástico (IP) en la Región Huánuco....	135
<b>Figura 80</b> Mapa de distribución de Densidad Seca Máxima en la Región Huánuco - data en análisis.....	136
<b>Figura 81</b> Mapa de distribución del Contenido Óptimo de Humedad en la Región Huánuco, en base a la data en análisis.....	138
<b>Figura 82</b> Distribución Litoestratigráfica de los proyectos reales a nivel de la región Huánuco .....	139

## RESUMEN

**Objetivo:** Determinar qué modelo de inteligencia artificial permite la predicción del CBR en obras viales en la región Huánuco, 2024. **Método:** La investigación es aplicada, cuantitativo, explicativo y experimental. La población, suelos a nivel de subrasante de obras viales de la macro región centro. La muestra, datos recolectados de mecánica de suelos y geotecnia de la región Huánuco; muestreo no probabilístico, por conveniencia; recopilándose total 2270 puntos de caracterización de suelos, 1365 puntos datos completos, incluyen CBR. Se analizó mediante Python, redes neuronales artificiales, recurrentes LSTM, recurrentes GRU, algoritmos de Random Forest y Support vector machine; datos limpios se estandarizaron, dividiéndolos en 80% entrenamiento, 10% validación y 10% prueba; se aleatorizó datos(3372), se sintetizó datos(3372), data ampliada para mayor precisión en la predicción. Se desarrolló una interfaz, recopila datos variables y a la vez predice CBRs. Mediante el ArcGIS se generó mapas geospaciales de distribución. **Resultados:** Se determinó que la Red Neuronal Artificial tiene mayor grado de precisión en predicción, con  $R^2$  de 0.9848, MAE de 0.8195, MSE de 1.9198 y RMSE de 1.3856. Se estableció una interfaz de buen desempeño, recopila datos y predice CBRs. Se generó información con ArcGIS, evidenciando que la máxima densidad seca, Humedad Óptima y el porcentaje de arena, son variables influyentes en la predicción del CBR. **Conclusión:** La principal conclusión es que el modelo de Redes Neuronales Artificiales logra predecir el CBR con alta precisión a partir de variables físicas y mecánicas de los suelos de subrasantes en obras viales.

*Palabras claves:* redes neuronales, California Bearing Ratio, Random Forest, máquina de soporte vectorial, propiedades físicas, propiedades mecánicas, litoestratigrafía.

## ABSTRACT

**Objective:** To determine which artificial intelligence model enables the prediction of CBR in road works within the Huánuco region, 2024. **Method:** The research is applied, quantitative, explanatory, and experimental. The population consists of subgrade level soils from road works in the central macro-region. The sample comprises data collected from soil mechanics and geotechnical studies in the Huánuco region; non-probabilistic sampling, by convenience; a total of 2270 soil characterization points were collected, with 1365 points being complete and including CBR data. Analysis was conducted using Python, artificial neural networks, recurrent LSTM, recurrent GRU, Random Forest and Support Vector Machine algorithms; clean data were standardized, divided into 80% training, 10% validation, and 10% testing; data were randomized (3372), data was synthesized (3372), data expanded for greater prediction accuracy. An interface was developed to collect variable data and predict CBRs simultaneously. Geospatial distribution maps were generated using ArcGIS. **Results:** It was determined that the Artificial Neural Network model exhibits the highest degree of prediction accuracy, with an  $R^2$  of 0.9848, MAE of 0.8195, MSE of 1.9198, and RMSE of 1.3856. A high-performance interface was established, collecting data and predicting CBRs. Information was generated with ArcGIS, demonstrating that maximum dry density, optimal moisture content, and sand percentage are influential variables in CBR prediction. **Conclusion:** The main conclusion is that the Artificial Neural Network model successfully predicts CBR with high accuracy based on physical and mechanical variables of subgrade soils in road works.

*Keywords:* neural networks, California Bearing Ratio, Random Forest, support vector machine, physical properties, mechanical properties, lithostratigraphy

## I. INTRODUCCIÓN

La mecánica de suelos permite determinar las características físicas mecánica de los mismos, cuyos resultados relacionados con la carga actuante ya sea estática o dinámica, abarca el campo de la ingeniería geotécnica, resaltándose fundamentalmente su caracterización natural anisotrópicas y heterogéneas, los mismos que son consecuencia de los procesos físicos a los que han sido sometidos a través del tiempo desde su formación.

Una de las preocupaciones incidentes es realizar modelaciones precisas que permitan establecer patrones de comportamiento estructural de los suelos, que desde el enfoque de la ingeniería geotécnica es complejo, más aún si solo se considera basarse en el empleo de la física, lo cual trae como consecuencia limitaciones para desarrollar soluciones numéricas y analíticas a determinados problemas recurrentes en el comportamiento de rocas y los suelos.

Convencionalmente si el objetivo es determinar el comportamiento de los materiales, esta se obtiene dentro del marco de dos métodos; el primero a través de ensayos de campo y laboratorio, los mismos que por lo general son genéricos, descriptivos, relativamente costosos y que demanda bastante tiempo en su procesamiento y el otro método es a través de correlaciones matemáticas y métodos numéricos, los mismos que se caracterizan por estar fundamentados en la teorías de la elasticidad y plasticidad, donde muchas veces no se logra el objetivo de simular en forma adecuada la respuesta mecánica de los suelos y rocas, debido a razones de formulaciones e idealizaciones complejas, y la consideraciones de muchos parámetros que tienen la características de ser empíricas.

La inteligencia artificial permite métodos de modelado, que resultan de interés del campo investigativo dentro de la ingeniería geotécnica, que genera alternativas de proyección al futuro; generando posibilidades de modelado complejo que permitan acciones de predicción con mayor grado de certeza que los métodos tradicionalmente aplicados.

Los métodos de inteligencia artificial ofrecen ventajas en cuanto a su empleo, los



mismos que son: (i) Son adaptables para establecer modelos de proceso no lineales y complejos, y desarrollar modelos sin hipótesis inicial de la relación entre las variables de entrada y salida; (ii) permiten la detección e identificación en diversos contextos, hacer monitoreos, selecciones y predicciones, (iii) evidencian precisión en cuanto a predicciones, pese a que se desconozca las relaciones físicas de los parámetros y, (iv) muestran idoneidad para realizar análisis de datos grandes a partir del cual se generen patrones (incluso desconociendo las reglas) (Baghbani et al., 2022).

En este contexto, el CBR es un parámetro geotécnico, muy necesario y de amplio empleo en los cálculos estructurales de la cimentación para obras viales; que tiene la imperiosa necesidad de plantear alternativas tecnológicas que permitan predecirlos, y determinar su valor de diseño que permita generar cálculos más certeros y evitar problemas como consecuencia de una incorrecta determinación de esta.

Por todo lo descrito, la inteligencia artificial se convierte en una alternativa tecnológica que permite encontrar soluciones de gran complejidad, como la determinación del parámetro geotécnico conocido como CBR; la misma que sería un paso importante para poder ampliar a otros parámetros geotécnicos necesarios en todo proyecto o estudio, que redundaría en beneficio para el estado y la sociedad.

### **1.1. Planteamiento del problema**

El CBR se constituye en el ensayo que permite hacer evaluaciones del suelo en cuanto a su calidad, tomando como referencia su resistencia, donde el ensayo a escala de placa es el CBR, referido a la relación de soporte California (California Bearing Ratio), valor de suma importancia, puesto que depende ello el diseño estructural de cualquier obra civil.

La inteligencia artificial a través del Machine Learning permite desarrollar algoritmos de predicción en base a patrones de comportamiento, de datos existentes, que mediante un entrenamiento adecuado del modelo determina valores predictivos del comportamiento

geotécnico de los suelos; en la actualidad es una rama de la ciencia que está en desarrollo sobre todo en el campo geotécnico, no emplea dada la naturaleza de los datos y la insuficiencia de datos compatibilizados; siendo este uno de ellos objetivos de la presente investigación.

Uno de los grandes problemas en obras viales, es la existencia de la heterogeneidad y anisotropía de los suelos, que constituyen la cimentación, lo cual conlleva en principio a asumir valores generales, en base a las prospecciones y caracterización física mecánica de los suelos de muestras específicas, a lo largo de todo el eje de la vía materia de proyecto, pero que en la realidad no es tan real, surgiendo de esta forma vicios ocultos al momento de la ejecución de la obras, errores en el diseño estructural de la vía, problemas relacionados con un inadecuado estudio de suelos, consecuentemente problemas con los estudios geotécnicos; Todo ello evidencia en la actualidad consecuencias negativas, como expedientes técnicos deficientes, obras paralizadas, procesos administrativos y judiciales; que se traducen en perjuicios económicos para el estado y la población.

Esta realidad actual, es permisible mejorarla, en la medida, que en base a datos de estudios realizados y prospecciones complementarias, generar patrones de comportamiento de suelos, que incidan en la posibilidad de correlacionarlos y establecer algoritmos, que en función a las mismas permitan predecir valores de comportamiento estructural de suelos, como en este caso del CBR; lo cual posibilita tener una visión más específica y detallada del suelo o roca de la zona en análisis, consecuentemente mayores datos para el diseño estructural, siendo una real ventaja, respecto a lo tradicional.

En síntesis el problema se evidencia en la no existencia de suficientes valores de CBR que caracterice a los suelos de los tramos de carretera en estudio, dado la heterogeneidad de las propiedades físicas y mecánicas de los suelos, que hace que se tengan problemas en el diseño de la cimentaciones de obras viales, deficientes expedientes técnicos, vicios ocultos al momento de la construcción, adicionales de obra, paralizaciones de obra, pérdidas económicas

para el estado; siendo imprescindible tener mayor información en de patrones geológicos y geotécnicos, a partir del cual generar mayor cantidad de datos que permitan inferir propiedades relacionadas a la capacidad de soporte de los suelos (CBR).

## **1.2. Descripción del problema**

### ***1.2.1. A nivel global***

Es de suma importancia entender el comportamiento del suelo en el proceso de ejecución de cualquier tipo de obra, con mucha mayor razón de obras viales; dada su naturaleza compleja y heterogénea del suelo, impulsando a plantear interrogantes relacionados a ¿Cómo la Geotecnia actual establecería una relación certera y la comprensión de la dinámica del suelo con la obra a proyectarse? ¿es posible establecer valores confiables de CBR que se infiera a lo largo de todo el eje vial en estudio? ¿se hace necesario romper paradigmas mediante el empleo de otras disciplinas del conocimiento que permitan generar modelos que si bien es cierto serían complejos, pero den resultados confiables en el aspecto de precisión?, donde esta investigación establece como objetivo, revisar el estado del arte actual sobre la determinación de parámetros de diseño en Mecánica de Suelos como es el CBR y plantear posibles escenarios futuros que tiendan a mejorar las condiciones actuales, enfocándolo a partir de un diseño metodológico cualitativo y cuantitativo.

### ***1.2.2. A nivel local***

La región Huánuco en los últimos años ha evidenciado una serie de problemas de carácter técnico relacionado a las obras viales, paralizaciones de obras, suspensiones de plazo, adicionales de obra, fallas prematuras en obra; todas ellas originadas por estudios básicos mal ejecutados, trayendo como consecuencias perjuicios económicos al estado, serias disconformidades de la población, referidas al mal empleo del dinero del estado y malestar por las obras paralizadas; siendo una de las causas los estudios geotécnicos, donde uno de los parámetros es el valor del CBR, que dependiendo el tipo de carretera se realiza cada cierta

distancia, en general cada 500 m o cada kilómetro; lo cual funcionaría si la naturaleza del suelo fuera homogénea e isotrópica, lo cual dista de la realidad, dado que la naturaleza del suelo es todo lo contrario; lo cual genera la necesidad de buscar alternativas que permitan obtener estos valores con mayor certeza, siendo una alternativa de innovación el empleo de la inteligencia artificial, que permita generar modelos de Machine Learning, a través del cual predecir valores de CBR confiables que sean empleados en los diseños de la cimentación en carreteras.

### **1.3. Formulación del problema**

#### ***1.3.1. Problema general***

¿Qué modelo de Inteligencia artificial se debe desarrollar para permitir la predicción del CBR en obras viales en la región Huánuco, 2024?

#### ***1.3.2. Problemas específicos***

¿De qué forma un adecuado análisis de datos mediante el Machine Learning influye en el desarrollo de un modelo de predicción del CBR en obras viales en la región Huánuco?

¿El desarrollo de un sistema de recolección de datos incide en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco?

¿El correcto análisis del grado de precisión en proyecto reales permite validar el modelo de predicción del CBR en obras viales en la región Huánuco?

### **1.4. Antecedentes**

#### ***1.4.1. A nivel internacional***

Dávila y Cano (2023), en su trabajo de grado “*Revisión conceptual de las aplicaciones de la inteligencia artificial en el campo de la ingeniería geotécnica y su aproximación a casos de estudio de la región caribe colombiana*”, precisa que los modelos desarrollados empleando la inteligencia artificial, específicamente en el marco del Machine Learning, evidencia ventajas tales como: (i) desarrollan procesos complejos y con características no lineales sin condiciones iniciales de relaciones de los datos de input y output, (ii) evidencian capacidad de identificar

características de la data en diferentes contextos y a su vez seleccionar, monitorear y realizar predicciones, pese a que los parámetros y su relaciones sean desconocidas, y (iii) permiten analizar datas voluminosas de información, a partir del cual generan patrones con reglas características y generación de data nueva. Es preciso tener en cuenta que la inteligencia artificial muestra variada limitaciones que son necesarias analizar, tales como: a) los modelos generados son poco transparentes, en la medida que no establecen relaciones claras entre la entradas y salidas, asimismo el conocimiento inferido no se logra almacenar en una forma que sea muy interpretable, b) se evidencia que solo es posible la extrapolación dentro de los límites calibrados, en cuanto a los modelos, c) es complejo medir el valor de la incertidumbre de los modelos, lo que dificulta la evaluación en cuanto a la calidad de la predicción del modelo, y d) muestran dependencia de que haya previo conocimiento del hombre, de procesos físicos que se pretende predecir. Ante todo, ello, los métodos sobre inteligencia artificial, evidencia viabilidad en cuanto a su implementación, en múltiples campos de la ingeniería civil.

Ospina y Arístizabal (2021), en su investigación *“Aplicación de inteligencia artificial y técnicas de aprendizaje automático para la evaluación de la susceptibilidad por movimientos en masa”*, detalla acerca del desempeño del universo de algoritmos que aprenden automáticamente, que los no paramétricos brindan resultados mejores, en la medida que evidencian capacidad de adaptación o aprendizaje de la data. Requiriendo una base de datos grande. Asimismo, precisa que, del universo de modelos, los algoritmos ensamblados evidencian mejores resultados en cuanto a desempeño y capacidad de predecir. Bajo este marco, resulta relevante resaltar que modelos paramétricos lineales (LDA y RL), modelos ampliamente utilizados para evaluar la susceptibilidad en movimientos de masa, dan resultados muy limitados. Posiblemente debido a restricciones de linealidad de los modelos, lo que hace inferir que no se cumple para modelación de fenómenos muy complejos.

Peña y Asanza (2021) en su investigación *“Técnicas de aprendizaje automático para*

***caracterización y perfilado del terreno. aplicación práctica al CPTU***”, determina que se ha comprobado que el algoritmo de máquinas de vector soporte, proporciona modelos útiles y que se implementan de forma rápida y automatizada. Igualmente, el algoritmo de k-vecinos más próximos proporciona resultados similares, que se utilizan de forma similar con un coste computacional menor. Todos los algoritmos de agrupamiento (no supervisados) utilizados en este contexto aportan resultados similares e igualmente prácticos. Para la elaboración de los modelos se requiere realizar una validación cruzada extrayendo registros completos de uno o varios puntos de investigación en lugar de registros aleatorios. Operando así, es posible estudiar el punto de inflexión que define el modelo y que, a juicio de los autores, resulta un indicador razonable para desarrollar un modelo geológico práctico. De caso elaborar modelos predictivos más precisos, la validación cruzada aleatoria tiende a dar resultados significativamente mejores.

Valderrama et al. (2021), en su investigación ***“Desarrollo de un modelo predictivo de las propiedades mecánicas del suelo usando redes neuronales artificiales”***, establece que la forma como está compuesto el suelo incide en su comportamiento, infiriendo que pretender estimar sus propiedades se vuelva complejo. Asimismo, precisa que las propiedades del suelo serían predichas en tiempos cortos, como la creación de modelos de redes neuronales artificiales. Esta investigación muestra resultados compatibles con antecedentes, que evidencian que modelos de RNA, brindan buenas predicciones de CBR así como también de parámetros resultados de compactación. La investigación confirma que se logra predecir el CBR a partir de las propiedades físicas del suelo y de valores de compactación; es decir a partir del contenido de humedad óptimo, porcentajes de arena, de grava, de finos, valores del límite plástico, índice plástico, límite líquido, se logra predecir valores de CBR, empleando modelos de RNA. Detalla que, incrementando las neuronas en número en las capas ocultas de la RNA, mejora el grado de precisión de la predicción; aspecto que se debe tener cuidado pues el

aumento en exceso causaría efectos contrarios, disminuyendo la precisión del modelo. Precisa además el autor que en esta investigación empleo la fórmula de ‘Stathakis’ que permite establecer el número máximo de neuronas en cada capa oculta, siendo esto el límite.

Lara et al. (2018), en su artículo científico ***“Modelo computacional para la estimación de la densidad del suelo a través del sensoramiento continuo”*** establece que el método de K vecinos, quienes desarrollaron un modelo de predicción, demuestra su validez para inferir la densidad del suelo, en los márgenes definidos por las variables independientes; describe como la validación muestra resultados que validan el modelo, mostrando lo idóneo para estimar la densidad del suelo, mediante el sensoramiento continuo, evidenciando un valor alto de coeficiente correlacional ( $r = 0,957$ ) para los resultados predichos y mostrando un error medio absoluto igual a 2,7%; evidenciando mayor peso en las variables del modelo estudiado a: el contenido de humedad, precedido por la velocidad, el ancho de la herramienta, la fuerza de tiro y la profundidad.

Khasawneh et al. (2024) en el artículo científico, ***“Prediction of California Bearing Ratio Using Soil Index Properties by Regression and Machine-Learning Techniques”*** recomienda métodos regresión y aprendizaje automático, para el desarrollo de un modelo validado, que sirva para predicción de valores de la relación de carga de California (CBR), de un suelo de subrasante empleando propiedades índices del suelo. Se prepararon alrededor de 60 muestras experimentalmente agregando diferentes porcentajes de arena al suelo natural para proporcionar una amplia gama de propiedades del suelo. Se incluyeron un total de 110 muestras de suelo para generalizar el modelo previsto. Este estudio incluyó tres técnicas de autoaprendizaje (ML): redes neuronales artificiales (ANN), árbol de modelos M5P y el algoritmo perezoso K-nearest neighbor. Además, se utilizaron dos técnicas de modelado convencionales: regresión lineal múltiple (MLR) y regresión no lineal (NLR). En el modelo desarrollado, el CBR determinado en laboratorio representa las variables de respuesta, mientras

que las propiedades de compactación (contenido óptimo de humedad (OMC) y densidad seca máxima (MDD)), límites de Atterberg (límite líquido (LL), límite plástico (PL) e índice de plasticidad (PI)), densidad, parámetro de gradación (porcentaje de materiales retenidos en el tamiz #200 ( R 200 ) y porcentaje de materiales retenidos en el tamiz #10 ( R 10 )) se utilizaron como predictores. Los resultados revelaron que el mejor modelo para predecir el CBR para el suelo utilizando propiedades del material es el modelo ANN con R<sup>2</sup> de 90,46 y RMSE de 7,89, seguido de KNN, MLR, M5P y regresión no lineal en orden descendente.

Gowda et al. (2024), en el artículo de investigación ***“Prediction of the Subgrade Soil California Bearing Ratio Using Machine Learning and Neuro-Fuzzy Inference System Techniques: A Sustainable Approach in Urban Infrastructure Development”*** precisa la aplicación y desarrollo de técnicas de aprendizaje automático (regresión lineal multivariante, MLR, redes neuronales artificiales y el sistema de inferencia neurodifusa adaptativa, ANFIS) para predicción indirecta del CBR en función del tipo de suelo, el índice plástico y la densidad seca máxima (MDD). Analizaron 2191 muestras, para parámetros como el IP, la MDD, la distribución granulométrica y el CBR, aprovechando cálculos teóricos y análisis de big data. El ANFIS demostró un rendimiento superior en predecir el CBR con un valor R<sup>2</sup> de 0.81, por encima del MLR y la ANN. El análisis de sensibilidad reveló que el IP es el parámetro más significativo que afecta al CBR, con una importancia relativa del 46 %. Los hallazgos subrayan el gran potencial del aprendizaje automático y los sistemas de inferencia neurodifusa en la gestión sostenible de los recursos urbanos no renovables y brindan información importante para la planificación urbana, la selección de materiales de construcción y el desarrollo de infraestructura.

#### ***1.4.2. A nivel Nacional***

Callupe (2023), en su tesis ***“Evaluación del CBR y la deflexión del terreno natural usando redes neuronales en el mejoramiento de la carretera Oyón – Ambo, tramo II,***



**provincia Daniel Alcides Carrión – Pasco**”, determinó en cuanto a la predicción del CBR, se determinó que la mezcla de parámetros de entrada, como el porcentaje de finos, gravas, la humedad natural, el índice plástico, el contenido óptimo de humedad y el Proctor, resultó ser la mejor alternativa. La utilización de redes neuronales entrenadas con estos parámetros arrojó un coeficiente determinativo ( $R^2$ ) de 0.835, lo cual evidencia una alta correlación entre las propiedades del terreno y el valor del CBR. Se observó que el parámetro que tuvo más incidencia en predecir el CBR fue la MDS con porcentaje de 77.9%, seguido por el óptimo contenido de humedad con 6.5%. Esto proporciona una comprensión más precisa de la resistencia y propiedades del terreno natural, permitiendo encontrar indirectamente el valor del CBR. • Por otro lado, se encontró que la deflexión no presenta una correlación significativa ( $R^2$  mayor de 0.7) con los parámetros geotécnicos utilizados como entradas en las redes neuronales. Esto se debe a la variabilidad del material en estado natural en el cual se calcula la deflexión y a las propiedades físicas que se obtienen en el laboratorio. En consecuencia, la predicción de la deflexión mediante redes neuronales resulta menos precisa en comparación con la predicción del CBR.

Poma (2023), en su tesis **“Modelos Machine Learning en geomecánica minera para el control eficaz de perforación y voladura en labores de avance - unidad minera San Rafael”**, establece que el empleo de algoritmos de ML, en el campo de estudio es viable, computacionalmente, sin embargo, se hace necesario un mayor trabajo adicional en el cuidado de los datos y en establecer con precisión los procedimientos básicos que establecen el avance real: se evidencia claramente de los experimentos trabajados que la data empleada es insuficientes para caracterizar adecuadamente el fenómeno, significando la necesidad de considerar datos no considerados en la data actual que permitirían mejorar los ajustes obtenidos; y propone agregar otros factores que admitan mejor caracterización de la propagación de fracturas en los macizos rocosos, como la geometría característica en el frente

de las perforaciones, que estando registrados, evidencia problemas con respecto a las cargas explosivas y la secuencialidad de los disparos. El empleo de modelos bagging, permite observar variables muy incidentes del fenómeno, siendo importante medirlos de forma tal que permita afinar técnicas de como registrar la información. Precisa que lo mencionado debe ser valorado como una oportunidad y no como un problema, en la medida que para el análisis del fenómeno, la información determinante no existe, por lo que las investigaciones adicionales y recojo adicional de datos solo mejora el modelamiento respectivo.

Valderrama (2020), en su tesis *“Desarrollo de un modelo de redes neuronales artificiales para predecir las propiedades mecánicas del suelo”*, analizó los óptimos hiperparámetros de cada red neuronal artificial (ANN) a través del Python mediante el Spyder. Siendo relevante de este proceso de establecer los hiperparámetros, determinar la ANN con mejor predisposición de generalizar. El autor precisa que el parámetro MSE permitió evidenciar los hiperparámetros óptimos, en la medida que como modelo disminuyo el error y su desempeño con respecto a otro. Asimismo, la diversidad de técnicas que son aplicables de alguna manera dificulta estructurar el código en Spyder. • Se logro evidenciar que cada red neuronal artificial, aprende en forma correcta comparando valores verdaderos con relación a valores resultados de predicción a través del modelo. Se evidencio la obtención de valores de R altos para la densidad máxima seca, el contenido óptimo de humedad, CBR al (95% MDD) y CBR al (100% MDD), permitiendo evidenciar un alto desempeño de las ANN en predecir características del suelo en base a propiedades sencillas de medición, pese a cantidades bajas de ejemplos, considerando diversos elementos que inciden en el suelo en cuanto a su comportamiento. Precisa, que los modelos estudiados son susceptibles de ser usados en proyectos reales, de caso se necesite determinar propiedades rápidamente.

Boza y Merino (2018), en su tesis *“Parámetros de resistencia al corte de suelos a partir de sus propiedades físicas, utilizando redes neuronales artificiales y equipo Triaxial, UNH”*,

describe que los valores de cohesión determinados con las ANN y a través del Equipo Triaxial, mostraron un alta positiva correlación, con un coeficiente de  $R^2 = 0.982$ ; mediante la estadística inferencial, el valor de significancia que refleja los resultados del modelo de ANN fue 0,01, demostrando ser menor de 0,05 que es el nivel de confianza. Significando una variación adecuada y una correlación respecto a la cohesión determinadas a través de las ANN y el Triaxial. Precisa, asimismo, con respecto al ángulo de fricción interna determinados con las ANN y mediante el Triaxial mostraron una correlación positiva muy alta, donde el valor de  $R^2 = 0.963$ . Asimismo, inferencialmente la significancia que refleja el modelo de ANN fue 0,01, resaltando que con respecto al nivel de confianza de 0,05 es menor. Significando que muestra una correlación y variación adecuada del ángulo de fricción interna determinadas a través de las ANN y el Equipo Triaxial.

#### ***1.4.3. A nivel local***

A nivel local no se ha logrado evidenciar la existencia de estudios o investigaciones referentes al tema.

### **1.5. Justificación de la investigación**

La presente investigación se justifica desde dos enfoques el técnico y el socioeconómico. **Desde el aspecto técnico**, la importancia de generar alternativas de innovación tecnológica, que permitan a través de algoritmos matemáticos desarrollados mediante inteligencia artificial, predecir valores geotécnicos del CBR y calcular la capacidad de soporte de suelos orientados a las cimentaciones en obras viales. **Desde el aspecto socio económico**, la presente investigación, permitirá mejores estudios técnicos de obras viales con alternativas técnicas más reales, que garanticen mayor vida útil, mayor durabilidad, menor costo, lo cual significa mayor optimización económica, menor gasto para la población, en la medida que tendrá mejores obras viales y por mayor tiempo, menos daños a los vehículos y mayor comodidad para los conductores y pasajeros.

## 1.6. Limitaciones de la investigación

En el aspecto de limitaciones, se evidencia lo siguiente:

- a. **Limitaciones de Información:** por la naturaleza de la investigación, demandará una data considerable, que será materia de implementación.
- b. **Limitaciones de espacio:** la investigación está circunscrita a la región de Huánuco, lo cual significa resultados orientados a la misma.

## 1.7. Objetivos

### 1.7.1. Objetivo general

Determinar qué modelo de inteligencia artificial permite la predicción del CBR en obras viales en la región Huánuco, 2024.

### 1.7.2. Objetivos específicos

Analizar datos mediante el Machine Learning que influye en el desarrollo de un modelo de predicción del CBR en obras viales en la región Huánuco.

Diseñar un sistema de recolección de datos que incide en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco.

Analizar el grado precisión en proyectos reales que permita validar el modelo de predicción del CBR en obras viales en la región Huánuco.

## 1.8. Hipótesis

### 1.8.1. Hipótesis General

**Hipótesis Nula ( $H_0$ ):** No existe diferencia significativa entre los modelos de inteligencia artificial para la predicción del CBR en obras viales.

**Hipótesis Alternativa ( $H_a$ ):** Existe una diferencia significativa entre los modelos de inteligencia artificial para la predicción del CBR en obras viales

### 1.8.2. Hipótesis Específicas

El análisis de datos mediante el Machine Learning influirá en el desarrollo de un modelo

de predicción del CBR en obras viales en la región Huánuco.

El diseño de un sistema de recolección de datos incidirá en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco.

El análisis del grado de precisión en proyectos reales permitirá validar el modelo de predicción del CBR en obras viales en la región Huánuco.

## II. MARCO TEÓRICO

### 2.1. Marco conceptual

#### 2.1.1. *Machine Learning*

Es una herramienta para análisis de datos mejorado, proyectándose a una futura predicción, implementado sistemas nuevos o mejorando los ya existentes, a través del empleo de algoritmos desarrollados con antigua información o reciente que posibilita el óptimo desempeño del sistema a emplear. (Hinestroza, 2018)

El Machine Learning se constituye en una rama de la Inteligencia Artificial, que mediante algoritmos, da a los ordenadores la facultad de evidenciar patrones en datos masivos y desarrollar predicciones. Esta forma de aprender le permite desarrollar tareas en forma específica y autónoma a los computadores, no siendo necesario realizarse programaciones. La terminología originaria data del año 1959. Pero es que estos últimos años, ha alcanzado relevancia, debido a la mejora tecnológica de la computación y el crecimiento relevante de la tecnología de datos. El autor pone en relevancia que para el Big Data son relevantes en el aprendizaje automático las técnicas a emplearse. (Iberdrola, 2023)

#### 2.1.2. *Inteligencia artificial*

Mediante la inteligencia artificial, las cosas que realiza la mente son realizadas por los ordenadores. Aspectos como razonar se describen como “inteligentes”, aspectos como la visión, no. Todos contienen competencias psicológicas, tales como la asociación, percepción, planificación, predicción y el control motor, que hacen que los animales y seres humanos alcancen sus objetivos. El autor precisa que no se debe considerar como única dimensión a la inteligencia, sino un espacio densamente estructurado con diversas capacidades para el procesamiento de información. La inteligencia artificial emplea diversas técnicas para encontrar solución a una diversidad de tareas en diferentes espacios. (Boden, 2017)

La IA es definida como la capacidad de un ordenador en desarrollar actividades que

términos normales demandan la inteligencia humana. Una detallada definición considera a la IA como la capacidad de los ordenadores en emplear algoritmos, para realizar aprendizaje de los datos y emplear lo aprendido para toma decisiones al igual que sucedería con un ser humano. Precisa que estos dispositivos que trabajan con inteligencia artificial no requieren descansar y analizan datos de información bastante grandes en corto tiempo y en forma concurrente a diferencia del ser humano. Otro aspecto relevante es la diferencia considerable con respecto a los errores que resultan menores. (*Inteligencia artificial*, 2020).

### **2.1.3. Deep Learning**

Conocido como profundo aprendizaje, es una subdivisión del Machine Learning, que utiliza una jerarquía estructural de redes neuronales artificiales, que son construidas en semejanza a la estructura neuronal del cerebro del hombre, que evidencia nodos conectando neuronas como si fuese una tela de araña. La arquitectura resultante demanda un análisis no lineal de los datos. El Deep Learning, evidencia una técnica que orienta a los ordenadores a realizar lo que naturalmente sería para los humanos: en base a ejemplos. Es importante en el control a través de la voz en diferentes dispositivos, teléfonos, televisores, tablets y altavoces. Esta rama del machine learning, tiene mayor atención en la medida que se viene logrando resultados que no se evidenciaban anteriormente. (Alba, 2019).

Problemas centrales en cuanto a aprendizaje de representaciones, suelen ser resueltos por el Deep Learning, incorporando de representaciones simplificadas; es decir mediante esta técnica es posible construir conceptos más complejos, mediante una estructuración de conceptos simples; como representaciones de imágenes a través de interpretaciones de esquinas y contornos, definiendo aspectos de bordes. (Goodfellow et al., 2016).

### **2.1.4. Big Data**

Schroeck et al. (2012) precisa que este concepto tiene varios significados, empresarialmente se orientan al manejo de datos enfocados en los clientes, generar ecosistema

de información a partir de datos internos. Precisan los autores que el Big Data se emplea para inferir al público diversos conceptos, siendo este abanico: volúmenes grandes de datos, aspectos analíticos en redes sociales, herramientas tecnológicas actuales para gestionar datos, en tiempo real. La IBM a través de sus investigadores, desarrollaron una investigación en base a encuestas de 1,144 negocios y 95 profesionales de diferentes países, asimismo entrevistaron a académicos en más de dos docenas, especialistas y directivos empresariales, concluyendo que respecto a Big Data, infiere pensar en una amplitud grande de información, tipos nuevos de datos y análisis, informaciones concurrentes, ingreso de datos cuya fuentes son nuevas tecnologías, volúmenes de datos grandes e información de redes sociales.

Asimismo, se evidencia definiciones de Big Data, como herramientas, procedimientos y procesos que posibiliten organizar, crear, la manipulación y la gestión de datos muy voluminosas y su almacenamiento. Lo que ratifica la posición de que la gestión de conocimiento tiene como fuente importante a la Big Data. (Gómez, 2021).

#### **2.1.5. Algoritmo**

Conjunto de instrucciones secuenciales, las mismas que representan tareas bien definidas, cuya acción se desarrolla en un tiempo finito y para cierto número de recursos de computación. Es importante tener en cuenta que cualquier algoritmo debe de concluir de pasos bien definidos y contabilizados, de tal forma que sean empleados como una instrucción para el desarrollo de un algoritmo de mayor complejidad. (Botazzi et al., 2022)

Es la secuencialidad finita de pasos libre de posibles ambigüedades, ejecutadas en tiempos definidos, cuya motivación es resolver problemas y que la solución es evidenciable a través de un algoritmo. (Rodríguez, 2018)

#### **2.1.6. Redes Neuronales**

Las ANN (Artificial Neural Networks) se inspiran en la biología del cerebro humano en cuanto a sus redes neuronales; conformadas fundamentalmente por elementos cuyo



comportamiento es similar a las biológicas, en cuanto a funciones comunes, evidenciando una organización muy similar a la que muestra un cerebro humano. Precisa el autor que más que parecerse las ANN, se caracterizan porque la experiencia, es su base de aprendizaje, tienen la capacidad generalizadora a partir de datos previos, datos nuevos y posibilitan la abstracción de características principales de un conjunto de datos. (Basogain, 2022)

Las redes neuronales fundamentalmente emulan características importantes del ser humano, como la capacidad de aprender, memorizar y asociar actividades. Siendo la experiencia característica común de ambos agentes (ser humano y algoritmo). Una característica básica del ser humano es buscar soluciones a diversas situaciones apelando a la acumulación de experiencias que tiene, al igual que la red neuronal artificial que busca soluciones en base a la construcción de sistemas capaces de discernir a partir de previo entrenamiento y aprendizaje. (Matich, 2001)

### ***2.1.7. California Bearing Ratio (CBR)***

El CBR se constituye en un método empleado en la evaluación del suelo en cuanto a su calidad relativa, tanto para subrasantes, bases y sub-bases en pavimentos. Stanton y Porter en 1929 propusieron este método, ambos del Departamento de Carreteras de California, origen de su denominación, definiéndose como la Relación de Soporte California. En de precisar que existen países del orbe que lo conocen como Valor Relativo Soporte (VRS). Precisa el autor que Estados Unidos adopto este ensayo para evaluar condiciones del suelo para construir aeropuertos. En 1993. el CBR fue ampliamente utilizado para diseño de pavimentos flexibles, tomando como referencia la resistencia al corte. En el año 964, en la norma ASTM D 1883 se describe las directrices para su empleo en diseño y para campo en la ASTM D 4429, ambas establecidas por la American Society for Testing and Materials. (Araujo-Navarro, 2014).

El ensayo de CBR permite determinar la resistencia al cortante en suelos para condiciones de humedad controladas. Se obtiene relacionando la carga unitaria utilizada a una profundidad

de penetración del pistón en la muestra compactada y la carga unitaria patrón que demanda para lograr la penetración a una igual profundidad en la muestra estándar con material triturado. Siendo su unidad en porcentaje de la carga unitaria patrón. (Manzano, 2021)

#### ***2.1.8. Conjunto de datos***

Se constituyen en el conjunto de datos de determinado proceso, que permitan certificar los resultados de determinada investigación en desarrollo, habiéndose las mismas registrado en el proceso y sean de reconocimiento científico. (Peset y González, 2017b)

#### ***2.1.9. Algoritmo de predicción***

Los algoritmos predictivos se definen como herramientas encargadas de gestionar la información, en base a un proceso de entrenamiento supervisado o no supervisado, para que luego de una validación emita resultados que permitan asegurar resultados cercanos a los patrones iniciales, minimizando el error respectivo. (Gonzales, 2022)

#### ***2.1.10. Capacidad de soporte***

Conocida también como capacidad de carga, es la capacidad de un suelo para alcanzar el máximo esfuerzo sin llegar a fallar por corte. Ampliamente utilizado para diseñar cimentaciones superficiales. El autor precisa que al referirse a cimentaciones superficiales es cuando las mismas no llegan a superar los tres metros. (Ramírez, 2023)

#### ***2.1.11. Rendimiento del modelo***

Se determina mediante el valor del coeficiente  $R^2$  del modelo, definido como el porcentaje de variabilidad en los datos que el modelo explica. Permite determinar la performance del modelo de Machine Learning, dependiendo del entrenamiento el resultado. (Huet, 2023)

#### ***2.1.12. Coeficiente de correlación***

Se constituye en una herramienta estadística básica y de suma importancia para los estudios fundamentalmente de investigación que incida en la determinación del sentido y la

posible relación lineal que existe entre pares de variables. (Lahura, 2023)

#### ***2.1.13. Datos de entrenamiento***

Es un conglomerado de datos de un fenómeno utilizados en el proceso de aprendizaje. La data de entrenamiento por lo general es el conjunto más grande, en términos de tamaño, que se crea a partir del conglomerado de datos original y se emplea para encontrar el modelo. En otras palabras, los puntos de datos incluidos en el conglomerado de entrenamiento se utilizan para aprender los parámetros del modelo de interés. (Chipoco, 2023)

#### ***2.1.14. Datos de validación***

Un conjunto de datos ejemplos utilizados para ajustar los hiper parámetros de un clasificador, por ejemplo, para determinar el número de unidades ocultas en una red neuronal. (Chipoco, 2023).

#### ***2.1.15. Datos de prueba***

Viene a ser un grupo de datos ejemplos empleados solo para evaluar el rendimiento de un clasificador completamente especificado. El conglomerado de datos de prueba se emplea para evaluar el rendimiento de este modelo y garantizar que sean bien generalizados a puntos de datos nuevos e invisibles. (Chipoco, 2023)

#### ***2.1.16. Número de entradas***

Son los valores que permiten el entrenamiento del modelo de machine learning relacionados con la variable independiente (x), las mismas que dependiendo el modelo tendrán ciertas características relacionadas con los datos ya existentes; precisándose que cuanto mayor cantidad de datos (número de entradas) mejor será el entrenamiento del modelo. (Gonzales, 2022)

#### ***2.1.17. Número de salidas***

Son los valores que permiten evidenciar la predicción del parámetro investigado, las mismas que serían valores cuantitativos o cualitativos, valores de predicción que determinan la

funcionabilidad del modelo. (Gonzales, 2022)


### 2.1.18. Estructura de las redes neuronales artificiales (RNA)

Conformadas por capas neuronales estructuradas por unidades interconectadas mediante nodos. Las RNA se emplean para procesos en la que resulta complejo establecer lógicas restricciones explícitamente, como reconocer patrones y tareas de analizar datos para fines predictivos. Desarrollado por McCulloch y Pitts, en 1943, neurocientífico y científico lógico, respectivamente. Formularon una unidad de umbral binario, como estructura del modelo para la neurona artificial, como se aprecia en la figura 1. (Arana, 2021) El modelo matemático y el modelo de red neuronal estructuralmente, de esta unidad, es el siguiente:

$$y = H\left(\sum_{j=1}^n w_j x_{j-u}\right)$$

**Figura 1**

*Esquema característico de una red neuronal artificial*



*Nota:* Se aprecia una red neuronal multicapa


### 2.1.19. Las redes neuronales recurrentes (RNN):

Cea (2020) precisa que, en 1982, John Hopfield, tomando como referencia el trabajo de David Rumelhart, desarrollo inicialmente la neurona recurrente. La Recurrent Neural Networks – RNN, muestran capacidad de análisis de datos secuenciales temporalmente, cuyo tamaño es variable y a partir de ello realizar predicciones determinado el valor siguiente de la serie. Esta

forma de comportamiento es, de alguna manera un medio para conseguir creatividad y originalidad. Una forma más intuitiva de observar el funcionamiento de esta tipología de neuronas es procesarlas a través del tiempo, como se observa en la figura 2, en cada time step, la neurona recibe el dato de entrada respectiva y a su vez, la salida del time step anterior. Este proceso permite a la red recordar información de anteriores secuencias al momento de realizar el procesamiento de los datos del time step actual. Lo mismo sucede si el mismo concepto lo extendemos a una capa, como se evidencia en la figura 3, donde a partir de la capa recurrente en el tiempo se generan las demás capas recurrentes.

**Figura 2**


*Esquema del funcionamiento de la neurona en el tiempo*



*Nota:* A la izquierda la neurona recurrente y a la derecha la nueva neurona desarrollada.

**Figura 3**

*Esquema del funcionamiento por capas de neuronas recurrentes*




*Nota:* A la izquierda la capa recurrente, a la derecha la capa recurrente en el tiempo.

### 2.1.20. Las Máquinas de Soporte Vectorial (SVMs)

Betancourt (2005) describe que la SVM, tiene un proceso de aprendizaje en función de dos clases diferentes de puntos de entrada. Los datos vectoriales de soporte son capaces de establecer una frontera de decisión con respecto a los datos de aprendizaje, con escaso o conocimiento nulo de datos que están fuera de la frontera. Por medio de un Kernel Gausiano u otro Kernel son mapeados los datos, a espacios de dimensión mayor, encontrando la separación máxima entre clases. La función de frontera, al regresarlo al espacio de entrada, separa los datos en diferentes clases, formando diferentes agrupamientos, como se aprecia en la figura 4.

**Figura 4**

*Idea de la utilización de un kernel para transformación del espacio de los datos*



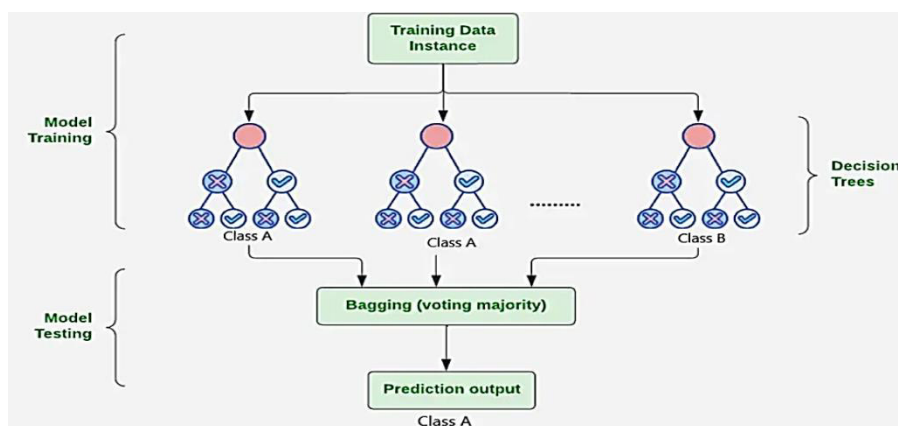
*Nota:* Mediante la función Kernel, los puntos de entrada son sometidos a producto punto en el espacio que muestra las características.

### 2.1.21. Random Forest Algorithm in Machine Learning (RF)

Hazam (2024) define que es un conglomerado de árboles de decisión que laboran en conjunto para hacer predicciones. El algoritmo de bosque aleatorio, viene a ser una técnica de aprendizaje de árboles automatizado, para hacer predicciones, utilizando todos los árboles para hacer la predicción. Se utilizan ampliamente para tareas de regresión y clasificación. Toma diferentes partes aleatorias de la data para entrenar cada árbol y luego combina los resultados promediándolos. Este enfoque ayuda a mejorar la precisión de las predicciones. El bosque aleatorio se basa en el aprendizaje conjunto; en la figura 5 se evidencia el funcionamiento del algoritmo desde la etapa de entrenamiento hasta la etapa de predicción.

**Figura 5**

*Esquema de funcionamiento del algoritmo del Random Forest*



*Nota:* El proceso comienza con un conjunto de datos con filas y sus etiquetas de clase correspondientes (columnas).

### 2.1.22. Características de la redes neuronales y algoritmos

Los modelos estudiados en la investigación se evidencian en la tabla 1, apreciándose una comparativa sintética de las diferencias, ventajas y desventajas de cada método.

**Tabla 1**

*Diferencias, ventajas y desventajas en el contexto de predicción del CBR*

Método	Diferencias	Ventajas	Desventajas
<b>RNN-LSTM</b>	Modela secuencias de datos con memoria a largo plazo mediante celdas LSTM.	Capacidad de capturar dependencias temporales y no lineales complejas.	Requiere alta capacidad computacional y gran cantidad de datos para entrenar.
<b>RNN-GRU</b>	Similar a LSTM, pero con una estructura más simple y menos parámetros.	Más eficiente y rápido que LSTM sin perder mucha precisión.	Serían menos preciso en problemas con dependencias a muy largo plazo.
<b>ANN</b>	Modela relaciones no lineales sin memoria temporal.	Flexible y fácil de implementar, útil para problemas de clasificación y regresión.	No maneja bien datos secuenciales o dependencias temporales.
<b>SVM</b>	Encuentra hiperplanos óptimos para la clasificación y regresión.	Preciso en conjuntos de datos pequeños y robusto frente a sobreajuste.	No es eficiente en grandes volúmenes de datos y difícil de ajustar.
<b>Random Forest (RF)</b>	Aglomerado de árboles de decisión entrenados de forma aleatoria.	Robusto a ruido, interpretabilidad alta y buen rendimiento en datos tabulares.	Serían menos preciso en relaciones altamente no lineales y dependientes del tiempo.

*Nota:* Elaboración propia.

### III. MÉTODO

#### 3.1. Tipo de investigación

- a. *Por su orientación.* Aplicada, dado la naturaleza del estudio, muestra un enfoque científico, donde las variables en la realidad serán operadas.
- b. *Por la teoría de contraste.* Experimental, dado que los datos inicialmente son encontrados por observación fenomenológico que han sido condicionados, sobre la base de variables física y mecánicas del suelo y se espera la consecuencia en la variable CBR.
- c. *Por la direccionalidad.* Prospectiva, en la medida que los datos fueron recopilados, estas se generaron de acuerdo con el comportamiento real del suelo y que el valor del CBR fue determinado experimentalmente.
- d. *Por la fuente de recolección de datos.* Prolectiva, en la medida que los datos recopilados inicialmente fueron determinados en base a criterios normativos y manipulados en los ensayos que identificaron las propiedades física y mecánicas del suelo y el CBR.
- e. *Por la evolución del fenómeno estudiado.* Transversal, dado que las medidas de las variables en cuanto a sus propiedades mecánica y físicas del suelo se midieron en un momento en el proceso de ensayo

##### 3.1.1. Nivel de investigación

Explicativo, analizándose la relación causal de variables como las propiedades física y mecánicas del suelo de la subrasante de carreteras con respecto al valor de su capacidad de soporte (CBR).

#### 3.2. Población y muestra

##### 3.2.1. Población

La población de estudio son los suelos a nivel de subrasante de las obras viales de la macro región 6: Junín, Pasco, Ucayali y Huánuco, mostrada en la Figura 6.



**Figura 6***Delimitación de la población de estudio**Nota:*

<https://czstore.online2023sale.ru/content?c=regiones+del+peru&id=34>;  
tomado el 19/01/2024

### 3.2.2. Muestra

La muestra será representada por datos recolectados de laboratorios especializados de mecánica de suelos y geotecnia, de carácter público y privado; siendo los criterios de inclusión:

- Sean resultados de propiedades físicas, mecánicas y geológicas de ensayos de suelos a nivel de subrasante en carreteras.
- Que las muestras de suelo tomadas de campo necesariamente estén ubicadas en la jurisdicción regional de Huánuco.

En la figura 7, donde se observa la delimitación de la muestra de estudio.

**Figura 7***Delimitación de la muestra de estudio*

*Nota:* <https://www.pinterest.com/pin/555350197773966085/>; tomado el  
18/01/2024

La técnica de muestro es no probabilístico, por conveniencia teniendo como criterio considerar un mayor universo de área a nivel regional.

### **3.3. Operacionalización de variables**

Se refiere al proceso de conversión de una variable conceptual a una variable operacional (Hernández-Sampieri y Mendoza, 2018). Bajo este contexto la variable independiente se descompuso en dos dimensiones: la data real, y el algoritmo de predicción. Asimismo, estas fueron divididas en indicadores que midan la variable de estudio. Asimismo, la tabla 2, evidencia el procedimiento de operacionalización de la variable dependiente. Se precisa que las dimensiones de la variable dependiente fueron el CBR y el rendimiento del modelo. Esto permitió cuantificar la disminución del error y el grado de precisión del modelo, al comparar los valores reales y predichos.

**Tabla 2***Matriz de operacionalización de variables*

VARIABLES	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIONES	INDICADORES	UNIDADES
<b>Variable independiente:</b>	Es la mezcla de algoritmos formulados con la finalidad de generar máquinas que evidencien iguales capacidades que un humano. Es la raíz donde se originan las imitaciones de las funciones inteligentes de los humanos a través de la generación y aplicación de algoritmos desarrollados dinámicamente en un entorno computacional.	Para establecer el algoritmo de predicción, se requerirá de una data compuesta de valores resultados de ensayos físicos y mecánicos del suelo materia de análisis, que incluya la recopilación de datos estadísticos o inspección visual. Además, se identificarán valores fundamentales para la determinación de la capacidad de un soporte para la cimentación de una obra vial.	Conjunto de datos	Datos de entrenamiento Datos de Validación Datos de prueba	Unidades de análisis
Modelo de Inteligencia artificial			Algoritmo de predicción	Número de entradas Número de salidas	Numero de layers
<b>Variable dependiente:</b>	El Ensayo CBR, se constituye en un parámetro característico del suelo que evidencia el valor de su capacidad de soporte como subrasante, base y subbase en el pavimento en cuanto a su diseño. Viene a ser un ensayo empírico que se desarrolla en un entorno controlado de las condiciones de densidad seca y humedad óptima.	El CBR aborda la consideración de propiedades como el contenido de humedad, capacidad de penetración en suelos, densidad humedad, densidad seca; a partir del cual caracterizar el suelo desde el punto de vista geotécnico. El Rendimiento del modelo permitirá determinar el grado de confiabilidad y seguridad del modelo expresado mediante el valor de R, que es fruto del entrenamiento y validación del modelo	Capacidad de Soporte	CBR	%
Predicción del CBR			Rendimiento del Modelo	Coefficiente de correlación	%

*Nota:* Elaboración propia

### 3.4. Instrumentos

**Ensayos en laboratorio (resultados recopilados de ensayos realizados de proyectos reales):** Se obtuvieron datos de Límites de Atterberg, granulometría, densidad máxima seca, contenido de humedad óptimo y Proctor modificado, incidentes en la clasificación de un suelo.

**Revisión y prueba de algoritmos (modelos mediante machine learning):** Redes Neuronales Artificiales, Redes Neuronales Recurrentes (Tipo LSTM, Tipo GRU), Máquina de soporte vectorial (SVM), Random Forest (RF).

Codificación de los algoritmos

Métricas de tendencia central, dispersión y forma, medidas de relación y correlación, la prueba F, Prueba de Friedman, Test de Wilcoxon, Intervalos de confianza (IC 95%) y análisis de covarianza. (Softwares): Python, SPSS vs 24, Microsoft Word y Excel.

### 3.5. Procedimientos

La recolección de la data real se realizó de la forma siguiente:

**Primera etapa,** se investigó bibliográficamente en el contexto local, nacional e internacional, lo referente al tema de investigación.

**Segunda etapa,** se recolectó bases de datos de estudios de determinación del CBR a nivel de la región de Huánuco, de laboratorios de mecánica de suelos y geotecnia; los mismos que fueron recolectados documentariamente.

**Tercera etapa,** se realizó recopilación de datos de expedientes técnicos y estudios de carretas en donde se evidencie la existencia de datos de determinación de propiedades físicas y mecánicas de suelos en la región de Huánuco, a través de plataformas gubernamentales como es el SEACE.

**Cuarta etapa,** con los datos recolectados se procedió al entrenamiento, validación y prueba de los modelos de Machine Learning.

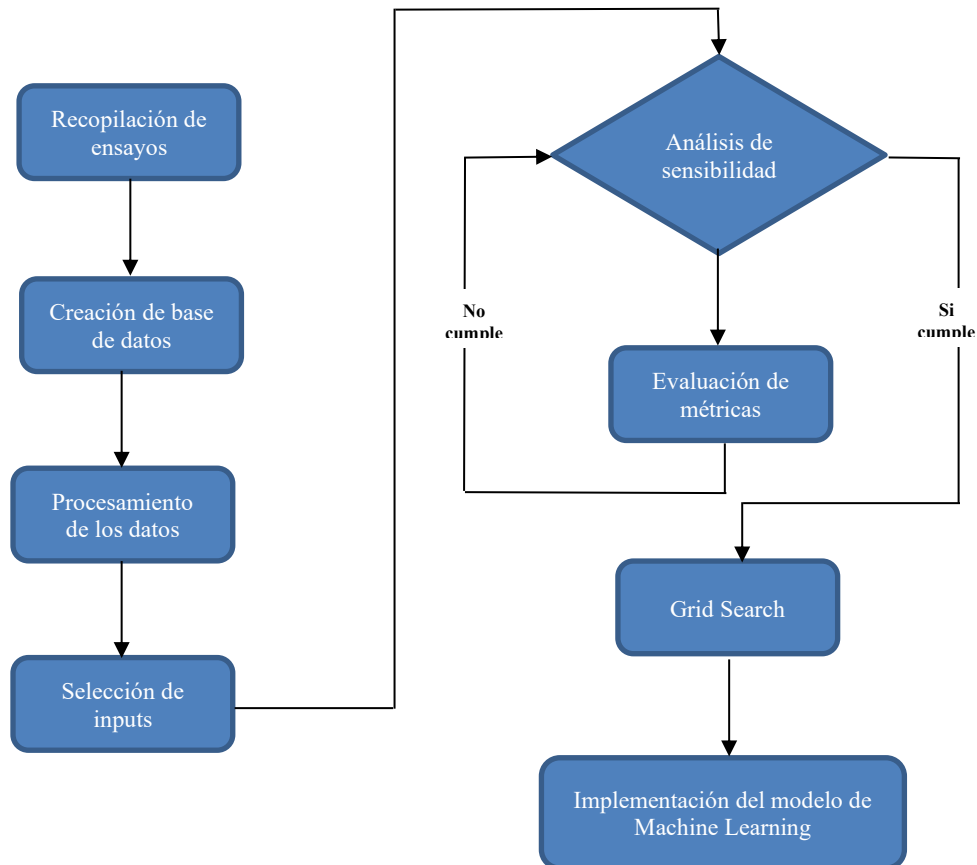
**Quinta etapa,** discusión y validación de los resultados obtenidos mediante aplicación

del modelo en proyectos reales que permita obtener la confiabilidad del modelo de predicción del CBR en obras viales.

Todo el proceso descrito, se evidencia en el siguiente diagrama de flujo de la figura 8.

**Figura 8**

*Diagrama de flujo de la investigación.*



*Nota:* Elaboración propia.

### 3.6. Análisis de datos

Se realizó en forma estructurada, buscando sistematizar las mismas de forma tal que permita la interpretación de los resultados, para lo cual se procedió a la revisión de la data de entrada como de salida y determinar conclusiones importantes empleando métodos analíticos. El proceso analítico de datos permitió categorizar, manipular y resumirlos, para responder los objetivos planteados en la presente investigación.

### **3.7. Consideraciones éticas**

Se actuó éticamente frente a los sujetos participantes en la presente investigación.

Se cauteló en todo lo posible las acciones a fin de evitar probables riesgos, buscando reducirlas e incrementar los beneficios de la investigación, para los participantes.

Ante el acceso de ciertas informaciones de carácter personal, se buscó las estrategias de proteger, garantizando la privacidad y confidencialidad.

La investigación evidencia potencialidad de generar conocimiento valioso, científico y social.

Se buscó en todo lo posible garantizar el proceso de consentimiento informado para garantizar la libertad de autodeterminación de los sujetos participantes en la investigación.

## IV. RESULTADOS

Previamente se hace necesario establecer claramente el flujo del proceso que permite llegar a los resultados de predicción de valores de CBR, precisando lo siguiente:

### 4.1. Entendimiento del problema

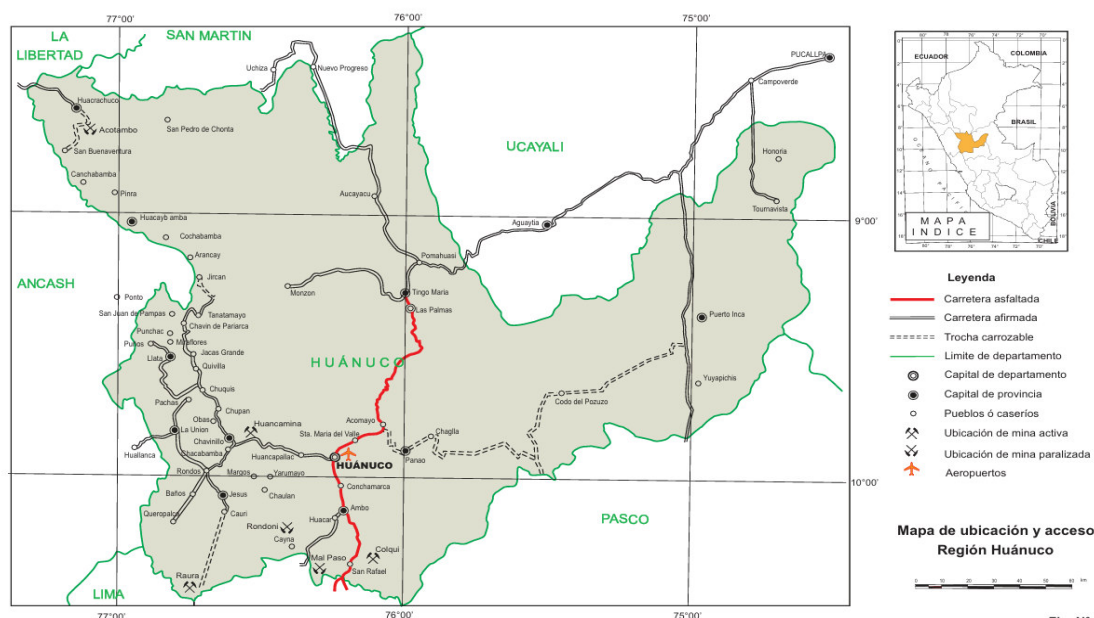
El CBR es un parámetro importante para evaluar la capacidad de soporte de suelos en subrasantes de carreteras. Predecir el CBR mediante redes neuronales y algoritmos implica:

#### 4.1.1. Recopilar datos históricos de ensayos de laboratorio y mediciones de campo

Se obtuvieron de laboratorios de Mecánica de Suelos, expedientes técnicos reales, del Organismo Supervisor de Contrataciones del Estado (OSCE), laboratorio de Geotecnia de la Universidad Nacional Hermilio Valdizan de Huánuco, laboratorios privados; habiendo obtenido **2,875 puntos**. Todas de la región Huánuco – Perú, mostrada en la figura 9.

**Figura 9**

*Ubicación geográfica de la región Huánuco - Perú*



*Nota:* Delimitación geográfica de la zona fuente de los 2875 puntos de análisis para efectos de predicción; adaptada de “Inventario de los recursos minerales de la región Huánuco” (p. 8), por Dirección de Geología Económica y Prospección Minera, 2016, INGEMMET.

La región Huánuco geográficamente está ubicada en la parte centro oriental del Perú, entre la cuenca hidrográfica del río Pachitea y la Cordillera Occidental, con una superficie de 54,563 km<sup>2</sup> y comprendida en el rango de coordenadas siguientes:

Latitud sur: entre los 08° 30' a 10° 30'

Longitud oeste: entre los 74° 30' a 77° 30'

#### ***4.1.2. Identificar variables predictoras***

Las propiedades físicas, mecánicas y características geológicas del suelo, permiten inferir su desempeño geotécnico; efectivamente los datos recopilados muestran valores de Granulometría, Densidad máxima seca, Límites de consistencia, Contenido óptimo de Humedad, Proctor Modificado, CBRs y la litoestratigrafía.

#### ***4.1.3. Entrenar un modelo de red neuronal***

Que permita generalizar adecuadamente los comportamientos del suelo para predecir el CBR en nuevas muestras; en este contexto se ha procedido a utilizar las siguientes técnicas:

##### ***a. Redes Neuronales Recurrentes (RNN):***

Entendiendo que está diseñada para trabajar con secuencias de datos, lo que las hace adecuadas para modelar problemas, siendo el orden y la dependencia temporal importantes, capturando mediante ellas las relaciones secuenciales y temporales en los datos de las propiedades mecánicas y físicas, que influyen en el CBR. Habiéndose empleado dos variantes:

##### ***LSTM (Long Short-Term Memory):***

Una variante de las RNN, para superar el problema de la debilidad de la gradiente que ocurre en las RNN tradicionales. Las LSTM son capaces de retener información a largo plazo, lo que las hace ideales para modelar relaciones complejas en los datos.

##### ***GRU (Gated Recurrent Units):***

También se utilizaron unidades GRU, una versión simplificada de las LSTM, que requieren menos recursos computacionales y son eficientes en predicción secuencial.



***b. Redes Neuronales Artificiales (ANN):***

Se implementaron redes neuronales feedforward con una o más capas ocultas para modelar las relaciones no lineales entre las propiedades del suelo y el CBR.

***c. Máquinas de Soporte Vectorial (SVM):***

Se utilizaron SVM con kernels lineales y no lineales (como el kernel radial, RBF) para clasificar y predecir el CBR.

***d. Random Forest (RF):***

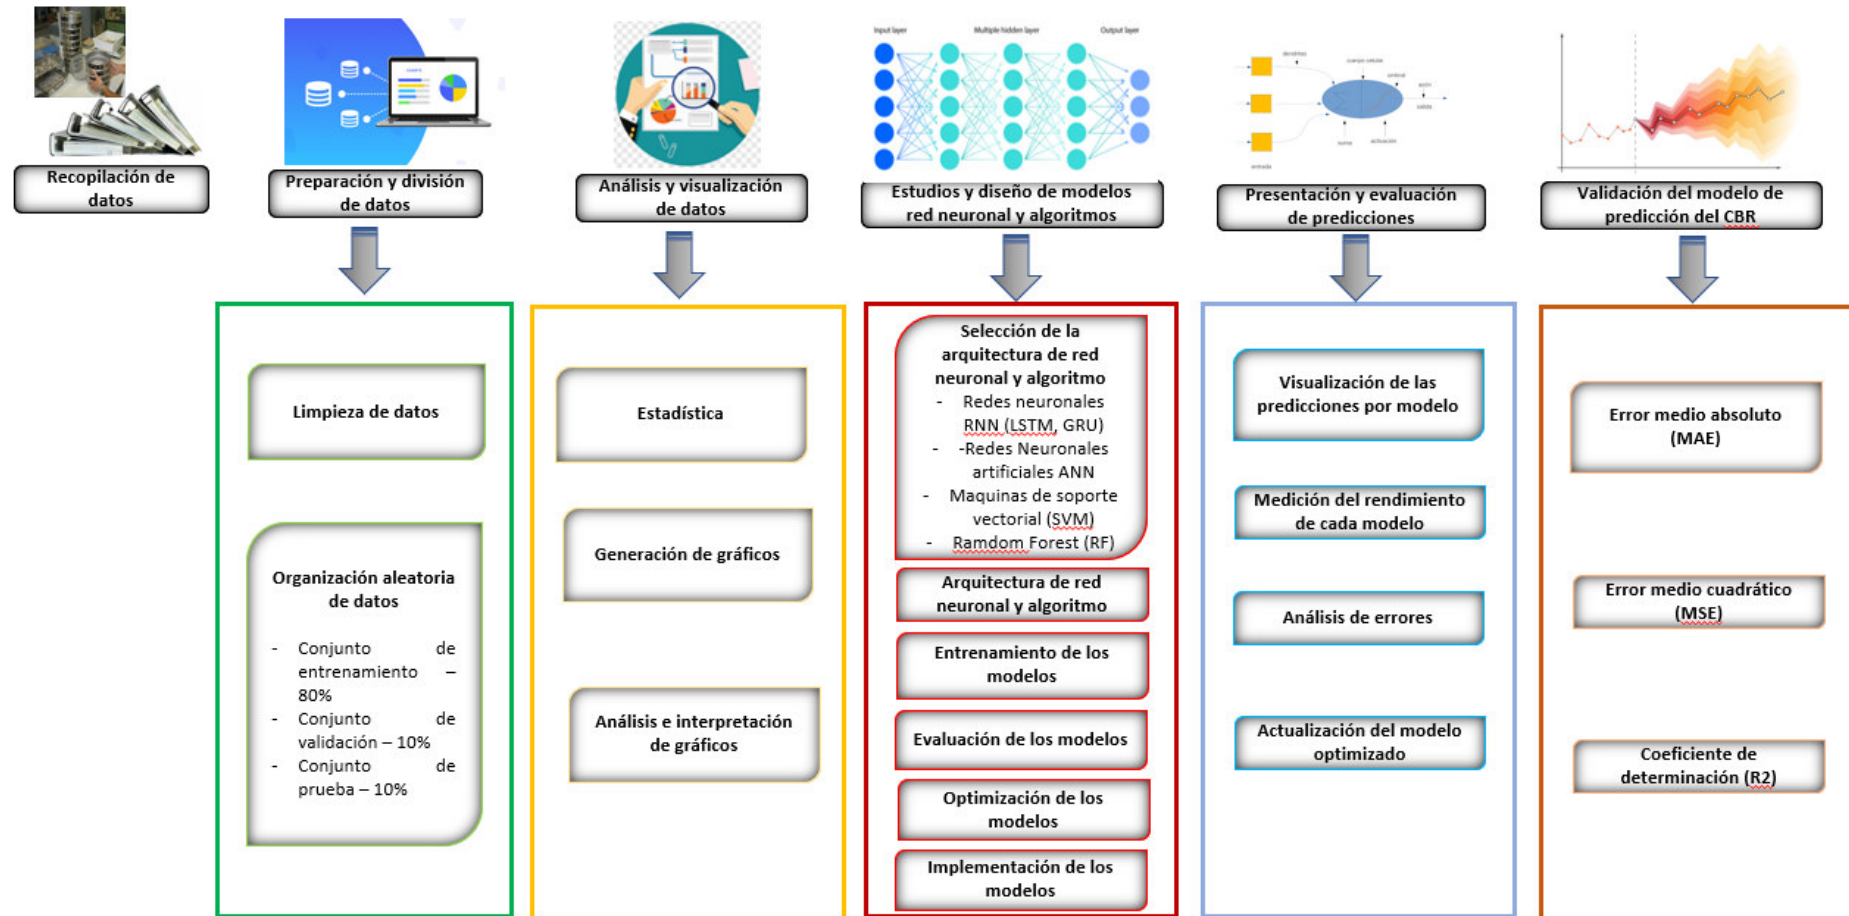
Se empleó este algoritmo de ensemble learning, que combina múltiples árboles de decisión reduciendo el sobreajuste y mejorando la precisión.

***4.1.4. En la presente investigación***

Adicional a la predicción del CBR a partir de propiedades físicas y mecánicas nuevas, se ha implementado la verificación de los resultados tomando en cuenta la ubicación geográfica del punto en análisis, con el aspecto geológico que es la litoestratigrafía, lo cual permite mayor certeza de que la predicción sea correspondiente; asimismo mediante el ARCGIS la generación de capas de información mediante una capa vectorial (shapefile) con los puntos de muestreo, asociando a cada punto sus propiedades índice y resultados de CBR; con la información geológica, crear una capa poligonal que represente las unidades litológicas en el área de estudio y una capa con la red de carreteras existente para contextualizar la ubicación de las subrasantes. En este contexto, es importante precisar que, para la presente investigación, ha tenido como esquema de desarrollo el mapa de proceso establecido en la figura 10, en la cual se evidencia, los alcances de lo realizado.

Figura 10

*Fases de la determinación del modelo de predicción del valor de CBR*



*Nota:* Se evidencia los subprocesos que se realizaron a fin de poder cumplir con los objetivos previstos.

## 4.2. Recopilación y procesamiento de datos

**4.2.1. Datos necesarios:** Los datos Necesarios considerados son los siguientes:

### 4.2.1.1 Variables de entrada (features):

**Propiedades físicas del suelo:** Granulometría, límite líquido, límite plástico, índice plástico, como se muestra en la figura 11 y la tabla 3.

**Figura 11**

*Datos de propiedades físicas del suelo a nivel de subrasante en carreteras*

ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN	MUESTRA DE	PROPIEDADES FÍSICAS					
				Granulometría			Límites de Consistencia		
				% grava	% arena	% limo -	LL (%)	LP (%)	IP (%)
1	Tramo: AMBRAMACHAY - PARASHAPAMPA, APARICIO POMARES, YAROWILCA, HUÁNUCO	Inicio: 76°37'43.59"W, 9°44'11.87"S, 3344; Fin: 76°36'06.16"W, 9°44'31.48"S, 3717 msnm.	C-1	18.050	46.220	35.740	NP	NP	NP
			C-2	71.020	26.920	2.060	NP	NP	NP
			C-3	87.500	10.940	1.560	NP	NP	NP
			C-4	12.750	70.730	16.520	18.330	17.630	0.700

*Nota:* Obsérvese los datos de propiedades físicas que permiten clasificar el suelo.

**Tabla 3**

*Datos recopilados a nivel de la región Huánuco de propiedades físicas.*

ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN COORDENADAS GEOGRÁFICAS	MUESTRA DE SUELO	PROPIEDADES FÍSICAS					
				Granulometría			Límites de Consistencia		
				% grava	% arena	% limo - arcilla	LL (%)	LP (%)	IP (%)
1	Tramo: AMBRAMACHAY - PARASHAPAMPA, APARICIO POMARES, YAROWILCA, HUÁNUCO	Inicio: 76°37'43.59"W, 9°44'11.87"S, 3344; Fin: 76°36'06.16"W, 9°44'31.48"S, 3717 msnm.	C-1	18.050	46.220	35.740	NP	NP	NP
			C-2	71.020	26.920	2.060	NP	NP	NP
			C-3	87.500	10.940	1.560	NP	NP	NP
			C-4	12.750	70.730	16.520	18.330	17.630	0.700
2	Tramo: EMP. HU-1076 - COLPAS, COLPAS, AMBO, HUÁNUCO	Inicio: 76°21'25.20"W, 10°17'46.86"S, 2480 msnm; Fin: 76°24'55.3"W, 10°16'05.69"S, 2723 msnm.	C-1	48.910	38.670	12.420	22.420	19.790	2.630
			C-2	21.620	57.540	20.850	25.080	20.990	4.090
			C-3	43.780	37.920	20.300	25.170	22.130	3.040
			C-4	42.970	47.040	9.990	29.520	26.130	3.390
			C-5	41.710	51.880	6.410	24.710	22.920	1.790
			C-6	34.930	44.320	20.750	22.470	19.160	3.310
			C-7	40.260	45.040	14.700	20.680	18.030	2.650
			C-8	32.820	42.320	24.860	22.150	18.760	3.390
			C-9	37.910	37.090	25.000	25.740	18.680	7.060
			C-10	60.090	26.800	13.110	26.850	23.030	3.820
			C-11	48.160	39.610	12.230	22.350	19.680	2.670
			C-12	46.960	40.300	12.740	23.340	19.190	4.150
			C-13	38.970	42.960	18.070	27.850	25.230	2.620
3			C-14	11.210	41.350	47.440	29.510	23.480	6.030
			C-15	30.430	48.920	20.650	24.090	21.050	3.040
			C-16	42.340	44.860	12.800	26.960	22.190	4.770
			C-17	23.440	47.980	28.580	30.120	23.550	6.570
			C-1	47.440	47.030	5.540	NP	NP	NP

Tramo: EMP. HU-523 (PTA. CARRETERA) - SECTOR ALTO COLOMBIA, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 msnm; Fin: 76°19'30.25"W, 8°50'51.11"S, 770 msnm.	C-2	22.480	44.170	33.350	NP	NP	NP
		C-3	48.630	48.660	2.710	NP	NP	NP
		C-4	10.800	32.340	56.850	38.070	29.880	8.190
		C-5	15.640	23.060	61.300	45.540	36.620	8.920
		C-6	9.820	24.720	65.460	34.740	27.960	6.780
		C-7	6.690	30.880	62.430	34.320	27.450	6.870
		C-8	1.310	28.550	70.130	42.100	36.300	5.800
		C-9	0.870	20.250	78.870	35.620	27.980	7.640
		C-10	1.810	21.610	76.580	33.100	27.770	5.330
		C-11	1.700	27.980	70.320	47.850	36.120	11.730
		C-1	11.480	19.810	68.720	38.280	27.030	11.250
4 Tramo: ALTO MARTHA - SECTOR HOJA GRANDE, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 msnm; Fin: 76°20'08.99"W, 8°48'38.97"S, 753 msnm.	C-2	11.470	29.720	58.810	42.600	29.530	13.070
		C-3	11.930	40.020	48.050	NP	NP	NP
		C-4	54.710	31.660	13.620	NP	NP	NP
		C-5	60.960	33.460	5.580	NP	NP	NP
		C-6	23.440	55.050	21.510	NP	NP	NP
		C-7	33.370	36.890	29.740	NP	NP	NP
		C-8	0.710	16.580	82.710	48.610	36.200	12.410
		C-9	34.950	33.980	31.070	NP	NP	NP
		C-10	66.800	22.310	10.890	NP	NP	NP
		C-11	51.780	37.290	10.920	NP	NP	NP
		C-12	57.870	25.800	16.330	NP	NP	NP

*Nota:* se observa un extracto de las 2270 calicatas, materia de resultado de ensayos.

**Propiedades Mecánicas del suelo:** Proctor Modificado (obteniendo, el contenido de humedad óptimo, máxima densidad). Como se evidencia en la figura 12 y la tabla 4.

## Figura 12

*Datos de propiedades mecánicas del suelo a nivel de subrasante en carreteras*

ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN	MUESTRA DE	PROPIEDADES MECÁNICAS		
				Proctor Modificado		CBR
1	Tramo: AMBRAMACHAY - PARASHAPAMPA, APARICIO POMARES, YAROWILCA, HUÁNUCO	Inicio: 76°37'43.59"W, 9°44'11.87"S, 3344; Fin: 76°36'06.16"W, 9°44'31.48"S, 3717 msnm.	C-1	2.190	7.500	39.000
			C-2			
			C-3			
			C-4	2.230	6.400	41.000

*Nota:* Obsérvese los parámetros de densidad y contenido de humedad, los que determinan condiciones para determinar el CBR.

## Tabla 4

*Datos recopilados a nivel de la región Huánuco de propiedades mecánicas.*

ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN COORDENADAS GEOGRÁFICAS	MUESTRA DE SUELO	PROPIEDADES MECÁNICAS		
				Proctor Modificado		CBR
				Densidad Seca (gr/cm3)	contenido óptimo de Humedad (%)	

1	Tramo: AMBRAMACHAY - PARASHAPAMPA, APARICIO POMARES, YAROWILCA, HUÁNUCO	<b>Inicio:</b> 76°37'43.59"W, 9°44'11.87"S, 3344; <b>Fin:</b> 76°36'06.16"W, 9°44'31.48"S, 3717 msnm.	C-1	2.190	7.500	39.000
			C-2			
			C-3			
			C-4	2.230	6.400	41.000
2	Tramo: EMP. HU-1076 - COLPAS, COLPAS, AMBO, HUÁNUCO	<b>Inicio:</b> 76°21'25.20"W, 10°17'46.86"S, 2480 msnm; <b>Fin:</b> 76°24'55.3"W, 10°16'05.69"S, 2723 msnm.	C-1	2.210	9.580	25.870
			C-2			
			C-3			
			C-4			
			C-5	2.050	9.110	20.370
			C-6			
			C-7			
			C-8			
			C-9	2.150	10.490	28.560
			C-10			
			C-11			
			C-12			
3	Tramo: EMP. HU-523 (PTA. CARRETERA) - SECTOR ALTO COLOMBIA, LA MORADA, MARAÑÓN, HUÁNUCO	<b>Inicio:</b> 76°14'51.47"W, 8°47'36.73"S, 542 msnm; <b>Fin:</b> 76°19'30.25"W, 8°50'51.11"S, 770 msnm.	C-13	2.060	11.330	19.050
			C-14			
			C-15			
			C-16			
			C-17	2.060	11.120	14.930
			C-1	2.250	6.890	22.930
			C-2			
			C-3			
			C-4			
			C-5	1.840	13.030	10.910
			C-6			
			C-7			
4	Tramo: ALTO MARTHA - SECTOR HOJA GRANDE, LA MORADA, MARAÑÓN, HUÁNUCO	<b>Inicio:</b> 76°14'51.47"W, 8°47'36.73"S, 542 msnm; <b>Fin:</b> 76°20'08.99"W, 8°48'38.97"S, 753 msnm.	C-8	1.870	10.340	8.080
			C-9			
			C-10			
			C-11	1.880	11.960	9.110
			C-1	1.840	12.180	10.290
			C-2			
			C-3			
			C-4			
			C-5	2.140	6.460	21.380
			C-6			
			C-8			
			C-9	2.080	6.960	19.030
			C-10			
			C-11			
			C-12	2.050	8.590	19.920

*Nota:* Se observa puntos sin parámetros mecánicos, significando que solo hay estratigrafía.

#### 4.2.1.2. Variable de salida (target):

Valores de CBRs.

#### 4.2.1.3. Variable de verificación de salida (target):

Valores cualitativos de la litoestratigrafía de la zona de donde se han realizado dichas pruebas incluidas en la data, datos que se evidencian en la figura 13 y la tabla 5.

**Figura 13**

*Propiedades litoestratigráficas del suelo a nivel de subrasante en carreteras*

ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN	MUESTRA DE	PROPIEDADES
				Unidades Litoestratigráficas
1	Tramo: AMBRAMACHAY - PARASHAPAMPA, APARICIO POMARES, YAROWILCA, HUÁNUCO	Inicio: 76°37'43.59"W, 9°44'11.87"S, 3344; Fin: 76°36'06.16"W, 9°44'31.48"S, 3717 msnm.	C-1	Pe-cm2
			C-2	Pe-cm2
			C-3	Pe-cm2
			C-4	Pe-cm2

*Nota:* Se aprecia las características geológicas del suelo en la zona de la toma de muestras.

**Tabla 5**

*Datos de unidades litoestratigráficas del suelo a nivel de subrasante en carreteras*

				PROPIEDADES GEOLÓGICAS
ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN COORDENADAS GEOGRÁFICAS	MUESTRA DE SUELO	Unidades Litoestratigráficas
1	Tramo: AMBRAMACHAY - PARASHAPAMPA, APARICIO POMARES, YAROWILCA, HUÁNUCO	Inicio: 76°37'43.59"W, 9°44'11.87"S, 3344; Fin: 76°36'06.16"W, 9°44'31.48"S, 3717 msnm.	C-1	Pe-cm2
			C-2	Pe-cm2
			C-3	Pe-cm2
			C-4	Pe-cm2
2	Tramo: EMP. HU-1076 - COLPAS, COLPAS, AMBO, HUÁNUCO	Inicio: 76°21'25.20"W, 10°17'46.86"S, 2480 msnm; Fin: 76°24'55.3"W, 10°16'05.69"S, 2723 msnm.	C-1	Ci-a
			C-2	Ci-a
			C-3	Ci-a
			C-4	Ci-a
			C-5	Ci-a
			C-6	Ci-a
			C-7	Ci-a
			C-8	Ci-a
			C-9	Ci-a
			C-10	Ci-a
			C-11	Ci-a
			C-12	Ci-a
			C-13	Ci-a
			C-14	Ci-a
			C-15	Ci-a
			C-16	Ci-a
			C-17	Ci-a
3			C-1	Qh-al

Tramo: EMP. HU-523 (PTA. CARRETERA) - SECTOR ALTO COLOMBIA, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 msnm; Fin: 76°19'30.25"W, 8°50'51.11"S, 770 msnm.	C-2	Qh-al
		C-3	Qh-al
		C-4	Qh-al
		C-5	Qh-al
		C-6	Qh-al
		C-7	Qh-al
		C-8	Qh-al
		C-9	Qh-al
		C-10	Qh-al
		C-11	Qh-al
		C-1	C-gd/to
4 Tramo: ALTO MARTHA - SECTOR HOJA GRANDE, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 msnm; Fin: 76°20'08.99"W, 8°48'38.97"S, 753 msnm.	C-2	C-gd/to
		C-3	C-gd/to
		C-4	NQ-tu
		C-5	NQ-tu
		C-6	NQ-tu
		C-7	NQ-tu
		C-8	NQ-tu
		C-9	Qh-al
		C-10	Qh-al
		C-11	Qh-al
		C-12	Qh-al

*Nota:* La tabla muestra un extracto de los 2270 puntos con su caracterización litoestratigráfica, obtenidos de la INGEMMET- Mapas geológicos de los cuadrángulos de la región Huánuco.

### 4.3.Preprocesamiento

#### 4.3.1. Limpieza de datos

Se procedió a eliminar valores atípicos (outliers) y el manejo técnico de los datos faltantes. Como se observó, de los 2270 puntos correspondientes a Calicatas, no todas ellas tienen los parámetros mecánicos, como son la densidad máxima seca y la humedad optima, parámetros que sirven de datos para la determinación del CBR, sino solamente los parámetros físicos como la granulometría y los límites de Atteberg, por lo que se hace necesario hacer una limpieza de datos, los mismos que se han realizado mediante un algoritmo en PYTHON, que permita solo tener como resultado valores que permitan predecir valores de CBR, a partir de datos físicos y mecánicos, en la figura 14 se observa el algoritmo utilizado y en la tabla 6 los datos obtenidos fruto de este proceso.

**Figura 14**

*Extracto del algoritmo PYTHON utilizado para hacer la limpieza de los outliers*

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import StandardScaler, MinMaxScaler
from sklearn.impute import SimpleImputer

# Cargar la base de datos desde un archivo Excel
ruta_archivo = 'datos_cbr.xlsx' # Cambia esto por la ruta de tu archivo
datos = pd.read_excel(ruta_archivo)

# Mostrar las primeras filas para inspección
print("Datos originales:")
print(datos.head())

# 1. Manejo de valores faltantes
print("\nValores faltantes por columna:")
print(datos.isnull().sum())

# Rellenar valores faltantes con la media (para variables numéricas)
imputador = SimpleImputer(strategy='mean')
datos_imputados = pd.DataFrame(imputador.fit_transform(datos), columns=datos.columns)

# 2. Detección de outliers (valores atípicos)
def detectar_outliers(columna):
    Q1 = columna.quantile(0.25)
    Q3 = columna.quantile(0.75)
```

*Nota:* Proceso mediante el rango intercuartílico (IQR) identificando valores atípicos en las columnas numéricas y los normaliza o estandariza a variables numéricas escalándolas adecuadamente.



Tabla 6

*Extracto de los datos obtenidos luego de la limpieza de datos*

ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN COORDENADAS GEOGRÁFICAS	MUESTRA DE SUELO	PROPIEDADES FÍSICAS						PROPIEDADES MECÁNICAS			PROPIEDADES GEOLÓGICAS
				Granulometría			Límites de Consistencia			Proctor Modificado			Unidades Litoestratigráficas
				% grava	% arena	% limo - arcilla	LL (%)	LP (%)	IP (%)	Densidad Seca (gr/cm3)	contenido óptimo de Humedad (%)	CBR	
1	Tramo: AMBRAMACHAY - PARASHAPAMPA, APARICIO POMARES, YAROWILCA, HUÁNUCO	Inicio: 76°37'43.59"W, 9°44'11.87"S, 3344; Fin: 76°36'06.16"W, 9°44'31.48"S, 3717 msnm.	C-1	18.050	46.220	35.740	NP	NP	NP	2.190	7.500	39.000	Pe-cm2
			C-4	12.750	70.730	16.520	18.330	17.630	0.700	2.230	6.400	41.000	Pe-cm2
2	Tramo: EMP. HU-1076 - COLPAS, COLPAS, AMBO, HUÁNUCO	Inicio: 76°21'25.20"W, 10°17'46.86"S, 2480 msnm; Fin: 76°24'55.3"W, 10°16'05.69"S, 2723 msnm.	C-1	48.910	38.670	12.420	22.420	19.790	2.630	2.210	9.580	25.870	Ci-a
			C-5	41.710	51.880	6.410	24.710	22.920	1.790	2.050	9.110	20.370	Ci-a
			C-9	37.910	37.090	25.000	25.740	18.680	7.060	2.150	10.490	28.560	Ci-a
			C-13	38.970	42.960	18.070	27.850	25.230	2.620	2.060	11.330	19.050	Ci-a
			C-17	23.440	47.980	28.580	30.120	23.550	6.570	2.060	11.120	14.930	Ci-a
3	Tramo: EMP. HU-523 (PTA. CARRETERA) - SECTOR ALTO COLOMBIA, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 msnm; Fin: 76°19'30.25"W, 8°50'51.11"S, 770 msnm.	C-1	47.440	47.030	5.540	NP	NP	NP	2.250	6.890	22.930	Qh-al
			C-5	15.640	23.060	61.300	45.540	36.620	8.920	1.840	13.030	10.910	Qh-al
			C-8	1.310	28.550	70.130	42.100	36.300	5.800	1.870	10.340	8.080	Qh-al
			C-11	1.700	27.980	70.320	47.850	36.120	11.730	1.880	11.960	9.110	Qh-al
4	Tramo: ALTO MARTHA - SECTOR HOJA GRANDE, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 msnm; Fin: 76°20'08.99"W, 8°48'38.97"S, 753 msnm.	C-1	11.480	19.810	68.720	38.280	27.030	11.250	1.840	12.180	10.290	C-gd/to
			C-5	60.960	33.460	5.580	NP	NP	NP	2.140	6.460	21.380	NQ-tu
			C-9	34.950	33.980	31.070	NP	NP	NP	2.080	6.960	19.030	Qh-al
			C-12	57.870	25.800	16.330	NP	NP	NP	2.050	8.590	19.920	Qh-al
5	LLUNGAN-ATAGO-CARACOSMA- CHOGORRAGRA-CUCHIHUASI, DISTRITO DE SAN PEDRO DE CHAULAN - HUÁNUCO- HUÁNUCO	Inicio: 76°29'05.14"W, 10°03'21.52"S, 3560 msnm; Fin: 76°28'09.97"W, 10°05'02.41"S, 3887 msnm.	C-5	97.790	9.300	22.910	NP	NP	NP	1.740	5.700	26.800	Ki-chpt
			C-9	39.490	35.900	24.620	NP	NP	NP	1.880	6.000	7.600	Ki-g
			C-13	42.560	17.010	40.440	45.130	23.400	21.730	1.900	6.180	7.600	Ki-g
6	MEJORAMIENTO DEL CAMINO VECINAL COCHAS - CHACRAS,	Inicio: 76°29'04.77"W, 10°01'01.02"S, 3447 msnm; Fin:	C-1	26.720	51.580	21.710	35.300	31.680	3.620	2.060	7.500	23.160	KP-ca
			C-5	39.220	56.330	4.450	33.830	30.090	3.740	2.090	7.530	23.730	KP-ca
			C-9	4.540	14.560	80.900	NP	NP	NP	1.930	10.730	18.510	KsP-c

7	DISTRITO DE MARGOS, PROVINCIA DE HUÁNUCO	76°30'05.57" <b>W</b> , 10°02'00.86" <b>S</b> , 3730 msnm.	C-13	7.130	37.510	55.370	30.920	26.030	4.890	2.000	9.850	19.270	Q-al
			C-16	13.340	58.270	28.390	NP	NP	NP	1.910	7.250	18.150	Q-al
	MEJORAMIENTO DEL CAMINO VECINAL COLPASHPAMPA - PATAHUASI - RAURA, DISTRITO DE MARGOS, PROVINCIA DE HUÁNUCO	<b>Inicio:</b> 76°31'33.11" <b>W</b> , 10°02'14.98" <b>S</b> , 3598 msnm; <b>Fin:</b> 76°29'42.89" <b>W</b> , 10°04'50.58" <b>S</b> , 3479 msnm.	C-1	0.100	8.050	91.850	20.600	18.980	1.620	1.840	12.080	13.540	KsP-c
			C-5	59.030	36.660	4.310	NP	NP	NP	2.120	8.300	33.730	KsP-c
			C-9	44.830	41.810	13.360	NP	NP	NP	2.120	6.530	30.480	KsP-c
			C-13	35.850	39.230	24.930	NP	NP	NP	2.140	7.100	24.730	KsP-c
			C-17	32.220	32.620	35.160	NP	NP	NP	2.170	6.800	24.000	KsP-c
			C-21	42.490	28.270	29.240	NP	NP	NP	2.190	6.360	29.320	KsP-c
			C-25	28.190	39.820	31.980	35.490	32.170	3.320	2.040	9.440	21.290	KsP-c
			C-29	30.070	29.210	40.720	30.320	28.840	1.480	2.080	7.950	27.310	KsP-c
			C-33	38.410	17.350	44.240	NP	NP	NP	2.180	7.080	29.570	KsP-c
			C-37	15.640	41.580	42.780	21.900	18.570	3.330	2.010	7.950	20.930	Q-al
			C-41	14.200	55.180	30.610	29.460	25.350	4.110	1.940	11.520	19.200	Q-al

*Nota:* Es de precisar que luego de la limpieza de datos se obtuvieron 1356 puntos, que será el total de datos a utilizarse para fines predictivos.

Asimismo, se precisa que se realizaron las siguientes acciones:

#### **4.3.2. Normalización/Estandarización:**

Las redes neuronales funcionan mejor con datos normalizados, por lo que se asignó el escalar entre 0 y 1 o estandarizar con media 0 y desviación estándar 1.

#### **4.3.3. División de datos:**

Se procedió a realizar esta actividad, teniendo en cuenta lo siguiente:

**Conjunto de entrenamiento (training set):** Los datos utilizados para **entrenar el modelo**, se constituyó en el 80%, con la finalidad que el modelo ajuste sus parámetros (pesos y sesgos) para minimizar la función de pérdida (error) en este conjunto. Para la presente investigación luego de la limpieza de datos se obtuvo una muestra de 1356 puntos, de los cuales el 80% es **1084 puntos**.

**Conjunto de Validación (Validation Set):** Se utilizó el 10%, con la finalidad de ajustar los hiperparámetros del modelo y para evaluar su rendimiento durante el entrenamiento. Para la investigación es **135 puntos**.

**Conjunto de Prueba (Test Set):** Utilizado para evaluar el rendimiento final del modelo terminado el entrenamiento y el ajuste de hiperparámetros. Este conjunto simula datos nunca vistos por el modelo. Para la investigación se consideró **137 puntos**.

#### **Validación del modelo:**

Se empleó la técnica de **validación cruzada k-fold**, evaluando el rendimiento de los modelos y asegurar que los resultados no dependan de una partición específica de los datos.

Las métricas de evaluación incluyeron el **R<sup>2</sup>**, el **MSE**, el **MAE** y la **RMSE**.

En ese contexto, La división de los datos se realizó de manera aleatoria, tratando de garantizar que cada conjunto sea representativo de la distribución general de los datos. Este proceso se realizó mediante un algoritmo en Python, cuyo esquema se muestra en la figura 15 y se adjunta en anexos.

**Figura 15**

*Algoritmo que posibilita aleatorizar la división de los datos*

```

1  import pandas as pd
2  from sklearn.model_selection import train_test_split
3
4  # Cargar los datos desde un archivo Excel
5  df = pd.read_excel("datos_cbr.xlsx") # Reemplazar con el nombre correcto del archivo
6
7  # Seleccionar características y variable objetivo
8  features = ["granulometria", "limite_plastico", "limite_liquido", "indice_plastico", "densidad_max_sec", "humedad_optima"]
9  target = "CBR"
10
11 X = df[features] # Variables de entrada
12 y = df[target]   # Variable objetivo
13
14 # División de datos: 80% entrenamiento, 20% restante
15 X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.2, random_state=42)
16
17 # División del 20% restante en 10% validación y 10% prueba
18 X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.5, random_state=42)
19
20 # Verificar la cantidad de datos en cada conjunto
21 print(f"Tamaño del conjunto de entrenamiento: {X_train.shape[0]}")
22 print(f"Tamaño del conjunto de validación: {X_val.shape[0]}")
23 print(f"Tamaño del conjunto de prueba: {X_test.shape[0]}")
24
25 # Guardar los conjuntos en archivos separados (opcional)
26 X_train.to_csv("X_train.csv", index=False)
27 y_train.to_csv("y_train.csv", index=False)
28 X_val.to_csv("X_val.csv", index=False)
29 y_val.to_csv("y_val.csv", index=False)
30 X_test.to_csv("X_test.csv", index=False)
31 y_test.to_csv("y_test.csv", index=False)
32

```

*Nota:* Mediante este algoritmo, se tiene ya la data base, de cada conjunto de datos.

## 4.4. Entrenamiento del modelo

### 4.4.1. Respecto al objetivo específico 1:

**Analizar datos mediante el Machine Learning que influye en el desarrollo de un modelo de predicción del CBR en obras viales en la región Huánuco;** el análisis de los modelos de predicción basado en RNN, ANN, el Random Forest y la Máquina de soporte Vectorial, para pronosticar los valores de CBR, de subrasantes en carreteras, utilizando datos de propiedades físicas, mecánicas como inputs.

Las variables de entrada o predictoras son: Granulometría, Límites de consistencia, Densidad máxima seca y el Contenido de humedad óptimo.

La Variable de salida: Valor del CBR

Para entrenar los modelos de predicción, empleamos el 80% de los 1124 datos, de las variables de entrada (datos provienen de fuentes confiables). En base a esa data, se determinó el modelo optimizado capaz de predecir el valor de CBR con un margen de error mínimo, idealmente inferior al 5%; a partir del cual se amplió la data con datos sintéticos a un volumen de tres veces la inicial.

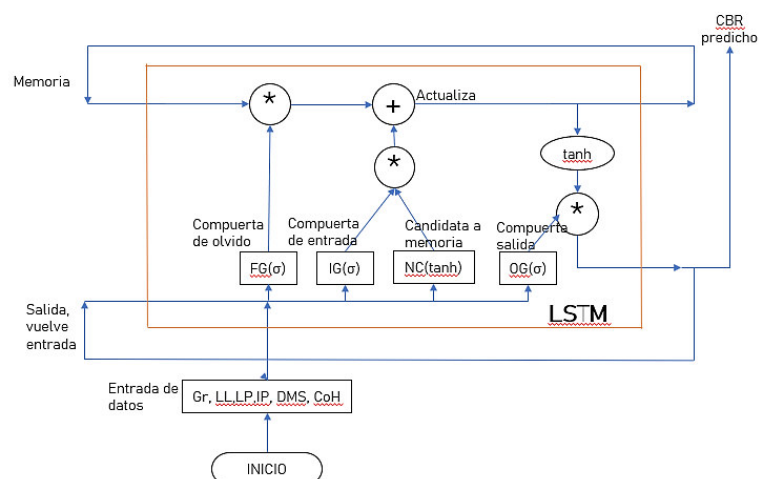
En cuanto a las limitaciones de hardware y software, a pesar de que los modelos RNN, ANN, demandan altos recursos computacionales, al no ser voluminosa la data, fue posible el procesamiento con equipos informáticos convencionales.

#### 4.4.1.1. Entrenamiento Redes Neuronales Recurrentes (Long Short-Term Memory).

Normalizado los datos de entrada mediante **MinMaxScaler** o **StandardScaler**; se estructuró la red mediante la utilización de una capa **LSTM** con varias neuronas, seguida de capas **Dense** y una de salida con activación lineal, se muestra el esquema en la figura 16.

**Figura 16**

*Diagrama de flujo de entrenamiento de una Red Neuronal Recurrente LSTM*



*Nota:* obsérvese el proceso realizado por el modelo para partir de los datos de entrada.

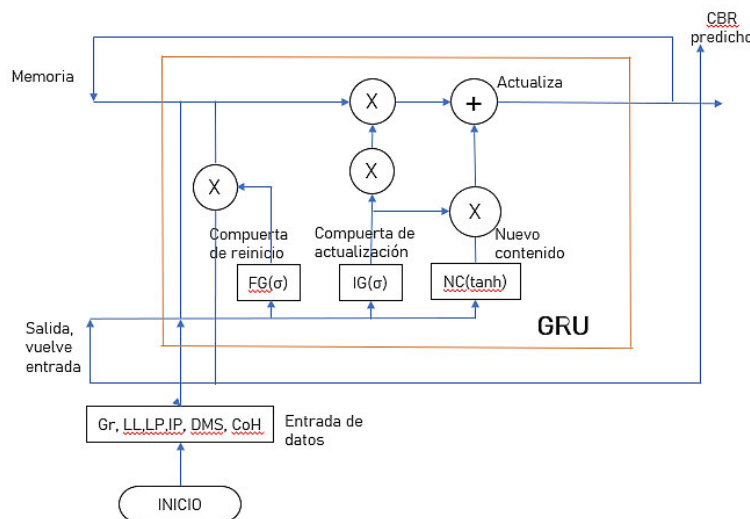
Se empleó **Adam** como optimizador y **MSE** como función de pérdida, el proceso de entrenamiento mediante la alimentación de la red con lotes (**batch\_size** de 32 o 64), se realizó **backpropagation** y **gradient descent** minimizando la pérdida. La evaluación en el conjunto de validación para ajustar hiperparámetros como **learning\_rate**, número de capas y neuronas.

#### 4.4.1.2. Entrenamiento redes neuronales artificiales (Gated Recurrent Unit).

Se estructuró la red usando capas **GRU** en lugar de **LSTM**, lo que reduce el número de parámetros y mejora la eficiencia computacional, se observa el esquema en la figura 17.

**Figura 17**

*Diagrama de flujo de entrenamiento de una Red Neuronal Recurrente GRU*



*Nota:* Se visualiza las acciones que realiza el modelo en el entrenamiento

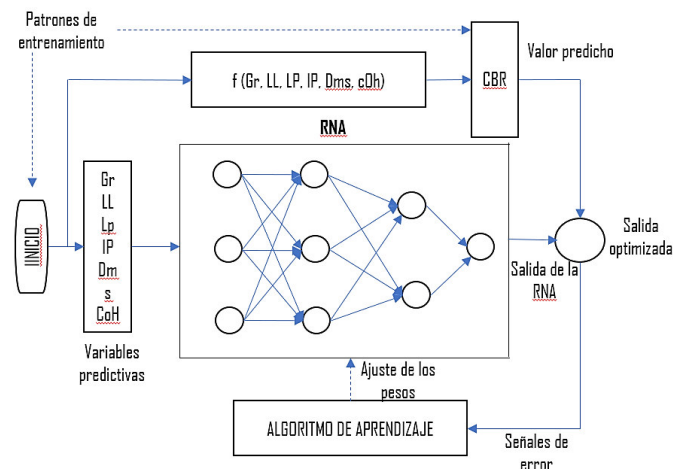
Se empleó **Adam** con **MSE** para minimizar el error en la predicción del CBR; . Realizándose el proceso de entrenamiento con **epochs** adaptativas para evitar sobreajuste, con técnicas como **early stopping**; evaluando el rendimiento en el conjunto de validación para prevenir **overfitting**.

#### 4.4.1.3. Entrenamiento mediante redes neuronales artificiales (ANN)

Luego de realizado el preprocesamiento mediante la Normalización y transformación de los datos, se procedió a estructurar la red mediante varias capas **Dense**, con activación **ReLU** en capas ocultas y **linear** en la salida, en la figura 18, se observa el proceso.

**Figura 18**

*Esquema del proceso de entrenamiento de una Red Neuronal Artificial*



*Nota:* Se evidencia los subprocesos que realiza el modelo en el proceso de entrenamiento.

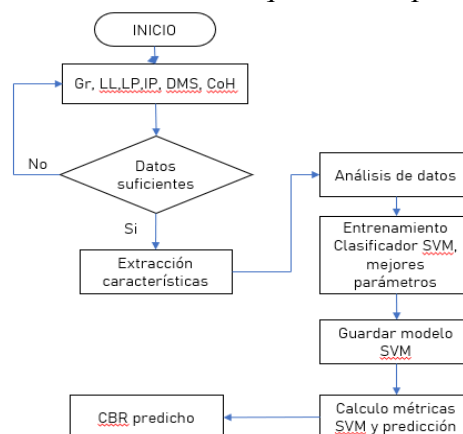
Se optimiza con **Adam**, con **MSE**, ajustando pesos mediante **backpropagation** con **batch\_size** adecuado y **dropout**, evaluando y ajustando hiperparámetros.

#### 4.4.1.4. Entrenamiento mediante Máquina de Soporte Vectorial

En el **preprocesamiento** se normaliza con el **StandardScaler**, se estructuró el modelo con un **SVR**, con kernel **rbf**, **linear** o **poly**. Ajustándose el **C** y **épsilon**, obsérvese la figura 19.

**Figura 19**

*Diagrama de flujo de entrenamiento de una Máquina de Soporte Vectorial (SVM)*



*Nota:* se evidencia en el esquema los subprocesos que realiza este algoritmo.

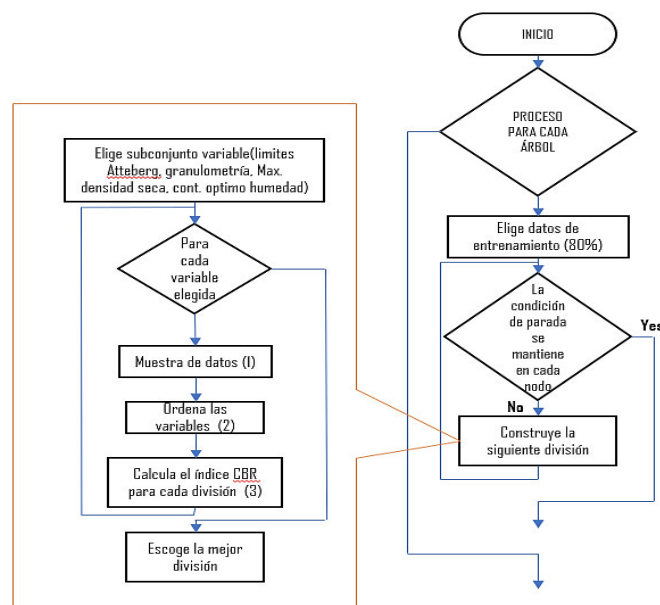
En el proceso de entrenamiento, se realizó la búsqueda de hiperparámetros mediante **GridSearchCV** y **cross-validation**, evaluándose en el conjunto de validación y se compara con otros modelos para ajustar hiperparámetros.

#### 4.4.1.5. Entrenamiento mediante Random Forest

Realizado la Conversión de variables en formato adecuado y verificación de valores atípicos, se estructuró el modelo usando un conjunto de N árboles de decisión con **max\_depth** y **n\_estimators** óptimos, ajustándolos mediante **max\_features**, **min\_samples\_split** y **max\_depth** para mejorar la precisión. El esquema se observa en la figura 20.

**Figura 20**

*Diagrama de flujo de entrenamiento de una Random Forest (RF)*



*Nota:* Se aprecia los subprocesos desde el input hasta el output en el entrenamiento.

Para el entrenamiento se emplearon múltiples árboles con **bootstrap** para mejorar la robustez del modelo, validándose la misma con la medición de la importancia de cada variable en la predicción y se optimizan hiperparámetros mediante **GridSearchCV**.

#### 4.4.2. Respecto al objetivo específico 2:

**Diseñar un sistema de recolección de datos que incide en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco.** A este respecto se ha



generado una INTERFAZ que genera el ingreso de los datos predictores y enlaza los cinco modelos analizados, generando un valor de predicción del CBR óptimo. El código desarrollado en Python es una aplicación web desarrollada con **Flask** que permite realizar predicciones del valor **CBR** utilizando los modelos de Machine Learning estudiados en la presente investigación; además permite visualizar, agregar, editar y eliminar registros de una base de datos SQLite, que a su vez permite descargar la base de datos en formato **CSV**, para generar mayor entrenamiento.

El código se compone de **importaciones de librerías**: Para manejar el modelo, la base de datos y el entorno web. **Carga de datos y modelos**: Se cargan escaladores y modelos preentrenados para realizar predicciones. **Rutas (@app.route)** que manejan las distintas funcionalidades del sistema.

Las librerías importadas son:

```
from flask import Flask, render_template, request, jsonify
from tensorflow.keras.models import load_model
import joblib
import numpy as np
import json
import os
import sqlite3
```

Donde **Flask**, permite crear la aplicación web; **load\_model**, cargar modelos entrenados de **TensorFlow/Keras**; **joblib**, permite cargar modelos de **Random Forest**, **SVM**, o escaladores; **numpy**, para manipulación de arreglos numéricos y **qlite3**, para la gestión de la base de datos SQLite.

Luego se procede a inicializar la aplicación, mediante el código `app = Flask(__name__)`; asimismo se hace importante cargar el orden de columnas con:

with open("column\_order.json") as f:

column\_order = json.load(f)

La página principal muestra (**index.html**) de la aplicación; la ruta/predecir recibe datos del usuario a través de un formulario HTML y el parámetro "modelo" indica qué modelo se utilizará para la predicción. Es necesario recordar que los modelos disponibles para la predicción son las ya entrenadas la red neuronal artificial ANN, la red neuronal recurrente LSTM, la red neuronal recurrente GRU, los algoritmos Random Forest y la Máquina de soporte vectorial. Es de precisar que cada modelo utiliza sus propios escaladores para normalizar los datos de entrada y salida. Asimismo, se precisa que la gestión de la Base de Datos (SQLite) están establecidas mediante rutas que permiten manipular la base de datos:

/datos → Muestra los registros almacenados.

/guardar → Guarda un nuevo registro.

/eliminar/<int:id> → Elimina un registro por su ID.

/editar/<int:id> → Edita un registro existente.

/descargar\_csv → Descarga los registros en formato **CSV**.

En síntesis, el flujo del sistema precisa que primeramente el usuario accede a la interfaz web; selecciona un modelo e ingresa los valores de entrada (datos predictores); el sistema recibe estos datos, los normaliza y los envía al modelo seleccionado; el modelo genera un valor predicho para el **CBR**; el sistema responde con el valor estimado y un mensaje de éxito o error; finalmente el usuario guarda el registro en la base de datos, editarlo o eliminarlo según sea necesario.

#### **4.4.3. Respecto al objetivo específico 3:**

**Analizar el grado precisión en proyectos reales que permita validar el modelo de predicción del CBR en obras viales en la región Huánuco.** Se ha desarrollado en amplitud en el punto 5.2. de la presente investigación, donde se evidencia las bondades desde el punto

de vista de precisión y confiabilidad por cada uno de los cinco modelos, los mismos que han sido entrenados en base a datos reales de propiedades físicas y mecánicas; de la misma forma se podrá verificar en el INTERFAZ creado como parte del objetivo específico 2, el grado de confiabilidad y precisión con respecto a nuevos datos que se ingresen y su correspondiente generación del valor de CBR.

#### **4.4. Procesamiento de Datos**

El procesamiento de datos realizados fue con procesos específicos para cada tipo de red y algoritmo, como se describe:

##### **4.4.1. Red Neuronal ANN**

###### **4.4.1.1. Carga y limpieza de datos**

El primer paso es la importación del dataset:

**python**

**CopiarEditar**

```
file_path = "data/Datos_Sinteticos_Triplicado_CBR.csv"
```

```
df = pd.read_csv(file_path)
```

###### **4.4.1.2. Conversión y Limpieza**

La columna **CBR** se convierte explícitamente a tipo **float** mediante la función **pd.to\_numeric()** para manejar posibles valores erróneos o inconsistentes.

Se emplea la opción **errors='coerce'** que permite convertir datos no válidos en valores NaN.

```
df["CBR"] = pd.to_numeric(df["CBR"], errors='coerce')
```

```
df = df.dropna()
```

Este paso garantiza que solo se consideren muestras válidas para el entrenamiento, reduciendo el riesgo de sesgos o inconsistencias derivadas de datos anómalos.

###### **4.4.1.3. Balanceo del conjunto de datos**

El conjunto de datos se enriquece aplicando un **sobremuestreo selectivo** para mejorar la representación de las clases minoritarias.

Se seleccionan los registros con valores de CBR **menores a 10** (suelos débiles) y mayores a **30** (suelos muy resistentes).

Posteriormente, se concatenan estas muestras adicionales con el dataset original.

```
low_cbr = df[df["CBR"] < 10]
```

```
high_cbr = df[df["CBR"] > 30]
```

```
df_balanced = pd.concat([df, low_cbr, high_cbr], axis=0).reset_index(drop=True)
```

Este procedimiento introduce un enfoque estratégico para mitigar el desequilibrio de clases y optimizar el rendimiento predictivo del modelo, especialmente en los rangos extremos del CBR.

#### **4.4.1.4. Data Augmentation Inteligente**

Dado que los datos para entrenar una red neuronal suelen requerir robustez frente a fluctuaciones naturales, se implementa un método de **Data Augmentation** basado en la adición de ruido gaussiano.

Se genera un conjunto de datos adicional al sumar perturbaciones aleatorias siguiendo una distribución normal:

$$X_{augmented} = X_{balanced} + N(0, 0.005)X_{augmented} = X_{balanced} + \mathcal{N}(0, 0.005)$$

```
df_augmented = df_balanced.copy()
```

```
df_augmented += np.random.normal(0, 0.005, df_augmented.shape)
```

```
df = pd.concat([df_balanced, df_augmented], axis=0).reset_index(drop=True)
```

Este enfoque simula pequeñas variaciones inherentes a la medición del CBR en campo, mejorando así la capacidad del modelo para generalizar en condiciones reales.

#### **4.4.1.5. División del conjunto de datos**

El dataset es dividido utilizando el método **train\_test\_split()** en tres subconjuntos clave:

- A. *Entrenamiento* (80% del total)
- B. *Validación* (10% del total)
- C. *Prueba* (10% del total), utilizándose el siguiente código:

```
X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.2,
random_state=42)

X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.5,
random_state=42)
```

Este enfoque reduce el riesgo de sobreajuste, asegurando que el modelo se evalúe en datos no vistos durante el entrenamiento.

#### 4.4.1.6. Transformación para la arquitectura RNN(GRU)

Dado que la red neuronal emplea una arquitectura híbrida ANN-GRU, es necesario reformatear las matrices de entrada.

El reshape transforma las matrices de entrada a un formato tridimensional con la forma **(n\_samples, 1, n\_features)**, requisito técnico para el módulo GRU, codificándose:

```
X_train_rnn = X_train.reshape((X_train.shape[0], 1, X_train.shape[1]))
X_val_rnn = X_val.reshape((X_val.shape[0], 1, X_val.shape[1]))
X_test_rnn = X_test.reshape((X_test.shape[0], 1, X_test.shape[1]))
```

Esta transformación convierte cada muestra en una secuencia temporal de un solo paso, permitiendo que la GRU capture patrones temporales y relacionales en los datos.

#### 4.4.1.7. Normalización y escalamiento

Aunque no se evidencia explícitamente en el código, el empleo de **BatchNormalization()** durante la fase de modelado actúa indirectamente como una técnica de normalización dinámica. Esta operación mejora la estabilidad del entrenamiento y facilita la convergencia rápida del modelo.

#### 4.4.1.8. Manejo de overfitting

Para evitar el sobreajuste durante el entrenamiento, se implementan las siguientes estrategias avanzadas:

A. ***Dropout()***:

Introduce un mecanismo de regularización mediante la desactivación aleatoria de neuronas en cada iteración.

B. ***EarlyStopping()***:

Finaliza el entrenamiento cuando la mejora en el conjunto de validación se estabiliza.

C. ***ReduceLROnPlateau()***:

Reduce dinámicamente la tasa de aprendizaje si la mejora en la pérdida es mínima durante un número determinado de épocas. Codificandose:

```
early_stopping = EarlyStopping(monitor='val_loss', patience=200,
restore_best_weights=True)

reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.5, patience=100,
min_lr=1e-6)
```

#### 4.4.1.9. Codificación de la variable objetivo (CBR)

El modelo se construye para predecir valores continuos de CBR, por lo que la variable objetivo no se transforma en categorías discretas. Esto es adecuado para tareas de regresión.

#### 4.4.1.10. Evaluación y Métricas

El desempeño del modelo se mide utilizando tres métricas clave:

- A. ***MSE (Error Cuadrático Medio)***: Evalúa la magnitud promedio del error.
- B. ***RMSE (Raíz del Error Cuadrático Medio)***: Mide la dispersión del error con mayor sensibilidad a valores extremos.
- C. ***R<sup>2</sup> (Coeficiente de Determinación)***: Evalúa la capacidad explicativa del modelo respecto a la variabilidad de los datos. Los mismos que se codifica como:

```
mse = mean_squared_error(y_test, y_pred)
```

```
rmse = np.sqrt(mse)
```

```
r2 = r2_score(y_test, y_pred)
```

#### 4.4.1.11. Visualización avanzada

Las visualizaciones implementadas permiten evaluar el comportamiento del modelo de manera exhaustiva, **Curvas de entrenamiento** para identificar patrones de convergencia; **Gráfico Real vs. Predicho** que facilita la inspección visual de la precisión del modelo y **Matriz de correlación** para explorar la relación entre variables predictoras y el CBR.

### 4.5. Presentación de Resultados

Los resultados obtenidos se detallan por cada tipo de red neuronal y algoritmo utilizado, las mismas que se detallan:

#### 4.5.1. Red Neuronal artificial ANN

Las tablas 7, 8 y 9 muestran los valores de las métricas obtenidas del modelo de ANN

##### 4.5.1.1. Métricas de desempeño del modelo con datos normalizados

**Tabla 7**

*Métricas del modelo red neuronal artificial ANN para datos normalizados*

<b>Métrica</b>	<b>Valor</b>
MSE	9.7407
RMSE	3.1210
MAE	1.6463
R <sup>2</sup>	0.9174

##### 4.5.1.2. Métricas de desempeño del modelo con datos ampliados aleatorizados

**Tabla 8**

*Métricas del modelo red neuronal artificial ANN para datos aleatorizados*

<b>Métrica</b>	<b>Valor</b>
MSE	2.6770
RMSE	1.6362
MAE	0.8943
R <sup>2</sup>	0.9777

#### 4.5.1.3. Métricas de desempeño del modelo con datos ampliados sintetizados

**Tabla 9**

*Métricas del modelo red neuronal artificial ANN para datos sintetizados*

<b>Métrica</b>	<b>Valor</b>
MSE	1.9198
RMSE	1.3856
MAE	0.8195
R <sup>2</sup>	0.9848

#### 4.5.1.4. Parámetros óptimos del Modelo

La tabla 10, muestra los parámetros óptimos del modelo de ANN.

**Tabla 10**

*Parámetros óptimos resultado del Modelo ANN de predicción.*

<b>Parámetros óptimos del modelo</b>	<b>Valor</b>
Numero de épocas	430
Tasa de aprendizaje final	$1 \times 10^{-41} \times 10^{-4} \times 1 \times 10^{-4}$
Neuronas en la capa GRU	64
Dropout	0.3
Activación final	Lineal
Función de pérdida	MSE

#### 4.5.2. Red Neuronal Recurrente LSTM (RNN-LSTM)

Las tablas 11, 12 y 13 muestran las métricas obtenidas para el modelo RNN-LSTM

##### 4.5.2.1. Métricas de desempeño del modelo con datos normalizados

**Tabla 11**

*Métricas del modelo red neuronal recurrente RNN-LSTM para datos normalizados*

<b>Métrica</b>	<b>Valor</b>
MSE	15.4391
RMSE	4.5632
MAE	3.1254
R <sup>2</sup>	0.8024

##### 4.5.2.2. Métricas de desempeño del modelo con datos ampliados aleatorizados



**Tabla 12**

*Métricas del modelo red neuronal recurrente RNN-LSTM para datos aleatorizados*

<b>Métrica</b>	<b>Valor</b>
MSE	14.8721
RMSE	3.8943
MAE	2.5872
R <sup>2</sup> (Coeficiente de Determinación)	0.8356

#### 4.5.2.3. Métricas de desempeño del modelo con datos ampliados sintetizados

**Tabla 13**

*Métricas del modelo red neuronal recurrente RNN-LSTM para datos sintetizados*

<b>Métrica</b>	<b>Valor</b>
MSE	13.7961
RMSE	3.7143
MAE	2.2976
R <sup>2</sup>	0.8543

#### 4.5.2.4. Parámetros óptimos del Modelo

En la tabla 14 se evidencia los parámetros óptimos del modelo RNN-LSTM.

**Tabla 14**

*Parámetros óptimos resultado del Modelo RNN-LSTM de predicción.*

<b>Parámetros óptimos del modelo</b>	<b>Valor</b>
Numero de épocas	640
Tasa de aprendizaje final	$1 \times 10^{-38} \times 10^{-3}$
Neuronas en la capa GRU	112
Dropout	0.2
Activación final	Lineal
Función de pérdida	MSE

#### 4.5.3. Red Neuronal Recurrente GRU (RNN-GRU)

Las tablas 15, 16 y 17 muestran los valores de las métricas para este modelo.

##### 4.5.3.1. Métricas de desempeño del modelo con datos normalizados

**Tabla 15**

*Métricas del modelo red neuronal recurrente RNN-GRU para datos normalizados*

<b>Métrica</b>	<b>Valor</b>
MSE	18.3425
RMSE	5.3465
MAE	3.3287
R <sup>2</sup>	0.7834

#### 4.5.3.2. Métricas de desempeño del modelo con datos ampliados aleatorizados

**Tabla 16**

*Métricas del modelo red neuronal recurrente RNN-GRU para datos aleatorizados*

<b>Métrica</b>	<b>Valor</b>
MSE	14.7345
RMSE	3.8386
MAE	2.3965
R <sup>2</sup>	0.8322

#### 4.5.3.3. Métricas de desempeño del modelo con datos ampliados sintetizados

**Tabla 17**

*Métricas del modelo red neuronal recurrente RNN-GRU para datos sintetizados*

<b>Métrica</b>	<b>Valor</b>
MSE	13.2999
RMSE	3.6469
MAE	2.4646
R <sup>2</sup>	0.8613

#### 4.5.3.4. Parámetros óptimos del Modelo

De la misma forma la tabla 18 muestra los parámetros óptimos del modelo.

**Tabla 18**

*Parámetros óptimos resultado del Modelo RNN-GRU de predicción.*

<b>Parámetros óptimos del modelo</b>	<b>Valor</b>
Numero de épocas	646
Tasa de aprendizaje final	$1 \times 10^{-37} \times 10^{-3} \times 1 \times 10^{-3}$
Neuronas en la capa GRU	112(3 capas)

Dropout	0.2
Activación final	Lineal
Función de pérdida	MSE

#### 4.5.4. *Ramdom Forest (RF)*

Las tablas 19, 20 y 21, muestran las métricas obtenidas luego del entrenamiento del modelo

##### 4.5.4.1. Métricas de desempeño del modelo con datos normalizados

**Tabla 19**

*Métricas del modelo algorítmico Ramdom Forest (RF) para datos normalizados*

<b>Métrica</b>	<b>Valor</b>
MSE	10.4351
RMSE	4.3124
MAE	2.9156
$R^2$	0.7943

##### 4.5.4.2. Métricas de desempeño del modelo con datos ampliados aleatorizados

**Tabla 20**

*Métricas del modelo algorítmico Ramdom Forest (RF) para datos aleatorizados*

<b>Métrica</b>	<b>Valor</b>
MSE	5.5328
RMSE	2.3522
MAE	1.5224
$R^2$	0.9370

##### 4.5.4.3. Métricas de desempeño del modelo con datos ampliados sintetizados

**Tabla 21**

*Métricas del modelo algorítmico Ramdom Forest (RF) para datos sintetizados*

<b>Métrica</b>	<b>Valor</b>
MSE	9.3821
RMSE	3.0630
MAE	2.0402
$R^2$	0.8927

##### 4.5.4.4. Parámetros óptimos del Modelo

La tabla 22 muestra los parámetros óptimos del modelo.

**Tabla 22**

*Parámetros óptimos resultado del Modelo de Random Forest (RF).*

<b>Parámetros óptimos del modelo</b>	<b>Valor</b>
Numero de arboles	300
Profundidad máxima	30
Mínimo de muestras para dividir un nodo	5
Mínimo de muestras en las hojas	5
Número de Entrenamientos (Fits)	720
Total, combinaciones posibles	144

#### **4.5.5. Máquina de Soporte Vectorial (MSV)**

Las tablas 23, 24 y 25 muestran las métricas obtenidas luego del entrenamiento

##### **4.5.5.1. Métricas de desempeño del modelo con datos normalizados**

**Tabla 23**

*Métricas del modelo algorítmico SVM para datos normalizados*

<b>Métrica</b>	<b>Valor</b>
MSE	3.8543
RMSE	2.9467
MAE	1.8954
$R^2$	0.8145

##### **4.5.5.2. Métricas de desempeño del modelo con datos ampliados aleatorizados**

**Tabla 24**

*Métricas del modelo algorítmico SVM para datos aleatorizados*

<b>Métrica</b>	<b>Valor</b>
MSE	4.7020
RMSE	2.1684
MAE	1.1729
$R^2$	0.9465

##### **4.5.5.3. Métricas de desempeño del modelo con datos ampliados sintetizados**

**Tabla 25**

*Métricas del modelo algorítmico SVM para datos sintetizados*

<b>Métrica</b>	<b>Valor</b>
MSE	6.7541
RMSE	2.5928
MAE	1.6388
$R^2$	0.9228

#### 4.5.5.4. Parámetros óptimos del Modelo

La tabla 26 muestra los parámetros óptimos del modelo.

**Tabla 26**

*Parámetros óptimos del algoritmo SVM de predicción.*

<b>Parámetros óptimos del modelo</b>	<b>Valor</b>
Parámetro de penalización (C)	1000
Tolerancia error función de pérdida	0.20
Kernel (gamma)	1
kernel "rbf" (Radial Basis Function)	No lineal
Valor de entrenamiento (fits)	500

## V. DISCUSIÓN DE RESULTADOS

### 5.1. Análisis descriptivo

#### 5.1.1. Análisis de la base de datos inicial

Es importante tener en cuenta, un análisis inicial de la base de datos tal como se pudo recopilar de la fuente de información, para ello consideramos algunos aspectos importantes:

##### 5.1.1.1 Valores de CBR a lo largo de los diferentes proyectos:

##### Análisis de Datos


**Promedio de CBR:** El valor promedio de CBR entre los proyectos es de 20.23, con una desviación estándar de 10.10.

**Rango de CBR:** Los valores de CBR varían de 5.01 a un máximo de 42.30.

**Proyectos Destacados:** proyectos como "Tramo I: Emp. PE-18b Purupampa - Emp. Huascapampa, Panao, Pachitea, Huánuco" tienen un promedio de CBR alto de 34.81. En el gráfico 21 se evidencia estos resultados.

**Figura 21**

*Diagrama de barras de valores CBR en el universo de proyectos*



*Nota:* Se evidencia la variabilidad de valores de CBRs a nivel de los proyectos analizados

### **Visualización de la Tendencia**

**Distribución Visual:** El gráfico muestra una variabilidad significativa en los valores promedio de CBR entre los proyectos.

**Patrones Observados:** No hay un patrón claro de aumento o disminución en los valores de CBR; los valores parecen distribuidos de manera desigual.

### **Conclusiones:**

**Variabilidad Significativa:** Existe una amplia variabilidad en los valores de CBR entre los diferentes proyectos, lo que sugiere diferencias en las condiciones o métodos de construcción.

**Proyectos con CBR Alto:** Algunos proyectos presentan valores de CBR significativamente más altos, lo que podría indicar mejores condiciones del suelo o técnicas de construcción más efectivas.

**5.1.1.2. Variabilidad en el contenido de humedad óptimo a la correlación entre el porcentaje de grava y los valores de CBR.**

### **Preprocesamiento de Datos**

**Conversión de datos:** Las columnas relacionadas con granulometría, contenido de humedad y CBR se convirtieron a tipos numéricos.

**Manejo de valores faltantes:** Los valores faltantes se llenaron con la media de cada columna.


### **Análisis de Correlación**

**Rangos de contenido de humedad:** Se segmentó el contenido de humedad en rangos: '0-5%', '5-10%', '10-15%', '15-20%', y '20%+'.

**Correlación observada:** La correlación entre el porcentaje de grava y los valores de CBR varía entre 0.24 y 0.36, aumentando con el contenido de humedad. En el gráfico 22 se observa este comportamiento.

**Figura 22**

*Correlación con respecto al rango de contenido de humedad*



*Nota:* se observa que el rango de contenido de humedad tiene mayor incidencia a partir del 15%.

### **Visualización de Resultados**

**Gráfico de correlación:** La visualización muestra que la correlación es más fuerte en los rangos de humedad más altos ('15-20%' y '20%+').

### **Conclusión**

**Aumento de correlación con humedad:** La correlación entre el porcentaje de grava y los valores de CBR aumenta con el contenido de humedad óptimo, siendo más fuerte en los rangos de humedad más altos.

**Importancia del contenido de humedad:** La variabilidad en el contenido de humedad es un factor clave que afecta la relación entre las propiedades físicas y mecánicas del suelo.

**5.1.1.3. Influencia del porcentaje de Limo-Arcilla en los valores de CBR en comparación con el porcentaje de Arena**

### **Relación entre limo-arcilla y CBR**

**Promedio de limo-arcilla:** 34.76% con una desviación estándar de 23.82.



**Promedio de CBR asociado:** 19.10 con una desviación estándar de 9.89.

**Datos de muestra:** incluyen un porcentaje de limo-arcilla de 35.74% con un CBR de 39.0. En la figura 23 se observa estas tendencias.

### **Relación entre arena y CBR**

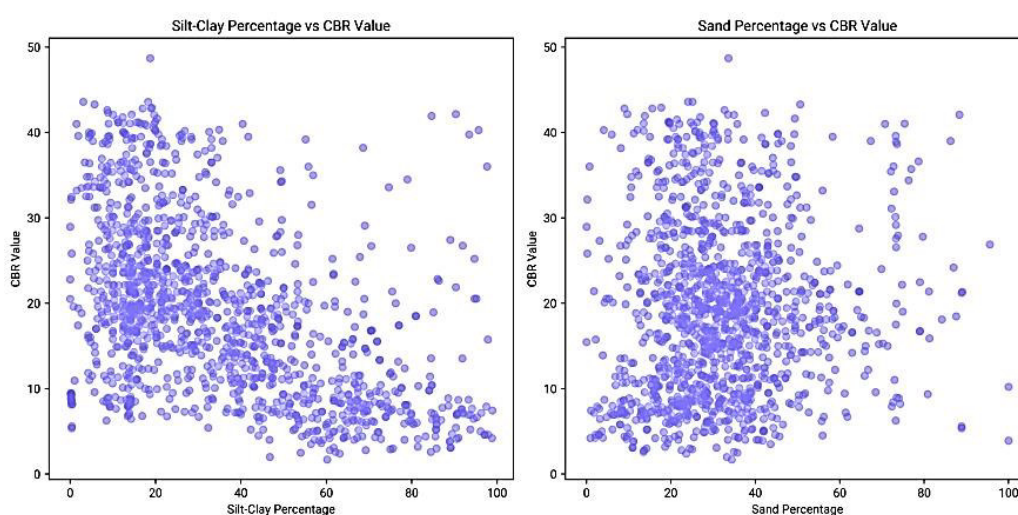
**Promedio de arena:** 32.11% con una desviación estándar de 15.65.

**Promedio de CBR asociado:** 19.08 con una desviación estándar de 9.90.

**Datos de muestra:** incluyen un porcentaje de arena de 46.22% con un CBR de 39.0.

**Figura 23**

*Influencia granulométrica en los valores de CBR*



*Nota:* se observa la influencia significativa del limo-arcilla y la arena en los valores del CBR, aunque sin una correlación clara.

### **Relación entre limo-arcilla y CBR**

**Promedio de limo-arcilla:** 34.76% con una desviación estándar de 23.82.

**Promedio de CBR asociado:** 19.10 con una desviación estándar de 9.89.

**Datos de muestra:** Ejemplos incluyen un porcentaje de limo-arcilla de 35.74% con un CBR de 39.0.

### **Relación entre arena y CBR**

**Promedio de arena:** 32.11% con una desviación estándar de 15.65.

***Promedio de CBR asociado:*** 19.08 con una desviación estándar de 9.90.

***Datos de muestra:*** incluyen un porcentaje de arena de 46.22% con un CBR de 39.0.

### **Visualización de la influencia**

***Gráfico de limo-arcilla vs CBR:*** Muestra una dispersión amplia, sugiriendo una relación no lineal clara.

***Gráfico de arena vs CBR:*** También muestra una dispersión amplia, sin una correlación evidente.

### **Conclusiones:**

***Relación no lineal:*** Ambos porcentajes de limo-arcilla y arena muestran una amplia dispersión en relación con los valores de CBR, indicando que no hay una correlación lineal fuerte.

***Variabilidad en CBR:*** La variabilidad en los valores de CBR es similar para ambos tipos de suelo, sugiriendo que otros factores influyen significativamente en los valores de CBR.

#### **5.1.1.4. Valores atípicos de CBR en la distribución general**

##### **Identificación de Valores Atípicos**

Media de CBR: 48.70

Desviación estándar de CBR: 15.03

***Valores atípicos identificados:*** Los valores con un Z-score mayor a 3 se consideran atípicos. Los proyectos con valores de CBR atípicos son:

Proyecto 59.0: CBR = 56.1, Z-score = 3.27

Proyecto 60.0: CBR = 54.4, Z-score = 3.12

Proyecto 62.0: CBR = 54.9, Z-score = 3.16

Proyecto 63.0: CBR = 71.2, Z-score = 4.62

Proyecto 69.0: CBR = 87.5, Z-score = 6.08

Proyecto 70.0: CBR = 69.1, Z-score = 4.43

Proyecto 71.0: CBR = 98.5, Z-score = 7.07

Proyecto 73.0: CBR = 75.0, Z-score = 4.96

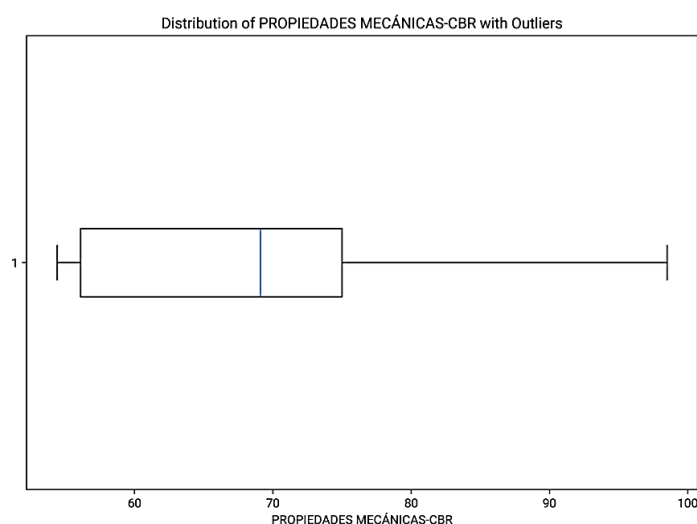
Proyecto 105.0: CBR = 68.93, Z-score = 4.42

### Visualización de la Distribución

**Gráfico de caja:** Muestra la distribución de los valores de CBR, destacando los valores atípicos que se encuentran fuera del rango intercuartílico. Como se observa en la figura 24.

**Figura 24**

*Valores atípicos en la muestra respecto al CBR*



*Nota:* Obsérvese valores aparentemente atípicos, sin embargo, hay que tener en cuenta que el valor  $> 40$  no necesariamente signifique que está mal, sino de un suelo muy gravoso.

### **5.1.1.5. Variación de los valores de CBR entre diferentes unidades litoestratigráficas**

#### Análisis estadístico de los valores de CBR

**Media de CBR:** La media de los valores de CBR entre las unidades litoestratigráficas es de 18.22, con un rango que va desde 5.92 hasta 48.70.

**Mediana de CBR:** La mediana es de 17.83, con mínimo de 4.90 y un máximo de 48.70.

**Desviación estándar de CBR:** La desviación estándar promedio es de 6.84, indicando

variabilidad en los valores de CBR entre las unidades.


### **Visualización de la variación de CBR**

**Distribución visual:** El gráfico muestra cómo los valores de CBR (media, mediana y desviación estándar) varían entre las diferentes unidades litoestratigráficas.

**Rango de variación:** Se observa una amplia variación en los valores de CBR, con valores significativamente más altos o más bajos, como se observa en la figura 25.

**Figura 25**

*Variabilidad del valor del CBR con respecto a la litoestratigrafía*



*Nota:* Se observa por grupos geológicos como varía el valor del CBR.

### **Conclusiones:**

**Variabilidad significativa:** Existe una variabilidad significativa en los valores de CBR entre las diferentes unidades litoestratigráficas.

#### **5.1.1.6. Valores de CBR en diferentes regiones geográficas**

##### **Análisis de datos**

**Promedio de CBR:** El valor promedio de CBR es 20.86, desviación estándar de 11.07.

**Rango de CBR:** Los valores de CBR varían desde 5.01 hasta un máximo de 48.92.


**Muestra de datos:** Para las ubicaciones geográficas y sus valores promedio de CBR:

Ubicación: 74°42'25.05"W, 8°46'17.03"S, 158 msnm; CBR: 5.01

Ubicación: 75°29'32.02"W, 9°52'14.27"S, 3797 msnm; CBR: 34.2, obsérvese este comportamiento en la figura 26.

**Figura 26**

*Valores del CBR por zonas de ubicación geográficas*



*Nota:* Obsérvese que existe variabilidad del valor del CBR.

### **Visualización de datos**

**Distribución visual:** El gráfico de líneas muestra una variación significativa en los valores promedio de CBR entre diferentes regiones geográficas.

**Patrones observados:** Algunas regiones presentan valores de CBR consistentemente altos, mientras que otras tienen valores más bajos.

### **Conclusión**

**Variabilidad regional:** Existe una considerable variabilidad en los valores de CBR entre las diferentes regiones geográficas, lo que sugiere que las propiedades mecánicas del suelo varían significativamente según la ubicación.

#### **5.1.1.7. Tendencia de la Densidad Seca Máxima para diferentes proyectos**

### **Análisis de Datos**

**Promedio de Densidad Seca Máxima:** La media de la densidad seca máxima es de 2.01



evaluación de las propiedades mecánicas, su variabilidad influye en la calidad y durabilidad.

#### 5.1.1.8. Valores de Densidad Seca a lo largo de diferentes ubicaciones geográficas

##### Análisis de Datos

**Promedio de Densidad Seca:** La media de la densidad seca es de  $2.04 \text{ gr/cm}^3$ , con una desviación estándar de 0.44.

**Rango de Densidad Seca:** Los valores oscilan entre 1.26 y  $6.17 \text{ gr/cm}^3$ .

**Muestra de Datos:** Las ubicaciones muestran densidades secas promedio que varían desde 1.569 hasta  $2.186 \text{ gr/cm}^3$ .


##### Visualización de la Tendencia

**Patrón General:** La mayoría de las ubicaciones tienen valores de densidad seca alrededor de  $2 \text{ gr/cm}^3$ .

**Variaciones Notables:** Hay picos significativos en ciertas ubicaciones, con un valor máximo cercano a  $6 \text{ gr/cm}^3$ , como se evidencia en la figura 28.

**Figura 28**

*Variabilidad de la Máxima densidad seca con respecto a su ubicación geográfica*



##### Conclusión

**Consistencia General:** La densidad seca es relativamente consistente en la mayoría de

las ubicaciones, con algunas excepciones.

### 5.1.1.9. Correlación entre los Límites de Consistencia y los valores de CBR

#### Cálculo de la Correlación

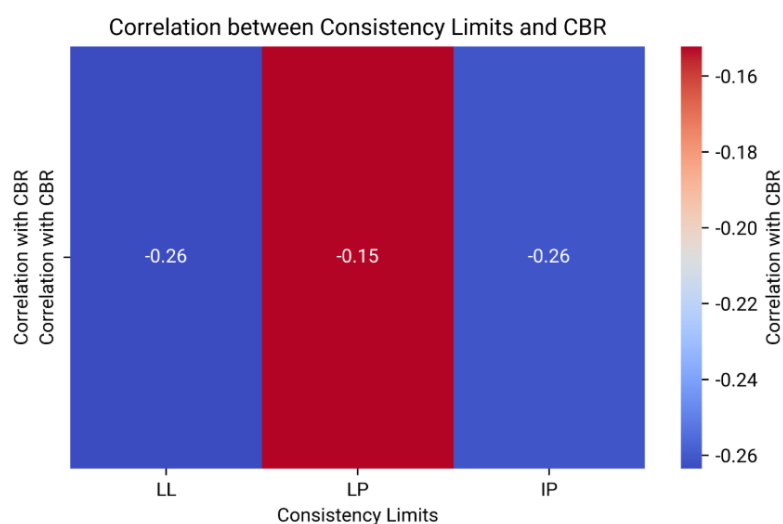
**Límite Líquido:** La correlación con el CBR es de -0.26, relación negativa moderada.

**Límite Plástico:** La correlación con el CBR es de -0.15, relación negativa más débil.

**Índice de Plasticidad:** La correlación con el CBR es de -0.26, similar al LL, también indicando una relación negativa moderada. Estos valores se observan en la figura 29.

**Figura 29**

*Correlación entre los límites de consistencia y el valor de CBR*



#### Visualización de la Correlación

**Visualización:** Se observa las correlaciones negativas entre los límites de consistencia (LL, LP, IP) y los valores de CBR, con LL e IP teniendo correlaciones más fuertes que LP.

#### Conclusiones:

**Relación Negativa:** Los límites de consistencia tienen una correlación negativa con los valores de CBR, lo que sugiere que a medida que aumentan los límites de consistencia, los valores de CBR tienden a disminuir.

**Importancia de LL e IP:** El Límite Líquido y el Índice de Plasticidad influyen similar y significativamente en los valores de CBR, en comparación con el Límite Plástico.



### 5.1.1.10. Variación de los valores de CBR con diferentes porcentajes de Grava

#### Análisis de datos

**Porcentaje de grava:** La media es del 36.25% con un rango de 0% a 100%.

**CBR medio:** La media es de 19.59 con un rango de 1.70 a 48.70.

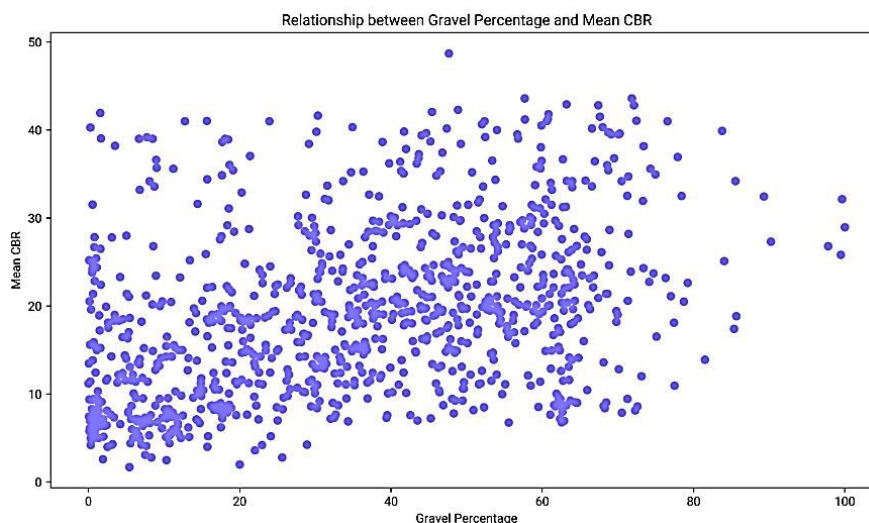
#### Visualización de la relación

**Distribución:** La gráfica de dispersión muestra una amplia variabilidad en los valores de CBR para diferentes porcentajes de grava.

**Tendencia general:** No hay una clara tendencia lineal entre el porcentaje de grava y el CBR, indicando que otros factores influyen en los valores de CBR. Obsérvese la figura 30.

**Figura 30**

*Relación de la proporción de grava con el CBR.*



#### Conclusiones:

**Variabilidad:** Los valores de CBR muestran una alta variabilidad con diferentes porcentajes de grava, sugiriendo que la relación no es directamente proporcional.

### 5.1.1.11. Variabilidad en el porcentaje de Arena a la consistencia de los suelos, considerando los Límites Líquidos y Plásticos

#### Análisis estadístico

Media del porcentaje de arena: 32.30%

Desviación estándar del porcentaje de arena: 15.90%


Correlación con LL (%): -0.16, indicando una relación negativa débil.

Correlación con LP (%): -0.11, también mostrando una relación negativa débil.

Correlación entre LL (%) y LP (%): 0.77, lo que sugiere una fuerte relación positiva entre los límites líquidos y plásticos. Obsérvese la figura 31.

**Figura 31**

*Correlación de los límites de Atterberg con respecto a la presencia de la arena*



*Nota:* se evidencia la correlación inversa entre los límites de consistencia y la arena

### **Visualización de la relación**

**Gráfico LL (%) vs % arena:** Muestra una dispersión de puntos que sugiere una relación negativa débil entre el porcentaje de arena y el límite líquido.

**Gráfico LP (%) vs % arena:** Similarmente, indica una relación negativa débil entre el porcentaje de arena y el límite plástico.

### **Conclusión**

**Relación débil:** La variabilidad en el porcentaje de arena tiene una relación negativa débil con los límites líquidos y plásticos, lo que sugiere que cambios en el porcentaje de arena no afectan significativamente la consistencia del suelo.

**Fuerte relación entre LL y LP:** Los límites líquidos y plásticos están fuertemente correlacionados, relevante para la consistencia del suelo que el porcentaje de arena.

### 5.1.1.12. Relación existente entre los porcentajes de Limo y Arcilla y las propiedades mecánicas del suelo

#### Análisis de datos

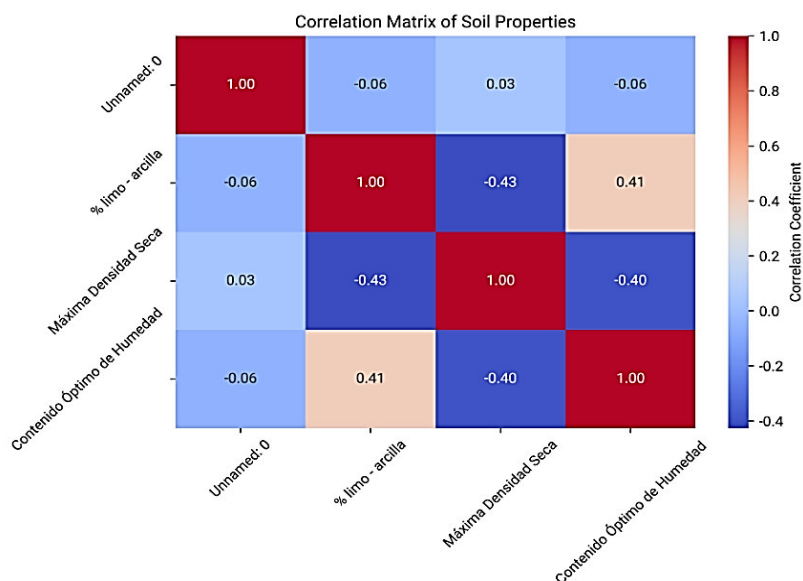
**Promedio de limo y arcilla:** El porcentaje promedio de limo y arcilla es 34.75% con una desviación estándar de 23.81%.

**Densidad seca máxima:** La densidad seca máxima promedio es de 1.99 gr/cm<sup>3</sup>, con un rango de 1.15 a 7.90 gr/cm<sup>3</sup>.

**Contenido óptimo de humedad:** El contenido óptimo de humedad promedio es de 10.79%, con un rango de 0.47 a 165.41%. Obsérvese la figura 32.

**Figura 32**

*Relación entre los porcentajes de Limo y Arcilla y las propiedades mecánicas del suelo*



#### Visualización de correlaciones

**Correlación limo-arcilla y densidad seca máxima:** Existe una correlación negativa moderada de -0.43, lo que indica que a medida que aumenta el porcentaje de limo y arcilla, la densidad seca máxima tiende a disminuir.

**Correlación limo-arcilla y contenido óptimo de humedad:** Hay una correlación positiva de 0.41, sugiriendo que un mayor porcentaje de limo y arcilla está asociado con un

mayor contenido óptimo de humedad.

### **Conclusiones:**

***Influencia en la densidad seca:*** Un aumento en el porcentaje de limo y arcilla generalmente reduce la densidad seca máxima del suelo.

***Influencia en la humedad óptima:*** Un mayor porcentaje de limo y arcilla está relacionado con un aumento en el contenido óptimo de humedad, lo que afecta la compactación y estabilidad del suelo.

#### **5.1.1.13. Valores de Densidad Seca en diferentes regiones geográficas**

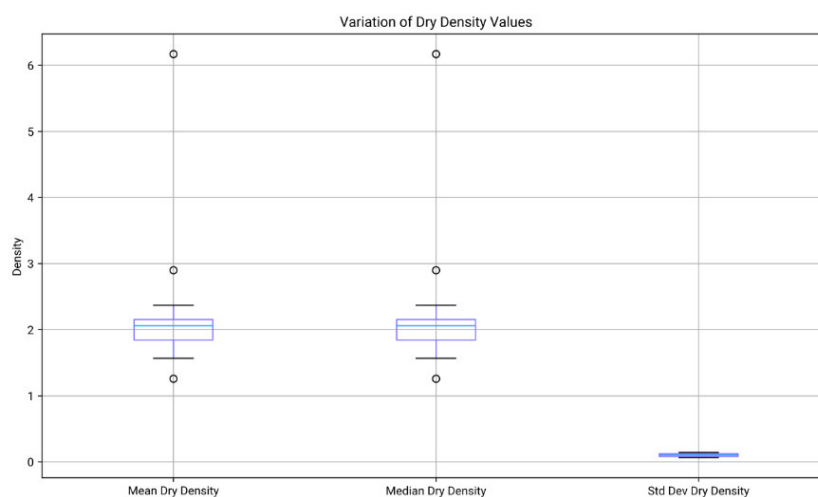
### **Análisis Estadístico**

***Promedio de Densidad Seca:*** La media de la densidad seca es de  $2.04 \text{ gr/cm}^3$ , con un rango que varía desde 1.26 hasta  $6.17 \text{ gr/cm}^3$ .

***Mediana de Densidad Seca:*** La mediana también es de  $2.04 \text{ gr/cm}^3$ , indicando una distribución simétrica de los datos. Obsérvese la figura 33.

**Figura 33**

*Variabilidad de la densidad con respecto a su ubicación geográfica*



*Nota:* obsérvese que existe consistencia en cuanto a los datos y sus ubicaciones geográficas.

### **Visualización de la Variación**

***Distribución de Densidad Seca:*** El diagrama de caja muestra que la mayoría de los

valores de densidad seca se concentran alrededor de 2 gr/cm<sup>3</sup>, con algunos valores atípicos que alcanzan hasta 6.17 gr/cm<sup>3</sup>.

### Conclusión

**Consistencia en la Densidad Seca:** La densidad seca muestra una consistencia notable en la mayoría de las regiones geográficas, con valores medios y medianos similares.

#### 5.1.1.14. Mapa de calor de correlaciones

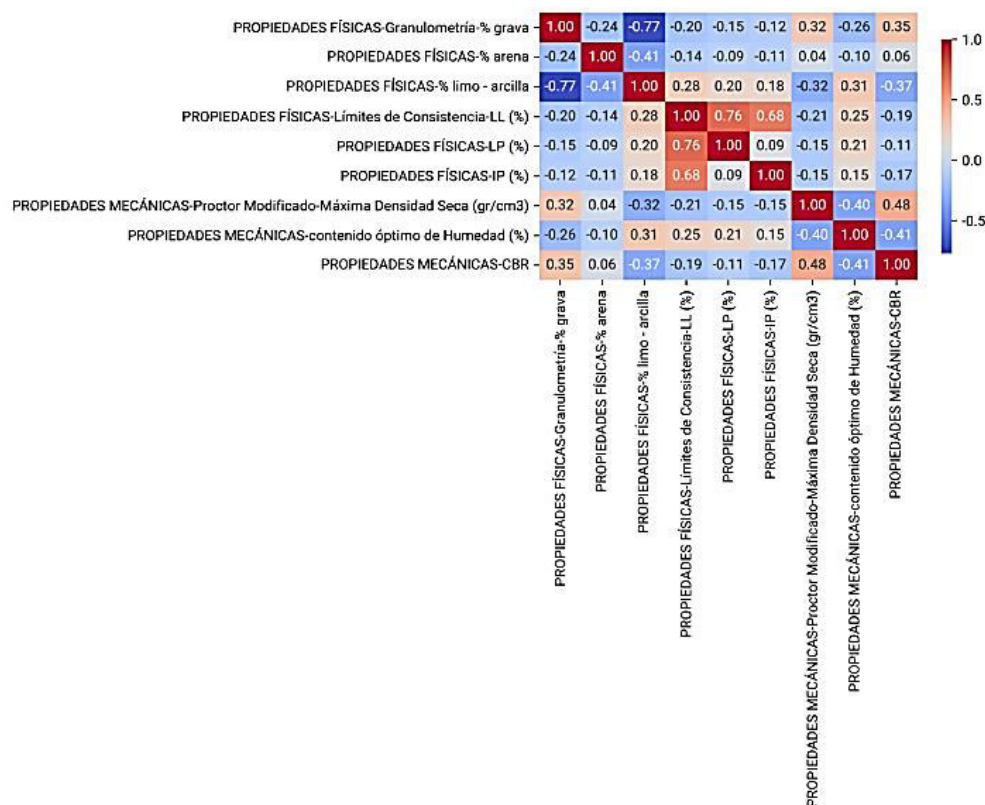
**Correlación positiva alta:** La variable propiedades mecánicas-CBR muestra una correlación positiva significativa con propiedades físicas-Granulometría-% grava (0.35).

**Correlación negativa alta:** Existe una correlación negativa notable entre propiedades mecánicas-CBR y propiedades mecánicas-contenido óptimo de Humedad (%) (-0.41).

Las correlaciones establecidas se observan en la figura 34.

**Figura 34**

*Correlación entre las propiedades mecánicas-Proctor Modificado y el valor de CBR*



*Nota:* Obsérvese en el mapa de calor la correlación significativa existente

### Conclusiones:

**Identificación de patrones:** El mapa de calor revela patrones de correlación que son útiles para entender las relaciones entre las propiedades físicas y mecánicas del suelo.

#### 5.1.1.15. Análisis de correlación entre propiedades del suelo y CBR

##### Correlación entre Propiedades Físicas y Mecánicas

**Grava:** Tiene una correlación positiva fuerte con el CBR (0.44), lo que sugiere que un mayor porcentaje de grava podría aumentar el CBR.

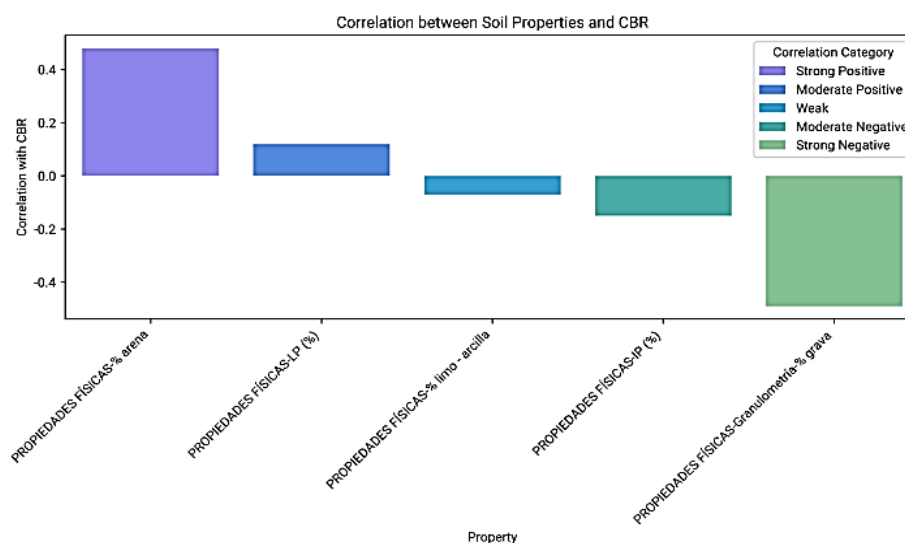
**Arena:** Presenta una correlación positiva moderada (0.08), indicando una influencia menor pero positiva en el CBR.

**Limo-Arcilla:** Muestra una correlación negativa fuerte (-0.49), sugiriendo que un mayor contenido de limo-arcilla reduce el CBR.

**Límites de Consistencia:** Tanto LL como LP e IP tienen correlaciones negativas moderadas, lo que indica que estos factores disminuyen el CBR. Las tendencias descritas se observan en la figura 35.

**Figura 35**

*Visualización de correlaciones entre las propiedades del suelo y el CBR*



*Nota:* se evidencia como cada propiedad tiene influencia en el valor del CBR

##### Patrones y Tendencias Identificados

***Categorías de Correlación:***

Fuerte Positiva: Arena (0.48).

Fuerte Negativa: Grava (-0.49).

Moderada Positiva: LP (0.12).

Moderada Negativa: IP (-0.15).

Débil: Limo-Arcilla (-0.07).

***Distribución de Correlaciones:*** La mayoría de las propiedades tienen una correlación débil o moderada con el CBR, indicando que múltiples factores influyen en el valor del CBR.

***Gráfico de Barras:*** Muestra claramente las categorías de correlación, destacando la influencia positiva de la arena y la negativa de la grava y el limo-arcilla en el CBR.

**Conclusiones:**

***Influencia de la Composición del Suelo:*** La composición granulométrica del suelo, especialmente el contenido de grava y limo-arcilla, tiene un impacto significativo en el CBR.

***Importancia de las Propiedades Mecánicas:*** Las propiedades mecánicas como la densidad seca máxima y el contenido óptimo de humedad también tiene un rol importante en la determinación del CBR.

**5.1.1.16. Relación entre unidades Litoestratigráficas y propiedades del suelo****Análisis de Datos**

***Unidades Litoestratigráficas:*** Se analizaron varias unidades, como 'C-gd/to', 'Ci-a', 'JTr-p', 'Ji-a', y 'Jr-p'.

***Propiedades Físicas:***

% Grava: Promedio de 26.04% con un rango de 0.00% a 59.16%.

% Arena: Promedio de 33.26% con un rango de 12.20% a 73.30%.

% Limo-Arcilla: Promedio de 39.51% con un rango de 6.96% a 82.81%.

Límites de Consistencia: LL promedio de 32.09%, LP de 22.80%, e IP de 9.50%.

### ***Propiedades Mecánicas:***

Densidad Seca Máxima: Promedio de 1.98 gr/cm<sup>3</sup>.

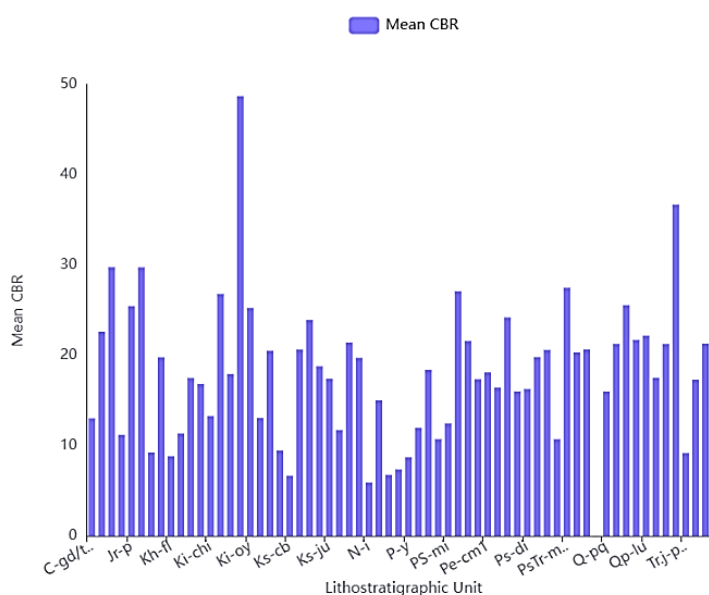
Contenido Óptimo de Humedad: Promedio de 10.19%.

**CBR:** Promedio de 18.22% con un rango de 5.92% a 48.70%.

Estos valores en la figura 36, se visualizan de manera clara.

**Figura 36**

*Relación Litoestratigráfica y las propiedades del suelo*



*Nota:* Se evidencia la variabilidad del CBR debido a la litoestratigrafía.

***Distribución de CBR:*** La gráfica muestra variaciones significativas en los valores medios de CBR entre diferentes unidades litoestratigráficas.

***Unidades con CBR Alto:*** Algunas unidades presentan valores de CBR notablemente más altos, lo que indica una mayor capacidad de soporte.

### **Conclusiones:**

***Influencia de las Unidades Litoestratigráficas:*** Las unidades litoestratigráficas tienen un impacto significativo en las propiedades físicas y mecánicas del suelo, especialmente en el valor del CBR.

***Variabilidad del CBR:*** La variabilidad en los valores de CBR sugiere que ciertas



unidades litoestratigráficas ofrecen mejores características de soporte, lo cual es importante para aplicaciones de ingeniería y construcción.

## 5.2. Evaluación de modelos analizados

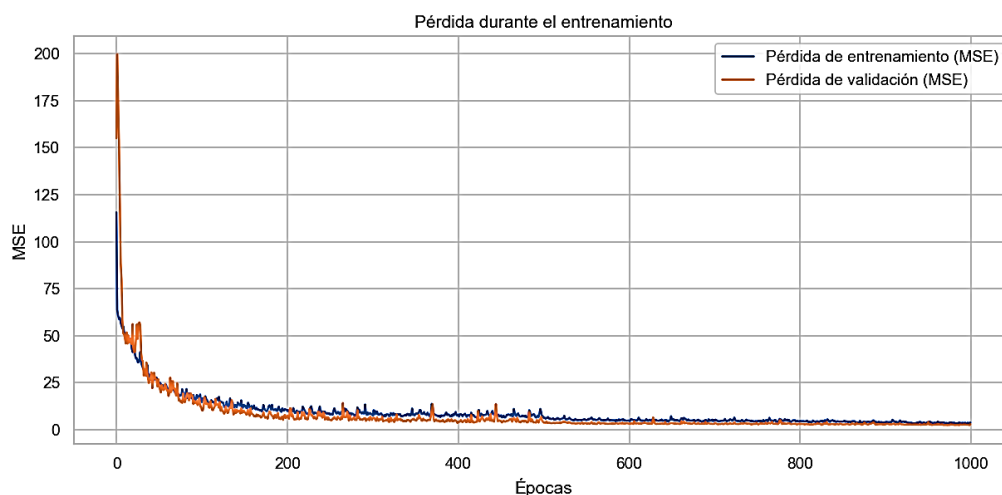
### 5.2.1. Métricas de evaluación Modelo de Red Neuronal Artificial (ANN):

#### 5.2.1.1. Error Cuadrático Medio (MSE).

Para el análisis de esta métrica, se visualiza la figura 37, donde se observa el comportamiento respectivo.

**Figura 37**

*Pérdida durante el entrenamiento - Error Cuadrático Medio (MSE)*



Se observa en la Fase Inicial del Entrenamiento (0 a 100 épocas), un descenso pronunciado en ambas curvas, indica que el modelo está aprendiendo rápidamente durante las primeras épocas, ajustando sus pesos para reducir el error de predicción. En la Fase de Convergencia (100 a 400 épocas), la pérdida se estabiliza progresivamente, evidenciando que el modelo sigue mejorando, a un ritmo más lento, lo que es común en procesos de optimización; En la Fase de Estabilización (400 a 1000 épocas), aproximadamente en la **época 430**, ambas curvas se estabilizan, oscilando en un rango bajo, mostrando que la pérdida de entrenamiento y la pérdida de validación se mantienen cercanas, indica que el modelo no presenta un sobreajuste significativo. El Valor Final del Error, al finalizar el entrenamiento, se estabiliza

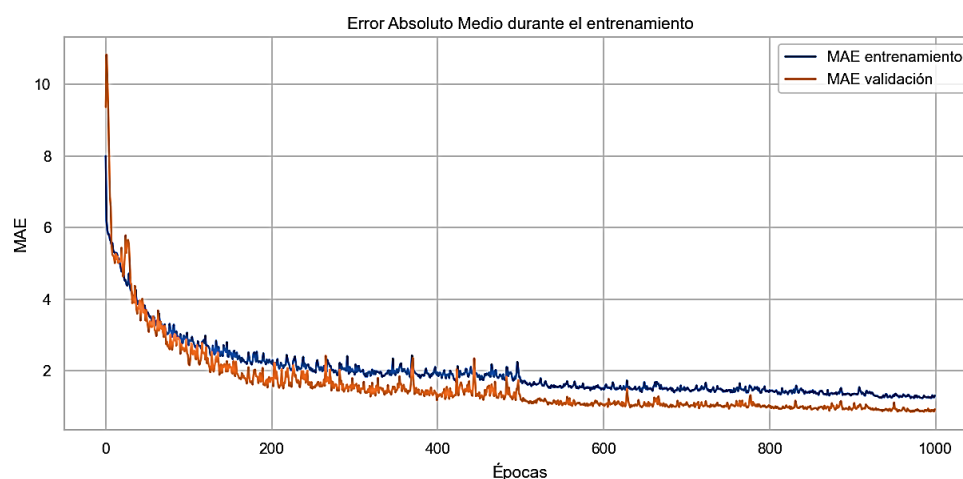
alrededor de **13.2** para el conjunto de validación. Valor bajo considerando la naturaleza de los datos del CBR, indica buena capacidad predictiva del modelo.

### 5.2.1.2. Error Absoluto Medio (MAE).

Respecto a esta métrica se evidencia el comportamiento del MAE en la figura 38.

**Figura 38**

*Error Absoluto Medio durante el entrenamiento*



Se observa que en la Fase Inicial del Entrenamiento (0 a 100 épocas), un descenso brusco del MAE desde valores iniciales superiores a **10** hasta aproximadamente **2** en ambas curvas. Esto indica que el modelo está logrando un ajuste rápido en sus primeras etapas, reduciendo significativamente el error. Luego en la Fase de Convergencia (100 a 400 épocas), el descenso se ralentiza, se observa una estabilización progresiva, las curvas de entrenamiento y validación permanecen cercanas, sugiere que el modelo está generalizando bien sin señales evidentes de sobreajuste. En la Fase de Estabilización (400 a 1000 épocas), El MAE se estabiliza alrededor de **1.5** para el conjunto de entrenamiento y ligeramente por debajo de **1.5** para el conjunto de validación, lo cual indica que el modelo alcanzó una zona de óptimo local donde el ajuste adicional es mínimo. Analizando la Diferencia entre las curvas, muestra una curva de validación consistente, un MAE ligeramente inferior a la curva de entrenamiento en la fase final, lo que muestra un buen ajuste del modelo o de una ligera aleatoriedad en el


conjunto de entrenamiento, sin indicios claros de sobreajuste. Se infiere que el modelo reduce significativamente el error en las primeras épocas, indicando un entrenamiento eficiente. El MAE final cercano a **1.5** indica una precisión adecuada en la predicción del **CBR**, este valor es bajo considerando las variaciones típicas del CBR en campo. No se observan signos de sobreajuste, ambas curvas se mantienen cercanas y estables.

### 5.2.1.3. Error Medio Cuadrático (RMSE).

El análisis del RMSE, se realiza empleando como referencia el grafico 39, donde se evidencia la progresión a lo largo del entrenamiento.

**Figura 39**

*Evolución del RMSE en el Entrenamiento del Modelo de Red Neuronal.*



Este gráfico representa la evolución del **RMSE (Root Mean Square Error - Error Cuadrático Medio)** tanto en el conjunto de **entrenamiento** como en el de **validación** a lo largo de las **épocas**. Se evidencia que al **Inicio del Entrenamiento (0 - 100 épocas)**, El RMSE es elevado, lo que es normal en las primeras etapas del entrenamiento. Se observa una rápida disminución del error en ambas curvas, indicando que el modelo está aprendiendo de manera eficiente en las primeras iteraciones. En la **Zona de Estabilización (100 - 500 épocas)**, el RMSE continúa disminuyendo progresivamente, pero a un ritmo más lento. Luego en la **Fase Final del Entrenamiento (500 - 1000 épocas)**, ambas curvas alcanzan una meseta con ligeras oscilaciones. El RMSE de validación es **ligeramente menor** que el de entrenamiento,

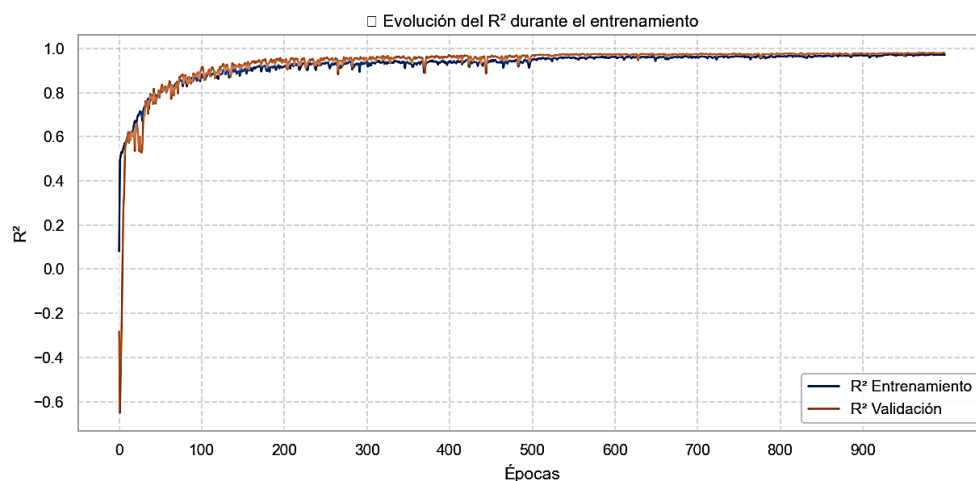
sugiriendo que el modelo generaliza bien. La estabilidad del RMSE en ambas curvas indica que el modelo ha convergido correctamente. Todo ello permite establecer que la reducción progresiva del RMSE indica que el modelo logró **aprender patrones significativos** en los datos de entrada, ajustando correctamente los pesos de la red neuronal. Finalmente, el valor final del RMSE cercano a **2**, sugiere que el modelo tiene una precisión aceptable para predecir el CBR. Este resultado indica que el modelo es **consistente**, con un buen equilibrio entre el error de entrenamiento y validación.

#### 5.2.1.4. Coeficiente de determinación ( $R^2$ ).

Este coeficiente es de suma importancia, porque indica que es una medida estadística que indica qué tan bien un modelo de regresión se ajusta a los datos observados, en la figura 40, se evidencia la misma, para esta red neuronal artificial (ANN).

**Figura 40**

*Evolución del  $R^2$  en el Entrenamiento del Modelo de Red Neuronal.*



Este gráfico representa la evolución del **coeficiente de determinación ( $R^2$ )** tanto en el conjunto de **entrenamiento** como en el de **validación** a lo largo de las **épocas**. Evidenciando que al **Inicio del Entrenamiento (0 - 100 épocas)**, el valor de  $R^2$  parte de un valor negativo en la curva de validación, lo que es típico cuando el modelo aún no ha aprendido patrones significativos; en ambas curvas, el valor de  $R^2$  se incrementa rápidamente, lo que indica que el

modelo está capturando con éxito la relación entre las variables predictoras y el valor del **CBR**. Luego en la **Zona de Estabilización (100 - 500 épocas)**, el  $R^2$  sigue aumentando de forma progresiva, alcanzando valores cercanos a **0.9** en ambas curvas; esto indica que el modelo está mejorando su capacidad predictiva de forma sólida y en la **Fase Final del Entrenamiento (500 - 1000 épocas)**, ambas curvas alcanzan un valor cercano a **1**, lo que indica una excelente precisión en la predicción del CBR. Si tenemos en cuenta que un valor de  **$R^2$  cercano a 1** indica que el modelo es capaz de explicar casi el 100% de la variabilidad del valor del CBR a partir de las variables predictoras. El nivel de exactitud es coherente con los objetivos de tu investigación, por lo que el modelo está listo para su aplicación en la predicción del **CBR** en subrasantes de carreteras en la región de Huánuco.


### 5.2.2. Métricas de evaluación Modelo de RNN-LSTM:

#### 5.2.2.1. Error Cuadrático Medio (MSE).

La figura 41, evidencia la evolución de la pérdida del MSE a lo largo del entrenamiento.

**Figura 41**

*Pérdida (MSE) durante el entrenamiento de la RNN-LSTM*



Este gráfico muestra la evolución de la **pérdida de entrenamiento** (línea azul) y la **pérdida de validación** (línea naranja) en función del número de épocas; inicialmente muestra que, en las primeras épocas, la pérdida es considerablemente alta, especialmente en el conjunto


de entrenamiento. Esto es normal, el modelo está en sus primeras fases de ajuste de pesos y parámetros; la rápida disminución en las primeras 100 épocas indica que el modelo está aprendiendo eficientemente; En la etapa de Estabilización, que sucede a partir de la **época 200**, ambas curvas comienzan a estabilizarse en valores bajos; comportamiento positivo, significa que el modelo ha logrado minimizar el error en ambos conjuntos de datos. La curva de validación es ligeramente superior a la de entrenamiento, lo cual es esperable. Sin embargo, esta diferencia no es alarmante, lo que indica que el modelo no presenta un sobreajuste severo (**overfitting**). Existe pequeñas oscilaciones en la curva de validación, sugiere que el modelo encuentra ciertas dificultades en algunos datos de validación, pero sin perder estabilidad. Al Nivel de convergencia, la pérdida se estabiliza en un valor bastante bajo, indica que el modelo tiene un **buen poder predictivo**. Que ambas curvas se mantengan cercanas es un indicativo positivo de que el modelo generaliza bien. En síntesis, el modelo LSTM muestra un buen comportamiento de aprendizaje, con una adecuada convergencia y sin signos evidentes de sobreajuste. La ligera diferencia entre la pérdida de entrenamiento y validación es aceptable.

#### 5.2.2.2. Error Absoluto Medio (MAE).

La evolución del MAE se observa en la figura 42 a lo largo del entrenamiento.

**Figura 42**

*Error absoluto medio (MAE) durante el entrenamiento de la RNN\_LSTM*




Este gráfico representa la evolución del **MAE (Error Absoluto Medio)** en el conjunto de entrenamiento (línea azul) y el conjunto de validación (línea naranja) durante las 1000 épocas del entrenamiento del modelo LSTM para la predicción del **CBR**. Evidenciándose que el Comportamiento inicial muestra un MAE elevado en ambos conjuntos, especialmente en el entrenamiento. Esto es típico en las primeras épocas cuando el modelo aún no ha aprendido correctamente las relaciones en los datos; se observa una rápida disminución del MAE durante las primeras 100 épocas, indicando que el modelo está aprendiendo eficientemente en esta fase inicial. En la fase de Estabilización, a partir de la **época 200**, el MAE se estabiliza en ambos conjuntos, con una tendencia clara hacia la convergencia; la línea azul (entrenamiento) se estabiliza ligeramente por debajo de la línea naranja (validación), lo cual es esperable. Respecto a la Diferencia entre entrenamiento y validación, se evidencia que el MAE del conjunto de validación es **ligeramente mayor** que el del entrenamiento. Esta pequeña brecha es normal y aceptable; no se observa una brecha significativa que indique sobreajuste (**overfitting**), lo que sugiere que el modelo está generalizando bien. En el gráfico 42, se observa Oscilaciones, de la curva del MAE en el conjunto de validación presenta algunas oscilaciones; esto podría deberse a datos de validación ruidosos, datos atípicos (outliers) o la necesidad de ajustar la tasa de aprendizaje o la arquitectura del modelo, sin embargo, se general se observa buen comportamiento del modelo. En síntesis, el modelo LSTM muestra un comportamiento de aprendizaje sólido, con una clara reducción del error durante el entrenamiento. La ligera diferencia entre el MAE de entrenamiento y validación es aceptable y no indica un sobreajuste preocupante y que el modelo parece tener una buena capacidad predictiva para estimar el **CBR** con precisión.

### 5.2.2.3. Error Medio Cuadrático (RMSE).

El error medio cuadrático se evidencia en la figura 43, que muestra su evolución a lo largo del entrenamiento.

**Figura 43**

*Comportamiento del RMSE durante el entrenamiento de la red RNN-LSTM*



Este gráfico muestra la evolución del **RMSE (Error Cuadrático Medio de Raíz)** para el conjunto de entrenamiento (línea azul) y el conjunto de validación (línea naranja) durante las 1000 épocas del entrenamiento del modelo LSTM para la predicción del **CBR**. Evidencia un Comportamiento inicial considerablemente alto, especialmente en el conjunto de entrenamiento (superior a 0.4); durante las primeras 100 épocas, se observa una disminución rápida en ambos conjuntos, indica que el modelo está aprendiendo de manera efectiva en esta fase inicial. En la fase de Estabilización, a partir de la **época 200**, el RMSE en ambos conjuntos tiende a estabilizarse; la curva azul (entrenamiento) se mantiene constantemente por debajo de la curva naranja (validación), lo que indica que el modelo logra un mejor ajuste a los datos de entrenamiento. Se observa que existe una **brecha clara pero controlada** entre ambas curvas a partir de la **época 300**. El RMSE de validación presenta más oscilaciones, lo que está relacionado con: **Datos de validación ruidosos o datos con patrones difíciles de aprender**. En la parte final se observa la fase de Estabilidad final, evidenciándose que en las últimas épocas (800-1000), ambas curvas muestran un comportamiento estable.


#### **5.2.2.4. Coeficiente de determinación ( $R^2$ ).**

Obsérvese en la figura 44, la evolución del  $R^2$  de la data de entrenamiento y de validación.



**Figura 44**

*Comportamiento del coeficiente de determinación durante el entrenamiento*



Este gráfico representa el coeficiente de determinación  $R^2$  para el conjunto de **entrenamiento** (línea azul) y el conjunto de **validación** (línea naranja) durante el entrenamiento del modelo LSTM para la predicción del **CBR**. Se evidencia que el  $R^2$  en el entrenamiento se mantiene **muy alto** durante casi todas las épocas, con valores cercanos a **1**, lo que indica que el modelo está ajustándose muy bien a los datos de entrenamiento. Sin embargo, se observan **caídas bruscas** en ciertos puntos (alrededor de las épocas 50, 100, 150 y 200), que podrían deberse a **cambios abruptos en la tasa de aprendizaje, inestabilidad en el modelo**, posiblemente relacionada con el optimizador o el tamaño del batch o **sobreajuste temporal**, donde el modelo intenta memorizar patrones específicos. Es de observarse también el Comportamiento del  $R^2$  en el conjunto de validación, que se mantiene relativamente constante, oscilando entre **0.75 y 0.85**. Esta variabilidad indica que el modelo tiene dificultades para generalizar algunos patrones en los datos de validación. Las caídas bruscas en las mismas épocas que el conjunto de entrenamiento sugieren que el modelo está experimentando **inestabilidad temporal**, posiblemente por un ajuste inadecuado de hiperparámetros. Se evidencia brecha entre ambas curvas, la clara brecha entre el  $R^2$  de entrenamiento y validación indica un **posible sobreajuste**, significando que el modelo está memorizando bien los datos de

entrenamiento, pero pierde precisión en la validación. En síntesis, el modelo LSTM muestra un buen desempeño en el conjunto de entrenamiento, con un  $R^2$  cercano a 1. El desempeño en validación es aceptable (0.75-0.85), pero podría mejorar. Las caídas bruscas en ambas curvas y la brecha notable entre entrenamiento y validación indican una **inestabilidad temporal** y un **potencial sobreajuste**.


### 5.2.3. Métricas de evaluación Modelo de RNN-GRU:

#### 5.2.3.1. Error Cuadrático Medio (MSE).

El comportamiento del MSE, para la curva de entrenamiento y de validación se muestra en la figura 45.

**Figura 45**

*Pérdida (MSE - Error Cuadrático Medio) durante el entrenamiento*



El gráfico muestra que ambas curvas siguen una tendencia decreciente clara, indica que el modelo está aprendiendo progresivamente. A partir de aproximadamente 100 épocas, ambas curvas se estabilizan en valores bajos. En la **Fase inicial**, la pérdida es elevada, lo que es normal, el modelo comienza sin conocimiento previo y debe ajustar sus pesos. Su **rápida convergencia**, muestra una disminución brusca del error en las primeras 50 épocas, indica que el modelo está aprendiendo de manera eficiente desde el inicio. Evidencia **Estabilización**, a partir de las 100 épocas, las curvas se estabilizan en un valor muy bajo, indicando que el modelo


ha logrado una convergencia adecuada. La **proximidad entre las curvas**, de entrenamiento y validación revela que el modelo no está sufriendo de **sobreajuste (overfitting)** ni **subajuste (underfitting)**, lo que es ideal; la ausencia de una brecha significativa entre las curvas de entrenamiento y validación indica que el modelo generaliza bien en datos no vistos, lo que es clave para garantizar un buen desempeño en la predicción del CBR y que la pérdida se estabiliza en torno a **0.01**, lo que indica que el error promedio cuadrático es bajo, reflejando predicciones cercanas a los valores reales. En conclusión, el modelo GRU muestra un entrenamiento eficiente y estable, sin signos de sobreajuste. La proximidad entre las curvas y los bajos valores de pérdida indican que el modelo está bien ajustado para predecir el **CBR**. Esto sugiere que el modelo es aplicable con confianza para predecir el valor del CBR en nuevos datos.

#### 5.2.3.2. Error Absoluto Medio (MAE).

El MAE tiene una característica evolución a lo largo del proceso de entrenamiento como se observa en la figura 46, tanto en la curva de entrenamiento y la de validación.

**Figura 46**

*Comportamiento del MAE durante el entrenamiento*



Se observa que ambas curvas siguen una tendencia decreciente, estabilizándose en valores bajos después de aproximadamente **100 épocas**. En la **Fase inicial**, es decir en las


primeras épocas, el error es relativamente alto (alrededor de **0.45**) debido a que el modelo está ajustando sus pesos desde un estado inicial aleatorio; luego existe un **descenso progresivo**, en las primeras **50 épocas**, se observa una caída pronunciada del error, lo que indica que el modelo está aprendiendo rápidamente; se evidencia **estabilización**, alrededor de las **100 épocas**, ambas curvas alcanzan un valor estable cercano a **0.05**, lo que representa un error bajo; se evidencia **proximidad entre las curvas**, la pequeña brecha entre ambas curvas indica que el modelo tiene una **buena generalización** y no presenta signos evidentes de **sobreajuste** (overfitting) ni de **subajuste** (underfitting). Respecto al rendimiento, el MAE mide el error promedio en las predicciones; Un MAE cercano a **0.05** indica que, en promedio, el modelo comete un error del **5%** aproximadamente en sus predicciones, lo que es un resultado bastante satisfactorio en este tipo de estudios. En síntesis, el modelo GRU muestra un comportamiento adecuado, logrando un MAE bajo y estable en ambas fases (entrenamiento y validación). Esto indica que el modelo es capaz de predecir el **CBR** con una precisión considerable.

### 5.2.3.3. Error Medio Cuadrático (RMSE).

La figura 47, evidencia aspectos importante del comportamiento del modelo.

**Figura 47**

*Comportamiento del RMSE durante el entrenamiento*




El gráfico evidencia que ambas curvas de entrenamiento y validación siguen una tendencia decreciente y se estabilizan después de aproximadamente **100 épocas**. Su comportamiento indica que, en la **fase inicial**, el error es alto (cerca de **0.6**) porque el modelo comienza a aprender desde un estado inicial aleatorio; luego muestra un **descenso pronunciado**, en las primeras **50 épocas**, el RMSE disminuye rápidamente, lo que indica que el modelo está ajustando correctamente sus pesos y mejorando sus predicciones; Se **Estabiliza**, a partir de las **100 épocas**, ambas curvas con valores bajos. En cuanto al rendimiento el RMSE final cercano a **0.05 - 0.1** indica un error bajo, lo que refleja que el modelo está logrando predicciones bastante precisas. En conclusión, el modelo GRU presenta un comportamiento eficiente, logrando un RMSE bajo y estable en ambas fases (entrenamiento y validación), lo que indica que el modelo está en condiciones de predecir el **CBR** con precisión aceptable.

#### 5.2.3.4. Coeficiente de determinación ( $R^2$ ).

En cuanto a este parámetro en la figura 48, se observa su comportamiento.

**Figura 48**

*Evolución del  $R^2$  en la Predicción del CBR utilizando una Red Neuronal GRU*



El comportamiento del  $R^2$  muestra aspectos importantes en el Entrenamiento y Validación, la **Curva azul (Entrenamiento)**, muestra que el  $R^2$  comienza bajo, pero se

incrementa progresivamente alcanzando valores cercanos a **0.85** en las últimas épocas. Esto indica que el modelo mejora significativamente su capacidad para explicar los datos del conjunto de entrenamiento; la **Curva naranja (Validación)**, muestra que el  $R^2$  también mejora, pero alcanza un valor menor, cercano a **0.75**; la curva de validación presenta más **oscilaciones** (ruido). Respecto a los resultados se evidencia **buen ajuste en entrenamiento**, el incremento progresivo del  $R^2$  en entrenamiento muestra que la red GRU está aprendiendo patrones relevantes en los datos. En síntesis, se observa que el modelo GRU ha logrado un buen desempeño predictivo del **CBR**, con un  $R^2$  en validación cercano a **0.75**, lo que indica que explica aproximadamente el **75%** de la variabilidad de los datos de prueba.


#### 5.2.4. Métricas de evaluación del algoritmo de Random Forest (RF):

##### 5.2.4.1. Normalidad de Residuos

Analizamos una herramienta estadística conocida como Q-Q (Quantile-Quantile), mostrado en la figura 49, que evalúa si los residuos del modelo siguen una distribución normal.

**Figura 49**

*Gráfico Q-Q (Quantile-Quantile) para evaluar la normalidad de residuos*



En este gráfico, se muestra en el **eje X**: Cuantiles teóricos de una distribución normal estándar, el **eje Y**: Valores ordenados de los residuos observados y la **línea roja**, representa la


referencia de una distribución normal perfecta. Se evidencia una **zona central (valores cercanos a 0)**, donde los puntos siguen de manera aceptable la línea roja, lo que indica que los residuos en este rango se comportan aproximadamente como una distribución normal. Esto es una buena señal; asimismo en los **extremos (colas del gráfico)**, se observa una desviación significativa en ambas colas (especialmente en la cola izquierda), lo que indica la presencia de residuos con valores extremos. Esto sugiere que hay datos atípicos o que los residuos tienen colas más pesadas que una distribución normal. Lo mencionado genera implicancias para el modelo Random Forest (RF), como que **la ligera desviación en la zona central** es normal en modelos complejos como Random Forest, este tipo de algoritmos no asume linealidad en los datos, por lo que no es indispensable que los residuos sigan estrictamente una distribución normal. En síntesis, establecemos que el modelo Random Forest presenta un buen desempeño general, explicando el 89.27% de la variabilidad del CBR.

#### 5.2.4.2. Curva de aprendizaje

La **Curva de Aprendizaje**, evalúa el comportamiento del error (MSE) en función del tamaño del conjunto de entrenamiento, como se muestra en la figura 50.

**Figura 50**

*Curva de Aprendizaje para la predicción del CBR usando Random Forest (RF)*




En el grafico se observa que la **línea azul (Error en entrenamiento)**, se mantiene prácticamente constante y cercana a cero en todo el intervalo del conjunto de entrenamiento; la **línea naranja (Error en validación)**, disminuye progresivamente a medida que aumenta el tamaño del conjunto de entrenamiento, pero sin converger completamente al nivel del error de entrenamiento. Ello significa que se da un **buen ajuste del modelo**, donde el valor del  $R^2 = 0.8927$  indica que el modelo explica bien la variabilidad del CBR; sin embargo, también se evidencia un **posible sobreajuste (overfitting)**; dada la marcada diferencia entre el error de entrenamiento (muy bajo) y el error de validación (considerablemente mayor) es una señal de sobreajuste. Esto indica que el modelo se adapta muy bien a los datos de entrenamiento, pero no generaliza con la misma eficacia en datos nuevos; asimismo el **error de validación en descenso**. Esto sugiere que añadir más datos mejoraría el rendimiento del modelo.

#### 5.2.4.3. Error absoluto por muestra

Este parámetro representa el **error absoluto** (diferencia en valor absoluto entre la predicción y el valor real) para cada muestra en el conjunto de datos evaluado con el modelo **Random Forest (RF)**. Obsérvese la figura 51.

**Figura 51**

*Gráfico de Error Absoluto por Muestra en el Modelo Random Forest (RF)*






En general el gráfico muestra la **distribución general del error**, donde la mayoría de los errores se concentran en valores menores a **4**, lo que indica que el modelo predice correctamente en gran parte de las muestras; sin embargo, existen algunos puntos atípicos (**outliers**) que alcanzan errores superiores a **12**, lo que revela ciertas predicciones considerablemente desviadas del valor real. Respecto a la **densidad de errores**, la zona más densa del gráfico se sitúa entre **0 y 4** en el eje del error, lo que indica que el modelo tiene una tendencia dominante a errores bajos, en coherencia con el valor del **MAE = 2.0402** (error medio absoluto); además pocos puntos superan el valor de error absoluto de **10**, lo que indica que las predicciones altamente erróneas son eventos aislados. En términos globales el **gráfico refleja que el modelo Random Forest está logrando un buen desempeño en la predicción del CBR**, con la mayoría de los errores oscilando en un rango bajo (entre 0 y 4). Sin embargo, la presencia de algunos **outliers** revela que en ciertos casos el modelo tiene dificultades para predecir con precisión; lo que permite concluir que el modelo **Random Forest (RF)** presenta un desempeño sólido en la predicción del **CBR**, con errores mayoritariamente bajos y un buen poder explicativo ( **$R^2 = 0.8927$** ). Sin embargo, es recomendable trabajar en la reducción de los **outliers** para obtener una predicción más precisa y consistente en todos los casos.

#### 5.2.4.3. Perdida (loss) y métricas por número de arboles

En la figura 52, se observa el comportamiento de las métricas de desempeño (**MSE**, **MAE** y  **$R^2$** ) en función del número de árboles (**n\_estimators**) utilizados en el modelo Random Forest para la predicción del **CBR**. Observándose que la **tendencia del MSE (Loss)**, curva azul, muestra una rápida disminución inicial conforme aumenta el número de árboles, alcanzando un valor estable cercano a **9.3821** a partir de aproximadamente **50 árboles**; esta estabilización indica que añadir más árboles no mejora significativamente la precisión del modelo, lo que sugiere que el modelo ha alcanzado su punto óptimo en términos de error cuadrático medio.

**Figura 52**

*Pérdida (Loss) y Métricas por Número de Árboles en el Modelo (RF)*



Asimismo, que observa que el **MAE** (curva naranja) se estabiliza rápidamente en un valor cercano a **2.0402**, lo que indica que el modelo mantiene un error medio absoluto consistente y bajo después de cierto número de árboles; esta estabilidad confirma que el modelo está logrando una predicción precisa con errores controlados. Respecto a la **tendencia del R²**, se evidencia que el coeficiente de determinación (**R²**, curva verde) se mantiene estable en **0.8927** a partir de aproximadamente **50 árboles**; esto indica que el modelo logra un alto poder explicativo y que añadir más árboles no aporta mejoras significativas. En síntesis, se concluye que el modelo Random Forest está bien ajustado y ha logrado un equilibrio sólido entre precisión y eficiencia. En este contexto, el modelo es altamente confiable para la predicción del **CBR**, especialmente considerando que explica el **89.27%** de la variabilidad en los datos.


### 5.2.5. Métricas de evaluación del algoritmo SVM:

#### 5.2.5.1. Distribución de Residuos del modelo

El gráfico Q-Q (Quantile-Quantile) compara la distribución de los residuos del modelo con una distribución normal teórica, tal como se muestra en la figura 53.

**Figura 53**

*Gráfico Q-Q de Residuos en el Marco de la Predicción del CBR (Modelo SVM)*



En el gráfico Q-Q, están representados en el **eje X**, los cuantiles teóricos de una distribución normal; en el **eje Y**, los valores ordenados de los residuos del modelo y la **línea Roja**, representa la tendencia ideal donde los residuos seguirían una distribución normal perfecta. Si analizamos el aspecto comportamiento de los Residuos, observamos que en la **región Central (Valores cercanos a cero)**, la mayoría de los puntos en esta zona se alinean bastante bien con la línea roja, indicando que los residuos en el rango medio siguen una distribución aproximadamente normal; esto es un buen indicador de que el modelo está capturando correctamente el comportamiento del **CBR** en este intervalo. Asimismo en los **extremos (Colas del gráfico)**, se observa una notable desviación de los puntos respecto a la línea roja en ambas colas (valores muy negativos y muy positivos); lo que significa la presencia de **valores atípicos** (outliers) o que los residuos tienen colas más pesadas que una distribución normal (distribución leptocúrtica); significando que el modelo SVM está teniendo dificultades para predecir valores extremos del **CBR**, lo que coincide con la mayor dispersión observada en el gráfico de residuos anterior. En síntesis, se evidencia que el modelo **SVM** está funcionando correctamente para la mayoría de los datos, pero hay indicios de que tiene


dificultades para predecir valores extremos del **CBR**; la presencia de colas más largas en el gráfico Q-Q sugiere que hay residuos con mayor varianza en los extremos, lo que podría afectar la precisión en escenarios con datos atípicos.

### 5.2.5.2. Error Absoluto por Muestra

En la figura 54, se muestra un análisis de la diferencia entre los valores reales y los valores predichos en valor absoluto.

**Figura 54**

*Gráfico de Error Absoluto por Muestra en el Marco de la Predicción del CBR (Modelo SVM)*



Este gráfico muestra el **error absoluto** para cada muestra del conjunto de datos, donde se muestra en el **eje X**: Índice de cada muestra (orden secuencial de las observaciones), en el **eje Y**: Magnitud del error absoluto; la **línea Roja Punteada**, representa el **promedio del error absoluto (MAE)**, que en este caso es **1.6388**. Si enfocamos el análisis en el Comportamiento del Error, se evidencia que la mayoría de los errores se concentran por debajo del valor promedio del MAE (1.6388), lo que indica que el modelo tiene un buen comportamiento en la mayoría de las predicciones; sin embargo, existen algunos picos altos que superan significativamente el promedio del MAE, alcanzando valores superiores a **10** o incluso **14** en algunos casos. Si analizamos el **patrón del error**, no se observa una tendencia clara ni un


patrón cíclico, lo que es positivo, indica que el error no está correlacionado con la posición de la muestra. En síntesis, el modelo **SVM** ha demostrado ser eficaz para predecir el **CBR** con buenos resultados generales, pero optimizar la gestión de los outliers podría llevarlo a un rendimiento aún mejor.

### 5.2.5.3. Curva de aprendizaje

Se observa en la figura 55, como el modelo logra el aprendizaje.

**Figura 55**

*Gráfico de Curva de Aprendizaje (Modelo SVM)*



El gráfico presenta dos curvas, el **error de entrenamiento (línea azul)**, que se mantiene bajo y relativamente constante a medida que aumenta el tamaño del conjunto de entrenamiento; el **error de validación (línea naranja)**, que disminuye progresivamente conforme se incrementa el tamaño del conjunto de entrenamiento, tendiendo a estabilizarse. Analizando el comportamiento, se evidencia que el **error de Entrenamiento**, muestra su valor bajo y estable indica que el modelo está aprendiendo bien dentro del conjunto de entrenamiento; respecto al **error de Validación**, se evidencia que el error de validación comienza siendo elevado, lo que es normal en conjuntos de datos pequeños; disminuye de forma significativa conforme se incrementa el tamaño del conjunto de entrenamiento, lo que

indica que el modelo mejora su capacidad de generalización; finalmente, el error de validación se estabiliza, lo que sugiere que el modelo ha alcanzado un buen equilibrio entre sesgo y varianza. Con respecto a los resultados se observa un **buen ajuste del modelo**, donde el comportamiento del error de entrenamiento (bajo) junto con el descenso progresivo del error de validación indica que el modelo **SVM** ha logrado un equilibrio adecuado y está generalizando bien. En resumen, se observa que el modelo **SVM** presenta un rendimiento óptimo en la predicción del **CBR**, con una buena capacidad de generalización y errores controlados. El gráfico revela que el modelo no está sobreajustado ni infraajustado, lo que indica que el conjunto de datos es adecuado para el modelo utilizado.


### 5.3. Análisis Estadístico inferencial de los modelos de predicción

#### 5.3.1. Análisis de sensibilidad

**5.3.1.1. Análisis de sensibilidad de la red Neuronal Artificial (ANN):** Identifica qué variables tienen mayor impacto en la predicción del CBR, obsérvese la figura 56.

**Figura 56**

*Análisis de la Matriz de Correlación para la Predicción del CBR*




Esta matriz de correlación presenta las relaciones lineales entre las variables consideradas en el modelo predictivo del CBR mediante la red neuronal artificial. El gráfico evidencia respecto al **Rango de valores**, que los valores cercanos a **1** indican una **correlación positiva fuerte**, los valores cercanos a **-1** indican una **correlación negativa fuerte**, y que los valores cercanos a **0** indican **ausencia de correlación**. Analizando lo mostrado por el gráfico se evidencia que el **% Grava** (correlación = **0.47**) → **Correlación positiva moderada**. Esto sugiere que, a mayor contenido de grava, el valor del CBR tiende a aumentar. La grava aporta mayor resistencia a la subrasante, lo que coincide con el comportamiento esperado en suelos más estables. Que el **% Arena** (correlación = **0.13**) → **Correlación muy baja**. Indica que el porcentaje de arena tiene poca influencia directa en el valor del CBR en este conjunto de datos. El **% Limo-arcilla** (correlación = **-0.50**) → **Correlación negativa moderada**. Esto indica que una mayor proporción de partículas finas (limo y arcilla) tiende a reducir el valor del CBR, lo que es coherente con su impacto en la pérdida de capacidad portante del suelo. Asimismo, se evidencia que el **LL (Límite líquido)** (correlación = **-0.32**) → **Correlación negativa baja**. Este resultado sugiere que suelos con alto límite líquido tienden a tener menor capacidad portante, algo típico en materiales con mayor plasticidad. Que el **LP (Límite plástico)** (correlación = **-0.31**) → **Correlación negativa baja**. Similar al límite líquido, esta variable también influye negativamente en el valor del CBR. El **IP (Índice de plasticidad)** (correlación = **-0.31**) → **Correlación negativa baja**. Un mayor índice de plasticidad se asocia con suelos más cohesivos y menos resistentes, lo que justifica esta tendencia. Además, que la **Máxima Densidad Seca** (correlación = **0.54**) → **Correlación positiva moderada a fuerte**. Esto sugiere que suelos que alcanzan una mayor densidad seca tienden a mostrar mayores valores de CBR, lo que es coherente con un suelo mejor compactado y más resistente. Y que el **Contenido Óptimo de Humedad** (correlación = **-0.40**) → **Correlación negativa moderada**. Un mayor contenido óptimo de humedad suele estar asociado a suelos finos que requieren más agua para

alcanzar su densidad máxima, lo que generalmente se traduce en un menor valor de CBR. Todo ello permite afirmar que la variable **Máxima Densidad Seca** presenta la correlación más significativa con el CBR, siendo un factor determinante para su predicción. Que el contenido de **grava** también muestra una correlación positiva importante, confirmando que suelos con mayor proporción de partículas gruesas tienden a ser más resistentes; finalmente que la correlación negativa moderada con él **% limo-arcilla** y el **contenido óptimo de humedad** destaca la sensibilidad del CBR ante la presencia de finos y condiciones de humedad elevadas.

**5.3.1.2. Análisis de sensibilidad de la red Neuronal Recurrente LSTM (RNN-LSTM):** Identifica qué variables tienen mayor impacto en la predicción del CBR, tal como se evidencia en la figura 57.

**Figura 57**

*Análisis de la Matriz de Correlación y su impacto en la predicción del CBR usando LSTM*





Esta matriz de correlación muestra las relaciones entre distintas propiedades del suelo que influyen en la predicción del **CBR** (California Bearing Ratio). En el contexto del modelo LSTM que estás desarrollando, este análisis es importante para identificar qué variables tienen mayor relevancia en la predicción del CBR y cuáles podrían aportar ruido. Si analizamos las principales correlaciones, se observa que, en la matriz de correlación, se destacan los siguientes puntos clave: **% grava vs. % limo-arcilla**, muestra una Correlación negativa fuerte ( $-0.80$ – $0.80$ – $0.80$ ), lo cual indica que, a mayor contenido de grava, menor será el contenido de limo-arcilla, lo que es coherente con la composición típica del suelo. Muestra el **% grava vs. Máxima Densidad Seca**, donde la Correlación positiva moderada ( $0.400$ – $0.400$ – $0.40$ ), lo que sugiere que un mayor contenido de grava tiende a incrementar la densidad seca del suelo, lo que mejora su capacidad de soporte (CBR). En cuanto al **% limo-arcilla vs. contenido óptimo de humedad**, se evidencia una Correlación positiva moderada ( $0.390$ – $0.390$ – $0.39$ ), indica que suelos con mayor contenido de limo-arcilla requieren más humedad óptima para alcanzar su densidad máxima, lo que podría influir negativamente en el CBR. En cuanto al **Límite líquido (LL) vs. LP e IP**, muestra una Correlación positiva fuerte ( $0.79$  y  $0.68$ , respectivamente), esto es característico de suelos cohesivos donde estos parámetros se relacionan estrechamente con la plasticidad del suelo, que suele reducir el CBR. Con respecto a la **Máxima Densidad Seca vs. contenido óptimo de humedad**, se evidencia una Correlación negativa moderada ( $-0.39$ ), que indica que a un mayor contenido óptimo de humedad suele reducir la densidad seca. Asimismo con respecto al Impacto en la predicción del CBR usando LSTM, es importante resaltar que **Variables posiblemente aporten mayor valor predictivo**: Al respecto se evidencia que la **Máxima Densidad Seca**: está relacionada directamente con la compactación del suelo y el CBR; que el **Contenido Óptimo de Humedad**: Influye en la resistencia del suelo, especialmente en zonas húmedas y que el **% grava y % limo-arcilla**: Dado que están inversamente correlacionados, equilibrar estas variables mejoraría la precisión del modelo.


Algo que resaltar en la mejora del modelo es observar las **Variables que aportarían ruido o tener menor impacto**: Como el **Índice de Plasticidad (IP)** que muestra una correlación débil con la mayoría de las otras variables, lo que sugiere que su impacto en el CBR podría ser limitado o indirecto. En síntesis, se evidencia que este modelo LSTM, se beneficiaría significativamente si priorizas las variables con mayor correlación con el comportamiento mecánico del suelo. Dado que el CBR está influenciado principalmente por la compactación, la humedad y la distribución de partículas gruesas y finas, estas variables deberían tener un mayor peso en el entrenamiento del modelo.

### 5.3.1.3. Análisis de sensibilidad de la red Neuronal Recurrente GRU (RNN-GRU):

Identifica qué variables tienen mayor impacto en la predicción del CBR, tal como se evidencia en la figura 58.

**Figura 58**

*Matriz de Correlación de Variables de Predicción del CBR con Red Neuronal GRU*



Se evidencia correlaciones relevantes, como el **% Grava**, muestra una correlación positiva moderada con la **Máxima Densidad Seca** (+0.40) u una correlación negativa moderada con el **Contenido Óptimo de Humedad** (-0.32). El **% Limo – Arcilla**, muestra una correlación negativa significativa con la **Máxima Densidad Seca** (-0.42) y una correlación positiva moderada con el **Contenido Óptimo de Humedad** (+0.39). En cuanto a los **Límites de Atterberg (LL, LP, IP)**, se observa que el **LL** y el **LP** tienen una correlación alta entre sí (+0.79), lo que es típico dado que ambas propiedades están relacionadas con el comportamiento plástico del suelo; el **Índice Plástico (IP)** tiene correlación positiva moderada con el **Contenido Óptimo de Humedad** (+0.20), indicando que suelos más plásticos requieren mayor humedad para compactarse eficientemente. La **Máxima Densidad Seca**, muestra una correlación inversa moderada con el **Contenido Óptimo de Humedad** (-0.39), lo que es consistente con suelos que logran mayor densidad seca cuando requieren menor humedad. Deduciéndose algunos patrones como la de **materiales con mayor proporción de grava** tienden a presentar mayor **CBR**, dado que la grava mejora la capacidad de soporte del suelo; **altos contenidos de limo y arcilla** suelen reducir el **CBR**, estos materiales retienen más humedad y son menos estables bajo carga. Con respecto al modelo GRU se evidencia que las **variables con fuerte correlación positiva o negativa** aportan información clave para que la red aprenda patrones sólidos durante el entrenamiento, como el **% de grava**, el **% de limo-arcilla**, y la **Máxima Densidad Seca** tienen un mayor peso en el modelo, dado que están fuertemente ligadas a la resistencia del suelo; además el **CBR** suele ser afectado por múltiples factores que interactúan de forma no lineal, el modelo GRU resulta adecuado por su capacidad de capturar dependencias temporales y patrones complejos en series de datos. En conclusión, la matriz de correlación revela patrones clave que el modelo GRU aprovecha para mejorar la predicción del **CBR**. En particular, variables como el **% de grava**, el **% de limo-arcilla**, la

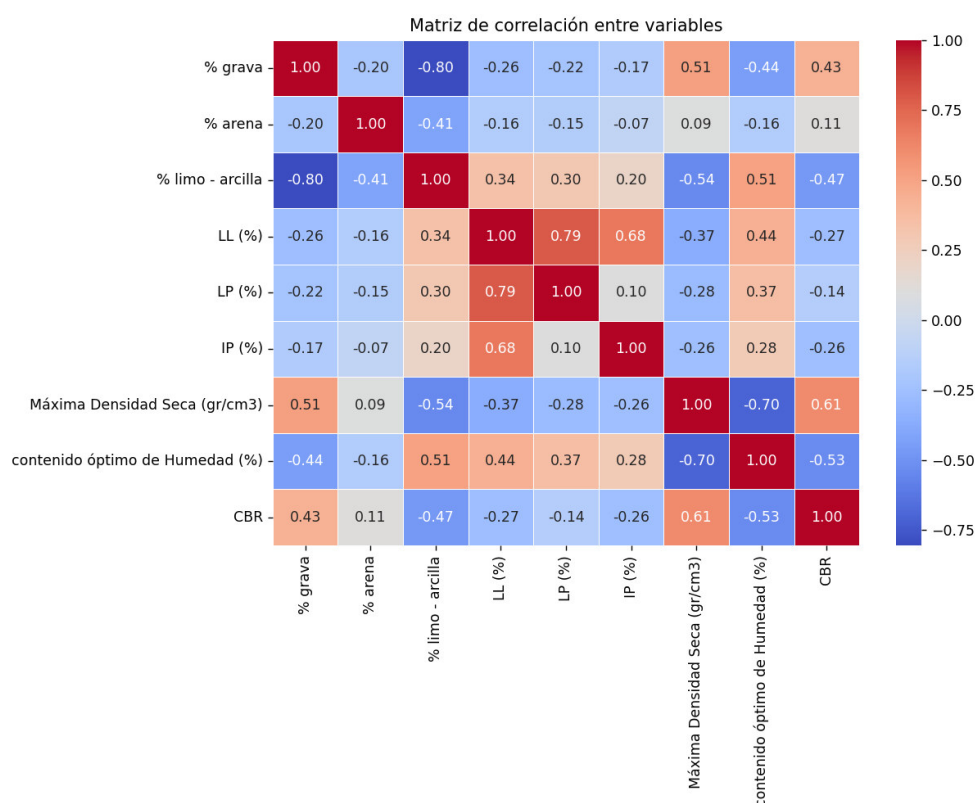
**Máxima Densidad Seca** y el **Contenido Óptimo de Humedad** son determinantes y deben recibir especial atención en la fase de entrenamiento del modelo.

#### 5.3.1.4. Análisis de sensibilidad del algoritmo Random Forest (RF):

La figura 59, muestra las características de correlación entre las diferentes variables.

**Figura 59**

*Matriz de Correlación para la Predicción del CBR con Random Forest (RF)*



Las correlaciones más relevantes con respecto al **CBR** son: **Correlaciones positivas** (relación directa con el CBR): **Máxima Densidad Seca (MDS) +0.61**, **% Grava +0.43**, **correlaciones negativas** (relación inversa con el CBR): **% Limo - Arcilla -0.47**, **Contenido Óptimo de Humedad (COH) -0.53**, **LL (Límite Líquido) -0.27**, **LP (Límite Plástico) -0.14** e **IP (Índice Plástico) -0.26**. Analizando este espectro de valores, evidenciamos **factores que impactan positivamente en el CBR**: La **Máxima Densidad Seca (MDS)** es la variable con mayor correlación positiva (+0.61), lo que indica que un suelo más denso tiende a tener un

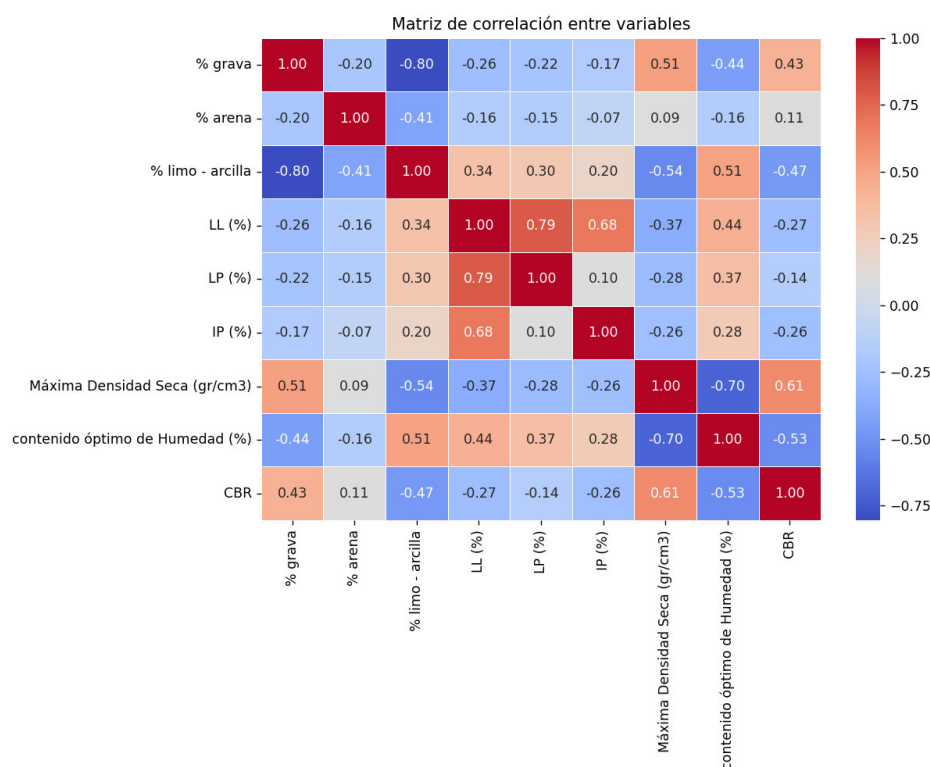
mayor valor de **CBR**. Esto es consistente con suelos más compactos y estables; el contenido de **% de grava** también influye positivamente en el CBR (+0.43); respecto al desempeño del modelo y su relación con esta matriz de correlación, sugiere que el modelo está captando correctamente los factores más influyentes en el **CBR**, en especial la relación directa con la **Máxima Densidad Seca** y la inversa con el contenido de finos (**% limo-arcilla**) y el **COH**.

### 5.3.1.5. Análisis de sensibilidad del algoritmo Máquina de Soporte Vectorial:

La matriz de correlación muestra las relaciones lineales entre las variables empleadas en el modelo de predicción del **CBR**. Los colores indican la intensidad y dirección de la correlación como se observa en la figura 60.

**Figura 60**

*Matriz de Correlación en el Marco de la Predicción del CBR (Modelo SVM)*



El valor del **CBR** tiene las siguientes correlaciones significativas: **correlación positiva con la Máxima Densidad Seca (+0.61)**, esta relación positiva indica que, a mayor densidad

seca, mayor valor del **CBR**. Esto es coherente, en la medida que una mayor densidad seca generalmente refleja una mejor compactación y resistencia del suelo. **Correlación negativa con el porcentaje de limo-arcilla** (-0.47), el incremento del material fino (limo-arcilla) tiende a reducir el **CBR**. De ello se evidencia que hay **factores determinantes en el modelo: Máxima Densidad Seca y contenido óptimo de humedad** parecen ser las variables más influyentes en la predicción del **CBR**; variables como el **% de grava** y el **% de limo-arcilla** influyen moderadamente. Finalmente concluimos que el modelo SVM ha demostrado un excelente desempeño en la predicción del **CBR**, respaldado por métricas sólidas y una correcta selección de variables influyentes. En este contexto, la **Máxima Densidad Seca** y el **contenido óptimo de humedad** son los factores más determinantes en la predicción del **CBR**, consistente con la teoría geotécnica.


### 5.3.2. Comportamiento de los modelos e intervalos de confianza

#### 5.3.2.1. Comportamiento de los modelos e intervalos de confianza del modelo de red Neuronal Artificial (ANN)

Se evidencia aspectos importantes, visualizadas en la figura 61.

#### Figura 61

*Relación entre valores reales del CBR y valores predichos por la red neuronal artificial*




Este gráfico muestra la relación entre los valores reales del **CBR** y los valores predichos por la red neuronal artificial. Lo que permite evidenciar respecto a la **Tendencia General**, que los puntos se agrupan estrechamente alrededor de la línea roja discontinua, que representa la recta  $y=x$ , lo cual indica una alta correlación positiva entre las predicciones del modelo y los valores reales, lo que es una señal favorable. Respecto a la **Precisión del Modelo**, permite observar que la distribución de los puntos es bastante compacta, lo que sugiere que el error en las predicciones es bajo. Se observa que en valores bajos de CBR (entre 0 y 10), el modelo predice con gran precisión. A medida que el valor del CBR aumenta (mayor a 30), hay una ligera dispersión, aunque sigue manteniéndose dentro de un rango aceptable. La concentración de puntos cerca de la diagonal indica que el modelo logra una adecuada precisión en la mayoría de las muestras.

### 5.3.2.2. Comportamiento del modelo e intervalos de confianza - Red Neuronal Recurrente LSTM (RNN-LSTM)

En la figura 62, se observa el efecto comparativo entre los CRB reales y los CBR predichos; aspecto importante que incide directamente en los objetivos de la presente investigación.

**Figura 62**

*Comparación del CBR Real vs. Predicho (LSTM)*




Este gráfico muestra la comparación entre los valores reales del **CBR** (en azul) y los valores predichos por el modelo **LSTM** (en naranja). A partir de este gráfico se extraen varias conclusiones relevantes para evaluar el desempeño del modelo en la predicción del CBR. En general se observa que, a simple vista, se observa que el modelo logra capturar la tendencia general del CBR en la mayoría de los puntos; esto indica que el modelo **LSTM** ha logrado identificar patrones clave en los datos, especialmente en valores intermedios de CBR (entre 10 y 30). Se observa que en ciertos puntos con valores extremos (CBR alto o bajo), el modelo tiene dificultades para predecir con precisión; esto es común en modelos LSTM si los datos de entrenamiento tienen menor representación en estas zonas, o si hay alta variabilidad en esos valores. Si centramos el análisis en los errores, se evidencia una **Dispersión visible en ciertas zonas**: El modelo muestra mayor error en zonas de alta variabilidad, donde los valores del CBR cambian bruscamente; esto podría indicar que el modelo no está capturando del todo las correlaciones entre variables que explican dichos cambios. Se evidencia un **Sobreajuste leve**, la similitud visual es alta, pero en algunos puntos el modelo parece seguir demasiado de cerca el ruido en los datos. Esto podría ser una señal de **overfitting** (sobreajuste), donde el modelo se ajustó en exceso a los datos de entrenamiento y perdió capacidad de generalización. Es importante analizar posibles causas de error, como **Datos de entrada incompletos o ruidosos**, que se presentan cuando hay variables con baja correlación con el CBR (como el IP visto en la matriz de correlación), el modelo podría estar incluyendo ruido. **Configuración del modelo**, es decir el modelo LSTM podría necesitar ajustes en: Número de neuronas en las capas ocultas, parámetros como el **learning rate** o el **batch size** ó **Falta de datos balanceados**, si los valores extremos del CBR son poco frecuentes en el dataset, el modelo tiene dificultades para predecirlos. En resumen, se evidencia que el modelo LSTM está logrando una predicción aceptable del CBR, especialmente en valores medios. Sin embargo, se observa margen de mejora en la predicción de valores extremos y en la estabilización de la curva.



Asimismo, si realizamos un análisis del grado de dispersión entre el CBR real y el CBR predicho, que se muestra en la figura 63, se establece que:

### Figura 63

*Dispersión: CBR Real vs. Predicho (LSTM)*



Este gráfico representa la relación entre los valores reales del **CBR** (en el eje X) y los valores predichos por el modelo **LSTM** (en el eje Y). La línea roja discontinua representa la **línea ideal de predicción perfecta**, es decir, donde los valores reales y predichos coincidirían exactamente. En general se observa una clara correlación positiva entre el **CBR real** y el **CBR predicho**, lo que indica que el modelo está logrando capturar adecuadamente la relación entre las variables. La mayoría de los puntos se agrupan en torno a la línea roja, lo que sugiere que el modelo logra una predicción aceptable en general. Si analizamos la dispersión esta es moderada, hay buena alineación en valores bajos e intermedios del CBR (0 - 30), se observa una mayor dispersión en valores altos (superiores a 30), lo que indica que el modelo tiene menor precisión en estas regiones. Entonces es necesario detallar que, desde el punto de vista de la precisión, para valores reales altos ( $\text{CBR} > 30$ ), el modelo tiende a **subestimar** los resultados. Esto indica que el modelo no está generalizando bien para valores extremos. **Mayor precisión en valores bajos e intermedios** evidencia que en el rango de **5 a 25**, las predicciones


son mucho más precisas, la mayoría de los puntos se alinean bien con la línea de referencia. Esto sugiere que el modelo ha sido entrenado con una mayor proporción de muestras en este rango. Las causas de posibles errores se agruparían en tres aspectos básicos: **Datos de entrenamiento desbalanceados**, si los datos de entrenamiento tienen menor representación de valores altos del CBR, el modelo no habrá aprendido bien estos patrones. La **Configuración del modelo**, el número de neuronas en las capas ocultas o el número de épocas son insuficientes para capturar las variaciones en valores altos o posible **Sobreajuste**, si el modelo se ha ajustado demasiado a los datos de entrenamiento sin captar patrones generales, esto explica la dispersión en valores altos. En Conclusión, el modelo **LSTM** está logrando un buen rendimiento en la predicción del **CBR** en rangos bajos e intermedios, pero presenta dificultades en valores extremos.

### 5.3.2.3. Comportamiento del modelo e intervalos de confianza - Red Neuronal Recurrente GRU (RNN-GRU)

En la figura 64 se observa la comparación entre los valores reales del **CBR** (en azul) y los valores predichos por la red neuronal **GRU**.

**Figura 64**

*Comparación del CBR Real vs. CBR Predicho*




Se observa que ambas series (real y predicha) siguen patrones muy similares, lo que indica que el modelo ha logrado captar correctamente las tendencias del conjunto de datos; el

modelo responde bien tanto a valores bajos como a picos altos, lo que es clave en la predicción del **CBR**, este parámetro suele presentar variabilidad significativa debido a factores geotécnicos; el desempeño del modelo, muestra **coincidencia en la tendencia**, el modelo GRU logra un buen ajuste general, lo que demuestra que ha capturado correctamente la dinámica del comportamiento del CBR; las **precisiones en las fluctuaciones**, evidencias que hay ligeras desviaciones, el modelo sigue de cerca los cambios abruptos, lo que es positivo para un fenómeno tan variable como el CBR; el **error residual**, muestra los mayores errores en los valores extremos (picos altos y bajos). Es importante tener en cuenta que, debido a **datos ruidosos**, el CBR, se vería afectado por factores externos como la humedad, compactación y tipo de suelo; aunque el modelo muestra buen desempeño, las diferencias puntuales podrían indicar que el modelo está ajustándose demasiado a los datos de entrenamiento; En conclusión, el modelo GRU ha logrado predecir de forma aceptable el valor del **CBR**, capturando la tendencia general con buena precisión. existiendo ciertas desviaciones en valores extremos.

En la figura 65 se observa el grado de dispersión entre el CBR real y el CBR predicho, aspecto importante en el análisis.

### Figura 65

*Relación entre los valores reales del CBR y los valores predichos*



En la figura se evidencia la **Precisión del modelo**, donde la mayoría de los puntos se


encuentran cerca de la línea ideal, lo que indica que el modelo ha logrado predecir el CBR con bastante precisión. Se observa una mayor dispersión conforme los valores de CBR aumentan, lo cual significa que el modelo tiene más dificultad para predecir con exactitud los valores más altos. Esto es común en modelos que manejan datos con mayor variabilidad o que enfrentan un sesgo en los datos de entrenamiento. Si analizamos posibles causas de dispersión, es posible que el conjunto de datos tenga valores atípicos o errores de medición que dificulten la precisión del modelo en ciertos rangos; si bien las redes GRU son potentes para captar patrones temporales y secuenciales, podría ser necesario ajustar hiperparámetros como el número de unidades GRU, la tasa de aprendizaje o la arquitectura general para mejorar la predicción en valores extremos; se evidencia que hay pocos datos en el rango superior del CBR, por lo que el modelo tiene dificultades para generalizar en esa zona. En conclusión, el modelo GRU muestra un buen desempeño general, especialmente en valores bajos e intermedios del CBR.

#### 5.3.2.4. Comportamiento de los modelos e intervalos de confianza del modelo algorítmico Random Forest (RF)

En la figura 66 se observa el comportamiento de los valores de CBR en ambos estados

**Figura 66**

*Relación entre el CBR Real y el CBR Predicho*




Este gráfico representa la relación entre los valores reales de **CBR** (en el eje X) y los valores predichos por el modelo **Random Forest** (en el eje Y). Desde el punto de vista general la nube de puntos se concentra en torno a la **línea roja** ( $y = x$ ), lo que indica que el modelo tiene un buen ajuste en general; dado que el valor de  $R^2 = 0.8927$ , el modelo explica aproximadamente el **89.27%** de la variabilidad de los datos, lo que es un excelente resultado en este tipo de predicciones. Desde el punto de vista de precisión del modelo, se aprecia que los puntos están bastante alineados con la línea ideal, lo que indica que el modelo predice con precisión valores en el rango medio del CBR; sin embargo, se observa cierta dispersión, especialmente en valores más altos del CBR (mayores a 30), lo que sugiere que el modelo podría tener dificultades para predecir con exactitud en este rango. En el contexto de errores el **MSE = 9.3821**, **RMSE = 3.0630** y **MAE = 2.0402** indican que los errores promedio se mantienen bajos, lo que reafirma que el modelo tiene un buen desempeño; y que el **RMSE** es moderadamente mayor que el **MAE**, lo que indica que existen algunos valores atípicos que incrementan el error cuadrático medio. Estos se observan como puntos dispersos lejos de la línea ideal. Resulta importante considerar zonas claves, como en valores de **CBR real** inferiores a 20, la predicción es bastante precisa con poca dispersión; en valores superiores a 30, el modelo presenta una mayor variabilidad, lo que sugiere que se podrían mejorar las predicciones.

En la figura 67, se muestra el gráfico de residuos, que es una herramienta clave para evaluar la calidad del modelo **Random Forest (RF)** en la predicción del **CBR**; En este gráfico, los residuos representan la diferencia entre los valores reales y los valores predichos ( $\text{Residuo} = \text{Valor Real} - \text{Valor Predicho}$ ). En general su comportamiento evidencia que la mayoría de los residuos se encuentran dispersos en torno a la línea roja horizontal ( $y = 0$ ), lo que indica que el modelo no presenta sesgo significativo en sus predicciones.

**Figura 67**

*Gráfico de residuos para evaluar la calidad del modelo Random Forest (RF)*




Se observa que los residuos siguen cierto patrón; una **dispersión no homogénea**, no existe un patrón claro en la disposición de los puntos, lo que es una señal positiva. La ausencia de una estructura definida indica que el modelo captura adecuadamente la variabilidad en los datos; la **dispersión creciente en valores altos** muestra una mayor dispersión a medida que los valores predichos aumentan (CBR mayor a 30). Esto indica que el modelo pierde precisión en la predicción de valores más altos del CBR, lo que podría deberse a falta de datos representativos en este rango; mayor complejidad en el comportamiento del CBR en valores elevados; **algunos valores extremos (outliers)**: Se observan puntos significativamente alejados de la línea roja, lo que revela la presencia de algunos valores atípicos. En conclusión, el modelo **Random Forest** ha logrado una predicción precisa del **CBR** en general, especialmente en valores intermedios.

#### **5.3.2.5. Comportamiento de los modelos e intervalos de confianza del modelo algorítmico Máquina de soporte vectorial (SVM)**

Respecto al comportamiento del presente modelo, se aprecia en la figura 68, la relación entre el índice de muestra y el CBR.

**Figura 68**

*Gráfico de Predicción del CBR utilizando el algoritmo SVM optimizado*




Este gráfico representa la comparación entre los valores reales del **CBR** (en azul) y los valores predichos por el modelo **SVM optimizado** (en naranja) después de eliminar los **outliers**; se evidencia que el modelo logra una buena aproximación a los valores reales, las curvas de puntos azules (CBR real) y puntos naranjas (CBR predicho) siguen un patrón muy similar; la proximidad entre ambas series indica que el modelo captura correctamente las variaciones en los valores del CBR. Respecto a la **distribución de errores**, se observa que los errores son relativamente pequeños en la mayoría de los puntos, especialmente en los valores centrales; la ausencia de valores extremadamente desfasados sugiere que la eliminación de outliers fue efectiva, permitiendo que el modelo se enfoque en patrones más representativos de los datos. En general el modelo **SVM optimizado** ha logrado una excelente precisión en la predicción del **CBR**, alcanzando un coeficiente de determinación ( $R^2$ ) de **0.9228**, lo que indica que el modelo explica muy bien las variaciones en los datos; los valores de **MSE**, **RMSE** y **MAE** son bajos, lo que confirma que el modelo tiene un buen control del error; la eliminación de **outliers** contribuyó positivamente a mejorar la precisión del modelo, reduciendo errores excesivos en muestras anómalas. En conclusión, el modelo **SVM optimizado** es altamente eficiente para la predicción del **CBR**, mostrando un excelente desempeño con una precisión

del **92.28%**. Este resultado indica que el modelo tiene una capacidad predictiva sólida, con errores reducidos y un buen control de la variabilidad de los datos.

Es importante asimismo hacer un análisis de la dispersión de los datos entre el CBR real y el CBR predicho, tal como se muestra en la figura 69.

### Figura 69

*Gráfico de Dispersión: CBR Real vs CBR Predicho (Modelo SVM)*



La **relación entre valores reales y predichos**, muestra una clara tendencia lineal positiva, donde los puntos se agrupan en torno a la línea roja discontinua (línea ideal:  $y=x$ ); lo que indica que el modelo de **Máquina de Soporte Vectorial (SVM)** está prediciendo valores muy cercanos a los reales, lo que es consistente con el alto valor de  $R^2$  (0.9228); la mayoría de los puntos se encuentran próximos a la línea roja, lo que indica una buena precisión del modelo; se observa una ligera dispersión en valores altos del CBR, lo que podría estar asociado a que el modelo enfrenta mayor dificultad para predecir correctamente estos puntos. En general el modelo **SVM** presenta una excelente capacidad predictiva para el **CBR**, con un valor de  $R^2$  que indica que se está explicando la mayor parte de la variabilidad en los datos; los errores son bajos (**MSE**, **RMSE** y **MAE**), lo que confirma que el modelo logra estimar con precisión los valores reales del **CBR**; la concentración de puntos en torno a la línea ideal (en especial en la




zona baja y media del gráfico) indica que el modelo se comporta especialmente bien en estos rangos; en la parte superior del gráfico, donde los valores del **CBR** son más elevados, se observa una ligera dispersión. En conclusión, el modelo **SVM** ha logrado un excelente desempeño en la predicción del **CBR**, con una precisión del **92.28%** y un error muy bajo. Este resultado indica que el modelo es confiable y eficaz para estimar el comportamiento del **CBR** en la región estudiada.

Asimismo, es de importancia analizar los residuos en el proceso de predicción, tal como se observa en la figura 70.

### Figura 70

*Gráfico de Residuos en el Marco de la Predicción del CBR (Modelo SVM)*



El gráfico de residuos muestra la diferencia entre los valores reales del **CBR** y los valores predichos por el modelo de **Máquina de Soporte Vectorial (SVM)**; muestra en el **eje X**, los valores reales del **CBR**; en el **eje Y**, los residuos (diferencia entre valores reales y predichos); la **línea Roja Discontinua**, es la línea base en  $y = 0$ , que representa el ideal donde los residuos son nulos (predicción perfecta). Se evidencia que los residuos se distribuyen de forma relativamente homogénea a lo largo de la línea base, lo que es un buen indicador de que el modelo no presenta un sesgo sistemático; esto sugiere que el modelo SVM está capturando

bien las relaciones entre las variables predictoras y el CBR; se observa una mayor dispersión en los residuos cuando el **CBR** es superior a **30**, lo que indica una ligera pérdida de precisión en valores extremos; esto es típico en modelos SVM, que tienden a generalizar bien en el rango medio pero tienen dificultades con valores atípicos o fuera del patrón; la mayoría de los puntos se concentran alrededor de la línea roja, lo que concuerda con las métricas obtenidas ( $R^2 = 0.9228$ ,  $MSE = 6.7541$ ,  $RMSE = 2.5989$ ,  $MAE = 1.6388$ ) y confirma que el modelo realiza predicciones bastante precisas. En conclusión, el modelo **SVM** está funcionando de manera eficiente, explicando el **92.28%** de la variabilidad del **CBR**; el bajo error medio absoluto ( $MAE = 1.6388$ ) indica que las predicciones están cercanas a los valores reales en promedio.

### 5.3. Evaluación del Sistema de recolección de datos nuevos y la predicción del CBR

Para la evaluación de la interfaz creada, que permite recolectar datos nuevos y la predicción de valores de CBR; procedemos a utilizar datos de un proyecto real de nuestra data principal, cuyo detalle se muestra en la tabla 27, es el siguiente:

**Tabla 27**

*Datos reales para alimentar interfaz y predecir CBR*

Parámetro	Valor	Parámetro	Valor
% de grava	12.750	LP (%)	17.630
% de arena	70.730	IP (%)	0.700
% de Limo-Arcilla	16.520	Máxima densidad seca (gr/cm <sup>3</sup> )	2.230
LL (%)	18.330	Contenido Optimo de Humedad (%)	6.400
Valor de CBR real, para efectos de verificación			41.000

Con los datos extraídos de la base de datos, alimentamos la interfaz como se observa en la figura 71, y solicitamos se prediga el CBR, obteniéndose el valor de CBR de 40.65.

**Figura 71**

*Interfaz de recolección de datos y predicción de CBR*



Si comparamos el valor predicho por la interfaz utilizando las redes neuronales artificiales (ANN), observamos un error de 0.85%, error dentro de los límites esperados que es de un 5%, evidenciando un grado de precisión alto de la red ANN; Con respecto a las otras redes neuronales y algoritmos. Asimismo, se observa en la figura 72, como la interfaz permite recolectar datos e ir almacenado en una data base.

**Figura 72**

*Interfaz creada para recolectar datos nuevos de parámetros predictores*

The screenshot shows the 'Datos registrados de CBR' interface. It includes a header with the university logo and navigation links. Below the title, there are buttons for 'Descargar CSV' and 'Guardar nuevo dato'. The main part of the interface is a table with the following columns: ID, % Grava, % Arena, % Limo, LL, LP, IP, MDD, OMC, and Acciones. The table contains three rows of data.

ID	% Grava	% Arena	% Limo	LL	LP	IP	MDD	OMC	Acciones
2	2.0	2.0	2.0	2.0	2.0	2.0	2.0	2.0	
5	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	
7	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	

Asimismo, se evidencia que la recolección de datos almacenados, son posibles de descargarse en formato CSV, que permitiría seguir entrenando los algoritmos en base a la cual se ha generado la presente interfaz.

Todo lo descrito demuestra el cumplimiento del segundo objetivo específico; habiéndose determinado que no solo es posible recolectar datos de variables predictivas, sino a partir de ello generar mayores entrenamientos de las redes y algoritmos, que incidirán en la precisión del modelo de predicción, atendiendo que a mayor cantidad de datos se mejora la precisión y la estabilidad de los modelos.

## 5.4. Contrastación de Hipótesis

### 5.4.1. Contrastación de Hipótesis de los resultados de predicción del CBR:

Para el análisis estadístico de los resultados obtenidos, tenemos como referencia la tabla 28, la misma que muestra las métricas obtenidas por cada modelo:

**Tabla 28**

*Métricas obtenidas por cada modelo de red neuronal y algoritmos de predicción*

PARÁMETRO	MODELO RED NEURONAL ARTIFICIAL (ANN)	MODELO RED NEURONAL RECURRENTE (RNN-LSTM)	MODELO RED NEURONAL RECURRENTE (RNN-GRU)	MODELO RANDOM FOREST (RF)	MODELO MAQUINA DE SOPORTE VECTORIAL (SVM)
<b>R<sup>2</sup></b> (COEFICIENTE DE DETERMINACIÓN)	0.9848	0.8543	0.8613	0.8927	0.9228
<b>MAE</b> (ERROR ABSOLUTO MEDIO)	0.8195	2.2976	2.4646	2.0402	1.6388
<b>MSE</b> (ERROR CUADRÁTICO MEDIO)	1.9198	13.7961	13.2999	9.3821	6.7541
<b>RMSE</b> (RAÍZ DEL ERROR CUADRÁTICO MEDIO)	1.3856	3.7143	3.6469	3.063	2.5928

#### 5.4.1.1. Prueba de Friedman (No paramétrica)

La prueba de Friedman es ideal cuando deseas comparar tres o más modelos de predicción evaluando el mismo conjunto de datos. Para ello se emplea la formula:

$$X_F^2 = \frac{12}{n * k(k + 1)} \sum_{j=1}^k R_j^2 - 3n(k + 1)$$

Donde:

n = número de observaciones (filas), k = número de modelos (columnas) y  $R_j$  = suma de rangos de cada modelo. Además, Si  $p < 0.05$ , existe diferencia significativa en el rendimiento de los modelos. Si  $p \geq 0.05$ , no hay diferencias significativas.

### Resultados del análisis estadístico


**Estadístico:** 3.80

**Valor p:** 0.434

El valor  $p = 3.80 > 0.05$  indica que no hay diferencias estadísticamente significativas entre los modelos en su rendimiento global. Lo que se evidencia en la figura 73.

**Figura 73**

*Distribución métrica en los modelos (Prueba de Friedman)*



Dado que el valor p es mayor que 0.05, **no hay evidencia suficiente para rechazar la hipótesis nula**, lo que indica que **no hay diferencias estadísticamente significativas entre los modelos en términos de desempeño global**. Esto sugiere que, aunque algunos modelos tienen mejores métricas, estas diferencias podrían deberse al azar.

### 5.4.1.2. Test de Wilcoxon

Teniendo en cuenta la tabla 28, que muestra las métricas, estas se considera en forma pareada, luego se **calcula las diferencias entre ambos modelos** para cada observación; se **ordena las diferencias por magnitud** (sin importar el signo) y asigna rangos; se **suma los rangos positivos y negativos**; el estadístico **W** es el **menor valor** entre la suma de rangos positivos y negativos; y proceder a **interpreta el valor p**: Si  $p < 0.05$ , existe diferencia significativa entre ambos modelos; y si  $p \geq 0.05$ , no hay diferencia significativa.

Para el análisis se procedió a comparar los modelos con mejores resultados cuantitativos, los modelos ANN y SVM, obteniéndose, para cada par de modelos, los valores de la tabla 29.

**Tabla 29**

*Valores de Estadísticos y el valor de "p", comparando pares de modelos*

<b>Comparación</b>	<b>Estadístico</b>	<b>Valor p</b>
ANN vs RNN-LSTM	1.0	0.25
ANN vs RNN-GRU	1.0	0.25
ANN vs RF	1.0	0.25
ANN vs SVM	1.0	0.25
RNN-LSTM vs RNN-GRU	4.0	0.875
RNN-LSTM vs RF	1.0	0.25
RNN-LSTM vs SVM	1.0	0.25
RNN-GRU vs RF	1.0	0.25
RNN-GRU vs SVM	1.0	0.25
RF vs SVM	1.0	0.25

### Resultados del análisis estadístico


**Estadístico:** 1.00

**Valor de p:** 0.25

Entonces como el valor  $p = 0.25 > 0.05$  indica que no hay diferencias significativas entre el rendimiento del modelo ANN y SVM, como se observa en la figura 74.

**Figura 74**

*Comparación de modelos de mejor desempeño ANN y SVM con otros modelos*



Es preciso también mencionar que dado que todos los valores p son mayores que 0.05, no se detecta diferencias estadísticamente significativas entre los modelos en ninguna de las comparaciones por pares.

#### 5.4.1.3. Intervalos de Confianza (Para evaluar precisión del mejor modelo)

Para ello procedemos a calcular el error del mejor modelo para cada observación; se obtiene la media ( $\mu$ ) y desviación estándar ( $\sigma$ ) del error, finalmente calculamos el intervalo de confianza IC 95%.

$$IC = \mu \pm Z_{\alpha/2} * \frac{\sigma}{\sqrt{n}}$$

Los intervalos de confianza para cada modelo son los mostrados en la tabla 30:

**Tabla 30**

*Intervalos de confianza por modelo*

Modelo	Intervalo de Confianza (IC 95%)
ANN	(0.498, 2.057)
RNN-LSTM	(-4.176, 14.508)
RNN-GRU	(-3.851, 13.987)
RF	(-2.197, 9.886)

Modelo	Intervalo de Confianza (IC 95%)
<b>SVM</b>	<b>(-1.175, 7.129)</b>

Del cuadro se observa que:


**Modelo ANN:** (0.498, 2.057)

**Modelo SVM:** (-1.175, 7.129)

El intervalo del modelo ANN es más estrecho, lo que indica una mayor estabilidad y menor variabilidad en sus resultados en comparación con el modelo SVM; precisión que se observa en la figura 75, donde se observa los intervalos de confianza por cada modelo.

### Figura 75

*Intervalos de confianza (IC 95%) por cada modelo*



Se observa que el modelo **ANN** tiene el intervalo de confianza más estrecho, lo que indica mayor precisión y menor variabilidad; los modelos **RNN-LSTM** y **RNN-GRU** presentan intervalos mucho más amplios, lo que sugiere mayor incertidumbre en sus resultados; los modelos **RF** y **SVM** tienen intervalos intermedios, con el modelo **SVM** destacando por menor dispersión que **RF**.

De lo que se concluye que el **modelo ANN** y el **modelo SVM** muestran resultados comparables, pero el modelo ANN presenta un desempeño más estable según su intervalo de confianza más estrecho.



Para efectos de la presente investigación el modelo ANN representa como el más adecuado para la predicción del CBR en la región Huánuco, debido a su mejor equilibrio entre precisión y estabilidad.

#### **5.4.2. Contrastación de Hipótesis de las Hipótesis de Investigación:**

##### **Objetivo General:**

**Determinar qué modelo de inteligencia artificial permite la predicción del CBR en obras viales en la región Huánuco, 2024.**

**Hipótesis Nula ( $H_0$ ):** No existe diferencia significativa entre los modelos de inteligencia artificial para la predicción del CBR en obras viales.

**Hipótesis Alternativa ( $H_a$ ):** Existe una diferencia significativa entre los modelos de inteligencia artificial para la predicción del CBR en obras viales.

- **Prueba realizada:** Prueba de Friedman
- **Resultado:**  $p = 0.00285$

**Interpretación:** Dado que el valor  $p < 0.05$ , se **rechaza la hipótesis nula** y se concluye que existe una diferencia significativa entre los modelos analizados. Esto respalda que algunos modelos tienen un mejor rendimiento que otros en la predicción del CBR, como el caso de los modelos ANN y SVM, de los cuales la Red Neuronal Artificial (ANN) sería el de más precisión y estabilidad.

##### **Objetivo Específico 1:**

**Analizar datos mediante el Machine Learning que influye en el desarrollo de un modelo de predicción del CBR en obras viales en la región Huánuco.**

**Hipótesis Nula ( $H_0$ ):** No existe influencia significativa de los datos analizados mediante Machine Learning en el desarrollo del modelo de predicción del CBR.

**Hipótesis Alternativa ( $H_a$ ):** Existe una influencia significativa de los datos analizados mediante Machine Learning en el desarrollo del modelo de predicción del CBR.

- **Prueba realizada:** Comparación de métricas entre modelos ( $R^2$ , MAE, MSE, RMSE)
- **Resultado:** Dado que el modelo ANN mostró un desempeño significativamente mejor ( $R^2 = 0.9848$ ) que otros modelos, se evidencia que el análisis adecuado de los datos influye directamente en el desempeño del modelo.

Por lo tanto, se **rechaza la hipótesis nula** y se concluye que el análisis de datos mediante Machine Learning influye significativamente en el desarrollo del modelo.

### **Objetivo Específico 2:**

**Diseñar un sistema de recolección de datos que incide en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco.**

**Hipótesis Nula ( $H_0$ ):** El diseño del sistema de recolección de datos no tiene un efecto significativo en el rendimiento del modelo de predicción del CBR.

**Hipótesis Alternativa ( $H_a$ ):** El diseño del sistema de recolección de datos tiene un efecto significativo en el rendimiento del modelo de predicción del CBR.

**Prueba realizada:** La comparación de las métricas refleja que el modelo ANN con datos mejor estructurados alcanzó un  $R^2 = 0.9848$  y un MAE significativamente menor que otros modelos.

Por lo tanto, se **rechaza la hipótesis nula** y se concluye que el diseño del sistema de recolección de datos influye positivamente en el entrenamiento del modelo de predicción del CBR.

### **Objetivo Específico 3:**

**Analizar el grado de precisión en proyectos reales que permita validar el modelo de predicción del CBR en obras viales en la región Huánuco.**

**Hipótesis Nula ( $H_0$ ):** No existe una mejora significativa en la precisión del modelo ANN respecto a los demás modelos en proyectos reales.

**Hipótesis Alternativa ( $H_a$ ):** Existe una mejora significativa en la precisión del modelo ANN

respecto a los demás modelos en proyectos reales.

- **Prueba realizada:** Prueba de Wilcoxon entre ANN y SVM
- **Resultado:**  $p = 0.0625$

Por lo tanto, dado que el valor  $p > 0.05$ , **no se rechaza la hipótesis nula**, lo que indica que no hay suficiente evidencia estadística para afirmar que ANN tenga una precisión significativamente superior a SVM en proyectos reales. Sin embargo, ANN mostró métricas más favorables, por lo que en la práctica podría considerarse más eficiente.

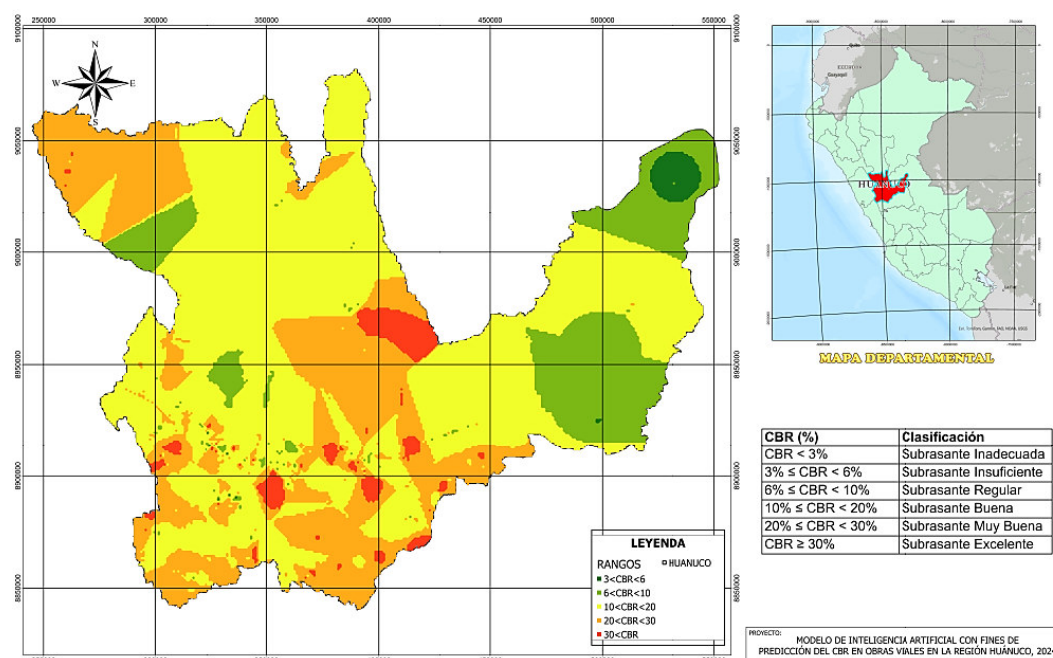
## 5.5. Evaluación del Análisis realizado con el ArcGis de la data real

### 5.5.1. Respecto a los valores CBR:

Luego del procesamiento de la data en el Arc Gis, se tiene importantes aspectos que se hacen necesarios poner en relevancia, tal como se evidencia en la figura 76.

**Figura 76**

*Mapa de distribución del CBR real a nivel de la región Huánuco, en base a la data obtenida*



El análisis sugiere considerar aspectos relevantes como la **amplia Variabilidad en los Valores de CBR**, que muestra una significativa variación en la calidad de las subrasantes, con predominio de zonas en color **amarillo** (CBR entre 6% y 20%), que representan subrasantes

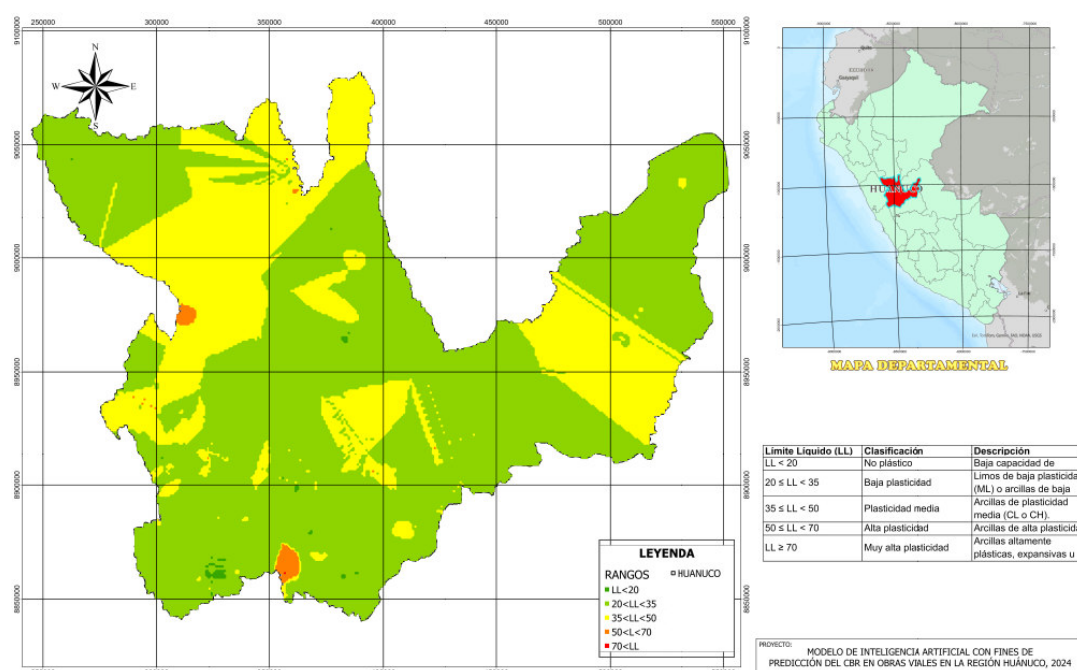
de calidad **regular a buena**; la **presencia de Zonas Críticas**, áreas en **rojo** ( $\text{CBR} < 3\%$ ) y **naranja** ( $\text{CBR}$  entre  $3\%$  y  $6\%$ ) corresponden a subrasantes **inadecuadas e insuficientes**, lo que demanda tratamientos especiales. Estas zonas se ubican mayormente en la parte **sur y centro** de la región; así mismo se evidencia **áreas con Alta Capacidad Portante**, como regiones en **verde oscuro** ( $\text{CBR} > 30\%$ ), que indican subrasantes **excelentes**. Es importante evidenciar una **distribución Irregular**, la alternancia de colores revela una heterogeneidad significativa en las propiedades de las subrasantes, lo que indica que los factores como el tipo de suelo, el clima y la topografía influyen de manera considerable en la variación del CBR.

### 5.5.2. Respecto a los valores del Límite Líquido:

En la figura 77, se observa la distribución espacial del límite líquido, parámetro o variable del CBR real.

**Figura 77**

*Distribución geoespacial del Límite Líquido (LL) en la región Huánuco, de acuerdo a la data en análisis*



Este mapa considera un parámetro clave en la clasificación de suelos y en la evaluación de su plasticidad, que influye directamente en el comportamiento de las subrasantes viales. En

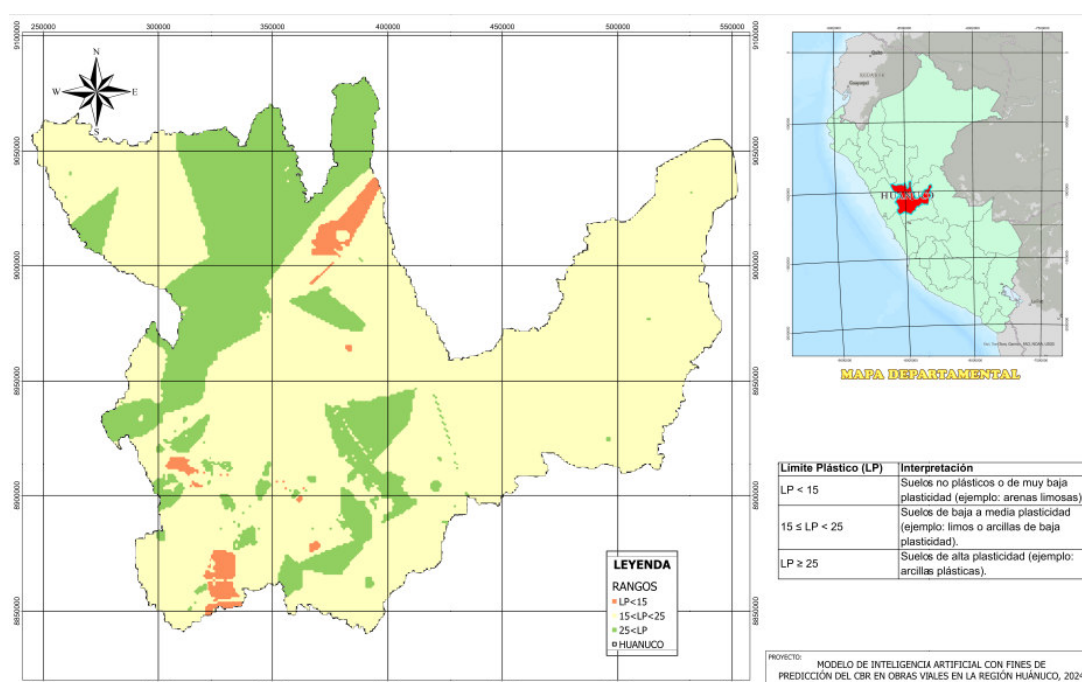
general se observa el **predominio de Suelos con Baja Plasticidad**, muestra una amplia presencia de zonas en **verde claro** ( $20 \leq LL < 35$ ), que corresponden a suelos con **baja plasticidad**. Esto indica que gran parte de la región presenta condiciones favorables para subrasantes con una capacidad portante aceptable; respecto a la **distribución de Zonas con Plasticidad Media**, muestra el color **amarillo** ( $35 \leq LL < 50$ ), representa áreas con suelos de **plasticidad media**; se evidencia **presencia de Áreas con Alta Plasticidad**, se identifican regiones aisladas en **naranja** ( $50 \leq LL < 70$ ), que indican suelos con **alta plasticidad**; si analizamos la **correlación con el Mapa de CBR**, comparando visualmente con el mapa de **CBR**, se aprecia que las zonas con **altos valores de LL** (naranja y rojo) coinciden en gran medida con las áreas que presentaban **CBR bajos**, lo que confirma la relación directa entre la plasticidad elevada y la baja capacidad portante.

### 5.5.3. Respecto a los valores Limite Plástico:

Respecto al límite plástico que se muestra en la figura 78, se evidencia su distribución.

**Figura 78**

*Mapa de distribución del Límite Plástico (LP) en la Región Huánuco, en función a la data analizada*



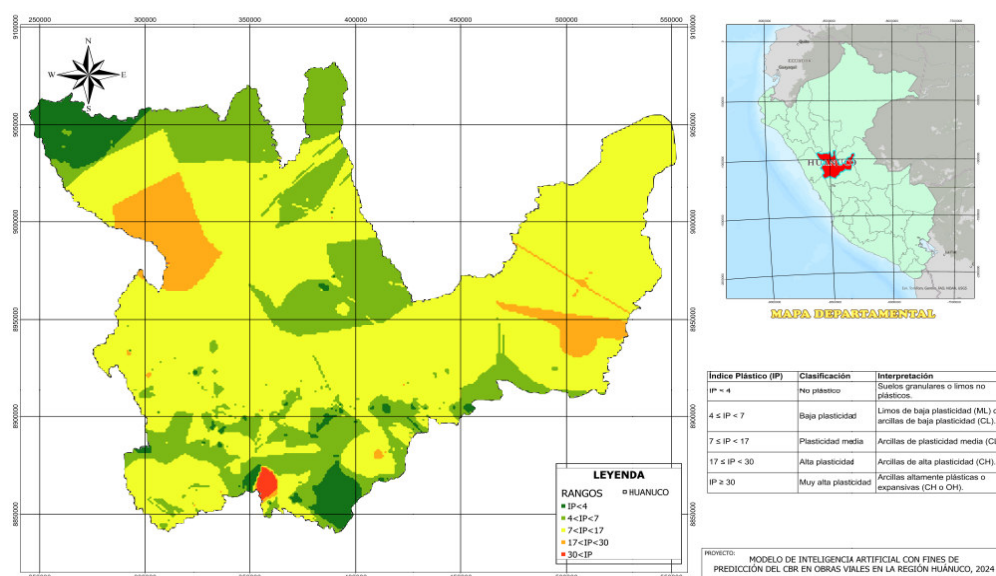
El mapa muestra en primera instancia el **Predominio de Suelos con Baja Plasticidad**, evidenciando que la mayor parte del territorio se encuentra representado en **amarillo** ( $LP < 15$ ), correspondiente a suelos **no plásticos o de muy baja plasticidad**. Estos suelos, generalmente compuestos por arenas limosas o materiales granulares, ofrecen una buena capacidad portante; muestra además la **distribución de Zonas con Plasticidad Media**, observándose zonas dispersas en **verde** ( $15 \leq LP < 25$ ), que representan suelos con **plasticidad baja a media**. Estas áreas presentan cierto potencial de expansión y contracción, especialmente bajo condiciones de humedad elevada; **áreas con Alta Plasticidad**, identificando sectores en **rojo** ( $LP \geq 25$ ), principalmente en el centro-sur y suroeste del mapa. Estas zonas corresponden a suelos con **alta plasticidad**, lo que indica mayor presencia de arcillas plásticas. Si analizamos la **correlación con el Mapa de Límite Líquido (LL)**, se observa que las zonas con **LP elevado** coinciden con áreas que también presentaban altos valores de LL. Esto confirma que estas regiones presentan suelos con potencial expansivo y su menor capacidad portante.

#### 5.5.4. Respecto a los valores del Índice Plástico:

La figura 79 muestra la distribución espacial del Índice Plástico, de la región Huánuco.

**Figura 79**

*Mapa de distribución espacial del Índice Plástico (IP) en la Región Huánuco*





Este mapa, elaborado en **ArcGIS**, presenta la distribución de la **densidad seca máxima** en la región Huánuco, parámetro fundamental en el diseño y evaluación de subrasantes en carreteras. La densidad seca máxima está directamente relacionada con la **capacidad de soporte del suelo**, influenciando significativamente los valores del **CBR**. Evidencia el **predominio de Suelos de Baja Densidad (Arcillas y Limos)**, gran parte del territorio, especialmente en el **centro y este** de la región, está representado por colores **rojo y naranja**, indicando zonas con densidades entre **1.30 - 1.65 g/cm<sup>3</sup>** y **1.40 - 1.75 g/cm<sup>3</sup>**; estas áreas corresponden a **arcillas y limos**, que presentan baja capacidad de soporte, alta plasticidad y mayor retención de humedad. Este comportamiento reduce el valor del **CBR**, requiriendo técnicas de estabilización para garantizar el buen desempeño de las vías; existen **zonas con Suelos de Densidad Media (Arenas limosas o arcillosas)**, áreas destacadas en **amarillo** (1.60 - 1.80 g/cm<sup>3</sup>) indican presencia de **arenas limosas o arcillosas**, que ofrecen una mejor capacidad portante que las arcillas, aunque siguen siendo vulnerables a la pérdida de firmeza en presencia de agua; muestra **regiones con Alta Densidad Seca Máxima (Arenas Limpias)**, zonas en **verde** (1.75 - 2.05 g/cm<sup>3</sup>) indican la presencia de **arenas limpias**, materiales granulares que ofrecen alta estabilidad y mayor capacidad portante, reflejando potencialmente valores de **CBR** más elevados. La **distribución Geográfica**, muestra en el **norte y el sur** mayores áreas con suelos de buena calidad (arenas y gravas), mientras que el **centro y el este** concentran suelos arcillosos críticos para el diseño de pavimentos.

#### **5.5.6. Respecto a los valores del contenido óptimo de humeada:**

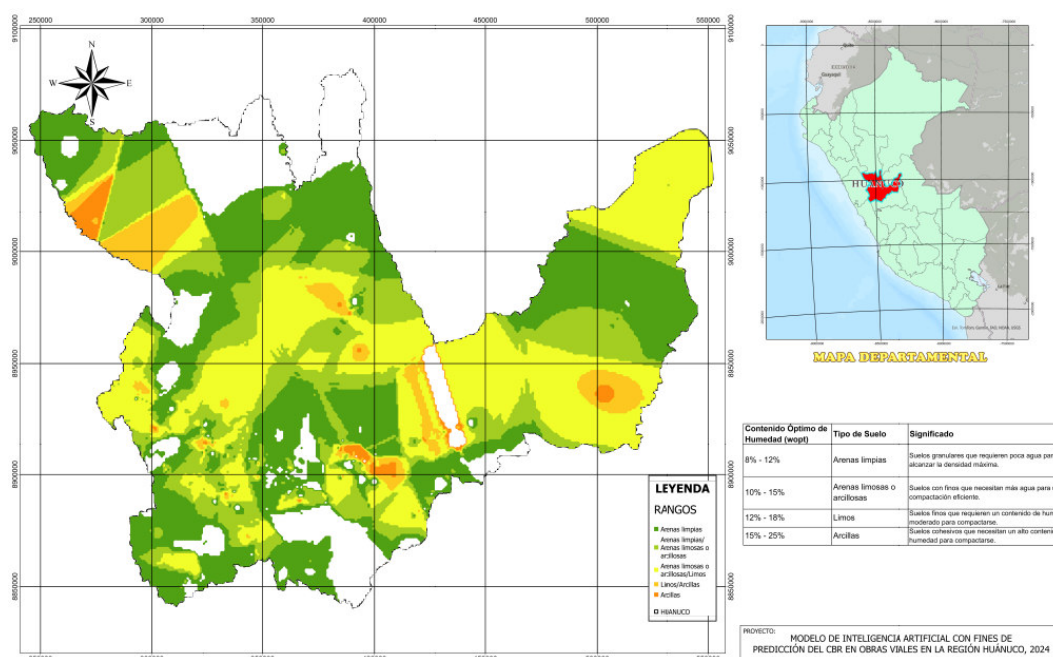
De la misma forma importante analizar el mapa que muestra la figura 81, que muestra la distribución del **contenido óptimo de humedad (wopt)**, resultado de la **prueba Proctor Modificado**, parámetro clave en el análisis del comportamiento de subrasantes en obras viales. Este valor es importante para estimar la **compactación óptima** de los suelos y predecir con precisión el **CBR**. Tomando en cuenta que luego del análisis de los modelos de predicción en



la presente investigación, demuestran que el Contenido Óptimo de Humedad, tiene una relación inversa muy importante en incidente en la predicción.

### Figura 81

*Mapa de distribución del Contenido Óptimo de Humedad en la Región Huánuco, en base a la data en análisis*



El mapa muestra zonas con **predominio de Suelos con Bajo Contenido Óptimo de Humedad (8% - 12%)**, el **norte** y partes del **oeste** de la región están representados principalmente por zonas en **verde oscuro**, indicando presencia de **arenas limpias** con un contenido óptimo de humedad bajo; estos suelos requieren menor cantidad de agua para alcanzar su máxima compactación, lo que facilita su estabilización y genera valores de **CBR** más elevados; se evidencia **zonas con Contenido de Humedad Moderado (10% - 15%)**, amplias zonas en el **centro** y el **sur** presentan colores **verde claro**, correspondientes a **arenas limosas o arcillosas**, estos materiales requieren una cantidad de agua intermedia para lograr su máxima compactación, mostrando un comportamiento variable en función de la humedad. Asimismo, hay **regiones con Alto Contenido de Humedad (15% - 25%)**, con áreas dispersas en colores **amarillo** y **naranja** reflejan la presencia de **limos** y **arcillas**, especialmente en el

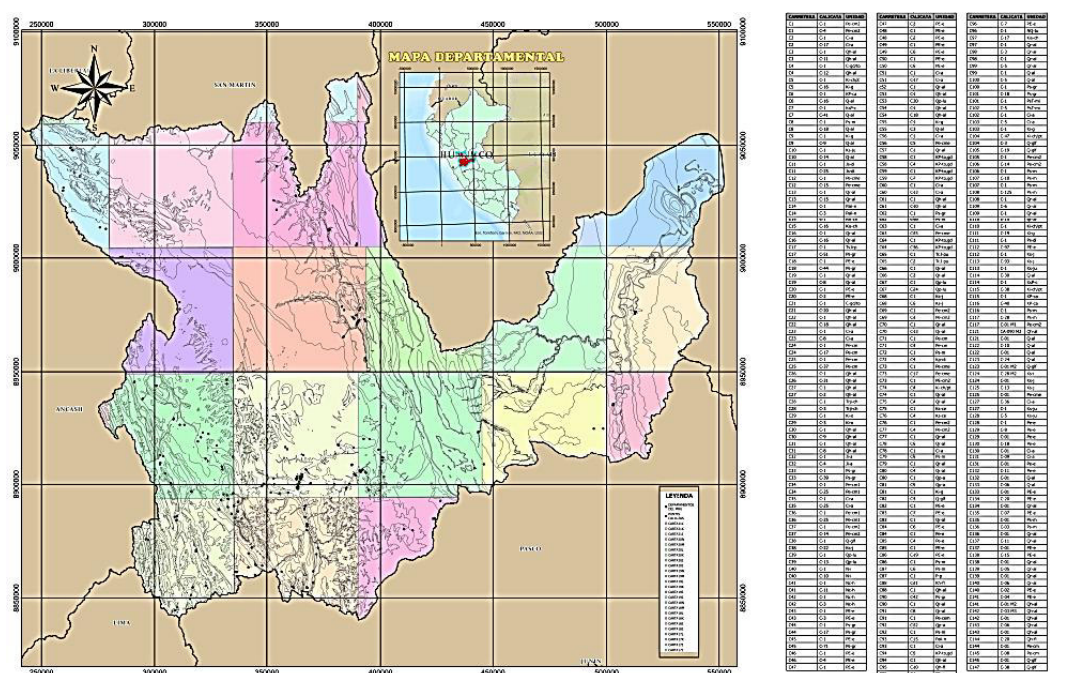
**centro-este** y zonas puntuales del **sur**; estos suelos requieren mayor contenido de agua para alcanzar su densidad óptima y presentan mayor susceptibilidad a la pérdida de firmeza con el incremento de humedad, lo que reduce significativamente el valor del **CBR**. Geográficamente la presencia de zonas críticas (arcillas y limos) en áreas del centro y sur sugiere que los modelos predictivos de **CBR** deben considerar factores adicionales como el drenaje, el tipo de estabilización aplicada y las condiciones climáticas locales.

### 5.5.7. Respecto a los valores de la Litoestratigrafía:

Finalmente, en la figura 82, se observa la distribución a nivel de la región Huánuco, del aspecto de Litoestratigráfico y como se relaciona con los valores CBR obtenidos de los proyectos reales.

**Figura 82**

*Distribución Litoestratigráfica de los proyectos reales a nivel de la región Huánuco*



Del mapa se observa **Diversidad Geológica Significativa**, es decir una amplia variedad de unidades litoestratigráficas, lo que indica una geología heterogénea en la región de Huánuco. Esto es relevante porque las propiedades mecánicas de las subrasantes varían considerablemente según el tipo de formación geológica; las **implicancias en el Valor del**

**CBR**, muestran regiones con formaciones sedimentarias o arcillosas, con valores de CBR más bajos debido a su baja capacidad de soporte y mayor retención de humedad, por otro lado, áreas con formaciones rocosas o compuestas por materiales granulares suelen presentar valores de CBR más altos, favoreciendo la estabilidad estructural. Respecto al **impacto en el Diseño Vial**, se observa zonas con predominio de materiales arcillosos requerirán estrategias de mejoramiento como estabilización química (con cal o cemento) o la utilización de geotextiles para optimizar el soporte, en cambio, áreas con mayor presencia de materiales gruesos podrían necesitar menos intervenciones para lograr valores adecuados de CBR. La **segmentación para el Modelado Predictivo**, indica que la variación geológica indica que se debe considerar la **clasificación litoestratigráfica como una variable clave** en el modelo de predicción del CBR. Esto permitirá identificar patrones específicos para cada tipo de terreno. Además, evidencia **posibles Zonas Críticas**, algunas áreas, especialmente en regiones montañosas o con fuertes pendientes, requiriendo mayor atención debido a la susceptibilidad a erosión o inestabilidad del suelo, lo que podría afectar negativamente el CBR.

## VI. CONCLUSIONES

6.1. Con respecto al objetivo general, se concluye que el modelo de inteligencia artificial Redes Neuronales Artificiales (ANN), permite la predicción del CBR en obras viales en la región Huánuco, con mayor precisión y confiabilidad; con respecto a las Redes Neuronales Recurrentes LSTM, las redes neuronales recurrentes GRU y los algoritmos de Random Forest y Maquina de Soporte Vectorial; precisando que estas cuatro últimas también permiten la predicción del CBR con menor grado de certeza y confiabilidad, pero muy aceptables en su predicción.

6.2. Respecto al objetivo específico 1, la data de análisis recopilada, constituida por propiedades físicas de los suelos como la granulometría, limite líquido, limite plástico e índice plástico; propiedades mecánicas como la Máxima densidad seca y el contenido óptimo de humedad; sometidas a los análisis y pruebas con las redes neuronales y los algoritmos, demostraron que la máxima densidad seca, el contenido óptimo de humedad y el porcentaje de grava, son las variables más influyentes en el desarrollo del modelo de predicción del CBR en obras viales de la región Huánuco.

6.3. Respecto al objetivo específico 2, se desarrolló una interfaz, articulando las tres redes neuronales y dos algoritmos analizados, que permite recolectar datos variables de propiedades físicas y mecánicas de suelos, dentro de las cuales están la máxima densidad seca, el contenido óptimo de humedad y el porcentaje de arena que son los más incidentes y que a su vez la interfaz permite predecir el CBR, valor que se verifica con la clasificación litoestratigráfica establecida por la INGEMMET para los cuadrángulos geológicos de la región Huánuco.

6.4. Respecto al objetivo específico 3, luego del análisis de la data recopilada de proyectos reales en una cantidad de 2270 puntos de caracterización de suelos, la limpieza realizada como resultado en 1124 puntos, la misma que se procedió a ampliar en dos formas como datos aleatorizados y datos sintéticos, tomando este último con una cantidad de 3372 puntos con fines

de una mayor precisión y confiabilidad; tomando como base los datos sintéticos, se logra validar el modelo de predicción del CBR en obras viales en la región Huánuco, siendo el la red neuronal artificial (ANN) con métricas de con  $R^2$  de 0.9848, MAE de 0.8195, MSE de 1.9198 y RMSE de 1.3856; valores que demuestran la validez del modelo y que también son validables con la interfaz generada, en donde se a verificado el funcionamiento de todos los modelos, pero en el contexto de mayor precisión y confiabilidad la red neuronal artificial, que tiene como parámetros óptimos el número de épocas de 430, tasa de aprendizaje final de  $1 \times 10^{-4}$   $\times 10^{-4}$ , numero de neuronas en la capa 64, un Dropout de 0.3 y un modelo de activación lineal.

6.5. Con respecto al grado de correlación de las variables predictoras con el CBR, considerando la data inicial recopilado de proyectos reales, se evidencia una correlación positiva alta entre las propiedades mecánicas – CBR y las propiedades físicas-granulometría-% grava de 0.35, lo cual es lógico geotécnicamente donde a mayor cantidad de grava mejor valor del CBR; existe una correlación negativa alta entre las propiedades mecánicas-CBR y propiedades mecánicas-contenido óptimo de Humedad (%) de -0.41, lo cual también se cumple en la práctica donde suelos con mayor cantidad de humedad optima tiene menor valor del CBR. Es de precisar que estas tendencias también se verificaron en los resultados de la data sintética mediante la corrida de los modelos de predicción.

6.6. El análisis de sensibilidad de la red neuronal artificial, tomando como base la data real a la data ampliada a 3372 puntos con datos sintéticos, muestra tendencias muy similares con respecto a la data inicial de proyectos reales, donde el CBR con respecto al porcentaje de grava muestra una correlación de 0.47; lo que significa que, a mayor contenido de grava, el valor del CBR tiende a aumentar. La grava aporta mayor resistencia a la subrasante, lo que coincide con el comportamiento geotécnico esperado en suelos más estables. Asimismo, el porcentaje de Limo-arcilla muestra una correlación de -0.50, la misma que es moderada, pero que indica que

una mayor proporción de partículas finas (limo y arcilla) tiende a reducir el valor del CBR, lo que es coherente con su impacto geotécnico, en la pérdida de capacidad portante del suelo.

6.7. Respecto a las variables más incidentes, de acuerdo con el modelo de redes neuronales artificiales (ANN) se verifica que la Máxima Densidad Seca evidencia una correlación de 0.54, Correlación positiva moderada a fuerte. Esto sugiere que suelos que alcanzan una mayor densidad seca tienden a mostrar mayores valores de CBR, lo que es coherente con un suelo mejor compactado y más resistente; que el Contenido Óptimo de Humedad evidencia una correlación de -0.40, Correlación negativa moderada. Un mayor contenido óptimo de humedad suele estar asociado a suelos finos que requieren más agua para alcanzar su densidad máxima, lo que generalmente se traduce en un menor valor de CBR. Todo ello permite afirmar que la variable Máxima Densidad Seca presenta la correlación más significativa con el CBR, siendo un factor determinante para su predicción. Que el contenido de grava también muestra una correlación positiva importante, confirmando que suelos con mayor proporción de partículas gruesas tienden a ser más resistentes; finalmente que la correlación negativa moderada con el % limo-arcilla y el contenido óptimo de humedad destaca la sensibilidad del CBR ante la presencia de finos y condiciones de humedad elevadas.

6.8. Respecto al grado de dispersión de datos con respecto al CBR real y el CBR predicho, en la red neuronal artificial (ANN), evidencia una alta correlación positiva entre las predicciones del modelo y los valores reales, mostrando que los puntos se agrupan alrededor de la recta  $y=x$ , mostrando que valores de CBR (entre 0 y 10) el modelo precisa con gran precisión, a media que el valor de CBR aumenta a mayor de 30, hay una ligera dispersión pero mantiene una precisión en un rango aceptable, lo cual demuestra que el modelo referido predice los valores de CBR con precisión y confiabilidad.

6.8. Respecto a la distribución geoespacial generada mediante el ArcGIS, muestra una amplia Variabilidad en los Valores de CBR, que indica significativa variación en la calidad de las

subrasantes, con predominio de zonas con CBR entre 6% y 20%, que representan subrasantes de calidad regular a buena. Esto indica que la mayor parte de la región requiere algún tipo de mejoramiento para cumplir estándares óptimos en pavimentación; la presencia de Zonas Críticas, con  $\text{CBR} < 3\%$  y CBR entre 3% y 6% corresponden a subrasantes inadecuadas e insuficientes, lo que demanda tratamientos especiales. Estas zonas se ubican mayormente en la parte sur y centro de la región; así mismo se evidencia áreas con Alta Capacidad Portante, como regiones en  $\text{CBR} > 30\%$ , que indican subrasantes excelentes. Estas áreas se concentran en el extremo norte del mapa, sugiriendo zonas con características geológicas favorables. Es importante evidenciar una distribución Irregular, una heterogeneidad significativa en las propiedades de las subrasantes, lo que indica que los factores como el tipo de suelo, el clima y la topografía influyen de manera considerable en la variación del CBR.

## VII. RECOMENDACIONES

7.1. Pese a que en todos los modelos considerados en el análisis, se han trabajado con el número de datos reales, datos aleatorios y datos sintéticos, se ha verificado que los resultados en cuanto a predicción son buenos y aceptables; se hace necesario que se acceda a mayor cantidad de datos, considerando sobre todo la alta variabilidad de los suelos y su comportamiento geotécnico que está influenciados con respecto a factores climáticos, factores geomorfológicos, que se ha evidenciado que pese a tener las mismas características físicas mecánicas, tienen diferentes comportamiento mecánicos, lo cual influye en los valores de predicción del CBR.

7.2. La data inicial corresponde a 147 proyectos de infraestructura vial reales, sin embargo, esta data no abarca en su integridad a toda la región Huánuco, por lo que es recomendable que se obtenga mayor cantidad de data, de zonas no mapeada, lo cual es evidenciable en los mapas generados por el ArcGIS, donde se aprecia zonas no mapeadas; por lo que estudios posteriores podrían ahondar en el análisis para mayor cantidad de data.

7.3. Si bien es cierto que las tres redes neuronales y los dos algoritmos de predicción, han demostrado buen desempeño en cuanto a predicción, obteniéndose valores del  $R^2$  mayor a 0.80; es posible mejorarlos empleando algunas técnicas de validación y probar con técnicas de preprocesamiento de los datos, especialmente si hay variables con escalas muy distintas, como es el caso de la naturaleza de los datos de los suelos.

7.4. En la presente investigación se ha logrado la predicción del CBR, tomando como datos predictores a las características granulométricas, los límites de Atterberg y parámetros mecánicos derivados del ensayo Proctor y siendo el aspecto geológico – litoestratigrafía un aspecto verificador, tanto en el análisis de la interfaz de almacenamiento de datos y predicción y el análisis mediante al ArcGIS; sería interesante en estudios posteriores buscar la forma de como introducir el aspecto geológico en forma más directa como variable predictor, así como



los factores climáticos, ambientales, que son importantes considerando el entorno donde se analizan los suelos.

## VIII. REFERENCIAS

Alba, F. (2019). *Deep Learning*. [Tesis de grado, Universidad de Sevilla].

<https://idus.us.es/bitstream/handle/11441/90004/Centeno%20Franco%20Alba%20TFG.pdf>

Arana, C. (2021). Redes Neuronales recurrentes: Análisis de los modelos especializados en datos secuenciales. *Universidad Del Cema - Argentina*, 1(797), 25.

Araujo-Navarro, W. (2014). *Ecuaciones de correlación del CBR con propiedades índice de suelos para la ciudad de Piura*. [Trabajo de grado, Universidad de Piura].

[https://pirhua.udep.edu.pe/bitstream/handle/11042/2192/ICI\\_208.pdf?sequence=1&isAllowed=y](https://pirhua.udep.edu.pe/bitstream/handle/11042/2192/ICI_208.pdf?sequence=1&isAllowed=y)

Basogain, X. (2022). *Redes neuronales artificiales y sus aplicaciones*. (1º ed.). Escuela Superior de Ingeniería de Bilbao.

[https://ocw.ehu.eus/pluginfile.php/40137/mod\\_resource/content/1/redes\\_neuro/contenidos/pdf/libro-del-curso.pdf](https://ocw.ehu.eus/pluginfile.php/40137/mod_resource/content/1/redes_neuro/contenidos/pdf/libro-del-curso.pdf)

Betancourt, G. (2005). Las Máquinas de soporte vectorial (SVMs). *Universidad Tecnológica de Pereira - Colombia*, XI(27), 67-72.

Boden, M. A. (2017). *Inteligencia artificial*. (I. Pérez Parra, Trad.; Primera edición). Turner.

Botazzi, C., Costarelli, S., D'Elia, J., & Dalcin, L. (2022). *Algoritmos y Estructuras de Datos*.

Universidad Nacional del Litoral. <https://cimec.org.ar/~mstorti/aed/aednotes.pdf>

- Boza, M., & Merino, R. (2018). Parámetros de resistencia al corte de suelos a partir de sus propiedades físicas, utilizando redes neuronales artificiales y equipo triaxial , UNH [Tesis de grado, Universidad Nacional de Huancavelica].  
<https://repositorio.unh.edu.pe/items/27d74174-b7b7-435c-86c0-4704120ef527>
- Callupe, B. (2023). *Evaluación del CBR y la deflexión del terreno natural usando redes neuronales en el mejoramiento de la carretera Oyón – Ambo, tramo II, provincia Daniel Alcides Carrión – Pasco*. [Tesis de grado, Universidad San Ignacio de Loyola]. <https://repositorio.usil.edu.pe/bitstreams/f39258e7-0336-4fc6-be7f-06f495a4d787/download>
- Camargo, J., Camargo, J., & Joyanes, L. (2015). Conociendo Big Data. *Revista Facultad de Ingeniería*, 24(38). [http://www.scielo.org.co/scielo.php?pid=S0121-11292015000100006&script=sci\\_arttext](http://www.scielo.org.co/scielo.php?pid=S0121-11292015000100006&script=sci_arttext)
- Cea, J. (2020). *Redes Neuronales recurrentes para la generación automática de música*. [Tesis de grado, Universidad Politécnica de Madrid].  
[https://oa.upm.es/63687/1/TFM\\_JUAN\\_JULIAN\\_CEA\\_MORAN.pdf](https://oa.upm.es/63687/1/TFM_JUAN_JULIAN_CEA_MORAN.pdf)
- Chipoco, J. (2023). *Deep Learning con Python*. *Revista del Centro de Tecnologías de Información y Comunicaciones*, 01(176).  
<https://es.scribd.com/document/601452881/Separata01V3>.

- Dávila, A., & Cano, L. (2023). *Revisión conceptual de las aplicaciones de la inteligencia artificial en el campo de la ingeniería geotécnica y su aproximación a casos de estudio de la región Caribe Colombiana*. [Tesis de grado, Universidad de Cartagena]. <https://repositorio.unicartagena.edu.co/handle/11227/16612>
- Gómez, Á. (2021). *Big Data, un sistema de gestión de datos*. [Tesis de grado, Tecana American University]. [https://tauniversity.org/sites/default/files/articulo\\_big\\_data\\_de\\_angel\\_gomez\\_degraves.pdf](https://tauniversity.org/sites/default/files/articulo_big_data_de_angel_gomez_degraves.pdf)
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT Press.
- Gowda, S., Kunjar, V., Gupta, A., Kavitha, G., Shukla, B. K., & Sihag, P. (2024). Prediction of the Subgrade Soil California Bearing Ratio Using Machine Learning and Neuro-Fuzzy Inference System Techniques: A Sustainable Approach in Urban Infrastructure Development. *Urban Science*, 8(1), 4. <https://doi.org/10.3390/urbansci8010004>
- Hazam, A. (2024). Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning*, 2024, 69-79.
- Hinestroza, D. (2018). *El Machine Learning a través de los tiempos, y los aportes a la Humanidad*. [Tesis de grado, Universidad libre seccional Pereira]. <https://repository.unilibre.edu.co/bitstream/handle/10901/17289/EL%20MACHINE%20LEARNING.pdf?sequence=1>
- Iberdrola. (2023). Descubre los principales beneficios del «Machine Learning». *Iberdrola*, 1(1), 10.

Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro (2020) (3<sup>a</sup> ed) (with Rouhiainen, L.). Alienta.

Khasawneh, M. A., Al-Akhrass, H. I., Rabab'ah, S. R., & Al-sugaier, A. O. (2024).

Prediction of California Bearing Ratio Using Soil Index Properties by Regression and Machine-Learning Techniques. *International Journal of Pavement Research and Technology*, 17(2), 306-324. <https://doi.org/10.1007/s42947-022-00237-z>

Lara, D., Herrera, M., García, M., & Beltrán, R. (2018). Modelo computacional para la estimación de la densidad del suelo a través del sensoramiento continuo. *Revista Ciencias Técnicas Agropecuarias*, 27(1), 15.

Manzano, P. (2021). Correlación entre el CBR, DCP, propiedades índice y mecánicas en suelos del Cantón Píllaro; Parroquia Marcos Espinel; de la provincia de Tungurahua [Trabajo de grado, Universidad Técnica de Ambato].  
<https://repositorio.uta.edu.ec/bitstream/123456789/32598/1/Tesis%20I.%20C.%201474%20-%20Manzano%20Ort%C3%ADz%20Patricia%20Monserrath.pdf>

Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Universidad Tecnológica Nacional.  
[https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monografias/matich-redesneuronales.pdf](https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monografias/matich-redesneuronales.pdf)

Ospina, J., & Arístizabal, E. (2021). Aplicación de inteligencia artificial y técnicas de aprendizaje automático para la evaluación de la susceptibilidad por movimientos en masa. *Revista Mexicana de ciencias Geología*, 38(1), 13.

- Peña, S., & Asanza, E. (2021). Técnicas de aprendizaje automático para caracterización y perfilado del terreno. Aplicación práctica al CPTU. Laboratorio de Geotecnia del CEDEX, España, 152, 31.
- Poma, H. (2023). *Modelos Machine Learning en Geomecánica minera para el control eficaz de perforación y voladura en labores de avance—Unidad minera San Rafael*. [Tesis de grado, Universidad Nacional del Altiplano].  
<https://tesis.unap.edu.pe/handle/20.500.14082/19626?show=full>
- Rodríguez, J. (2018). *Algoritmos y Programación*. Fundación Universitaria del área Andina.
- Valderrama, F. (2020). *Desarrollo de un modelo de redes neuronales artificiales para predecir las propiedades mecánicas del suelo*. [Tesis de grado, Universidad Señor de Sipán].  
[https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/8395/Valderrama%20Purizaca%2c%20Frank%20Jes%c3%bas\\_.pdf?sequence=4&isAllowed=y](https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/8395/Valderrama%20Purizaca%2c%20Frank%20Jes%c3%bas_.pdf?sequence=4&isAllowed=y)
- Valderrama, F., Mejía, H., Muñoz, S., & Tuesta, V. (2021). Desarrollo de un modelo predictivo de las propiedades mecánicas del suelo usando redes neuronales artificiales. *Lámpsakos*, (26), e-4042. <https://doi.org/10.21501/21454086.4042>

## IX. ANEXOS

### Anexo A. Matriz de Consistencia

#### TITULO: MODELO DE INTELIGENCIA ARTIFICIAL CON FINES DE PREDICCIÓN DEL CBR EN OBRAS VIALES EN LA REGIÓN HUÁNUCO-2024

PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES		INDICADORES	METODOLOGÍA, TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS
			DEPENDIENTE	INDEPENDIENTE		
<b><u>General</u></b> ¿Qué modelo de Inteligencia artificial se debe desarrollar para permitir la predicción del CBR en obras viales en la región Huánuco, 2024?	<b><u>General</u></b> Determinar qué modelo de inteligencia artificial permite la predicción del CBR en obras viales en la región Huánuco, 2024.	<b><u>General</u></b> El desarrollo de un modelo de inteligencia artificial permitirá predecir el CBR en obras viales en la región Huánuco, 2024.	▪ CBR	▪ Inteligencia artificial	▪ algoritmo	<b><u>Tipo y Diseño de la Investigación:</u></b> ▪ Enfoque: Cuantitativo ▪ Alcance: Experimental ▪ Diseño de la Investigación: Explicativa.  <b><u>Unidad de Análisis:</u></b> ▪ Provincia de Huánuco.  <b><u>Técnicas e Instrumentos de Recolección y procesamiento de datos:</u></b>  <b>Ensayos en laboratorio (recopilación de datos)</b> Clasificación de suelos-Granulometría Límites de Atterberg Contenido de humedad Densidad seca Contenido de Humedad Proctor modificado <b>Creación del algoritmo (modelos mediante machine learning y Deep learning)</b> Asesoramiento sobre la codificación. Realización de códigos Medidas de tendencia central, de dispersión y forma, medidas de relación y correlación, la prueba Friedman, Wicoxon, IC(5%). (Software): SPSS vs 24 Python ArcGIS Microsoft Excel y Word
<b><u>Específicos</u></b>  1. ¿De qué forma un adecuado análisis de datos mediante el Machine Learning influye en el desarrollo de un modelo de predicción del CBR en obras viales en la región Huánuco?	<b><u>Específicos</u></b>  1. Analizar datos mediante el Machine Learning que influye en el desarrollo de un modelo de predicción del CBR en obras viales en la región Huánuco.	<b><u>Específicas</u></b>  1. El análisis de datos mediante el Machine Learning influirá en el desarrollo de un modelo de predicción del CBR en obras viales en la región Huánuco.	▪ Modelo de predicción	▪ Machine Learning	▪ Base de datos	
2. ¿El desarrollo de un sistema de recolección de datos incide en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco?	2. Diseñar un sistema de recolección de datos que incide en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco.	2. El diseño de un sistema de recolección de datos incidirá en el entrenamiento del modelo de predicción del CBR en obras viales en la región Huánuco.	▪ Modelo de Predicción	▪ Entrenamiento del modelo	▪ confiabilidad	
3. ¿El correcto análisis del grado de precisión en proyectos reales permite validar el modelo de predicción del CBR en obras viales en la región Huánuco?	3. Analizar el grado de precisión en proyectos reales que permita validar el modelo de predicción del CBR en obras viales en la región Huánuco.	3. El análisis del grado de precisión en proyectos reales permitirá validar el modelo de predicción del CBR en obras viales en la región Huánuco.	▪ Validación	▪ precisión	▪ confiabilidad	

Fuente: Elaboración propia.

# Anexo B. Base de datos de propiedades físicas, mecánicas y geológicas – proyectos reales

BASE DE DATOS DE PROPIEDADES FÍSICAS, MECÁNICAS Y GEOLÓGICAS													
ITEM	NOMBRE DE PROYECTO	UBICACIÓN EN COORDENADAS GEOGRÁFICAS	MUESTRA DE SUELO	PROPIEDADES FÍSICAS						PROPIEDADES MECÁNICAS			PROPIEDADES
				Granulometría			Límites de Consistencia			Proctor Modificado	contenido óptimo de Humedad	CBR	
				% grava	% arena	% limo - arcilla	LL (%)	LP (%)	IP (%)				
1	Tramo: AMBRAMACHAY - PARAGUAPAMPA, APARICIO POVARIES, YAROWILCA, HUÁNUCO	Inicio: 76°37'43.59"W, 9°44'11.87"S, 3344; Fin: 76°36'06.30"W, 9°44'31.48"S, 3337 metros.	C-1	18.050	46.220	35.740	NP	NP	NP	2.190	7.500	39.000	Pe-cm2
			C-2	71.020	26.920	2.060	NP	NP	NP				Pe-cm2
			C-3	87.500	10.940	1.560	NP	NP	NP				Pe-cm2
			C-4	12.750	70.730	16.520	18.330	17.630	0.700	2.230	6.400	41.000	Pe-cm2
2	Tramo: EMP. HU-3076 - COUPAS, COUPAS, AMBIO, HUÁNUCO	Inicio: 76°21'25.20"W, 10°17'46.86"S, 2480 metros; Fin: 76°24'55.1"W, 10°16'05.69"S, 2723 metros.	C-1	48.910	38.670	12.420	22.420	19.790	2.630	2.210	9.580	25.870	Ci-a
			C-2	21.620	57.540	20.850	25.080	20.990	4.090				Ci-a
			C-3	45.780	37.930	20.300	25.170	22.130	3.040				Ci-a
			C-4	42.970	47.040	9.990	29.520	26.130	3.390				Ci-a
			C-5	41.710	53.880	6.410	24.730	22.920	1.790	2.050	9.110	20.370	Ci-a
			C-6	34.930	44.320	20.750	22.470	19.160	3.310				Ci-a
			C-7	40.260	45.040	14.700	20.680	18.030	2.650				Ci-a
			C-8	32.820	42.320	24.860	22.150	18.760	3.390				Ci-a
			C-9	37.910	37.090	25.000	25.740	18.680	7.060	2.150	10.490	28.560	Ci-a
			C-10	60.090	26.800	13.110	26.890	23.030	3.820				Ci-a
			C-11	48.160	39.610	12.230	22.350	19.680	2.670				Ci-a
			C-12	46.960	40.300	12.740	23.340	19.190	4.150				Ci-a
			C-13	38.970	42.960	18.070	27.850	25.230	2.620	2.060	11.330	19.060	Ci-a
			C-14	11.210	43.350	47.440	29.520	23.480	6.030				Ci-a
			C-15	30.490	48.920	20.650	24.090	21.050	3.040				Ci-a
			C-16	42.540	44.860	12.800	26.960	22.190	4.770				Ci-a
			C-17	23.440	47.980	28.580	30.120	23.550	6.570	2.060	11.120	34.930	Ci-a
3	Tramo: EMP. HU-523 (PTA. CARRETERA) - SECTOR ALTO COLOMBIA, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 metros; Fin: 76°19'30.29"W, 8°50'51.11"S, 770 metros.	C-1	47.440	47.030	5.540	NP	NP	NP	2.250	6.890	22.930	Qc-al
			C-2	22.480	44.170	33.350	NP	NP	NP				Qc-al
			C-3	48.630	48.660	2.710	NP	NP	NP				Qc-al
			C-4	10.800	32.340	56.850	38.070	29.880	8.190				Qc-al
			C-5	15.640	23.060	61.300	45.540	36.620	8.920	1.840	13.030	10.910	Qc-al
			C-6	9.820	24.720	65.460	34.740	27.960	6.780				Qc-al
			C-7	6.690	30.880	62.430	34.520	27.450	6.870				Qc-al
			C-8	1.310	28.550	70.130	42.100	36.300	5.800	1.870	10.340	8.080	Qc-al
			C-9	0.870	20.250	78.870	35.620	27.980	7.640				Qc-al
			C-10	1.830	21.610	76.580	33.100	27.770	5.330				Qc-al
			C-11	1.700	27.980	70.320	47.850	36.120	11.730	1.880	11.960	9.110	Qc-al
4	Tramo: ALTO MARTHA - SECTOR HOYA GRANDE, LA MORADA, MARAÑÓN, HUÁNUCO	Inicio: 76°14'51.47"W, 8°47'36.73"S, 542 metros; Fin: 76°20'08.99"W, 8°48'38.97"S, 753 metros.	C-1	11.480	19.810	68.720	38.280	27.030	11.250	1.840	12.180	10.290	Cgd/lo
			C-2	11.470	29.720	58.810	42.600	29.530	13.070				Cgd/lo
			C-3	11.930	40.020	48.050	NP	NP	NP				Cgd/lo
			C-4	54.710	31.680	13.620	NP	NP	NP				NQ-tu
			C-5	60.960	33.460	5.580	NP	NP	NP	2.140	6.460	21.380	NQ-tu
			C-6	23.440	55.050	21.510	NP	NP	NP				NQ-tu
			C-7	33.370	36.890	29.740	NP	NP	NP				NQ-tu
			C-8	0.710	16.580	82.710	48.610	36.200	12.410				NQ-tu
			C-9	34.950	33.980	31.070	NP	NP	NP	2.080	6.960	19.090	Qc-al
			C-10	66.800	22.310	10.890	NP	NP	NP				Qc-al
			C-11	51.780	37.290	10.920	NP	NP	NP				Qc-al
			C-12	57.670	25.800	16.330	NP	NP	NP	2.050	8.590	19.920	Qc-al
5	LUNGAN-ATAGO-CARACOSIVA CHIGORRAGRA-CUCHIHUASI, DISTRITO DE SAN PEDRO DE CHAWLAN - HUÁNUCO	Inicio: 76°29'05.14"W, 10°03'21.52"S, 3560 metros; Fin: 76°28'09.97"W, 10°02'02.41"S, 3887 metros.	C-1	40.070	16.830	43.090	35.100	18.920	16.180				Ki-chpt
			C-2	46.720	25.930	27.350	39.490	21.190	18.300				Ki-chpt
			C-3	52.540	25.760	21.700	21.780	18.790	2.990				Ki-chpt
			PONTON N° 01	72.630	15.320	12.060	NP	NP	NP				Ki-chpt
			C-5	97.790	9.300	22.910	NP	NP	NP	1.740	5.700	26.800	Ki-chpt
			C-6	45.230	35.110	19.670	NP	NP	NP				Ki-chpt
			C-7	50.050	28.380	21.570	NP	NP	NP				Ki-g
			C-8	48.990	23.080	27.340	NP	NP	NP				Ki-g
			C-9	39.490	35.900	24.620	NP	NP	NP	1.880	6.020	7.600	Ki-g
			C-10	77.730	13.200	9.160	NP	NP	NP				Ki-g
			C-11	55.640	14.200	30.160	NP	NP	NP				Ki-g
			C-12	74.150	25.740	0.120	27.020	20.400	6.620				Ki-g
			PONTON 02	63.460	19.320	17.220	NP	NP	NP				Ki-g
			C-13	42.560	17.010	40.440	45.130	23.400	21.730	1.900	6.180	7.600	Ki-g
			C-14	12.490	30.250	57.260	44.760	34.880	9.880				Ki-g
			C-15	6.810	14.450	78.740	NP	NP	NP				Ki-g
C-16	24.140	34.700	41.170	33.160	31.310	1.810				Ki-g			
6	MEJORAMIENTO DEL CAMINO VECINAL COCHAS - CHACRAS, DISTRITO DE MARGOS, PROVINCIA DE HUÁNUCO	Inicio: 76°29'04.77"W, 10°01'01.02"S, 3447 metros; Fin: 76°30'05.57"W, 10°02'00.86"S, 3732 metros.	C-1	26.720	51.880	21.710	35.300	31.680	3.620	2.060	7.500	23.160	KP-ca
			C-2	51.880	33.190	15.230	23.370	19.570	3.800				KP-ca
			C-3	41.170	32.950	25.890	28.570	23.960	4.610				KP-ca
			C-4	54.660	36.320	9.020	27.650	24.810	2.840				KP-ca
			C-5	39.220	56.330	4.450	33.830	30.090	3.740	2.090	7.530	23.730	KP-ca
			C-6	32.780	48.070	19.150	18.650	17.170	1.480				KuP-c
			C-7	5.420	31.800	62.780	27.820	23.170	4.650				KuP-c
			C-8	60.940	22.500	16.560	22.320	22.110	0.210				KuP-c
			C-9	4.540	14.560	80.900	NP	NP	NP	1.930	10.730	18.510	KuP-c
			C-10	46.310	28.920	24.770	18.580	15.770	2.810				KuP-c
			C-11	7.720	37.280	55.010	28.090	23.880	4.210				KuP-c
			C-12	32.780	48.070	19.150	18.650	17.170	1.480				KuP-c
			C-13	7.130	37.510	55.370	30.920	26.030	4.890	2.000	9.850	19.270	Q-al
			C-14	40.050	28.510	21.440	17.770	14.940	2.830				Q-al
			C-15	35.240	42.940	21.820	NP	NP	NP				Q-al
			C-16	13.540	58.270	28.190	NP	NP	NP	1.910	7.250	18.150	Q-al
			C-1	0.100	8.050	91.850	20.600	18.980	1.620	1.840	12.080	13.540	KuP-c
			C-2	5.690	35.240	59.070	45.640	29.150	16.490				KuP-c



7	MEJORAMIENTO DEL CAMINO VECINAL COLPAGHAPPA - PATAHUASI - RAURA, DISTRITO DE HUÁNUCO	Inicio: 76°31'33.11"W, 10°02'14.98"S, 3588 msnm; Raz: 76°29'42.89"W, 10°04'50.58"S, 3479 msnm	C-3	20.140	28.730	51.540	27.890	23.500	4.390				KaP-c
			C-4	52.202	32.190	15.610	NP	NP	NP				KaP-c
			C-5	59.092	36.660	4.310	NP	NP	NP	2.120	8.300	31.730	KaP-c
			C-6	71.030	27.690	1.290	NP	NP	NP				KaP-c
			C-7	66.460	28.660	4.870	NP	NP	NP				KaP-c
			C-8	74.950	12.300	12.750	17.520	15.710	1.810				KaP-c
			C-9	44.830	41.810	13.360	NP	NP	NP	2.120	6.530	30.480	KaP-c
			C-10	2.000	81.530	14.470	NP	NP	NP				KaP-c
			C-11	0.880	34.700	64.420	35.070	32.130	2.940				KaP-c
			C-12	34.240	21.600	44.160	NP	NP	NP				KaP-c
			C-13	35.890	39.230	24.930	NP	NP	NP	2.140	7.100	24.730	KaP-c
			C-14	39.600	28.050	32.340	36.270	31.030	5.240				KaP-c
			C-15	15.040	67.580	17.380	NP	NP	NP				KaP-c
			C-16	44.670	35.710	19.620	29.000	22.570	6.430				KaP-c
			C-17	32.220	32.620	35.160	NP	NP	NP	2.170	6.800	24.000	KaP-c
			C-18	36.040	46.710	17.240	24.430	21.800	2.610				KaP-c
			C-19	26.370	36.050	37.380	NP	NP	NP				KaP-c
			C-20	42.610	37.860	19.530	NP	NP	NP				KaP-c
			C-21	42.490	28.270	29.240	NP	NP	NP	2.190	6.360	29.320	KaP-c
			C-22	30.860	48.900	20.240	NP	NP	NP				KaP-c
			C-23	56.810	29.150	14.040	32.470	28.350	4.120				KaP-c
			C-24	25.640	59.380	14.980	NP	NP	NP				KaP-c
			C-25	28.190	39.820	31.980	35.490	32.170	3.320	2.040	9.440	21.290	KaP-c
			C-26	34.050	15.730	50.220	35.730	29.280	6.430				KaP-c
			C-27	62.890	34.800	2.250	NP	NP	NP				KaP-c
			C-28	25.440	55.440	19.120	NP	NP	NP				KaP-c
			C-29	30.070	29.210	40.720	30.320	28.840	1.480	2.080	7.950	27.510	KaP-c
			C-30	20.230	61.560	16.210	NP	NP	NP				KaP-c
			C-31	26.450	57.960	15.600	NP	NP	NP				KaP-c
			C-32	48.410	34.040	17.550	NP	NP	NP				KaP-c
			C-33	38.410	17.350	44.240	NP	NP	NP	2.180	7.080	29.570	KaP-c
			C-34	42.610	39.130	18.060	NP	NP	NP				KaP-c
			C-35	21.920	33.080	45.000	32.840	28.960	3.880				Q-al
			C-36	34.120	45.560	20.320	18.810	16.520	2.290				Q-al
			C-37	15.640	42.580	42.780	21.900	18.570	3.330	2.010	7.950	20.930	Q-al
			C-38	52.390	30.220	17.430	29.080	25.970	3.110				Q-al
			C-39	43.550	41.530	14.910	NP	NP	NP				Q-al
			C-40	40.040	36.940	23.020	26.940	24.790	2.150				Q-al
			C-41	14.220	55.180	30.630	29.460	25.350	4.110	1.940	11.520	19.200	Q-al
8	MEJORAMIENTO DEL CAMINO VECINAL RACCHAPPA - PUCAHUANCA, DISTRITO DE MARGOS, PROVINCIA DE HUÁNUCO	Inicio: 76°33'18.96"W, 10°02'49.47"S, 3084 msnm; Raz: 76°34'38.87"W, 10°05'11.36"S, 2799 msnm.	C-1	25.010	30.660	46.340	31.350	28.320	3.030	2.080	7.800	22.610	Ps-m
			C-2	27.710	36.360	35.870	34.820	27.730	7.090				Ps-m
			C-3	27.410	64.870	7.710	NP	NP	NP				Ps-m
			C-4	47.290	29.960	22.760	NP	NP	NP				Ps-m
			C-5	71.380	21.570	7.050	28.190	24.960	3.230	2.260	6.040	34.720	Ps-m
			C-6	30.020	40.250	29.720	NP	NP	NP				Tr-p
			C-7	30.080	19.480	50.450	NP	NP	NP				Tr-p
			C-8	37.280	43.420	19.300	NP	NP	NP				Tr-p
			C-9	57.570	27.770	14.870	NP	NP	NP	2.180	8.550	29.760	Tr-p
			C-10	21.740	28.830	49.430	28.350	25.780	2.570				Ki-g
			C-11	3.390	27.400	69.210	25.930	23.680	2.230				Ki-g
			C-12	20.920	62.690	16.390	27.650	25.090	2.560				Ki-g
			C-13	5.300	24.000	70.700	24.140	19.840	4.300	1.920	11.640	16.840	Ki-ch/tp
			C-14	11.370	15.050	73.570	44.160	28.490	15.670				Ki-ch/tp
			C-15	38.680	29.920	31.200	NP	NP	NP				Ks-j
			C-16	34.540	35.660	29.810	26.770	21.980	4.790				Ks-j
			C-17	30.870	54.590	14.540	NP	NP	NP	2.030	7.330	24.870	Q-al
			C-18	33.970	28.420	37.620	NP	NP	NP				Q-al
9	MEJORAMIENTO DE LA CARRETERA MARGOS - HUANCACANCHA, DISTRITO DE MARGOS, PROVINCIA DE HUÁNUCO	Inicio: 76°33'20.48"W, 10°00'10.08"S, 3537 msnm; Raz: 76°33'08.03"W, 10°00'36.98"S, 3848 msnm.	C-1	30.640	34.940	34.420	30.190	27.040	3.150	2.070	8.550	21.840	Ki-g
			C-2	0.160	25.140	74.500	32.900	30.640	2.260				Ki-g
			C-3	6.750	33.080	60.170	29.340	24.670	4.670				Ki-g
			C-4	22.180	19.170	58.650	NP	NP	NP				Ki-g
			C-5	5.180	42.190	52.630	25.770	20.614	5.156	1.890	8.850	16.330	Ki-g
			C-6	14.160	43.070	42.770	NP	NP	NP				KaP-ca
			C-7	45.200	52.910	5.890	NP	NP	NP				KaP-ca
			C-8	36.400	35.990	27.610	24.650	19.170	5.480				Q-al
			C-9	24.030	59.390	16.580	NP	NP	NP	1.940	10.000	24.430	Q-al
10	MEJORAMIENTO DEL CAMINO VECINAL PACAYHUA - PACAHUARI, DISTRITO DE MARGOS, PROVINCIA DE HUÁNUCO	Inicio: 76°33'41.17"W, 9°59'25.57"S, 3567 msnm; Raz: 76°32'31.72"W, 9°59'34.66"S, 3681 msnm.	C-1	38.980	11.780	49.210	40.820	36.890	3.930	2.100	8.000	28.360	Ka-ju
			C-2	40.740	25.530	33.730	25.550	23.970	1.580				Ka-ju
			C-3	9.800	43.520	46.680	26.100	22.490	3.610				Ka-ju
			C-4	16.640	30.310	53.050	24.960	19.900	5.080				Ka-ju
			C-5	11.460	22.830	65.710	39.130	35.930	3.200	1.720	17.000	15.270	Ka-ju
			C-6	34.160	36.120	29.720	28.780	27.200	1.580				Ka-ju
			C-7	56.400	16.310	27.280	26.650	20.840	5.810				KaP-ca
			C-8	61.690	19.090	19.220	26.490	25.660	0.830				KaP-ca
			C-9	13.920	26.510	59.570	36.750	29.680	7.070	1.910	9.470	19.720	KaP-ca
			C-10	47.360	22.960	29.680	16.620	14.930	1.690				Q-al
			C-11	13.430	18.300	68.270	NP	NP	NP				Q-al
			C-12	63.880	24.290	13.830	27.440	21.120	6.320				Q-al
			C-13	38.390	22.320	39.290	32.080	27.600	4.480	2.270	6.600	32.470	Q-al
			C-14	7.040	5.990	87.020	47.530	40.410	7.120				Q-al
			C-1	9.450	14.340	76.210	27.810	23.760	4.050	1.820	9.750	20.000	Je-di
			C-2	12.310	36.970	50.720	25.090	20.510	4.580				Je-di
			C-3	12.900	8.680	78.410	47.300	30.350	16.950				Je-di
			C-4	0.350	0.830	98.820	45.520	23.300	22.220				Je-di
			C-5	23.900	35.720	40.390	32.540	24.350	8.190	2.230	6.400	41.000	Je-di
			C-6	0.650	31.190	68.170	NP	NP	NP				Je-di
			C-7	2.480	43.110	54.410	33.980	25.380	8.600				Je-di
			C-8	1.110	92.710	6.180	45.970	27.490	18.480				Je-di
			C-9	3.080	79.650	17.280	34.650	25.480	9.170	2.000	7.900	27.800	Je-di
			C-10	17.870	16.480	65.630	29.230	27.510	1.700				Je-di

11	TRAMO: QUEBRADA PARDAVE - OROPAMPA, SAN PABLO DE PILLAG, HUÁNUCO.	Inicio: 7°5'54.94"W, 9°45'52.90"S, 2876 msnm; Fin: 7°5'57.19"W, 9°45'53.11"S, 3053 msnm.	C-11	0.650	36.040	63.310	45.230	27.860	17.350													Ju-di	
			C-12	1.790	23.840	74.380	48.900	30.850	18.050														Ju-di
			C-13	0.330	49.230	50.440	NP	NP	NP				1.810	10.040	39.600								Ju-di
			C-14	13.210	38.670	48.120	NP	NP	NP														Ju-di
			C-15	14.500	19.630	65.870	25.620	22.390	3.230														Ju-di
			C-16	1.510	19.640	78.850	42.550	26.550	16.000														Ju-di
			C-17	11.210	39.610	49.380	NP	NP	NP				2.170	7.110	35.600								Ju-di
			C-18	6.000	12.980	81.020	NP	NP	NP														Ju-di
			C-19	45.330	39.040	15.630	24.620	23.210	1.410														Ju-di
			C-20	8.490	20.130	71.380	44.780	29.420	15.360														Ju-di
			C-21	6.670	67.320	26.020	NP	NP	NP				2.190	7.500	39.000								Ju-di
			C-22	16.380	18.990	65.630	NP	NP	NP														Ju-di
			C-23	17.940	31.140	49.520	45.670	27.050	18.630														Ju-di
			C-24	32.310	25.200	42.490	NP	NP	NP														Ju-di
			C-25	13.400	25.180	61.420	28.460	23.840	4.620				1.890	8.450	25.200								Ju-di
12	TRAMO I MATIGRANDE - SALAPAMPA - SANTA ROSA DE PAQUKAG, AMBO, AMBO, HUÁNUCO	Inicio: 7°0'04.40"W, 10°12'04.70"S, 2337 msnm; Fin: 7°0'10.13"W, 10°13'36.19"S, 2837 msnm.	C-1	85.530	10.590	3.890	NP	NP	NP													Fe-crne	
			C-2	9.200	20.800	10.000	NP	NP	NP														Fe-crne
			C-3	46.890	30.150	22.960	31.730	25.430	6.360														Fe-crne
			C-4	30.660	40.400	28.930	42.470	33.900	8.570				2.090	5.650	25.950								Fe-crne
			C-5	56.700	14.730	28.570	31.150	24.870	6.280														Fe-crne
			C-6	21.920	48.310	29.760	30.670	25.790	4.880														Fe-crne
			C-7	31.650	48.890	19.460	43.560	33.860	9.700														Fe-crne
			C-8	31.740	18.720	49.540	27.850	22.640	5.210				2.200	7.320	29.760								Fe-crne
			C-9	61.950	29.000	9.050	NP	NP	NP														Fe-crne
			C-10	54.370	32.990	12.640	NP	NP	NP														Fe-crne
			C-11	25.320	48.340	26.340	29.850	24.920	4.940														Fe-crne
			C-12	22.980	45.130	31.890	32.090	24.960	7.130				2.070	8.550	21.840								Fe-crne
			C-13	16.120	39.060	44.820	45.040	34.880	10.160														Fe-crne
			C-14	77.840	19.540	2.620	39.020	31.550	7.470														Fe-crne
			C-15	51.520	39.030	9.440	NP	NP	NP				2.290	7.050	31.780								Fe-crne
13	MEJORAMIENTO CARRETERA CENTRAL TRAMO I C.P. PAUCARIMBA, DISTRITO DE ANAHUAS, PROVINCIA DE HUÁNUCO	Inicio: 7°0'14.41"W, 9°56'56.42"S, 1938 msnm; Fin: 7°0'14.20"W, 9°56'32.90"S, 1915 msnm.	C-1	50.320	41.740	5.940	NP	NP	NP													Qr-ul	
			C-2	33.280	40.820	25.900	NP	NP	NP				2.070	8.550	21.840								Qr-ul
			C-3	26.780	60.870	12.350	NP	NP	NP														Qr-ul
			C-4	8.710	16.640	74.650	26.980	20.330	6.650														Qr-ul
			C-5	40.870	37.330	21.800	18.370	15.470	2.900				2.290	7.050	31.780								Qr-ul
			C-6	0.590	23.980	75.440	21.570	19.570	2.000														Qr-ul
			C-7	30.350	50.970	18.680	19.070	17.810	1.240														Qr-ul
			C-8	4.010	42.760	51.230	30.840	30.020	0.820				1.910	9.470	17.100								Qr-ul
			C-9	5.050	81.120	13.830	NP	NP	NP														Qr-ul
			C-10	24.610	49.150	26.230	22.220	20.710	1.510														Qr-ul
			C-11	52.170	40.870	6.960	NP	NP	NP				2.290	6.650	33.590								Qr-ul
			C-12	0.220	42.450	57.330	24.980	20.960	4.020														Qr-ul
			C-13	45.580	54.340	0.080	NP	NP	NP														Qr-ul
			C-14	21.410	64.610	13.990	NP	NP	NP				1.960	10.700	21.370								Qr-ul
			C-15	3.370	76.430	20.200	21.250	18.330	2.920														Qr-ul
14	TRAMO: HUACACHUCHO - SAN BUENAVENTURA, NARANJO, HUÁNUCO	Inicio: 7°36'25.10"S, 2949 msnm; Fin: 7°37'11.08"S, 2916 msnm.	C-1	39.700	48.480	11.830	24.830	21.170	3.660													Pd-n	
			C-2	53.800	31.190	15.010	21.120	16.770	6.340				2.370	7.350	26.500							Pd-n	
			C-3	43.670	50.610	5.710	NP	NP	NP				2.380	9.100	31.200							Pd-n	
15	TRAMO: SAN SALVADOR - COCATAMBO, SANTA VIRGINIA, PANAO, PACHITEA, HUÁNUCO	Inicio: 7°54'44.38"W, 10°05'12.64"S, 1611 msnm; Fin: 7°54'01.13"W, 10°06'59.95"S, 1626 msnm.	C-1	2.490	40.560	56.950	24.220	22.860	1.360														Kn-eh
			C-2	36.670	40.480	22.860	33.380	23.010	10.350														Kn-eh
			C-3	0.000	32.600	64.400	34.230	23.310	10.920														Kn-eh
			C-4	42.180	39.370	18.240	29.980	19.710	10.270														Kn-eh
			C-5	13.210	38.430	48.360	39.530	30.370	8.940				1.790	10.700	8.420								Kn-eh
			C-6	43.650	35.630	20.720	23.780	17.490	6.290														Kn-eh
			C-7	21.630	47.250	31.120	47.780	25.800	21.980														Kn-eh
			C-8	42.590	39.390	18.020	45.730	34.760	10.950														Kn-eh
			C-9	18.890	47.660	33.490	32.330	30.210	2.100				1.870	12.950	31.790								Kn-eh
			C-10	22.510	48.120	29.370	24.730	20.440	4.290														Kn-eh
			C-11	40.130	24.800	35.070	22.630	13.770	8.860														Kn-eh
			C-12	5.730	31.120	63.170	42.380	22.950	19.430														Kn-eh
			C-13	4.900	42.960	52.540	21.730	17.720	3.990				1.910	7.450	33.140								Kn-eh
			C-14	4.750	30.760	64.490	21.760	18.550	3.210														Kn-eh
			C-15	11.320	46.220	42.460	34.150	22.810	11.940														Kn-eh
C-16	9.360	26.910	63.730	31.230	27.670	3.560				1.830	21.560	33.200								Kn-eh			
16	MEJORAMIENTO CARRETERA CENTRAL TRAMO II SEGURO SOCIAL-PORTALES, DISTRITO DE ANAHUAS, PROVINCIA DE HUÁNUCO	Inicio: 7°0'14.19.23"W, 9°56'11.49"S, 2035 msnm; Fin: 7°0'13.40.22"W, 9°54'30.43"S, 1890 msnm.	C-1	85.530	10.590	3.890	NP	NP	NP													Qr-ul	
			C-2	69.200	20.800	10.000	NP	NP	NP														Qr-ul
			C-3	46.890	30.150	22.960	31.200	25.430	5.770														Qr-ul
			C-4	61.260	37.220	1.520	42.260	33.900	8.360				2.187	6.520	33.200								Qr-ul
			C-5	56.700	14.730	28.570	29.540	24.870	4.670														Qr-ul
			C-6	21.920	48.310	26.760	30.540	25.790	4.750														Qr-ul
			C-7	31.650	48.890	19.460	43.260	34.140	9.120														Qr-ul
			C-8	31.740	18.720	49.540	27.290	22.640	4.650				2.205	7.050	34.100								Qr-ul
			C-9	61.950	29.000	9.050	NP	NP	NP														Qr-ul
			C-10	54.370	32.990	12.640	NP	NP	NP														Qr-ul
			C-11	25.320	48.340	26.340	29.980	24.920	5.070														Qr-ul
			C-12	22.980	45.130	31.890	33.030	24.960	8.050				2.139	6.100	35.100								Qr-ul
			C-13	16.120	39.060	44.820	44.730	34.880	9.850														Qr-ul
			C-14	77.840	19.540	2.620	39.130	31.550	7.560														Qr-ul
			C-15	51.520	39.030	9.440	NP	NP	NP														Qr-ul
C-16	20.230	37.760	42.010	NP	NP	NP														Qr-ul			
			C-1	38.050	49.620	12.330	27.650	24.810	2.840													Tsl-p	
			C-2	15.370	51.240	33.390	30.890	18.970	11.920														Tsl-p
			C-3	21.730	39.640	38.630	29.150	19.120	10.030														Tsl-p
			C-4	21.920	48.310	29.760	31.150	25.790	5.360														Tsl-p
			C-5	32.610	38.560	28.830	34.140	19.670	14.470				1.900	6.700	15.								



17	TRAMO: SANTA ROSA - LEON RAMPA - SAN SALVADOR, SANTA VIRGINIA, PANAMÁ, PACHITEA, HUÁNUCO	Inicio: 75°11'50.40"W, 9°53'09.07"S, 568 msnm; Fin: 75°40'21.13"W, 10°00'59.95"S, 3626 msnm.	C-11	36.040	46.710	17.240	29.940	19.990	10.350				Tsl-p
			C-12	30.310	37.350	32.340	28.730	19.600	9.130				Tsl-p
			C-13	21.210	64.570	14.230	31.900	19.200	12.100	2.020	8.920	28.750	Ps-m
			C-14	34.120	45.560	20.320	25.900	16.520	9.380				Ps-m
			C-15	28.640	50.820	20.540	30.450	19.130	11.520				Ps-m
			C-16	35.220	41.190	23.580	32.750	18.860	15.890				Ps-m
			C-17	27.760	36.360	35.870	34.820	16.860	17.960	2.040	9.440	29.200	Ps-m
			C-18	36.670	40.480	22.860	33.580	23.030	10.350				Ps-m
			C-19	0.000	32.600	67.400	14.230	23.310	10.920				Ps-m
			C-20	42.180	39.570	18.240	29.980	19.710	10.270				Ps-m
			C-21	15.210	38.430	48.360	39.510	30.370	8.940	1.990	10.730	19.790	Ps-m
			C-22	43.650	35.630	20.720	23.780	17.480	6.290				Ps-m
			C-23	21.630	47.250	31.120	47.780	25.800	21.980				Ps-m
			C-24	42.590	39.390	18.020	45.730	34.760	10.950				Ps-m
			C-25	18.850	47.660	33.490	32.530	30.230	2.100	1.900	8.200	23.160	Ps-m
			C-26	22.510	48.120	29.370	24.730	20.440	4.290				Ps-m
			C-27	40.190	24.800	35.070	22.630	13.770	8.860				Ps-m
			C-28	5.710	31.120	63.370	42.580	22.950	19.430				Ps-m
			C-29	4.500	42.960	52.540	21.710	17.720	3.990	1.840	12.100	19.790	Ps-gr
			C-30	4.750	30.760	64.490	21.760	18.550	3.210				Ps-gr
			C-31	11.520	46.220	42.460	34.150	22.810	11.540				Ps-gr
			C-32	9.360	26.910	63.730	31.230	27.670	3.560				Ps-gr
			C-33	2.490	40.560	56.950	24.220	22.860	1.360	2.020	7.800	16.420	Ps-gr
			C-34	36.670	40.480	22.860	33.580	23.030	10.350				Ps-gr
			C-35	54.400	30.370	12.230	40.160	20.540	19.620				Ps-gr
			C-36	42.180	39.570	18.240	29.980	19.710	10.270				Ps-gr
			C-37	31.580	47.570	20.850	20.130	14.400	5.710	2.150	6.250	33.680	Ps-gr
			C-38	12.820	61.340	25.840	21.460	16.700	4.760				Ps-gr
			C-39	30.980	40.810	28.210	51.800	27.480	4.310				Ps-gr
			C-40	34.140	43.810	22.050	23.390	19.240	4.150				Ps-gr
			C-41	66.930	23.630	9.440	39.430	37.470	1.960	2.140	7.300	36.460	Ps-gr
			C-42	46.310	28.920	24.770	18.580	15.770	2.810				Ps-gr
			C-43	32.780	48.070	19.150	18.650	17.170	1.480				Ps-gr
			C-44	51.640	31.990	16.370	19.230	13.270	5.940				Ps-gr
			C-45	39.750	44.250	16.000	36.600	34.110	2.490	2.170	7.000	36.210	Ps-gr
			C-46	32.040	36.660	31.290	25.290	18.070	7.220				Ps-gr
			C-47	39.700	40.040	20.250	18.230	11.640	6.570				Ps-gr
			C-48	67.650	21.520	10.830	38.790	27.420	1.370				Ps-gr
			C-49	74.950	12.300	12.750	17.520	15.710	1.810	2.120	7.300	34.950	Ps-gr
			C-50	2.000	83.510	14.470	33.680	21.560	12.120				Ps-gr
			C-51	34.860	56.230	8.910	22.860	15.880	6.980				Ps-gr
18	TRAMO I EMP. PE-LIBO PURUPAMPA - DWP, HUASCAPAMPA, PANAMÁ, PACHITEA, HUÁNUCO	Inicio: 75°58'59.99"W, 9°53'30.84"S, 2525 msnm; Fin: 75°57'33.86"W, 9°58'21.15"S, 3634 msnm.	C-1	45.980	49.450	4.580	26.750	23.650	3.100	2.150	5.880	34.810	PE-e
			C-2	19.530	27.930	52.730	NP	NP	NP				PE-e
			C-3	15.740	39.610	46.650	33.710	31.770	1.940				PE-e
			C-4	15.470	66.620	17.910	30.220	27.010	3.210				PE-e
			C-5	30.900	32.040	37.060	NP	NP	NP	2.040	7.040	32.720	PE-e
			C-6	4.870	31.070	64.050	NP	NP	NP				PE-e
			C-7	7.020	41.720	51.270	27.650	24.810	2.840				PE-e
			C-8	5.690	35.240	59.070	45.640	29.150	16.490				PE-e
			C-9	18.280	28.400	53.310	35.710	29.280	6.410	2.050	10.130	22.260	PE-e
			C-10	0.860	54.120	45.020	NP	NP	NP				PE-e
			C-11	30.020	40.250	29.710	NP	NP	NP				PE-e
			C-12	18.950	19.340	61.900	36.860	35.730	1.110				PE-e
			C-13	0.780	50.940	48.270	NP	NP	NP	2.000	7.920	27.820	PE-e
			C-14	24.940	39.580	35.480	25.310	20.010	5.300				PE-e
			C-15	4.050	36.110	59.820	NP	NP	NP				PE-e
			C-16	61.570	35.300	3.130	NP	NP	NP				PE-e
			C-17	5.650	19.460	74.890	26.080	23.620	2.460	1.760	11.900	11.720	PE-e
			C-18	20.920	62.690	16.390	27.650	25.090	2.560				PE-e
			C-19	12.460	58.990	28.550	NP	NP	NP				PE-e
			C-20	5.500	60.780	31.710	NP	NP	NP				PE-e
			C-21	6.760	55.910	37.330	NP	NP	NP	2.170	9.340	33.200	PE-e
			C-22	1.170	26.850	75.970	NP	NP	NP				PE-e
			C-23	2.490	35.840	61.670	25.120	22.990	2.110				PE-e
			C-24	0.950	34.170	64.870	NP	NP	NP				PE-e
			C-25	1.560	42.220	56.220	NP	NP	NP	1.800	10.880	15.230	PE-e
			C-26	3.290	47.000	49.710	NP	NP	NP				PE-e
			C-27	13.950	62.290	23.770	NP	NP	NP				PE-e
			C-28	0.780	32.190	67.030	NP	NP	NP				PE-e
			C-29	8.460	86.250	5.290	NP	NP	NP	2.190	7.500	39.000	PE-e
			C-30	21.730	30.760	47.510	NP	NP	NP				PE-e
			C-31	0.120	9.010	90.870	29.150	20.690	8.460				PE-e
			C-32	1.850	67.840	30.310	NP	NP	NP				PE-e
			C-33	1.090	47.060	51.850	NP	NP	NP	1.780	11.450	15.000	PE-e
			C-34	1.120	98.420	0.460	NP	NP	NP				PE-e
			C-35	12.680	77.290	10.010	NP	NP	NP				PE-e
			C-36	9.500	72.850	17.650	NP	NP	NP				Ps-gr
			C-37	8.920	78.640	12.440	NP	NP	NP	2.170	7.130	36.610	Ps-gr
			C-38	15.340	40.290	44.370	33.810	26.430	7.380				Ps-gr
			C-39	4.470	69.240	26.290	NP	NP	NP				Ps-gr
			C-40	25.020	61.190	13.790	NP	NP	NP				Ps-gr
			C-41	52.360	30.220	17.430	29.080	25.970	3.110	2.230	6.400	41.000	Ps-gr
			C-42	18.710	57.720	23.570	32.520	26.110	6.410				Ps-gr
			C-43	21.750	23.230	55.020	35.860	29.410	6.450				Ps-gr
			C-44	36.530	37.510	25.940	NP	NP	NP				Ps-gr
19	MEJORAMIENTO CARRETERA CENTRAL TRAMO II PORTALES LA ESPERANZA, DISTRITO DE JAMARETA, PROVINCIA DE	Inicio: 76°11'39.74"W, 9°54'30.58"S, 1879 msnm; Fin: 76°12'43.60"W, 9°55'00.00"S, 1879 msnm.	C-1	6.970	25.020	68.020	NP	NP	NP				Gr-al
			C-2	40.480	44.120	15.400	NP	NP	NP	2.030	6.450	30.050	Gr-al
			C-3	25.040	46.740	28.220	30.070	22.910	7.140				Gr-al
			C-4	3.470	44.320	52.210	NP	NP	NP				Gr-al
			C-5	3.080	67.370	29.550	NP	NP	NP				Gr-al



	HUANUCO	9°5'22.10"S, 1902 msnm.	C-6	26.700	17.830	55.470	NP	NP	NP					Dr-al
			C-7	0.230	46.420	53.350	39.230	37.080	2.130	1.990	9.500	17.870		Dr-al
			C-8	23.520	54.700	21.980	NP	NP	NP					Dr-al
20	CHIVICHACRO - QURSHUAR - HUAPOCHA - PABLO	Inicio: 7°19'21.11"S, 76°14'56.25"W, 3632 msnm; Fin: 7°19'21.11"S, 76°14'56.25"W, 3632 msnm.	C-1	83.770	11.170	5.050	26.000	20.910	5.090	2.176	7.210	39.900		PE-e
			C-2	59.870	20.580	19.550	25.460	21.870	3.590	2.194	5.200	40.510		PE-e
			C-3	0.500	34.760	64.750	33.280	28.090	5.170					Cgd-to
			C-4	0.000	27.110	72.890	36.670	30.400	6.270					Cgd-to
			C-5	4.120	44.180	51.700	36.520	28.190	8.330					Cgd-to
			C-6	0.950	34.960	64.130	32.200	26.790	5.410	1.830	4.900	15.380		Cgd-to
			C-7	6.190	25.930	67.880	38.170	34.690	3.480					Cgd-to
			C-8	0.280	22.960	76.770	35.060	27.830	7.230					Cgd-to
			C-9	0.100	56.170	43.730	26.390	19.070	7.320					Cgd-to
			C-10	6.750	20.750	72.500	39.950	33.090	6.860	1.750	4.500	13.370		Cgd-to
			C-11	0.140	40.540	59.330	35.300	31.110	4.190					NQ-tu
			C-12	4.480	43.870	51.650	39.270	31.980	7.290					NQ-tu
			C-13	0.320	42.540	57.150	NP	NP	NP					NQ-tu
			C-14	0.540	27.570	71.890	27.150	19.740	7.410	1.950	4.760	15.540		NQ-tu
			C-15	39.390	19.050	41.560	42.260	37.360	4.900					NQ-tu
			C-16	7.220	48.110	44.480	32.660	27.880	4.780					NQ-tu
			C-17	0.000	14.790	85.210	NP	NP	NP					Qh-al
			C-18	1.620	54.070	44.110	NP	NP	NP	1.980	4.860	22.410		Qh-al
			C-19	0.450	22.260	77.290	66.880	59.190	7.690					Qh-al
			C-20	44.150	39.520	16.330	NP	NP	NP					Qh-al
			C-21	42.600	40.190	17.210	NP	NP	NP					Qh-al
			C-22	48.260	18.430	33.310	35.400	29.440	5.960	2.050	6.100	30.110		Qh-al
			C-23	50.520	43.740	5.940	NP	NP	NP					Qh-al
			C-24	33.280	40.820	25.900	NP	NP	NP	2.070	6.550	23.840		Qh-al
			C-25	26.780	60.870	12.350	NP	NP	NP					Qh-al
			C-26	8.730	16.640	74.650	26.980	20.330	6.650					Qh-al
			C-27	40.870	37.330	21.800	18.370	15.470	2.900	2.290	7.050	31.780		Qh-al
			C-28	0.590	23.980	75.440	21.570	19.570	2.000					Trigs/mq-ga
			C-29	30.350	50.370	18.680	19.070	17.810	1.240					Trigs/mq-ga
			C-30	4.020	42.760	53.230	30.840	30.020	0.820	1.910	0.470	17.300		Trigs/mq-ga
			C-31	5.050	81.120	13.830	NP	NP	NP					Trigs/mq-ga
			C-32	24.610	49.150	26.210	22.220	20.710	1.510					Trigs/mq-ga
			C-33	52.170	40.870	6.960	NP	NP	NP	2.290	6.650	33.590		PsTr-mq/ga-ma
			C-34	0.220	42.450	57.330	24.980	20.960	4.020					PsTr-mq/ga-ma
			C-35	15.580	51.310	0.080	NP	NP	NP					PsTr-mq/ga-ma
			C-36	21.410	64.610	13.990	NP	NP	NP	1.960	10.700	21.370		PsTr-mq/ga-ma
			C-37	3.370	76.430	20.200	21.250	18.330	2.920					Qh-al
			C-38	39.700	48.480	11.830	24.830	21.170	3.660	2.370	5.350	36.520		Qh-al
			C-39	53.800	31.190	15.010	23.110	16.770	6.340	2.340	6.540	39.350		Qh-al
			C-40	43.670	50.610	5.710	NP	NP	NP	2.380	5.910	41.290		Qh-al
			C-41	27.060	46.370	26.570	NP	NP	NP					Cia
			C-42	32.750	53.340	11.900	NP	NP	NP					Cia
			C-43	24.690	30.610	44.690	NP	NP	NP	2.040	7.500	19.410		Cia
			C-44	37.760	47.130	15.110	NP	NP	NP					Cia
			C-45	31.130	42.600	26.280	NP	NP	NP					Cia
			C-46	28.240	39.850	31.910	NP	NP	NP	1.986	6.920	18.450		Cia
			C-47	43.510	28.630	27.860	NP	NP	NP					Cia
			C-48	21.800	25.360	52.840	NP	NP	NP					Cia
			C-49	71.260	28.470	0.270	39.500	9.450	30.050	1.620	20.410	9.450		Pe-cm
			C-50	62.430	37.430	0.140	39.580	9.620	29.960	1.760	18.470	8.810		Pe-cm
			C-51	50.900	48.580	0.520	52.060	23.250	28.810	1.730	15.570	8.170		Pe-cm
			C-52	72.280	27.450	0.270	31.340	23.720	7.620	1.890	15.900	8.140		Pe-cm
			C-53	62.180	37.600	0.220	41.930	28.050	15.890	1.730	20.620	9.240		Pe-cm
			C-54	61.720	37.910	0.380	39.050	32.710	6.340	1.860	11.430	8.590		Pe-cm
			C-55	63.710	36.070	0.220	38.650	15.210	23.420	1.880	10.760	9.250		Pe-cm
			C-56	62.510	37.240	0.240	41.410	32.050	9.360	1.730	20.290	8.810		Pe-cm
			C-57	68.270	35.510	0.230	39.880	9.110	30.770	1.630	19.720	8.390		Pe-cm
			C-58	62.570	37.460	0.170	38.840	26.380	12.460	1.880	10.520	9.450		Pe-cm
			C-59	68.440	31.330	0.220	17.340	7.620	29.520	1.640	18.950	9.030		Pe-cm
			C-60	72.590	27.380	0.230	30.520	26.170	4.350	1.860	11.690	8.600		Pe-cm
			C-61	48.470	51.350	0.170	52.670	24.390	28.290	1.750	14.410	9.250		Pe-cm
			C-62	48.070	51.800	0.130	48.650	33.310	15.340	1.730	14.910	9.460		Pe-cm
			C-63	49.460	50.320	0.230	52.390	33.950	18.440	1.740	14.450	9.250		Pe-cm
			C-64	10.750	88.850	0.400	20.980	15.860	5.120	1.690	19.160	5.590		Pe-cm
			C-65	10.810	88.850	0.340	20.250	16.850	3.400	1.680	19.840	5.370		Pe-cm
			C-66	43.400	30.500	26.100	26.000	18.000	8.000	2.160	7.600	32.600		Pe-cm
			C-67	0.000	55.300	44.700	33.000	21.000	12.000	1.854	14.800	21.100		Pe-cm
			C-68	58.700	23.600	17.700	30.000	23.000	7.000	2.307	6.600	28.560		Pe-cm
			C-69	57.100	25.000	17.900	28.000	22.000	6.000	2.286	8.400	21.450		Pe-cm
			C-70	59.700	23.700	16.600	24.000	20.000	4.000	2.265	7.400	34.500		Pe-cm
			C-71	62.700	22.800	14.500	24.000	22.000	2.000	2.317	7.500	36.500		Pe-cm
			C-72	0.000	29.600	70.400	29.000	20.000	9.000	1.951	15.100	16.800		Pe-cm
			C-73	7.000	27.800	65.200	34.000	22.000	12.000	1.751	16.100	9.300		Pe-cm
			C-74	45.200	21.700	31.300	39.000	25.000	14.000	2.017	13.900	38.200		Pe-cm
			C-75	59.800	24.700	15.500	NP	NP	NP	2.145	8.600	34.900		Pe-cm
			C-76	46.700	12.300	41.000	38.000	27.000	11.000	1.903	14.900	23.400		Pe-cm
			C-77	52.000	33.500	14.400	NP	NP	NP	2.166	9.300	39.200		Pe-cm
			C-78	73.300	16.700	9.900	31.000	21.000	10.000	2.119	7.300	28.500		Pe-cm
			C-79	0.000	21.000	79.000	29.000	20.000	9.000	1.884	15.400	34.500		Pe-cm
			C-80	56.800	25.300	17.900	28.000	22.000	6.000	2.244	9.900	40.800		Pe-cm
			C-81	6.300	7.900	85.800	40.000	27.000	13.000	1.519	29.000	5.800		Pe-cm
			C-82	56.800	21.600	21.500	NP	NP	NP	2.157	8.300	39.200		Pe-cm
			C-83	55.700	31.300	13.200	NP	NP	NP	2.131	9.000	39.100		Pe-cm
			C-84	0.000	52.800	47.200	38.000	29.000	9.000	1.886	12.700	17.200		Pe-cm
			C-85	0.000	43.300	56.900	39.000	26.000	13.000	1.699	16.200	9.500		Pe-cm
			C-86	0.000	23.000	77.000	34.000	27.000	7.000	1.835	15.200	17.400		Pe-cm
			C-87	0.000	2.900	97.100	56.000	42.000	14.000	1.549	27.500	4.600		Pe-cm
			C-88	0.000	52.800	47.200	38.000	29.000	9.000	1.886	12.700	17.200		Pe-cm
			C-89	0.000	43.300	56.900	39.000	26.000	13.000	1.699	16.200	9.500		Pe-cm
			C-90	0.000	23.000	77.000	34.000	27.000	7.000	1.835	15.200	17.400		Pe-cm
			C-91	0.000	2.900	97.100	56.000	42.000	14.000	1.549	27.500	4.600		Pe-cm
			C-92	0.000	52.800	47.200	38.000	29.000	9.000	1.886	12.700	17.200		Pe-cm
			C-93	0.000	43.300	56.900	39.000	26.000	13.000	1.699	16.200	9.500		Pe-cm
			C-94	0.000	23.000	77.000	34.000	27.000	7.000	1.835	15.200	17.400		Pe-cm
			C-95	0.000	2.900	97.100	56.000	42.000	14.000	1.549	27.500	4.600		Pe-cm
			C-96	0.000	52.800	47.200	38.000	29.000	9.000	1.886	12.700	17.200		Pe-cm
</														



26	MEJORAMIENTO DEL SERVICIO DE ESPACIOS PÚBLICOS VIALES URBANOS EN LA CIUDAD DE TINGO MARIA DEL DISTRITO DE RUPA RUPA - PROVINCIA DE LEONCIO PRADO	Inicio: 75°58'44.53"W, 9°17'30.95"S, 649 metros; Fin: 76°00'07.28"W, 9°18'11.26"S, 653 metros.	C-23	0.000	21.500	78.500	38.000	24.000	14.000	1.683	16.400	8.100	Pe-cm
			C-24	0.000	15.900	84.100	37.000	27.000	10.000	1.812	17.600	9.800	Pe-cm
			C-25	8.500	27.900	61.700	33.000	26.000	7.000	1.836	17.000	14.500	Pe-cm
			C-26	0.000	26.300	73.900	42.000	28.000	14.000	1.525	24.600	6.700	Pe-cm
			C-27	0.000	15.900	84.100	36.000	27.000	9.000	1.774	17.600	10.400	Pe-cm
			C-28	0.000	10.900	89.100	42.000	30.000	12.000	1.490	26.800	3.100	Pe-cm
			C-29	0.000	30.900	69.100	37.000	29.000	8.000	1.645	21.800	14.700	Pe-cm
			C-30	52.300	14.600	33.200	26.000	19.000	7.000	2.233	8.100	36.500	Pe-cm
			C-31	0.000	33.800	66.200	33.000	27.000	6.000	1.779	12.100	15.800	Pe-cm
			C-32	0.000	11.300	88.900	44.000	31.000	13.000	1.465	32.300	3.800	Pe-cm
			C-33	0.000	57.700	42.300	27.000	25.000	2.000	1.833	16.300	21.600	Pe-cm
			C-34	0.000	22.400	77.600	31.000	23.000	8.000	1.778	17.100	10.100	Pe-cm
			C-35	0.000	58.500	41.500	28.000	23.000	5.000	1.737	16.800	19.100	Pe-cm
			C-36	57.600	30.000	12.400	30.000	24.000	6.000	2.048	9.800	41.100	Pe-cm
			C-37	0.000	55.200	44.800	32.000	NP	NP	1.877	12.100	18.100	Pe-cm
			C-1	51.180	34.820	14.020	NP	NP	NP				Qh-al
			C-2	68.830	26.720	4.450	NP	NP	NP				Qh-al
			C-3	77.220	20.260	2.520	NP	NP	NP				Qh-al
			C-4	68.690	26.660	4.650	NP	NP	NP	2.130	5.340	39.750	Qh-al
			C-5	77.130	20.240	2.630	NP	NP	NP				Qh-al
			C-6	69.520	26.230	4.290	NP	NP	NP				Qh-al
			C-7	69.300	26.140	4.560	NP	NP	NP				Qh-al
			C-8	71.830	25.300	3.070	NP	NP	NP	2.100	5.210	43.600	Qh-al
			C-9	71.740	25.070	3.190	NP	NP	NP				Qh-al
			C-10	67.520	31.070	1.410	NP	NP	NP				Qh-al
			C-11	69.660	26.270	4.070	NP	NP	NP				Qh-al
			C-12	68.500	26.600	4.900	NP	NP	NP				Qh-al
			C-13	68.870	26.740	4.390	NP	NP	NP	2.210	5.110	39.450	Qh-al
			C-14	51.100	34.750	14.150	NP	NP	NP				Qh-al
			C-15	50.000	37.910	12.090	NP	NP	NP				Qh-al
			C-16	49.910	37.840	12.250	NP	NP	NP				Qh-al
			C-17	70.390	27.910	1.700	NP	NP	NP				Qh-al
			C-18	70.420	27.930	1.650	NP	NP	NP				Qh-al
			C-19	70.240	27.850	1.910	NP	NP	NP	2.140	4.500	39.600	Qh-al
			C-20	76.540	21.980	1.480	NP	NP	NP				Qh-al
			C-21	63.240	20.480	16.280	NP	NP	NP				Qh-al
			C-22	68.870	26.740	4.390	NP	NP	NP	2.170	3.400	40.000	Qh-al
			C-23	51.100	34.750	14.150	NP	NP	NP				Qh-al
			C-24	50.000	37.910	12.090	NP	NP	NP				Qh-al
			C-25	49.910	37.840	12.250	NP	NP	NP				Qh-al
			C-26	70.390	27.910	1.700	NP	NP	NP				Qh-al
			C-27	70.420	27.930	1.650	NP	NP	NP				Qh-al
			C-28	70.240	27.850	1.910	NP	NP	NP				Qh-al
			C-29	76.540	21.980	1.480	NP	NP	NP				Qh-al
			C-30	63.240	20.480	16.280	NP	NP	NP				Qh-al
			C-31	76.540	21.980	1.480	NP	NP	NP	2.160	5.300	41.000	Qh-al
27	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VIAL EN EL TRAMO LA CURVA JUJÚ C. TELLÓ BUENOS AIRES RD. DISTRITO DE RUPA RUPA - PROVINCIA DE LEONCIO PRADO	Inicio: 75°58'44.53"W, 9°17'30.95"S, 649 metros; Fin: 76°00'07.28"W, 9°18'11.26"S, 653 metros.	C-1	29.260	17.110	53.430	30.000	18.000	12.000	1.704	13.900	28.000	Qh-al
			C-2	24.030	21.260	52.710	32.000	20.000	12.000	1.740	11.290	24.600	Qh-al
28	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VIAL EN LA VÍA DE ACCESO A LA LOCALIDAD DE LA PALMAS, DISTRITO DE RUPA RUPA - PROVINCIA DE LEONCIO PRADO	Inicio: 75°58'44.53"W, 9°17'30.95"S, 649 metros; Fin: 76°00'07.28"W, 9°18'11.26"S, 653 metros.	C-1	0.600	26.800	27.300	23.000	NP	NP	1.833	9.200	21.100	Tri-ch
			C-2	0.700	25.600	26.100	24.000	NP	NP	1.845	8.900		Tri-ch
			C-3	35.600	20.800	26.100	27.000	19.200	7.800	2.009	18.500	19.500	Tri-ch
29	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VIAL EN LA LOCALIDAD DE SUPTE SAN JORGE, DISTRITO DE RUPA RUPA - PROVINCIA DE LEONCIO PRADO	Inicio: 75°58'44.53"W, 9°17'30.95"S, 649 metros; Fin: 76°00'07.28"W, 9°18'11.26"S, 653 metros.	C-1	0.770	31.130	68.670	31.000	22.700	8.300				Ko-e
			C-2	0.930	34.700	65.300	25.700	22.300	3.400				Ko-e
			C-3	47.650	33.620	18.740	21.380	16.220	5.160	2.094	7.510	48.700	Ko-e
30	REHABILITACIÓN Y CONSTRUCCIÓN DE CAMINO VECINAL BAJO PISCORUVACU - MANTARO, DISTRITO DE RUPA RUPA - PROVINCIA DE LEONCIO PRADO	Inicio: 76°00'55.99"W, 9°17'30.48"S, 650 metros; Fin: 76°04'21.57"W, 9°15'06.20"S, 1084 metros.	C-1	32.020	17.460	50.530	37.740	29.040	8.700	1.685	12.530	7.200	Qh-al
			C-2	14.430	24.120	61.450	41.550	25.730	15.620	1.665	14.860	7.000	Qh-al
			C-3	2.110	13.080	84.820	41.140	26.490	14.650	1.623	16.790	6.400	Qh-al
			C-4	5.260	6.150	88.600	43.270	28.690	14.580	1.846	15.500	8.000	Qh-al
			C-5	39.910	13.250	48.990	40.980	26.280	14.720	1.945	15.500	13.000	Qh-al
			C-6	81.490	3.830	14.670	NP	NP	NP	2.096	9.110	13.500	Qh-al
			C-7	18.780	14.670	74.130	47.670	32.170	15.700	1.720	18.640	7.900	Qh-al
			C-8	0.920	32.760	66.320	40.840	28.350	12.490	1.703	19.600	6.200	Qh-al
			C-9	56.440	16.870	26.650	NP	NP	NP	1.987	12.360	15.800	Qh-al
31	MEJORAMIENTO DE LA PAVIMENTACIÓN EN LA ALAMEDA PERÚ - TINGO MARIA, LEONCIO PRADO	Inicio: 75°59'51"W, 9°17'44.78"S, 650 metros; Fin: 76°00'01.96"W, 9°17'56.92"S, 648 metros.	C-1	22.560	18.860	58.580	22.520	18.400	3.920	1.850	8.700	16.100	Qh-al
			C-2	2.820	13.940	85.640	28.070	20.750	7.320				Qh-al
			C-3	30.840	42.760	26.480	NP	NP	NP				Qh-al
			C-4	1.440	21.230	77.330	25.860	21.930	3.930				Qh-al
			C-5	16.400	28.170	33.460	NP	NP	NP				Qh-al
			C-6	6.520	8.960	84.520	35.000	26.950	8.050	1.875	8.120	13.550	Qh-al
			C-7	59.070	26.160	14.770	NP	NP	NP				Qh-al
			C-8	0.970	15.710	83.320	NP	NP	NP				Qh-al
32	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD EN EL TRAMO LA CURVA JUJÚ C. TELLÓ BUENOS AIRES RD. DISTRITO DE RUPA RUPA - PROVINCIA DE LEONCIO PRADO	Inicio: 76°00'27.82"W, 9°16'22.09"S, 638 metros; Fin: 76°03'55.60"W, 9°14'19.28"S, 943 metros.	C-1	51.840	34.620	13.530	33.000	27.000	6.000	2.166	8.000	11.100	Ji-a
			C-2	50.170	45.060	4.770	NP	NP	NP				Ji-a
			C-3	3.430	1.170	2.740	NP	NP	NP				Ji-a
			C-4	2.540	1.310	6.780	NP	NP	NP				Ji-a
			C-1	35.450	42.240	22.310	NP	NP	NP				Ps-gr
			C-2	14.910	45.210	39.880	NP	NP	NP	1.826	9.580	10.630	Ps-gr
			C-3	5.470	47.300	47.420	NP	NP	NP	1.814	11.090	11.240	Ps-gr
			C-4	10.270	48.330	43.410	NP	NP	NP	2.842	12.100	13.950	Ps-gr
			C-5	3.400	7.680	88.920	53.560	23.560	30.000				Ps-gr
			C-6	23.420	44.260	32.320	NP	NP	NP	1.981	8.640	25.780	Ps-gr
			C-7	18.280	17.330	64.390	37.700	16.960	20.740				Ps-gr
			C-8	17.510	16.850	65.680	28.720	16.770	11.950				Ps-gr
			C-9	14.800	13.560	71.640	NP	NP	NP				Ps-gr
			C-10	9.030	17.760	73.200	30.550	16.670	13.880				Ps-gr
			C-11	23.000	16.800	60.200	NP	NP	NP				Ps-gr
			C-12	9.120	20.650	70.230	38.410	13.320	25.090				Ps-gr
			C-13	6.860	15.470	77.680	35.050	19.000	16.050				Ps-gr
			C-14	33.380	26.350	40.230	NP	NP	NP				Ps-gr
			C-15	77.380	19.250	3.370	NP	NP	NP				Ps-gr



33	CREACIÓN DEL CAMINO VECINAL: PAMPANILLAS – HUARIÑOS – SANTA VIRGINIA, DISTRITO DE PANAO, PROVINCIA DE PACHITEA – HUÁNUCO	Inicio: 75°49'04.34"W, 10°07'42.64"S, 3704 msnm; Fin: 75°41'40.81"W, 10°09'06.03"S, 1586 msnm.	C-16	48.150	29.360	22.490	NP	NP	NP	1.979	11.060	20.530	Pc-gr			
			C-17	47.010	20.940	21.320	NP	NP	NP	1.968	10.580	20.190	Pc-gr			
			C-18	8.090	18.730	73.170	33.690	26.560	0.000				Pc-gr			
			C-19	7.150	14.640	78.210	34.420	24.660	9.760				Pc-gr			
			C-20	35.540	32.510	31.950	NP	NP	NP				Pc-gr			
			C-21	75.990	17.320	6.690	NP	NP	NP				Pc-gr			
			C-22	48.760	19.120	32.120	NP	NP	NP	1.921	12.030	16.050	Pc-gr			
			C-23	61.130	22.030	16.850	NP	NP	NP	1.933	9.210	19.620	Pc-gr			
			C-24	33.300	21.680	45.020	30.200	21.330	8.870	1.852	12.380	11.760	Pc-gr			
			C-25	0.000	28.310	41.570	27.300	22.140	5.160	1.825	13.930	11.240	Pc-gr			
			C-26	28.930	31.210	39.860	25.670	19.410	6.260	1.824	12.240	15.390	Pc-gr			
			C-27	36.180	23.230	40.600	22.650	18.960	3.690	1.893	10.720	10.480	Pc-gr			
			C-28	46.510	27.130	26.360	NP	NP	NP	1.963	7.300	33.280	Pc-gr			
			C-29	20.270	37.090	42.640	25.140	15.890	9.250	1.770	14.330	13.260	Pc-gr			
			C-30	54.750	20.640	24.610	NP	NP	NP	1.934	8.250	28.270	Pc-gr			
			C-31	15.180	34.930	49.890	26.280	20.170	6.110	1.797	13.910	9.330	Pc-gr			
			C-32	24.880	8.520	66.600	22.270	15.620	6.650	1.545	16.960	7.410	Pc-gr			
			C-33	50.020	38.290	11.680	NP	NP	NP				Pc-gr			
			C-34	69.130	19.630	11.240	NP	NP	NP	2.166	8.260	36.150	Pc-gr			
			C-35	61.500	20.840	17.670	NP	NP	NP				Pc-gr			
			C-36	41.730	45.350	12.930	25.920	20.570	5.350	2.099	6.450	39.820	Pc-gr			
			C-37	58.950	32.380	8.660	23.660	19.630	4.030	2.129	5.780	33.950	Pc-gr			
			C-38	46.710	41.490	11.800	23.680	19.540	4.140	2.133	6.210	35.500	Pc-gr			
			C-39	38.870	42.350	18.780	28.450	20.820	7.650	2.031	8.380	38.650	Pc-gr			
			34	REHABILITACIÓN Y MEJORAMIENTO DEL CAMINO VECINAL EMP. R-033 ENTRE LAS LOCALIDADES DE CONQUE – TAYBO, EN EL DISTRITO DE PAMPAMARCA, PROVINCIA DE YAROWILCA – HUÁNUCO.	Inicio: 76°42'10.61"W, 9°47'21.44"S, 3449 msnm; Fin: 76°43'16.18"W, 9°42'20.44"S, 3429 msnm.	C-1	3.000	37.500	59.900	33.100	24.000	9.100	1.600	16.000	5.800	Pc-cm1
						C-2	23.300	28.100	48.600	60.000	30.600	29.400	1.961	14.300	28.700	Pc-cm1
						C-3	34.900	30.200	34.900	38.200	23.100	15.100	2.000	12.900	40.320	Pc-cm1
						C-4	15.500	36.800	47.700	38.500	26.200	12.300	1.760	16.700	25.900	Pc-cm1
						C-5	13.100	49.200	37.700	30.500	20.700	9.800	1.940	12.500	16.800	Pc-cm1
						C-6	24.900	29.600	45.500	45.600	26.500	19.100	1.800	21.800	34.900	Pc-cm1
						C-7	50.700	25.500	21.800	37.100	23.600	13.500	2.110	8.000	35.200	Pc-cm1
						C-8	50.200	19.100	30.700	45.500	38.400	7.100	2.075	12.500	30.500	Pc-cm1
						C-9	27.600	35.600	36.800	49.300	35.700	13.600	1.901	12.500	19.000	Pc-cm1
						C-10	14.100	49.500	35.400	30.800	19.600	11.200	1.841	11.900	17.100	Pc-cm1
						C-11	11.000	51.300	35.900	44.800	23.900	20.900	1.706	16.300	34.100	Pc-cm1
						C-12	69.500	15.300	15.200	25.300	20.800	4.500	1.938	7.800	36.800	Pc-cm1
						C-13	18.600	38.300	41.200	42.300	31.700	10.600	1.825	13.600	21.900	Pc-cm1
						C-14	9.100	49.700	41.200	21.900	15.500	6.400	1.811	14.100	13.500	Pc-cm1
						C-15	10.700	20.900	68.400	44.600	22.600	22.000	1.579	16.300	4.400	Pc-cm1
C-16	12.400	66.100				21.500	41.300	30.700	10.600	1.813	14.200	15.000	Pc-cm1			
C-17	7.600	52.500				39.900	44.900	28.400	16.500	1.838	14.200	21.200	Pc-cm1			
C-18	18.100	37.700				44.200	35.500	22.300	13.200	1.841	17.100	8.600	Pc-cm1			
C-19	60.800	26.900				12.300	18.300	15.000	3.300	2.225	6.400	41.800	Pc-cm1			
C-20	57.700	26.200				16.100	34.500	24.400	10.100	2.018	8.200	41.200	Pc-cm1			
C-21	3.300	51.200				45.500	51.300	39.400	11.900	1.780	14.300	18.100	Pc-cm1			
C-22	24.200	37.700				38.300	35.200	21.000	14.200	1.795	15.100	14.100	Pc-cm1			
C-23	4.800	65.900				29.300	44.100	35.300	8.800	1.831	14.200	14.400	Pc-cm1			
C-24	3.800	55.600				40.600	32.500	21.300	11.200	1.720	16.100	11.300	Pc-cm1			
C-25	23.800	37.000				39.200	40.500	27.200	13.300	1.841	15.100	18.900	Pc-cm1			
35	MEJORAMIENTO DEL CAMINO VECINAL CHAVINILLO – LAGHAGAYAN, PROVINCIA DE YAROWILCA.	Inicio: 76°36'21.52"W, 9°51'17.83"S, 3485 msnm; Fin: 76°34'10.67"W, 9°48'46.18"S, 3856 msnm.	C-1	15.900	35.300	48.800	41.000	31.200	9.800	1.820	17.300	18.100	Cia			
			C-2	30.900	37.000	32.100	41.000	31.500	9.500	1.822	17.000	16.500	Cia			
			C-3	54.100	28.000	17.900	28.500	25.700	2.800	2.163	8.800	38.600	Cia			
			C-4	62.700	29.100	8.200	29.100	22.500	6.600	2.100	10.600	35.300	Cia			
			C-5	27.700	14.500	32.800	24.100	8.700	15.400	2.321	2.010	30.200	Cia			
			C-6	11.900	45.400	42.700	42.200	31.900	10.300	1.823	18.400	15.000	Cia			
			C-7	41.400	42.800	15.800	35.100	23.500	11.600	1.727	18.800	15.600	Cia			
			C-8	42.600	34.800	22.600	35.700	24.000	11.700	1.992	11.400	32.000	Cia			
			C-9	61.100	26.500	12.400	30.400	22.200	8.200	1.982	12.000	34.000	Cia			
			C-10	48.400	25.000	26.600	33.800	24.200	9.600	1.990	10.200	30.100	Cia			
			C-11	67.600	21.400	11.000	22.500	18.600	3.900	2.247	6.200	41.520	Cia			
			C-12	7.200	38.200	54.600	33.500	18.600	14.900	1.628	17.000	6.400	Cia			
			C-13	54.000	33.500	12.500	30.200	21.300	8.900	1.978	12.700	40.000	Cia			
			C-14	77.900	14.700	7.400	16.100	12.000	4.100	2.261	6.000	36.940	Cia			
			C-15	18.700	41.500	39.800	40.600	27.100	13.500	1.811	16.100	20.000	Cia			
36	REHABILITACIÓN Y MEJORAMIENTO DEL CAMINO VECINAL DEL CENTRO POBLADO DE HUAYUCILANO – JARPO, DISTRITO DE CHAVINILLO, PROVINCIA DE YAROWILCA	Inicio: 76°37'06.10"W, 9°50'40.23"S, 3439 msnm; Fin: 76°34'06.82"W, 9°47'17.48"S, 3849 msnm.	C-16	56.700	15.000	28.300	40.600	26.500	14.100	1.980	10.800	39.500	Cia			
			C-17	74.300	17.300	8.600	27.000	19.400	7.600	2.122	8.500	35.600	Cia			
			C-18	11.200	28.400	60.400	37.400	27.700	9.700	1.530	18.100	6.000	Cia			
			C-19	0.000	27.700	72.300	31.300	23.200	8.100	1.525	17.500	4.900	Cia			
			C-20	5.400	34.400	60.200	57.200	45.100	12.100	1.367	26.600	1.700	Cia			
			C-21	0.000	45.700	54.300	34.200	24.500	9.700	1.587	16.200	4.400	Cia			
			C-22	1.300	41.800	56.900	43.900	36.500	7.400	1.360	19.800	5.000	Cia			
			C-23	22.000	19.200	58.800	35.800	31.900	3.900	1.370	19.800	3.600	Cia			
			C-24	58.600	32.700	8.700	21.800	17.900	3.900	2.228	6.100	42.640	Cia			
			C-25	22.200	36.300	40.900	37.900	26.500	11.400	1.710	17.100	20.400	Cia			
36	REHABILITACIÓN Y MEJORAMIENTO DEL CAMINO VECINAL DEL CENTRO POBLADO DE HUAYUCILANO – JARPO, DISTRITO DE CHAVINILLO, PROVINCIA DE YAROWILCA	Inicio: 76°37'06.10"W, 9°50'40.23"S, 3439 msnm; Fin: 76°34'06.82"W, 9°47'17.48"S, 3849 msnm.	C-1	16.400	39.800	41.800	33.900	NP	NP	1.717	16.200	18.200	Pc-cm1			
			C-2	0.000	2.100	97.900	67.900	57.100	10.800	1.337	18.300	4.600	Pc-cm1			
			C-3	0.000	40.800	59.200	54.400	48.400	6.000	1.560	17.600	4.000	Pc-cm1			
			C-4	58.600	37.700	3.700	24.800	NP	NP	2.006	17.500	32.540	Pc-cm1			
			C-5	0.000	25.000	75.000	29.500	24.500	5.000	1.324	18.400	2.900	Pc-cm1			
			C-6	8.300	22.500	69.200	37.400	30.900	6.500	1.361	17.800	2.800	Pc-cm1			
			C-7	34.500	45.300	20.200	31.800	23.400	8.400	2.098	9.300	25.100	Pc-cm1			
			C-8	25.700	71.500	24.500	19.100	5.400	13.700	1.682	12.300		Pc-cm1			
			C-9	13.900	21.600	63.300	37.400	26.200	11.200	1.836	20.900	2.400	Pc-cm1			
			C-10	0.000	35.900	64.300	32.400	23.400	9.000	1.458	18.400	4.300	Pc-cm1			
			C-11	0.000	36.000	64.000	35.000	28.100	6.900	1.531	18.500	4.200	Pc-cm1			



37	MEJORAMIENTO Y AMPLIACIÓN DE LOS SERVICIOS DE TRANSITABILIDAD DE PISTAS Y VEREDAS DE LA LOCALIDAD DE GASHANPAMPA, DISTRITO DE SAN MIGUEL DE CAURI, PROVINCIA DE LAURICOCHA, REGIÓN HUÁNUCO	Inicio: 76°39'10.51"W, 10°12'28.53"S, 4107 msnm; Fin: 76°39'33.28"W, 10°12'50.93"S, 4108 msnm.	C-17	20.700	42.700	36.600	36.000	26.000	10.000	1.868	14.090	14.800	Pe-cm1
			C-18	28.600	37.700	33.700	23.000	17.000	6.000	2.034	12.900	28.500	Pe-cm1
			C-19	11.500	13.300	75.200	37.000	24.000	13.000	1.781	16.100	7.400	Pe-cm1
			C-20	51.300	28.000	20.700	28.000	25.000	3.000	2.185	9.900	28.500	Pe-cm1
			C-21	59.600	16.800	23.600	27.000	18.000	9.000	2.111	12.100	20.670	Pe-cm1
			C-22	71.400	15.300	13.300	27.000	16.000	11.000	2.134	8.700	28.200	Pe-cm1
			C-23	71.700	13.600	14.700	31.000	21.000	10.000	2.099	7.700	23.900	Pe-cm1
			C-24	57.600	12.700	29.700	37.000	23.000	14.000	1.899	9.400	21.300	Pe-cm1
			C-25	38.700	25.000	36.300	36.000	24.000	12.000	1.938	12.800	13.100	Pe-cm1
			C-1	53.120	28.170	18.710	24.700	17.000	7.700				Pe-cm2
			C-2	49.980	35.050	14.970	27.600	19.700	7.900				Pe-cm2
			C-3	2.320	35.680	62.000	42.900	34.300	8.600				Pe-cm2
			C-4	24.730	44.000	31.270	26.000	18.400	7.600				Pe-cm2
			C-5	34.470	35.450	30.080	26.000	18.800	7.200				Pe-cm2
38	CREACIÓN DEL CAMINO VECINAL TRAMO INDEPENDENCIA - RAUBA - SAN MIGUEL DE CAURI - LAURICOCHA - HUÁNUCO	Inicio: 76°40'25.80"W, 10°21'25.01"S, 4039 msnm; Fin: 76°44'30.20"W, 10°20'48.41"S, 4660 msnm.	C-6	34.500	35.490	30.010	27.500	18.800	8.700	2.035	8.700	20.000	Pe-cm2
			C-7	60.740	23.010	16.250	23.000	15.300	7.700				Pe-cm2
			C-8	14.470	35.450	30.080	26.000	18.800	7.200				Pe-cm2
			C-9	2.320	35.680	62.000	42.900	34.300	8.600				Pe-cm2
			C-10	34.500	35.490	30.010	27.500	18.800	8.700				Pe-cm2
			C-11	49.980	35.050	14.970	27.600	19.700	7.900				Pe-cm2
			C-12	53.120	28.170	18.710	24.700	17.000	7.700				Pe-cm2
			C-13	49.980	35.050	14.970	27.600	19.700	7.900	2.020	8.000	19.500	Pe-cm2
			C-14	56.270	37.690	6.040	19.200	17.300	1.900	2.195	5.400	17.000	Pe-cm2
			C-1	32.460	15.560	58.980	33.000	22.000	11.000	1.710	10.800	7.300	Q-gf
			C-2	23.320	20.180	56.490	30.000	21.000	9.000				Q-gf
			C-3	30.010	35.500	34.490	35.000	28.000	7.000				Q-gf
			C-4	55.090	29.280	15.610	22.000	16.000	6.000	1.930	9.000	11.100	Q-gf
			C-5	37.280	11.230	49.490	23.000	16.000	7.000				Q-gf
39	CREACIÓN DE PISTAS Y VEREDAS EN LA LOCALIDAD DE HUAPIN, DISTRITO DE SAN FRANCISCO DE ASIS, LAURICOCHA - HUÁNUCO	Inicio: 76°40'29.13"W, 9°58'34.56"S, 3441 msnm; Fin: 76°40'30.20"W, 9°58'27.93"S, 3430 msnm.	C-6	50.280	43.170	6.540	22.000	15.000	7.000				Q-gf
			C-7	20.330	30.360	49.110	35.000	27.000	8.000				Q-gf
			C-8	27.810	22.200	49.380	34.000	26.000	8.000	2.220	7.400	21.800	Q-gf
			C-9	25.300	25.470	49.230	33.000	27.000	6.000				Ks-j
			C-10	31.490	35.070	33.480	30.000	28.000	2.000				Ks-j
			C-11	54.010	16.150	29.840	30.000	27.000	3.000	2.110	13.900	21.100	Ks-j
			C-12	47.010	24.430	28.560	31.000	26.000	5.000				Ks-j
			C-13	39.470	12.970	47.570	32.000	26.000	6.000				Ks-j
			C-14	36.210	45.530	18.260	34.000	25.000	9.000	2.200	7.500	25.000	Ks-j
			C-15	35.840	17.700	46.460	35.000	22.000	13.000				Ks-j
			C-16	38.770	51.370	9.870	29.000	20.000	9.000				Ks-j
			C-17	20.690	44.230	35.330	24.000	16.000	8.000	2.200	8.600	24.800	Ks-j
			C-18	47.560	47.050	5.390	24.000	15.000	9.000				Ks-j
			C-19	50.950	24.490	24.560	25.000	16.000	9.000				Ks-j
40	CREACIÓN DE PISTAS Y VEREDAS EN LA LOCALIDAD DE HONORIA, DISTRITO DE HONORIA, PROVINCIA DE PUERTO INCA, REGIÓN HUÁNUCO	Inicio: 74°42'25.05"W, 8°46'17.03"S, 158 msnm; Fin: 74°42'32.42"W, 8°45'32.15"S, 163 msnm.	C-20	44.510	26.650	28.840	26.000	16.000	10.000	2.190	8.100	19.700	Ks-j
			C-21	41.410	31.610	26.980	29.000	26.000	3.000	7.900	7.900	24.400	Ks-j
			C-22	33.600	36.670	29.720	35.000	29.000	6.000	2.190	8.300	23.500	Ks-j
			C-1	35.390	37.190	7.490	23.990	23.370	0.620	2.185	6.880	18.650	Qp-lu
			C-2	99.530	0.660	0.010	NP	NP	NP				Qp-lu
			C-3	3.860	94.330	1.810	NP	NP	NP				Qp-lu
			C-4	0.790	29.890	69.320	22.270	14.580	7.690	1.733	14.370	5.680	Qp-lu
			C-5	1.330	42.550	56.340	18.730	13.290	5.420				Qp-lu
			C-6	7.470	23.680	68.850	20.950	16.270	4.680	1.821	12.540	7.320	Qp-lu
			C-7	1.400	18.880	79.720	22.300	16.640	5.660				Qp-lu
			C-8	6.220	19.220	74.560	20.530	15.660	4.650	1.809	12.230	7.610	Qp-lu
			C-9	7.740	20.600	71.660	26.270	16.270	10.000				Qp-lu
			C-10	5.740	29.330	64.940	23.620	16.550	7.070	1.745	15.040	6.010	Qp-lu
			C-11	12.870	18.450	68.880	23.530	15.580	7.730				Qp-lu
			C-12	6.220	56.090	37.690	NP	NP	NP	1.905	10.310	15.210	Qp-lu
41	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD CARRETERA EMP. PE-SN (MONTERRICO)-LA LIBERTAD, RUTA N°10-1012, L=5.400M - LA LIBERTAD DEL DISTRITO DE YUAYACHIS - PROVINCIA DE PUERTO INCA	Inicio: 75°00'40.54"W, 8°43'29.21"S, 252 msnm; Fin: 75°03'04.48"W, 8°43'29.86"S, 205 msnm.	C-13	1.170	43.400	55.430	21.130	14.450	6.660				Qp-lu
			C-1	12.200	26.030	61.770	20.140	19.700	0.440	1.578	8.380	5.010	N-i
			C-2	0.000	20.170	79.830	43.170	23.940	19.230	1.632	15.410	6.310	N-i
			C-3	0.000	18.810	81.190	42.050	28.980	13.070	1.611	15.280	6.010	N-i
			C-4	0.000	52.660	47.340	24.560	18.310	6.050	1.824	11.190	7.210	N-i
			C-5	0.440	48.000	51.560	25.640	19.880	5.760	1.727	10.390	8.310	N-i
			C-6	0.000	18.530	81.470	54.720	32.210	22.510	1.421	18.230	4.110	N-i
			C-7	0.230	42.020	57.750	21.030	18.030	2.980	1.527	8.120	4.980	N-i
			C-8	0.000	21.730	78.270	41.120	30.170	10.950	1.671	14.970	5.910	N-i
			C-9	0.160	28.670	71.370	33.640	19.400	14.240	1.690	15.590	6.110	N-i
			C-10	0.000	14.260	85.740	40.150	29.220	10.930	1.599	16.390	5.210	N-i
			C-1	0.000	19.570	80.430	35.320	21.550	13.770	1.569	13.500	5.840	Nic-h
			C-2	0.150	49.330	50.520	28.480	22.870	5.610				Nic-h
			C-3	0.000	20.720	79.280	34.730	24.540	10.190	1.572	14.310	6.210	Nic-h
42	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD CARRETERA EMP. PE-SN (MONTERRICO)-LA LIBERTAD, RUTA N°10-1012, L=5.400M - LA LIBERTAD DEL DISTRITO DE YUAYACHIS - PROVINCIA DE PUERTO INCA	Inicio: 75°00'40.54"W, 8°43'29.21"S, 252 msnm; Fin: 75°03'04.48"W, 8°43'29.86"S, 205 msnm.	C-4	0.090	19.390	80.520	27.160	23.650	3.510				Nic-h
			C-5	0.000	14.360	85.640	47.690	29.750	17.940	1.562	13.160	5.220	Nic-h
			C-6	0.180	33.800	66.200	32.570	27.530	5.040				Nic-h
			C-7	0.000	33.690	66.310	26.680	18.540	8.140	1.532	13.090	6.340	Nic-h
			C-8	1.220	24.870	73.910	31.600	30.060	1.540				Nic-h
			C-9	0.240	31.510	68.250	36.830	26.650	10.160	1.561	13.480	6.120	Nic-h
			C-10	7.220	28.310	64.470	24.650	19.390	5.260				Nic-h
			C-11	0.660	43.530	55.810	26.650	20.350	6.300	1.693	12.330	8.220	Nic-h
			C-1	0.000	34.280	65.720	37.740	15.910	21.630	1.635	18.690	8.410	Nic-h
			C-2	0.000	16.670	81.330	45.850	19.820	26.030				Nic-h
			C-3	0.000	12.840	87.160	47.520	22.470	24.850	1.585	20.710	7.760	Nic-h
43	ACCESO DEL CENTRO POBLADO SANTO TORIBIO LA PUNTA, DISTRITO DE HUAPIN	Inicio: 76°01'33.12"W, 9°53'22.65"S, 3008 msnm; Fin: 76°01'33.12"W, 9°53'22.65"S, 3008 msnm.	C-1	15.640	40.730	43.630	41.000	20.570	20.430	2.123	7.288	23.640	PE-e
			C-2	15.670	39.510	44.820	39.000	21.670	17.530	2.124	7.684	22.080	PE-e
			C-3	15.040	36.770	48.190	39.000	23.990	15.010	2.132	7.000	20.590	PE-e



44	CREACION DEL CAMINO VECINAL CARHUE- SANTA VIRGINIA, DISTRITO PANAJO, PROVINCIA PACHITEA	Inicio: 75°47'00.11"W, 10°07'57.84"S, 3618 msnm; Fin: 75°41'45.56"W, 10°05'09.88"S, 1623 msnm.	C-6	48.760	19.120	32.120	NP	NP	NP	1.921	12.030	12.630	Ps-gr			
			C-7	61.130	22.030	16.850	25.670	19.410	6.260	1.933	9.210	12.230	Ps-gr			
			C-8	33.300	23.680	45.020	30.200	21.330	8.870	1.852	12.380	17.480	Ps-gr			
			C-9	28.120	28.310	43.570	27.300	22.140	5.160	1.825	13.930	15.890	Ps-gr			
			C-10	28.930	31.210	39.860	25.670	19.410	6.260	1.824	12.240	20.330	Ps-gr			
			C-11	36.180	23.230	40.600	22.650	18.960	3.690	1.893	10.720	16.390	Ps-gr			
			C-12	46.510	27.130	26.360	NP	NP	NP	1.963	7.300	39.370	Ps-gr			
			C-13	20.270	37.090	42.640	25.140	15.890	9.250	1.770	14.330	17.590	Ps-gr			
			C-14	54.750	20.640	24.610	NP	NP	NP	1.934	8.250	37.520	Ps-gr			
			C-15	15.180	34.930	49.890	26.280	20.170	6.110	1.893	10.720	12.660	Ps-gr			
			C-16	24.880	8.520	66.600	22.270	15.620	6.650	1.545	16.960	10.680	Ps-gr			
			C-17	69.130	19.630	11.240	NP	NP	NP	2.166	8.260	41.200	Ps-gr			
			45	REHABILITACIÓN Y MEJORAMIENTO DE LA CARRETERA IMP. RUTA 28A (PTE. RANCHO) CHAGLLA- RUMICHAICA	Inicio: 76°05'36.26"W, 9°49'36.26"S, 1788 msnm; Fin: 75°53'53.91"W, 9°55'09.71"S, 3291 msnm.	C-1	43.400	30.500	26.300	26.000	18.000	8.000	2.160	7.600	39.800	PE-e
						C-2	0.000	55.300	44.700	33.000	21.000	12.000	1.854	14.800	21.100	PE-e
						C-3	58.700	23.600	17.700	30.000	23.000	7.000	2.307	6.600	31.200	PE-e
						C-4	57.100	25.000	17.900	28.000	22.000	6.000	2.286	8.400	37.650	PE-e
						C-5	59.700	23.700	16.600	24.000	20.000	4.000	2.265	7.400	39.500	PE-e
C-6	62.700	22.800				14.500	24.000	22.000	2.000	2.317	7.500	38.190	PE-e			
C-7	0.000	29.600				70.400	29.000	20.000	9.000	1.951	15.100	16.800	PE-e			
C-8	7.000	27.800				65.200	34.000	22.000	12.000	1.751	16.100	9.300	PE-e			
C-9	45.200	21.700				33.300	39.000	25.000	14.000	2.017	13.900	39.200	PE-e			
C-10	59.800	24.700				15.500	NP	NP	NP	2.145	8.600	41.200	PE-e			
C-11	46.700	12.300				41.000	38.000	27.000	11.000	1.903	14.900	23.400	PE-e			
C-12	52.000	33.500				14.400	NP	NP	NP	2.166	9.300	42.100	PE-e			
C-13	73.300	16.700				9.900	31.000	21.000	10.000	2.119	7.300	35.400	PE-e			
C-14	0.000	21.000				79.000	29.000	20.000	9.000	1.884	15.400	8.100	PE-e			
C-15	56.800	25.300				17.900	28.000	22.000	6.000	2.244	9.900	37.500	PE-e			
C-16	6.300	7.900				85.800	40.000	27.000	13.000	1.519	29.000	5.800	PE-e			
C-17	56.800	23.600				21.500	NP	NP	NP	2.157	8.300	38.600	PE-e			
C-18	55.700	31.100				13.200	NP	NP	NP	2.131	9.000	36.400	PE-e			
C-19	0.000	52.800				47.200	38.000	29.000	9.000	1.886	12.700	17.200	PE-e			
C-20	0.000	43.100				56.900	39.000	26.000	13.000	1.699	16.200	9.500	PE-e			
C-21	0.000	23.000				77.000	34.000	27.000	7.000	1.835	15.200	17.400	PE-e			
C-22	0.000	2.900				97.100	56.000	42.000	14.000	1.549	27.500	4.600	PE-e			
C-23	0.000	21.500				78.500	38.000	24.000	14.000	1.683	16.400	8.100	PE-e			
C-24	0.000	15.900				84.100	37.000	27.000	10.000	1.812	17.600	9.800	PE-e			
C-25	8.500	27.900				63.700	33.000	26.000	7.000	1.836	17.000	14.900	PE-e			
C-26	0.000	26.300				73.700	42.000	28.000	14.000	1.525	24.600	6.700	PE-e			
C-27	0.000	15.300				84.700	36.000	27.000	9.000	1.774	17.600	10.400	PE-e			
C-28	0.000	10.900				89.100	42.000	30.000	12.000	1.490	26.800	3.100	PE-e			
C-29	0.000	30.900				69.100	37.000	29.000	8.000	1.645	21.800	14.700	PE-e			
C-30	52.300	14.600				33.300	26.000	19.000	7.000	2.233	8.100	36.500	PE-e			
C-31	0.000	33.800				66.200	33.000	27.000	6.000	1.779	12.100	15.800	PE-e			
C-32	0.000	11.300				88.700	44.000	31.000	13.000	1.465	32.300	3.800	PE-e			
C-33	0.000	57.700				42.300	27.000	25.000	2.000	1.833	16.300	21.600	PE-e			
C-34	0.000	22.400				77.600	31.000	23.000	8.000	1.778	17.100	10.100	PE-e			
C-35	0.000	58.500				41.500	28.000	23.000	5.000	1.737	16.800	19.100	PE-e			
C-36	57.600	30.000				12.400	30.000	24.000	6.000	2.048	9.800	40.110	PE-e			
C-37	0.000	55.200				44.800	32.000	NP	NP	1.877	12.100	18.100	PE-e			
C-38	70.100	21.100				8.800	NP	NP	NP	2.178	8.800	39.500	PE-e			
C-39	0.000	9.400				90.600	46.000	39.000	7.000	1.523	26.600	6.900	PE-e			
C-40	0.000	55.500				44.500	30.000	26.000	4.000	1.841	13.000	15.800	PE-e			
C-41	48.400	29.900				21.700	NP	NP	NP	2.161	9.600	36.500	PE-e			
C-42	0.000	33.500				66.500	44.000	36.000	8.000	1.561	26.900	11.500	PE-e			
C-43	0.000	23.900				76.100	38.000	26.000	12.000	1.536	25.100	9.700	PE-e			
C-44	0.000	8.200				91.800	52.000	39.000	13.000	1.623	32.500	7.600	PE-e			
C-45	0.000	38.400				61.600	40.000	28.000	12.000	1.709	17.100	6.300	PE-e			
C-46	0.000	7.900				92.100	48.000	32.000	16.000	1.570	26.500	7.100	PE-e			
C-47	0.000	47.300				52.700	33.000	26.000	7.000	1.787	14.600	16.100	PE-e			
C-48	0.000	56.700				43.300	33.000	24.000	9.000	1.847	12.800	15.000	PE-e			
C-49	0.000	8.100				91.900	49.000	29.000	20.000	1.644	22.000	7.200	PE-e			
C-50	0.000	21.700				78.300	40.000	33.000	7.000	1.699	17.000	4.000	PE-e			
C-51	0.000	65.700				34.300	28.000	NP	NP	1.954	11.700	18.100	PE-e			
C-52	0.000	20.000				80.000	57.000	38.000	19.000	1.567	27.500	6.000	Ps-gr			
C-53	0.000	14.200				85.800	55.000	41.000	14.000	1.245	41.000	3.000	Ps-gr			
C-54	0.000	32.700				67.300	36.000	25.000	11.000	1.722	17.000	10.100	Ps-gr			
C-55	0.000	55.300				44.700	33.000	28.000	5.000	1.836	13.900	17.700	Ps-gr			
C-56	0.000	24.900				75.100	23.000	NP	NP	1.855	20.100	11.900	Ps-gr			
C-57	0.000	32.300				67.700	31.000	24.000	7.000	1.806	13.500	10.800	Ps-gr			
C-58	0.000	60.400				39.600	33.000	NP	NP	2.000	10.500	16.900	Ps-gr			
C-59	0.000	58.300				41.700	30.000	24.000	6.000	2.241	8.300	39.500	Ps-gr			
C-60	0.000	54.300				45.700	35.000	31.000	4.000	1.885	12.000	17.900	Ps-gr			
C-61	0.000	33.600				66.400	39.000	30.000	9.000	1.873	14.500	7.700	Ps-gr			
C-62	0.000	35.200				64.800	42.000	27.000	15.000	1.474	31.000	4.400	Ps-gr			
C-63	0.000	26.000				74.000	28.000	NP	NP	1.657	23.100	9.300	Ps-gr			
C-64	0.000	49.400				50.600	34.000	30.000	4.000	1.734	20.300	19.000	Ps-gr			
C-65	0.000	36.200				63.800	39.000	33.000	6.000	1.668	19.500	12.500	Ps-gr			
C-66	1.900	13.500				84.500	40.000	24.000	16.000	1.587	27.000	2.600	Ps-gr			
C-67	0.000	28.300				71.700	34.000	27.000	7.000	1.885	15.700	9.700	Ps-gr			
C-68	0.000	14.300				85.700	34.000	25.000	9.000	1.604	16.600	6.400	Ps-gr			
C-69	0.000	25.700				74.300	39.000	28.000	11.000	1.726	19.700	8.500	Ps-gr			
C-70	0.000	14.300				85.700	47.000	38.000	9.000	1.415	36.600	6.600	Ps-gr			
C-71	78.400	17.300				4.500	34.000	24.000	10.000	2.154	11.800	32.500	Ps-gr			
46	RECONSTRUCCIÓN DE PUENTE SOBRE Y CUNETAS; ADQUISICIÓN DE SEÑALES DE TRÁFICO; EN GUJA; SERVICIO DE TRANSITABILIDAD VIAL; Y SEÑALIZACIÓN DE CRUCE.	Inicio: 75°58'00.85"W, 9°53'32.77"S, 2534 msnm; Fin: 75°58'10.05"W, 9°54'16.17"S, 2855 msnm.	C-1	14.520	37.910	47.770	17.230	29.980	7.270	1.835	15.850	16.930	PE-e			
			C-2	18.470	33.190	49.340	35.950	33.200	2.710	1.882	12.710	20.480	PE-e			
			C-3	35.660	36.020	28.320	30.230	27.200	3.030	1.879	12.460	20.870	PE-e			
			C-4	4.540	78.990	15.560	NP	NP	NP	1.928	9.510	22.480	PE-e			
47	MOVILIDAD URBANA EN LAS VÍAS LOCALES DE CALLAGUA	Inicio: 75°58'00.85"W, 9°53'42.38"S, 2549 msnm; Fin: 76°02'58.00"W, 9°54'16.17"S, 2855 msnm.	C-1	0.600	22.600	76.810	40.130	32.030	8.080	1.943	7.460	13.170	PE-e			
			C-2	45.480	42.700	11.810	33.370	27.770	5.600	2.125	6.000	26.260	PE-e			
			C-3	54.110	24.420	21.470	33.140	30.690	2.450	2.099	6.390	26.320	PE-e			



48	MEJORAMIENTO DEL SERVIDOR DE MOVILIDAD URBANA EN LOS JIRONES: MANOZGUA 11-3	Inicio: 76°14'10.10"E, 9°53'43.52"S, 2465 msnm; Fin: 76°15'01.62"E, 9°53'43.52"S	C-1	8.070	27.790	34.350	30.320	25.850	4.470	2.113	7.450	34.180	FE-e	
49	MEJORAMIENTO DEL SERVIDOR DE TRANSITABILIDAD DE LA CARRETERA DEPARTAMENTAL HU 112, TRAMO HUASCHACA-CALLAGAN MANZANA DEL DISTRITO DE MOLINO - PROVINCIA DE PACHETA	Inicio: 76°02'07.80"W, 9°56'54.54"S, 2456 msnm; Fin: 76°00'50.50"W, 9°58'01.94"S, 2577 msnm	C-2	1.580	18.550	79.870	39.380	35.690	3.690	1.620	10.600	26.510	FE-e	
			C-1	16.780	40.520	42.710	24.530	22.160	2.170	1.912	12.130	12.510	FE-e	
			C-2	3.380	29.220	67.400	27.960	22.360	5.600	1.679	18.340	8.570	FE-e	
			C-3	10.520	44.550	44.930	25.360	23.170	2.190	1.830	15.990	11.250	FE-e	
			C-4	3.970	57.470	38.560	26.390	24.080	2.310	1.877	15.140	13.640	FE-e	
			C-5	5.960	37.280	56.770	27.420	23.490	3.930	1.786	17.150	11.240	FE-e	
50	VEREDAS DE LOS JIRONES 9 DE OCTUBRE, MOLINO, CUBA, UNION PANAO, CRESPO CASTILLO, SAN JORGE, ABUALACIN, JOSE CARLOS	Inicio: 76°01'04.15"W, 9°54'30.60"S, 2365 msnm; Fin: 76°00'43.80"W, 9°54'48.63"S, 2370 msnm	C-6	8.840	36.290	54.870	25.500	22.220	3.280	1.650	19.100	12.740	FE-e	
			C-1	5.000	39.200	55.800	37.000	21.000	16.000	1.260	7.100	35.000	FE-e	
			C-2	7.000	36.300	56.900	35.000	28.000	7.000	1.300	8.000	35.000	FE-e	
			C-3	53.700	32.000	14.300	22.000	19.000	3.000	2.210	5.100	32.400	FE-e	
			C-4	64.100	18.300	17.600	24.000	21.000	3.000	2.160	4.800	31.500	FE-e	
51	MEJORAMIENTO DE LA TRANSITABILIDAD DE ACCESOS A PUERTO PROVINCIA DE AMBO	Inicio: 76°19'54.57"W, 10°17'46.59"S, 2358 msnm; Fin: 76°18'30.17"W, 10°17'44.69"S, 2360 msnm	C-5	47.000	45.400	7.600	22.000	19.000	3.000	2.170	7.300	38.700	FE-e	
			C-1	41.190	41.050	17.710	75.620	58.290	37.330					Ci-a
			C-2	30.770	36.010	33.220	56.760	39.340	16.820	1.987	9.321	11.021		Ci-a
			C-3	0.000	0.000	100.000	67.190	23.560	43.630					Ci-a
			C-4	77.490	21.480	1.030	58.900	45.420	13.480	1.982	10.020	10.954		Ci-a
			C-5	54.490	26.160	19.390	65.740	29.200	36.540					Ci-a
			C-6	51.360	27.420	21.220	55.870	25.370	30.500					Ep-di
			C-7	38.000	21.700	40.300	70.680	35.680	35.000					Ep-di
			C-8	45.060	22.720	32.220	56.350	29.140	27.210					Ep-di
			C-9	46.470	26.790	26.740	59.230	28.690	30.540					Ep-di
			C-10	48.680	17.860	33.460	57.480	30.110	27.370					Ci-a
			C-11	35.000	24.380	40.620	60.580	24.170	36.410	2.071	9.210	15.213		Ci-a
			C-12	48.920	19.530	31.550	68.280	25.860	42.420					Ci-a
			C-13	50.260	21.550	26.190	76.510	30.190	46.120					Ci-a
			C-14	25.420	27.050	47.530	60.750	37.030	23.720					Ci-a
			C-15	21.340	35.510	43.150	73.950	29.170	44.780	2.163	8.100	14.871		Ci-a
			C-16	65.110	22.240	12.650	79.730	43.770	35.960					Ci-a
			C-17	67.620	28.970	3.410	73.080	36.030	37.090					Ci-a
52	MEJORAMIENTO Y REHABILITACION DEL CAVINO VECINAL TRAMO: EMP. HU - GSE CAYMAN	Inicio: 76°16'49.92"W, 9°58'50.00"S, 2184 msnm; Fin: 76°17'11.00"W, 9°58'55.70"S, 2239 msnm	C-1	14.280	16.930	68.790	34.170	18.380	15.790	1.905			Gr-al	
53	MEJORAMIENTO A NIVEL DE ASFALTADO DE LA CARRETERA LA UNION, GUILLANCANCHA, ENTRADA A HUANCLO PAMPA, DISTRITO DE LA UNION, PROVINCIA DE DOS DE MAYO, REGION HUANCLO	Inicio: 76°48'03.85"W, 9°49'42.34"S, 2224 msnm; Fin: 76°48'01.31"W, 9°51'36.80"S, 2292 msnm	C-1	34.930	24.560	40.510	20.260	13.360	6.900				Qh-al	
			C-2	9.270	37.150	53.580	24.850	16.950	7.900					Qh-al
			C-3	47.720	24.620	27.660	16.880	15.660	1.220	2.005	7.324	23.120		Qh-al
			C-4	9.850	30.410	59.740	20.280	16.220	4.060					Qh-al
			C-5	32.690	37.370	29.940	20.300	14.110	6.190					Qh-al
			C-6	10.910	35.530	53.560	18.340	13.760	4.580	2.010	7.120	20.450		Qh-al
			C-7	4.600	83.090	12.310	18.470	15.070	3.400					Qh-al
			C-8	12.820	58.120	29.060	21.150	16.580	4.570					Qh-al
			C-9	13.150	51.570	35.280	19.770	15.050	4.720					Qh-lu
			C-10	24.530	21.300	54.170	24.700	15.720	8.980					Qh-lu
			C-11	51.890	18.810	29.300	21.160	16.700	4.460	2.065	7.932	26.543		Qh-lu
			C-12	29.800	63.460	6.740	14.670	13.930	0.740					Qh-lu
			C-13	76.910	2.620	20.470	26.340	20.670	5.670					Qh-lu
			C-14	26.640	23.810	52.550	24.680	17.050	7.630					Qh-lu
			C-15	45.920	18.120	35.960	20.580	15.740	4.840	2.120	8.340	27.974		Qh-lu
			C-16	74.450	14.850	10.700	25.940	19.870	6.070					Qh-lu
			C-17	49.640	38.360	12.000	23.590	19.050	4.540					Qh-lu
			C-18	58.690	21.350	17.960	23.280	18.290	4.990	2.090	8.290	26.590		Qh-lu
			C-19	45.750	31.950	22.300	19.670	15.120	4.550					Qh-lu
			C-20	52.090	20.360	27.550	22.190	16.180	6.010					Qh-lu
54	MEJORAMIENTO DEL JR. VICTOR REYES ROCA DE LA LOCALIDAD DE NARANILLO, DISTRITO DE LUYANDO - LEONCIO PRADO	Inicio: 75°59'27.13"W, 9°14'33.52"S, 632 msnm; Fin: 75°59'30.59"W, 9°15'07.64"S, 6344 msnm	C-1	64.740	27.450	7.810	22.570	19.200	3.370				Qh-al	
			C-2	17.550	57.540	4.910	NP	NP	NP					Qh-al
			C-3	1.480	11.670	86.850	31.450	18.790	12.660					Qh-al
			C-4	63.200	27.830	8.970	23.210	19.100	4.110					Qh-al
			C-5	57.650	38.910	3.440	NP	NP	NP					Qh-al
			C-6	12.730	21.490	65.780	26.570	18.870	7.700					Qh-al
			C-7	61.390	30.500	8.150	23.760	19.750	4.010					Qh-al
			C-8	54.430	39.250	6.320	23.470	19.630	3.840					Qh-al
			C-9	57.050	0.000	4.790	NP	NP	NP	2.009	9.310	15.460		Qh-al
			C-10	0.050	9.890	90.100	26.850	18.810	8.040					Qh-al
			C-11	68.140	22.660	9.200	23.350	19.450	3.900					Qh-al
			C-12	66.410	29.600	3.990	NP	NP	NP					Qh-al
			C-13	64.580	24.860	10.560	23.200	18.440	4.760	2.223	5.840	9.023		Qh-al
			C-14	0.000	2.830	97.170	28.400	18.410	9.990					Qh-al
			C-15	51.780	23.890	24.330	21.830	18.810	3.020					Qh-al
			C-16	32.160	62.630	5.210	21.870	19.990	1.880					Qh-al
			C-17	52.520	43.260	4.220	NP	NP	NP					Qh-al
			C-18	59.490	32.720	7.790	22.540	19.530	2.810	2.229	5.170	8.543		Qh-al
55	MEJORAMIENTO DEL CAVINO VECINAL NIÑO CHICA - JOSE CARRERA - GUAYMA - DISTRITO DE	Inicio: 76°04'19.00"S, 3406 msnm; Fin: 76°50'33.06"W, 330084.69E, 4453 msnm	C-1	44.000	26.170	29.810	28.170	20.200	7.970	2.113	8.090	30.980	Ki-g	
			C-2	49.170	19.210	31.610	19.320	14.090	5.230	2.109	8.230	29.750		Ki-l
			C-3	72.450	13.540	14.010	24.190	17.890	6.300	2.189	7.160	41.060		Ki-l
56	MEJORAMIENTO DE VIAS CON PAVIMENTO, VEREDAS Y MUROS DE CONTENCIÓN EN EL JR. PROGRESO-SAN RAFAEL, PROVINCIA DE AMBO	Inicio: 76°44'03.61"W, 10°04'19.00"S, 3406 msnm; Fin: 76°50'33.06"W, 330084.69E, 4453 msnm	C-1	1.840	28.060	70.100	30.020	26.030	3.990				Ci-a	
			C-2	58.850	22.880	18.270	32.190	26.140	6.050	2.060	8.680	19.400		Ci-a
			C-3	35.670	25.380	38.950	27.490	24.990	2.500					Ci-a
			C-4	68.880	23.100	8.020	41.670	41.280	0.390	2.112	8.054	28.650		Fe-cme
57	CONSTRUCCION Y MEJORAMIENTO DE PISTAS Y VEREDAS EN LA URBANIZACION	Inicio: 76°11'03.23"W, 10°20'21.43"S, 2703 msnm; Fin: 76°10'58.03"W, 10°20'21.43"S, 2703 msnm	C-5	76.010	16.530	7.460	21.820	19.860	1.960				Fe-cme	
			C-1	48.850	42.280	8.870	23.690	21.540	2.150	2.223	4.780	42.100		Qh-al
			C-2	60.590	19.700	19.710	25.520	18.570	6.950	2.149	8.080	41.020		KP-to,gd
			C-3	63.190	17.660	19.150	24.820	18.170	6.650	2.138	7.970	42.910		KP-to,gd
58	REHABILITACION DEL CAVINO VECINAL EMP. 3N (PUENTE MIRAFLORES) - UCHIPAS - EMP. HU - GSE CAYMAN	Inicio: 76°20'29.69"W, 9°55'28.45"S, 2057 msnm; Fin: 76°20'19.71"W, 9°56'05.24"S, 2063 msnm	C-4	57.680	24.070	18.250	23.560	17.430	6.130	2.158	7.910	43.590	KP-to,gd	
			C-1	67.980	12.090	19.930	24.870	19.180	5.690	2.134	6.930	40.320		KP-to,gd
			C-2	60.730	19.370	19.920	26.610	19.640	6.970	2.146	7.840	41.260		KP-to,gd
			C-3	72.110	8.960	18.930	26.520	19.550	6.970	2.171	8.130	42.820		KP-to,gd
59	REHABILITACION DEL CAVINO VECINAL TRAMO: EMP. 3N (PUENTE MIRAFLORES) - EMP. HU - GSE CAYMAN	Inicio: 76°19'02.30"W, 9°54'03.28"S, 2747 msnm; Fin: 76°18'02.30"W, 9°54'03.28"S, 2747 msnm	C-4	67.980	12.090	19.930	24.870	19.180	5.690	2.134	6.930	40.320	KP-to,gd	
			C-1	60.730	19.370	19.920	26.610	19.640	6.970	2.146	7.840	41.260		KP-to,gd
			C-2	72.110	8.960	18.930	26.520	19.550	6.970	2.171	8.130	42.820		KP-to,gd
			C-3	66.570	13.510	19.920	25.890	19.910	6.980	2.119	8.420	40.180		KP-to,gd
60	REHABILITACION DEL CAVINO VECINAL TRAMO: EMP. 3N (PUENTE MIRAFLORES) - EMP. HU - GSE CAYMAN	Inicio: 76°19'02.30"W, 9°54'03.28"S, 2747 msnm; Fin: 76°18'02.30"W, 9°54'03.28"S, 2747 msnm	C-4	73.400	8.110	18.490	26.040	19.080	6.960	2.131	7.880	18.170	KP-to,gd	
			C-1	60.730	19.370	19.920	26.610	19.640	6.970	2.146	7.840	41.260		KP-to,gd
			C-2	72.110	8.960	18.930	26.520	19.550	6.970	2.171	8.130	42.820		KP-to,gd
			C-3	66.570	13.510	19.920	25.890	19.910	6.980	2.119	8.420	40.180		KP-to,gd



	333 (PUNTE PULLAG) DESVIO HUAMPON - SUWANAN, DEL DISTRITO DE SAN FRANCISCO	9°58'52.41"S, 3607 msnm	C-5	68.730	11.700	19.570	27.580	20.930	6.650	2.089	7.830	35.440	KP-ta.gd
			C-6	67.410	15.590	17.000	25.900	20.190	5.710	2.151	6.940	42.810	KP-ta.gd
			C-7	45.410	34.920	19.670	26.760	19.980	6.780	2.097	8.180	42.050	KP-ta.gd
60	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD URBANA EN EL SECTOR DEL CENTRO POBLADO DE COCHACALLA, DISTRITO DE SAN RAFAEL, PROVINCIA AMBO	Inicio: 76°12'27.11"W, 10°21'39.69"S, 3199 msnm; Fin: 76°12'39.70"W, 10°21'30.23"S, 3236 msnm	C-1	34.600	34.200	31.200	26.540	18.920	7.620	2.107	9.030	21.840	Cia
			C-2	47.410	32.230	20.360	26.550	19.210	7.340	2.119	9.210	24.580	Cia
			C-3	43.690	31.500	24.850	26.320	18.650	7.670	2.171	8.930	36.820	Cia
			C-4	37.650	28.830	31.520	33.240	18.400	14.840	2.112	9.090	22.660	Cia
			C-5	47.290	27.110	25.440	25.900	17.910	7.990	2.085	8.720	19.690	Cia
			C-6	73.120	17.180	9.500	27.350	22.140	5.210	1.999	9.970	12.020	Cia
			C-7	36.100	32.250	31.650	26.900	17.860	9.040	1.983	10.010	20.580	Cia
			C-8	47.590	32.060	20.350	27.010	19.340	7.670	2.073	9.230	15.310	Cia
			C-9	43.280	32.600	24.120	26.240	19.510	6.730	2.061	8.870	14.740	Cia
			C-10	36.560	29.700	31.740	11.650	19.800	11.850	2.119	8.720	27.810	Cia
			C-11	47.360	25.790	26.850	25.680	18.610	7.010	2.158	8.430	40.180	Cia
			C-12	71.240	19.550	9.210	26.750	21.280	5.470	2.169	6.520	39.210	Cia
			C-13	44.650	29.710	25.440	26.580	17.910	8.610	2.229	7.840	39.650	Cia
61	MEJORAMIENTO A NIVEL DE ARRANQUE DE LA CARRETERA GUALLAYCANCHI A DESVIO A RONDOS, PROVINCIA DE DOS DE MAYO	Inicio: 76°48'07.79"W, 9°51'59.30"S, 3600 msnm; Fin: 76°46'56.02"W, 9°54'09.63"S, 3660 msnm	C-1	1.650	0.700	97.650	14.520	26.510	8.010	2.142	6.110	36.020	Qh-al
			C-2	31.240	40.110	28.650	48.750	29.650	19.100	2.001	8.040	19.180	Qh-al
			C-3	0.520	42.960	56.520	NP	NP	NP	2.153	6.070	31.520	Qh-al
			C-4	0.250	4.100	95.650	15.620	25.460	10.160	2.181	4.840	40.290	Qh-al
			C-5	1.650	88.140	10.010	11.920	23.650	8.270	2.209	4.710	42.080	Qh-al
			C-6	1.540	13.810	84.650	44.650	32.840	11.810	2.184	5.050	41.940	Qh-al
			C-7	0.000	9.690	90.150	27.510	22.920	4.610	2.189	4.890	42.160	Qh-al
			C-8	21.350	44.150	34.500	NP	NP	NP	2.158	6.420	37.040	Qh-al
			C-9	0.600	5.930	93.470	38.630	27.650	10.980	2.166	4.910	35.770	Qh-al
			C-10	3.500	27.890	68.610	28.410	21.450	6.960	2.217	4.760	38.200	Qh-al
62	MEJORAMIENTO CARRETERA CHAGLLA A VERDE POZO, DISTRITO DE CHAGLLA - PACHITEA	Inicio: 75°54'07.05"W, 9°50'34.78"S, 3037 msnm; Fin: 75°55'10.81"W, 9°48'25.63"S, 2951 msnm	C-1	72.420	19.200	8.380	27.070	21.210	5.860				Ps-gr
			C-2	52.190	31.980	15.810	25.550	19.500	6.050				Ps-gr
			C-3	12.960	22.680	64.360	30.120	20.250	9.870				Ps-gr
			C-4	20.970	42.200	36.830	26.900	20.800	6.100	1.182	10.620	7.654	Ps-gr
			C-5	48.400	27.580	24.020	26.620	22.960	3.660				Ps-gr
			C-6	11.680	45.630	42.690	14.160	20.260	13.900				Ps-gr
			C-7	44.690	29.090	26.260	11.790	21.040	10.750				Ps-gr
			C-8	14.560	27.800	57.640	38.910	19.470	19.460				Ps-gr
			C-9	60.090	31.250	8.700	25.350	22.470	2.880	2.985	11.060	19.370	Ps-gr
			C-10	11.500	45.450	43.050	32.440	19.900	12.540				Ps-gr
			C-11	59.420	26.580	14.000	26.970	20.080	6.890				Ps-gr
			C-12	10.310	32.840	57.050	36.260	19.900	16.360				Ps-gr
			C-13	58.010	14.420	27.570	24.950	22.790	2.160	3.213	12.340	20.184	Ps-gr
			C-14	7.180	29.450	63.370	33.930	20.520	13.430				Ps-gr
			C-15	18.110	23.930	57.960	35.940	20.720	15.220				Ps-gr
			C-16	1.410	13.510	85.080	17.600	19.770	17.830	2.940	10.760	18.950	Ps-m
			C-17	0.720	17.240	82.040	17.610	20.480	17.130				Ps-m
			C-18	6.380	26.500	67.120	14.610	20.200	14.410				Ps-m
63	MEJORAMIENTO DE LA CARRETERA COUPAS - JAUISH - COQUIN - YAVOR - UCHUMARCA - DISTRITO DE COUPAS - PROVINCIA DE AYACUCHO	Inicio: 76°24'46.74"W, 10°16'11.65"S, 2704 msnm; Intermedio: 76°26'00.76"W, 10°15'02.02"S, 3308 msnm; Fin: 76°26'30.05"W, 10°16'41.25"S, 3498 msnm	C-19	0.940	21.950	77.110	15.530	22.900	12.630				Ps-m
			C-20	0.600	13.040	86.360	16.430	18.840	17.590	2.030	8.340	22.640	Ps-m
			C-21	15.510	40.000	44.460	27.100	19.790	7.310				Ps-m
			C-22	3.100	18.310	78.590	17.030	18.770	18.260				Ps-m
			C-23	0.860	12.610	86.530	14.040	19.560	14.480				Ps-m
			C-24	8.910	29.430	61.660	32.650	18.980	13.670	1.997	8.510	23.450	Ps-m
			C-25	7.150	41.520	51.310	13.480	19.810	13.670				Ps-m
			C-26	0.000	20.520	79.480	10.380	20.200	10.180				Ps-m
			C-27	64.240	20.920	14.840	25.800	21.390	4.410	2.101	8.120	22.450	Ps-m
			C-28	5.510	20.920	73.570	16.850	19.440	17.410				Ps-m
			C-29	46.170	22.170	31.660	26.910	20.590	6.320				Ps-m
			C-30	74.010	9.970	16.010	25.960	20.310	5.610				Ps-m
64	MEJORAMIENTO DE LA CARRETERA COUPAS - JAUISH - COQUIN - YAVOR - UCHUMARCA - DISTRITO DE COUPAS - PROVINCIA DE AYACUCHO	Inicio: 76°24'46.74"W, 10°16'11.65"S, 2704 msnm; Intermedio: 76°26'00.76"W, 10°15'02.02"S, 3308 msnm; Fin: 76°26'30.05"W, 10°16'41.25"S, 3498 msnm	C-1	41.320	27.030	31.650	28.100	19.870	8.210	2.262	5.920	35.350	Cia
			C-2	28.740	49.790	21.470	23.650	20.120	3.510	2.264	5.890	32.640	Cia
			C-3	30.520	49.320	20.360	22.450	18.650	3.800	2.183	7.990	41.630	Cia
			C-4	41.690	25.790	32.560	27.630	21.100	6.510	2.126	8.260	40.090	Cia
			C-5	29.140	48.390	22.470	23.690	20.320	3.370	1.996	9.040	38.430	Cia
			C-6	30.120	49.210	20.650	23.540	19.540	4.000	2.008	9.210	39.810	Cia
			C-7	41.080	26.440	31.580	28.010	19.800	8.210	2.077	8.910	37.840	Cia
			C-8	29.890	48.010	22.140	23.960	20.320	3.640	1.908	10.880	29.080	Cia
			C-9	30.470	48.880	20.650	22.650	19.450	3.200	2.084	7.970	29.940	Cia
			C-10	41.690	32.880	25.470	27.630	20.350	7.280	2.116	7.210	30.040	Cia
			C-11	29.560	48.460	21.980	24.630	21.400	3.210	2.149	7.014	30.040	Cia
			C-12	31.250	48.190	20.360	23.870	18.960	4.910	2.149	7.014	32.170	Cia
			C-13	30.470	48.320	21.210	23.540	19.140	4.400	1.914	9.220	18.110	Cia
			C-14	41.520	52.110	6.390	NP	NP	NP	2.097	7.890	31.230	Pe-cme
			C-15	100.000	0.000	0.000	NP	NP	NP	2.091	8.010	28.960	Pe-cme
			C-16	0.500	86.960	12.540	NP	NP	NP	2.009	8.380	24.180	Pe-cme
			C-17	85.690	11.700	2.690	NP	NP	NP	1.931	8.280	18.840	Pe-cme
			C-18	66.540	27.990	5.470	NP	NP	NP	2.183	6.910	13.610	Pe-cme
			C-19	0.510	80.840	18.650	NP	NP	NP	1.861	10.460	9.360	Pe-cme
			C-20	40.360	53.120	6.520	NP	NP	NP	2.104	8.080	29.760	Pe-cme
			C-21	99.630	0.170	0.200	NP	NP	NP	2.145	7.222	32.140	Pe-cme
			C-22	0.000	87.550	12.450	NP	NP	NP	1.929	9.014	18.460	Pe-cme
			C-23	85.360	12.800	1.840	NP	NP	NP	1.907	8.960	17.410	Pe-cme
			C-24	65.470	29.780	4.790	NP	NP	NP	1.898	9.479	16.020	Pe-cme
			C-25	0.680	81.220	18.100	NP	NP	NP	1.919	9.112	15.890	Pe-cme
65			C-1	62.520	24.810	12.870	19.600	18.450	11.150	1.856	8.960	14.960	KP-ta.gd
			C-2	61.870	24.590	13.540	12.450	20.320	12.130	1.912	10.090	10.040	KP-ta.gd
			C-3	63.540	22.210	14.250	13.670	21.450	12.220	1.845	11.930	8.170	KP-ta.gd
			C-4	64.100	22.140	17.760	19.600	19.540	10.060	1.964	9.070	11.890	KP-ta.gd
			C-5	62.470	23.580	13.950	12.450	22.140	10.310	2.098	8.910	18.440	KP-ta.gd
			C-6	64.520	21.580	14.100	13.670	23.140	10.530	1.913	10.230	9.080	KP-ta.gd
			C-7	62.350	24.110	13.540	19.600	20.320	9.280	2.089	9.190	17.040	KP-ta.gd
			C-8	61.580	24.570	13.850	12.450	21.470	10.980	1.885	10.770	8.750	KP-ta.gd
			C-9	63.580	22.880	13.540	13.670	23.540	10.130	2.116	2.291	28.010	KP-ta.gd



64	MEJORAMIENTO A NIVEL DE AFIRMADO DE HUANCAYACU A HUAYKAMBAMBA, DISTRITO DE SAN FRANCISCO DE CAYRA - HUANCAYACU	Inicio: 75°54'07.05"W, 9°50'34.78"S, 3097 msnm; Fin: 75°55'10.81"W, 9°48'25.63"S, 2951 msnm	C-10	63.140	23.740	13.120	29.600	20.140	9.460	1.873	10.540	8.710	KF-ta, gd			
			C-11	62.870	23.450	13.680	32.450	21.780	10.670	1.857	11.880	9.960	KF-ta, gd			
			C-12	63.580	22.150	14.270	33.670	23.680	9.990	1.839	11.930	6.470	KF-ta, gd			
			C-13	62.470	23.990	13.540	29.600	20.650	8.950	1.879	10.940	7.860	KF-ta, gd			
			C-14	62.650	23.790	13.560	32.450	20.320	12.130	1.880	10.690	7.950	KF-ta, gd			
			C-15	63.580	22.950	13.470	33.670	23.470	10.200	1.893	10.490	7.990	KF-ta, gd			
			C-16	62.470	24.320	13.210	29.600	20.140	9.460	1.974	9.070	11.580	KF-ta, gd			
			C-17	63.240	23.500	13.660	32.450	21.780	10.670	2.177	8.360	24.170	KF-ta, gd			
			C-18	62.850	23.120	14.030	33.670	23.140	10.530	2.085	8.970	19.480	KF-ta, gd			
			C-19	62.550	24.010	13.440	29.600	20.470	9.130	1.904	10.610	6.790	KF-ta, gd			
			C-20	61.220	25.540	13.240	32.450	20.690	11.760	1.997	9.410	14.930	KF-ta, gd			
			C-21	63.470	22.970	13.560	33.670	23.140	10.530	1.894	11.030	8.040	KF-ta, gd			
			C-22	63.110	23.420	13.470	29.600	20.380	9.220	2.194	8.270	31.290	KF-ta, gd			
			C-23	62.580	23.220	14.200	32.450	23.140	9.310	2.113	9.190	21.040	KF-ta, gd			
			C-24	63.540	22.780	13.680	33.670	20.650	13.020	1.926	10.860	8.290	KF-ta, gd			
			C-25	62.940	23.780	13.880	29.600	22.870	6.730	1.883	11.120	7.170	KF-ta, gd			
			C-26	62.740	23.550	13.710	32.450	20.250	12.200	2.233	8.520	11.240	KF-ta, gd			
			C-27	64.120	21.770	14.110	33.670	23.230	10.440	2.134	9.880	18.120	KF-ta, gd			
			C-28	63.220	22.930	13.850	29.600	20.140	9.460	2.207	8.090	34.120	KF-ta, gd			
			C-29	61.450	24.980	13.570	32.450	22.490	9.960	2.091	9.370	16.720	KF-ta, gd			
			C-30	63.750	21.980	14.270	33.670	23.470	10.200	2.108	9.170	17.950	KF-ta, gd			
			C-31	63.540	22.610	13.850	29.600	23.650	5.950	1.914	10.930	8.060	KF-ta, gd			
			C-32	62.140	24.210	13.650	32.450	22.350	10.100	2.078	9.310	15.980	KF-ta, gd			
			C-33	63.470	22.640	13.890	33.670	21.470	12.200	2.152	8.810	18.180	KF-ta, gd			
			C-34	62.580	24.210	13.210	29.600	20.960	8.640	2.179	8.160	19.740	KF-ta, gd			
			C-35	61.850	23.940	14.210	32.450	21.640	10.810	1.905	10.270	8.660	KF-ta, gd			
			C-36	63.540	21.870	14.590	33.670	27.080	6.590	2.184	8.290	21.890	KF-ta, gd			
			65	MEJORAMIENTO DEL CRUCE VECINAL DE CHASQUI - BOCA MANA, MUNICIPIO DE	Inicio: 76°14'34.34"W, 9°52'14.27"S, 3797 msnm; Fin: 76°10'13.82"W, 9°55'18.77"S, 3894 msnm	C-1	33.650	17.050	49.320	27.600	18.700	8.950	2.186	8.820	34.100	Tr-J-gu
						C-2	52.450	19.150	28.400	29.100	22.460	6.700	2.049	8.920	39.200	Tr-J-gu
			66	LA URBANIZACIÓN LOS EUCALIPTOS - LUCMA, DISTRITO DE AMARILLO	Inicio: 76°13'41.00"W, 9°55'18.77"S, 3894 msnm; Fin: 76°13'41.00"W, 9°54'11.78"S, 3656 msnm	C-1	40.120	29.780	30.120	28.650	19.640	9.010	2.001	7.120	23.120	Dr-al
						C-2	31.850	40.500	27.650	27.650	18.540	9.110	2.094	7.840	25.650	Dr-al
			67	MEJORAMIENTO DE LA CARRETERA CHUMIPATA A SHUPPA, DISTRITO DE LA UNIÓN, PROVINCIA DE DOS DE MAYO	Inicio: 76°47'23.05"W, 9°50'03.08"S, 3553 msnm; Fin: 76°44'57.17"W, 9°54'41.78"S, 3656 msnm	C-3	36.140	43.320	23.540	27.030	20.350	6.660	2.073	8.030	22.350	Dr-al
						C-1	18.450	73.300	8.250	29.300	14.120	15.180	2.208	4.180	18.920	Qp-lu
						C-2	17.650	73.240	9.110	29.300	13.980	15.320	2.213	4.110	19.600	Qp-lu
						C-3	15.650	75.330	9.020	29.300	13.450	15.850	2.420	6.420	41.030	Qp-lu
						C-4	18.350	73.300	8.350	29.300	13.740	15.560	2.086	8.030	19.180	Qp-lu
C-5	17.540	73.320				9.140	29.300	12.690	16.610	2.009	8.720	26.570	Qp-lu			
C-6	16.360	74.900				8.740	29.300	12.650	16.650	1.989	8.980	19.020	Qp-lu			
C-7	18.470	72.980				8.550	29.300	13.550	15.750	1.982	9.860	11.020	Qp-lu			
C-8	17.580	73.790				8.630	29.300	14.030	15.270	2.064	7.940	27.940	Qp-lu			
C-9	18.540	72.250				9.210	29.300	13.470	15.830	2.127	7.080	31.090	Qp-lu			
C-10	17.650	73.180				9.170	29.300	13.680	15.620	2.166	4.780	30.110	Qp-lu			
C-11	16.350	74.750				8.900	29.300	14.330	14.970	2.009	8.690	22.180	Qp-lu			
C-12	15.690	76.330				7.980	29.300	13.650	15.650	2.203	6.740	34.400	Qp-lu			
C-13	18.650	72.860				8.490	29.300	14.020	15.280	2.209	6.870	33.080	Qp-lu			
C-14	17.560	73.430				9.010	29.300	13.660	15.640	2.008	8.840	19.970	Qp-lu			
C-15	19.100	72.130				8.770	29.300	13.470	15.830	2.212	6.940	35.430	Qp-lu			
C-16	18.630	72.720				8.650	29.300	14.590	14.710	2.217	6.970	36.030	Qp-lu			
C-17	17.470	73.470				9.060	29.300	13.650	15.650	1.966	4.560	8.950	Qp-lu			
C-18	18.880	72.660				8.460	29.300	15.010	14.290	1.908	9.750	8.420	Qp-lu			
C-19	16.570	74.110				9.120	29.300	14.680	14.620	1.876	9.830	8.220	Qp-lu			
C-20	17.330	74.000				8.670	29.300	13.840	15.460	1.957	7.940	8.870	Qp-lu			
C-21	18.370	72.310				9.520	29.300	14.350	14.950	1.882	9.980	7.920	Qp-lu			
C-22	17.380	73.340				9.280	29.300	13.880	15.420	2.094	7.910	27.580	Qp-lu			
C-23	18.240	73.270				8.490	29.300	14.670	14.630	1.819	10.530	6.260	Qp-lu			
C-24	17.690	73.540				8.770	29.300	13.790	15.510	2.209	7.090	18.650	Qp-lu			
68	MEJORAMIENTO CAMINO VECINAL PAMPACARICHA A AQUI IN PUQUIO, DISTRITO DE BAÑOS, PROVINCIA DE LAURICOCHA	Inicio: 76°44'36.97"W, 10°04'34.13"S, 3804 msnm; Fin: 76°44'11.64"W, 10°05'20.04"S, 3588 msnm	C-1	59.420	24.330	13.650	26.350	19.450	6.900	2.065	8.050	28.430	Ks-j			
			C-2	58.620	28.130	13.250	25.470	20.320	5.150	2.003	8.650	25.390	Ks-j			
			C-3	54.360	30.990	14.650	25.320	21.140	4.180	1.976	8.890	19.050	Ks-j			
			C-4	57.650	28.390	13.960	25.460	20.350	5.110	1.896	9.630	11.340	Ks-j			
			C-5	58.440	27.690	13.870	26.030	19.650	6.360	2.212	7.130	26.840	Ks-j			
69	MEJORAMIENTO DEL CRUCE VECINAL OBRAS A TUNAHUAYAN, DISTRITO DE OBRAS, PROVINCIA DE YACUYALCA	Inicio: 76°48'18.67"W, 9°45'20.02"S, 3697 msnm; Fin: 76°38'56.07"W, 9°44'18.45"S, 3657 msnm	C-1	53.950	17.930	48.320	35.620	17.450	18.170	2.167	8.030	15.450	Pe-cm2			
			C-2	32.540	30.220	37.240	32.140	18.020	14.130	2.014	8.120	12.320	Pe-cm2			
			C-3	30.240	34.540	35.220	30.250	17.690	12.560	2.220	8.340	11.030	Pe-cm2			
70	MEJORAMIENTO DE TRANSITABILIDAD URBANA EN EL AA. III. LUZMILA TEMPLO, DISTRITO DE AMARILLO	Inicio: 76°13'42.40"W, 9°55'13.77"S, 3891 msnm; Fin: 76°13'34.77"W, 9°54'57.68"S, 3889 msnm	C-1	53.210	19.580	27.210	20.600	18.470	2.130	2.181	7.980	24.160	Dr-al			
			C-2	54.120	20.470	25.410	22.450	19.120	3.330	2.194	7.160	29.390	Dr-al			
			C-3	8.560	38.210	53.230	23.980	18.870	5.110	2.186	7.740	26.810	Dr-al			
			C-4	47.250	32.430	20.320	19.800	15.210	4.590	1.984	10.080	9.960	Dr-al			
			C-5	71.240	23.160	5.400	NP	NP	NP	2.169	7.760	25.820	Dr-al			
			C-6	53.210	20.250	26.540	22.430	17.890	4.520	2.141	8.010	21.430	Dr-al			
			C-7	57.650	17.810	24.540	21.470	18.140	3.330	2.153	7.610	24.660	Dr-al			
			C-8	7.690	37.190	55.120	23.650	19.320	4.330	2.194	6.940	39.180	Dr-al			
			C-9	45.630	34.050	20.320	19.430	15.770	3.640	2.159	7.380	24.650	Dr-al			
			C-10	70.120	23.680	6.200	NP	NP	NP	2.014	9.110	12.830	Dr-al			
			C-11	47.860	31.000	21.340	18.650	16.140	2.510	2.086	8.930	16.240	Dr-al			
			C-12	48.650	30.570	20.780	19.140	15.660	3.480	2.162	7.080	31.440	Dr-al			
			C-13	49.210	29.680	21.110	18.740	16.870	1.870	2.209	5.040	38.430	Dr-al			
71	MEJORAMIENTO DEL CRUCE CARRETERA HUANCASH A JIRCAN, DISTRITO DE JIRCAN - JIRCANALTO	Inicio: 76°14'34.34"W, 9°13'05.15"S, 3354 msnm; Fin: 76°13'10.27"W, 9°14'43.78"S, 3195 msnm	C-1	5.650	18.700	75.650	35.640	18.520	17.120	2.120	8.650	11.430	Pe-cm			
			C-2	6.250	26.130	67.420	30.250	17.120	13.130	1.970	8.340	9.560	Pe-cm			
			C-3	4.980	28.770	66.250	31.570	16.860	14.710	2.018	9.140	14.020	Pe-cm			
72	MEJORAMIENTO DEL CAMINO VECINAL PARCOY A MASQUIM, DISTRITO DE COYAS, PROVINCIA DE AMBO	Inicio: 76°43'12.59"W, 9°13'05.15"S, 3354 msnm; Fin: 76°43'10.27"W, 9°14'43.78"S, 3195 msnm	C-1	20.920	29.030	50.050	75.620	38.290	37.330	2.213	8.421	20.940	Ps-m			
			C-2	64.710	25.900	9.390	56.760	39.940	16.820				Ps-m			
			C-3	38.820	31.410	29.770	67.190	23.560	43.630	1.887	3.870	20.500	Ep-di			
			C-4	72.130	21.640	6.230	58.900	45.420	13.480				Ep-di			
			C-1	41.750	52.460	5.850	NP	NP	NP				Pe-cme			
			C-2	100.000	0.000	0.000	NP	NP	NP				Pe-cme			
			C-3	0.000	88.850	11.150	NP	NP	NP	2.050	8.290	21.223		Pe-cme		
			C-4	86.390	12.090	1.520	NP	NP	NP					Pe-cme		
			C-5	67.820	27.780	4.420	NP	NP	NP					Pe-cme		
			C-7	0.780	82.250	17.480	NP	NP	NP					Pe-cme		



73	MEJORAMIENTO DEL CAMINO VECINAL DE YAPAC A YANACOCCHA, DISTRITO DE COLPAS, PROVINCIA DE AMBO	Inicio: 76°25'03.40"W, 10°18'27.62"S, 3351 metros; Fin: 76°29'44.12"W, 10°17'43.03"S, 4353 metros	C-8	0.000	82.050	17.950	NP	NP	NP				Pe-cme
			C-9	0.240	96.330	3.430	NP	NP	NP				Pe-cme
			C-10	0.000	95.570	4.430	NP	NP	NP	2.221	8.525	26.885	Pe-cme
			C-11	43.340	53.430	1.250	NP	NP	NP				Pe-cme
			C-12	56.000	40.980	3.030	NP	NP	NP				Pe-cme
			C-13	67.830	27.780	4.400	NP	NP	NP	2.154	8.310	26.123	Pe-cme
			C-14	58.890	38.670	2.440	NP	NP	NP				Pe-cme
			C-15	26.400	67.240	6.360	NP	NP	NP				Pe-cme
			C-16	99.470	0.180	0.350	NP	NP	NP	2.057	8.223	25.810	Pe-cme
			C-17	75.340	27.050	2.760	NP	NP	NP				Pe-cme
74	MEJORAMIENTO DEL CAMINO VECINAL OROQUENO A SHIBIPATA, DISTRITO DE SAN MIGUEL DE CAURI, PROVINCIA DE LA URBICOCCHA	Inicio: 76°16'11.34"W, 10°18'06.39"S, 3720 metros; Fin: 76°36'41.26"W, 10°14'28.46"S, 4318 metros	C-1	4.530	17.160	78.130	36.840	18.930	17.890	2.001	9.510	12.390	PE-cm2
			C-2	4.870	27.590	67.540	51.240	17.650	13.590	1.987	8.970	11.540	PE-cm2
			C-3	37.590	39.930	22.480	32.660	20.090	12.570	2.189	8.940	26.800	K-g
			C-4	49.630	39.180	11.190	26.390	19.230	7.160	2.104	7.960	11.140	K-ch/pt
75	PAVIMENTACIÓN DE LA CALLE BRANCAHO DEL C.P. DE LUCIA BAJA, DISTRITO DE AMARILLO	Inicio: 76°13'56.86"W, 9°55'43.90"S, 3911 metros; Fin: 76°13'50.10"W, 9°55'40.70"S, 3936 metros	C-1	41.440	27.410	31.150	29.120	20.270	8.850	2.111	8.740	19.190	Q-al
			C-2	32.510	39.420	28.070	28.440	20.480	7.960	2.093	8.850	20.490	Q-al
			C-3	37.520	40.050	22.430	27.330	20.530	6.780	2.135	8.090	19.210	Q-al
			C-4	34.360	33.010	32.630	30.030	20.050	9.980	2.129	8.910	18.740	Q-al
76	MEJORAMIENTO DEL CAMINO VECINAL 8 DE DICIEMBRE A SHALAYCORRAL, DISTRITO DE SAN MIGUEL DE CAURI, PROVINCIA DE LA URBICOCCHA	Inicio: 76°18'24.80"W, 10°20'05.18"S, 3695 metros; Fin: 76°36'35.17"W, 10°21'27.44"S, 4383 metros	C-1	9.740	21.160	68.900	28.540	20.200	8.340	1.879	11.540	20.510	Es-ce
			C-2	45.420	18.590	35.950	26.440	20.100	6.340	1.946	12.800	21.040	Es-ce
			C-3	21.190	26.670	52.340	30.900	19.810	11.090	2.003	10.290	18.680	Es-ce
			C-4	35.080	14.930	9.990	24.970	20.790	4.180	2.186	7.240	16.540	Es-ce
77	MEJORAMIENTO DEL CAMINO VECINAL BELLAVIDA - YAMUNA, DISTRITO DE RACHAS - DOS DE MAYO	Inicio: 76°44'34.92"W, 9°40'21.40"S, 3474 metros; Fin: 76°44'48.57"W, 9°41'00.91"S, 3491 metros	C-1	34.040	16.180	49.580	36.450	18.420	18.030	1.996	6.540	11.100	Pe-cm2
			C-2	33.230	28.010	38.760	33.450	18.420	15.030	1.879	7.010	14.210	Pe-cm2
			C-3	31.490	33.090	35.460	31.240	18.420	12.820	2.034	6.980	13.450	Pe-cm2
			C-4	52.700	17.410	29.890	33.100	20.250	12.890	2.152	7.230	15.600	Pe-cm2
78	CONSTRUCCIÓN DE PISTAS Y VEREDAS JR. MAYRO JR. SANTA ELENA JR. CONCEPCION Y CALLE PRINCIPAL DEL CENTRO POBLADO DE LUCIA DISTRITO DE AMARILLO - HUÁNUCO	Inicio: 76°13'56.84"W, 9°55'43.90"S, 3912 metros; Fin: 76°13'51.77"W, 9°55'40.70"S, 3936 metros	C-1	44.790	39.760	15.490	24.680	20.910	3.770	2.158	7.460	16.540	Q-al
			C-2	46.800	38.210	14.990	24.920	20.970	3.950	2.089	8.160	19.560	Q-al
			C-3	44.100	42.060	13.840	24.330	21.260	3.070	2.046	8.070	12.450	Q-al
			C-4	44.710	26.670	28.620	25.100	22.450	2.650	2.202	7.870	18.140	Q-al
			C-5	41.660	42.180	16.160	25.680	21.090	4.590	2.009	8.620	12.450	Q-al
79	MEJORAMIENTO DEL CAMINO VECINAL MOSCA A RODIO, DISTRITO DE SAN FRANCISCO DE MOSCA, PROVINCIA DE AMBO	Inicio: 76°17'17.91"W, 10°20'46.38"S, 3577 metros; Fin: 76°15'45.78"W, 10°21'31.54"S, 4000 metros	C-1	42.360	25.190	32.450	28.050	20.720	7.340	2.098	8.740	24.080	C-a
			C-2	29.780	47.350	22.870	24.630	20.480	4.150	1.986	7.890	21.340	C-a
			C-3	31.240	47.420	21.340	23.450	19.670	3.780	1.930	6.780	19.450	C-a
			C-4	32.940	44.270	22.790	23.670	18.650	5.020	1.876	6.540	11.230	Ps-m
			C-5	28.380	32.660	38.960	29.850	21.940	7.870	1.898	8.010	16.840	Ps-m
80	MEJORAMIENTO INTEGRAL DEL JIRÓN LOS RIOS, DEL DISTRITO DE PILCO MARCA, PROVINCIA DE HUÁNUCO	Inicio: 76°14'47.99"W, 9°57'33.33"S, 3932 metros; Fin: 76°14'31.55"W, 9°57'23.63"S, 3936 metros	C-1	2.340	29.770	67.890	34.780	19.210	5.570	2.040	11.540	11.540	Q-al
			C-2	5.670	29.010	65.320	23.120	19.210	3.910	1.879	9.450	8.650	Q-al
			C-3	1.230	28.650	70.120	24.650	19.210	5.440	1.976	10.120	9.450	Q-al
			C-4	0.540	26.750	72.710	28.450	19.210	9.240	1.994	9.080	10.430	Q-al
81	CONSTRUCCIÓN DE PISTAS Y VEREDAS DEL DISTRITO DE CONCHAMARCA-AMBO - HUÁNUCO	Inicio: 76°12'59.17"W, 10°02'18.09"S, 2139 metros; Fin: 76°12'53.28"W, 10°02'02.43"S, 2145 metros	C-1	50.540	31.810	17.650	24.650	19.800	4.850	2.231	5.020	26.540	Q-a
			C-2	49.980	31.900	18.120	21.540	19.760	1.780	2.165	4.870	21.560	Q-a
			C-3	51.320	30.750	17.930	23.650	20.540	3.110	2.212	5.010	22.430	Q-a
			C-4	48.650	32.910	18.440	24.560	19.340	5.220	1.994	4.210	20.980	Q-a
			C-5	53.020	27.470	18.610	25.620	21.760	3.850	2.233	4.780	21.650	Q-a
82	MEJORAMIENTO DE LA CARRETERA TURHUAYANA QURULACOCCHA, DISTRITO DE SAN MIGUEL DE CAURI	Inicio: 76°40'36.08"W, 10°22'21.83"S, 4047 metros; Fin: 76°41'00.94"W, 10°24'02.14"S, 4372 metros	C-1	60.430	25.700	13.870	25.430	22.654	2.776	2.220	7.020	32.120	K-g
			C-2	50.760	25.920	14.320	26.780	21.430	5.350	2.210	6.870	35.840	K-g
			C-3	63.990	22.500	13.550	27.030	23.032	3.998	2.201	6.520	34.200	Q-g/ff
83	MEJORAMIENTO DE LA CARRETERA MERCENARIO - POMACUCHO - SAN JUAN DE LUKUARI - TAMBO DE SAN JOSE - SAN PEDRO DE CHOQUE CANCHA DISTRITO DE SANTA MARIA DEL VALLE - HUÁNUCO	Inicio: 76°14'47.91"W, 9°50'46.48"S, 3997 metros; Fin: 76°17'37.70"W, 9°47'45.47"S, 2688 metros	C-1	18.570	31.780	49.650	35.240	19.540	15.700	2.182	2.740	8.650	PE-e
			C-2	19.520	32.860	47.620	36.540	18.230	18.310	2.202	8.010	7.600	PE-e
			C-3	21.410	30.310	48.280	30.230	20.110	10.100	2.198	8.160	7.320	PE-e
			C-4	18.690	36.140	45.210	35.870	21.450	14.420	2.009	9.120	6.540	PE-e
			C-5	12.470	41.210	46.320	29.660	20.750	8.910	2.128	8.840	7.560	PE-e
			C-6	17.680	42.670	39.650	35.430	21.010	14.400	2.108	8.090	7.230	PE-e
			C-7	17.590	31.210	53.240	36.770	19.650	17.120	2.214	8.490	7.890	PE-e
84	REHABILITACIÓN DEL CAMINO VECINAL EMP. JU 648 - PACHAMBAMBA - RAUSA - RATAKOCCHA - EMP. JU 649 - DISTRITO DE SANTA MARIA DEL VALLE - HUÁNUCO	Inicio: 76°13'49.24"W, 9°51'11.80"S, 3975 metros; Fin: 76°13'42.24"W, 9°49'36.99"S, 2869 metros	C-1	47.590	32.740	19.710	27.230	21.860	5.370	2.208	7.280	22.140	Q-al
			C-2	48.190	37.580	14.230	26.870	20.080	6.790	2.225	5.860	19.250	Q-al
			C-3	68.420	17.690	13.890	25.450	21.860	3.590	2.209	5.140	21.400	PE-e
			C-4	36.240	39.610	24.130	30.620	20.760	9.860	2.108	8.080	21.200	PE-e
			C-5	66.320	19.200	14.480	26.760	21.640	5.120	2.213	6.980	19.650	PE-e
			C-6	42.090	38.560	19.350	27.560	20.640	6.920	2.219	7.440	18.120	PE-e
85	PAVIMENTACIÓN DE VIAS SECTOR AFRASCO POMAROS ZONA I, CIUDAD DE HUÁNUCO	Inicio: 76°15'01.64"W, 9°55'54.08"S, 3934 metros; Fin: 76°14'54.60"W, 9°55'45.08"S, 3919 metros	C-1	0.750	28.720	70.530	26.240	19.280	6.960	1.943	10.070	26.700	Pe-e
			C-2	1.020	31.130	67.850	25.450	18.980	6.470	1.921	9.680	25.430	Pe-e
			C-3	4.180	34.190	61.630	25.280	19.640	5.640	1.983	9.770	23.100	Pe-e
			C-4	0.920	30.370	68.710	26.520	19.600	6.720	1.991	9.320	18.700	Pe-e
86	REHABILITACIÓN DEL CAMINO VECINAL SAN JOSE DE PAUCAR MACCHA - CERRO ALEGRE, DISTRITO DE AMARILLO, PROVINCIA DE HUÁNUCO	Inicio: 76°30'30.30"W, 9°56'33.10"S, 2792 metros; Fin: 76°11'36.37"W, 9°56'41.60"S, 3036 metros	C-1	6.580	13.560	79.860	38.980	18.920	20.060	1.916	11.440	7.120	PE-e
			C-2	57.090	30.110	12.800	26.020	22.480	3.540	2.209	8.650	22.140	PE-e
			C-3	65.030	14.560	20.410	30.120	21.410	8.710				PE-e
			C-4	40.530	24.970	34.500	34.430	19.110	15.300				PE-e
			C-5	12.260	25.020	62.720	37.230	19.330	17.890	1.983	9.960	9.840	PE-e
			C-6	0.350	19.070	80.580	34.030	21.820	12.190				PE-e
			C-7	2.250	25.750	72.000	31.530	20.940	10.590				PE-e
			C-8	40.670	10.783	48.547	37.960	20.490	17.470	2.158	8.030	27.040	PE-e
			C-9	6.150	34.630	59.220	37.880	19.520	18.390				PE-e
			C-10	10.140	40.570	49.290	29.520	20.240	9.280				PE-e
			C-11	28.620	34.090	37.290	37.620	20.590	17.030	2.007	8.960	14.270	PE-e
			C-12	14.960	24.710	60.130	39.560	20.150	19.410				PE-e



88	MEJORAMIENTO Y REHABILITACION DEL CAMINO VECINAL PUERTO INCA - PUERTO SRA, DESVÍO: SAN PABLO DE SINAL, KM 16, PUMAYACU ALTO, CERRO SRA, SAN JOSE DE UMÓN, DISTRITO DE PUERTO INCA, PROVINCIA DE PUERTO INCA - HUÁNUCO	Inicio: 74°57'47.12"W, 9°22'53.68"S, 206 metros; Rio: 74°52'57.42"W, 9°15'38.50"S, 187 metros	C-6	74.140	17.340	8.520	27.210	22.200	5.010	2.204	8.820	22.760	Ps-m	
			C-1	0.890	8.590	90.520	37.880	18.500	19.380	1.895	11.020	7.020	Ps-p	
			C-2	0.500	8.140	91.360	39.460	17.520	21.940					Ps-p
			C-3	45.690	46.590	7.720	25.810	22.520	3.290					Ps-p
			C-4	0.000	6.180	91.820	39.640	18.890	20.750	1.879	11.240	6.910	Ps-p	
			C-5	0.610	11.780	87.610	39.140	19.680	19.460					Ps-p
			C-6	2.440	28.270	69.290	29.110	18.610	10.500	1.973	10.550	8.120	Ps-p	
			C-7	1.100	23.520	75.380	27.500	18.210	9.290					Ps-y
			C-8	28.360	16.910	54.730	38.710	19.490	19.220	2.031	9.280	10.270	Ps-y	
			C-9	0.220	2.590	97.230	39.570	17.870	21.700					Ps-y
			C-10	3.380	5.800	90.820	36.260	18.100	18.160	1.905	11.170	7.140	Ps-y	
			C-11	0.000	4.740	95.260	38.040	19.100	18.940	1.884	11.360	6.670	Ks-ch	
			C-12	0.000	29.650	70.350	38.250	19.840	18.410					Ks-ch
			C-13	0.640	61.340	38.220	34.400	20.930	15.470	1.976	9.510	9.440	Ks-ca-h	
			C-14	0.000	6.340	91.660	38.200	18.080	20.120					Ks-ca-h
			C-15	0.000	20.110	79.890	38.910	18.570	20.340	1.899	11.220	6.910	Ks-e	
			C-16	2.800	84.590	12.610	26.640	21.760	4.880					Ks-e
			C-17	5.330	56.870	37.800	26.640	21.760	4.880	2.021	8.160	21.050	Ks-e	
			C-18	1.950	1.770	96.280	39.990	17.620	22.370	1.918	10.430	7.150	Ks-e	
			C-19	0.230	8.900	90.890	39.310	18.310	20.980	1.909	9.840	8.680	Kh-fl	
			C-20	0.970	39.260	59.770	12.410	20.140	12.270					Kh-fl
C-21	0.000	38.240	61.760	27.550	20.120	7.430	1.994	9.130	8.970	Kh-fl				
89	REHABILITACION DE CAMINO VECINAL MORCA - LUATA - HUAMANIN	Inicio: 76°45'56.22"W, 9°13'10.76"S, 2849 metros; Rio: 76°48'38.21"W, 9°13'02.82"S, 3280 metros	C-1	64.560	17.540	17.900	38.700	31.200	7.500	2.205	6.450	26.850	Qh-ai	
			C-2	63.490	19.750	16.800	40.800	30.870	9.930	2.127	5.960	26.120	Qh-ai	
			C-3	65.100	16.850	18.050	40.400	29.560	10.840	2.150	5.750	25.340	Qh-ai	
			C-4	63.000	19.500	17.500	39.700	31.300	8.400	1.985	6.800	23.780	Ks-ju	
			C-5	63.780	19.020	17.200	39.000	28.600	10.400	2.040	7.040	23.650	Ks-ju	
			C-6	64.200	19.400	16.400	38.000	29.600	8.400	2.230	6.400	28.100	Ks-ju	
			C-7	65.890	15.810	18.300	41.010	30.000	11.010	2.209	5.200	27.600	Ks-ju	
90	CREACION DEL CAMINO VECINAL PAMPAPUASA - HUAYOSANTA VIRGINIA, DISTRITO DE PAPAJO, PROVINCIA DE PACHITEA	Inicio: 75°49'07.08"W, 10°07'42.46"S, 3707 metros; Rio: 75°41'46.48"W, 10°05'07.28"S, 3612 metros	C-2	14.910	45.210	39.880	NP	NP	NP	2.170	9.580	10.610	Ps-qr	
			C-3	5.470	47.110	47.420	NP	NP	NP	2.570	11.090	11.240	Ps-qr	
			C-4	10.270	48.320	41.410	NP	NP	NP	2.440	12.100	11.950	Ps-qr	
			C-8	23.420	44.260	32.320	NP	NP	NP	1.150	10.640	5.420	Ps-qr	
			C-18	48.150	29.360	22.490	NP	NP	NP	2.410	11.060	20.530	Ps-qr	
			C-19	47.010	31.670	21.320	NP	NP	NP	2.560	10.580	20.190	Ps-qr	
			C-25	55.550	21.780	22.670	NP	NP	NP	2.730	12.020	6.760	Ps-qr	
			C-26	61.130	22.020	16.850	NP	NP	NP	2.230	7.490	6.800	Ps-qr	
			C-28	33.300	21.680	45.020	30.100	21.330	8.870	2.210	12.380	11.760	Ps-qr	
			C-29	21.180	35.250	43.570	27.300	22.140	5.160	2.740	11.930	11.240	Ps-qr	
			C-30	28.930	31.210	39.860	25.670	19.410	6.260	2.140	12.240	15.390	Ps-qr	
			C-31	36.380	23.220	40.600	22.650	18.960	3.690	2.320	10.720	10.480	Ps-qr	
			C-32	46.510	27.130	26.360	NP	NP	NP	2.610	7.300	33.280	Ps-qr	
			C-33	20.270	37.090	42.640	25.140	15.890	9.250	2.370	14.310	11.260	Ps-qr	
			C-34	54.750	20.640	24.620	NP	NP	NP	2.170	8.250	28.270	Ps-qr	
			C-35	15.180	34.930	49.890	26.280	20.170	6.110	2.320	11.910	9.330	Ps-qr	
			C-36	24.880	8.510	66.600	22.270	15.620	6.650	2.070	16.960	7.410	Ps-qr	
			C-38	69.130	19.630	11.240	NP	NP	NP	2.650	8.260	41.150	Ps-qr	
			C-39	41.730	45.340	12.930	25.920	20.570	5.350	2.400	6.450	39.820	Ps-qr	
			C-40	58.950	32.390	8.660	23.660	19.630	4.030	2.210	5.780	28.430	Ps-qr	
			C-41	46.710	41.490	11.800	23.680	19.540	4.140	2.890	6.210	25.120	Ps-qr	
			C-42	38.870	42.350	18.780	28.450	20.800	7.650	2.120	8.380	38.650	Ps-qr	
91	CREACIÓN DEL SERVICIO DE MOVILIDAD URBANA EN LAS VÍAS LOCALES DE LA URB SANTA ELENA I y II DEL CC. PP. DE LUJAZA DISTRITO DE AMARILLO, PROVINCIA DE HUÁNUCO	Inicio: 76°13'48.08"W, 9°55'20.97"S, 1893 metros; Rio: 76°13'41.58"W, 9°55'18.03"S, 1903 metros	C-1	54.070	18.840	27.090	21.600	18.400	5.200	2.035	8.700	20.000	Qr-ai	
			C-2	60.180	13.830	25.990	22.200	18.700	3.500	1.890	15.500	23.000	Qr-ai	
			C-3	6.770	36.700	56.530	24.100	19.500	4.600	2.070	10.800	14.000	Qr-ai	
			C-4	49.280	30.430	20.290	18.600	15.400	3.200	1.680	18.600	16.000	Qr-ai	
			C-5	74.690	20.810	4.500	NP	NP	NP	2.290	5.900	36.400	Qr-ai	
			C-6	48.530	28.950	22.560	22.000	19.500	2.500	2.115	7.600	24.000	Qr-ai	
			C-7	46.730	31.810	21.460	24.100	21.300	2.900	2.065	9.000	19.000	Qr-ai	
C-8	61.490	28.480	10.030	23.100	20.700	2.600	2.160	7.200	23.650	Qr-ai				
92	MEJORAMIENTO DE LOS CAMINOS VECINALES TRAMO 1: EMP. PE 3N: EMP. HU 2031 - CONCHAMARCA (HU - 1036 ESTACION CASHATAMBO); TRAMO 2: SANTO TORIBIO - CRUCE ORMITA LAS PAMPAS - EMP. HU 2031, DISTRITO DE CONCHAMARCA - PROVINCIA	Inicio: 76°13'16.11"W, 10°02'21.61"S, 2046 metros; Rio: 76°13'03.38"W, 10°02'51.25"S, 2018 metros	C-1	33.340	28.120	38.040	24.880	20.290	4.590	2.034	10.740	15.650	Pe-cem	
			C-5	34.420	45.340	20.240	17.610	17.230	0.380	2.231	8.330	26.990	Pe-cem	
			C-9	43.820	24.580	33.600	29.190	29.970	5.380	2.087	9.510	24.650	Pe-cem	
			C-13	51.340	25.770	22.890	26.970	21.390	5.580	2.110	8.530	19.040	Pe-cem	
			C-14	19.610	15.750	64.640	43.840	30.200	13.640	1.770	15.090	11.120	Qp-a	
			C-17	36.320	43.220	20.460	23.570	21.110	2.460	2.150	7.080	35.280	Qp-a	
			C-18	28.630	28.340	43.030	25.900	18.550	7.350	2.021	8.780	10.200	Qp-a	
C-22	65.810	23.190	10.000	24.630	19.100	5.530	2.280	55.670	23.880	Qp-a				
93	MEJORAMIENTO Y CONSTRUCCIÓN DE LA CARRETERA - HUACRAHUCO Y SAN BUENAVENTURA	Inicio: 77°08'56.80"W, 8°16'22.94"S, 2186 metros; Rio: 77°11'12.56"W, 8°46'03.80"S, 3177 metros	C-1	50.120	43.740	5.940	NP	NP	NP				Ps-m	
			C-2	33.280	40.820	25.900	NP	NP	NP	2.070	8.550	23.840	Ps-m	
			C-3	26.780	60.870	12.350	NP	NP	NP				Ps-m	
			C-4	8.710	16.640	74.650	26.980	20.340	6.640				C-e	
			C-5	40.870	38.050	21.080	18.170	15.470	2.900	2.290	7.050	31.780	C-e	
			C-6	0.590	23.970	75.440	21.570	19.540	2.030				C-e	
			C-7	30.350	50.970	18.680	19.070	17.380	1.690				C-e	
			C-8	4.010	42.760	53.230	30.840	30.030	0.810	1.910	9.470	17.300	Ir-p	
			C-9	5.050	81.120	13.830	NP	NP	NP				Ir-p	
			C-10	24.610	49.160	26.230	22.220	20.710	1.510				Ir-p	
			C-11	51.170	40.870	6.960	NP	NP	NP	2.290	6.650	33.590	Ir-p	
			C-12	0.220	42.450	57.330	24.980	20.960	4.020				Fal-n	
			C-13	45.580	54.340	0.080	NP	NP	NP				Fal-n	
			C-14	21.410	64.600	13.990	NP	NP	NP	1.960	10.700	21.370	Fal-n	
			C-15	3.570	76.430	20.200	21.250	18.330	2.920				Fal-n	
94	MEJORAMIENTO DE LA RED VIAL DEPARTAMENTAL DE LA RUTA HU-111 TRAMO EMP. PE 3N TRAMO HIGUERAS - SAN JOSE DE COZO, L-16 KM DISTRITO SAN BUENAVENTURA	Inicio: 76°21'47.40"W, 9°55'03.96"S, 2158 metros; Rio: 76°23'16.07"W, 9°57'17.58"S, 2332 metros	C-1	64.200	21.600	14.200	12.170	25.890	6.280	2.189	7.300	29.400	C-e	
			C-2	60.120	26.230	13.650	10.120	21.430	8.690	2.050	8.600	23.560	C-e	
			C-3	63.400	22.700	13.900	29.600	20.500	9.100	1.985	8.100	24.600	RP-to-gd	
			C-4	62.500	23.400	14.100	32.450	22.300	10.150	2.134	9.200	25.300	RP-to-gd	
			C-5	64.700	20.400	14.900	13.670	25.320	8.350	2.040	7.420	18.600	RP-to-gd	
95	MEJORAMIENTO DE LA RED VIAL DEPARTAMENTAL DE LA RUTA HU-111 TRAMO EMP. PE 3N TRAMO HIGUERAS - SAN JOSE DE COZO, L-16 KM DISTRITO SAN BUENAVENTURA	Inicio: 76°20'51.30"W, 9°55'03.96"S, 2158 metros; Rio: 76°23'16.07"W, 9°57'17.58"S, 2332 metros	C-1	0.000	50.430	49.570	23.170	22.130	1.042	1.759	16.000	26.000	Ch-al	



[illegible]



107	RECONSTRUCCIÓN DE LA CARRETERA SANTOS ATAHUALPA DEL DISTRITO MARIANO DÁMASO BETRAÍN, PROVINCIA DE LEONCIO PRADO - HUÁNUCO	9°19'24.13"S, 671 metros; Rte. 76°33'36.72"W, 9°21'36.85"S, 881 msnm.	C-5	40.870	37.330	21.800	18.570	15.470	2.900	1.960	10.700	21.370	Ps-m
			C-6	0.590	23.970	75.440	21.570	19.570	2.000	1.960	10.700	21.370	Ps-m
			C-7	30.350	50.970	18.680	19.070	17.830	1.240	1.960	10.700	21.370	Ps-m
			C-8	4.010	42.760	53.230	30.840	30.030	0.810	1.960	10.700	21.370	Ps-m
			C-9	5.090	81.120	13.830	NP	NP	NP	1.960	10.700	21.370	Ps-m
			C-10	24.610	49.160	26.230	22.230	20.710	1.510	1.960	10.700	21.370	Ps-m
			C-1	51.380	27.900	18.720	NP	NP	NP	2.050	7.640	36.540	Ps-m
			C-2	52.900	33.530	13.570	NP	NP	NP				Ps-m
			C-3	68.590	24.000	7.410	NP	NP	NP	2.066	4.630	36.020	Ps-m
			C-4	64.060	27.580	8.360	NP	NP	NP				Ps-m
108	CREACIÓN DE CAMINO VECINAL MONOPANPA - ABRA ALLEGRA SHOTOI - FUENTE CHORRO PAMPA, PROVINCIA DE PACHTITA - HUÁNUCO	Inicio: 75°46'27.27"W, 9°49'23.64"S, 2275 msnm; Rte: 75°30'48.24"W, 9°44'15.54"S, 509 msnm.	C-5	59.260	27.480	13.260	25.140	18.770	6.370	2.069	7.660	35.810	Ps-m
			C-6	45.570	38.030	16.420	22.000	19.670	2.330				Ps-m
			C-7	45.380	36.890	17.730	31.960	22.340	9.620	1.981	11.630	22.890	Ps-m
			C-8	42.890	13.910	43.200	37.740	21.760	15.980				Tsl-p
			C-9	35.320	25.030	39.670	31.550	21.350	10.200	1.895	11.640	19.150	Tsl-p
			C-10	45.800	22.920	31.280	28.660	20.390	8.270				Tsl-p
			C-11	43.210	36.520	22.270	28.100	20.180	7.920	1.981	9.570	36.390	Tsl-p
			C-12	40.880	31.970	27.150	28.680	20.730	7.950				Tsl-p
			C-13	0.030	36.940	63.030	21.840	18.300	3.540	1.768	15.650	11.190	Tsl-p
			C-14	8.300	31.460	60.240	37.700	23.760	13.940				Tsl-p
			C-15	0.000	6.890	93.120	47.130	26.680	20.450				Tsl-p
			C-16	0.390	10.170	89.440	51.660	27.760	23.900	1.481	25.970	4.700	Tsl-p
			C-17	0.280	5.410	94.310	58.670	33.530	25.140				Tsl-p
			C-18	42.890	13.910	43.200	38.830	22.760	16.070	1.767	15.080	16.020	Tsl-p
			C-19	16.180	17.030	66.810	29.900	21.610	8.290	1.711	15.210	8.660	Tsl-p
			C-20	26.320	7.840	65.840	29.410	21.470	7.940				Tsl-p
			C-21	25.670	10.780	63.550	27.130	21.360	5.770	1.730	14.290	8.270	Tsl-p
			C-22	45.570	38.030	16.420	27.320	19.420	7.900				Tsl-p
			C-23	25.720	7.880	66.400	21.830	17.440	4.390				Tsl-p
			C-24	6.490	26.580	66.930	23.190	20.280	3.110				Tsl-p
			C-25	20.460	30.780	48.760	29.900	18.140	11.760	1.840	16.640	18.250	Tsl-p
			C-26	22.160	21.810	56.030	33.460	20.810	12.650	1.785	13.900	8.700	Tsl-p
			C-27	22.020	30.590	47.390	38.440	28.730	9.710	1.767	12.290	13.100	Tsl-p
			C-28	7.060	32.300	60.640	31.760	22.250	9.510				Tsl-p
			C-29	21.920	31.980	46.100	44.640	35.520	9.320	1.758	18.140	13.540	Tsl-p
			C-30	22.670	14.940	62.390	28.880	21.430	7.450				Tsl-p
			C-31	17.450	31.160	51.390	33.210	20.240	12.970	1.957	11.780	8.200	Tsl-p
			C-32	14.380	18.490	67.130	28.350	23.270	5.080				Tsl-p
			C-33	38.270	19.600	42.130	33.520	21.100	12.220	1.779	18.600	19.100	Tsl-p
			C-34	22.670	14.940	62.390	29.760	23.360	6.400				Tsl-p
			C-35	20.240	27.150	52.610	37.930	27.970	9.960	1.780	19.080	11.600	Tsl-p
			C-36	1.030	7.380	91.590	42.960	28.950	14.010	1.809	12.230	7.600	Tsl-p
			C-37	0.100	27.490	72.410	30.510	21.470	9.040				Tsl-p
			C-38	1.460	11.650	86.890	42.510	28.810	13.700	1.560	17.120	6.320	Tsl-p
			C-39	47.860	28.190	23.950	30.160	21.480	8.780				Tsl-p
			C-40	26.650	25.960	47.390	35.070	30.350	4.720	1.920	12.830	10.560	Tsl-p
			C-41	40.440	12.600	46.960	25.950	18.200	7.750				Tsl-p
			C-42	36.690	34.740	28.570	36.170	18.020	18.150	1.905	10.770	23.650	Tsl-p
			C-43	55.160	24.240	20.600	27.980	19.750	8.230				Tsl-p
			C-44	18.160	41.750	40.090	32.840	21.680	11.160	1.811	13.410	13.680	Tsl-p
			C-45	46.210	29.390	24.400	29.190	20.310	8.980				Tsl-p
			C-46	45.240	18.240	36.520	27.760	20.110	7.650	1.814	16.650	7.240	Tsl-p
			C-47	27.220	26.520	46.260	24.040	18.460	5.580				Tsl-p
			C-48	14.360	30.900	54.740	29.610	21.570	8.040	1.765	16.280	10.400	Tsl-p
			C-49	42.890	13.910	43.200	39.740	23.760	15.980				Tsl-p
			C-50	16.950	11.810	71.240	37.700	23.760	13.940	1.568	19.900	8.460	Tsl-p
			C-51	36.950	41.730	21.320	30.990	22.330	8.660				Tsl-p
			C-52	36.690	34.740	28.570	36.170	17.620	18.550	1.535	17.160	7.200	Tsl-p
			C-53	8.220	9.020	82.760	28.420	20.240	8.180				Tsl-p
			C-54	2.390	3.340	94.470	45.080	31.680	13.400	1.609	165.410	6.460	Ps-m
			C-55	20.460	30.780	48.760	29.900	18.140	11.760	1.843	16.640	18.250	Ps-m
			C-56	32.510	25.740	41.750	30.060	18.260	11.800	1.797	18.250	17.580	Ps-m
			C-57	24.000	18.360	57.640	26.760	19.320	7.440	1.805	15.190	12.450	Ps-m
			C-58	30.060	21.590	48.350	31.010	20.170	10.840	1.805	17.240	12.930	Ps-m
			C-59	3.230	20.720	76.050	27.550	33.530	-5.980				Ps-m
			C-60	36.540	26.710	36.750	25.400	18.090	7.310	1.832	13.760	15.930	Ps-m
			C-61	28.770	25.550	45.680	28.560	20.350	8.210				Ps-m
			C-62	1.110	10.090	88.800	28.990	21.310	7.680				Ps-m
			C-63	1.370	10.100	88.530	28.430	23.760	4.670	1.637	17.310	8.870	Ps-m
			C-64	0.110	8.170	91.720	28.820	20.740	8.080				Ps-m
			C-65	15.970	32.700	51.330	25.390	18.190	7.200				Ps-m
			C-66	32.290	16.610	51.100	39.850	26.310	13.540	1.791	18.160	9.000	Ps-m
			C-67	0.000	10.950	89.050	37.700	23.760	13.940				Ps-m
			C-68	60.940	6.210	32.830	31.640	19.940	11.700	1.894	11.810	20.100	Ps-m
			C-69	10.100	24.290	65.610	28.510	23.330	5.180				Ps-m
			C-70	31.180	21.580	47.240	31.010	20.170	10.840	1.805	17.240	12.930	Ps-m
			C-71	31.150	32.690	34.160	21.640	16.390	5.250				Ps-m
			C-72	35.350	30.320	34.330	31.580	19.220	12.360	1.913	8.330	15.600	Ps-m
			C-73	15.370	65.110	19.520	26.190	18.310	7.880				Ps-m
			C-74	64.770	25.960	9.670	25.910	21.420	4.490	2.150	4.520	14.120	Ps-m
			C-75	52.010	35.680	12.310	24.250	20.100	4.150	2.150	4.950	12.650	Ps-m
109	RECONSTRUCCIÓN Y CONSTRUCCIÓN DE LAS VÍAS VEHICULARES Y PEATONALES DE LA AVENIDA LOS COMARCOS Y	Inicio: 76°34'44.95"W, 9°57'40.61"S, 2938 msnm.	C-1	48.530	28.910	22.560	NP	NP	NP	2.115	7.600	24.000	Gr-al
			C-2	49.980	35.050	14.970	27.600	19.700	7.900				Gr-al
			C-3	35.400	34.590	30.010	27.500	18.800	8.700				Gr-al



110	JR. JUAN VELASCO ALVARADO, CAYHUAYNA BAJA, DISTRITO DE PILCOMARCA - HUÁNUCO	Hac: 76°14'31.95"W, 9°57'33.57"S, 2025 msnm.	C-4	45.870	27.270	26.860	30.800	26.500	4.300				Qr-al
			C-5	34.470	35.450	30.080	26.000	18.800	7.200	2.035	8.700	20.000	Qr-al
			C-6	65.870	17.750	16.380	29.900	24.400	5.500	2.170	7.700	25.400	Qr-al
			C-1	43.920	42.920	13.160	11.520	1.220	10.100	2.147	7.990	26.700	Qr-al
			C-2	7.200	64.280	28.520	25.710	10.060	5.650				Qr-al
			C-3	43.060	42.460	14.480	16.760	15.040	1.720	2.094	6.890	23.680	Qr-al
			C-4	47.520	40.360	12.120	16.930	15.460	1.470				Qr-al
			C-5	45.160	42.400	12.440	10.310	2.470	7.840	2.120	7.850	23.650	Qr-al
			C-6	7.120	61.520	31.960	26.140	19.820	6.320				Qr-al
			C-7	7.000	62.920	30.080	26.720	10.160	6.560	2.040	10.160	16.600	Qr-al
			C-8	44.400	43.440	12.160	10.070	2.380	7.690				Qr-al
			C-9	44.600	43.160	12.240	10.880	2.560	8.320	2.155	7.200	25.700	Qr-al
			C-10	40.920	40.320	18.760	17.190	14.710	2.680				Qr-al
			C-11	48.920	35.920	15.160	16.860	15.700	1.160	2.120	7.100	21.240	Qr-al
			C-12	7.560	60.960	31.680	25.390	10.010	5.320				Qr-al
			C-13	30.300	45.300	23.900	32.150	34.140	8.010	2.162	7.790	25.500	Qr-al
111	MEJORAMIENTO Y AMPLIACION DEL SERVICIO DE TRANSITABILIDAD VIAL INTERURBANA EN EL CAMINO VECINAL HU-729 TRAMO: HU-106 DIV. ISCOPIAMPA MILPO - DISTRITO DE RONDOS DE LA PROVINCIA DE LAURICOCHA DEL DEPARTAMENTO DE HUÁNUCO	Inicio: 76°47'56.56"W, 9°51'31.50"S, 3580 msnm; Hac: 76°45'24.92"W, 9°56'45.14"S, 3890 msnm.	C-1	0.060	1.080	98.860	35.740	27.230	8.510	1.621	15.940	7.430	Ki-ch/pt
			C-2	32.680	38.140	29.180	49.830	30.560	19.270	1.498	10.750	7.670	Ki-ch/pt
			C-3	0.110	41.950	57.940	NP	NP	NP	1.445	24.680	5.120	Ki-ch/pt
			C-4	0.090	2.350	97.820	36.190	26.050	10.140	1.698	11.020	15.760	Ki-ch/pt
			C-5	1.080	89.030	9.890	32.910	24.390	8.520	2.069	7.340	23.340	Ki-ch/pt
			C-6	0.760	13.980	85.260	45.160	33.350	13.810	1.587	15.980	7.010	Ki-ch/pt
			C-7	0.000	8.060	91.940	28.060	23.400	4.660	2.135	6.230	26.750	Ki-ch/pt
			C-8	19.210	45.250	35.520	NP	NP	NP	2.113	9.650	28.450	Ki-ch/pt
			C-9	0.000	5.330	94.670	39.250	28.030	13.220	2.041	7.650	20.540	Ki-g
			C-10	3.010	27.450	69.540	29.270	22.830	6.440	1.891	8.780	14.270	Ki-g
			C-11	0.000	9.640	90.360	39.520	25.390	14.130	1.396	11.450	5.430	Ki-g
			C-12	0.210	33.020	66.770	31.300	23.860	7.440	2.172	16.230	22.540	Ki-g
			C-13	0.800	13.170	86.030	NP	NP	NP	2.102	14.970	22.860	Ki-g
			C-14	8.450	36.580	54.970	NP	NP	NP	2.021	17.120	20.190	Ki-g
			C-15	1.080	9.890	89.030	32.910	24.390	8.520	2.211	10.540	27.420	Ki-g
			C-16	0.130	4.690	95.180	27.140	24.370	2.770	1.996	12.930	20.540	Ki-g
			C-17	0.080	5.230	94.690	33.580	27.050	6.530	2.152	6.740	25.210	Ki-g
			C-18	0.000	9.660	90.340	39.520	25.390	14.130	2.076	11.420	21.870	Ki-g
			C-19	0.110	41.950	57.940	NP	NP	NP	1.812	23.860	6.450	Ki-g
112	MEJORAMIENTO DEL CAMINO VECINAL VILLASOL - MARARAMPAMPA - HUÁNUCALIA - PILLAO	Inicio: 76°04'06.98"W, 9°49'09.06"S, 3929 msnm; Hac: 76°01'10.50"W, 9°47'56.76"S, 3717 msnm.	C-1	46.960	53.040	0.000	46.700	31.210	15.490				Ps-di
			C-2	36.290	49.530	14.180	24.270	22.990	1.280	1.940	10.500	18.000	Ps-di
			C-3	34.340	46.450	19.210	26.880	17.220	9.660				Ps-di
			C-4	45.350	50.760	3.290	17.790	15.880	1.910				Ps-di
			C-5	22.420	24.560	53.020	36.460	28.530	7.980				Ps-di
			C-6	62.480	29.150	8.170	56.610	32.260	24.150				Ps-di
			C-7	25.030	33.260	41.710	46.300	36.750	9.550	1.975	8.510	20.900	Ps-di
			C-8	54.340	33.130	12.550	23.120	16.480	6.640				Ps-di
			C-9	31.720	46.130	22.150	58.270	35.500	22.770				Ps-di
			C-10	60.510	39.490	0.000	40.210	23.420	16.790				Ps-di
			C-11	42.990	26.750	30.260	30.820	21.560	9.260				Ps-di
			C-12	2.580	84.190	13.230	NP	NP	NP	2.020	11.800	18.100	Ps-di
			C-13	37.970	28.610	33.420	32.670	25.690	6.980				Ps-di
			C-14	0.290	6.350	93.420	42.650	29.630	13.020				Ps-di
			C-15	29.630	20.320	50.050	17.790	15.880	1.910				Ps-di
			C-16	19.250	6.510	74.240	47.600	29.890	17.710				Ps-di
			C-17	10.040	11.240	78.720	43.750	24.210	19.540				Ps-di
			C-18	21.980	21.030	56.990	44.400	25.790	18.610				Ps-di
			C-19	13.820	13.750	72.430	56.520	32.820	21.700	1.848	9.250	9.600	Ps-di
			C-20	64.890	35.110	0.000	37.060	26.480	10.580				Ps-di
			C-21	25.480	60.040	14.480	27.510	21.590	5.920				Ps-di
			C-22	48.150	40.760	11.090	33.310	62.910	-29.600				Ps-di
			C-23	50.720	32.590	16.690	31.350	25.250	6.100				Ps-di
			C-24	66.230	24.430	9.160	47.150	34.300	12.850				Ps-di
			C-25	50.110	30.590	19.300	34.790	26.770	8.020				Ps-di
			C-26	21.770	42.550	53.680	38.990	26.170	12.820				Ps-di
			C-27	53.480	21.280	25.240	52.920	35.430	17.490	1.800	8.600	14.700	Ps-di
			C-28	32.240	32.350	35.410	43.580	33.260	10.120				Ps-di
			C-29	22.380	40.020	37.600	44.290	25.010	19.280				PE-e
			C-30	34.340	46.450	19.210	26.880	17.220	9.660				PE-e
			C-31	60.190	38.920	0.890	37.900	33.780	4.120				PE-e
			C-32	78.720	21.280	0.000	29.690	38.740	0.990	1.869	8.480	20.500	PE-e
			C-33	47.500	31.240	21.260	23.110	18.630	4.480				PE-e
			C-34	38.850	50.960	10.190	20.690	15.660	5.030				PE-e
			C-35	47.500	31.240	21.260	28.980	28.260	0.720				PE-e
			C-36	32.840	47.180	19.980	42.710	27.440	15.270				PE-e
			C-37	35.060	38.440	26.500	35.530	27.780	7.790				PE-e
			C-38	33.510	26.130	40.380	51.290	34.260	17.030	1.980	12.500	17.100	PE-e
			C-39	32.110	16.970	50.920	37.920	28.760	9.160				PE-e
			C-40	44.540	28.650	26.810	42.260	30.270	13.990				PE-e
			C-41	20.390	44.930	54.680	41.120	32.010	9.110				PE-e
			C-42	61.350	25.170	13.480	43.970	36.020	7.990				PE-e
			C-43	17.400	81.330	1.270	31.360	23.840	7.520				PE-e
			C-44	36.450	35.320	28.230	35.360	26.900	8.460	1.970	11.000	21.300	PE-e
			C-45	37.680	36.500	25.820	30.520	21.670	8.890				PE-e
			C-46	17.390	50.480	32.130	36.820	25.670	11.150				PE-e
			C-47	54.930	31.080	13.990	35.890	29.650	6.210				PE-e
			C-48	70.520	19.980	9.500	41.890	27.330	14.560				PE-e
			C-49	46.200	36.740	17.060	37.000	28.440	8.560				PE-e
			C-50	54.680	39.830	5.490	28.590	19.670	8.920				PE-e
			C-51	37.090	35.920	26.990	34.080	30.110	3.970	2.070	10.800	22.500	PE-e
			C-52	47.500	29.930	22.570	23.460	22.910	0.590				PE-e
			C-53	61.340	38.660	0.000	41.870	28.160	13.710				PE-e
			C-54	67.540	20.250	12.210	48.400	32.260	16.140				PE-e
			C-55	63.310	36.690	0.000	39.290	17.742	21.548				PE-e



			C-56	78.490	21.510	0.000	27.810	24.970	2.840				PE-a
			C-57	46.980	53.020	0.000	31.700	26.010	5.190	2.020	7.600	22.800	PE-a
			C-58	65.670	31.070	3.260	28.620	15.250	13.370				PE-a
			C-59	8.430	15.610	75.960	17.790	15.880	1.910				PE-a
			C-60	72.380	20.400	7.220	28.850	24.610	4.240				PE-a
			C-61	37.840	22.910	39.250	50.840	36.110	14.730				PE-a
			C-62	21.780	26.890	51.330	42.610	29.470	13.140				PE-a
			C-63	58.120	8.970	32.910	80.300	37.920	42.380	1.790	16.090	12.100	PE-a
			C-64	5.200	30.050	64.750	37.780	31.510	6.470				PE-a
			C-65	51.510	19.750	28.730	17.790	15.880	1.910				PE-a
			C-66	27.860	31.120	41.020	24.840	24.770	0.070				PE-a
			C-67	29.890	30.190	39.920	43.190	35.900	7.290				PE-a
			C-68	52.560	25.450	21.990	35.150	27.800	7.350				PE-a
			C-69	55.420	30.710	13.870	33.470	26.450	7.020				PE-a
			C-70	52.050	54.650	13.300	27.260	27.180	0.080				PE-a
			C-71	8.890	48.510	42.610	23.780	20.900	2.880				PE-a
			C-72	17.090	37.800	45.120	33.930	30.720	3.210	2.100	10.600	19.100	PE-a
			C-73	3.460	38.970	57.570	33.190	32.430	0.760				PE-a
			C-74	9.980	20.370	69.650	33.940	25.170	8.770				PE-a
			C-75	33.890	23.160	42.950	39.790	25.910	13.880				PE-a
			C-76	79.420	20.580	0.000	33.230	24.280	8.950				PE-a
			C-77	84.910	13.920	1.160	24.140	21.150	2.990				PE-a
			C-78	6.890	21.260	71.890	35.090	33.760	1.330				PE-a
			C-79	4.620	58.290	37.090	46.900	33.010	13.890				PE-a
			C-80	11.350	19.190	69.460	36.800	33.840	2.960				PE-a
			C-81	55.160	33.560	11.280	29.670	25.740	3.930				PE-a
			C-82	80.570	19.430	0.000	31.460	30.070	1.390				PE-a
			C-83	55.350	34.630	10.020	27.680	23.940	4.340	2.060	12.000	16.800	PE-a
			C-84	63.310	36.690	0.000	39.250	31.900	7.350				PE-a
			C-85	9.590	88.950	1.460	51.490	42.670	8.820				PE-a
			C-86	30.800	8.980	60.220	37.830	23.570	14.260				PE-a
			C-87	2.090	13.110	84.800	60.880	43.750	17.130				PE-a
			C-88	46.310	53.690	0.000	27.320	21.110	6.210				PE-a
			C-89	7.820	7.880	84.300	71.270	45.280	25.990	1.740	12.850	11.400	PE-a
			C-90	26.310	72.130	1.540	64.670	47.540	17.130				PE-a
			C-91	26.470	73.530	0.000	62.540	50.500	12.040				PE-a
			C-92	41.680	50.870	7.450	27.340	20.880	6.460				PE-a
			C-93	58.300	23.400	18.300	22.320	16.940	5.380	2.050	7.920	12.350	PE-a
			C-94	45.450	38.630	15.920	21.710	17.520	4.190	2.040	9.000	11.400	PE-a
			C-95	65.940	19.700	14.360	22.350	17.520	4.830	2.000	7.600	10.450	PE-a
			C-96	47.290	48.660	4.050	NP	NP	NP				PE-a
			C-97	4.160	91.680	4.160	NP	NP	NP				PE-a
113	"SALDO DE OBRA DEL PROYECTO: MEJORAMIENTO Y REHABILITACIÓN DEL SISTEMA VIAL DE CAMINOS VECINALES DEL DISTRITO DE MARGOS" RAMPAS - YACUS TRAMO I: RAMPAS - YACUS	Inicio: 76°28'29.21"W, 9°54'08.21"S, 1445 msnm; Fin: 76°30'15.84"W, 9°59'02.85"S, 1260 msnm.	C-1	37.480	40.350	22.160	28.710	24.210	4.500	2.101	9.070	25.400	Ks-j
			C-2	36.910	32.270	30.810	28.850	23.300	5.550				Ks-j
			C-3	34.510	17.400	48.070	28.840	23.890	4.950				Ks-j
			C-4	19.890	16.170	63.940	29.120	23.210	5.910				Ks-j
			C-5	59.890	36.680	3.430	NP	NP	NP	2.008	5.760	36.500	Ks-j
			C-6	19.340	33.840	46.820	32.090	24.000	8.090				Ks-j
			C-7	53.500	14.160	32.340	29.710	23.830	5.880				Ks-j
			C-8	38.270	24.180	37.550	28.970	23.200	5.770				Ks-j
			C-11	63.670	22.640	13.690	29.000	23.770	5.230				Ks-j
			C-12	18.300	29.280	52.420	28.830	23.670	5.160				Ks-j
			C-13	18.240	34.010	47.750	32.230	20.690	11.540	1.847	12.400	18.500	Ks-j
			C-14	2.940	31.000	66.060	33.030	20.680	12.350				Ks-j
			C-15	32.980	30.640	36.380	29.050	20.770	8.280				Ks-j
			C-16	32.390	32.340	35.270	28.730	23.430	5.300				Ks-j
			C-17	30.010	32.750	37.230	28.120	23.750	4.370	1.991	13.500	28.300	Ks-j
			C-18	6.510	23.900	69.590	30.390	19.240	11.150				Ks-j
			C-19	24.210	25.540	50.250	31.120	20.890	10.330				Ks-j
			C-20	28.100	28.070	43.830	32.730	20.280	12.450				Ks-j
			C-22	20.580	26.220	53.200	30.190	21.720	8.570				Ks-j
			C-23	11.520	27.950	60.530	33.910	20.980	12.930				Ks-j
			C-24	13.980	25.700	58.320	33.450	21.040	12.410				Ks-j
			C-25	7.130	9.610	83.240	33.470	21.610	11.860	1.881	17.230	4.400	Ks-j
			C-27	36.670	19.980	43.350	30.990	21.510	9.480				Ks-j
			C-28	32.650	31.700	35.650	29.120	23.030	6.290				Ks-j
			C-29	45.940	14.880	39.180	27.880	23.230	4.650	1.886	14.360	11.200	Ks-j
			C-30	27.240	25.610	47.150	29.380	23.250	6.090				Ks-j
			C-31	23.640	33.190	41.170	31.340	23.890	7.450				Ks-j
			C-32	43.640	21.260	35.100	30.980	24.780	6.200				Ks-j
			C-33	36.860	18.350	44.790	29.180	23.920	5.460	1.936	13.530	11.300	Ks-j
			C-34	36.990	23.470	39.540	29.670	23.990	5.680				Ks-j
			C-35	33.910	26.100	39.970	29.970	23.290	6.680				Ks-j
			C-36	50.780	27.660	21.560	29.040	19.470	9.570				Ks-j
			C-38	28.650	33.200	38.150	29.050	23.390	5.660				Ks-j
			C-40	79.490	18.210	2.300	NP	NP	NP				Ks-j
			C-47	75.680	7.300	17.020	29.430	24.220	5.210				Ks-j
			C-49	26.300	26.580	47.120	32.520	22.570	9.950	1.927	13.730	12.800	Ks-j
			C-50	6.790	4.400	88.850	33.160	23.780	9.580				Ks-j
			C-51	44.860	15.350	39.790	33.930	20.740	13.190				Ks-j
			C-52	40.880	14.210	44.910	34.180	21.020	13.160				Ks-j
			C-53	29.670	32.850	37.480	31.880	23.970	7.910	1.893	12.470	12.600	Ks-j
			C-55	14.790	18.090	67.120	28.530	23.120	5.410				Ks-j
			C-57	49.310	30.070	20.600	33.960	20.600	13.360	1.995	14.290	11.100	Ks-j
			C-57-A	26.310	33.950	39.730	31.610	24.210	7.600	1.957	14.410	9.800	Ks-j
			C-58	6.790	11.550	81.660	28.720	20.920	7.800				Ks-j
			C-59	5.360	22.340	72.300	30.280	23.300	6.980				Ks-j
			C-60	30.200	38.890	30.910	32.870	24.450	8.420				Ks-j
			C-62	5.480	11.390	83.130	31.240	20.150	11.090				Ks-j
			C-63	22.010	48.730	29.250	31.150	25.120	6.030				Ks-j



114	"SALDO DE OBRA DEL PROYECTO: MEJORAMIENTO Y REHABILITACIÓN DEL SISTEMA VIAL DE CAMINOS VECINALES DEL DISTRITO DE MARGOS" PAMPAS - YACUS TRAMO II: YACUS - PACAYHUA - MARGOS	Inicio: 70°30'33.14"W, 9°59'09.28"S, 3234 metros; Fin: 70°31'19.28"W, 9°31'39.28"S, 3561 metros.	C-64	19.480	16.870	63.650	33.110	24.150	8.960				Ks-j
			C-65	61.810	22.330	15.860	29.410	23.860	5.550	2.023	10.920	25.700	Ks-j
			C-66	14.670	29.880	55.450	32.040	25.170	6.870				Ks-j
			C-68	90.220	13.820	35.960	33.790	21.110	12.680				Ks-j
			C-69	17.240	26.970	55.790	33.380	24.730	8.690	1.925	13.250	10.500	Ks-j
			C-70	31.650	17.240	51.110	29.030	23.620	5.410				Ks-j
			C-71	24.060	10.240	65.700	32.560	24.310	8.250				Ks-j
			C-73	29.620	18.640	51.740	34.070	24.890	9.180	1.875	13.420	13.400	Ks-j
			C-74	28.530	16.440	55.030	33.120	24.550	8.770				Ks-j
			C-75	42.340	27.360	30.500	33.700	25.070	8.630				Ks-j
			C-76	27.050	15.350	57.600	33.750	21.450	12.300				Ks-j
			C-77	30.540	16.460	53.000	32.940	24.360	8.580	1.945	14.020	9.200	Ks-j
			C-78	15.910	23.470	60.620	32.190	24.770	7.420				Ks-j
			C-79	21.390	30.060	48.550	32.940	24.990	7.990				Ks-j
			C-80	22.250	35.660	42.090	32.840	24.070	8.770				Ks-j
			C-81	35.540	34.430	30.030	29.530	23.940	5.590	2.040	12.120	18.600	Ks-j
			C-83	39.830	22.440	37.730	29.770	23.800	5.970				Ks-j
			C-85	17.540	25.040	57.420	28.120	24.180	3.940	1.947	13.690	10.000	Ks-j
			C-86	51.700	27.440	20.860	33.410	25.300	8.110				Ks-j
			C-87	55.450	21.260	23.290	29.890	24.910	4.980				Ks-j
			C-88	34.020	19.320	46.060	29.140	24.740	4.400				Ks-j
			C-89	48.400	13.320	38.280	27.910	21.390	6.520	1.897	13.660	15.400	Ks-j
			C-90	36.260	17.620	46.120	28.450	24.400	4.090				Ks-j
			C-92	41.200	27.020	29.780	29.810	24.710	5.100				Ks-j
			C-93	31.320	19.390	47.290	28.560	23.880	4.680	1.943	12.880	12.400	Ks-j
114	"SALDO DE OBRA DEL PROYECTO: MEJORAMIENTO Y REHABILITACIÓN DEL SISTEMA VIAL DE CAMINOS VECINALES DEL DISTRITO DE MARGOS" PAMPAS - YACUS TRAMO II: YACUS - PACAYHUA - MARGOS	Inicio: 70°30'33.14"W, 9°59'09.28"S, 3234 metros; Fin: 70°31'19.28"W, 9°31'39.28"S, 3561 metros.	C-1	48.440	29.800	21.760	28.980	23.930	5.090	2.019	10.710	14.700	Ks-ju
			C-2	39.710	35.430	24.860	28.420	23.630	4.790				Ks-ju
			C-3	48.260	25.160	26.580	29.090	23.040	6.010				Ks-ju
			C-4	38.690	21.790	39.520	29.550	23.340	6.210				Ks-ju
			C-5	38.540	22.920	38.540	29.750	24.350	5.400	1.896	11.110	11.800	Ks-ju
			C-6	48.270	15.660	36.070	29.160	23.150	6.010				Ks-ju
			C-7	69.750	8.210	22.040	29.270	23.530	5.740				Ks-ju
			C-8	38.750	10.620	50.630	30.910	23.930	6.980				Ks-ju
			C-9	27.610	9.420	62.970	30.100	23.840	6.260	1.923	14.330	10.700	Ks-ju
			C-10	63.800	19.320	16.880	29.530	23.620	5.910				Ks-ju
			C-11	68.830	9.340	22.030	29.660	23.440	6.220				Ks-ju
			C-12	58.080	12.530	29.390	29.090	24.480	4.610				Ks-ju
			C-13	51.610	10.820	37.580	29.810	23.770	6.040	1.889	13.530	11.100	Ks-ju
			C-14	39.530	6.260	54.210	29.910	23.530	6.380				Ks-ju
			C-15	16.250	23.450	60.340	32.940	21.250	11.690				Ks-ju
			C-16	38.470	6.610	54.920	33.860	24.430	9.430				Ks-ju
			C-17	71.890	15.520	12.590	29.700	24.210	5.490				Ks-ju
			C-18	29.940	36.200	33.860	28.720	23.110	5.610	1.987	12.490	10.100	Ks-ju
			C-19	41.670	36.130	20.200	33.760	21.020	12.740				Ks-ju
			C-20	34.550	31.900	33.550	32.190	22.090	10.300				Ks-ju
			C-21	34.810	32.560	32.630	33.870	21.520	12.350				Ks-ju
			C-22	16.870	15.900	67.230	32.900	21.340	11.560	1.965	15.960	8.700	Ks-ju
			C-23	52.600	12.230	35.170	29.130	24.110	5.020				Q-al
			C-24	33.790	26.690	39.520	29.580	23.830	5.750				Q-al
			C-25	34.710	10.700	54.590	29.480	24.190	5.290				Q-al
			C-26	29.430	8.720	61.850	29.880	24.060	5.820	1.959	13.600	8.600	Q-al
			C-28	21.870	6.520	69.630	33.530	20.680	12.850				Q-al
			C-29	18.580	23.430	57.980	32.500	21.010	11.490	1.876	14.340	8.800	Q-al
			C-30	68.520	15.230	16.270	34.650	20.200	14.450				Q-al
115	"SALDO DE OBRA DEL PROYECTO: MEJORAMIENTO Y REHABILITACIÓN DEL SISTEMA VIAL DE CAMINOS VECINALES DEL DISTRITO DE MARGOS" PAMPAS - YACUS TRAMO III: MARGOS - COLPASHIPAMPA - MARCACASHA	Inicio: 70°31'33.51"W, 10°00'28.88"S, 3542 metros; Fin: 70°30'36.49"W, 10°02'55.71"S, 3558 metros.	C-1	1.600	45.130	53.290	30.820	23.630	7.190	1.818	13.380	6.500	KsP-c
			C-2	20.810	5.400	73.790	32.670	21.080	11.590				KsP-c
			C-3	2.060	7.630	90.310	31.860	20.280	11.580				KsP-c
			C-4	12.180	20.330	67.510	31.520	20.120	11.400				KsP-c
			C-5	40.180	16.740	43.080	30.720	21.020	9.700	1.899	13.520	10.200	KsP-c
			C-6	0.070	1.150	98.780	35.390	21.930	13.460				KsP-c
			C-7	6.690	2.660	90.690	34.520	21.090	13.230				KsP-c
			C-8	22.000	13.920	64.090	33.720	20.740	12.980				KsP-c
			C-9	47.900	31.870	20.230	31.090	21.130	9.960	1.962	12.380	24.300	KsP-c
			C-10	10.610	10.420	78.970	33.580	21.190	12.390				KsP-c
			C-11	24.990	20.970	54.040	31.310	23.570	7.740				KsP-c
			C-12	0.840	3.280	95.880	33.800	20.900	12.900				KsP-c
			C-13	0.290	3.590	96.120	33.610	20.800	12.810	1.748	19.030	5.000	KsP-c
			C-14	10.650	14.190	75.160	33.050	21.140	11.910				KsP-c
			C-15	42.450	19.150	38.400	33.660	24.400	9.260				KsP-c
			C-16	28.340	22.980	48.880	33.400	21.520	11.880				KsP-c
			C-17	5.590	8.950	85.500	33.620	20.250	13.570	1.863	16.400	4.400	KsP-c
			C-18	17.850	9.010	73.140	33.710	21.200	12.510				Ks-j
			C-19	7.790	5.250	86.970	32.000	19.980	12.020				Ks-j
			C-20	0.100	0.460	99.440	33.920	21.200	12.720				Ks-j
			C-21	27.900	24.820	47.280	32.840	20.460	12.380	1.996	13.640	17.200	Ks-j
			C-22	0.210	8.490	91.300	33.800	21.130	12.670				Ks-j
			C-23	1.740	4.930	93.310	33.850	21.700	12.150				Ks-j
			C-24	15.960	16.610	67.430	32.920	21.440	11.480				Ks-j
			C-25	0.300	0.900	98.800	34.380	20.670	13.710	1.783	17.350	4.200	Ks-j
			C-26	11.350	11.450	77.400	34.250	20.970	13.280				Ks-j
			C-27	25.100	15.400	59.500	32.910	21.860	11.050				Ks-j
			C-28	38.340	21.480	40.180	33.780	20.960	12.820				Ks-j
			C-29	11.100	25.180	61.720	34.080	20.300	13.780	1.875	14.890	8.600	Ks-j
			C-30	1.680	4.550	93.770	34.890	22.840	12.050				Ki-ch/pt
			C-31	30.930	4.310	64.760	32.930	21.020	11.910				Ki-ch/pt
			C-32	46.440	28.490	25.070	34.310	21.060	13.250				Ki-ch/pt
			C-33	53.560	35.510	10.930	32.670	20.470	12.200	1.990	10.190	29.200	Ki-ch/pt
			C-34	5.550	5.050	89.400	34.140	20.670	13.470				Ki-ch/pt
			C-35	5.870	21.700	72.430	32.900	21.030	11.870				Ki-ch/pt
			C-36	46.560	23.610	29.830	32.530	20.740	11.790				Ki-ch/pt



			C-37	8.290	16.390	75.420	34.190	21.500	12.650	1.924	12.790	7.600	Ki-ch/pt
			C-38	24.780	35.230	39.930	30.770	21.060	9.710				Ki-ch/pt
116	"SALDO DE OBRA DEL PROYECTO: MEJORAMIENTO Y REHABILITACIÓN DEL SISTEMA VIAL DE CAMINOS VECINALES DEL DISTRITO DE MARGOS" PAMPAS - YACUS TRAMO IV: ACCESO A CDCHAS Y CDCHAS	Inicio: 76°28'51.15"W, 10°01'49.51"S, 3195 msnnm; Fin: 76°30'04.12"W, 10°02'00.11"S, 3226 msnnm.	C-1	5.250	21.620	73.130	30.590	21.520	9.070	1.949	14.610	7.900	RP-ca
			C-2	49.880	12.200	37.920	28.510	22.870	5.640				RP-ca
			C-3	49.210	21.170	29.620	30.080	22.980	7.100				RP-ca
			C-4	13.410	34.700	51.890	29.940	23.560	6.380				RP-ca
			C-5	11.110	22.360	66.530	30.920	21.540	9.380	1.904	15.900	7.900	RP-ca
			C-6	18.640	35.230	46.150	28.870	23.300	5.570				RP-ca
			C-7	30.540	22.850	46.610	30.930	22.070	8.860				RP-ca
			C-8	6.990	38.050	55.020	31.940	21.190	10.150				RP-ca
			C-9	10.340	22.180	67.480	31.990	21.030	10.960	1.886	14.360	7.800	RP-ca
			C-10	27.370	31.980	40.650	29.160	23.060	6.100				RP-ca
			C-11	21.070	29.950	48.980	29.620	23.700	5.920				RP-ca
			C-12	20.510	15.580	63.910	31.960	20.400	11.560				RP-ca
			C-13	11.950	28.000	60.050	33.270	20.760	12.510	1.830	13.850	5.500	RP-ca
			C-14	7.190	27.330	65.480	35.050	20.520	14.530				RP-ca
			C-15	21.100	32.610	44.290	32.630	22.660	9.970				RP-ca
			C-16-A	25.150	41.290	33.560	28.320	23.620	4.700				RP-ca
			C-16-B	9.540	10.900	79.560	35.540	22.190	13.350				RP-ca
			C-17	13.190	33.280	53.530	29.200	23.530	5.670	1.988	11.510	6.200	RP-ca
			C-18	2.990	17.650	79.360	31.300	20.250	11.050				RP-ca
			C-19	34.580	28.340	37.080	28.770	23.530	5.240				RP-ca
			C-20	17.010	38.650	44.340	33.070	23.960	9.110				RP-ca
			C-21	1.280	33.740	64.980	34.440	22.200	12.240	1.867	15.380	7.400	RP-ca
			C-22	13.210	33.070	55.710	28.740	24.490	6.290				RP-ca
			C-23	12.430	36.780	50.790	27.510	22.850	4.660				RP-ca
			C-24	18.450	47.430	34.120	30.850	21.490	9.560				RP-ca
			C-25-A	19.000	34.130	46.870	29.000	23.110	5.890				RP-ca
			C-25-B	3.170	25.440	71.390	33.110	21.890	11.220	1.863	16.450	4.300	RP-ca
			C-26	16.780	31.240	51.980	29.850	23.650	6.200				RP-ca
			C-27	17.450	27.450	55.100	30.970	26.460	4.510				RP-ca
			C-28	24.140	28.490	47.370	30.470	21.350	9.120				RP-ca
			C-29	9.070	39.590	51.340	31.310	24.100	7.210	1.741	15.740	6.800	RP-ca
			C-30	19.700	22.180	58.140	31.570	23.530	8.040				RP-ca
			C-31	0.190	10.760	89.050	31.270	20.130	11.140				RP-ca
			C-32	6.890	41.430	51.680	28.720	23.070	5.650				RP-ca
			C-33	9.730	20.880	69.390	32.020	20.390	11.830	1.976	16.500	6.100	RP-ca
			C-34	0.750	7.600	91.650	31.510	20.480	11.030				RP-ca
			C-35	49.440	38.950	11.610	35.940	20.850	15.090				RP-ca
			C-36	10.620	18.360	71.020	33.150	20.530	12.620				RP-ca
			C-37	7.620	19.580	72.800	33.930	21.130	12.800	1.657	19.700	4.100	RP-ca
			C-38	24.570	61.980	13.450	35.100	20.640	14.460				RP-ca
			C-39	1.770	9.690	88.540	35.280	21.300	13.980				RP-ca
			C-40	0.280	8.140	91.580	36.070	22.520	13.550				RP-ca
117	"SALDO DE OBRA DEL PROYECTO: MEJORAMIENTO Y REHABILITACIÓN DEL SISTEMA VIAL DE CAMINOS VECINALES DEL DISTRITO DE MARGOS" PAMPAS - YACUS TRAMO V: CRUZ TOCANA - RACHAFAYWA	Inicio: 76°34'48.24"W, 10°00'12.74"S, 4165 msnnm; Fin: 76°33'39.59"W, 10°02'54.67"S, 3873 msnnm.	C-1	20.920	15.530	63.550	34.680	23.720	10.960	1.509	12.180	9.300	Ps-m
			C-2	17.320	9.890	72.790	33.760	20.670	13.090				Ps-m
			C-3	15.110	12.070	72.820	33.060	20.550	12.510				Ps-m
			C-4	48.090	28.420	23.490	33.180	20.640	12.540				Ps-m
			C-5	30.210	24.750	45.040	34.460	22.880	13.580	1.891	12.590	8.400	Ps-m
			C-6	23.330	14.560	62.130	33.470	21.230	12.240				Ps-m
			C-7	26.410	9.650	63.940	34.270	21.030	13.240				Ps-m
			C-8	16.590	19.060	64.350	35.070	21.210	13.860				Ps-m
			C-9	34.170	27.460	38.370	33.560	21.580	11.980	1.886	14.360	13.100	Ps-m
			C-11	45.790	25.720	28.490	33.160	21.100	12.060				Ps-m
			C-12	14.510	13.550	71.940	33.540	21.760	11.780				Ps-m
			C-13	16.710	16.690	66.690	33.720	20.790	12.930	1.811	14.540	10.500	Ps-m
			C-14	11.590	16.890	69.520	32.990	20.890	12.100				Ps-m
			C-15	20.240	13.480	66.280	33.990	21.680	12.310				Ps-m
			C-16	28.950	17.180	53.870	33.930	21.430	12.500				Ps-m
			C-18	43.570	28.330	28.100	32.530	20.410	12.120				Ps-m
			C-19	15.700	14.540	69.760	34.460	21.600	12.860				Ps-m
			C-20	17.700	13.290	69.010	34.060	21.300	12.760				Ps-m
			C-21	10.890	10.300	78.810	32.890	20.250	12.640	1.881	15.980	7.400	Ps-m
			C-22	17.750	15.570	66.680	34.650	21.100	13.550				Ps-m
			C-23	14.550	13.640	71.810	33.960	21.230	12.730				Ps-m
			C-24	11.510	10.940	77.530	33.460	21.200	12.260				Ps-m
			C-25	22.930	16.260	60.810	34.450	21.540	13.110	1.883	12.760	4.200	Ps-m
			C-26	20.440	14.280	65.280	32.800	21.090	11.710				Ps-m
			C-27	57.130	13.120	29.750	30.650	23.590	7.060				Ps-m
			C-28	38.340	17.760	43.350	33.640	21.100	12.740				Ps-m
			C-01 M1	46.900	38.900	14.200	15.000	13.000	2.000	2.251	6.200	8.790	Pe-cm2
			C-01 M2	9.400	35.800	54.800	26.000	21.000	5.000	1.932	7.400	9.450	Pe-cm2
			C-02 M1	27.900	44.500	27.600	15.000	11.000	4.000	1.865	7.120	11.230	Pe-cm2
			C-02 M2	62.000	19.600	18.400	20.000	13.000	7.000	1.764	6.800	9.900	Pe-cm2
			C-02 M3	43.000	43.500	15.500	20.000	13.000	7.000	1.875	8.560	11.050	Pe-cm2
			C-03 M1	53.200	29.600	17.200	17.000	0.000	17.000	1.793	7.450	14.600	Ki-g
			C-03 M2	33.400	29.500	37.100	19.000	13.000	6.000	1.863	6.540	13.800	Ki-g
			C-04 M1	59.300	27.200	13.500	16.000	9.000	7.000	1.967	6.870	16.500	Ki-g
			C-05 M1	50.100	39.900	10.000	19.000	14.000	5.000	1.956	7.320	15.800	Ki-g
			C-05 M2	53.600	27.300	19.100	25.000	18.000	7.000	1.962	7.540	17.400	Ki-g
			C-06 M1	37.900	44.900	17.200	13.000	NP	NP	1.892	8.650	16.300	Ki-g
			C-06 M2	22.200	33.800	44.000	38.000	24.000	14.000	1.765	8.020	16.800	Ki-g
			C-07 M1	48.900	35.500	15.600	24.000	0.000	24.000	1.812	7.650	17.200	Ki-j
			C-07 M2	20.300	30.500	49.200	23.000	18.000	5.000	1.789	6.450	17.300	Ki-j
			C-08 M1	55.400	30.500	14.100	0.000	0.000	0.000	1.802	7.020	16.800	Ki-j
			C-09 M1	48.900	39.200	11.900	15.000	12.000	3.000	1.821	6.100	18.400	Ki-j
			C-09 M2	51.500	36.100	12.400	17.000	13.000	4.000	1.798	7.700	15.900	Ki-j
			C-10 M1	39.700	35.100	25.200	21.000	14.000	7.000	2.169	9.400	24.600	Ki-ch/pt
			C-10 M2	52.900	27.000	20.100	21.000	14.000	7.000	2.204	7.900	23.400	Ki-ch/pt
			C-10A M1	53.700	29.300	17.000	25.000	18.000	7.000	2.192	8.900	29.400	Ki-ch/pt



118	MEDRAMIENTO DE LA CARRETERA OROPUCUQUO - II DE DICIEMBRE-PUCAHUAY, SAN MIGUEL DE CAURI, PROVINCIA DE LAURICOCHA	Inicio: 76°36'14.73"W, 10°13'08.13"S, 3736 msnm; Intermedio: 76°38'22.63"W, 10°20'05.54"S, 3997 msnm; Fin: 76°35'52.30"W, 10°24'07.17"S, 4460 msnm.	C-11 M1	43.200	28.800	28.000	23.000	15.000	8.000	1.986	9.380	19.300	Ka-j
			C-11 M2	32.200	33.300	34.500	21.000	14.000	7.000	1.896	8.020	18.300	Ka-j
			C-11A M1	62.100	25.300	12.600	17.000	NP	NP	1.865	8.230	17.500	Ka-j
			C-12 M1	26.000	37.300	36.700	NP	NP	NP	1.932	9.230	17.300	Ka-j
			C-12 M2	31.900	36.200	31.900	24.000	15.000	9.000	2.101	7.850	19.100	Ka-j
			C-13 M1	69.800	23.800	6.400	21.000	18.000	3.000	1.995	8.100	18.200	Ka-j
			C-13 M2	12.100	49.400	38.500	18.000	13.000	5.000	1.941	9.210	17.400	Ka-j
			C-13A M1	12.100	18.900	69.000	37.000	19.000	18.000	2.201	7.640	29.100	Ka-ce
			C-14 M1	41.600	27.900	30.500	26.000	20.000	6.000	2.146	8.220	29.400	Ka-ce
			C-14 M2	65.600	24.700	9.700	0.000	0.000	NP	2.135	9.350	25.600	Ka-ce
			C-15 M1	63.400	28.300	8.300	0.000	0.000	NP	1.996	7.550	23.700	Ka-ce
			C-15 M2	68.600	24.200	7.200	0.000	0.000	NP	1.965	8.220	21.400	Ka-ce
			C-15A M1	30.300	35.690	34.010	37.000	29.000	8.000	1.998	9.110	23.100	Ka-ce
			C-16 M1	26.200	32.300	41.500	26.000	15.000	11.000	2.016	8.010	22.100	Ka-ce
			C-16 M2	44.500	30.200	25.300	20.000	15.000	5.000	2.112	8.320	24.300	Ka-ce
			C-16A M1	50.600	28.200	21.200	25.000	16.000	9.000	2.067	9.410	21.100	Ka-ce
			C-16A M2	62.200	30.600	7.200	13.000	0.000	NP	2.165	7.090	29.110	Q-gfl
			C-17 M1	49.100	27.300	23.600	34.000	21.000	13.000	1.955	8.650	29.700	Q-gfl
			C-16 M2	58.400	31.400	10.200	16.000	11.000	5.000	1.850	9.350	30.120	Q-gfl
			C-16 M2	58.500	9.600	31.900	17.000	9.000	8.000	1.968	7.020	29.210	Q-gfl
			C-17 M1	60.200	30.200	9.600	20.000	12.000	8.000	2.103	8.540	29.400	Q-gfl
			C-18 M1	65.600	24.500	9.900	15.000	11.000	4.000	2.189	9.350	30.200	KaP-c
			C-19 M1	61.500	26.300	10.200	19.000	11.000	8.000	2.175	7.660	22.100	KaP-c
			C-19A M1	39.200	40.300	20.500	25.000	16.000	9.000	1.950	8.430	23.100	KaP-c
			C-40 M1	49.000	19.900	31.100	29.000	18.000	11.000	1.860	9.650	21.090	KaP-c
			C-41 M1	40.100	35.700	24.200	19.000	13.000	6.000	1.870	7.910	19.430	KaP-c
			C-41 M2	46.200	34.700	19.100	27.000	20.000	7.000	1.940	8.280	19.870	KaP-c
			C-41 M3	61.300	26.400	10.300	25.000	18.000	7.000	1.965	8.170	20.400	KaP-c
			C-42 M1	49.400	29.700	20.900	14.000	0.000	NP	2.112	9.340	20.800	KaP-c
			C-42 M2	71.300	16.200	12.500	29.000	16.000	13.000	1.974	7.650	20.600	KaP-c
			C-43 M1	55.800	31.600	12.600	0.000	NP	NP	2.107	8.390	28.900	KaP-c
			C-43 M2	77.000	12.700	10.300	27.000	18.000	9.000	2.161	9.320	21.120	Ka-ce
			C-43A M1	41.100	26.400	32.500	36.000	23.000	13.000	2.211	7.080	20.210	Ka-ce
			C-43A M2	17.900	35.200	46.900	41.000	29.000	12.000	1.932	8.310	19.430	Ka-ce
			C-44 M1	54.600	34.700	10.700	0.000	0.000	0.000	1.951	9.370	19.550	Ka-ce
			C-45 M1	40.100	35.300	24.600	21.000	13.000	8.000	2.209	7.570	19.330	Ka-ce
			C-45 M2	52.900	22.500	24.600	19.000	12.000	7.000	2.180	8.110	18.540	Ka-ce
			C-45 M3	54.500	22.900	22.600	21.000	13.000	8.000	2.060	9.050	18.430	Ka-ce
			C-46 M1	48.500	37.300	14.200	12.000	0.000	0.000	1.937	7.500	19.000	Ka-ce
			C-47 M1	54.600	29.200	16.200	16.000	11.000	5.000	1.926	8.250	21.300	Ka-ce
			C-47 M2	40.200	23.500	36.300	35.000	17.000	18.000	2.070	8.500	20.700	Ka-ce
			C-48 M1	59.900	26.800	13.900	33.000	21.000	12.000	2.182	8.030	28.500	Ka-ce
			C-49 M1	42.700	40.400	16.900	20.000	12.000	8.000	2.211	8.200	19.400	Ka-ce
			C-49 M2	34.500	34.600	30.900	26.000	20.000	6.000	2.027	11.200	15.400	Ka-ce
119	ESTUDIO DEFINITIVO DEL MEDRAMIENTO DE LA CARRETERA HUALLICO - CONMOCOCHA, SECTOR: HUALLICO - LA UNION - HUALLANCA TRAMO I: HUALLICO A PUNTO UNION	Inicio: 76°15'37.91"W, 9°56'17.10"S, 2824 msnm; Intermedio: 76°21'47.19"W, 9°55'04.28"S, 2158 msnm; Fin: 76°31'03.30"W, 9°52'03.10"S, 2961 msnm.	C-01 M2	53.600	24.100	20.300	17.000	NP	NP	2.271	6.300	28.500	Qr-al
			C-06 M1	46.500	22.200	31.300	43.200	32.500	10.700	2.123	8.500	17.100	Qr-al
			C-11 M1	56.900	25.300	17.800	16.100	32.100	4.000	2.174	7.120	23.500	Qr-al
			C-16 M1	29.000	39.300	31.700	37.800	32.100	5.700	2.141	7.400	16.700	Qr-al
			C-21 M2	21.800	48.800	29.400	24.800	21.700	3.100	2.111	9.500	14.500	Qr-al
			C-26 M1	48.200	30.000	21.800	38.900	35.900	3.000	2.253	6.500	27.100	Qr-al
			C-31 M1	0.000	55.700	44.300	31.800	18.900	12.900	1.935	10.900	6.200	Qr-al
			C-36 M1	19.000	34.000	47.000	23.000	18.000	5.000	2.103	7.400	13.600	Qr-al
			C-41 M1	22.600	38.700	38.700	48.300	32.700	15.600	2.207	8.000	24.100	Qr-al
			C-46 M2	23.000	71.300	5.700	40.200	26.700	13.500	2.150	6.700	15.000	Qr-al
			C-51 M1	38.200	40.100	21.700	23.500	NP	NP	2.197	6.500	20.500	Qr-al
			C-56 M1	35.300	36.600	28.100	18.800	12.500	6.300	2.185	6.600	17.800	Qr-al
			C-61 M2	10.100	35.300	54.600	31.800	21.100	10.700	1.909	10.900	8.300	Qr-al
			C-66 M2	29.500	24.400	46.100	14.100	12.300	1.800	2.019	9.300	13.100	Qr-al
			C-71 M2	53.500	29.100	17.400	21.900	17.400	4.500	2.208	7.400	22.800	Qr-al
			C-76 M1	39.600	33.600	26.800	37.000	18.400	18.400	2.045	9.900	7.100	Qr-al
			C-81 M1	20.100	38.100	41.800	18.700	16.900	1.800	2.158	6.500	16.300	Qr-al
			C-86 M2	30.700	38.600	30.700	24.100	17.000	7.100	2.189	7.300	13.900	Qr-al
			C-91 M2	25.600	13.600	60.800	35.500	19.500	16.000	1.942	10.200	2.800	Qr-al
			C-96 M1	51.400	28.700	19.900	16.800	NP	NP	2.104	8.200	16.800	C-a
			C-101 M1	47.000	20.400	32.600	34.700	24.500	10.200	1.940	10.700	14.800	C-a
			C-106 M2	61.600	18.000	20.400	27.100	17.400	9.700	2.260	6.200	18.600	C-a
			C-111 M1	27.400	44.400	28.200	13.500	NP	NP	2.073	8.800	18.800	Qr-al
			CA-26 M1	37.700	37.900	24.400	25.000	18.200	6.800	2.040	8.900	22.200	PE-a
			CA-30 M1	19.400	38.500	42.100	28.400	22.800	5.600	1.970	11.700	11.400	PE-a
			C-126 M2	53.600	38.800	7.600	15.600	NP	NP	2.203	7.100	33.500	PE-a
			C-131 M2	0.000	56.200	43.800	39.600	28.200	11.400	1.890	9.000	6.700	PE-a
			C-136 M1	0.000	33.500	66.500	38.300	27.500	10.800	1.868	13.200	4.000	PE-a
			C-141 M2	0.000	24.400	75.600	39.700	31.000	8.700	1.728	17.200	3.000	PE-a
			C-146 M1	25.800	68.500	5.700	24.400	NP	NP	1.996	10.000	9.600	KP-to-gd
			C-151 M1	53.700	33.700	10.600	38.600	35.200	3.400	2.155	7.900	19.700	KP-to-gd
			C-156 M2	0.000	46.500	53.500	43.000	31.900	11.100	1.882	12.300	5.800	KP-to-gd
			C-161 M2	14.700	19.200	66.100	39.800	29.200	10.600	1.849	12.000	6.700	KP-to-gd
			C-166 M1	0.000	66.900	33.100	67.100	35.100	32.000	1.930	10.800	16.800	KP-to-gd
			C-171 M1	8.100	61.800	30.100	35.200	23.100	12.100	1.840	12.300	6.700	KP-to-gd
			C-176 M1	58.300	28.600	13.100	50.200	46.200	4.000	2.156	6.600	37.400	KP-to-gd
			C-181 M1	21.900	38.800	39.300	42.800	30.700	12.100	1.881	11.100	9.700	KP-to-gd
			C-186 M1	57.300	29.100	13.600	29.800	24.100	5.700	2.149	7.200	27.000	KP-to-gd
			CA-42 M1	30.000	31.600	38.400	28.800	24.900	3.900	2.030	9.600	20.500	KP-to-gd
			C-196 M1	64.300	22.000	13.700	24.300	14.200	10.100	2.131	9.000	21.200	KP-to-gd
			C-201 M2	77.400	12.300	10.300	24.500	18.100	6.400	2.145	9.300	18.100	KP-to-gd
C-206 M1	0.000	55.900	44.100	33.100	22.600	10.500	1.910	9.600	4.500	KP-to-gd			
C-211 M2	6.600	30.100	63.300	36.200	21.700	14.500	1.878	17.600	5.300	KP-to-gd			
C-216 M1	0.000	18.600	81.400	36.000	24.500	11.500	1.889	16.800	3.100	PS-mi			
C-221 M1	6.400	29.800	63.800	19.500	NP	NP	1.737	16.900	6.900	PS-mi			
C-226 M1	36.300	57.400	6.500	25.200	NP	NP	1.941	11.000	19.600	PS-mi			



120	ESTUDIO DEFINITIVO DEL MEJORAMIENTO DE LA CARRETERA HUÁNUCO - COMOCOCCHA, SECTOR: HUÁNUCO - LA UNIÓN - HUALLANCA SUB TRAMO II: PUNTO UNIÓN - TINGO CHICO	Inicio: 76°33'03.30"W, 9°52'03.10"S, 2961 msnm; Intermedio: 76°36'10.50"W, 9°51'12.88"S, 3475 msnm; Fin: 76°43'12.64"W, 9°38'55.78"S, 2985 msnm.	C-230 M1	76.300	7.800	15.900	26.500	20.100	6.400	1.791	14.100	23.200	PS-mi
			C-231 M1	0.000	9.500	90.500	25.700	18.900	6.800	1.879	13.900	4.100	Tr-j-pu
			C-236 M1	20.100	18.300	61.600	26.500	21.500	5.000	1.862	15.100	4.900	Tr-j-pu
			C-241 M1	60.400	28.800	10.800	13.800	NP	NP	1.902	9.500	14.900	Tr-j-pu
			C-246 M1	41.800	20.100	38.100	29.100	20.600	8.500	2.080	7.000	18.000	Tr-j-pu
			C-251 M1	15.700	37.600	46.700	27.100	19.000	8.300	1.907	12.000	4.000	Tr-j-pu
			C-256 M1	44.800	19.100	36.100	27.400	18.300	9.100	2.031	12.800	21.000	PS-mi
			C-261 M1	36.500	18.500	45.000	35.600	28.200	7.400	1.975	10.700	15.800	PS-mi
			C-266 M1	41.400	7.800	50.800	27.000	18.900	8.100	2.009	9.400	12.300	PS-mi
			C-271 M1	16.500	17.900	65.600	34.500	26.300	8.200	1.891	16.500	7.800	PS-mi
			C-276 M1	34.300	12.800	52.900	27.600	18.700	8.900	1.986	9.500	6.900	PS-mi
			C-276 M1	34.300	12.800	52.900	27.600	18.700	8.900	1.986	9.500	6.900	PS-mi
			C-280 M1	56.300	16.600	27.100	29.100	22.400	6.700	2.031	8.300	16.400	PS-mi
			C-285 M1	50.400	18.800	30.800	25.800	19.000	6.800	2.004	8.200	18.100	PS-mi
			C-290 M1		100.000		25.600	19.800	5.800	1.821	14.800	3.900	PS-mi
			C-295 M1	0.000	28.000	72.000	28.100	22.800	5.500	1.905	12.000	4.900	PS-T-mi
			C-300 M1	56.200	31.400	12.400	25.100	NP	NP	2.108	10.900	19.000	PS-T-mi
			C-305 M1	15.800	39.000	45.200	54.600	39.300	15.100	1.737	16.000	5.200	PS-T-mi
			C-310 M1	3.000	34.900	62.100	32.100	20.800	11.300	1.766	14.600	2.600	PS-T-mi
			C-315 M1		100.000		33.900	NP	NP	2.012	11.100	10.200	PS-T-mi
			C-320 M1	7.500	30.800	61.700	34.800	25.500	9.300	1.849	13.600	3.100	PS-T-mi
			C-326 M1	14.900	57.200	27.900	30.700	NP	NP	1.972	10.100	9.800	PS-T-mi
			C-331 M2	16.500	38.000	45.500	27.900	22.500	5.400	2.006	11.300	13.900	PS-T-mi
			C-336 M2	48.300	34.300	17.400	20.100	NP	NP	1.997	12.500	15.000	PS-T-mi
			C-341 M1	59.400	27.000	13.600	26.200	NP	NP	2.094	6.300	22.200	PS-T-mi
			C-346 M1	52.300	33.100	14.600	23.100	NP	NP	2.132	8.300	17.000	Cl-a
			C-351 M1	38.200	29.900	31.900	28.400	24.300	4.100	2.034	10.900	14.900	Cl-a
			C-356 M1	45.600	35.300	19.100	21.700	NP	NP	1.933	7.800	18.900	Cl-a
			C-361 M1	47.400	32.900	19.700	22.200	NP	NP	1.967	8.200	17.500	Cl-a
			C-366 M1	44.600	41.000	14.400	23.200	NP	NP	2.024	7.700	24.800	Cl-a
			C-371 M1	61.200	27.700	11.100	25.900	20.200	5.700	2.156	6.600	31.500	Pe-cm2
			C-376 M1	46.000	28.000	26.000	40.100	27.500	12.600	2.102	8.000	16.900	Pe-cm2
			C-381 M1	57.600	30.000	12.400	24.800	NP	NP	2.211	7.900	16.800	Pe-cm2
			C-386 M1	54.100	34.700	11.200	15.100	NP	NP	2.198	8.200	14.900	Pe-cm2
			C-391 M1	0.000	41.700	58.300	32.000	NP	NP	1.900	17.600	3.900	Pe-cm2
			C-396 M2	46.400	31.000	22.600	33.200	24.900	8.300	1.892	13.200	10.200	Pe-cm2
			C-401 M1	48.500	36.700	14.800	21.200	NP	NP	2.114	9.500	28.400	Pe-cm2
			C-406 M1	59.200	32.400	8.400	22.100	NP	NP	2.167	6.700	20.100	Pe-cm2
			C-411 M1	51.500	33.000	15.500	23.100	NP	NP	2.129	8.200	18.700	Pe-cm2
			C-416 M1	38.700	30.200	31.100	32.500	26.300	6.200	1.988	9.400	13.200	Pe-cm2
C-421 M1	25.000	35.000	40.000	25.800	20.100	5.700	1.961	12.600	7.000	Pe-cm2			
C-426 M1	23.000	37.800	39.200	31.800	24.100	7.700	1.981	14.100	7.200	Pe-cm2			
C-431 M1	11.800	43.900	44.300	33.300	26.300	7.000	1.948	15.100	6.700	Pe-cm2			
C-436 M1	24.100	33.600	42.300	20.800	NP	NP	1.936	16.700	5.200	Pe-cm2			
C-441 M1	41.500	35.800	22.700	29.500	NP	NP	2.098	7.400	23.700	Pe-cm2			
C-446 M1	64.300	18.800	16.900	30.700	NP	NP	2.031	8.000	18.000	Pe-cm2			
C-451 M1	39.600	27.200	33.200	41.200	24.300	16.900	1.908	11.800	8.900	Pe-cm2			
C-456 M1	41.400	22.800	35.800	38.200	26.900	11.100	2.015	9.900	11.700	Pe-cm2			
C-461 M1	44.300	36.400	19.500	17.800	NP	NP	2.051	9.500	20.100	Pe-cm2			
C-466 M1	29.500	38.700	31.800	19.900	NP	NP	2.024	11.600	10.100	Pe-cm2			
C-471 M1	49.400	36.500	14.100	22.400	NP	NP	2.076	10.800	15.700	Qh-a1			
C-476 M1	41.900	40.000	16.100	24.600	NP	NP	2.205	9.320	20.000	Qh-a1			
C-481 M1	56.300	32.700	11.000	20.200	NP	NP	2.152	7.220	24.700	Qh-a1			
C-486 M1	40.900	40.200	18.900	37.300	30.100	7.200	2.077	9.770	16.700	Qh-a1			
C-491 M1	58.900	32.000	9.300	23.700	NP	NP	2.137	9.000	17.800	Qh-a1			
C-496 M1	51.700	20.300	28.000	35.900	NP	NP	2.101	7.800	32.100	Qh-a1			
C-501 M1	34.100	38.700	27.200	30.000	23.800	6.200	1.950	12.500	9.500	Qh-a1			
C-506 M1	43.200	40.500	16.300	20.700	NP	NP	1.896	9.850	10.400	Qh-a1			
C-511 M1	44.700	29.100	26.200	32.800	NP	NP	2.095	11.700	16.100	Qh-a1			
C-516 M1	8.000	39.300	52.700	27.900	19.700	8.200	1.932	14.200	5.100	Qh-a1			
C-521 M1	38.800	32.100	29.100	35.500	NP	NP	2.067	12.100	15.100	Qh-a1			
C-526 M1	39.400	39.300	21.300	28.400	NP	NP	1.966	16.100	7.100	Qh-a1			
121	ESTUDIO DEFINITIVO DEL MEJORAMIENTO DE LA CARRETERA HUÁNUCO - COMOCOCCHA, SECTOR: HUÁNUCO - LA UNIÓN - HUALLANCA SUB TRAMO II	Inicio: 76°43'12.64"W, 9°38'55.78"S, 2985 msnm; Intermedio: 76°48'06.53"W, 9°49'37.74"S, 3205 msnm; Fin: 76°56'19.60"W, 9°53'06.17"S, 3643 msnm.	C-531 M1	40.300	43.900	15.200	37.600	30.600	7.000	1.883	11.200	8.500	Qh-a1
			C-536 M1	49.300	42.300	8.400	16.700	NP	NP	2.118	8.400	24.300	Pe-cm2
			C-541 M1	55.400	37.200	7.400	28.700	NP	NP	2.089	6.390	17.700	Pe-cm2
			C-546 M1	68.100	15.700	16.200	42.100	26.100	16.000	1.974	9.800	13.600	Pe-cm2
			C-551 M1	0.000	61.400	38.600	16.100	12.000	4.300	2.005	10.000	7.200	Pe-cm2
			C-556 M1	6.800	37.300	55.900	31.700	NP	NP	1.831	13.220	4.900	Pe-cm2
			C-561 M1	58.600	27.500	13.900	36.100	23.200	13.100	2.109	7.100	19.300	Pe-cm2
			C-566 M1	52.500	28.800	18.700	19.600	NP	NP	2.042	8.600	20.500	Pe-cm2
			C-571 M1	40.300	43.300	16.400	25.100	NP	NP	2.093	10.100	19.100	Pe-cm2
			C-576 M1	41.700	42.000	16.300	32.100	27.900	4.300	1.992	10.200	17.800	Pe-cm2
			C-581 M1	38.900	35.100	26.000	17.100	NP	NP	1.994	8.670	15.500	Pe-cm2
			C-586 M1	58.100	27.300	14.600	22.900	NP	NP	2.095	7.000	24.000	Pe-cm2
			C-591 M2	39.600	31.800	28.600	23.400	NP	NP	2.031	8.900	14.100	Pe-cm2
			C-596 M1	49.400	34.600	16.000	38.900	NP	NP	2.054	7.180	22.500	Pe-cm2
			C-601 M1	59.100	28.300	12.400	22.500	NP	NP	1.975	9.300	19.800	Pe-cm2
			C-606 M1	56.300	27.600	16.100	22.600	NP	NP	2.201	6.700	28.700	Pe-cm2
C-611 M1	55.500	17.100	27.400	33.000	23.800	9.200	2.067	9.600	16.500	Pe-cm2			
C-616 M1	62.600	14.900	22.500	31.000	27.400	3.600	2.156	7.500	27.600	Pe-cm2			
C-621 M1	56.900	28.300	14.800	39.400	25.100	14.300	2.098	8.500	16.800	Pe-cm2			
C-626 M1	5.900	29.700	64.400	35.600	NP	NP	1.827	13.140	5.000	Pe-cm2			
C-631 M1	11.300	36.800	49.900	42.100	19.800	22.100	1.922	12.700	7.900	Pe-cm2			
C-636 M1	36.900	39.100	24.000	39.500	NP	NP	1.983	8.950	9.500	Pe-cm2			
C-641 M1	0.000	44.700	55.300	50.100	30.500	19.600	1.783	24.700	4.600	Qh-a1			
C-646 M1	52.700	27.800	19.500	25.600	NP	NP	2.073	9.200	23.600	Qh-a1			
C-651 M1	2.500	40.300	57.200	36.900	24.900	12.000	1.794	16.500	4.000	Qh-a1			
C-656 M1	0.000	43.600	56.400	49.200	31.100	18.100	1.766	17.200	3.500	Qh-a1			
C-661 M1	57.600	25.100	17.300	27.000	16.200	10.800	2.233	8.900	24.800	Qh-a1			
C-666 M1	70.500	18.100	11.400	25.600	NP	NP	2.193	7.700	34.200	Qh-a1			



121			C-671 M1	54.600	32.600	12.800	29.700	NP	NP	2.111	12.100	17.100	Qh-al	
			C-675 M1	18.400	73.300	8.300	29.100	14.500	14.800	2.045	11.950	17.500	Qp-tu	
			C-676 M1	49.500	37.500	13.000	23.900	15.400	8.500	2.207	9.700	26.700	Ks-ju	
			C-681 M1	42.600	30.400	27.000	26.000	15.900	10.100	2.089	10.600	15.000	Ks-ju	
			C-686 M1	36.800	40.800	22.400	15.200	NP	NP	1.986	11.500	15.000	Ks-ce	
			C-691 M1	50.500	21.000	28.500	29.500	NP	NP	2.090	12.000	12.200	Ks-ce	
			C-696 M1	53.900	27.200	18.900	25.700	18.600	7.100	2.118	10.500	19.500	Ks-ju	
			C-701 M2	63.900	21.800	14.300	21.700	15.400	6.300	2.075	11.900	13.900	Ks-ce	
			C-706 M1	54.700	27.700	17.600	26.500	NP	NP	2.009	12.300	10.000	Ks-ce	
			C-711 M1	65.500	24.800	10.100	24.600	17.200	7.400	2.131	9.800	24.100	Ks-ju	
			C-716 M1	59.700	29.300	11.000	21.300	13.600	7.700	2.121	8.700	19.300	Ks-ju	
			C-721 M1	55.200	27.300	17.500	29.500	27.100	2.400	2.161	7,7	27.000	Ks-ju	
			CA-083 M1	37.400	25.700	36.900	14.500	25.300	9.200	2.070	8.300	20.400	Ks-ce	
			C-731 M1	59.900	23.400	16.700	23.300	19.800	3.500	2.151	7.900	23.200	Ks-ce	
			C-736 M1	59.600	22.700	17.700	45.900	34.100	11.800	2.120	9.900	17.500	Ri-chi	
			C-741 M1	17.500	21.900	60.600	53.700	35.700	18.000	1.911	21.900	4.600	Ri-chi	
			C-745 M1	50.200	20.500	29.300	28.700	22.200	6.500	2.141	7.300	52.500	Ki-oy	
			C-751 M1	54.300	23.700	22.000	13.800	18.200	13.600	2.109	12.800	18.000	Ki-oy	
			C-756 M1	35.800	18.200	46.000	44.600	29.500	15.100	2.076	12.700	13.200	Ri-chi	
			C-761 M1	47.600	44.300	8.300	25.600	12.200	13.400	2.098	10.200	17.800	Ri-chi	
			C-766 M1	38.900	38.500	22.600	28.600	20.400	8.200	2.110	11.700	17.000	Qh-al	
			C-771 M1	49.900	29.400	20.700	21.200	NP	NP	2.082	7.500	23.900	Qh-al	
			CA-090 M2	44.800	32.100	23.300	32.400	26.700	5.700	1.891	11.300	8.800	Qh-al	
122	CREACIÓN DEL SERVICIO DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LAS PRINCIPALES CALLES DEL BARRIO AYANCOCHA DEL CENTRO POBLADO JUAN JOSÉ CRESPO Y CASTILLO DE AYANCOCHA, DISTRITO DE AMBO, PROVINCIA DE AMBO -HUÁNUCO	Inicio: 76°12'32.48"W, 10°06'43.56"N, 2064 msnm; Fin: 76°12'29.96"W, 10°06'23.68"N, 2044 msnm.	C-01	11.700	60.570	27.730	29.000	15.870	11.130				Q-al	
			C-02	11.970	60.760	27.270	29.800	16.180	11.620					Q-al
			C-03	42.200	45.200	12.700	18.880	14.010	4.870	2.122	7.810	19.340		Q-al
			C-04	31.650	46.650	21.700	21.850	18.150	3.700					Q-al
			C-05	4.700	61.070	34.230	38.200	21.060	17.140					Q-pa
			C-06	20.440	59.520	20.040	35.000	28.880	6.120	2.114	8.250	16.000		Q-pq
			C-07	20.480	58.400	21.120	14.800	20.310	14.490					Q-al
			C-08	16.080	52.720	31.200	35.500	20.830	12.670					Q-al
			C-09	13.720	61.560	24.720	32.340	19.380	12.960					Q-al
			C-10	20.120	58.800	21.080	14.450	22.030	12.420	2.132	7.000	18.110		Q-al
123	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VIAL INTERURBANA DE LAS CALLES PRINCIPALES Y ADYACENTES DEL DISTRITO DE TOMAYUCHUA - PROVINCIA DE AMBO - DEPARTAMENTO DE HUÁNUCO	Inicio: 76°12'43.74"W, 10°04'41.56"N, 2020 msnm; Fin: 76°12'57.52"W, 10°04'44.58"N, 2018 msnm.	C-01	0.000	69.860	30.140	25.700	22.500	3.200	2.115	7.600	24.000	Q-al	
			C-02	1.450	67.130	31.420	37.500	30.300	7.200					Q-al
			C-03	2.840	54.870	42.290	40.700	35.500	5.200					Q-al
			C-04	49.280	30.430	20.290	18.600	15.400	3.200					Q-al
			C-05	60.180	13.830	25.990	22.200	18.700	3.500					Q-al
			C-06	3.440	31.580	64.980	27.300	19.800	7.500	2.066	9.000	19.000		Q-al
			C-07	2.840	54.870	42.290	40.700	35.500	5.200					Q-al
			C-08	28.230	42.390	29.380	14.500	29.500	5.000					Q-al
			C-09	1.970	31.360	66.670	29.700	24.200	5.500					Q-al
			C-10	53.120	28.170	18.730	24.700	17.000	7.700					Q-al
			C-11	49.980	35.050	14.970	27.600	19.700	7.900					Q-al
			C-12	2.320	35.680	62.000	42.900	34.300	8.600					Q-al
			C-13	24.730	44.000	31.270	26.000	18.400	7.600					Q-al
			C-14	34.470	35.450	30.080	25.000	18.800	6.200					Q-al
			C-15	34.500	35.490	30.030	27.500	18.800	8.700	2.096	8.700	20.000		Q-al
			C-16	60.740	23.030	16.250	23.000	15.300	7.700					Q-al
			C-17	34.470	35.450	30.080	26.000	18.800	7.200					Q-al
			C-18	2.320	35.680	62.000	42.900	34.300	8.600					Q-al
			C-19	34.500	35.490	30.030	27.500	18.800	8.700					Q-al
			C-20	49.980	35.050	14.970	27.800	19.700	8.100					Q-al
			C-21	53.120	28.170	18.730	24.200	17.000	7.200					Q-al
			C-22	49.280	30.430	20.290	18.600	15.400	3.200					Q-al
			C-23	49.980	35.050	14.970	27.900	19.700	8.200	2.020	8.000	19.500		Q-al
			C-24	56.270	37.690	6.040	19.100	17.300	1.900	2.195	5.400	17.000		Q-al
124	CREACIÓN DE CAMINO VICINAL TIEMPO INDEPENDENCIA - TIRQUICOCHA - RAURA - SAN MIGUEL DE CAURI - LAURICOCHA - HUÁNUCO	Inicio: 76°40'09.97"W, 10°21'23.16"N, 4006 msnm; Fin: 76°44'40.44"W, 10°26'48.69"N, 4614 msnm.	C-01 M2	32.460	8.560	58.980	33.000	22.000	11.000	1.710	10.800	7.300	Q-gh	
			C-04 M2	55.090	29.280	15.630	22.000	16.000	6.000	1.930	9.000	11.100		Q-gh
			C-06 M2	27.810	22.210	49.980	34.000	26.000	8.000	2.220	7.400	21.800		Ks-j
			C-12 M2	54.030	16.150	29.840	30.000	27.000	3.000	2.110	13.900	21.100		Ks-j
			C-15 M2	36.210	45.530	18.260	34.000	25.000	9.000	2.200	7.500	25.000		Ks-j
			C-19 M2	20.650	44.220	35.130	24.000	16.000	8.000	2.200	8.600	24.800		Ks-ce
			C-22 M2	44.510	26.650	28.840	26.000	16.000	10.000	2.190	8.100	19.700		Q-gh
			C-25 M2	43.410	31.620	26.980	29.000	26.000	3.000	2.100	7.900	24.400		Ks-ce
C-28 M2	33.600	36.680	29.720	35.000	29.000	6.000	2.190	8.300	23.900		Ks-i			
125	MEJORAMIENTO Y AVULACIÓN DE LOS SERVICIOS DE TRANSITABILIDAD DE PISTA Y VEREDAS DE LA LOCALIDAD DE GASHWAMPAMPA, DISTRITO DE SAN MIGUEL DE CAURI, PROVINCIA DE LAURICOCHA - REGIÓN HUÁNUCO	Inicio: 76°39'28.25"W, 10°12'49.17"N, 4104 msnm; Fin: 76°39'29.60"W, 10°12'31.96"N, 4102 msnm.	C-01	53.120	28.170	18.730	24.700	17.000	7.700	1.956	8.340	21.410	Ks-j	
			C-02	49.980	35.050	14.970	27.600	19.700	7.900	1.846	7.230	19.400		Ks-j
			C-03	2.320	35.680	62.000	42.900	34.300	8.600	2.123	7.650	19.600		Ks-j
			C-04	24.730	44.000	31.270	26.000	18.400	7.600	1.766	9.120	22.300		Ks-j
			C-05	34.470	35.450	30.080	25.000	18.800	6.200	1.879	6.970	18.540		Ks-j
			C-06	34.500	35.490	30.030	27.500	18.800	8.700	2.128	7.120	18.760		Ks-j
			C-07	60.740	23.030	16.250	23.000	15.300	7.700	2.035	8.700	20.000		Ks-j
			C-08	34.470	35.450	30.080	26.000	18.800	7.200	2.251	9.340	21.760		Ks-j
			C-09	2.320	35.680	62.000	42.900	34.300	8.600	1.981	8.760	20.250		Ks-j
			C-10	34.500	35.490	30.030	27.500	18.800	8.700	1.839	7.320	18.560		Ks-j
			C-11	49.980	35.050	14.970	27.300	19.700	7.600	1.941	7.890	18.890		Ks-j
			C-12	53.120	28.170	18.730	24.700	17.000	7.700	2.013	8.670	19.430		Ks-j
			C-13	49.980	35.050	14.970	27.100	19.700	7.400	2.020	8.000	19.500		Ks-j
126	CONSTRUCCIÓN DEL CAMINO VICINAL MARAYZONCOR - SANTO DOMINGO DE RONDOS HUALLAPARAC, DISTRITO DE SAN RAFAEL - AMBO - HUÁNUCO, TRAMO I	Inicio: 76°10'20.90"W, 10°18'26.23"N, 2659 msnm; Fin: 76°10'38.89"W, 10°17'45.62"N, 3272 msnm.	C-01	44.520	45.200	10.280	22.470	19.720	2.750	2.190	8.330	18.460	Pe-cme	
			C-02	57.800	29.100	13.100	27.060	23.720	3.340					Pe-cme
			C-03	20.450	48.770	30.780	25.540	21.810	1.730	2.120	8.950	18.340		Pe-cme
			C-04	28.180	37.020	34.800	27.340	25.150	2.190					Pe-cme
			C-05	50.050	31.630	18.320	32.630	27.110	5.520	2.070	9.360	22.190		Pe-cme
			C-06	38.400	36.460	25.140	26.700	23.520	3.180					Pe-cme
			C-07	28.930	32.450	38.620	23.770	21.190	2.580	2.120	9.010	15.250		Pe-cme
			C-08	21.710	54.940	23.330	10.270	23.360	6.910					Pe-cme
			C-09	40.790	44.030	15.180	32.560	28.670	3.890	2.070	9.400	21.060		Pe-cme
			C-10	22.210	52.480	25.320	32.120	22.390	9.730					Pe-cme
			C-11	37.300	38.870	24.030	24.830	21.130	3.700	2.310	5.130	32.660		Pe-cme



127	CONSTRUCCIÓN DEL CAMINO VECINAL MARAYZONDO - SANTO DOMINGO DE BONDOS HUALLAPARAC, DISTRITO DE SAN RAFAEL - AMBO - HUÁNUCO, TRAMO II (Rondos a Huallapara)	Início: 78°10'38.89"W, 10°17'45.42"S, 3272 metros; Fin: 78°11'01.09"W, 10°17'40.22"S, 3227 metros.	C-12	24.880	45.570	29.550	19.530	18.630	0.900				C-a
			C-13	42.760	32.820	24.420	30.280	21.130	9.150	2.220	6.570	18.020	C-a
			C-14	39.020	29.030	31.950	21.920	19.410	2.510				C-a
			C-15	5.300	28.040	66.660	27.960	21.440	6.520	2.000	12.470	17.220	C-a
			C-16	64.850	13.300	21.850	25.260	38.040	7.220				C-a
			C-17	40.300	40.850	19.050	22.160	19.840	2.320				C-a
			C-18	49.260	36.330	14.430	26.510	22.790	3.720	2.069	9.400	20.020	C-a
			C-19	6.320	40.630	53.050	21.220	17.150	4.070				C-a
			C-20	11.280	28.290	60.430	28.950	18.820	10.130	2.120	6.960	15.560	C-a
			C-21	29.300	38.870	31.830	27.470	24.580	2.890				C-a
			C-22	66.250	14.750	19.000	31.890	27.210	4.680	2.090	9.330	23.160	C-a
			C-23	59.700	28.100	12.200	33.910	25.090	8.820				C-a
			C-24	55.270	28.720	16.030	33.830	21.820	12.010	1.920	11.730	17.220	C-a
			C-25	52.040	14.940	33.020	36.710	25.580	11.130				C-a
			C-26	2.610	54.060	43.330	35.030	NP	NP	1.900	12.360	17.520	C-a
			C-27	43.310	28.470	28.220	35.510	21.920	11.590				C-a
128	MEJORAMIENTO DEL SERVICIO DE MOVILIDAD URBANA EN EL PERÍMETRO DE LA PLAZA DE ARMAS, JR. INCAS CUADRA 1V2, 06 ANCIAN CUADRA 1.3.3.3	Início: 78°48'08.37"W, 9°33'09.07"S, 3455 metros; Fin: 78°48'52.24"W, 9°32'56.87"S, 3457 metros.	C-1	4.190	39.210	56.600	27.220	15.160	12.060	1.865	9.590	6.580	Es-ju
			C-2	0.870	28.480	70.650	33.510	17.670	15.840	1.851	10.190	6.230	Es-ju
			C-4	5.610	36.800	57.590	35.550	17.410	18.140	1.875	10.380	7.160	Es-ju
			C-5	2.590	39.990	57.420	28.590	16.090	12.500				Es-ju
			C-1	14.320	37.920	47.770	37.230	29.960	7.270	1.835	15.650	12.240	Pe-e
129	RENOVACIÓN DE PLATAFORMA Y CUNETAS, ADQUISICIÓN DE SEÑALES DE TRÁFICO, EN EL LAJ SERVICIO DE TRANSITABILIDAD DE PANAJO, PROVINCIA PACHITEA, DEPARTAMENTO DE HUÁNUCO	Início: 75°58'27.67"W, 9°54'02.78"S, 2580 metros; Fin: 75°58'32.27"W, 9°53'47.88"S, 2573 metros.	C-2	27.170	45.610	27.220	36.090	33.280	2.770				Pe-e
			C-3	18.470	32.190	49.340	35.910	33.200	2.710	1.882	12.710	15.320	Pe-e
			C-4	2.870	16.600	80.530	40.660	35.350	5.310				Pe-e
			C-5	35.650	36.030	28.320	30.230	27.200	3.030	1.879	12.460	15.140	Pe-e
			C-6	26.360	35.500	38.140	30.970	26.950	4.020				Pe-e
130	CONSTRUCCIÓN DE PISTAS Y VEREDAS DE LOS JARDINES 9 DE OCTUBRE, MOLINO, CUBA, UNIÓN PANAD, CRESPO CASTILLO, SAN JORGE, APALLACUY, JOSÉ CARLOS MARIATEGUI, JERUSALEN Y CALLE ANGÉLICA DE LA LOCALIDAD DE MOLINO, DISTRITO DE MOLINO - PACHITEA - HUÁNUCO	Início: 76°02'04.98"W, 9°54'33.99"S, 2367 metros; Fin: 75°00'49.04"W, 9°54'42.42"S, 2375 metros.	C-7	5.450	78.990	15.560	NP	NP	NP	1.028	9.510	16.740	Pe-e
			C-8	16.350	34.320	49.330	39.950	31.890	8.060				Pe-e
			C-01	6.300	40.900	52.800	45.000	38.000	25.000				Pe-e
			C-02	2.600	43.400	54.000	24.000	22.000	2.000				Pe-e
			C-03	5.000	39.200	55.800	37.000	21.000	16.000	1.260	7.100	20.000	Pe-e
			C-04	2.700	42.800	54.500	39.000	21.000	18.000				Pe-e
			C-05	53.600	32.300	14.100	24.000	21.000	3.000				Pe-e
			C-06	53.600	32.300	14.100	25.000	21.000	2.000				Qr-al
			C-07	7.000	36.100	56.900	35.000	28.000	7.000	1.300	8.000	22.500	Qr-al
			C-08	7.000	36.000	57.000	24.000	21.000	3.000				Qr-al
			C-09	7.000	35.900	57.100	22.000	20.000	2.000				Qr-al
			C-10	53.600	32.100	14.300	21.000	21.000	0.000				Pe-e
			C-11	53.700	32.000	14.300	25.000	19.000	6.000	2.210	5.100	19.800	Pe-e
			C-12	47.200	45.100	7.700	26.000	20.000	6.000				Pe-e
			C-13	64.500	18.200	17.300	23.000	19.000	4.000				Pe-e
			C-14	30.700	56.800	12.500	22.000	16.000	6.000				Qr-al
131	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD EN LA CIUDAD DE CAYNA, DISTRITO DE CAYNA, PROVINCIA DE AMBO - HUÁNUCO	Início: 76°23'12.02"W, 10°16'28.40"S, 3282 metros; Fin: 76°23'18.69"W, 10°16'16.03"S, 3318 metros.	C-15	64.300	18.300	17.600	20.000	21.000	-1.000	2.160	4.800	23.600	Qr-al
			C-16	7.000	36.000	57.000	21.000	20.000	1.000				Qr-al
			C-17	47.300	45.200	7.700	25.000	20.000	3.000				Pe-e
			C-18	47.600	45.400	7.800	24.000	19.000	5.000	2.170	7.300	20.600	Pe-e
			C-01	48.510	28.910	22.560	0.000	0.000	0.000	2.116	7.600	24.000	C-a
			C-02	74.690	20.810	4.300	0.000	0.000	0.000	2.290	5.900	11.000	C-a
			C-03	19.980	33.240	46.780	28.000	20.500	7.500	2.040	13.100	2.000	C-a
			C-04	45.870	27.270	26.860	30.800	26.500	4.300				C-a
			C-05	46.730	31.810	21.460	24.200	21.300	2.900	2.036	8.700	20.000	C-a
			C-06	53.070	23.530	23.400	20.800	17.500	3.300	2.020	8.000	19.500	C-a
			C-07	48.530	28.910	22.560	22.000	19.500	2.500	2.115	7.600	24.000	C-a
			C-08	46.730	31.810	21.450	24.200	21.300	2.900	2.065	9.000	19.000	C-a
			C-09	65.230	16.230	18.540	18.200	15.800	2.400	2.185	7.000	23.500	C-a
132	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD DE LA CARRETERA TRAMO JULIALLA CALLAGAN MANZANO DEL DISTRITO DE MOLINO, PROVINCIA DE PACHITEA - DEPARTAMENTO DE HUÁNUCO	Início: 76°23'12.02"W, 10°16'28.40"S, 3282 metros; Fin: 76°23'18.69"W, 10°16'16.03"S, 3318 metros.	C-01	16.780	40.510	42.710	24.330	22.160	2.170	1.912	12.130	10.380	Pe-e
			C-02	31.430	53.910	14.660	NP	NP	NP				Pe-e
			C-03	5.380	29.220	67.400	27.960	22.360	5.600	1.679	18.140	6.280	Pe-e
			C-04	10.180	43.130	46.090	24.120	20.540	3.580				Pe-e
			C-05	10.520	44.550	44.930	25.360	23.170	2.190	1.830	15.990	7.810	Pe-e
			C-06	1.300	35.590	63.110	24.740	21.150	3.590				PE-g
			C-07	3.970	57.470	38.560	26.390	24.080	2.310	1.877	15.140	10.710	PE-g
			C-08	5.900	57.940	38.160	NP	NP	NP				PE-g
			C-09	5.960	57.270	56.770	27.420	25.490	3.930	1.786	17.150	8.920	Pe-e
			C-10	1.320	56.740	41.940	26.390	22.170	4.420				Pe-e
			C-11	8.830	36.300	54.870	25.500	22.220	3.280	1.850	19.100	8.080	Pe-e
133	CREACIÓN DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN EL BARRIO BUENOS AIRES, EN LA LOCALIDAD DE AMBO - DEPARTAMENTO DE HUÁNUCO	Início: 76°12'21.78"W, 10°07'55.04"S, 2125 metros; Fin: 76°12'29.24"W, 10°07'51.10"S, 2060 metros.	C-01	21.910	48.860	29.210	19.000	12.000	7.000				Q-al
			C-02	26.690	45.350	27.960	12.000	9.000	3.000	1.771	5.780	22.600	Q-al
			C-03	20.550	44.540	34.920	14.000	10.000	4.000				Q-al
			C-04	13.520	50.570	35.910	17.000	12.000	5.000				Q-al
			C-05	11.030	51.130	37.840	21.000	15.000	6.000	1.583	6.690	14.260	Q-al
			C-06	22.520	50.410	27.070	23.000	19.000	4.000				Q-al
	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD DE LA AV. HEROES DE JACTAY -	Início: 76°15'06.57"W,	C-01	43.340	39.100	17.560	27.180	19.120	8.060	2.069	5.130	29.700	PE-e
			C-02	53.440	18.460	28.100	26.290	17.990	8.300	2.072	8.650	27.820	PE-e
			C-03	36.980	34.400	28.620	17.680	13.980	3.700	2.061	8.760	28.450	PE-e
			C-04	31.610	30.010	36.380	24.610	16.960	7.650	1.943	10.150	24.260	PE-e
			C-05	46.770	23.400	29.830	26.260	18.670	7.590	1.973	9.890	37.420	PE-e
			C-06	21.890	50.680	27.430	NP	NP	NP	1.978	9.130	21.150	PE-e
			C-07	32.950	40.170	26.840	NP	NP	NP	1.998	8.160	22.820	PE-e
			C-08	55.700	30.060	14.240	28.890	23.090	5.800	1.983	9.080	21.610	PE-e
			C-09	36.650	33.140	30.210	NP	NP	NP	1.974	8.610	20.070	PE-e



134	AV. CIRCONVALACIÓN, TRAMO CRUZ VERDE - LOMA BLANCA - CERRO JACTAY, DISTRITO Y PROVINCIA DE HUÁNUCO (TRAMO I)	9°56'00.26"S, 1941 metros; Fin: 76°15'01.57"W, 9°55'32.02"S, 2029 metros.	C-10	67.400	24.720	7.880	NP	NP	NP	1.968	8.940	20.910	PE-e	
			C-11	44.120	42.990	12.890	NP	NP	NP	2.040	10.720	27.170	PE-e	
			C-12	43.470	34.630	21.920	31.090	23.490	7.600	2.073	8.910	23.800	PE-e	
			C-13	32.120	27.660	40.220	26.720	19.540	7.180	1.958	13.060	12.900	PE-e	
			C-14	53.960	26.370	19.670	24.450	16.650	7.800	2.064	9.470	12.210	PE-e	
			C-15	14.860	21.870	63.270	26.060	18.420	7.640	1.834	14.630	8.300	PE-e	
			C-16	18.570	30.470	50.960	22.550	15.410	7.140	1.851	12.860	11.500	PE-e	
			C-17	2.490	4.220	93.290	16.540	11.960	4.580	1.763	14.620	8.700	PE-e	
			C-18	35.140	27.330	57.550	17.890	12.400	5.490	1.986	10.860	11.500	PE-e	
			C-19	58.470	16.260	25.270	23.980	15.360	8.620	2.011	10.230	10.960	PE-e	
135	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD DE LA AV. HEROES DE JACTAY - AV. CIRCONVALACIÓN, TRAMO CERRO JACTAY-LAS MORAS Y PUENTE VIA CRUZES, DISTRITO Y PROVINCIA DE HUÁNUCO (TRAMO II)	Inicio: 76°15'01.57"W, 9°55'32.01"S, 2029 metros; Fin: 76°14'45.98"W, 9°55'08.60"S, 1988 metros.	C-01	6.310	9.080	84.610	29.890	21.810	8.080	1.668	14.880	7.180	Qr-al	
			C-02	9.750	12.920	77.330	28.020	19.510	8.510	1.711	14.570	7.320	PE-e	
			C-03	49.620	12.360	38.020	28.380	21.300	7.080	1.973	9.920	10.600	PE-e	
			C-04	10.610	16.670	72.720	23.460	17.650	5.810	1.768	14.650	8.300	Qr-al	
			C-05	68.810	21.050	10.140	23.540	NP	NP	2.184	4.940	24.610	PE-e	
			C-06	64.060	19.580	16.360	27.620	22.080	5.540	2.008	8.840	19.650	PE-e	
			C-07	37.560	21.430	41.010	20.890	7.300	13.590	1.839	12.740	12.400	PE-e	
136	CONSTRUCCIÓN DE LA CARRETERA VECINAL BELLA BELLA ALTA RIO TIGRE - JUAN GARCÍA (TRAMO I) DEL DISTRITO DE LA MORADA, PROVINCIA DE HUÁNUCO	Inicio: 76°07'49.18"W, 9°52'07.69"S, 821 metros; Fin: 76°03'36.27"W, 9°52'38.14"S, 886 metros.	C-01	31.210	40.230	28.540	28.350	NP	NP				Pe-cm	
			C-02	17.000	10.530	72.470	33.700	NP	NP	1.742	8.700	8.200		Pe-cm
			C-03	28.880	18.090	55.030	25.940	NP	NP					Pe-cm
137	MEJORAMIENTO DE LOS SERVICIOS DE TRANSITABILIDAD VEHICULAR Y PEATONAL EN LA AVENIDA SAN FAUSTO EN LA LOCALIDAD DE CAYUWANA DEL DISTRITO DE PILCO MARCA - PROVINCIA DE HUÁNUCO	Inicio: 76°14'49.20"W, 9°57'50.07"S, 1964 metros; Fin: 76°14'54.55"W, 9°57'33.17"S, 1918 metros.	C-01	43.910	42.920	13.160	11.520	1.220	10.300	2.147	7.990	26.700	Qr-al	
			C-03	43.080	42.440	14.480	16.760	15.040	1.720	2.094	6.850	23.560	Qr-al	
			C-05	45.180	42.380	12.440	10.310	2.470	7.840	2.120	7.850	23.550	Qr-al	
			C-07	7.000	62.920	30.080	26.720	20.160	6.560	2.040	10.160	16.600	Qr-al	
			C-09	44.800	42.960	12.240	10.880	2.560	8.320	2.135	7.200	23.700	Qr-al	
			C-11	48.910	35.920	15.160	16.860	15.700	1.160	2.120	7.100	21.240	Qr-al	
138	RECUPERACIÓN DEL SERVICIO DE MOVILIDAD URBANA EN LAS VÍAS LOCALES DE LA AV. PERÚ Y AV. JAVIER HERRERA PÉREZ DEL A.A.H.H. SAN LUIS.	Inicio: 76°14'32.01"W, 9°56'52.15"S, 1931 metros; Fin: 76°14'13.16"W, 9°56'31.52"S, 1854 metros.	C-01	14.840	42.150	43.030	23.760	17.500	8.260	2.740	7.300	13.200	PE-e	
			C-02	16.510	39.970	43.900	25.120	23.370	1.790	2.130	7.500	12.400	PE-e	
			C-03	22.980	52.040	24.980	21.470	16.480	4.990	2.220	7.750	11.700	PE-e	
			C-04	62.750	9.110	28.140	23.840	17.940	5.900	2.210	6.100	11.500	PE-e	
			C-05	22.500	38.210	39.290	22.770	16.370	6.400	1.980	7.250	11.200	PE-e	
			C-06	22.560	38.030	39.450	22.490	11.010	11.480	1.977	5.410	8.800	PE-e	
			C-07	35.160	13.517	51.323	24.000	18.390	5.610	1.959	7.000	11.000	PE-e	
			C-08	29.880	11.490	58.630	23.200	18.350	4.850	2.012	6.600	10.600	PE-e	
			C-09	46.250	10.580	43.170	23.860	18.550	5.310	2.112	4.300	11.000	PE-e	
			C-10	53.250	41.600	5.150	23.540	18.390	5.150	2.117	6.700	11.500	PE-e	
			C-11	46.310	6.890	46.780	23.870	18.010	5.860	1.983	6.150	10.400	PE-e	
			C-12	52.290	8.070	39.640	22.730	17.840	4.890	1.943	7.300	8.500	PE-e	
			C-13	43.490	7.490	49.020	22.860	17.200	5.660	2.010	6.300	7.000	PE-e	
			C-14	59.710	6.820	33.460	23.450	17.330	6.120	2.123	7.580	11.400	PE-e	
			C-15	48.280	8.310	43.390	22.350	16.220	6.130	2.200	7.120	7.800	PE-e	
139	CONSTRUCCIÓN DE LAS VÍAS URBANAS DE LA LOCALIDAD DE LA MORADA, DISTRITO DE LA MORADA, PROVINCIA DE HUÁNUCO	9°57'38.15"S, 1925 metros; Fin: 76°04'49.42"W, 9°56'03.47"S, 1878 metros.	C-01	48.510	28.930	22.560	0.000	0.000	0.000	2.115	7.690	24.000	Qr-al	
			C-05	34.470	35.450	30.080	26.000	18.800	7.200	2.053	8.700	20.000	Qr-al	
140	MEJORAMIENTO DEL SERVICIO VIAL URBANO EN LAS CALLES DEL A.A.H.H. MANUEL GONZÁLEZ PRADA, DEL DISTRITO DE AMARILLOS - PROVINCIA DE HUÁNUCO	Inicio: 76°13'38.90"W, 9°55'03.67"S, 1886 metros; Fin: 76°13'41.80"W, 9°54'55.18"S, 1882 metros.	C-01	55.400	27.300	17.300	22.870	17.040	5.830	2.145	7.800	28.100	Qr-al	
			C-02	48.450	32.050	19.500	20.380	15.060	5.320				Qr-al	
			C-03	62.000	26.500	11.500	20.450	16.140	4.310				Qr-al	
			C-04	15.700	71.900	12.400	21.890	15.790	6.100				Qr-al	
			C-05	51.800	29.800	18.400	22.810	17.110	5.700	2.231	7.795	27.840	Qr-al	
			C-06	56.300	31.100	12.000	23.590	18.420	5.170				Qr-al	
141	VEREDAS EN LAS CALLES MANUEL GONZÁLEZ PRADA Y VEREDAS Y DRENAJE PLUVIAL EN LA AV. LAS AMÉRICAS CORAS, 6, 7 Y 8 - AUCAYACI, DISTRITO DE JOSÉ CRISTÓ Y CASTILLO - LICHMO PRADO - HUÁNUCO	9°47'13.95"S, 2150 metros; Fin: 76°06'42.64"W, 8°55'55.00"S, 572 metros.	C-02	1.220	17.230	81.550	27.490	22.600	4.890	1.740	9.000	10.300	PE-e	
			C-04	25.010	33.260	41.750	46.300	36.750	9.550	1.975	9.010	24.000	PE-e	
142	CONSTRUCCIÓN DE LAS VÍAS URBANAS DE LA LOCALIDAD DE LA MORADA, DISTRITO DE LA MORADA, PROVINCIA DE HUÁNUCO	Inicio: 76°07'49.18"W, 9°52'07.69"S, 821 metros; Fin: 76°07'01.82"W, 8°55'56.67"S, 568 metros.	C-01 M2	47.670	38.500	13.830	25.220	15.890	9.360				Qr-al	
			C-01 M3	0.000	31.430	68.570	30.000	19.310	10.690	1.926	10.530	8.280	Qr-al	
			C-02 M2	43.410	38.370	19.200	26.540	14.680	11.860				Qr-al	
			C-02 M3	0.000	28.430	71.570	30.960	16.540	14.420				Qr-al	
			C-03 M2	46.110	39.140	14.730	25.420	16.360	9.000				Qr-al	
143	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD DE LA AVENIDA INDEPENDENCIA, CUADRAS 01 AL 07, DISTRITO DE JOSÉ CRISTÓ Y CASTILLO, PROVINCIA DE LICHMO PRADO - HUÁNUCO	Inicio: 76°07'08.19"W, 8°56'08.04"S, 569 metros; Fin: 76°06'42.64"W, 8°55'55.00"S, 572 metros.	C-01	16.110	70.210	13.470	11.000	8.000	3.000	1.628	9.200	13.300	Qr-al	
			C-02	22.510	52.590	24.890	12.000	9.000	3.000				Qr-al	
			C-03	10.040	57.970	31.990	10.000	8.000	2.000				Qr-al	
			C-04	49.490	40.570	9.540	19.000	16.000	3.000	1.608	6.300	10.600	Qr-al	
			C-05	83.140	17.270	3.590	23.000	NP	NP				Qr-al	
			C-06	26.050	60.430	13.540	9.000	8.000	1.000				Qr-al	
			C-01	0.500	34.750	64.750	33.260	28.090	5.170				Qr-al	
			C-02	0.000	27.110	72.890	36.670	30.400	6.270				Qr-al	
			C-03	4.120	44.180	51.700	36.520	28.190	8.330				Qr-al	
			C-04	0.910	34.960	64.130	32.200	26.790	5.410	1.830	4.900	13.380	Qr-al	
144	MEJORAMIENTO DEL SERVICIO DE TRANSITABILIDAD VIAL INTERURBANA DEL CAMINO VECINAL TRAMO EMP HUSOS-ALTO HUAMUCO (NUEVA PALESTINA)-PUENTE MASHACA DEL DISTRITO DE LA MORADA, PROVINCIA DE MARAÑÓN, DEPARTAMENTO DE HUÁNUCO	Inicio: 76°19'20.48"W, 8°40'27.62"S, 585 metros; Fin: 76°16'59.34"W, 8°38'23.08"S, 530 metros.	C-05	6.190	25.930	67.880	38.170	34.690	3.480				Qr-al	
			C-06	0.280	22.950	76.770	35.060	27.830	7.230				Qr-al	
			C-07	0.100	56.170	43.730	26.390	19.070	7.320				Qr-al	
			C-08	6.750	20.750	72.500	39.950	33.090	6.860	1.750	4.500	13.370	Qr-al	
			C-09	0.140	40.540	59.320	35.300	31.110	4.190				Qr-al	
			C-10	4.480	43.870	51.650	19.270	31.980	7.290				Qr-al	
			C-11	0.310	42.540	57.150	NP	NP	NP				Qr-al	
			C-12	0.540	27.570	71.890	27.150	19.740	7.410	1.950	4.750	15.540	Qr-al	
			C-13	39.110	19.110	41.560	42.260	37.360	4.900				Qr-al	
			C-14	7.210	48.310	44.480	32.660	27.880	4.780				Qr-al	
			C-15	0.000	14.790	85.210	NP	NP	NP				Qr-al	
			C-16	1.620	54.070	44.310	NP	NP	NP	1.980	4.860	22.410	Qr-al	
145	MEJORAMIENTO Y AMPLIACIÓN DEL SERVICIO DE MOVILIDAD URBANA EN LAS VÍAS LOCALES DEL JR. ANCHAS Y LA AV. 28 DE JULIO EN EL DISTRITO DE HUACACHICO, PROVINCIA DE HUÁNUCO	Inicio: 76°19'20.48"W, 8°40'27.62"S, 585 metros; Fin: 76°16'59.34"W, 8°38'23.08"S, 530 metros.	C-01	27.060	46.370	26.570	NP	NP	NP				Pe-cm	
C-02	32.750	53.350	13.900	NP	NP	NP					Pe-cm			
C-03	24.690	30.620	44.690	NP	NP	NP	1.024	7.500	19.410		Pe-cm			
C-04	37.760	47.130	15.130	NP	NP	NP					Pe-cm			
C-05	31.130	40.590	28.280	NP	NP	NP					Pe-cm			
C-06	28.240	39.850	31.910	NP	NP	NP					Pe-cm			



MARANON, DEPARTAMENTO DE HUANCJO			C-07	41.510	28.630	27.860	NP	NP	NP				Fe-cm
			C-08	21.850	25.380	52.840	NP	NP	NP				Fe-cm
146	MEJORAMIENTO DEL CAMINO VECINAL HUARASANI - LAURICOCHA - 8 DE DICIEMBRE INDEPENDENCIA, DISTRITO DE SAN MIGUEL DE CAJARI - LAURICOCHA (TRAMO I)	Inicio: 76°40'48.94"W, 10°17'28.26"S, 4183 msnm; Fin: 76°39'31.14"W, 10°18'57.04"S, 3863 msnm.	C-01	40.100	45.100	14.800	19.800	12.800	7.000	1.870	14.100	16.600	Q-gh
			C-02	15.700	34.200	50.100	14.000	23.600	10.400				Q-gh
			C-03	21.400	58.300	20.300	12.500	17.800	14.700	1.940	12.800	16.400	Q-gh
			C-04	20.800	52.200	27.000	29.800	18.800	11.000				Q-gh
			C-05	44.800	40.600	14.600	10.900	18.400	12.500				Q-gh
			C-06	40.400	47.500	12.100	13.600	20.900	12.700				Q-gh
			C-07	34.700	43.100	22.200	29.800	20.100	9.700	2.090	12.900	35.200	Q-gh
			C-08	17.700	68.500	13.800	43.100	27.500	15.800				Q-gh
			C-09	28.200	38.000	33.800	26.900	17.400	9.500				Q-gh
			C-10	9.200	39.100	51.700	10.900	21.200	9.700				Q-gh
			C-11	25.100	29.900	45.000	28.900	15.700	13.200	1.750	16.500	15.100	Q-gh
			C-12	35.200	42.900	21.900	27.100	18.100	9.200				Q-gh
			C-13	22.400	46.300	31.300	42.200	27.700	14.500				Q-gh
			C-14	29.600	42.900	27.500	12.000	18.500	13.500				Q-gh
			C-15	40.900	44.200	14.900	19.200	26.100	13.100	2.020	13.800	35.500	Q-gh
			C-16	24.500	24.700	50.800	24.300	17.300	7.000				Q-gh
			C-17	26.600	56.800	16.600	17.000	30.700	6.300	1.820	16.700	18.100	Q-gh
			C-18	21.600	53.200	25.200	14.200	28.100	6.100				Q-gh
			C-19	12.200	36.900	50.900	13.300	23.400	9.900				KaP-c
			C-20	24.600	55.600	19.800	12.600	25.900	6.700				KaP-c
			C-21	20.100	49.700	30.200	41.000	31.700	9.300	2.134	8.700	34.800	KaP-c
			C-22	50.900	19.900	29.200	10.300	22.100	8.200				KaP-c
			C-23	50.400	31.100	18.500	13.600	10.000	3.600				KaP-c
			C-24	7.800	42.000	50.200	27.100	19.200	8.100				KaP-c
			C-25	30.200	54.900	14.900	40.100	31.600	8.700	1.610	18.100	14.300	KaP-c
147	MEJORAMIENTO DEL CAMINO VECINAL HUARASANI - LAURICOCHA - 8 DE DICIEMBRE INDEPENDENCIA, DISTRITO DE SAN MIGUEL DE CAJARI - LAURICOCHA (TRAMO II)	Inicio: 76°38'23.14"W, 10°20'04.61"S, 3655 msnm; Fin: 76°40'28.31"W, 10°21'27.46"S, 4035 msnm.	C-26	14.400	47.600	38.000	19.800	16.800	3.000	2.100	7.700	31.600	Q-gh
			C-27	41.200	38.500	18.300	14.400	22.600	11.800				Q-gh
			C-28	26.500	58.900	14.600	41.800	27.200	14.600	1.761	16.100	12.200	Q-gh
			C-29	13.600	35.800	50.600	29.800	16.600	13.200				Q-gh
			C-30	42.800	43.100	14.100	10.900	17.600	13.100	2.060	14.300	23.200	Q-gh
			C-31	30.900	49.100	20.000	27.800	17.400	10.400				Q-gh
			C-32	9.500	40.400	50.100	28.200	19.300	8.900				Q-gh
			C-33	38.400	39.600	22.000	11.600	27.800	3.800				Q-gh
			C-34	35.100	45.900	18.000	26.800	17.000	9.800				Q-gh
			C-35	9.200	39.100	51.700	14.000	22.400	11.600				Q-gh
			C-36	10.100	39.700	50.200	22.000	15.800	6.200				Q-gh
			C-37	35.100	51.600	13.300	16.900	22.300	14.600				Q-gh
			C-38	41.300	41.000	15.700	14.500	20.900	13.500				Q-gh

**Anexo C.** Códigos en Python de redes neuronales, algoritmos de predicción y recopilación de datos.

**Anexo C1.** Código de Red Neuronal Artificial (ANN)

```
import numpy as np; import pandas as pd
import matplotlib.pyplot as plt; import seaborn as sns; import tensorflow as tf
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, mean_absolute_error, r2_score
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, Dropout, GRU, BatchNormalization,
Concatenate, Input
from tensorflow.keras.optimizers import AdamW
from tensorflow.keras.callbacks import EarlyStopping, ReduceLROnPlateau
# Cargar datos
file_path = "data/CBR_dataset_aumentado_IA.csv"
df = pd.read_csv(file_path)
# Convertir CBR a float y limpiar
df["CBR"] = pd.to_numeric(df["CBR"], errors='coerce')
df = df.dropna()
# Balanceo del dataset
low_cbr = df[df["CBR"] < 10]
high_cbr = df[df["CBR"] > 30]
df_balanced = pd.concat([df, low_cbr, high_cbr],
axis=0).reset_index(drop=True)
# Data Augmentation Inteligente
df_augmented = df_balanced.copy()
df_augmented += np.random.normal(0, 0.005, df_augmented.shape)
df = pd.concat([df_balanced, df_augmented], axis=0).reset_index(drop=True)
# Separar variables
X = df.drop(columns=['CBR']).values
y = df['CBR'].values
# Dividir datos
X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.2,
random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.5,
random_state=42)
# Reshape para GRU
X_train_rnn = X_train.reshape((X_train.shape[0], 1, X_train.shape[1]))
X_val_rnn = X_val.reshape((X_val.shape[0], 1, X_val.shape[1]))
X_test_rnn = X_test.reshape((X_test.shape[0], 1, X_test.shape[1]))
# Callbacks
early_stopping = EarlyStopping(monitor='val_loss', patience=200,
restore_best_weights=True)
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.5, patience=100,
min_lr=1e-6)
# Arquitectura ANN + GRU
input_mlp = Input(shape=(X_train.shape[1],))
mlp = Dense(1024, activation='relu')(input_mlp)
mlp = BatchNormalization()(mlp)
mlp = Dropout(0.3)(mlp)
mlp = Dense(512, activation='relu')(mlp)
mlp = Dropout(0.3)(mlp)
mlp = Dense(256, activation='relu')(mlp)
```

```

mlp = Dense(128, activation='relu')(mlp)
input_rnn = Input(shape=(1, X_train.shape[1]))
rnn = GRU(256, activation='relu', return_sequences=True)(input_rnn)
rnn = Dropout(0.3)(rnn)
rnn = BatchNormalization()(rnn)
rnn = GRU(128, activation='relu', return_sequences=False)(rnn)
rnn = Dense(64, activation='relu')(rnn)
merged = Concatenate()([mlp, rnn])
output = Dense(1, activation='linear')(merged)
model = Model(inputs=[input_mlp, input_rnn], outputs=output)
model.compile(optimizer=AdamW(learning_rate=0.001), loss='mse',
metrics=['mae'])
# Entrenamiento
history = model.fit(
    [X_train, X_train_rnn], y_train,
    validation_data=([X_val, X_val_rnn], y_val),
    epochs=1000, batch_size=256, verbose=1,
    callbacks=[early_stopping, reduce_lr]
)
# Evaluación
y_pred = model.predict([X_test, X_test_rnn])
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)
mae = mean_absolute_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)
# Resultados
print(f"R²: {r2:.4f}")
print(f"MSE: {mse:.4f}")
print(f"RMSE: {rmse:.4f}")
print(f"MAE: {mae:.4f}")
# Guardar modelo
model.save("modelo_ANN.h5")
# ===== GRÁFICOS ===== #
# Estilo
sns.set(style="whitegrid")
# Gráfico de la pérdida (MSE)
plt.figure(figsize=(10, 5))
plt.plot(history.history['loss'], label='Pérdida de entrenamiento (MSE)')
plt.plot(history.history['val_loss'], label='Pérdida de validación (MSE)')
plt.title("Pérdida durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("MSE")
plt.legend()
plt.tight_layout()
plt.show()
# Gráfico del MAE
plt.figure(figsize=(10, 5))
plt.plot(history.history['mae'], label='MAE entrenamiento')
plt.plot(history.history['val_mae'], label='MAE validación')
plt.title("Error Absoluto Medio durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("MAE")
plt.legend()
plt.tight_layout()
plt.show()

```

```

# Comparación Real vs Predicho
plt.figure(figsize=(8, 8))
sns.scatterplot(x=y_test, y=y_pred.flatten(), alpha=0.6)
plt.plot([y_test.min(), y_test.max()], [y_test.min(), y_test.max()], 'r--')
plt.xlabel("CBR Real")
plt.ylabel("CBR Predicho")
plt.title("CBR Real vs. CBR Predicho")
plt.tight_layout()
plt.show()

#=====
import matplotlib.pyplot as plt
import seaborn as sns
import numpy as np

# === Gráfico de métricas ===
plt.figure(figsize=(10, 5))
# Gráfico 1: RMSE
plt.subplot(1, 3, 1)
plt.bar(['RMSE'], [rmse], color='#4CAF50')
plt.title("RMSE del Modelo")
plt.ylabel("Valor")
plt.grid(axis='y', linestyle='--', alpha=0.5)
plt.tight_layout()
plt.show()
# Gráfico 2: R²
plt.subplot(1, 3, 2)
plt.bar(['R²'], [r2], color='#2196F3')
plt.title("Coeficiente de Determinación R²")
plt.ylabel("Valor")
plt.grid(axis='y', linestyle='--', alpha=0.5)
plt.tight_layout()
plt.show()
import matplotlib.pyplot as plt
import seaborn as sns
# Filtrar solo columnas numéricas
correlacion = df.select_dtypes(include=['float64', 'int64']).corr()
# Gráfico de la matriz de correlación
plt.figure(figsize=(12, 10)) # Aumentar el tamaño del gráfico
sns.heatmap(
    correlacion,
    annot=True,
    cmap='coolwarm',
    fmt=".2f",
    linewidths=0.5,
    vmin=-1, vmax=1,
    cbar_kws={'shrink': 0.8} # Ajustar el tamaño de la barra de color
)
# Rotar las etiquetas del eje X e Y para mayor claridad
plt.xticks(rotation=45, ha='right', fontsize=10)
plt.yticks(rotation=0, fontsize=10)
plt.title("Matriz de Correlación", fontsize=14, weight='bold')
plt.tight_layout() # Ajustar automáticamente para evitar que se corten
elementos
plt.show()
# =====
import matplotlib.pyplot as plt
import numpy as np

```

```

# Crear el array de épocas correctamente
epochs = np.arange(0, len(history.history['mae']))
# === Gráfico del MAE ===
plt.figure(figsize=(10, 5))
plt.plot(epochs, history.history['mae'], label='MAE Entrenamiento')
plt.plot(epochs, history.history['val_mae'], label='MAE Validación')
plt.xticks(np.arange(0, len(epochs), 100)) # Mostrar las épocas cada 100
unidades
plt.title("Evolución del MAE durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("MAE")
plt.legend()
plt.grid(True, linestyle='--', alpha=0.5)
plt.tight_layout()
plt.show()
# === Gráfico del MSE ===
plt.figure(figsize=(10, 5))
plt.plot(epochs, history.history['loss'], label='MSE Entrenamiento')
plt.plot(epochs, history.history['val_loss'], label='MSE Validación')
plt.xticks(np.arange(0, len(epochs), 100))
plt.title("Evolución del MSE durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("MSE")
plt.legend()
plt.grid(True, linestyle='--', alpha=0.5)
plt.tight_layout()
plt.show()
# === Gráfico del RMSE ===
rmse_train = np.sqrt(history.history['loss'])
rmse_val = np.sqrt(history.history['val_loss'])
plt.figure(figsize=(10, 5))
plt.plot(epochs, rmse_train, label='RMSE Entrenamiento')
plt.plot(epochs, rmse_val, label='RMSE Validación')
plt.xticks(np.arange(0, len(epochs), 100))
plt.title("Evolución del RMSE durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("RMSE")
plt.legend()
plt.grid(True, linestyle='--', alpha=0.5)
plt.tight_layout()
plt.show()
# === Gráfico del R² ===
# El R² se calcula utilizando la varianza de los datos reales
r2_train = [1 - (mse / np.var(y_train)) for mse in history.history['loss']]
r2_val = [1 - (mse / np.var(y_val)) for mse in history.history['val_loss']]
plt.figure(figsize=(10, 5))
plt.plot(epochs, r2_train, label='R² Entrenamiento')
plt.plot(epochs, r2_val, label='R² Validación')
plt.xticks(np.arange(0, len(epochs), 100))
plt.title("Evolución del R² durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("R²")
plt.legend()
plt.grid(True, linestyle='--', alpha=0.5)
plt.tight_layout(); plt.show()

```

## Anexo C2. Código de Red Neuronal Recurrente LSTM (RNN-LSTM)

```

import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout, Input,
BatchNormalization
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
import matplotlib.pyplot as plt
# === Cargar datos ===
df = pd.read_csv("data/Datos_Sinteticos_triplicado_CBR.csv")
# === Normalizar el objetivo ===
scaler_cbr = MinMaxScaler()
df["CBR_norm"] = scaler_cbr.fit_transform(df[["CBR"]])
X = df.drop(columns=["CBR", "CBR_norm"]).values
y = df["CBR_norm"].values
X = X.reshape((X.shape[0], X.shape[1], 1))
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)
# === Modelo LSTM ===
model = Sequential([
    Input(shape=(X.shape[1], 1)),
    LSTM(64, return_sequences=True),
    Dropout(0.2),
    LSTM(32, return_sequences=True),
    Dropout(0.2),
    LSTM(16),
    BatchNormalization(),
    Dense(1, activation='linear')
])
model.compile(optimizer='adam', loss='mse', metrics=['mae'])
# === Callbacks ===
early_stop = EarlyStopping(monitor='val_loss', patience=80,
restore_best_weights=True)
checkpoint = ModelCheckpoint("modelo_RNN_LSTM.h5", monitor='val_loss',
save_best_only=True, verbose=1)
# === Entrenamiento ===
history = model.fit(
    X_train, y_train,
    validation_split=0.2,
    epochs=1000,
    batch_size=32,
    callbacks=[early_stop, checkpoint],
    verbose=1
)
# === Evaluación ===
y_pred_norm = model.predict(X_test).flatten()
y_pred = scaler_cbr.inverse_transform(y_pred_norm.reshape(-1, 1)).flatten()
y_real = scaler_cbr.inverse_transform(y_test.reshape(-1, 1)).flatten()
r2 = r2_score(y_real, y_pred)
mse = mean_squared_error(y_real, y_pred)
rmse = np.sqrt(mse)
mae = mean_absolute_error(y_real, y_pred)

```



```

print(f" R2 Score: {r2:.4f}")
print(f" MSE: {mse:.4f}")
print(f" RMSE: {rmse:.4f}")
print(f" MAE: {mae:.4f}")
# === GRÁFICOS ===
# 1. Gráfico de pérdida (loss) y MAE
plt.figure(figsize=(10, 5))
plt.plot(history.history["loss"], label="Pérdida de entrenamiento (MSE)")
plt.plot(history.history["val_loss"], label="Pérdida de validación (MSE)")
plt.title(" Pérdida (MSE) durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("MSE")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
plt.figure(figsize=(10, 5))
plt.plot(history.history["mae"], label="MAE entrenamiento")
plt.plot(history.history["val_mae"], label="MAE validación")
plt.title(" MAE durante el entrenamiento")
plt.xlabel("Épocas")
plt.ylabel("MAE")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
# 2. Comparación de CBR real vs. predicho
plt.figure(figsize=(10, 6))
plt.plot(y_real, label="CBR real", marker='o')
plt.plot(y_pred, label="CBR predicho", marker='x')
plt.title(" Comparación de CBR real vs. predicho (LSTM)")
plt.xlabel("Índice de muestra")
plt.ylabel("CBR")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
# 3. Gráfico de dispersión real vs predicho
plt.figure(figsize=(8, 6))
plt.scatter(y_real, y_pred, alpha=0.6)
plt.plot([y_real.min(), y_real.max()], [y_real.min(), y_real.max()], 'r--')
plt.xlabel("CBR Real")
plt.ylabel("CBR Predicho")
plt.title(" Dispersión: CBR Real vs. Predicho")
plt.grid(True)
plt.tight_layout()
plt.show()
#=====
# === 1. Gráfico del RMSE durante el entrenamiento ===
# Calculando el RMSE en cada época
rmse_train = np.sqrt(history.history["loss"])
rmse_val = np.sqrt(history.history["val_loss"])
plt.figure(figsize=(10, 5))
plt.plot(rmse_train, label="RMSE entrenamiento")
plt.plot(rmse_val, label="RMSE validación")
plt.title(" RMSE durante el entrenamiento")

```



```

plt.xlabel("Épocas")
plt.ylabel("RMSE")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
from tensorflow.keras.callbacks import Callback
from sklearn.metrics import r2_score
import matplotlib.pyplot as plt
import numpy as np
class R2Callback(Callback):
    def __init__(self, X_train, y_train, X_val, y_val, scaler):
        super().__init__()
        self.X_train = X_train
        self.y_train = y_train
        self.X_val = X_val
        self.y_val = y_val
        self.scaler = scaler
        self.r2_train = []
        self.r2_val = []
    def on_epoch_end(self, epoch, logs=None):
        y_train_pred = self.model.predict(self.X_train).flatten()
        y_val_pred = self.model.predict(self.X_val).flatten()
        # Desnormalización de datos
        y_train_denorm = self.scaler.inverse_transform(self.y_train.reshape(-
1, 1)).flatten()
        y_val_denorm = self.scaler.inverse_transform(self.y_val.reshape(-1,
1)).flatten()
        y_train_pred_denorm =
self.scaler.inverse_transform(y_train_pred.reshape(-1, 1)).flatten()
        y_val_pred_denorm = self.scaler.inverse_transform(y_val_pred.reshape(-
1, 1)).flatten()
        # Cálculo del R²
        self.r2_train.append(r2_score(y_train_denorm, y_train_pred_denorm))
        self.r2_val.append(r2_score(y_val_denorm, y_val_pred_denorm))
# === División de datos para el callback R² ===
split_idx = int(0.8 * len(X_train))
X_train_final, X_val = X_train[:split_idx], X_train[split_idx:]
y_train_final, y_val = y_train[:split_idx], y_train[split_idx:]
# === Entrenamiento con el callback R² ===
r2_callback = R2Callback(X_train_final, y_train_final, X_val, y_val,
scaler_cbr)
history = model.fit(
    X_train_final, y_train_final,
    validation_data=(X_val, y_val),
    epochs=1000,
    batch_size=32,
    callbacks=[early_stop, checkpoint, r2_callback],
    verbose=1
)
# === Gráfico del R² durante el entrenamiento ===
plt.figure(figsize=(10, 5))
plt.plot(r2_callback.r2_train, label="R² entrenamiento")
plt.plot(r2_callback.r2_val, label="R² validación")
plt.title("R² durante el entrenamiento")
plt.xlabel("Épocas")

```

```
plt.ylabel("R²")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
# === Matriz de Correlación ===
import seaborn as sns
# Restaurar datos en formato original para la correlación
df_corr = df.drop(columns=["CBR", "CBR_norm"]) # Elimina tanto CBR original
como el normalizado
plt.figure(figsize=(10, 8))
sns.heatmap(df_corr.corr(), annot=True, cmap="coolwarm", fmt=".2f",
linewidths=0.5, cbar=True)
plt.title(" Matriz de Correlación de Variables")
plt.tight_layout()
plt.show()
```

### Anexo C3. Código de Red Neuronal Recurrente GRU (RNN-GRU)

```

import pandas as pd; import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error
import matplotlib.pyplot as plt
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import GRU, Dense, Dropout, Input,
BatchNormalization
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint
import matplotlib.pyplot as plt
# === Cargar y preparar data ===
df = pd.read_csv("data/CBR_dataset_aumentado_IA.csv")
scaler_cbr = MinMaxScaler()
df["CBR_norm"] = scaler_cbr.fit_transform(df[["CBR"]])
X = df.drop(columns=["CBR", "CBR_norm"]).values
y = df["CBR_norm"].values
X = X.reshape((X.shape[0], X.shape[1], 1))
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)
# === Modelo GRU ajustado ===
model = Sequential([
    Input(shape=(X.shape[1], 1)),
    GRU(64, activation='tanh', return_sequences=True),
    Dropout(0.2),
    GRU(32, activation='tanh', return_sequences=True),
    Dropout(0.2),
    GRU(16, activation='tanh'),
    BatchNormalization(),
    Dense(1, activation='linear')
])
model.compile(optimizer='adam', loss='mse', metrics=['mae'])
# === Callbacks sin reducción de LR ===
early_stop = EarlyStopping(monitor='val_loss', patience=80,
restore_best_weights=True)
checkpoint = ModelCheckpoint("modelo_RNN_GRU.h5", monitor='val_loss',
save_best_only=True, verbose=1)
# === Entrenamiento ===
history = model.fit(
    X_train, y_train,
    validation_split=0.2,
    epochs=1000,
    batch_size=32,
    callbacks=[early_stop, checkpoint],
    verbose=1
)
# === Predicción y evaluación ===
y_pred_norm = model.predict(X_test).flatten()
y_pred = scaler_cbr.inverse_transform(y_pred_norm.reshape(-1, 1)).flatten()
y_real = scaler_cbr.inverse_transform(y_test.reshape(-1, 1)).flatten()
# === Métricas ===
r2 = r2_score(y_real, y_pred)
mse = mean_squared_error(y_real, y_pred)
rmse = np.sqrt(mse)
mae = mean_absolute_error(y_real, y_pred)

```

```

# === Mostrar métricas en consola ===
print("Resultados del modelo GRU:")
print(f"R² Score: {r2:.4f}")
print(f"MSE: {mse:.4f}")
print(f"RMSE: {rmse:.4f}")
print(f"MAE: {mae:.4f}")
# === Gráfico ===
plt.figure(figsize=(10, 5))
plt.scatter(y_real, y_pred, alpha=0.5, label="Pred vs Real")
plt.plot([y_real.min(), y_real.max()], [y_real.min(), y_real.max()], 'r--',
label="Ideal")
plt.xlabel("CBR Real")
plt.ylabel("CBR Predicho")
plt.title("GRU Ajustado - CBR")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
#plt.show(block=False)
#plt.pause(5)
#plt.close()
# ===== Graficos =====
# === Gráfico de métricas durante el entrenamiento ===
plt.figure(figsize=(10, 5))
# Gráfico de la pérdida (MSE)
#plt.subplot(2, 2, 1)
plt.plot(history.history['loss'], label='Pérdida (MSE) - Entrenamiento')
plt.plot(history.history['val_loss'], label='Pérdida (MSE) - Validación')
plt.title('Pérdida (MSE) durante el entrenamiento')
plt.xlabel('Épocas')
plt.ylabel('Pérdida (MSE)')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
# Gráfico del MAE
#plt.subplot(2, 2, 2)
plt.plot(history.history['mae'], label='MAE - Entrenamiento')
plt.plot(history.history['val_mae'], label='MAE - Validación')
plt.title('MAE durante el entrenamiento')
plt.xlabel('Épocas')
plt.ylabel('MAE')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
# Gráfico de RMSE (Calculado manualmente)
#plt.subplot(2, 2, 3)
rmse_train = np.sqrt(np.array(history.history['loss']))
rmse_val = np.sqrt(np.array(history.history['val_loss']))
plt.plot(rmse_train, label='RMSE - Entrenamiento')
plt.plot(rmse_val, label='RMSE - Validación')
plt.title('RMSE durante el entrenamiento')
plt.xlabel('Épocas')
plt.ylabel('RMSE')
plt.legend()

```

```

plt.grid(True)
plt.tight_layout()
plt.show()
# Gráfico del R² (solo valor final)
plt.subplot(2, 2, 4)
plt.bar(['R²'], [r2], color='skyblue')
plt.title('R² del modelo GRU')
plt.ylim(0, 1)
plt.text(0, r2 + 0.02, f'{r2:.4f}', ha='center')
plt.grid(True, axis='y')
plt.tight_layout()
plt.show()
#=====
import seaborn as sns
import matplotlib.pyplot as plt
import pandas as pd
import numpy as np
# === Gráfico 1: Comparación detallada del CBR real vs. CBR predicho ===
plt.figure(figsize=(12, 6))
plt.plot(y_real, label="CBR Real", marker='o', markersize=4)
plt.plot(y_pred, label="CBR Predicho", marker='x', markersize=4)
plt.title("Comparación del CBR Real vs. CBR Predicho")
plt.xlabel("Muestras")
plt.ylabel("CBR")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
# === Gráfico 2: Matriz de correlación de variables con nombres visibles ===
plt.figure(figsize=(10, 8))
# Convertir X nuevamente a un DataFrame para que incluya los nombres de las variables
X_df = pd.DataFrame(X.reshape(X.shape[0], -1), columns=df.drop(columns=["CBR",
"CBR_norm"]).columns)
# Generar la matriz de correlación
corr_matrix = X_df.corr()
# Gráfico de la matriz de correlación
sns.heatmap(corr_matrix, annot=True, cmap='coolwarm', fmt='.2f',
linewidths=0.5)
plt.title("Matriz de Correlación de Variables")
plt.tight_layout()
plt.show()
# =====
import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import r2_score
import matplotlib.pyplot as plt
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import GRU, Dense, Dropout, Input,
BatchNormalization
from tensorflow.keras.callbacks import EarlyStopping, ModelCheckpoint,
Callback
# === Cargar y preparar data ===
df = pd.read_csv("data/Datos_Sinteticos_Triplicado_CBR.csv")

```

```

scaler_cbr = MinMaxScaler()
df["CBR_norm"] = scaler_cbr.fit_transform(df[["CBR"]])
X = df.drop(columns=["CBR", "CBR_norm"]).values
y = df["CBR_norm"].values
X = X.reshape((X.shape[0], X.shape[1], 1))
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2,
random_state=42)
# === Clase personalizada para R² ===
class R2Metric(Callback):
    def __init__(self, x_train, y_train, x_val, y_val):
        super().__init__()
        self.x_train = x_train
        self.y_train = y_train
        self.x_val = x_val
        self.y_val = y_val
        self.r2_train = []
        self.r2_val = []
    def on_epoch_end(self, epoch, logs=None):
        y_train_pred = self.model.predict(self.x_train).flatten()
        y_val_pred = self.model.predict(self.x_val).flatten()
        r2_train_value = r2_score(self.y_train, y_train_pred)
        r2_val_value = r2_score(self.y_val, y_val_pred)
        self.r2_train.append(r2_train_value)
        self.r2_val.append(r2_val_value)
        print(f"Epoch {epoch + 1}: R² Train = {r2_train_value:.4f}, R² Val =
{r2_val_value:.4f}")
    def plot_r2_evolution(self):
        plt.figure(figsize=(8, 5))
        plt.plot(self.r2_train, label='R² - Entrenamiento', marker='o')
        plt.plot(self.r2_val, label='R² - Validación', marker='o')
        plt.title('Evolución del R² durante el entrenamiento')
        plt.xlabel('Épocas'); plt.ylabel('R² Score'); plt.legend()
        plt.grid(True); plt.show()
# === Modelo GRU ===
model = Sequential([Input(shape=(X.shape[1], 1)),
    GRU(64, activation='tanh', return_sequences=True),
    Dropout(0.2),
    GRU(32, activation='tanh', return_sequences=True),
    Dropout(0.2),
    GRU(16, activation='tanh'),
    BatchNormalization(),
    Dense(1, activation='linear')])
model.compile(optimizer='adam', loss='mse', metrics=['mae'])
# === Callbacks ===
early_stop = EarlyStopping(monitor='val_loss', patience=80,
restore_best_weights=True)
checkpoint = ModelCheckpoint("modelo_RNN_GRU.h5", monitor='val_loss',
save_best_only=True, verbose=1)
r2_metric = R2Metric(X_train, y_train, X_test, y_test)
# === Entrenamiento ===
model.fit(X_train, y_train,
    validation_split=0.2, epochs=1000, batch_size=32,
    callbacks=[early_stop, checkpoint, r2_metric],
    verbose=1)
# === Gráfico de evolución del R² ===
r2_metric.plot_r2_evolution()

```

#### Anexo C4. Código del Algoritmo de Random Forest (RF)

```

import pandas as pd, import numpy as np
import matplotlib.pyplot as plt
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import GridSearchCV, train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error
import joblib # para guardar el modelo
# Cargar y limpiar datos
df = pd.read_csv("data/CBR_dataset_aumentado_IA.csv")
df = df[(df["contenido óptimo de Humedad (%)"] < 50) &
        (df["Máxima Densidad Seca (gr/cm3)"] < 3)]
X = df.drop(columns=["CBR"])
y = df["CBR"]
# Escalado
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)
# División
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y,
                                                    test_size=0.2, random_state=42)
# Parámetros de búsqueda
param_grid = {
    'n_estimators': [200, 300],
    'max_depth': [None, 15, 30],
    'min_samples_split': [2, 5],
    'min_samples_leaf': [1, 2, 5],
    'max_features': ['auto', 'sqrt'],
    'bootstrap': [True, False]
}
# Modelo base
rf = RandomForestRegressor(random_state=42)
grid_search = GridSearchCV(rf, param_grid, cv=5, scoring='r2', n_jobs=-1,
                           verbose=2), grid_search.fit(X_train, y_train)
# Mejor modelo
best_rf = grid_search.best_estimator_
y_pred = best_rf.predict(X_test)
# Métricas
r2 = r2_score(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)
mae = mean_absolute_error(y_test, y_pred)
# Resultados por consola
print("Mejor configuración Random Forest:", grid_search.best_params_)
print(f"R²: {r2:.4f}")
print(f"MSE: {mse:.4f}")
print(f"RMSE: {rmse:.4f}")
print(f"MAE: {mae:.4f}")
# Gráfico
plt.figure(figsize=(10, 6))
plt.plot(y_test.values, label="CBR real", marker='o')
plt.plot(y_pred, label="CBR predicho (RF)", marker='x')
plt.title("CBR real vs predicho con Random Forest optimizado")
plt.xlabel("Índice de muestra")
plt.ylabel("CBR")
plt.legend()

```



```

plt.grid(True)
plt.tight_layout()
plt.show()
# === Guardar modelo entrenado ===
joblib.dump(best_rf, "modelo_random_forest.pkl") # Puedes usar también
.joblib
print(" Modelo guardado como 'modelo_random_forest.pkl'")
# =====
# === Gráfico de métricas ===
plt.figure(figsize=(12, 6))
# Gráfico 1: CBR Real vs Predicho
plt.subplot(1, 2, 1)
plt.plot(y_test.values, label="CBR real", marker='o')
plt.plot(y_pred, label="CBR predicho (RF)", marker='x')
plt.title("CBR real vs predicho con Random Forest optimizado")
plt.xlabel("Índice de muestra")
plt.ylabel("CBR")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error
# === 1. Gráfico de dispersión CBR Real vs CBR Predicho ===
plt.figure(figsize=(8, 6))
sns.regplot(x=y_test, y=y_pred, scatter_kws={"alpha": 0.6}, line_kws={"color":
"red"})
plt.title("Dispersión de CBR Real vs Predicho")
plt.xlabel("CBR Real")
plt.ylabel("CBR Predicho")
plt.grid(True)
plt.legend()
plt.show()
# === 2. Gráfico del MAE durante el entrenamiento ===
plt.figure(figsize=(8, 6))
mae_values = -grid_search.cv_results_['mean_test_score'] # El MAE se calcula
en negativo en GridSearchCV
plt.plot(mae_values, label='MAE en entrenamiento', marker='o')
plt.title("Evolución del MAE durante el entrenamiento")
plt.xlabel("Iteraciones del GridSearch")
plt.ylabel("MAE")
plt.grid(True)
plt.legend()
plt.show()
# === 3. Gráfico del MSE durante el entrenamiento ===
plt.figure(figsize=(8, 6))
mse_values = grid_search.cv_results_['mean_test_score'] * -1 # Mismo
principio que el MAE
plt.plot(mse_values, label='MSE en entrenamiento', marker='o')
plt.title("Evolución del MSE durante el entrenamiento")
plt.xlabel("Iteraciones del GridSearch")
plt.ylabel("MSE")
plt.grid(True)

```

```

plt.legend()
plt.show()
# === 4. Gráfico del RMSE durante el entrenamiento ===
# === Corrección del GridSearchCV ===
grid_search = GridSearchCV(rf, param_grid, cv=5,
scoring='neg_mean_squared_error', n_jobs=-1, verbose=2)
grid_search.fit(X_train, y_train)
# === 4. Gráfico del RMSE durante el entrenamiento (Corregido) ===
try:
    # Extraer los resultados del MSE en negativo (que es lo que entrega
GridSearchCV)
    if 'mean_test_score' in grid_search.cv_results_:
        mse_values = -grid_search.cv_results_['mean_test_score'] # Se
invierte el signo para obtener valores reales
        # Convertir a RMSE
        rmse_values = np.sqrt(mse_values)
        # Filtrar valores no válidos
        valid_rmse_values = rmse_values[~np.isnan(rmse_values) &
~np.isinf(rmse_values)]
        # Comprobar si hay datos válidos
        if len(valid_rmse_values) == 0:
            print("No hay valores válidos para graficar el RMSE. Verifica el
GridSearchCV.")
            exit()
        # Eje X adecuado
        iterations = range(1, len(valid_rmse_values) + 1)
        # Graficar
        plt.figure(figsize=(8, 6))
        plt.plot(iterations, valid_rmse_values, label='RMSE en entrenamiento',
marker='o')
        plt.title("Evolución del RMSE durante el entrenamiento")
        plt.xlabel("Iteraciones del GridSearch")
        plt.ylabel("RMSE")
        plt.ylim(min(valid_rmse_values) * 0.9, max(valid_rmse_values) * 1.1)
        plt.grid(True)
        plt.legend()
        plt.show()
except KeyError:
    print("Error: El parámetro 'mean_test_score' no se encontró en los
resultados del GridSearchCV.")
except ValueError as e:
    print(f" Error en los datos del RMSE: {e}")
except Exception as e:
    print(f" Error inesperado: {e}")
# === 5. Gráfico del R² durante el entrenamiento ===
plt.figure(figsize=(8, 6))
plt.plot(grid_search.cv_results_['mean_test_score'], label='R² en
entrenamiento', marker='o')
plt.title("Evolución del R² durante el entrenamiento")
plt.xlabel("Iteraciones del GridSearch")
plt.ylabel("R²")
plt.grid(True)
plt.legend()
plt.show()
# === 6. Matriz de correlación ===
import pandas as pd

```

```

import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt
# Ejemplo de generación de datos (sustituir con tus datos reales)
# df = pd.read_csv('tus_datos.csv') # Si estás trabajando con un archivo
# Crear una matriz de correlación
plt.figure(figsize=(14, 8)) # Tamaño optimizado para incluir todos los datos
correlation_matrix = df.corr()
# Mapa de calor mejorado
sns.heatmap(
    correlation_matrix,
    annot=True, # Mostrar los valores de correlación
    cmap='coolwarm', # Paleta de colores mejorada
    fmt=".2f", # Formato numérico claro
    linewidths=0.5, # Líneas divisorias más nítidas
    cbar_kws={'shrink': 0.8}, # Tamaño optimizado de la barra de color
    vmin=-1, vmax=1 # Escala completa para mejor interpretación
)
# Título más claro
plt.title('Matriz de correlación de las variables', fontsize=14,
fontweight='bold')
plt.xticks(rotation=45, ha='right') # Rótulos inclinados para mayor
legibilidad
plt.yticks(rotation=0) # Mantener etiquetas verticales
plt.tight_layout() # Mejor ajuste del gráfico
plt.legend()
plt.show()

```

### Anexo C5. Código de Algoritmo de Máquina de Soporte Vectorial (SVM)

```

from sklearn.model_selection import GridSearchCV, train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.svm import SVR
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error
import pandas as pd, import numpy as np, import matplotlib.pyplot as plt
import joblib # para guardar el modelo
# Cargar y limpiar
df = pd.read_csv("data/Datos_Sinteticos_Triplicado_CBR.csv")
df = df[(df["contenido óptimo de Humedad (%)"] < 50) & (df["Máxima Densidad
Seca (gr/cm3)"] < 3)]
# Features y label
X = df.drop(columns=["CBR"])
y = df["CBR"]
# Escalado
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)
# División
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y,
test_size=0.2, random_state=42)
# Grid EXTENDIDO
param_grid = {
    "kernel": ["rbf"],
    "C": [1, 10, 100, 500, 1000],
    "gamma": [0.001, 0.01, 0.1, 1, "scale"],
    "epsilon": [0.001, 0.01, 0.1, 0.2]
}
print(" Realizando búsqueda de hiperparámetros... (puede tardar unos
segundos)")
grid_search = GridSearchCV(SVR(), param_grid, cv=5, scoring="r2", n_jobs=-1,
verbose=2)
grid_search.fit(X_train, y_train)
# Resultados
best_model = grid_search.best_estimator_
y_pred = best_model.predict(X_test)
r2 = r2_score(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)
mae = mean_absolute_error(y_test, y_pred)
# Mostrar resultados
print("\n Mejor configuración SVM:", grid_search.best_params_)
print(f"R²: {r2:.4f}")
print(f"MSE: {mse:.4f}")
print(f"RMSE: {rmse:.4f}")
print(f"MAE: {mae:.4f}")
# Gráfico
plt.figure(figsize=(10, 6))
plt.plot(y_test.values, label="CBR real", marker='o')
plt.plot(y_pred, label="CBR predicho", marker='x')
plt.title("CBR real vs predicho con SVM optimizado (sin outliers)")
plt.xlabel("Índice de muestra")
plt.ylabel("CBR")
plt.legend()
plt.grid(True)
plt.tight_layout()

```

```

plt.show()
# === Guardar modelo entrenado ===
joblib.dump(best_model, "modelo_svm.pkl") # Puedes cambiar a .joblib si
prefieres
print(" Modelo guardado como 'modelo_svm.pkl'")
#=====
# === Gráfico de métricas ===
import seaborn as sns
import matplotlib.pyplot as plt
import numpy as np
# Inicialización de Seaborn para un mejor estilo
sns.set(style="whitegrid")
import numpy as np
import matplotlib.pyplot as plt
from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score
# Gráfico de la Pérdida (Loss) vs Épocas
plt.plot(history.history['loss'], label='Pérdida - Entrenamiento')
plt.plot(history.history['val_loss'], label='Pérdida - Validación')
plt.title('Evolución de la Pérdida durante el Entrenamiento')
plt.xlabel('Épocas')
plt.ylabel('Pérdida (Loss)')
plt.legend()
plt.grid(True)
plt.show()
# Gráfico de Métricas vs Épocas
plt.plot(history.history['mae'], label='MAE - Entrenamiento')
plt.plot(history.history['val_mae'], label='MAE - Validación')
plt.title('Evolución del MAE durante el Entrenamiento')
plt.xlabel('Épocas')
plt.ylabel('MAE')
plt.legend()
plt.grid(True)
plt.show()
# Grafico de la evolución del R2
plt.plot(history.history['r2'], label='R² - Entrenamiento')
plt.plot(history.history['val_r2'], label='R² - Validación')
plt.title('Evolución del R² durante el Entrenamiento')
plt.xlabel('Épocas')
plt.ylabel('R²')
plt.legend()
plt.grid(True)
plt.show()
# Grafico de la curva de aprendizaje
from sklearn.model_selection import learning_curve
from sklearn.linear_model import LinearRegression
train_sizes, train_scores, val_scores = learning_curve(
    LinearRegression(), X, y, cv=5, scoring='neg_mean_squared_error'
)
plt.plot(train_sizes, -train_scores.mean(axis=1), label='Error -
Entrenamiento')
plt.plot(train_sizes, -val_scores.mean(axis=1), label='Error - Validación')
plt.title('Curva de Aprendizaje')
plt.xlabel('Tamaño del Conjunto de Entrenamiento')
plt.ylabel('MSE')
plt.legend()
plt.grid(True)

```

```

plt.show()
# === Matriz de correlación de variables ===
plt.figure(figsize=(10, 8))
corr_matrix = df.corr(numeric_only=True) # Asegura que solo se tomen valores
numéricos
sns.heatmap(corr_matrix, annot=True, cmap="coolwarm", fmt=".2f",
linewidths=0.5)
plt.title("Matriz de correlación entre variables")
plt.tight_layout()
plt.show()
import matplotlib.pyplot as plt
import seaborn as sns
# Gráfico de dispersión
plt.figure(figsize=(8, 6))
sns.scatterplot(x=y_test, y=y_pred, alpha=0.7)
plt.plot([min(y_test), max(y_test)], [min(y_test), max(y_test)], color='red',
linestyle='--', label='Línea Ideal (y = x)')
# Personalización del gráfico
plt.title("Dispersión: CBR real vs CBR predicho")
plt.xlabel("CBR Real")
plt.ylabel("CBR Predicho")
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.show()

```

### Anexo C6. Código de Interfase WEB de almacenamiento y predicción de CBR

```

from flask import Flask, render_template, request, jsonify
from tensorflow.keras.models import load_model
import joblib
import numpy as np
import json
import os
import sqlite3
app = Flask(__name__)
# Cargar orden de columnas
with open("column_order.json") as f:
    column_order = json.load(f)
@app.route('/')
def index():
    return render_template("index.html")
@app.route('/predecir', methods=['POST'])
def predecir():
    try:
        # Obtener modelo seleccionado
        modelo = request.form.get("modelo")
        if not modelo:
            return jsonify({
                'resultado': None,
                'mensaje': 'Modelo no especificado'})
        # Leer datos del formulario
        data_dict = {}
        for field in column_order:
            valor = request.form.get(field)
            if valor is None or valor.strip() == "":
                return jsonify({
                    'resultado': None,
                    'mensaje': f' Falta el campo: {field}'
                })
            data_dict[field] = float(valor)
        data_np = np.array([[data_dict[col] for col in column_order]])
        # === MODELO ANN (hibrido ANN + GRU)
        if modelo == "ann":
            model = load_model("modelo_ANN.h5", compile=False)
            scaler = joblib.load("scaler_ann.pkl")
            input_mlp = scaler.transform(data_np)
            input_rnn = input_mlp.reshape((1, 1, len(column_order)))
            pred = model.predict([input_mlp, input_rnn])[0][0]
        # === MODELO RNN GRU (con MinMaxScaler X + Y)
        elif modelo == "rnn_gru":
            model = load_model("modelo_RNN_GRU.h5", compile=False)
            scaler_X = joblib.load("scaler_rnn_gru_x.pkl")
            scaler_y = joblib.load("scaler_rnn_gru_y.pkl")
            data_scaled = scaler_X.transform(data_np)
            input_rnn = data_scaled.reshape((1, len(column_order), 1))
            pred_norm = model.predict(input_rnn)[0][0]
            pred = scaler_y.inverse_transform([[pred_norm]])[0][0]
        # === MODELO RNN LSTM (usa mismo escalado que GRU)
        elif modelo == "rnn_lstm":
            model = load_model("modelo_RNN_LSTM.h5", compile=False)
            scaler_X = joblib.load("scaler_rnn_lstm_x.pkl")
            scaler_y = joblib.load("scaler_rnn_lstm_y.pkl")

```



```

        data_scaled = scaler_X.transform(data_np)
        input_rnn = data_scaled.reshape((1, len(column_order), 1))
        pred_norm = model.predict(input_rnn)[0][0]
        pred = scaler_y.inverse_transform([[pred_norm]])[0][0]
# === RANDOM FOREST
elif modelo == "random_forest":
    model = joblib.load("modelo_random_forest.pkl")
    scaler = joblib.load("scaler_rf_x.pkl")
    data_scaled = scaler.transform(data_np)
    pred = model.predict(data_scaled)[0]
# === SVM
elif modelo == "svm":
    model = joblib.load("modelo_svm.pkl")
    scaler = joblib.load("scaler_svm_x.pkl")
    data_scaled = scaler.transform(data_np)
    pred = model.predict(data_scaled)[0]
else:
    return jsonify({
        'resultado': None,
        'mensaje': f' Modelo no reconocido: {modelo}'
    })
return jsonify({
    'resultado': float(round(pred, 2)),
    'mensaje': ' Predicción exitosa'
})
except Exception as e:
    return jsonify({
        'resultado': None,
        'mensaje': f' Error: {str(e)}'
    })
@app.route('/datos')
def datos():
    conn = sqlite3.connect("cbr.db")
    conn.row_factory = sqlite3.Row
    datos_raw = conn.execute("SELECT * FROM datos_cbr").fetchall()
    datos = [dict(fila) for fila in datos_raw]
    conn.close()
    return render_template("datos.html", datos=datos)
@app.route('/guardar', methods=['POST'])
def guardar():
    data = request.form
    conn = sqlite3.connect("cbr.db")
    cursor = conn.cursor()
    cursor.execute("""
        INSERT INTO datos_cbr (grava, arena, limo, ll, lp, ip, mdd, omc)
        VALUES (?, ?, ?, ?, ?, ?, ?, ?)
    """, (
        data['grava'], data['arena'], data['limo'], data['ll'],
        data['lp'], data['ip'], data['mdd'], data['omc']
    ))
    conn.commit()
    conn.close()
    return jsonify({'mensaje': ' Registro guardado correctamente'})
@app.route('/eliminar/<int:id>', methods=['POST'])
def eliminar(id):
    conn = sqlite3.connect("cbr.db")

```

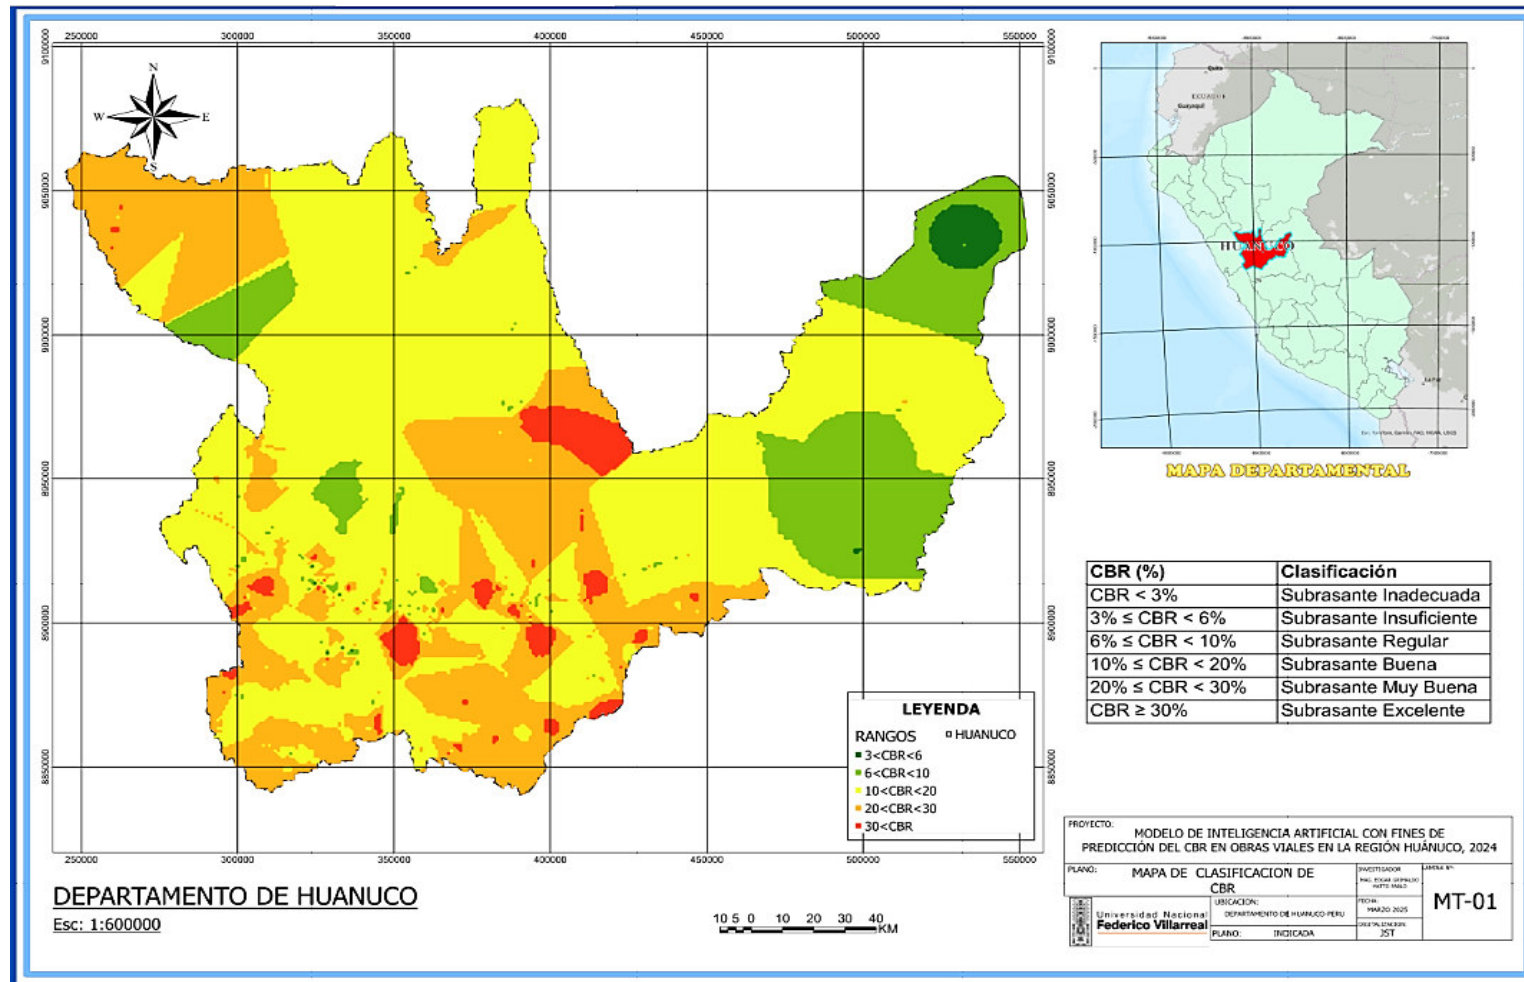
```

        conn.execute("DELETE FROM datos_cbr WHERE id = ?", (id,))
        conn.commit()
        conn.close()
        return jsonify({'mensaje': 'Registro eliminado'})
@app.route('/editar/<int:id>', methods=['POST'])
def editar(id):
    data = request.form
    conn = sqlite3.connect("cbr.db")
    conn.execute("""
        UPDATE datos_cbr SET grava=?, arena=?, limo=?, ll=?, lp=?, ip=?,
mdd=?, omc=?
        WHERE id=?
    """, (
        data['grava'], data['arena'], data['limo'], data['ll'],
        data['lp'], data['ip'], data['mdd'], data['omc'], id
    ))
    conn.commit()
    conn.close()
    return jsonify({'mensaje': 'Registro actualizado'})
@app.route('/descargar_csv')
def descargar_csv():
    conn = sqlite3.connect("cbr.db")
    cursor = conn.cursor()
    cursor.execute("SELECT * FROM datos_cbr")
    rows = cursor.fetchall()
    columnas = [desc[0] for desc in cursor.description]
    conn.close()
    import csv
    from io import StringIO
    si = StringIO()
    writer = csv.writer(si)
    writer.writerow(columnas)
    writer.writerows(rows)
    from flask import Response
    return Response(
        si.getvalue(),
        mimetype='text/csv',
        headers={"Content-Disposition": "attachment;filename=datos_cbr.csv"}
    )
if __name__ == '__main__':
    app.run(debug=True)

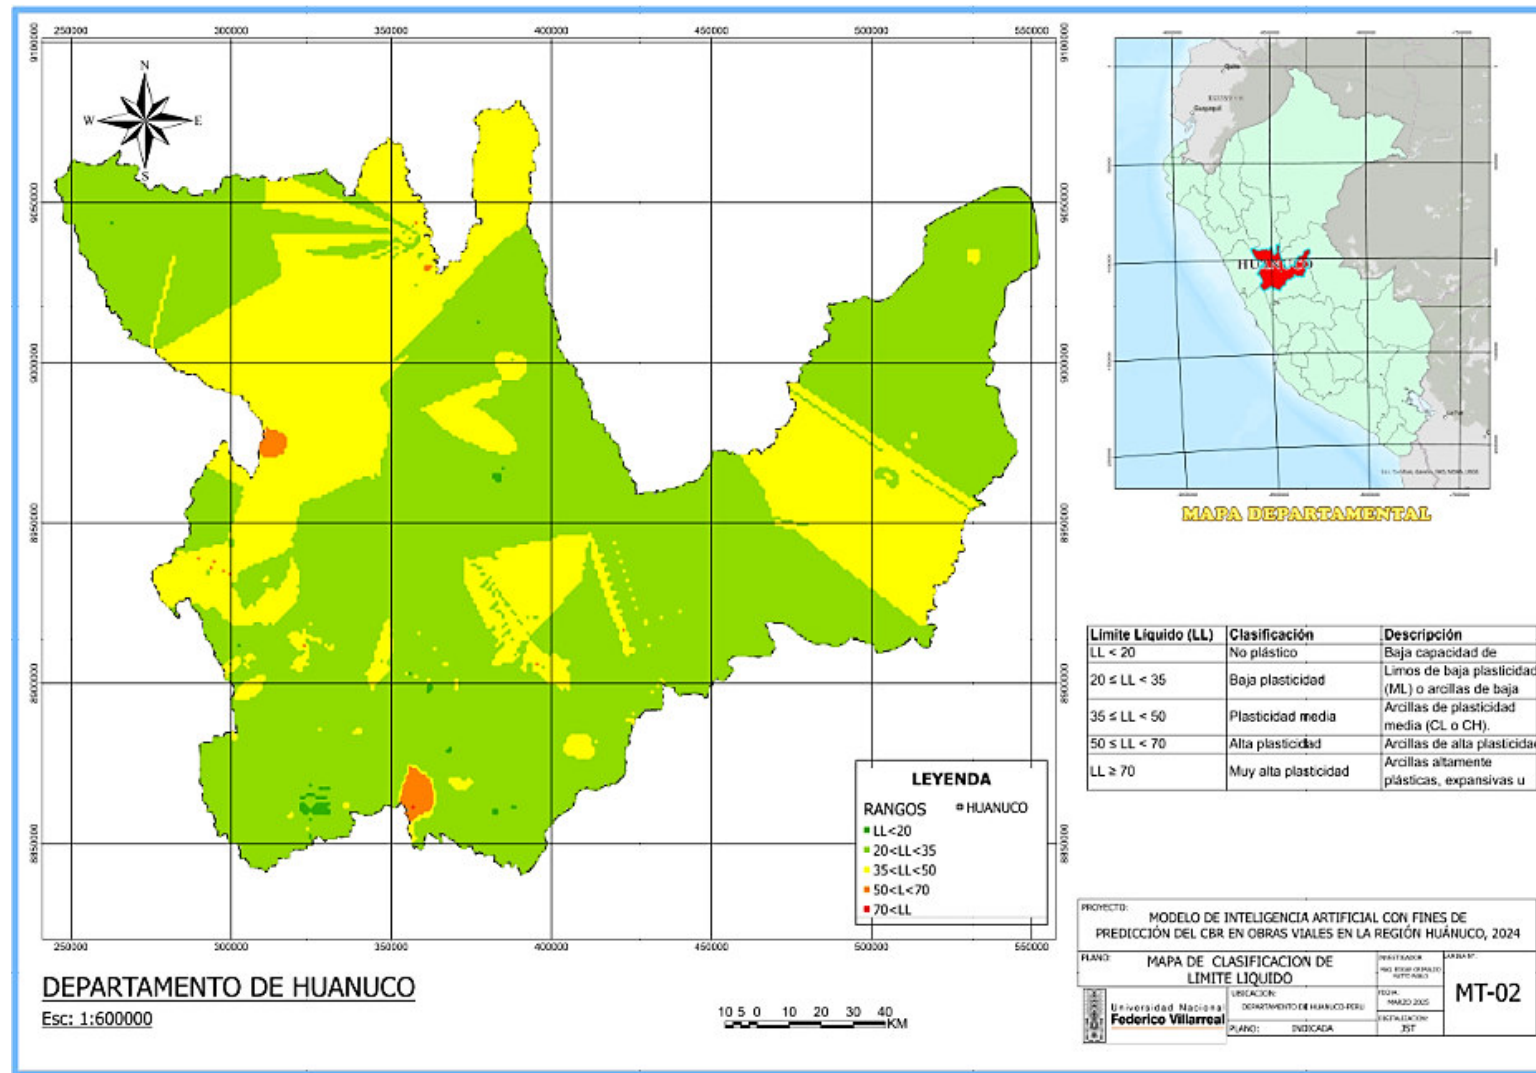
```

## Anexo D. Mapas Temáticos de propiedades físicas, mecánicas y geológicas en función de la data real inicial – Proyectos estudiados

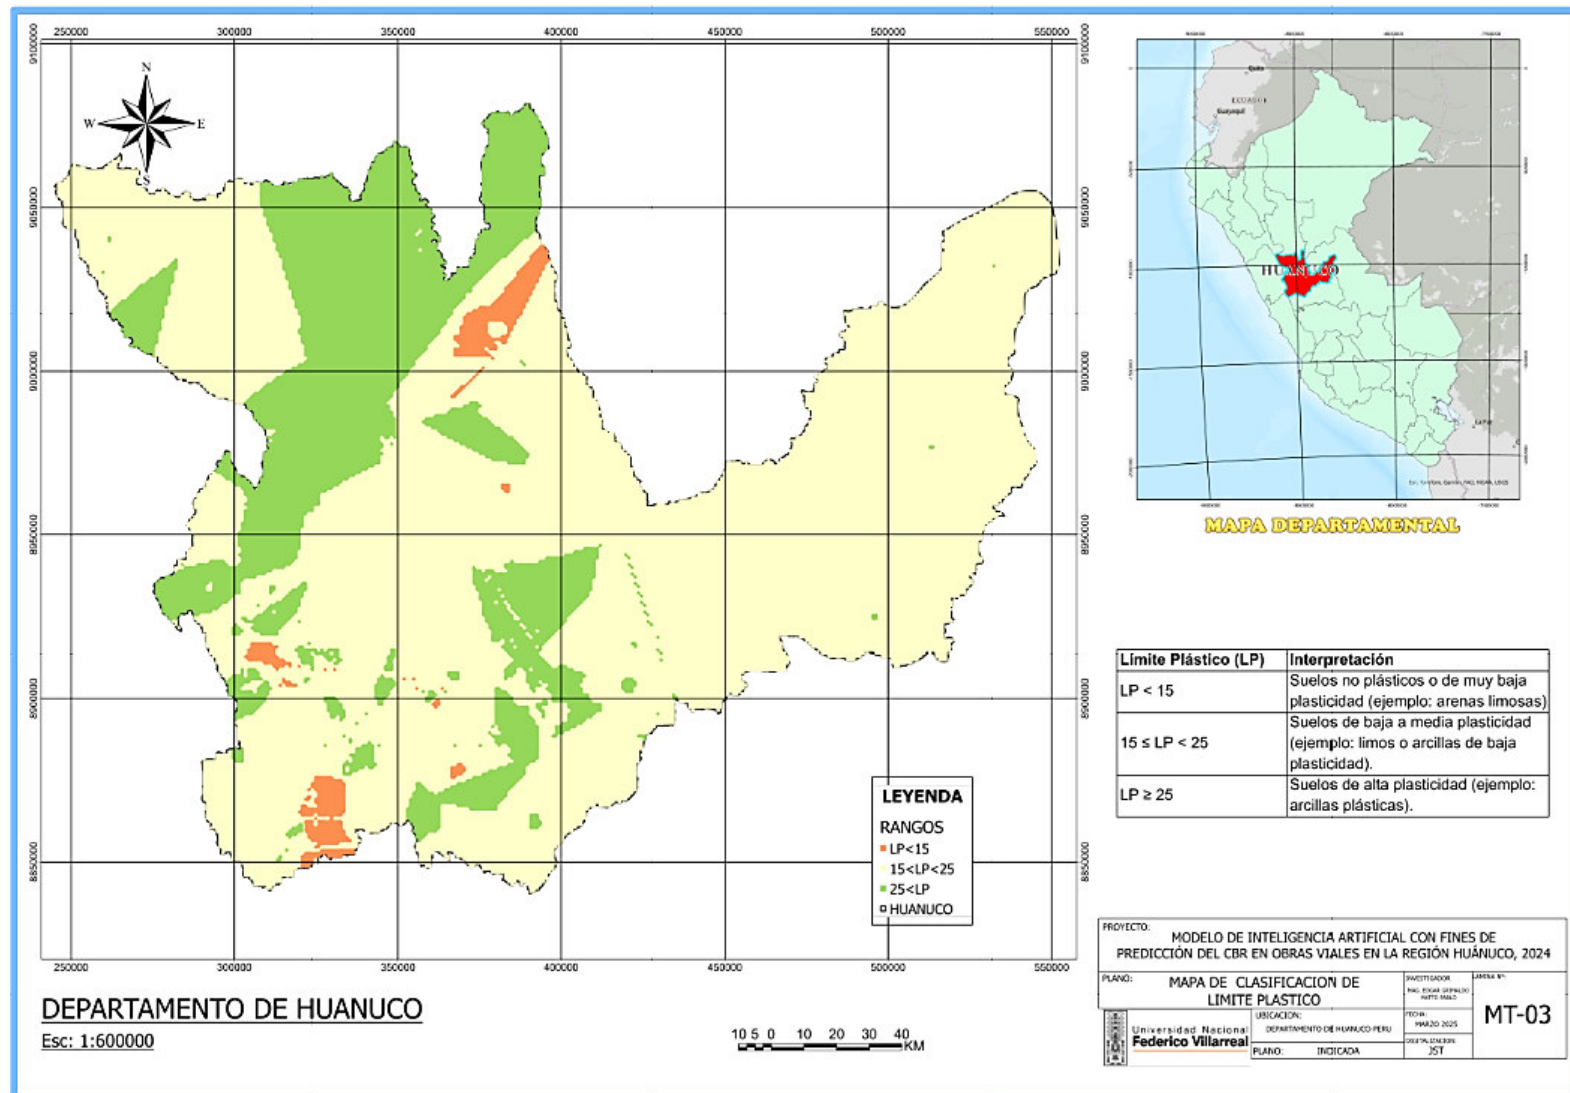
### Anexo D1. Distribución de Granulometría de la región Huánuco



*Anexo D2. Distribución de Limite Liquido de la región Huánuco*

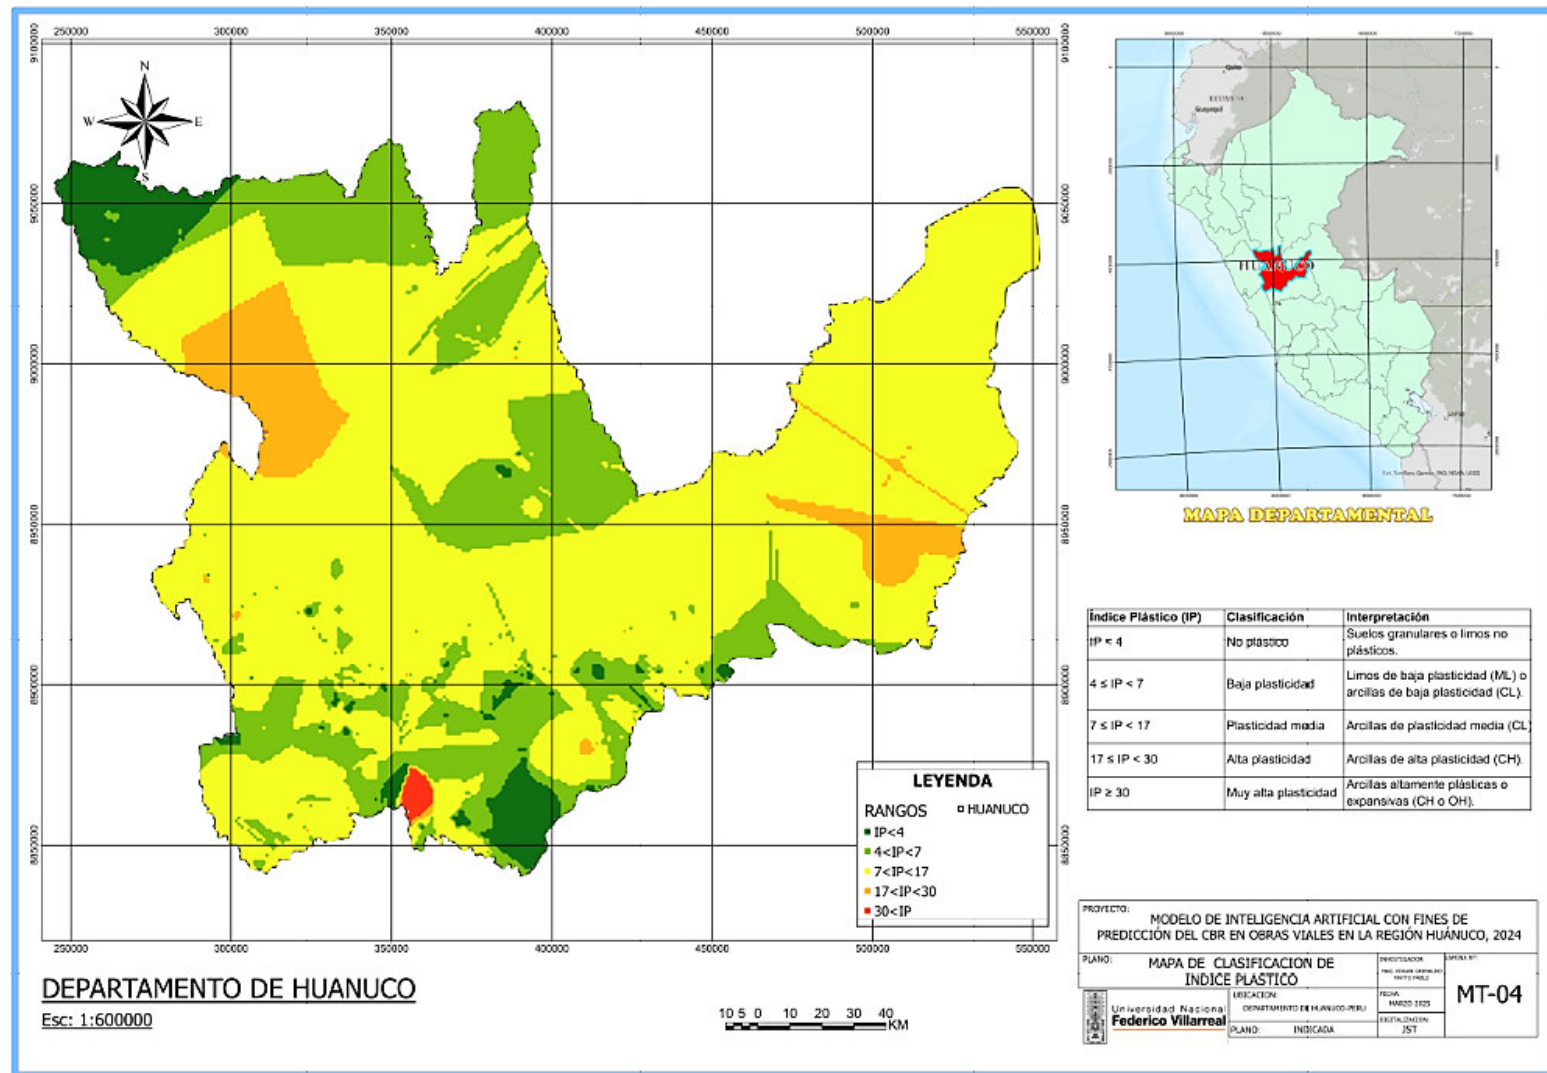


**Anexo D3. Distribución de Limite Plástico de la región Huánuco**

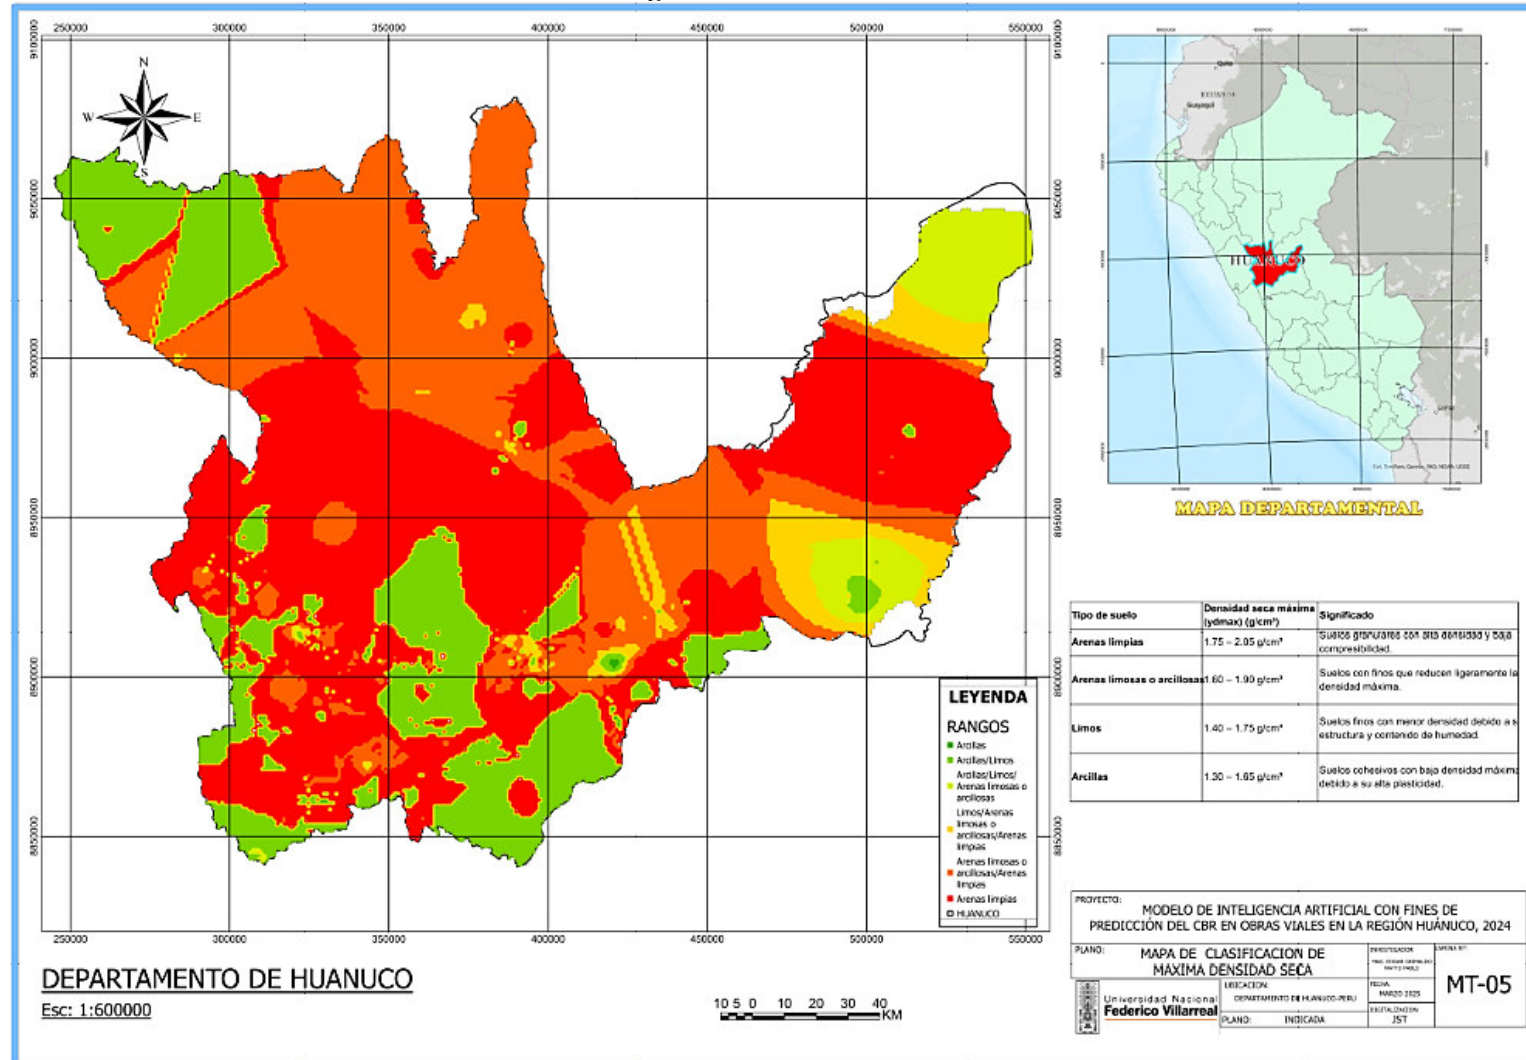




*Anexo D4. Distribución de Índice Plástico de la región Huánuco*



**Anexo D5. Distribución de la Máxima Densidad Seca de la región Huánuco**





**Anexo D6. Distribución del Contenido Óptimo de Humedad de la región Huánuco**

