

FACULTAD DE INGENIERÍA

Escuela Académico Profesional de Ingeniería Civil

Tesis

**Predicción de propiedades mecánicas de suelos
utilizando redes neuronales artificiales**

Medalith Manrique Dávila

Para optar el Título Profesional de
Ingeniera Civil

Huancayo, 2019

Repositorio Institucional Continental
Tesis digital



Esta obra está bajo una Licencia "Creative Commons Atribución 4.0 Internacional" .

ASESOR

Msc. Ing. Augusto García Corzo

AGRADECIMIENTO

Universidad Continental

Por brindarme la oportunidad y permitirme esta formación profesional.

Docente de la Universidad Continental y Asesor de Tesis.

Msc. Ing. Augusto García Corzo

Por la paciencia, inspiración y por el aporte de su experiencia profesional en mi investigación en el desarrollo de mi tesis.

A mis padres y familiares, por el apoyo, confianza y por la colaboración en la elaboración de la tesis.

DEDICATORIA

A mis padres, por haberme dado la vida, por ser fuente de inspiración de lucha, de perseverancia y por la confianza depositada, también por el apoyo incondicional, sus consejos y ejemplos a seguir en el logro de mis objetivos.

A mis tíos, tías, abuelos por los consejos y su apoyo incondicional.

ÍNDICE DE CONTENIDO

PORTADA.....	I
ASESOR.....	II
AGRADECIMIENTO.....	III
DEDICATORIA.....	IV
ÍNDICE DE CONTENIDO.....	V
ÍNDICE DE TABLAS.....	X
ÍNDICE DE FIGURAS.....	XII
ÍNDICE DE GRÁFICOS.....	XVI
RESUMEN.....	XVII
ABSTRACT.....	XVIII
INTRODUCCIÓN.....	1
CAPÍTULO I PLANTEAMIENTO DE LA INVESTIGACIÓN.....	3
1.1. PLANTEAMIENTO Y FORMULACIÓN DEL PROBLEMA.....	3
1.1.1. PLANTEAMIENTO DEL PROBLEMA.....	3
1.1.2. FORMULACIÓN DEL PROBLEMA.....	4
1.2. OBJETIVOS.....	4
1.2.1. OBJETIVO GENERAL.....	4
1.2.2. OBJETIVOS ESPECÍFICOS.....	4
1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN.....	5
1.3.1. JUSTIFICACIÓN PRÁCTICA.....	5
1.3.2. JUSTIFICACIÓN METODOLÓGICA.....	5
1.3.3. JUSTIFICACIÓN ECONÓMICA.....	6
1.4. DELIMITACIÓN DE LA INVESTIGACIÓN.....	6
1.4.1. CONCEPTUAL.....	6
1.4.2. ESPACIAL.....	6
1.4.3. TEMPORAL.....	6
1.5. HIPÓTESIS.....	7
1.5.1. HIPÓTESIS GENERAL.....	7
1.5.2. HIPÓTESIS ESPECÍFICAS.....	7
1.6. VARIABLES.....	7
1.6.1. VARIABLE INDEPENDIENTE.....	7
1.6.2. VARIABLE DEPENDIENTE.....	7
CAPÍTULO II MARCO TEÓRICO.....	8
2.1. ANTECEDENTES DEL PROBLEMA.....	8

2.1.1. ANTECEDENTES INTERNACIONALES	8
2.1.2. ANTECEDENTES NACIONALES.....	10
2.2. BASES TEÓRICAS	12
2.2.1. REDES NEURONALES ARTIFICIALES (RNA).....	12
2.2.1.1. La Neurona Artificial	13
2.2.1.2. Características de las redes artificiales	13
2.2.1.3. Estructura básica de una red neuronal	14
2.2.1.4. Clasificación de la red neuronal artificial (RNA)	16
2.2.1.4.1 Según su Arquitectura de la red neuronal.....	16
a. Con conexiones hacia adelante (No recurrentes o Feedforward)	17
• Redes Neuronales Monocapa	17
• Redes Neuronales Multicapa	18
b. Con conexiones hacia atrás (Recurrentes o Feedback)	19
2.2.1.4.2 Según su aprendizaje de las Redes Neuronales Artificiales	19
a. Entrenamiento Supervisado	20
b. Entrenamiento No Supervisado	21
c. Reforzado o graduado	21
2.2.1.4.3 Según su aplicación de la Red Neuronal Artificial	22
2.2.1.5. Funciones de entrada	23
2.2.1.6. Tipo de pre procesamiento.....	23
2.2.1.7. Funciones de transferencia o funciones de activación	23
2.2.1.8. Funciones de error o performance.....	24
2.2.2. DISEÑO DE UN MODELO NEURONAL	25
2.2.3. MODELACIÓN DE UN PROBLEMA	25
2.2.3.1. Etapa de entrenamiento o de aprendizaje	25
2.2.3.2. Etapa de prueba.....	26
2.2.3.3. Evaluación del desempeño de la modelación neuronal.....	26
2.2.4. SOFTWARE NEURAL TOOLS V.7.6	26
2.2.4.1. Análisis de NeuralTools.....	27
2.2.4.2. NeuralTools y las redes neuronales.....	28
2.2.5. PROPIEDADES DEL SUELO	30
2.2.5.1. Propiedades físicas del suelo	30
a. Humedad natural del suelo.....	30
b. Análisis granulométrico del suelo.....	30
c. Consistencia del suelo	32
• Límite líquido	32

• Límite plástico.....	33
• Índice de plasticidad	33
• Límite de contracción.....	33
d. Clasificación de los suelos mediante el sistema SUCS	33
• Suelos gruesos	34
• Suelos finos	34
e. Clasificación de los suelos mediante el sistema AASHTO	36
2.2.5.2. Propiedades mecánicas del suelo.....	37
2.2.5.2.1 Compactación de suelos	37
a. Prueba de Proctor Estándar	37
b. Prueba de Proctor Modificado	38
2.2.5.2.2 Capacidad de soporte CBR (California Bearing Ratio)	38
2.3. MARCO CONCEPTUAL	40
CAPÍTULO III METODOLOGÍA DE LA INVESTIGACIÓN	41
3.1. METODOLOGÍA Y RECOLECCIÓN DE DATOS	41
3.1.1. TIPO DE INVESTIGACIÓN	41
3.1.2. NIVEL DE INVESTIGACIÓN.....	41
3.1.3. DISEÑO DE INVESTIGACIÓN	41
3.1.4. MÉTODO DE INVESTIGACIÓN	42
3.1.5. POBLACIÓN Y MUESTRA.....	42
3.1.5.1. Población	42
3.1.5.2. Muestra.....	42
3.1.6. TÉCNICAS DE RECOLECCIÓN DE DATOS	43
3.1.7. INSTRUMENTOS DE RECOLECCIÓN DE DATOS	43
3.1.8. TÉCNICAS DE ANÁLISIS DE DATOS.....	43
3.2. PROCEDIMIENTO METODOLÓGICO DE LA INVESTIGACIÓN	44
3.2.1. RECOPIACIÓN Y CONFORMACIÓN DE LA BASE DE DATOS ESPECÍFICOS	45
3.2.1.1. Descripción de los estudios definitivos y proyectos de Provias Nacional	45
3.2.1.2. Componentes de la base de datos para el desarrollo del modelo neuronal	46
3.2.1.3. Registro de los resultados de ensayos del suelo realizados.....	47
a. Método de ensayo para la determinación del contenido de humedad del suelo	47
c. Método de ensayo para el análisis granulométrico por tamizado	49
d. Método de ensayo para determinar el Límite Líquido, Límite Plástico e Índice de Plasticidad de suelos	50
e. Ensayo de Compactación Proctor Modificado	53
f. Ensayo de CBR (California Bearing Ratio)	55

3.2.2. ANÁLISIS PRELIMINAR	59
3.2.2.1. Instalación del software Neural tools.....	59
3.2.2.2. Identificación de los datos de entrada y salida	63
3.2.2.3. Conformación de datos y entrenamiento de la Red Neuronal Artificial con el software NeuralTools.....	63
3.2.2.4 Elección de la mejor red.....	64
3.2.3. DESARROLLO DEL MODELO DE LA RED NEURONAL ARTIFICIAL.....	65
3.2.3.1. Análisis de correlación para la validación del modelo neuronal.....	65
CAPÍTULO IV RESULTADOS Y DISCUSIÓN	66
4.1. RECOPIACIÓN Y CONFORMACIÓN DE LA BASE DE DATOS.....	66
4.1.1. BASE DE DATOS DESARROLLADO EMPLEANDO LOS ESTUDIOS DEFINITIVOS DE CARRETERAS.....	66
4.1.2. RESULTADOS DE LOS ENSAYOS DE SUELOS EN LABORATORIO PARA DETERMINAR EL RENDIMIENTO DEL MODELO NEURONAL DESARROLLADO	76
4.1.2.1. Contenido de humedad	76
4.1.2.2. Análisis granulométrico por tamizado.....	77
4.1.2.3. Límites de Atterberg	77
4.1.2.4. Clasificación del suelo según el método SUCS	77
4.1.2.5. Ensayo Proctor Modificado	78
4.1.2.6. Ensayo de CBR (Valor Relativo de Soporte).....	78
4.2. ANÁLISIS PRELIMINAR	79
4.2.1. SELECCIÓN DE DATOS DE INGRESO	79
4.2.2. ARQUITECTURA Y ETAPA DE ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL.	80
4.3. RESULTADOS DEL DESARROLLO DE LOS MODELOS DE REDES NEURONALES ARTIFICIALES	81
4.3.1. ANÁLISIS DE REGRESIÓN PARA EL CBR AL 100% DE LA MDS.....	82
4.3.2. ANÁLISIS DE REGRESIÓN PARA EL CBR AL 95% DE LA MDS.	84
4.3.3. ANÁLISIS DE REGRESIÓN PARA EL ÓPTIMO CONTENIDO DE HUMEDAD (OCH %).	86
4.3.4. ANÁLISIS DE REGRESIÓN PARA LA MÁXIMA DENSIDAD SECA (MDS – GR/CM3).	88
4.4. EVALUACIÓN DEL RENDIMIENTO DEL MODELO PROPUESTO CON DATOS DE LABORATORIO (VALIDACIÓN DEL MODELO NEURONAL ARTIFICIAL)	91
4.5. DISCUSIÓN DE RESULTADOS.....	98
4.5.1. DISCUSIÓN 1	98
4.5.2. DISCUSIÓN 2	98
4.5.3. DISCUSIÓN 3.....	98
4.5.4. DISCUSIÓN 4.....	99
CONCLUSIONES	100

RECOMENDACIONES	101
REFERENCIAS BIBLIOGRÁFICAS.....	102
ANEXOS	105

ÍNDICE DE TABLAS

Tabla 1: Funciones de error de predicción.....	24
Tabla 2: Tamaño de partículas.....	31
Tabla 3: Tamaños estándar de tamices.....	31
Tabla 4: Característica del suelo según el índice plasticidad.....	33
Tabla 5: Clasificación SUCS para suelos gruesos.....	35
Tabla 6: Clasificación SUCS para suelos finos.....	35
Tabla 7: Clasificación AASHTO para suelos granulares y finos.....	36
Tabla 8: Especificaciones para la prueba Proctor Estándar.....	37
Tabla 9: Especificaciones para la prueba Proctor Modificado.....	38
Tabla 10: Lecturas para definir el CBR.....	39
Tabla 11: Descripción de los estudios definitivos empleados.....	46
Tabla 12: Base de datos específicos.....	47
Tabla 13: Descripción de los estudios definitivos utilizados.....	47
Tabla 14: Masa mínima de la porción de suelo según el tamaño máximo.....	49
Tabla 15: Datos de entrada y salida.....	63
Tabla 16: Criterio del parámetro R^2 de bondad de ajuste o coeficiente de correlación.....	65
Tabla 17: Propiedades índice y clasificación de los suelos recopilados.....	67
Tabla 18: Propiedades índice y clasificación de los suelos recopilados (continuación).....	68
Tabla 19: Propiedades índice y clasificación de los suelos recopilados (continuación).....	69
Tabla 20: Propiedades índice y clasificación de los suelos recopilados (continuación).....	70
Tabla 21: Propiedades índice y clasificación de los suelos recopilados (continuación).....	71
Tabla 22: Propiedades índice y clasificación de los suelos recopilados (continuación).....	72
Tabla 23: Propiedades índice y clasificación de los suelos recopilados (continuación).....	73
Tabla 24: Propiedades índice y clasificación de los suelos recopilados (continuación).....	74
Tabla 25: Propiedades índice y clasificación de los suelos recopilados (continuación).....	75
Tabla 26: Ensayos de suelos en laboratorio.....	76
Tabla 27: Resumen de resultados del contenido de humedad.....	76
Tabla 28: Resultado granulométrico del suelo.....	77
Tabla 29: Resultados del límite líquido, plástico e índice de plasticidad.....	77
Tabla 30: Clasificación SUCS de muestras representativas.....	78
Tabla 31: Resultados del ensayo de proctor modificado.....	78
Tabla 32: Resultados del ensayo C.B.R.....	79
Tabla 33: Datos de ingreso (azul) y datos de salida (verde).....	79
Tabla 34: Análisis de regresión lineal utilizando 6 variables de entrada.....	81

Tabla 35: Resultados de la búsqueda de la mejor red neuronal.	90
Tabla 36: Resumen de resultados del ajuste de correlaciones de la RNA versus la base de datos recopilada.	91
Tabla 37: Criterio del parámetro R^2 de bondad de ajuste o coeficiente de correlación.....	92
Tabla 38: Resumen de resultados del ajuste de correlaciones de la RNA versus los de laboratorio.....	97
Tabla 39: Comparación de resultados obtenidos con la RNA y el del laboratorio.	97

ÍNDICE DE FIGURAS

Figura 1 : Comparación de una red Neuronal Biológica y una red Neuronal Artificial	13
Figura 2 : Estructura básica de una red neuronal artificial.	14
Figura 3 : Elemento procesado de una red neuronal artificial.	15
Figura 4 : Arquitectura de una red neuronal simple.	15
Figura 5 : Taxonomía de las Redes Neuronales.	16
Figura 6 : RNA con conexiones hacia adelante Monocapa.....	18
Figura 7 : RNA con conexiones hacia adelante Multicapa.	18
Figura 8 : RNA con conexiones hacia atrás.....	19
Figura 9 :Aprendizaje Supervisado de una RNA.....	21
Figura 10 :Funciones de activación comúnmente usadas.	23
Figura 11 :Posibles tendencias de la función error.	24
Figura 12 : Curva granulométrica de un suelo e interpretación de la curva	31
Figura 13 : Límites de Atterberg.....	32
Figura 14 : Carta de Casagrande (Suelos finos y orgánicos).	36
Figura 15 : Esfuerzo vs Penetración (determinación del valor de soporte CBR).	39
Figura 16: Procedimiento metodológico.	44
Figura 17: Procedimiento de desarrollo del modelo neuronal artificial.	45
Figura 18 : Pesado de las muestras y Secado de las muestra en el horno.	48
Figura 19 : Algoritmo a seguir para determinar el contenido de humedad.....	49
Figura 20 : Tamizado de la muestra representativa.....	50
Figura 21 : Algoritmo a seguir para determinar el análisis granulométrico.	50
Figura 22 : Realizando el ensayo de límite líquido y Muestras secas para pesar.	51
Figura 22 : Algoritmo a seguir para determinar el limite líquido	52
Figura 24 : Realizando el ensayo de limite plástico y secado de muestras.	53
Figura 25 : Algoritmo a seguir para determinar el límite plástico.	53
Figura 26 : Mezclado de muestras con contenidos de agua y Compactado.	55
Figura 27 : Algoritmo a seguir para determinar la MDS.	55
Figura 28 : Mezclado de las 3 muestras con el OCH, Compactado de muestras.....	57
Figura 29 : Medición de la expansión de la muestra.	58
Figura 30 : Ensayo de penetración con prensa CBR, Muestras ensayadas.	59
Figura 31 : Algoritmo a seguir para determinar el CBR.	59
Figura 32 : Ventana de control de cuentas de usuario.	60
Figura 33 : Ventana de decisiontools Suite 7.6.1.	60
Figura 34 : Ventana de decisiontools Suite 7.6.1.	61

Figura 35: Ventana de decisiontools Suite 7.6.1.....	61
Figura 36: Ventana de decisiontools Suite 7.6.1.....	61
Figura 37: Ventana de decisiontools Suite 7.6.1.....	62
Figura 38: Ventana de decisiontools Suite 7.6.1.....	62
Figura 39: Ventana de decisiontools Suite 7.6.1.....	62
Figura 40: Identificación de datos de entrada y salida.....	63
Figura 41: Datos independientes y dependientes.....	64
Figura 42: Ventana de configuración de entrenamiento.....	64
Figura 43: Ventana de búsqueda de mejor red.....	64
Figura 44: Administrador de conjunto de datos.....	80
Figura 45: Ventana de configuración de entrenamiento.....	80
Figura 46: Mapa de las canteras que se extrajeron las muestras de suelo.....	92
Figura 47: Determinación del contenido de humedad natural de las muestras.....	106
Figura 48: Análisis granulométrico por tamizado de las muestras.....	107
Figura 49: Ensayos de límite líquido de las muestras.....	107
Figura 50: Ensayos de límite plástico de las muestras.....	108
Figura 51: Ensayo de Proctor Modificado de las muestras.....	108
Figura 52: Ensayo de Proctor Modificado de las muestras.....	109
Figura 53: Ensayo de Relación de Soporte de California CBR de las muestras.....	109
Figura 54: Ensayo de Relación de Soporte de California CBR de las muestras.....	110
Figura 55: Ensayo de Relación de Soporte de California CBR de las muestras.....	110
Figura 56: Ensayo de contenido de humedad (Muestra C-1).....	111
Figura 57: Ensayo de límites de consistencia (Muestra C-1).....	112
Figura 58: Ensayo de granulometría por tamizado (Muestra C-1).....	113
Figura 59: Ensayo de Proctor Modificado (Muestra C-1).....	114
Figura 60: Ensayo de Relación de Soporte de California CBR (Muestra C-1).....	115
Figura 61: Ensayo de Relación de Soporte de California CBR (Muestra C-1).....	116
Figura 62: Ensayo de contenido de humedad (Muestra C-2).....	117
Figura 63: Ensayo de límites de consistencia (Muestra C-2).....	118
Figura 64: Ensayo de granulometría por tamizado (Muestra C-2).....	119
Figura 65: Ensayo de Proctor Modificado (Muestra C-2).....	120
Figura 66: Ensayo de Relación de Soporte de California CBR (Muestra C-2).....	121
Figura 67: Ensayo de Relación de Soporte de California CBR (Muestra C-2).....	122
Figura 68: Ensayo de contenido de humedad (Muestra C-3).....	123
Figura 69: Ensayo de límites de consistencia (Muestra C-3).....	124
Figura 70: Ensayo de granulometría por tamizado (Muestra C-3).....	125
Figura 71: Ensayo de Proctor Modificado (Muestra C-3).....	126

Figura 72: Ensayo de Relación de Soporte de California CBR (Muestra C-3).....	127
Figura 73: Ensayo de Relación de Soporte de California CBR (Muestra C-3).....	128
Figura 74: Ensayo de contenido de humedad (Muestra C-4).	129
Figura 75: Ensayo de límites de consistencia (Muestra C-4).....	130
Figura 76: Ensayo de granulometría por tamizado (Muestra C-4).	131
Figura 77: Ensayo de Proctor Modificado (Muestra C-4).....	132
Figura 78: Ensayo de Relación de Soporte de California CBR (Muestra C-4).....	133
Figura 79: Ensayo de Relación de Soporte de California CBR (Muestra C-4).....	134
Figura 80: Ensayo de contenido de humedad (Muestra C-5).	135
Figura 81: Ensayo de límites de consistencia (Muestra C-5).....	136
Figura 82: Ensayo de granulometría por tamizado (Muestra C-5).	137
Figura 83: Ensayo de Proctor Modificado (Muestra C-5).....	138
Figura 84: Ensayo de Relación de Soporte de California CBR (Muestra C-5).....	139
Figura 85: Ensayo de Relación de Soporte de California CBR (Muestra C-5).....	140
Figura 86: Ensayo de contenido de humedad (Muestra C-6).	141
Figura 87: Ensayo de límites de consistencia (Muestra C-6).....	142
Figura 88: Ensayo de granulometría por tamizado (Muestra C-6).	143
Figura 89: Ensayo de Proctor Modificado (Muestra C-6).....	144
Figura 90: Ensayo de Relación de Soporte de California CBR (Muestra C-6).....	145
Figura 91: Ensayo de Relación de Soporte de California CBR (Muestra C-6).....	146
Figura 92: Ensayo de contenido de humedad (Muestra C-7).	147
Figura 93: Ensayo de límites de consistencia (Muestra C-7).....	148
Figura 94: Ensayo de granulometría por tamizado (Muestra C-7).	149
Figura 95: Ensayo de Proctor Modificado (Muestra C-7).....	150
Figura 96: Ensayo de Relación de Soporte de California CBR (Muestra C-7).....	151
Figura 97: Ensayo de Relación de Soporte de California CBR (Muestra C-7).....	152
Figura 98: Ensayo de contenido de humedad (Muestra C-8).	153
Figura 99: Ensayo de límites de consistencia (Muestra C-8).....	154
Figura 100: Ensayo de granulometría por tamizado (Muestra C-8).....	155
Figura 101: Ensayo de Proctor Modificado (Muestra C-8).	156
Figura 102: Ensayo de Relación de Soporte de California CBR (Muestra C-8).....	157
Figura 103: Ensayo de Relación de Soporte de California CBR (Muestra C-8).....	158
Figura 104: Ensayo de contenido de humedad (Muestra C-9).....	159
Figura 105: Ensayo de límites de consistencia (Muestra C-9).....	160
Figura 106: Ensayo de granulometría por tamizado (Muestra C-9).....	161
Figura 107: Ensayo de Proctor Modificado (Muestra C-9).	162
Figura 108: Ensayo de Relación de Soporte de California CBR (Muestra C-9).....	163

Figura 109: Ensayo de Relación de Soporte de California CBR (Muestra C-9).	164
Figura 110: Ensayo de contenido de humedad (Muestra C-10).	165
Figura 111: Ensayo de límites de consistencia (Muestra C-10).	166
Figura 112: Ensayo de granulometría por tamizado (Muestra C-10).	167
Figura 113: Ensayo de Proctor Modificado (Muestra C-10).	168
Figura 114: Ensayo de Relación de Soporte de California CBR (Muestra C-10).	169
Figura 115: Ensayo de Relación de Soporte de California CBR (Muestra C-10).	170
Figura 116: Aplicación de la Red Neuronal Artificial desarrollada.	171
Figura 117: Aplicación de la Red Neuronal Artificial desarrollada.	171
Figura 118: Aplicación de la Red Neuronal Artificial desarrollada.	172
Figura 119: Aplicación de la Red Neuronal Artificial desarrollada.	172

ÍNDICE DE GRÁFICOS

Gráfico 1: Análisis de regresión para el entrenamiento.....	82
Gráfico 2: Análisis de regresión para el modelo total.	82
Gráfico 3: Análisis de regresión para el modelo total.	83
Gráfico 4: Análisis del impacto relativo de las variables usadas en la investigación.	83
Gráfico 5: Análisis de regresión para el entrenamiento.	84
Gráfico 6: Análisis de regresión para el modelo total.	84
Gráfico 7: Análisis de regresión para el modelo total.	85
Gráfico 8: Análisis del impacto relativo de las variables usadas en la investigación.	85
Gráfico 9: Análisis de regresión para el entrenamiento.....	86
Gráfico 10: Análisis de regresión para el modelo total.	86
Gráfico 11: Análisis de regresión para el modelo total.	87
Gráfico 12: Análisis del impacto relativo de las variables usadas en la investigación.	87
Gráfico 13: Análisis de regresión para el entrenamiento.....	88
Gráfico 14: Análisis de regresión para el modelo total.	88
Gráfico 15: Análisis de regresión para el modelo total.	88
Gráfico 15: Análisis de regresión para el modelo total.	89
Gráfico 16: Análisis del impacto relativo de las variables usadas en la investigación.	89
Gráfico 17: Correlación de los datos (CBR al 100% MDS) de RNA y laboratorio	93
Gráfico 18: Correlación de los datos (CBR al 100% MDS) de RNA y laboratorio.....	93
Gráfico 19: Correlación de los datos (CBR al 95% MDS) de RNA y laboratorio.	94
Gráfico 20: Correlación de los datos (CBR al 95% MDS) de RNA y laboratorio.	94
Gráfico 21: Correlación de los datos (OCH) de RNA y laboratorio.....	95
Gráfico 22: Correlación de los datos (OCH) de RNA y laboratorio.....	95
Gráfico 23: Correlación de los datos (MDS) de RNA y laboratorio.....	96
Gráfico 24: Análisis de regresión para la validación (predicción vs real).....	96

RESUMEN

El presente trabajo de tesis titulada “PREDICCIÓN DE PROPIEDADES MECÁNICAS DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES”, consiste en realizar la predicción de propiedades mecánicas de suelos (valor relativo de soporte CBR al 100%, 95%, Optimo contenido de humedad, Máxima densidad seca) utilizando modelos neuronales (Redes Neuronales Artificiales), a partir de sus propiedades índices del suelo (Granulometría, límites de consistencia). Para alcanzar el objetivo de la investigación, se realizó la recopilación y desarrollo de una base de datos de las propiedades mecánicas y físicas del suelo de los estudios y proyectos definitivos realizados por Provias Nacional. Una vez desarrollado la base de datos, se procedió a realizar el entrenamiento del modelo de la Red Neuronal Artificial, mediante las variables de entrada (porcentajes de grava, arena, finos, limite líquido, limite plástico, índice de plasticidad) y de salida (CBR al 100%, CBR al 95%, Optimo contenido de humedad, Máxima densidad seca), mediante el cual se realizó varias pruebas de ensayo-error buscando la mejor red neuronal con asistencia del software NeuralTools, con la cual se obtuvo 4 mejores modelos neuronales, en la que se utilizó el 80% de datos para el entrenamiento de los modelos neuronales y 20% para el proceso de prueba del modelo. Seguidamente para el proceso de validación de los modelos neuronales se realizó ensayos de laboratorio como ensayos de granulometría, límites de consistencia, Proctor modificado y CBR, mediante el cual se evaluó y comparó con en el modelo neuronal; es sí que se buscó un modelo neuronal eficiente y con una buena precisión. Como ya se mencionó, la metodología de investigación se basó en el desarrollo de una base de datos para el diseño de la estructura de la red neuronal artificial, para lo cual se tuvo que realizar el proceso de entrenamiento, prueba y validación del modelo neuronal. Los resultados obtenidos del trabajo de investigación, para el proceso de entrenamiento se obtuvo una buena correlación (coeficiente de correlación de Pearson entre 0.7 a 0.89), así como la de prueba. En el proceso de validación se comparó los resultados del modelo neuronal con los resultados obtenidos de los ensayos realizados en laboratorio, resultando una buena correlación (coeficiente de correlación de Pearson entre 0.7 a 0.89). Llegando así a desarrollar un modelo neuronal eficaz que pueda predecir las propiedades mecánicas de suelos con errores mínimos, proponiéndose como una alternativa en el estudio de la mecánica de suelos. Mediante el cual se puede adelantar algunos resultados para la toma de decisiones que requieran una atención inmediata, teniendo en claro que no se pretende reemplazar a ninguno de los ensayos realizados en laboratorio.

Palabras clave: Inteligencia Artificial, Red Neuronal Artificial, Propiedades físicas y mecánicas del suelo.

ABSTRACT

The present thesis titled "PREDICTION OF MECHANICAL PROPERTIES OF SOILS USING NEURAL ARTIFICIAL NETWORKS", consists of making the prediction of mechanical properties of soils (relative value of CBR support at 100%, 95%, Optimum moisture content, Maximum dry density) using neuronal models (Artificial Neural Networks), from their soil index properties (Granulometry, limits of consistency).

To achieve the objective of the investigation, the compilation and development of a database of the mechanical and physical properties of the soil of the studies and definitive projects carried out by Provias Nacional was carried out. Once the database was developed, the training of the Artificial Neural Network model was carried out, using the input variables (percentages of gravel, sand, fines, liquid limit, plastic limit, plasticity index) and output (100% CBR, 95% CBR, Optimum moisture content, Maximum dry density), through which several trial-and-error tests were conducted searching for the best neural network with the assistance of the NeuralTools software, with which 4 better models were obtained neuronal, in which 80% of data was used for the training of neuronal models and 20% for the model testing process. Then, for the validation process of the neuronal models, laboratory tests were carried out, such as granulometry tests, consistency limits, modified Proctor and CBR, by means of which it was evaluated and compared with in the neuronal model; Yes, we looked for an efficient neuronal model with good precision. As already mentioned, the research methodology was based on the development of a database for the design of the structure of the artificial neural network, for which the process of training, testing and validation of the neuronal model had to be performed. The results obtained from the research work, for the training process was obtained a good correlation (Pearson correlation coefficient between 0.7 to 0.89), as well as the test. In the validation process, the results of the neuronal model were compared with the results obtained from the laboratory tests, resulting in a good correlation (Pearson correlation coefficient between 0.7 to 0.89). In this way, we develop an effective neuronal model that can predict the mechanical properties of soils with minimal errors, proposing them as an alternative in the study of soil mechanics. By means of which it is possible to advance some results to make decisions that require immediate attention, being clear that it is not intended to replace any of the tests carried out in the laboratory.

Keywords: Artificial Intelligence, Artificial Neural Network, Physical and mechanical properties of the soil.

INTRODUCCIÓN

En todo proyecto de construcción, el suelo es de mucha importancia, ya que ésta se encarga de darle a la estructura un comportamiento estable. Por lo que es necesario y muy importante el estudio de mecánica de suelos, siendo las propiedades mecánicas y físicas del suelo necesarias para los diferentes diseños de infraestructura ingenieril. Para ello se debe realizar ensayos de laboratorio mediante el cual se determina estas propiedades físicas y mecánicas del suelo, como ensayos de granulometría, límites de consistencia, Proctor modificado y valor relativo de soporte CBR, en el caso de obras de carreteras, siendo estos resultados indispensables en el estudio de la mecánica del suelo.

Sin embargo, para poder tomar decisiones que requieran una respuesta de manera inmediata, es necesario de contar con una metodología nueva de obtener las propiedades mecánicas del suelo, de tal forma que sea eficiente y de una buena precisión de resultados, y además en la simplicidad de los datos de entrada, así como los ensayos básicos o índices del suelo como la granulometría y límites de consistencia que son parte de las propiedades físicas del suelo. Por ello este trabajo de investigación tuvo como objetivo principal desarrollar un modelo neuronal artificial capaz de predecir estas propiedades mecánicas del suelo con el menor error posible, tomando como ayuda al software NeuralTools. Para desarrollar el modelo neuronal, se tuvo como datos de entrada a la granulometría y límites de consistencia, y de manera independiente se tuvo como dato de salida al óptimo contenido de humedad, máxima densidad seca, valor relativo de soporte al 100% y 95% de la máxima densidad seca. Para el desarrollo del modelo neuronal se realizaron los procesos de entrenamiento, prueba, y validación, donde para determinar el indicador de confiabilidad del uso del modelo neuronal, se evaluó el factor de correlación entre los valores determinados según la Red Neuronal Artificial (predicciones) y los obtenidos en laboratorio (reales). Llegando así a obtener un modelo predictivo basado en redes neuronales artificiales.

Para ello la investigación consta de cinco capítulos:

En el capítulo I, se describe el planteamiento de la investigación donde se aprecia la problemática, objetivos, justificación, delimitación de la investigación, formulación de la hipótesis y las variables que se investigan.

En el capítulo II, se presenta el marco teórico, donde se describen los antecedentes respecto a las redes neuronales artificiales como metodologías para predecir diversos problemas; en las bases teóricas se presentan y describen puntos importantes para la investigación como: Red

Neuronal Artificial, procesos para el diseño de un modelo neuronal óptimo, Propiedades mecánicas del suelo, Propiedades físicas del suelo.

En el capítulo III, se presenta el marco metodológico, por lo que se detalla el tipo, nivel, diseño, método de la investigación. Aquí también se describe la población, muestra, instrumentos para la recolección y análisis de datos.

En el capítulo IV, se realiza el análisis y discusión de resultados, en los cuales se presentan la base de datos que se recopilaron, así como los resultados de los ensayos que se realizaron, también se presenta los procesos de desarrollo del modelo neuronal, así como la validación de este.

En el capítulo V, se responden a las preguntas de los problemas de investigación mediante todas las conclusiones y recomendaciones a las que se llegaron.

Finalmente se presentan los anexos que comprenden los ensayos de laboratorio realizados, memorias de cálculo y el panel fotográfico.

CAPÍTULO I

PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1. PLANTEAMIENTO Y FORMULACIÓN DEL PROBLEMA

1.1.1. PLANTEAMIENTO DEL PROBLEMA

Actualmente nuestro país se encuentra en un crecimiento económico, debido a ello se ha impulsado el sector construcción, tal es así que, en la región Junín, se vienen ejecutando grandes proyectos en edificaciones, infraestructura vial, obras hidráulicas, infraestructuras educativas, puentes etc.

Dentro de las infraestructuras viales, que van a generar el desarrollo económico y social de muchas localidades tanto en el ámbito urbano y rural, se vienen desarrollando estudios y ejecuciones de carreteras usando, pavimentación flexible, rígido, así como simplemente a nivel de afirmado, en donde el suelo llega a tener una participación importante, esto debido a su influencia en los diseños de estructuras de ingeniería, sin embargo, ante el sobredimensionamiento de muchas estructuras y en otras ocasiones el manejo deficiente y erróneo de los estudios de mecánica de suelos en el diseño de de ingeniería, nos conduce en general a despertar grandes dudas sobre los resultados obtenidos de las propiedades del suelo, lo cual hace que los ingenieros no cuenten con información precisa para el diseño de estructuras de ingeniería.

Mediante el uso de un programa especializado que recurre a las redes neuronales dentro de su algoritmo computacional, se podrá determinar las propiedades mecánicas del suelo, adelantando algunos datos para la toma de decisiones que requieran una atención inmediata y validar mediante un control de calidad, los resultados de los ensayos realizados.

Tal es así, que surge la idea de utilizar un software basado en algoritmos de redes neuronales para determinar las propiedades mecánicas del suelo de manera inmediata con el menor error posible, solamente a partir de las propiedades físicas del suelo que constan de ensayos muy sencillos y con un costo mínimo.

1.1.2. FORMULACIÓN DEL PROBLEMA

1.1.2.1. Problema general

¿Es posible determinar los resultados de los ensayos de las propiedades mecánicas de los suelos usando un software basado en algoritmos de redes neuronales artificiales?

1.1.2.2. Problemas específicos

- ¿Qué información se debe recopilar para formar una base de datos que permita determinar las propiedades mecánicas de los suelos, usando el software basado en Algoritmos de Redes Neuronales Artificiales?
- ¿Cómo se puede seleccionar la topología de la Red Neuronal Artificial óptima y estimar los pesos utilizando para cada criterio evaluado y poder determinar las propiedades mecánicas del suelo?
- ¿Es posible evaluar y comparar el rendimiento del modelo propuesto con datos reales, para determinar el nivel de precisión del modelo neuronal que determine las propiedades mecánicas de los suelos?

1.2. OBJETIVOS

1.2.1. OBJETIVO GENERAL

- ✓ Encontrar los resultados de los ensayos de las propiedades mecánicas de los suelos usando un software basado en algoritmos de redes neuronales artificiales.

□

1.2.2. OBJETIVOS ESPECÍFICOS

- ✓ Recopilar una base de datos que permita determinar las propiedades mecánicas de los suelos, usando el software basado en Algoritmos de Redes Neuronales Artificiales.

- ✓ Seleccionar la topología de la Red Neuronal Artificial óptima y estimar los pesos utilizando para cada criterio evaluado y poder determinar las propiedades mecánicas del suelo.
- ✓ Evaluar y comparar el rendimiento del modelo propuesto con datos reales, para determinar el nivel de precisión del modelo neuronal que determine las propiedades mecánicas de los suelos.

1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN

1.3.1. JUSTIFICACIÓN PRÁCTICA

En la presente investigación se busca a través de un software basado en algoritmos de redes neuronales artificiales, determinar resultados sobre las propiedades mecánicas del suelo, a partir de sus características físicas. Ya que nosotros como profesionales inmersos en la construcción, tomemos mejores decisiones, realizando un control de calidad de resultados de los ensayos ejecutados mediante la aplicación de estos modelos neuronales, lo que representa una manera muy fácil y accesible de obtener estas propiedades, trayendo consigo ahorro económico y optimización del tiempo.

1.3.2. JUSTIFICACIÓN METODOLÓGICA

La presente investigación propone la aplicación del método probabilístico en la determinación de redes neuronales artificiales para dar soporte a un software que nos permita la formación de redes lógicas para determinar las propiedades mecánicas del suelo, la cual estas están compuestas por neuronas en la que cada neurona representa un código de una variable; donde las variables de entrada, serán los porcentajes de granulometría, límites de consistencia, además la variable de salida será la capacidad de soporte CBR al 100% y 95%, máxima densidad seca del suelo, óptimo contenido de humedad, estos serán tomados de los proyectos de referencia ejecutados por Provias Nacional, con dicho entrenamiento de la Red Neuronal Artificial se formará la estructura en la que se ingresarán las variables de entrada para luego obtener la variable de salida, es así que se generaran y determinarán las propiedades mecánicas del suelo.

1.3.3. JUSTIFICACIÓN ECONÓMICA

Se puede tener resultados confiables de las propiedades mecánicas del suelo mediante el uso de los modelos neuronales desarrollados por el software en base a las propiedades físicas del suelo, resultando así más económica y con un alto porcentaje de confiabilidad en un corto tiempo. Además, se determinarán a partir de las propiedades físicas del suelo los cuales constan de ensayos muy sencillos y con un costo mínimo.

1.4. DELIMITACIÓN DE LA INVESTIGACIÓN

1.4.1. CONCEPTUAL

La presente investigación contempla conceptos de Inteligencia Artificial aplicado a determinar resultados de diversos problemas, específicamente en el área de la mecánica de suelos. Esta investigación se enfocó en la determinación de las propiedades mecánicas del suelo mediante el desarrollo de modelos de Redes Neuronales Artificiales por parte del software de programación, ya que por medio de estas se pueden determinar resultados de diversos problemas. Para esta investigación, se recopilaron bases de datos de estudios definitivos de Provias Nacional, y a partir de estos datos se entrenó una red neuronal capaz de estimar las propiedades mecánicas de suelos para nuevos casos particulares.

1.4.2. ESPACIAL

La presente investigación contempla conceptos de Inteligencia Artificial aplicado a determinar resultados de diversos problemas, específicamente en el área de la mecánica de suelos. Esta investigación se enfocó en la determinación de las propiedades mecánicas del suelo mediante el uso de un software cuyos algoritmos se basan en las Redes Neuronales Artificiales, ya que por medio de estas se pueden determinar múltiples resultados en una fracción de tiempo. Para esta investigación, se recopilaron bases de datos de estudios definitivos de Provias Nacional, y a partir de estos datos se entrenó una red neuronal capaz de estimar las propiedades mecánicas de suelos para nuevos casos particulares.

1.4.3. TEMPORAL

El desarrollo del proyecto de investigación, así como la recopilación de bases de datos, el entrenamiento del software basado en algoritmos de redes neuronales y la

realización de ensayos de suelos para su posterior validación se llevó a cabo en los meses de diciembre 2018 y abril del 2019.

1.5. HIPÓTESIS

1.5.1. HIPÓTESIS GENERAL

Es posible encontrar los resultados de los ensayos de las propiedades mecánicas de los suelos usando un software basado en algoritmos de redes neuronales artificiales.

1.5.2. HIPÓTESIS ESPECÍFICAS

- Existe información para formar una base de datos que permita determinar las propiedades mecánicas de los suelos, usando el software basado en Algoritmos de Redes Neuronales Artificiales.
- Se puede seleccionar la topología de la Red Neuronal Artificial óptima y estimar los pesos utilizando para cada criterio evaluado y poder determinar las propiedades mecánicas del suelo.
- Se puede evaluar y comparar el rendimiento del modelo propuesto con datos reales, para determinar el nivel de precisión del modelo neuronal que determine las propiedades mecánicas de los suelos

1.6. VARIABLES

1.6.1. VARIABLE INDEPENDIENTE

Sistema experto basado en redes neuronales artificiales.

1.6.2. VARIABLE DEPENDIENTE

Propiedades mecánicas del suelo.

CAPÍTULO II

MARCO TEÓRICO

2.1. ANTECEDENTES DEL PROBLEMA

Las obras de ingeniería vial desempeñan un importante aporte al desarrollo social, económico y físico de una región, debido a que permiten una conexión cultural entre los pueblos. Debido a ello la importancia de tener un buen sistema vial, por ende, una buena administración y gestión de la infraestructura, durante toda la ejecución de las obras, realizando evaluaciones y controles de calidad con respecto a los diseños, estudios de mecánicas de suelos, etc.

A continuación, se presentan los antecedentes de esta investigación sobre el uso de las Redes Neuronales Artificiales, ya que estas son utilizadas desde los años 90 para la predicción de diversos problemas.

2.1.1. ANTECEDENTES INTERNACIONALES

(Beltrán Calvo, 2012), para optar el grado de Doctor en Ingeniería Civil – Geotecnia, sustentó en la Universidad Nacional Autónoma de México la tesis titulada: “Evaluación estructural de pavimentos flexibles con métodos de inteligencia artificial y auscultación no destructiva”. La investigación planteó como objetivo estructurar un sistema de modelación no convencional, empleando modelos neuronales basados en las redes neuronales artificiales (RNA) y Lógica Difusa (LD), para identificar parámetros de comportamiento de pavimentos y evaluación estructural mediante auscultación no destructiva, con el fin de determinar la condición de rigidez y deterioro e identificar posibles intervenciones en sectores con problemas. El procedimiento metodológico consistió en determinar los modelos de capa mediante las redes neuronales artificiales y con la lógica difusa diseñar tres sistemas para inferir la condición de rigidez, deterioro y recomendaciones de conservación. Como parte final, se muestran los resultados obtenidos los cuales fueron, una evaluación integral de la condición estructural del pavimento flexible, por lo que se concluye que las redes neuronales artificiales y la lógica difusa poseen una inmensa capacidad de

procesamiento e interpretación de información (simulación de comportamientos), con lo cual se encuentra una solución de evaluación y gestión de pavimentos, usando la inteligencia artificial.

(Rojas Godoy, 2015), para optar el grado de Ingeniero Civil en Informática, sustentó en la Pontificia Universidad Católica de Valparaíso la tesis titulada: "Predicción de accidentes de tránsito utilizando redes neuronales artificiales y Cuckoo Search". Esta investigación tuvo como objetivo principal desarrollar un modelo para la predicción de accidentes de tránsito ocurridos en la región de Valparaíso, utilizando una Red Neuronal Artificial con el algoritmo de optimización Cuckoo Search.

La metodología desarrollada fue que, a partir de una serie de datos de accidentes de tránsito ocurridos en la región de Valparaíso, se obtuvo una serie suavizada por medio de la Media Móvil y una serie sin suavizar. Para ambos casos se utilizó un modelo de Red Neuronal Artificial junto a las metaheurísticas Cuckoo Search (CS) y Optimización por Enjambre de Partículas (PSO), obteniendo finalmente 4 modelos predictivos. Los resultados mostraron una mejora sustantiva en el caso de la serie suavizada en comparación a la serie sin suavizar. Para el caso de la serie suavizada, la topología óptima hallada para CS fue de 5 nodos de entrada, 8 nodos ocultos y 1 nodo de salida, mientras que para PSO fue de 13 nodos de entrada, 10 nodos ocultos y 1 nodo de salida. Entre la serie suavizada se evidencia una superioridad de CS sobre PSO en la métrica Porcentaje de Error Absoluto Medio (MAPE), obteniendo 12,11% y 14,96% respectivamente, mientras que en el caso de las otras métricas medidas correspondiente a la Raíz del Error Cuadrático Medio (RMSE), Coeficiente de Correlación (R) y Coeficiente de Determinación (R²), la diferencia fue mínima.

(Sarraute, 2007), para optar el grado de Licenciatura en Ciencias, sustentó en la Universidad de Buenos Aires la tesis titulada: "Aplicación de las redes neuronales al reconocimiento de sistemas operativos". Este trabajo de investigación tuvo como principal objetivo en la detección de sistemas operativos con la recolecta de información donde además se presentó algunas familias de redes neuronales, las redes de perceptrones multi-capas, y algunos de los algoritmos que se usan para entrenarlas (esperamos que con suficientes detalles y precisión como para satisfacer un público matemático). Estas redes neuronales serán usadas para resolver problemas que surgen en el campo de seguridad informática, la cual es la detección a distancia del sistema operativo. Con lo cual el aporte de este trabajo

es una aplicación de técnicas clásicas de inteligencia artificial a un problema de clasificación que brindó mejores resultados que las técnicas clásicas usadas para resolverlo.

2.1.2. ANTECEDENTES NACIONALES

(Vila Zuñiga, 2017), para optar el grado de Ingeniero Civil, sustentó en la Universidad Nacional del Centro del Perú la tesis titulada: "Análisis del comportamiento lineal de la estructura del pavimento flexible mediante redes neuronales en la carretera Panamericana Norte". Este proyecto de investigación tuvo como objetivo principal determinar el comportamiento lineal de la estructura de pavimento flexible mediante el uso de redes neuronales en la carretera Panamericana Norte, en el cual se desarrolla un modelo neuronal capaz de estimar módulos de elasticidad a partir de datos de deflexión mediante pruebas no destructivas y retro análisis modulares obtenidos con los softwares MICHBACK y BACKVIDE, mediante esto llega a desarrollar un modelo de análisis del comportamiento lineal de un sistema multicapa con el uso de redes neuronales artificiales. Para obtener una red neuronal optima, en el diseño se tuvo que realizar una intensa labor, llegando a resultar un modelo eficiente y confiable. Para la evaluación de la carretera Panamericana Norte se realizó a partir del modelo neuronal optimo, analizando el comportamiento lineal del Tramo I perteneciente al proyecto de Conservación Vial Sullana. De los resultados obtenidos se realiza un análisis con el apoyo de los indicadores estructurales de pruebas de deflexión y del numero estructural teórico y efectivo, encontrándose en el sector 4 bajos valores de módulos elásticos (menores a 10 000MPa) y con deflexiones máximas (0.6 μm), donde se evidencia que los módulos elásticos son congruentes con los indicadores estructurales. Cabe mencionar que los módulos elásticos en la subrasante obtenidos con la red neuronal, Michback y CVS son parecidos y tienen la misma tendencia con un valor promedio de 175 MPa. De igual manera ocurre con el numero estructural efectivo, siendo el sector I con los valores más bajos (menores de 3) lo que evidencia intervención en este sector.

(Vega Huerta, 2011), para optar el grado de Doctor en Ingeniería de Sistemas, sustentó en la Universidad Nacional Federico Villareal la tesis titulada “Redes neuronales para el reconocimiento de la calidad morfológica de mangos exportables para la empresa Biofruit del Perú S.A.C.” La investigación tuvo como objetivo entrenar una red neuronal que sea capaz de reconocer la calidad morfológica de los mangos de exportación con un margen de error menor al 5%. El procedimiento metodológico es mediante la toma digital de cada mango, para luego usar estas imágenes, y mediante un sistema, entrenar una red neuronal que reconozca acertadamente todos los elementos de la muestra.

Luego se precedió con las pruebas de reconocimiento con otros mangos de calidad y con los que no presentan dichas características, y si el software los reconoce acertadamente, diremos que hemos cumplido con nuestro objetivo. Como resultados se llega a concluir que, la empresa Biofruit puede realizar la clasificación de mangos exportables con un margen de error de 2.33% mediante un sistema experto basado en redes neuronales artificiales. Cabe mencionar que el error del personal de clasificación de mangos es de 17.3%, lo que nos dice que se llegó a obtener una optimización del 15%.

(Alvarez Ledesma, 2015), para optar el grado de Ingeniero Civil, sustentó en la Universidad Nacional del Centro del Perú la tesis titulada “Generación de caudales con modelos de redes neuronales artificiales a partir de las características de una cuenca”. La investigación tuvo como objetivo generar caudales con modelos de redes neuronales artificiales a partir de las características de una cuenca, mediante el cual se buscan generar caudales de los ríos en cuencas que no están siendo aforadas tales como la cuenca del río Huayanay en la provincia de Acobamba-Huancavelica, para lo cual se aplicaron métodos de recolección de datos y reconocimiento, de las estaciones hidrométricas y pluviométricas en distintos puntos de la cuenca del Mantaro, así como la medición in situ o directa en la cuenca del río Huayanay. Mediante esta base de datos se llegó a construir un complejo mecanismo de cálculo con modelos de redes neuronales artificiales que permiten generar caudales mensuales en subcuencas y microcuencas pertenecientes a la cuenca del Mantaro. Para lo cual el mecanismo fue calibrado con datos de 15 subcuencas y microcuencas pertenecientes a la misma, teniendo como variables de entrada a los parámetros fisiográficos, meteorológico y usos de suelo, con lo que dicho mecanismo fue entrenado con datos hidrométricos de cuencas aforadas para luego generar el caudal en cuencas no aforadas.

2.2. BASES TEÓRICAS

2.2.1. REDES NEURONALES ARTIFICIALES (RNA)


La red neuronal artificial fue empleada por primera vez por Russell en 1913, llegando a tomar fuerza a inicios de la década de los 40 llegando así a evolucionar hasta la actualidad.

Warren McCulloch y Walter Pitts realizaron la primera modelación matemática de una red neuronal artificial, donde el factor clave de un modelo neuronal es la característica de la capacidad de aprendizaje, donde las neuronas operan mediante impulsos binarios.

(Anderson, 1995), define a la red neuronal artificial como un modelo computacional inspirado en las redes neuronales biológicas, que puede llegar a considerarse como un sistema de procesamiento de información con una estructura distribuida de procesamiento paralelo, formadas de elementos de procesamiento que son las neuronas artificiales, que están interconectadas por una gran cantidad de conexiones que se denominan sinapsis.

Estas conexiones son utilizadas para almacenar información que está disponible para poder ser usado. Por lo que, en resumen, las redes neuronales artificiales intentan emular las funciones elementales de la red nerviosa del cerebro humano, en base a la interconexión de un sin número de elementos de procesamiento (neuronas o nodos), los cuales cada procesamiento adquiere un comportamiento completamente distinto o local, con el fin de recibir señales de entrada, procesarlas y emitir señales de salida. (Anderson, 1995)

Figura 1 : Comparación de una red Neuronal Biológica y una red Neuronal Artificial



Fuente: (Hilera, y otros, 1995)

2.2.1.1. La Neurona Artificial

(Satish, 2007), menciona que la neurona artificial fue desarrollada y diseñada para emular el funcionamiento básico de una neurona biológica. Este funcionamiento está basado en variables o grupos de entradas a la neurona, la cual esta es multiplicada por su porcentaje de peso o ponderación correspondiente análoga al grado de conexión de la sinapsis. También describe que las entradas ponderadas se adicionan y se calcula el nivel de excitación o activación de la neurona, y mediante las interconexiones de cada una de ellas se emiten señales de salidas.

2.2.1.2. Características de las redes artificiales

(Bredenhann, y otros, 2004), mencionan las características más importantes de la red neuronal, las cuales se describen a continuación.

- **Aprendizaje adaptativo:** Las redes neuronales artificiales al igual que las neuronas biológicas consiguen información y conocimiento sobre algo por medio del ejercicio, estudio o experiencia. A estas redes neuronales artificiales se les asigna un conjunto de entradas, y estas mismas neuronas

se entrenan para emitir salidas consistentes. Cabe mencionar que estas pueden alterar su comportamiento en función del entorno.


- **Generalización:** Las redes neuronales artificiales se amplifican automáticamente debido a su propia estructura que se desarrolla. En base a esto, las redes pueden predecir dentro de un margen, respuestas correctas a entradas que presentan pequeñas variaciones debido a la distorsión presentada.

- **Abstraer:** Las redes neuronales artificiales poseen la capacidad de aislar mentalmente o evaluar por separado las cualidades de un objeto. Además, son capaces de abstraer la esencia de un conjunto de entradas que aparentemente no poseen características, cualidades o aspectos comunes.

2.2.1.3. Estructura básica de una red neuronal

(Freeman, y otros, 1991), describen a la estructura básica de una red neuronal, la cual contempla lo siguiente:

Figura 2 : Estructura básica de una red neuronal artificial.




Fuente: Neural Networks - Algorithms, Applications and Programming Techniques.

- Conjunto de entradas (vector de entradas)
- Conjunto de pesos sinápticos, representa la interacción entre la neurona pre sináptica y la post sináptica.
- Regla de propagación, proporciona el potencial post sináptico.
- Función de activación, proporciona el estado de activación de la neurona en función del estado anterior y del valor post sináptico.

- Función de salida, proporciona la salida en función del estado de activación.

(Flores, y otros, 2008), explican y describen a la red neuronal como un conjunto de neuronas infinitamente interconectadas, el cual la salida (axón) de la neurona se ramifica y se encuentra conectada a las entradas (dentritas) de las otras neuronas a través de conexiones (sinapsis). Durante la etapa de aprendizaje de la red, la sinapsis se va modificando y mejorando, llegando así a obtener una red eficaz.


Figura 3 : Elemento procesado de una red neuronal artificial.



Fuente: (Beltrán Calvo, 2012).

La red típica consiste en una serie de capas con conexiones entre capas inmediatas consecutivas, estos grupos denominados capas o niveles son organizados por los elementos procesadores. (Flores, y otros, 2008)

Figura 4 : Arquitectura de una red neuronal simple.




Fuente: (Flores, y otros, 2008)

- Los sensores del sistema dirigen señales desde el entorno a las neuronas de entrada, como unos patrones de aprendizaje o archivos de almacenamiento.
- Una vez finalizado el tratamiento de la información las neuronas de salida envían señales directamente fuera del sistema (salidas de la red).
- El procesamiento básico de la información se lleva a cabo en las neuronas ocultas, las cuales reciben estímulos y emiten salidas dentro del sistema, sin ningún contacto alguno con el exterior.

2.2.1.4. Clasificación de la red neuronal artificial (RNA)

(Charytoniuk, 2000), clasifica a las redes neuronales artificiales según su arquitectura o topología de conexión, tipo de aprendizaje y según sus aplicaciones:

Figura 5 : Taxonomía de las Redes Neuronales.



Fuente: (Charytoniuk, 2000)

2.2.1.4.1 Según su Arquitectura de la red neuronal

(Yegnanarayana, 2006), explica que la topología o arquitectura de una red neuronal se establece por el número de neuronas, de las conexiones presentes entre ellas y las disposiciones de las mismas.

Las principales tipologías de red son monocapa, multicapa y recurrentes, lo cual las dos primeras se denominan propagación hacia adelante, ya que son redes acíclicas puesto que no poseen uniones de retroalimentación, esto significa que ninguna salida es una entrada de otra neurona del mismo nivel o de niveles anteriores, sin embargo, las redes de tipología recurrentes se les denomina redes de retroalimentación o redes de retropropagación, ya que son cíclicas, puesto que las salidas de las neuronas pueden ser entradas de neuronas del mismo nivel de neuronas anteriores o de la misma neurona. En base a esto se demuestra que las redes multicapa poseen cualidades por encima de las redes monocapa, con lo cual las redes más usadas son la multicapa y las recurrentes. Pero el desempeño de la red neuronal va a depender específicamente de la calidad y cantidad de datos presentados a la red, con la cual las neuronas lleguen a tener la mayor cantidad de interconexiones (arquitectura de la red) y además que tan fuerte son esas conexiones (valor de los pesos) y de la manera de aprendizaje (algoritmo de aprendizaje). De esta manera, se desarrolla la estructura y se determina el estado de activación de la red neuronal, la cual representa el conocimiento o información que se adquiere para interpretar, predecir y responder posteriormente ante estímulos externos.(Yegnanarayana, 2006)

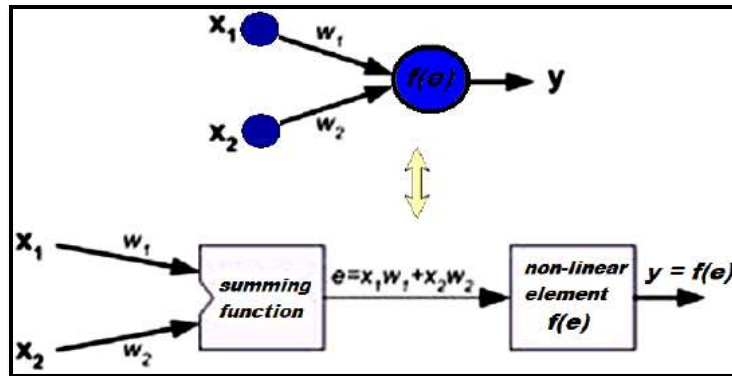
a. Con conexiones hacia adelante (No recurrentes o Feedforward)

Son aquellas redes cuyas conexiones son hacia adelante y unidireccionales, y se clasifican según el número de capas que poseen:

• Redes Neuronales Monocapa

Estas redes solo poseen una capa de neuronas que proyectan hacia las entradas a una capa de neuronas de salida, donde se realizan diversos cálculos.

Figura 6 : RNA con conexiones hacia adelante Monocapa.



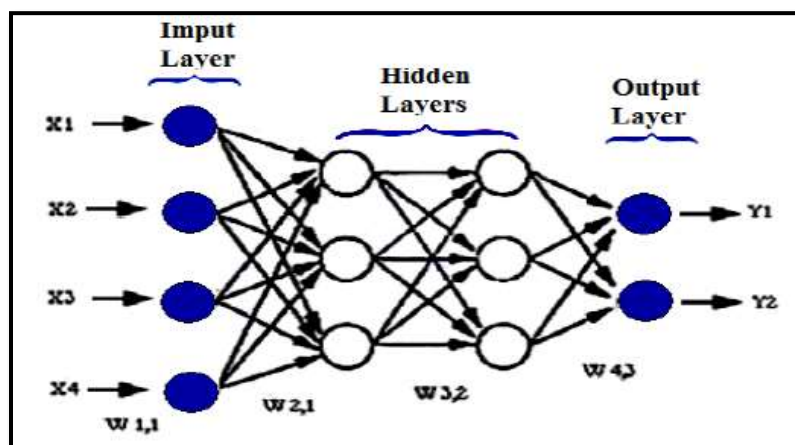
Fuente: (Charytoniuk, 2000)

Las redes neuronales artificiales más conocidas con esta arquitectura son: Monolayer Perceptron y el Adaline.

• Redes Neuronales Multicapa

Estas redes vienen a ser la extensión de una red neuronal monocapa, en cual poseen un conjunto de capas intermedias entre la entrada y la salida.

Figura 7 : RNA con conexiones hacia adelante Multicapa.




Fuente: (Charytoniuk, 2000)

Las redes neuronales artificiales más conocidas con esta arquitectura son: Multilayer Perceptron y el Madaline.

b. Con conexiones hacia atrás (Recurrentes o Feedback)

Son aquellas redes que se caracterizan por la existencia de las conexiones de retorno entre neuronas de una determinada capa con otras de capas anteriores, conexiones entre neuronas con una misma capa o conexiones de una neurona consigo misma.

Figura 8 : RNA con conexiones hacia atrás.



Fuente: (Charytoniuk, 2000)

Las redes neuronales artificiales más conocidas con esta arquitectura son: las SOM de Kohonen, Hopfield y las redes ART.

2.2.1.4.2 Según su aprendizaje de las Redes Neuronales Artificiales

(Goktepe, y otros), mencionan que la característica principal de la red neuronal es la capacidad de aprendizaje, mediante el cual la finalidad del entrenamiento de esta red neuronal es conseguir que una aplicación establecida, para un conjunto de entradas determine el conjunto de salidas deseadas o mínimamente consistentes. La metodología de entrenamiento de la red neuronal consiste en la aplicación secuencial de diversos conjuntos o vectores de entradas para que se ajusten los pesos de las interconexiones según un procedimiento determinado. Además, se menciona que, en el proceso de entrenamiento, los

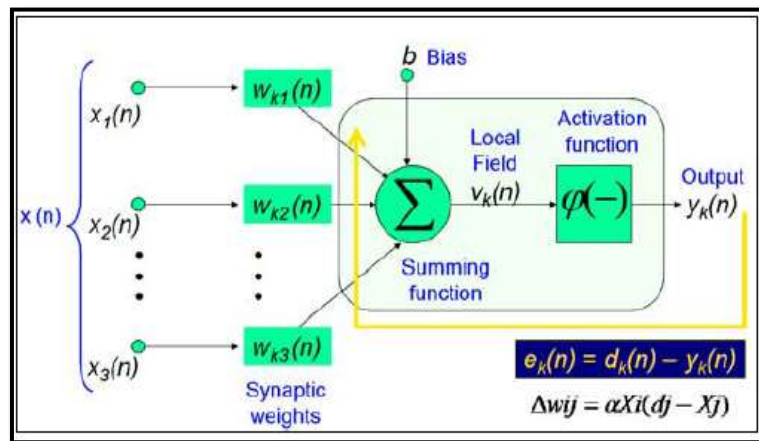
pesos convergen gradualmente hacia los valores que hacen que cada variable de entrada produzca el vector de salida deseado. Los algoritmos de entrenamiento o los procedimientos de ajuste de los valores de las conexiones de las redes neuronales artificiales se pueden clasificar en dos grupos: Supervisado y No Supervisado.

a. Entrenamiento Supervisado

(Bredenhann, y otros, 2004), explican que, cuando en el entrenamiento de la red neuronal artificial existe un parámetro de referencia ya conocido, se trata de un aprendizaje o entrenamiento supervisado. Este parámetro conocido es comparado con las salidas de la red, con lo cual decimos que el aprendizaje supervisado se caracteriza por un entrenamiento controlado por un agente externo que determina la respuesta que debería generar la red neuronal a partir de un vector de entrada determinada. Una vez terminado el proceso de entrenamiento, el supervisor comprueba la salida de la red, y en el caso de que esta no coincida con la deseada, se procederá a modificar los pesos de las conexiones. La finalidad de modificar los pesos de las conexiones es la de conseguir que la salida obtenida se aproxime a la deseada; con lo cual para realizar un aprendizaje supervisado se requiere disponer de un conjunto de patrones de los cuales se conoce su clase cierta.

Este tipo de entrenamiento se denomina entrenamiento o aprendizaje supervisado y los clasificadores así obtenidos son clasificadores supervisados.

Figura 9 :Aprendizaje Supervisado de una RNA.



Fuente: (Charytoniuk, 2000)

b. Entrenamiento No Supervisado

(Beltrán Calvo, 2012), explica que, cuando la salida no requiere ser contrastada con algo específico ya conocido, la red neuronal artificial realiza un aprendizaje o entrenamiento no supervisado. O sea, estas redes no tienen referencia de comparación por la cual contemplan la auto organización y la auto asociación, como proceso de obtención de la salida de la red.

El aprendizaje o entrenamiento no supervisado también es llamado como auto supervisado, ya que estas redes neuronales son capaces de auto organizarse, por lo que no requieren supervisión externa para ajustar los pesos de las conexiones entre neuronas.

c. Reforzado o graduado

(Beltrán Calvo, 2012) explica que el entrenamiento reforzado o graduado se da cuando no se conocen las salidas, pero se tiene algún indicio sobre ellas. Éstas pueden usarse para tareas supervisadas, pero requieren más tiempo.

2.2.1.4.3 Según su aplicación de la Red Neuronal Artificial

(Basogain Olabe, 1998), explica que las características especiales de los sistemas de computación neuronal permiten que sea utilizada esta nueva técnica de cálculo en una extensa variedad de aplicaciones. La computación neuronal provee un acercamiento mayor al reconocimiento y percepción humana que los métodos tradicionales de cálculo. Las redes neuronales artificiales presentan resultados razonables en aplicaciones donde las entradas presentan ruido o las entradas están incompletas. Algunas de las áreas de aplicación de las redes neuronales artificiales son las siguientes:

- **Reconocimiento de caracteres:** Es el proceso de interpretación visual y de clasificación de símbolos. Los investigadores de Nestor, Inc. han desarrollado un sistema de computación neuronal que, tras el entrenamiento con un conjunto de tipos de caracteres de letras, es capaz de interpretar un tipo de carácter o letra que no haya visto con anterioridad.
- **Reconocimiento de Patrones en Imágenes:** Una aplicación típica es la clasificación de objetivos detectados por un sonar. Existen varias ANN basadas en la popular Backpropagation cuyo comportamiento es comparable con el de los operadores humanos. Otra aplicación normal es la inspección industrial.
- **Predicción:** En el mundo real existen muchos fenómenos de los que conocemos su comportamiento a través de una serie temporal de datos o valores. Lapedes y Farber del Laboratorio de Investigación de los Álamos, han demostrado que la red backpropagation supera en un orden de magnitud a los métodos de predicción polinómicos y lineales convencionales para las series temporales caóticas.

2.2.1.5. Funciones de entrada

Las funciones de entrada se utilizan para ponderar las señales de entrada a cada neurona en función de su peso o intensidad. Existen muchas funciones como por ejemplo la distancia Euclidiana L1, o L2 si se eleva al cuadrado, el producto punto, la suma cuadrática, etc. (Satish, 2007)

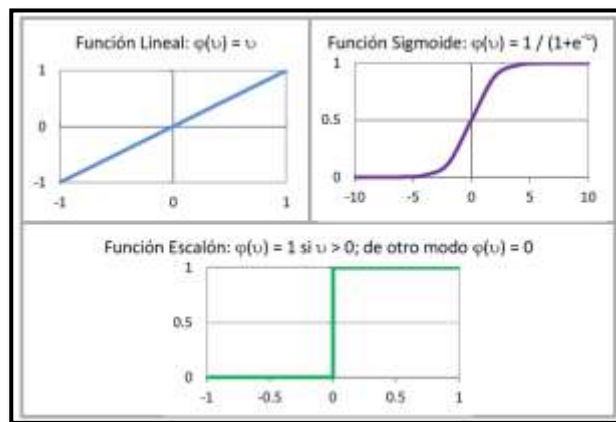
2.2.1.6. Tipo de pre procesamiento

Cuando el proceso de ajuste de los pesos resulta dispendioso y causa la saturación en las salidas de las neuronas y posteriormente su estancamiento, esto es producto de que las variables de entrada se encuentran dentro de magnitudes muy diferentes, o algunas de ellas oscilan dentro de intervalos o muy pequeños o muy amplios. Es debido a esto que se realiza un tipo de pre procesamiento a los datos de entrada, donde se ajustan dentro de valores adecuados que a la vez satisfagan el intervalo de valores de la función de transferencia seleccionada. Para esto generalmente se suele aplicar presiones en función de la desviación estándar o de los valores máximos y mínimo de cada variable. (Reddy, y otros, 2004)

2.2.1.7. Funciones de transferencia o funciones de activación

(Flores, y otros, 2008), explican las funciones de transferencia que actúan para limitar las salidas de una neurona a un intervalo finito. Cuando existen valores grandes de los pesos, la función seleccionada puede intervenir en el aprendizaje, permitiendo o no la modificación.

Figura 10 :Funciones de activación comúnmente usadas.



Fuente: (Flores, y otros, 2008)

2.2.1.8. Funciones de error o performance

(Flores, y otros, 2008), menciona que, en problemas de clasificación, el error da una idea de la porción de datos clasificadas incorrectamente por la red neuronal artificial. Para tareas de regresión, el error mide las diferencias entre las salidas y las calculadas por el modelo.


Tabla 1: Funciones de error de predicción.

Función de error	Definición
Error medio absoluto ("mean absolute error")	$MAE = \frac{\sum_{i=1}^P \sum_{j=1}^M y_{ij} - t_{ij} }{P}$ ó $MAE = \frac{\sum_{i=1}^P \sum_{j=1}^M y_{ij} - t_{ij} }{P \cdot M}$
Error cuadrático medio ("mean squared error")	$MSE = \frac{\sum_{i=1}^P \sum_{j=1}^M (y_{ij} - t_{ij})^2}{P}$ ó $MSE = \frac{\sum_{i=1}^P \sum_{j=1}^M (y_{ij} - t_{ij})^2}{P \cdot M}$
Raíz del error cuadrático medio ("root mean squared error")	$RMSE = \sqrt{\frac{\sum_{i=1}^P \sum_{j=1}^M (y_{ij} - t_{ij})^2}{P}}$ ó $RMSE = \sqrt{\frac{\sum_{i=1}^P \sum_{j=1}^M (y_{ij} - t_{ij})^2}{P \cdot M}}$

Fuente: (Flores, y otros, 2008).

Durante el aprendizaje o entrenamiento de la RNA pueden presentarse varias tendencias en el espacio error-tiempo.

Figura 11 :Posibles tendencias de la función error.



Fuente: (Flores, y otros, 2008)

La tendencia general en el error debe ser decreciente hasta encontrar el criterio preestablecido, aunque pueden presentarse algunas oscilaciones que constituyen "mínimos locales". Así mismo, puede darse el caso en que el error cambie de tendencia y se incremente de manera indefinida; se dice

entonces que la red está “sobre-entrenada” y comienza a memorizar o a aprender el ruido presente en el conjunto de datos. (Beltran, y otros, 2014).

(Flores, y otros, 2008), “Para evitar el fenómeno de sobre – entrenamiento se debe utilizar procesos de validación cruzada, en la cual se entrena y valida la red a la vez.”

2.2.2. DISEÑO DE UN MODELO NEURONAL

En el proceso de diseño se deben definir los siguientes elementos: la arquitectura de la red, las funciones de entrada, de transferencia, de error, el tipo de pre-procesamiento de los datos de entrada y el algoritmo de aprendizaje, entre otros. Todos estos elementos dependen del problema a abordar y de la base de datos disponible; para su definición se requiere un arduo trabajo, regularmente mediante ensayo y error. (Yegnaranarayana, 2006)

2.2.3. MODELACIÓN DE UN PROBLEMA

El proceso de modelación con Redes Neuronales Artificiales se efectúa mediante dos etapas denominadas de entrenamiento y de prueba, según se describe a continuación:

2.2.3.1. Etapa de entrenamiento o de aprendizaje

Esta viene a ser la primera etapa el cual refiere que una vez introducidos los ejemplos, la red identifica las relaciones entre las variables de entrada - salida (aprendizaje supervisado) asignando valores iniciales a los pesos; con base en dichas relaciones, la red calcula unas salidas y las compara con el comportamiento observado o deseado. Si los valores calculados satisfacen el criterio de aceptación o función de error pre-establecido entre salidas deseadas y calculadas, se dice que la red ha aprendido naturalmente las relaciones entre entradas y salidas; de lo contrario, el algoritmo de aprendizaje seleccionado ajusta los pesos de las conexiones entre las variables y el proceso continua iterativamente. En el aprendizaje no supervisado el proceso se realiza hasta alcanzar la estabilidad, es decir cuando no se identifiquen cambios significativos en los pesos, o se limita el aprendizaje a un determinado número de iteraciones. (Bredenhann, y otros, 2004)

2.2.3.2. Etapa de prueba

Evalúa la habilidad de las RNAs para proporcionar salidas o soluciones razonables para nuevos conjuntos de datos; con ello se busca la generalización de manera que el sistema se adapte. Para esos fines, se presentan nuevos conjuntos de variables de entrada a la red, pero no se introduce el correspondiente set de datos de salida; la red calcula unas salidas para los nuevos datos con base en los patrones aprendidos en el entrenamiento. (Yegnanarayana, 2006)

Cuando se obtienen resultados adecuados o satisfactorios en ambas etapas, se dice la RNA resultante constituye un modelo entrenado, capaz de realizar predicciones o estimaciones confiables y rápidas para conjuntos de datos nuevos o desconocidos. (Beltran, y otros, 2014)

2.2.3.3. Evaluación del desempeño de la modelación neuronal

(Ceylan, y otros, 2014), todos los análisis estadísticos para evaluar la precisión y el desempeño de una red entrenada, se deben reportar con base en los resultados obtenidos en la etapa de prueba, o con nuevos conjuntos de datos introducidos para efectos de validación.

En general, se utiliza la función de error como el principal indicador de precisión de los estimativos. Sin embargo, en las RNAs supervisadas es necesario introducir criterios adicionales para juzgar la calidad de los ajustes entre lo deseado y lo estimado, pues se ha encontrado que varias soluciones pueden proporcionar el mismo error.

Para lograr evaluaciones más completas, resulta útil graficar los valores deseados vs valores pronosticados o estimados y determinar indicadores de ajuste y de correlación; en la práctica común se utiliza el coeficiente de determinación (r^2) aunque éste tampoco resulta suficiente, pues buenas correlaciones no necesariamente reflejan buen nivel de igualdad. (Beltran, y otros, 2014).

2.2.4. SOFTWARE NEURAL TOOLS V.7.6

Neural Tools es un programa auxiliar de redes neuronales para Microsoft Excel que permite analizar datos en las hojas de cálculo de Excel y trabajar en el entorno familiar de Microsoft

Office. Combinando un eficaz administrador de datos y los más modernos algoritmos de redes neuronales. (NeuralTools V7.6, 2015).

Neural Tools ofrece lo mejor de dos mundos: la facilidad de uso y los informes de Microsoft Office, y las predicciones sólidas y precisas de las redes neuronales.

2.2.4.1. Análisis de NeuralTools

Las redes neuronales son capaces de aprender complejas relaciones de datos. Al imitar las funciones de un cerebro, pueden diferenciar patrones de datos y luego extrapolar predicciones cuando se introducen nuevos datos. Los problemas en los que se usan redes neuronales se pueden dividir en dos grupos generales:

- **Problemas de clasificación:** Problemas en los que se trata de determinar el tipo de categoría al que pertenece un elemento desconocido. Como ejemplo están los diagnósticos médicos o las predicciones de capacidad de pago de un crédito.
- **Problemas numéricos:** Situaciones en las que debe predecir un resultado numérico específico. Como ejemplo están la previsión del precio de acciones o la predicción del nivel de ventas durante un periodo de tiempo futuro.

Las redes neuronales se usan en una amplia variedad de aplicaciones, que incluyen: predicciones en el mercado de valores, asignación de riesgo en créditos y préstamos, detección de fraude crediticio, previsiones de ventas, previsiones comerciales en general, riesgo en inversiones, diagnósticos médicos, investigación científica y sistemas de control. NeuralTools incorpora los más modernos algoritmos de redes neuronales para hacer las mejores predicciones tanto en problemas de clasificación (denominados predicción de categoría en NeuralTools) como en problemas numéricos.

NeuralTools evalúa inteligentemente los bloques de datos, sugiriendo nombres y tipos de variables, así como ubicaciones de datos. Los conjuntos de datos y variables pueden residir en diferentes libros de trabajo y hojas de cálculo, permitiéndole organizar los datos como mejor le convenga. Luego,

puede entrenar las redes neuronales que hacen referencia a las variables, en lugar de tener que seleccionar de nuevo los datos una y otra vez en Excel. Y las variables de NeuralTools no están limitadas en su tamaño a una sola columna de datos de una hoja de cálculo de Excel; puede usar la misma columna a lo largo de hasta 255 hojas de cálculo para una sola variable.

2.2.4.2. NeuralTools y las redes neuronales

Cuando se usa NeuralTools, las redes neuronales se desarrollan y utilizan en cuatro pasos:

- **Preparación de datos** – Los datos que se usan en NeuralTools se definen en conjuntos de datos. El **Administrador de conjunto de datos** se usa para configurar los conjuntos de datos para que se puedan utilizar una y otra vez con las redes neuronales. (NeuralTools V7.6, 2015)
- **Entrenamiento:** Con el entrenamiento se genera una red neuronal a partir de un conjunto de datos compuesto de casos con valores de salida conocidos. Estos datos son frecuentemente casos históricos de los cuales se conocen los valores de salida / variable dependiente. (NeuralTools V7.6, 2015)
- **Prueba:** Con las pruebas se comprueba la red neuronal para ver cómo realiza la predicción de los valores de salida conocidos. Los datos usados para las pruebas son normalmente un subconjunto de los datos históricos. Este subconjunto no se utiliza para el entrenamiento de la red. Después de la prueba, se mide el funcionamiento de la red mediante estadísticas como el porcentaje de respuesta conocidas cuya predicción ha sido correcta. (NeuralTools V7.6, 2015)
- **Predicción:** Se usa una red neuronal entrenada para predecir valores de salida desconocidos. Una vez entrenada y probada, la red se puede usar para predecir salidas de datos de casos nuevos. (NeuralTools V7.6, 2015)

El entrenamiento y las pruebas son un proceso interactivo que a veces consume gran cantidad de tiempo. Normalmente se hace el entrenamiento varias veces con diferentes configuraciones para generar una red neuronal que obtenga los mejores resultados en la prueba. Cuando tenga la “mejor red” podrá usarla rápidamente para predecir. Ahora vamos a ver cómo funciona NeuralTools en Excel y como se definen conjuntos de datos y se entrenan y prueban redes neuronales usando esos conjuntos

de datos. Luego, haremos predicciones valores de salida desconocidos usando redes entrenadas. (NeuralTools V7.6, 2015)

La **pestaña Configuración de red** incluye lo siguiente:

- **Tipo de red** – Selecciona el tipo de red que se usará en el entrenamiento o la búsqueda de la Mejor red. Las **Opciones** de la pestaña Configuración de red cambian dependiendo del tipo de red seleccionado. Los tipos de redes disponibles son:

- a. **Búsqueda de mejor red.** En la Búsqueda de mejor red, NeuralTools prueba todas las configuraciones de red marcadas, incluyendo las redes PN/GRN y MLF con cuentas de nodos dentro del rango mínimo-máximo introducido. La configuración que tenga mejor funcionamiento para los datos se identifica basándose en el error obtenido en los datos de la prueba. Si selecciona **Almacenar todas las redes de prueba en un libro de trabajo nuevo**, podrá cargar individualmente cada una de las redes probadas (independientemente de si fue la red con mejor funcionamiento) del libro de trabajo y usarla para hacer una predicción después de completar el entrenamiento; también hay disponible un Informe de resumen completo para cada red. (NeuralTools V7.6, 2015)
- b. **Red PN/GRN.** Estos tipos de redes no requieren la selección de opciones adicionales para el entrenamiento; por esta razón esta configuración es la predeterminada cuando se instala NeuralTools. Si los datos tienen valores de salida numéricos, se entrenará una red GRN, y si los datos tienen valores de salida de categoría se entrenará una red PN. (NeuralTools V7.6, 2015)
- c. **Red MLF.** Las Redes multinivel siempre hacia adelante (MLF) tienen uno o dos niveles de nodos ocultos. Si selecciona cero nodos para el segundo nivel, éste se eliminará. La forma más fiable de encontrar la mejor configuración de una red MLF es usar la opción Búsqueda de mejor red en lugar de la opción de entrenar una sola red MLF. Si no hay tiempo suficiente para una Búsqueda de mejor Red, se recomienda que los valores “Número de nodos” se dejen en “Automático”. (NeuralTools V7.6, 2015)

2.2.5. PROPIEDADES DEL SUELO

2.2.5.1. Propiedades físicas del suelo

Según la norma de Suelos y Cimentaciones (E.050, 2015), menciona que, para determinar las propiedades del suelo, se tienen que realizar ensayos in situ y de laboratorio, las cuales estas están basadas en las Normas Técnicas Peruanas NTP. En la mecánica de suelos, es de suma importancia conocer las principales propiedades físicas del suelo, ya que interpretando correctamente los resultados podemos predecir a un futuro el comportamiento de un suelo determinado. (Crespo Villalaz, 2004 pág. 41)

a. Humedad natural del suelo

La Norma Técnica Peruana (NTP 339.127, 2006), define a la humedad o contenido de humedad, como la cantidad de agua presente en el suelo, el cual se expresa como porcentaje de la relación del peso de agua en una masa dada del suelo entre el peso de las partículas sólidas.

b. Análisis granulométrico del suelo

El análisis granulométrico es la obtención de la distribución de partículas expresados en porcentajes del peso total, ya que el suelo posee partículas de diferentes tamaños. Los métodos generalmente usados para encontrar la distribución de tamaños de partículas son: el análisis granulométrico por tamizado para partículas con diámetro superior a 0.075 mm. y el análisis hidrométrico para partículas con diámetro menor a 0.075 mm. (Braja Das, 2013 pág. 33)

La Norma Técnica Peruana (NTP 339.128, 2006), indica la distribución de partículas de los suelos mediante tamices estandarizados. Cabe mencionar que esta distribución de partículas nos ayudará a poder clasificar los suelos mediante los sistemas SUCS o AASHTO. El análisis granulométrico del suelo clasifica a estos en función del tamaño de sus partículas. La cual consiste en sacudir la muestra a través de los tamices estandarizados que tienen aberturas pequeñas gradualmente. (MTC, 2016)

Tabla 2: Tamaño de partículas.

TIPO DE MATERIAL		TAMAÑO DE PARTICULAS (mm.)
Grava		75 – 4.75
Arena		Arena gruesa: 4.75 – 2.00
		Arena media: 2.00 – 0.425
		Arena fina: 0.425 – 0.075
Material Fino	Limo	0.075 – 0.005
	Arcilla	Menor a 0.005

Fuente: Manual de ensayos de materiales, MTC 2016.

A continuación, se muestran los números estándares de tamices con sus respectivas aberturas en milímetros.


Tabla 3: Tamaños estándar de tamices.

N° Tamiz	Abertura (milímetros)
3"	75.000
1 1/2"	38.100
3/4"	19.000
3/8"	9.500
N° 4	4.760
N° 8	2.360
N° 16	1.100
N° 30	0.590
N° 50	0.297
N° 100	0.149
N° 200	0.075

Fuente: Manual de ensayos de materiales MTC, 2016.

El análisis de los datos se representa de manera gráfica (papel semilogarítmico), el por ciento de pesos acumulados (escala aritmética) y el tamaño de abertura del tamiz en la abscisa (escala logarítmica), con lo cual se determina la curva de distribución de tamaños de las partículas. (Braja Das, 2013 pág. 35)

Figura 12 : Curva granulométrica de un suelo e interpretación de la curva .




Fuente: (Bañon, y otros, 2012)

c. Consistencia del suelo

La teoría de la consistencia del suelo, fue desarrollada por Albert Atterberg en 1900, quien menciona que la incorporación de diferentes contenidos de humedad al grano fino, el cual con un contenido de humedad muy bajo el comportamiento del suelo es como un sólido quebradizo, pero cuando el contenido de humedad es muy alto, el suelo y el agua pueden fluir como un líquido. Debido a esto el comportamiento natural del suelo se divide en cuatro estados básicos: sólido, semisólido, plástico y líquido. (Braja Das, 2013 pág. 64)

Figura 13: Límites de Atterberg.



Fuente: Elaboración Propia

- **Límite líquido**

La Norma Técnica Peruana (NTP 339.129, 2006), define al límite líquido como la humedad que presenta el suelo, la cual se halla entre el límite del estado líquido y plástico. Esta humedad se determina colocando una masa de suelo en la Copa de Casagrande, el cual es separada con un ranurador, para luego dejar caer la copa desde una altura de 1cm, y llegar a cerrar la ranura en 1.3 cm, con 25 golpes de la cuchara contra la base. El cálculo del límite líquido se realizan mediante las pruebas con diferentes contenidos de humedad, el cual mediante el método gráfico se determina la humedad a los 25 golpes en un gráfico semilogarítmico (humedad versus número de golpes).

- **Límite plástico**

Se define al límite plástico como el contenido de humedad del suelo, al cual un cilindro de suelo de 3 milímetros de diámetro se rompa o resquebraje al formarse esta, la muestra de suelo a usar es con el pasante de la malla N° 40, al igual que para el ensayo del límite líquido. Cabe mencionar que la diferencia del límite líquido y límite plástico se denomina índice de plasticidad del suelo. (NTP 339.129, 2006)

- **Índice de plasticidad**

Representa el comportamiento de un suelo en base a su contenido de humedad, por lo que el suelo podrá trabajar de forma que será capaz de resistir deformaciones sin llegar a una falla.

Tabla 4: característica del suelo según el índice plasticidad

ÍNDICE DE PLASTICIDAD	CARACTERÍSTICAS
IP >20	Suelos muy arcillosos
20>IP >10	Suelos arcillosos
10>IP >4	Suelos poco arcillosos
IP=0	Suelos exentos de arcillas

Fuente: (MTC, 2016).

- **Límite de contracción**

(NTP 339.140, 2006), define al límite de contracción como la humedad máxima de un suelo para la cual, una reducción de la humedad no causa una variación del volumen del suelo.

d. Clasificación de los suelos mediante el sistema SUCS

La mecánica de suelos ha desarrollado algunos métodos de clasificación de estos, esto debido a que la naturaleza presenta variedades de suelo, según el tamaño de partículas y la plasticidad que presenta.

- **Suelos gruesos**

Los suelos gruesos vienen a ser las gravas y las arenas, donde si más de la mitad de la fracción gruesa es retenida por la malla N°4 esta pertenece al grupo de las gravas (G), caso contrario pertenecerá al de las arenas (S).

Estos dos grupos se dividen en cuatro grupos más que son GM, GP, GW, GC y SW, SP, SM, SC respectivamente para las gravas y las arenas, esto debido a que estos puedan presentar porcentajes de finos. Los símbolos de GW y GP indican a gravas bien graduadas y a gravas pobremente o mal graduadas respectivamente, de igual manera para aquellos que poseen finos los cuales son GM que indica a una grava limosa y GC a una grava arcillosa. De igual modo en las arenas SW, SP, SM y SC que refieren a arenas bien graduadas, arenas mal graduadas, arenas limosas y arenas arcillosas respectivamente. (Crespo Villalaz, 2004 pág. 92)

- **Suelos finos**

Los suelos finos que son los limos y las arcillas son agrupados en tres grupos con limite liquido menor a 50%, también agrupa en tres grupos aquellos con un límite liquido mayor a 50%, y un solo grupo para suelos finos altamente orgánicos. Si el suelo tiene un límite liquido menor a 50% o sea si el suelo es de compresibilidad baja o media, se añadirá el símbolo L a los prefijos M, C y O, obteniéndose los grupos ML, CL y OL que se les denominaran limos inorgánicos de baja compresibilidad, arcillas inorgánicas de baja compresibilidad y limos orgánicos de baja compresibilidad respectivamente.

Para las turbas que son suelos altamente orgánicos se le designan el símbolo Pt. (Crespo Villalaz, 2004 pág. 93)

Tabla 5: Clasificación SUCS para suelos gruesos.

DIVISIONES PRINCIPALES		Símbolos del grupo	NOMBRES TÍPICOS	IDENTIFICACIÓN DE LABORATORIO			
SUELOS DE GRANO GRUESO Más de la mitad del material retenido en el tamiz número 200.	GRAVAS Más de la mitad de la fracción gruesa es retenida por el tamiz número 4 (4,76 mm).	Gravas limpias (sin o con Pocos finos).	GW	Gravas, bien graduadas, mezclas grava-arena, pocos finos o sin finos.	Cu=D60/D10>4 Cc=(D30)2/D10xD60 entre 1 y 3		
			GP	Gravas mal graduadas, mezclas grava-arena, pocos finos o sin finos.		No cumplen con las especificaciones de granulometría para GW.	
		Gravas con finos (apreciable cantidad de finos).	GM	Gravas limosas, mezclas grava-arena-limo.	Determinar porcentaje de grava y arena en la curva granulométrica. Según el porcentaje de finos (fracción inferior al tamiz número 200). Los suelos de grano grueso se clasifican como sigue: <5%>GW, GP, SW, SP. >12%>GM, GC, SM, SC. 5 al 12%>casos límite que requieren usar doble símbolo.	Límites de Atterberg debajo de la línea A o IP<4.	Encima de línea A con IP entre 4 y 7 son casos límite que requieren doble símbolo.
			GC	Gravas arcillosas, mezclas grava-arena-arcilla.		Límites de Atterberg sobre la línea A con IP>7.	
	ARENAS Más de la mitad de la fracción gruesa pasa por el tamiz número 4 (4,76 mm).	Arenas limpias (pocos o sin finos).	SW	Arenas bien graduadas, arenas con grava, pocos finos o sin finos.		Cu=D60/D10>6 Cc=(D30)2/D10xD60 entre 1 y 3	
			SP	Arenas mal graduadas, arenas con grava, pocos finos o sin finos.		Cuando no se cumplen simultáneamente las condiciones para SW.	
		Arenas con finos (apreciable cantidad de finos).	SM	Arenas limosas, mezclas de arena y limo.	Límites de Atterberg debajo de la línea A o IP<4.	Los límites situados en la zona rayada con IP entre 4 y 7 son casos intermedios que precisan de símbolo doble.	
	SC		Arenas arcillosas, mezclas arena-arcilla.	Límites de Atterberg sobre la línea A con IP>7.			


Fuente: (Braja Das, 2013)

Tabla 6: Clasificación SUCS para suelos finos.

DIVISIONES PRINCIPALES		Símbolos del grupo	NOMBRES TÍPICOS
SUELOS DE GRANO FINO Más de la mitad del material pasa por el tamiz número 200	Limos y arcillas: Límite líquido menor de 50	ML	Limos inorgánicos y arenas muy finas, limos limpios, arenas finas, limosas o arcillosas, o limos arcillosos con ligera plasticidad.
		CL	Arcillas inorgánicas de plasticidad baja a media, arcillas con grava, arcillas arenosas, arcillas limosas.
		OL	Limos orgánicos y arcillas orgánicas limosas de baja plasticidad.
	Limos y arcillas: Límite líquido mayor de 50	MH	Limos inorgánicos, suelos arenosos finos o limosos con mica o diatomeas, limos elásticos.
		CH	Arcillas inorgánicas de plasticidad alta.
		OH	Arcillas orgánicas de plasticidad media a elevada; limos orgánicos.
Suelos muy orgánicos		PT	Turba y otros suelos de alto contenido orgánico.

Fuente: (Braja Das, 2013)

Figura 14: Carta de Casagrande (Suelos finos y orgánicos).



Fuente: (Braja Das, 2013)

e. **Clasificación de los suelos mediante el sistema AASHTO**

El sistema de clasificación AASHTO fue desarrollado en 1929 por la Administración de Carreteras de Estados Unidos, el cual clasifica actualmente al suelo en siete grupos principales: los cuales los grupos A-1, A-2 y A-3 son suelos granulares, donde el 35% o menos de las partículas pasan a través de la malla N° 200 y para suelos donde más de 35% pasa a través de la malla N°200 se clasifica en los grupos A-4, A-5, A-6 y A-7 que corresponden a suelos limosos y suelos arcillosos. (Braja Das, 2013 pág. 78)

Tabla 7: Clasificación AASHTO para suelos granulares y finos.

"DIVISIÓN GENERAL		Materiales Granulares (pasa menos del 35% por el tamiz ASTM # 200)						Materiales Limo-arcillosos (más del 35% por el tamiz ASTM # 200)				
GRUPO	A-1		A-3	A-2			A-4	A-5	A-6	A-7		
Subgrupo	A-1-a	A-1-b	A-3	A-2-4	A-2-5	A-2-6	A-2-7	A-4	A-5	A-6	A-7-5	A-7-6
ANÁLISIS GRANULOMÉTRICO (% que pasa por cada tamiz)												
Serie ASTM	# 10	≤ 50										
	# 40	≤ 30	≤ 50	≥ 51								
	# 200	≤ 15	≤ 25	≤ 10	≤ 35	≤ 35	≤ 35	≤ 35	≥ 36	≥ 36	≥ 36	≥ 36
ESTADOS DE CONSISTENCIA (de la fracción de suelo que pasa por el tamiz ASTM # 40)												
Limite Líquido			NP	≤ 40	≥ 41	≤ 40	≥ 41	≤ 40	≥ 41	≤ 40	> 41 (IP<LL-30)	> 41 (IP>LL-30)
Índice de plasticidad	≤ 6			≤ 10	≤ 10	≥ 11	≥ 11	≤ 10	≤ 10	≥ 11	≥ 11	≥ 11
INDICE DE GRUPO	0		0	0			≤ 4	≤ 8	≤ 12	≤ 20	≤ 20	
TIPOLOGIA	Fragmentos de piedra, grava y arena		Arena fina	Gravas y arenas limosas o arcillosas				Suelos limosos		Suelos arcillosos		
CALIDAD	EXCELENTE A BUENA						ACEPTABLE A MALA					
IG= (F-35) (0.2+0.005(LL-40))+0.01 (F-15) (IP-10); F: % pasado por el tamiz N° 200, LL: limite líquido; IP: índice plástico."												

Fuente: (Braja Das, 2013)

2.2.5.2. Propiedades mecánicas del suelo

2.2.5.2.1 Compactación de suelos

La compactación de los suelos está relacionada con la resistencia, deformabilidad y estabilidad, lo que la hace una propiedad importante la cual está influenciado por la humedad, por lo que mediante esto se pretende mejorar las características en los suelos que presentan las carreteras. (Montejo, 2002 pág. 476)

a. Prueba de Proctor Estándar

En 1933 Ralph R. Proctor, determinó que hay una correspondencia entre las propiedades mecánicas del peso volumétrico seco de un suelo compactado y su resistencia. La prueba de Proctor Estándar, se realiza mediante el compactado de una muestra de suelo en un molde de volumen y diámetro estandarizados, al momento de realizar la prueba el molde y la base son unidas para luego colocarle una extensión que viene a ser el collarín superior. Previamente se tiene que tener muestras de suelo preparados con diferentes contenidos de agua, para luego ser compactadas en tres capas de igual volumen por medio de un pisón que transmitirá 25 golpes por capa. (Braja Das, 2013 pág. 92)

Tabla 8: Especificaciones para la prueba Proctor Estándar.

“Descripción	Método A	Método B	Método C
Molde (Ø mm)	4 pulg. de diámetro (101.6mm)	4 pulg. de diámetro (101.6mm)	6 pulg. de diámetro (152.4mm)
Volumen (cm ³)	943.3 cm ³	943.3 cm ³	2124 cm ³
Pisón (N)	24.4 N	24.4 N	24.4 N
Altura de caída de pisón	304.8 mm	304.8 mm	304.8 mm
Golpes/Capa	25	25	56
Capas	3	3	3
Energía de compactación	591.3 KN-m/m ³	591.3KN-m/m ³	591.3 KN-m/m ³
Suelo a usar	Porción que pasa la malla N°4 (4.57mm). Se usa si 20% o menos por peso de material es retenido en la malla N°.4.	Porción que pasa la malla de 3/8” (9.5 mm). Se usa si el suelo retenido en la malla N°4 (4.75 mm) es más del 20%, y 20% o menos por peso es retenido en la malla 3/8” (9.5 mm).	Porción que pasa la malla de 3/4” (19 mm). Se usa si más de 20% por peso del material es retenido en la malla de 3/8” (9.5 mm), y menos de 30% por peso es retenido en la malla de 3/4” (19 mm).”

Fuente: (Braja Das, 2013)

b. Prueba de Proctor Modificado

La prueba de Proctor Modificado, surge debido al desarrollo de rodillos pesados y el empleo en la compactación con el fin de representar mejor las condiciones de campo, esto llegando a modificar a la prueba de Proctor Estándar. La prueba de Proctor Modificado se realiza con un molde de volumen y diámetro estandarizados, sin embargo, el compactado del suelo es en cinco capas por un pisón que transmite 25 golpes por capa. (Braja Das, 2013 pág. 98)

Para distintas energías de compactación, se observa que el punto de humedad óptimo varía en función de la energía que se le aplica a la muestra, esto debido al incremento del esfuerzo de compactación, la cual conllevan al peso unitario seco máximo incrementado del suelo. (Bañon, y otros, 2012 pág. 13)

Tabla 9: Especificaciones para la prueba Proctor Modificado.

“Descripción	Método A	Método B	Método C
Molde (Ø mm)	4 pulg. de diámetro (101.6mm)	4 pulg. de diámetro (101.6mm)	6 pulg. de diámetro (152.4mm)
Volumen (cm³)	943.3 cm ³	943.3 cm ³	2124 cm ³
Pisón (N)	44.5 N	44.5 N	44.5 N
Altura de caída de pisón	457.2 mm	457.2 mm	457.2 mm
Golpes/Capa	25	25	56
Capas	5	5	5
Energía de compactación	2696 KN-m/m ³	2696 KN-m/m ³	2696 KN-m/m ³
Suelo a usar	Porción que pasa la malla N°4 (4.57mm). Se usa si 20% o menos por peso de material es retenido en la malla N°4.	Porción que pasa la malla de 3/8” (9.5 mm). Se usa si el suelo retenido en la malla N°4 (4.75 mm) es más del 20%, y 20% o menos por peso es retenido en la malla 3/8” (9.5 mm).	Porción que pasa la malla de 3/4” (19 mm). Se usa si más de 20% por peso del material es retenido en la malla de 3/8” (9.5 mm), y menos de 30% por peso es retenido en la malla de 3/4” (19 mm).”

Fuente: (Braja Das, 2013)

2.2.5.2.2 Capacidad de soporte CBR (California Bearing Ratio)

Siguiendo los procedimientos de la Norma Técnica Peruana (NTP 339.145, 2006) o (ASTM D-1883), que indica que el valor de la relación de soporte conocido como CBR (California Bearing Ratio) es un índice de resistencia del suelo, que se refiere a que el suelo se somete a la penetración de un vástago

cilíndrico a una velocidad constante, cuyo resultado del índice CBR, nos dice que es la capacidad de soporte del suelo comparado con la de una grava patrón. Por cada espécimen de suelo se determinan dos valores de CBR, uno a 0.1 pulg. y a el otro a 0.2 pulg. de penetración. La norma ASTM D-1883 recomienda usar el CBR a una penetración de 0.1 pulg. mientras este índice sea menor al de 0.2 pulg. Si el valor del CBR para 0.1 pulg. fuese mayor que el de 0.2 pulg., se tiene que volver a realizar el ensayo para ese espécimen.

$$CBR = \frac{\text{presion en muestra problema}}{\text{presion en muestra patron}} \times 100 \dots \dots \dots (Ec. 1)$$


Para poder definir la forma de la curva de esfuerzo se deben hacer estas lecturas de penetración.

Tabla 10: Lecturas para definir el CBR

Milímetros	Pulgadas
0.63	0.025
1.27	0.050
1.90	0.075
2.54	0.100
3.17	0.125
3.81	0.150
5.08	0.200
7.62	0.300
10.16	0.400
12.70	0.500

Fuente: Manual de ensayos de materiales MTC, 2016.

Figura 15: Esfuerzo vs Penetración (determinación del valor de soporte CBR).



Fuente: Manual de ensayos de materiales MTC, 2016.

2.3. MARCO CONCEPTUAL

- **Red Neuronal Artificial (RNA):** Son modelos que pretenden imitar y simular el comportamiento del cerebro humano, cuya unidad básica de procesamiento está inspirada en la neurona que representan variables y funcionan como un sistema para el tratamiento de la información.
- **Neurona Artificial:** Es una inteligencia artificial donde emula el funcionamiento básico de una neurona biológica.
- **Conexiones hacia adelante:** Son aquellas cuyas conexiones son unidireccionales y hacia adelante, dentro de estas estas las redes neuronales monocapa y multicapa.
- **Redes Neuronales monocapa:** Solo tienen una capa de neuronas que proyectan hacia las entradas a una capa de neuronas de salida, donde se realizan diversos cálculos.
- **Redes Neuronales Multicapa:** Es la extensión de una red neuronal Monocapa, en cual posee un conjunto de capas intermedias entre la entrada y la salida.
- **Conexiones hacia atrás:** Son aquellas que se caracterizan por la existencia de las conexiones de retorno entre neuronas de una determinada capa con otras de capas anteriores, conexiones entre neuronas con una misma capa o conexiones de una neurona consigo misma.
- **Entrenamiento Supervisado:** Una red neuronal artificial realiza un aprendizaje o entrenamiento supervisado, cuando en el entrenamiento de la red, existe un parámetro de referencia ya conocido (maestro).
- **Entrenamiento No Supervisado:** Una red neuronal artificial realiza un aprendizaje o entrenamiento no supervisado, cuando la salida no requiere ser contrastada con algo específico ya conocido (maestro).
- **Propiedades físicas del suelo:** Las propiedades físicas del suelo son las que se definen como las propiedades obtenidas con los ensayos físicos mas no ensayos de resistencia, como contenido de humedad, límites de consistencia, granulometría, etc.
- **Propiedades mecánicas del suelo:** Las propiedades mecánicas del suelo son las que se definen como las propiedades obtenidas con los ensayos que se relacionan con la resistencia, deformabilidad y estabilidad, como ensayos de compactación, ensayos de corte, etc.

CAPÍTULO III

METODOLOGÍA DE LA INVESTIGACIÓN

3.1. METODOLOGÍA Y RECOLECCIÓN DE DATOS

3.1.1. TIPO DE INVESTIGACIÓN

(Ccanto Mallma, 2010), describe a la investigación aplicada como aquellas que se desarrollan con la finalidad de resolver problemas de la práctica o que busca describir o validar técnicas, instrumentos o materiales que optimicen los procesos o que permitan resolver problemas de la naturaleza práctica, aplicando los resultados obtenidos, por lo que la hipótesis en este tipo de investigaciones se demuestra en términos de eficaz o ineficaz. En base a esta definición la investigación es de TIPO APLICADA.

3.1.2. NIVEL DE INVESTIGACIÓN

(Hernandez Sampieri, y otros, 2010), explican que el nivel explicativo son más que describir conceptos o fenómenos o establecimiento de relaciones entre conceptos, es decir, estos están dirigidos a responder por las causas de los eventos o fenómenos físicos o sociales. El nivel explicativo, como su nombre indica, esta se centra en explicar por qué ocurre un fenómeno y en qué condiciones se manifiesta, o por qué se relaciona dos o más variables. En base a esto el nivel de investigación es EXPLICATIVA debido a que se emplearán ensayos de caracterización de suelos para determinar las propiedades mecánicas, mediante el desarrollo de una Red Neuronal Artificial.

3.1.3. DISEÑO DE INVESTIGACIÓN

(Hernandez Sampieri, y otros, 2010), menciona que el diseño cuasi-experimental manipula al menos una variable independiente para observar su efecto y relación con una o más

variables dependientes y se analizan las consecuencias o efectos producidas, por lo que no se asignan al azar a los grupos ni se emparejan, sino que dichos grupos ya están formados antes del experimento. En base a este sustento el diseño de investigación es CUASI-EXPERIMENTAL, debido a que no se modifica en su totalidad las variables, sino solo se observa la construcción y aplicación de la Red Neuronal con respecto a la mínima manipulación de los datos reales. También nos menciona que los diseños transeccionales o transversales recolectan datos en un solo momento. En base a este fundamento el diseño es transversal descriptivo.

3.1.4. MÉTODO DE INVESTIGACIÓN

(Hernandez Sampieri, y otros, 2010), definen que el método científico es el conjunto de procedimientos y técnicas que se usan para resolver y formular problemas de investigación mediante la prueba de hipótesis. En base a esta precisión el método es CIENTIFICO, con un enfoque CUANTITATIVO, ya que usa la recolección de datos para probar hipótesis, con base en la medición numérica y el análisis estadístico, para establecer patrones de comportamiento y probar teorías.

3.1.5. POBLACIÓN Y MUESTRA

3.1.5.1. Población

(Borja S., 2012), define a la población como el conjunto de elementos o sujetos que serán motivo de estudio. Con esa definición la población tomada serán los tipos de suelos existentes en la clasificación SUCS.

3.1.5.2. Muestra

(Borja S., 2012), define a la muestra como la unidad del objeto de estudio procedente de una población. En base a esta definición la muestra de estudio serán 10 muestras de suelo, a la cual se realizarán todos los ensayos de granulometría, límites de Atterberg, ensayos de compactación como Proctor y CBR.

El muestreo fue no probabilístico e intencional, ya que la elección de los elementos de muestra no depende de la probabilidad. Estas técnicas siguen otros criterios+ de selección (conocimientos del investigador, economía, comodidad, alcance, etc.), procurando que la muestra obtenida sea lo más representativa posible.

3.1.6. TÉCNICAS DE RECOLECCIÓN DE DATOS

(Ccanto Mallma, 2010), menciona que las técnicas de recolección de datos son los medios por los cuales el investigador recoge la información requerida de una realidad en función a los objetos de estudio. Con lo cual la técnica de recolección de datos fue la observación sistemática, ya que todos los resultados y la recopilación de información de datos se obtuvieron y registraron mientras se realizaron los ensayos, así como la recolecta directa de información.

Se tomaron la información de los diferentes estudios definitivos de carreteras por parte de Provias Nacional.

Se tomaron los datos de los diferentes ensayos realizados, de acuerdo a los tipos de suelo encontrados.

3.1.7. INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Los instrumentos de recolección de datos y medición empleados en esta investigación son:

- Ensayos de suelos de los estudios definitivos de carreteras por parte de Provias Nacional.
- Equipo de Proctor (moldes de compactación)
- Equipo de CBR (molde de compactación y prensa de penetración)
- Tamices estandarizados (mallas granulométricas)
- Horno eléctrico (contenido de humedad)
- Copa de Casagrande (límites de consistencia)

3.1.8. TÉCNICAS DE ANÁLISIS DE DATOS

Las técnicas de análisis de datos nos ayudaron a organizar, e interpretar los datos recogidos con los instrumentos de investigación. La primera técnica para el análisis de los datos e interpretar los resultados fue el método gráfico.

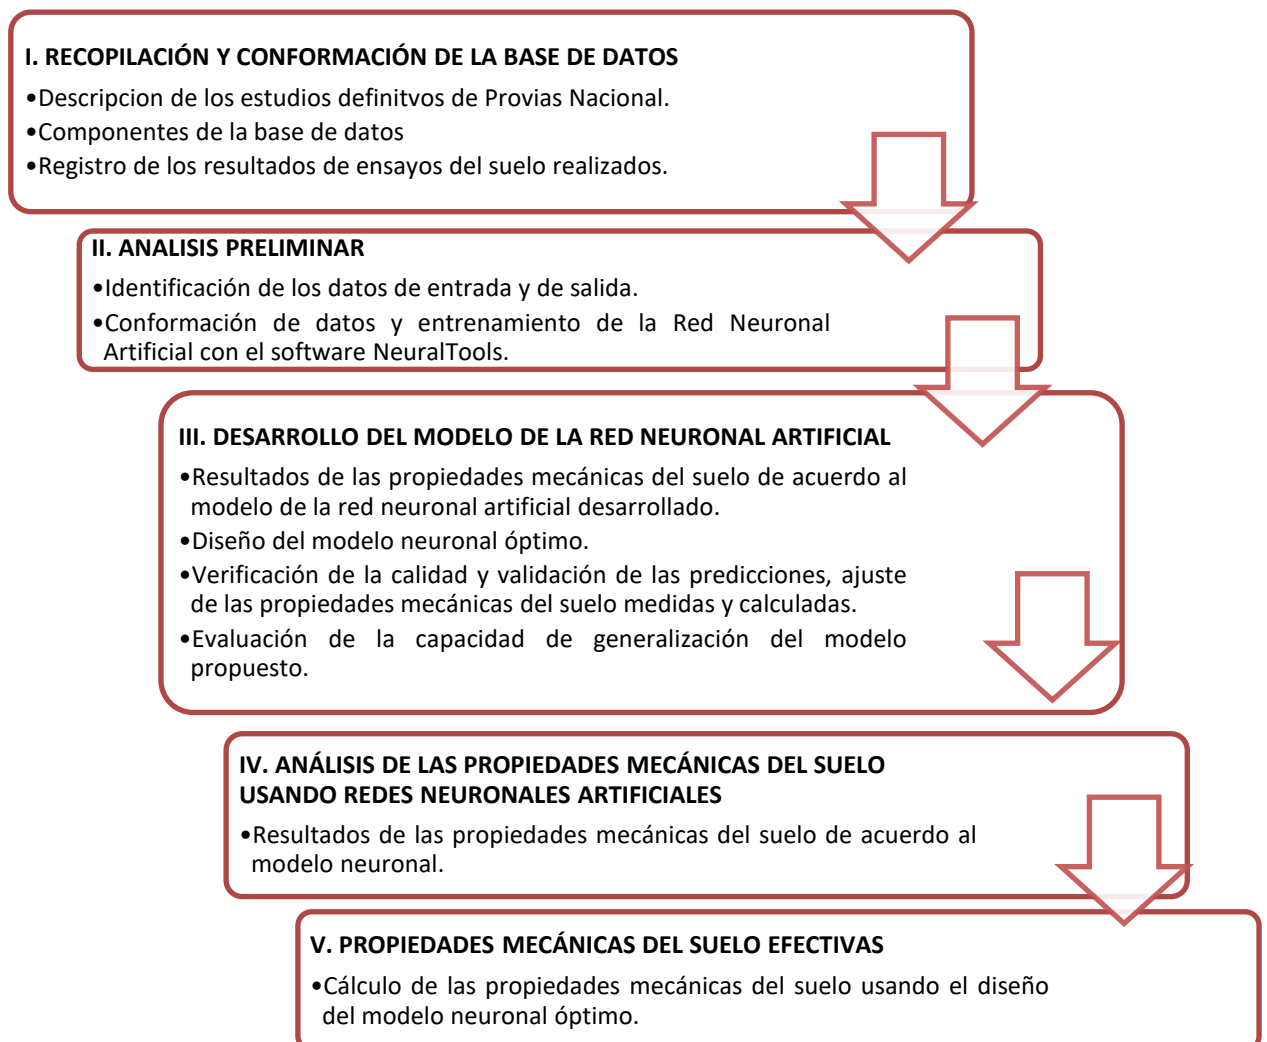
La organización de los datos se organizó en una matriz de tabulación (Excel), estos datos fueron recopilados y se fueron almacenado a medida que los demás datos se obtenían.

La descripción y análisis de los datos se hicieron mediante las técnicas de análisis cuantitativo que nos sirvió para mostrar las predicciones de las propiedades mecánicas del suelo mediante el desarrollo de una Red Neuronal Artificial, y encontrar el modelo con el menor error posible.

3.2. PROCEDIMIENTO METODOLÓGICO DE LA INVESTIGACIÓN

Teniendo la recopilación necesaria de la información base, se plantea el procedimiento de investigación:


Figura 16: Procedimiento metodológico.



Fuente: Elaboración propia.

El desarrollo de la investigación se llevó a cabo de la siguiente manera: recopilación de base de datos, análisis de la base de datos y los ensayos de suelos en laboratorio, conformación del modelo de la red neuronal artificial, análisis de las propiedades mecánicas del suelo, algoritmo efectivo que predice las propiedades mecánicas del suelo.

Figura 17: Procedimiento de desarrollo del modelo neuronal artificial.



Fuente: Elaboración propia.

3.2.1. RECOPIACIÓN Y CONFORMACIÓN DE LA BASE DE DATOS ESPECÍFICOS

Para la recopilación y conformación de la base de datos, se realizó una breve descripción de los estudios definitivos de Provias Nacional, la cual es una entidad encargada de la ejecución de proyectos de construcción, mejoramiento, rehabilitación y mantenimiento de la Red Vial Nacional, con el fin de brindar a los usuarios un medio de transporte eficiente y seguro, que contribuya a la integración económica y social del país. En base a esto se recopiló las propiedades físicas y mecánicas del suelo (subrasante) para desarrollar la red neuronal artificial. También se registraron los resultados de los ensayos de suelos realizados en laboratorio.

3.2.1.1. Descripción de los estudios definitivos y proyectos de Provias Nacional

A continuación, se presenta una breve descripción de los proyectos de carreteras empleados para la conformación de la base de datos.

Cabe mencionar que los datos para el entrenamiento, prueba y validación de la red neuronal son tomados de los ensayos de la subrasante de la carretera (eje), con lo que en la presente investigación se recopiló todas las propiedades físicas y mecánicas del suelo.

Tabla 11: Descripción de los estudios definitivos empleados.

Estudio Definitivo de Ingeniería	Lugar de extracción del material	Número de muestras recopiladas	Número de ensayos recopilados
Estudio definitivo de ingeniería para la rehabilitación y mejoramiento de la carretera Patahuasi – Yauri – Sicuani, tramo: Negromayo – Yauri – San Genaro	Subrasante (eje)	64	320
Estudio definitivo para la rehabilitación y mejoramiento de la carretera: Chongoyape – Cochabamba – Cajamarca, tramo: Cochabamba – Chota	Subrasante (eje)	16	80
Estudio definitivo para la rehabilitación y mejoramiento de la carretera Ayacucho – Abancay, tramo: Km 50+000 – Km 98+800	Subrasante (eje)	30	150
Estudio definitivo del proyecto de rehabilitación y mejoramiento de la carretera (Pu 135) Checca – Mazocruz	Subrasante (eje)	65	325
Estudio de Factibilidad y definitivo para el mejoramiento de la carretera Oyón – Ambo. Sector I: Oyón – Desvío Cerro de Pasco	Subrasante (eje)	37	185
MUESTRAS TOTALES RECOPIADAS: 212 (1060 ENSAYOS RECOPIADOS)			

Fuente: Elaboración Propia.

3.2.1.2. Componentes de la base de datos para el desarrollo del modelo neuronal

Para la construcción de la base de datos se incluye toda la información técnica disponible. A continuación, se presentan los datos específicos para la conformación de la base de datos global, ya que estos mismos datos se obtendrán mediante los ensayos de suelos en laboratorio.

Tabla 12: Base de datos específicos.

Tipo de Información	% Grava (3"-N°4)	% Arena (N°4-N°200)	% Finos (< N°200)	Límite Líquido (%)	Límite Plástico (%)	Índice de Plasticidad (%)	Óptimo Contenido de Humedad (%)	Máxima Densidad Seca (gr/cm3)	CBR (100% y 95%)
Análisis Granulométrico	X	X	X						
Límites de Consistencia				X	X	X			
Proctor Modificado							X	X	
Capacidad de Soporte CBR (%)									X

Fuente: Elaboración Propia.

3.2.1.3. Registro de los resultados de ensayos del suelo realizados

El registro de los ensayos del suelo se hizo mediante los procedimientos basados en las Normas Técnicas Peruanas, mediante los cuales se determinen las condiciones y todas las propiedades del suelo.

Tabla 13: Descripción de los estudios definitivos utilizados.

ENSAYOS	Norma NTP	Norma MTC	Norma ASTM
PROPIEDADES FÍSICAS			
Contenido de Humedad del suelo	NTP 339.127	MTC E 108	ASTM D 2216
Análisis Granulométrico por Tamizado	NTP 339.128	MTC E 107	ASTM D 422
Límite líquido de los suelos	NTP 339.129	MTC E 110	ASTM D 4318
Límite plástico de los suelos e índice de plasticidad	NTP 339.129	MTC E 111	ASTM D 4318
Clasificación de los suelos métodos SUCS	NTP 339.134		
Clasificación de los suelos método AASHTO	NTP 339.135		
PROPIEDADES MECÁNICAS			
Ensayo de Proctor Modificado	NTP 339.141	MTC E 115	ASTM D 1557
Ensayo de CBR (Relación de Soporte)	NTP 339.145	MTC E 132	ASTM D 1883

Fuente: Elaboración Propia.

a. Método de ensayo para la determinación del contenido de humedad del suelo

La finalidad de este ensayo es determinar el contenido de humedad que presenta una cantidad de suelo, en términos de su peso seco.

Procedimiento:

- Previamente se tomaron muestras de material, transportados dentro de bolsas plásticas.
- Se pesa la muestra húmeda representativa (W húmedo).
- Se deja secar en el horno a 105°C durante 24 horas.
- Se pesa la muestra seca (W seco).
- Se aplica la siguiente formula.

$$w(\%) = \frac{W_{humedo} - W_{seco}}{W_{seco}} \times 100 \dots \dots (Ec. 2)$$

Figura 18: Pesado de las muestras y Secado de las muestra en el horno.




Fuente: Elaboración Propia

Normas de referencias:

- NTP 339.151: Practicas estándar para la preservación y transporte de suelos.
- NTP 339.127: Método de ensayo para determinar el contenido de humedad de un suelo.

Figura 19: Algoritmo a seguir para determinar el contenido de humedad



Fuente: Elaboración Propia

c. Método de ensayo para el análisis granulométrico por tamizado

El propósito de este ensayo es la determinación de la distribución de los tamaños de las partículas del suelo, mediante el empleo de tamices estandarizadas desde 3" (76.200 mm) hasta la N°200 (0.074 mm). Para ello la masa de suelo a ensayar dependió del tamaño máximo de las partículas.

Tabla 14: Masa mínima de la porción de suelo según el tamaño máximo.

Diámetro Nominal de Partículas más grandes pulg. (mm)	Porción Aproximada de Masa Mínima (gr)
3/8" (9.5)	500
3/4" (19.0)	1000
1" (25.4)	2000
1 1/2" (38.1)	3000
2" (50.8)	4000
3" (76.2)	5000

Fuente: NTP 339.128.

Procedimiento:

- Previamente se homogeniza mediante el cuarteo de la muestra natural.
- Cuando la muestra encontrada es arcillosa y arenas con limos, estos se tratarán por la vía húmeda ya que presentan terrones, por lo que se cubre con agua para que se ablanden las partículas.
- La muestra se procede a lavar con el tamiz N° 200, teniendo el cuidado que las partículas finas no se pierdan. La muestra lavada, se coloca al horno para su secado.

- La muestra seca, se tamiza por las mallas desde la 3" hasta la N° 200, obteniendo los pesos retenidos en cada una de estas.

Figura 20: Tamizado de la muestra representativa.



Fuente: Elaboración Propia.

Normas de referencias:

- NTP 339.128: Método de ensayo para el análisis granulométrico por tamizado.

Figura 21: Algoritmo a seguir para determinar el análisis granulométrico.



Fuente: Elaboración Propia.

d. Método de ensayo para determinar el Límite Líquido, Límite Plástico e Índice de Plasticidad de suelos

La Norma Técnica Peruana (NTP 339.129, 2006), nos menciona el procedimiento a seguir de los ensayos, con lo cual determinaremos los límites de consistencia del suelo.

Procedimiento del límite líquido: Determinación del límite líquido por el método de multipunto:

- Lo primero es ajustar y verificar la Copa de Casagrande.


- La muestra a usar es la pasante del tamiz N° 40, la que se mezclara con 15 – 20 ml de agua, amasándola con la espátula. Los incrementos de agua serán de 1 – 3 ml.
- Se coloca una parte de la mezcla en la Copa de Casagrande, verificando que este nivelado y emparejado a una altura de 1 cm en el punto de profundidad máxima.
- Se divide la mezcla a través del centro de la cuchara de la Copa de Casagrande.
- Se procede a girar la manija a una velocidad de 2 golpes por segundo, el ensayo terminará cuando las dos mitades de la mezcla se junten en el fondo de la ranura a lo largo de 1.3 cm aproximadamente, y se anotará el número de golpes realizados.
- Cuando el suelo tiende a deslizarse en el momento de los golpes de la copa de Casagrande, deberá de agregarse más agua y volver a mezclar, si a pesar de esto sigue desliziéndose con un número de golpes menor a 25, entonces el suelo no presenta limite líquido.
- Se procede a tomar una parte de suelo del ancho de la espátula, para colocarlas en un recipiente para determinar el contenido de humedad.
- Se repite el procedimiento para cada mezcla de suelo ensayada.
- Los golpes para cerrar la ranura del suelo deben encontrarse entre los intervalos de 25-35, 20-30, 15-25, con el propósito de tener muestras con consistencia cercanas a las requeridas.

Figura 22: Realizando el ensayo de límite líquido y Muestras secas para pesar.



Fuente: Elaboración Propia

Figura 23: Algoritmo a seguir para determinar el límite líquido



Fuente: Elaboración propia

Procedimiento del límite plástico:

- Con la mezcla de suelo del ensayo de límite líquido, se moldea en forma de elipsoides con los dedos sobre la superficie lisa del vidrio, hasta conseguir formar cilindros.
- Si antes de llegar a 3.2 mm de diámetro de los cilindros, no se ha desmoronado o se formó grietas a su alrededor, se vuelve a realizar el proceso cuantas veces sea necesario, hasta que se logre el agrietamiento o desmoronamiento con dicho diámetro aproximadamente.
- El cilindro debe tener aproximadamente 3 mm de diámetro cuando empiece a desmoronarse o agrietarse.
- Se debe tener aproximadamente entre 6 a 8 gramos de porciones agrietadas, para proceder a determinar el contenido de humedad.
- Para determinar el índice de plasticidad del suelo se realiza mediante la diferencia del límite líquido y límite plástico.

Figura 24: Realizando el ensayo de limite plástico y secado de muestras.




Fuente: Elaboración Propia.

Normas de referencias:

- NTP 339.129: Método de ensayo para determinar el límite líquido, límite plástico e índice de plasticidad de suelos.

Figura 25: Algoritmo a seguir para determinar el límite plástico.



Fuente: Elaboración Propia.

e. Ensayo de Compactación Proctor Modificado

La finalidad del ensayo de Proctor Modificado es, determinar el contenido óptimo de humedad con lo cual se alcanza su máxima densidad seca. Este ensayo se realiza mediante la compactación del suelo aplicando una energía determinada.

Procedimiento:

- Previamente se tiene que secar la muestra al aire libre o al horno, solo si este estuviera húmedo.
- Previamente se tiene que determinar el método de prueba (A, B o C) que corresponda, esto a través del tamizado con las mallas 3/4", 3/8" y N°4.
- Se prepara 4 ó 5 muestras de aproximadamente 6 kg para el método C. Para el método A ó B se prepara 3 kg. Para luego ser mezcladas con agua de manera que este homogenizado.
- Se procede a la etapa de compactación de las cinco capas, con un número de golpes por capa de acuerdo al método de prueba determinado (25 ó 56 golpes por cada capa).
- La compactación se tiene que realizar de manera homogénea en toda el área.
- Con la última capa compactada, se procede al enrasado con una regla metálica quitando previamente el collarín. Para determinar el peso del suelo más el molde, previamente retirando la base.
- De la muestra compactada, ubicamos la parte central y se extrae una parte de suelo para determinar su contenido de humedad.
- Se repite el procedimiento para las otras muestras a ensayar, con contenidos de humedad variables.
- Por ultimo determinamos la densidad seca de cada punto realizado y graficamos la humedad versus las densidades secas, y mediante esto obtenemos la máxima densidad seca y el óptimo contenido de humedad.

$$\gamma_d = \frac{\gamma_m}{1 + \frac{w}{100}} \dots \dots (Ec. 3)$$

Donde:

γ_m = densidad húmeda = peso suelo húmedo /volumen

w = contenido de humedad

Figura 26: Mezclado de muestras con contenidos de agua y Compactado.




Fuente: Elaboración Propia.

Normas de referencias:

- NTP 339.141: Método de ensayo para la compactación del suelo en laboratorio utilizando energía modificada.

Figura 27: Algoritmo a seguir para determinar la MDS.



Fuente: Elaboración Propia.

f. Ensayo de CBR (California Bearing Ratio)

Mediante la Norma Técnica Peruana (NTP 339.145, 2006) o (ASTM D-1883), se determinó el valor relativo de soporte CBR, la cual menciona que se obtiene como un porcentaje del esfuerzo requerido para poder penetrar un pistón una profundidad de 0.1 pulgadas en la muestra de suelo, y el esfuerzo requerido para hacer penetrar 0.1 pulgadas el mismo pistón, pero en una

muestra patrón de piedra triturada. El valor del CBR generalmente se determina para 0.1 y 0.2 pulgadas de penetración, lo cual el esfuerzo requerido para la muestra patrón es 1000 y 1500 lb/plg² respectivamente. El ensayo de CBR comprende los 3 ensayos siguientes:

- Determinación de la densidad y humedad.
- Determinación de las propiedades expansivas del material.
- Determinación de la resistencia a la penetración.

Preparación del material:

- Con la muestra secada al aire o calentada a 60 C°, se procede a desmenuzar los terrones con el cuidado de no romper las partículas individuales del suelo.
- La muestra se tamiza por la malla 3/4" y la N° 4, para luego descartar la retenida en la 3/4" y reemplazarla en igual proporción con muestra de suelo retenida entre los tamices 3/4" y la N°4, luego homogenizar mediante el mezclado.
- También se determina el contenido de humedad de la muestra preparada.
- La cantidad de material que se necesitara es de 5kg para cada espécimen, esto en el proceso de compactación.

Determinación de la densidad y humedad:

- Previamente se alistan los moldes cilíndricos, el disco espaciador y el papel filtro grueso.
- Se mezclan las muestras con el óptimo contenido de humedad encontrada, homogenizándolo con la espátula.
- Se procede al proceso de compactación, para esto se divide la muestra en 5 partes de igual volumen. Se compactan las 5 capas con 10, 25 y 56 golpes por capa.
- Terminado la última capa, se quita el collarín y se enrasa la muestra, luego se retira la base, el disco espaciador y se voltea el molde, esto para determinar su peso.

- Determinado el peso de la muestra compactada, se calcula la densidad y la humedad.

Figura 28: Mezclado de las 3 muestras con el OCH, Compactado de muestras.



Fuente: Elaboración Propia.

Determinación de la expansión del material:

- Volteándose el molde y colocándose sobre la base perforada, se coloca el papel filtro sobre la muestra enrasada.
- Colocándose el papel filtro, se procede a colocar el plato y las pesas con el vástago graduable. La sobrecarga mínima será de 10 lbs.
- Luego se procede a sumergirlo en un depósito lleno de agua.
- Para las lecturas de la expansión, se colocará el trípode con el dial y se lectura el inicial, y cada 24 horas se tomará las lecturas correspondientes.
- Terminada las 96 horas o podría ser antes si el suelo es arenoso, se toma la lectura final, con estos datos se determina el porcentaje de hinchamiento el material, que viene a ser la diferencia de la lectura final menos el inicial, dividido entre la altura inicial de la muestra multiplicado por 100.

$$\text{Expansión (\%)} = \frac{\text{Expansión}}{\text{Altura de la muestra}} \times 100 \dots \dots (\text{Ec. 4})$$

Figura 29: Medición de la expansión de la muestra.



Fuente: Elaboración Propia.

Determinación de la resistencia a la penetración:

- Si no es necesario sumergir a la muestra en agua, se procederá a colocar las pesas y se pasaran al ítem 3 y 4.
- Si la muestra si fue sumergida en agua para determinar su expansión, se procede a drenar el agua, para poder realizar el ensayo de penetración, considerando las pesas que tenía en la etapa de hinchamiento.
- Teniendo el molde con la muestra y las pesas de sobrecarga, se instala la prensa, colocando el pistón sobre el centro de la muestra.
- Se regulan y se colocan en cero los diales de medición, estos para medir la penetración.
- Se procede a aplicar la carga en incrementos de 0.025 pulgadas a la velocidad de 0.05 pulgadas/minuto, y se procede a leer las cargas totales hasta que el pistón penetre 0.50 pulgadas.
- Teniendo el ultimo hincado del pistón de 0.50 pulgadas, se deja de aplicar la carga, para retirar el molde de la prensa.
- Por último, se determina el contenido de humedad de la muestra final.

Figura 30: Ensayo de penetración con prensa CBR, Muestras ensayadas.




Fuente: Elaboración Propia.

Normas de referencias:

- NTP 339.145: Método de ensayo de CBR (Relación de Soporte de California) de suelos compactados en el laboratorio.

Figura 31: Algoritmo a seguir para determinar el CBR.



Fuente: Elaboración Propia

3.2.2. ANÁLISIS PRELIMINAR

Una vez conformada la base de datos, se procedió a identificar las variables de entrada (independientes) y las variables de salida (dependientes), además se conformará los datos de entrada y salida en el software NeuralTools.

3.2.2.1. Instalación del software Neural tools.


El procedimiento de la instalación es el siguiente:

- a) Se descarga el instalador con el link:

<https://www.palisade-lta.com/soporte/SQLServer.asp>

b) Se hace click en la opción SI.

Figura 32: Ventana de control de cuentas de usuario.



Fuente: Instalador NeuralTools.

c) Realizar un click sobre la opción siguiente.


Figura 33: Ventana de decisiontools Suite 7.6.1.



Fuente: Instalador NeuralTools.

d) Seleccionar la opción “acepto los términos de contrato de licencia” y hacer click en siguiente.

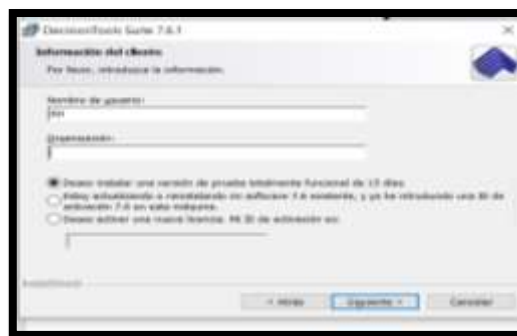
Figura 34: Ventana de decisiontools Suite 7.6.1.



Fuente: Instalador NeuralTools.

e) Pulsar la opción siguiente.

Figura 35: Ventana de decisiontools Suite 7.6.1.



Fuente: Instalador NeuralTools

f) Hacer click en la opción: siguiente.

Figura 36: Ventana de decisiontools Suite 7.6.1.



Fuente: Instalador NeuralTools

g) Pulsar la opción: instalar.

Figura 37: Ventana de decisiontools Suite 7.6.1.



Fuente: Instalador NeuralTools

h) Se espera que el proceso de instalación finalice.

Figura 38: Ventana de decisiontools Suite 7.6.1.



Fuente: Instalador NeuralTools

i) Finalmente, el NeuralTools se muestra de la siguiente manera en el escritorio.

Figura 39: Ventana de decisiontools Suite 7.6.1.



Fuente: Instalador neural tools

3.2.2.2. Identificación de los datos de entrada y salida


Se identificaron las variables independientes (datos de entrada) y las dependientes (datos de salida) de nuestra base de datos desarrollada.

Tabla 15: Datos de entrada y salida.

Tipo de Información	% Grava	% Arena	% Finos	% Límite Líquido	% Límite Plástico	% Índice de Plasticidad	% Óptimo Contenido de Humedad	gr/cm3 Máxima Densidad Seca	CBR (100%-95%)
Variable de entrada (independiente)	X	X	X	X	X	X			
Variable de salida (dependiente)							X	X	X

Fuente: Elaboración Propia.

Figura 40: Identificación de datos de entrada y salida.



Fuente: NeuralTools.

3.2.2.3. Conformación de datos y entrenamiento de la Red Neuronal Artificial con el software NeuralTools


Una vez conformado los conjuntos de datos independientes y dependientes, se procede con el proceso de entrenamiento del modelo neuronal, para su posterior predicción de cada una de las propiedades mecánicas del suelo en estudio.

Figura 41: Datos independientes y dependientes.

% GRAVA	% ARENA	% FINOS	L. LIQUIDO	L. PLASTICO	I.P.	CBR AL 100% MDS 0.1
3.000	37.100	59.900	33.100	24.000	9.100	8.500
23.300	28.100	48.600	60.000	30.600	29.400	25.600
34.900	30.200	34.900	38.200	23.100	15.100	54.000
15.500	36.800	47.700	38.500	26.200	12.300	31.300
13.100	49.200	37.700	30.500	20.700	9.800	23.500
24.900	29.600	45.500	45.600	26.500	19.100	19.900
50.700	25.500	23.800	37.100	23.600	13.500	46.900
50.200	19.100	30.700	45.500	38.400	7.100	38.400
27.600	35.600	36.800	49.300	35.700	13.600	25.600
14.100	49.500	36.400	30.800	19.600	11.200	27.300
11.000	53.100	35.900	44.800	23.900	20.900	21.300
69.500	15.300	15.200	25.300	20.800	4.500	42.700
18.600	38.300	43.100	42.300	31.700	10.600	28.400
9.100	49.700	41.200	21.900	15.500	6.400	22.000
10.700	20.900	68.400	44.600	22.600	22.000	6.400
12.400	66.100	21.500	41.300	30.700	10.600	19.900
7.600	52.500	39.900	44.900	28.400	16.500	28.400
18.100	37.700	44.200	35.500	22.300	13.200	17.100
60.800	26.900	12.300	18.300	NP	NP	64.700
57.700	26.200	16.100	24.500	24.400	10.000	59.700

Fuente: NeuralTools.

Figura 42: Ventana de configuración de entrenamiento.



Fuente: NeuralTools.

3.2.2.4 Elección de la mejor red

El software identifica todos los tipos de red y con diversos errores y selecciona a la mejor, es decir la que obtiene menor error RMS.

Figura 43: Ventana de búsqueda de mejor red.

	Error RMS	Tiempo de Entrenamiento	Razón de parada de entrenamiento
Célula	2.56	00:00:00	Auto-Parado
MLFN 3 neuronas	2.58	00:00:06	Auto-Parado
MLFN 4 neuronas	2.56	00:00:06	Auto-Parado
MLFN 4 neuronas	2.55	00:00:06	Auto-Parado
MLFN 5 neuronas	2.55	00:00:06	Auto-Parado

Fuente: NeuralTools.

3.2.3. DESARROLLO DEL MODELO DE LA RED NEURONAL ARTIFICIAL

En esta parte de la investigación se analiza los resultados que predicen la red neuronal artificial desarrollada con nuestra base de datos recopilada. Con lo cual se determinará el modelo neuronal óptimo y se verificará la calidad y validará con la comparación de propiedades mecánicas predichas con la RNA con las del laboratorio.

Se realizarán los análisis de regresión mediante las correlaciones obtenidas del modelo neuronal versus las obtenidas de la base de datos, las cuales son las siguientes:

3.2.3.1. Análisis de correlación para la validación del modelo neuronal

Después del entrenamiento, se llevó a cabo una comparativa de los valores predichos de la RNA con respecto a los del laboratorio, para este fin se evaluaron 10 tipos de suelos. Se probó el algoritmo de predicción de la red neuronal, esto con el fin de medir la capacidad de predicción del modelo neuronal, esto se realizó utilizando el valor de R^2 .

El propósito de la verificación es validar si las propiedades mecánicas calculadas por la red neuronal tienen la capacidad de reproducir de manera más cercana al igual o mejor las propiedades mecánicas del suelo medidas en laboratorio.

De acuerdo a Bayomy et al., (2012), los valores de la tabla mostrada a continuación indican cómo se califica un modelo de acuerdo con el valor de R^2 . Los valores de esta tabla también fueron utilizados para calificar la red neuronal.

Tabla 16: Criterio del parámetro R^2 de bondad de ajuste o coeficiente de correlación.

Criterio	R^2
Excelente	> 0.9
Bueno	0.7 – 0.89
Regular	0.4 – 0.69
Mala	0.2 – 0.39
Muy mala	< 0.19

Fuente: Bayomy et al., (2012).

En esta parte de la investigación se realizarán todos los análisis de las dispersiones de los resultados obtenidos con el modelo neuronal con los resultados determinados con los ensayos en laboratorio.

Aquí se realizarán los análisis de regresión mediante las correlaciones obtenidas del modelo neuronal versus los obtenidos en laboratorio.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1. RECOPIACIÓN Y CONFORMACIÓN DE LA BASE DE DATOS

Iniciamos con la recopilación de la base de datos mediante el registro de todas las propiedades del suelo de los ensayos realizados en los estudios definitivos y proyectos de Provias Nacional, las cuales fueron 5 expedientes técnicos de carreteras, con lo cual se desarrolló la estructura de la Red Neuronal Artificial.

Posteriormente con ellos se procedió al proceso de entrenamiento del modelo de la Red Neuronal Artificial, utilizando el Software NeuralTools. Una vez terminado el proceso de entrenamiento del modelo neuronal con el algoritmo deseado, se procedió al proceso de predicción de los resultados.

Así mismo, para el proceso de verificación o validación del modelo neuronal, se realizaron ensayos de laboratorio con el fin de obtener las propiedades físicas y mecánicas de los tipos de suelos encontrados, con lo cual se determinará el modelo neuronal óptimo con el menor error posible, verificando la calidad de la predicción de las propiedades mecánicas predichas con la Red Neuronal Artificial y las obtenidas en laboratorio. Por ultimo mencionamos que la comparación de resultados del RNA con los del laboratorio, es para evaluar la capacidad o rendimiento de la red neuronal de predecir valores desconocidos.

4.1.1. BASE DE DATOS DESARROLLADO EMPLEANDO LOS ESTUDIOS DEFINITIVOS DE CARRETERAS

A continuación, se presentan los aspectos relevantes de los proyectos de carreteras del cual se extrajeron los datos. En base a estos proyectos ejecutados se ha desarrollado una base de datos de las propiedades del suelo del eje de la subrasante, el cual contiene una gran cantidad de ensayos del suelo como ensayos de granulometría, límites de consistencia, Proctor modificado, ensayo de CBR, etc.

Tabla 17: Propiedades índice y clasificación de los suelos recopilados.

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
Estudio definitivo de ingeniería para la rehabilitación y mejoramiento de la carretera Patahuasi – Yauri – Sicuani, tramo: Negromayo – Yauri – San Genaro	68+700	C-38 - M-3	ML	3.000	37.100	59.900	33.100	24.000	9.100	16.000	1.600	8.500	5.800
	70+040	C-43 - M-2	SC	23.300	28.100	48.600	60.000	30.600	29.400	14.300	1.963	25.600	18.700
	71+560	C-49 - M-2	GC	34.900	30.200	34.900	38.200	23.100	15.100	12.900	2.000	54.000	50.500
	73+093	C-55 - M-3	SM	15.500	36.800	47.700	38.500	26.200	12.300	16.700	1.760	31.300	25.900
	73+870	C-58 - M-2	SC	13.100	49.200	37.700	30.500	20.700	9.800	12.500	1.940	23.500	16.800
	74+620	C-61 - M-3	SC	24.900	29.600	45.500	45.600	26.500	19.100	21.800	1.800	19.900	14.900
	75+580	C-65 - M-2	GC	50.700	25.500	23.800	37.100	23.600	13.500	8.000	2.110	46.900	35.200
	76+360	C-68 - M-2	GM	50.200	19.100	30.700	45.500	38.400	7.100	12.500	2.075	38.400	30.500
	77+180	C-71 - M-2	SM	27.600	35.600	36.800	49.300	35.700	13.600	12.500	1.903	25.600	19.000
	78+825	C-77 - M-2	SC	14.100	49.500	36.400	30.800	19.600	11.200	11.900	1.842	27.300	17.100
	80+560	C-83 - M-2	SC	11.000	53.100	35.900	44.800	23.900	20.900	16.300	1.706	21.300	14.300
	81+650	C-87 - M-2	GC-GM	69.500	15.300	15.200	25.300	20.800	4.500	7.800	1.938	42.700	36.800
	82+170	C-89 - M-3	SM	18.600	38.300	43.100	42.300	31.700	10.600	13.600	1.825	28.400	21.900
	83+100	C-93 - M-2	SC-SM	9.100	49.700	41.200	21.900	15.500	6.400	14.100	1.813	22.000	13.500
	85+670	C-103 - M-2	CL	10.700	20.900	68.400	44.600	22.600	22.000	16.300	1.579	6.400	4.400
	86+780	C-107 - M-2	SM	12.400	66.100	21.500	41.300	30.700	10.600	14.200	1.813	19.900	15.000
	87+890	C-111 - M-2	SM	7.600	52.500	39.900	44.900	28.400	16.500	14.200	1.838	28.400	21.200
	90+930	C-123 - M-2	SC	18.100	37.700	44.200	35.500	22.300	13.200	17.100	1.841	17.100	8.600
	91+160	C-124 - M-2	GM	60.800	26.900	12.300	18.300	NP	NP	6.400	2.225	64.700	41.800
	91+950	C-127 - M-1	GM	57.700	26.200	16.100	34.500	24.400	10.000	8.200	2.018	59.700	42.300
93+340	C-132 - M-2	SM	3.300	51.200	45.500	51.300	39.400	11.900	14.300	1.780	22.800	18.300	
95+090	C-139 - M-2	SC	24.200	37.700	38.100	35.200	21.000	14.200	15.100	1.795	21.600	14.100	
95+850	C-142 - M-2	SM	4.800	65.900	29.300	44.100	35.300	8.800	14.200	1.831	21.300	14.400	
97+580	C-149 - M-2	SC	3.800	55.600	40.600	32.500	21.300	11.200	16.100	1.720	15.600	11.300	
98+500	C-153 - M-2	SM	23.800	37.000	39.200	40.500	27.200	13.300	15.100	1.843	28.900	18.900	

Fuente: Elaboración Propia.

Tabla 18: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
Estudio definitivo de ingeniería para la rehabilitación y mejoramiento de la carretera Patahuasi – Yauri – Sicuani, tramo: Negromayo – Yauri – San Genaro	100+875	C-163 - M-2	SM	15.900	35.300	48.800	41.000	31.200	9.800	17.300	1.820	22.800	18.100
	102+300	C-169 - M-2	SM	30.900	37.000	32.100	41.000	31.500	9.500	17.000	1.822	25.600	16.500
	104+850	C-180 - M-3	GM	54.100	28.000	17.900	28.500	25.700	2.800	8.800	2.163	56.900	38.600
	105+800	C-184 - M-2	GP-GM	62.700	29.100	8.200	29.100	22.500	6.600	10.600	2.100	48.400	35.300
	107+530	C-191 -M-2	GM	57.800	27.700	14.500	32.800	24.100	8.700	9.900	2.010	49.800	42.000
	109+040	C-197 - M-2	SM	11.900	45.400	42.700	42.200	31.900	10.300	18.400	1.823	22.800	15.000
	109+320	C-198 - M-1	SC	41.400	42.800	15.800	35.100	23.500	11.600	18.800	1.727	21.300	15.600
	110+830	C-204 - M-2	GC	42.600	34.800	22.600	35.700	24.000	11.700	11.400	1.992	51.200	32.000
	112+063	C-209 - M-2	GC	61.100	26.500	12.400	30.400	22.200	8.200	12.000	1.982	51.200	34.000
	112+547	C-211 - M-2	GM	48.400	25.000	26.600	33.800	24.200	9.600	10.200	1.990	41.200	30.100
	113+557	C-215 - M-2	GP-GM	67.600	21.400	11.000	22.500	18.600	3.900	6.200	2.247	78.500	51.200
	115+030	C-220 - A-M-2	CL	7.200	38.200	54.600	33.500	18.600	14.900	17.000	1.628	7.100	6.400
	116+617	C-225 - M-2	GC	54.000	33.500	12.500	30.200	21.300	8.900	12.700	1.978	52.600	40.000
	118+020	C-229 - M-2	GP-GM	77.900	14.700	7.400	16.100	NP	NP	6.000	2.261	81.800	56.100
	119+450	C-235 - M-3	SM	18.700	41.500	39.800	40.600	27.100	13.500	16.100	1.811	29.900	20.000
	121+440	C-243 - M-2	GM	56.700	15.000	28.300	40.600	26.500	14.100	10.800	1.980	69.700	47.300
	123+440	C-251 - M-1	GP-GC	74.300	17.100	8.600	27.000	19.400	7.600	8.500	2.122	50.500	35.600
	125+600	C-260 - M-2	ML	11.200	28.400	60.400	37.400	27.700	9.700	18.100	1.530	7.100	6.000
	127+570	C-268 - M-2	ML	-	27.700	72.300	31.300	23.200	8.100	17.500	1.525	7.300	4.900
	129+530	C-276 - M-2	MH	5.400	34.400	60.200	57.200	45.100	12.100	26.600	1.367	2.300	1.700
130+400	C-279 - M-2	ML	-	45.700	54.300	34.200	24.500	9.700	16.200	1.587	7.400	4.400	
132+680	C-288 - M-3	OL	1.300	41.800	56.900	43.900	36.500	7.400	19.800	1.360	7.100	5.000	
133+930	C-293 - M-2	ML	22.000	19.200	58.800	35.800	31.900	3.900	19.800	1.370	5.100	3.600	
135+180	C-298 - M-2	GP-GM	58.600	32.700	8.700	21.800	17.900	3.900	6.100	2.228	74.000	54.400	
136+430	C-303 - M-2	SM	22.200	36.900	40.900	37.900	26.500	11.400	17.100	1.710	25.600	20.400	

Fuente: Elaboración Propia.

Tabla 19: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
Estudio definitivo de ingeniería para la rehabilitación y mejoramiento de la carretera Patahuasi – Yauri – Sicuani, tramo: Negromayo – Yauri – San Genaro	137+060	C-306 - M-2	SM	16.400	39.800	43.800	33.900	NP	NP	16.200	1.717	27.000	18.200
	139+150	C-316 - M-3	MH	-	2.100	97.900	67.900	57.100	10.800	18.300	1.337	6.000	4.600
	141+300	C-325 - M-1	ML	-	40.800	59.200	54.400	48.400	6.000	17.600	1.560	5.700	4.000
	142+280	C-329 - M-2	GP	58.600	37.700	3.700	24.800	NP	NP	7.500	2.006	56.900	52.000
	143+620	C-334 - M-1	ML	-	25.000	75.000	29.500	24.500	5.000	18.400	1.324	4.300	2.900
	145+480	C-342 - M-2	ML	8.300	22.500	69.200	37.400	30.900	6.500	17.800	1.361	4.300	2.800
	145+975	C-344 - M-2	SM	34.500	45.300	20.200	31.800	23.400	8.400	9.300	2.098	35.700	25.300
	146+530	C-346 - M-2	CL-ML	0.800	25.700	73.500	24.500	19.100	5.400	16.600	1.682	7.100	4.400
	147+540	C-350 - M-2	OL	13.300	23.600	63.100	37.400	26.200	11.200	20.900	1.362	3.100	2.400
	148+110	C-352 - M-2	ML	-	35.900	64.100	32.400	23.400	9.000	18.400	1.458	7.100	4.300
	149+860	C-360 - M-3	ML	-	36.000	64.000	35.000	28.100	6.900	18.500	1.531	5.800	4.200
	150+680	C-363 - M-3	MH	10.300	35.700	54.000	68.000	60.400	7.600	18.800	1.379	3.300	2.500
	152+180	C-369 - M-2	SM	20.600	52.000	27.400	23.300	NP	NP	16.500	1.836	29.900	20.600
153+760	C-375 - M-2	GM	46.100	39.700	14.200	22.000	NP	NP	6.900	2.213	57.600	39.200	
Estudio definitivo para la rehabilitación y mejoramiento de la carretera: Chongoyape – Cochabamba – Cajamarca, tramo: Cochabamba - Chota	119+185	C-1 - M-1	SC-SM	37.600	38.700	23.700	25.000	21.000	4.000	13.800	2.016	31.800	29.700
	119+185	C-1 - M-2	CL	-	46.200	53.800	31.000	20.000	11.000	16.470	1.752	13.700	11.700
	120+910	C-7 - M-1	SC	20.700	42.700	36.600	36.000	26.000	10.000	14.060	1.868	23.200	14.800
	122+800	C-15 - M-1	SC-SM	28.600	37.700	33.700	23.000	17.000	6.000	12.900	2.034	31.000	28.500
	124+800	C-23 - M-1	CL	11.500	13.300	75.200	37.000	24.000	13.000	16.100	1.781	10.400	7.400
	126+710	C-31 - M-1	GM	51.300	28.000	20.700	28.000	25.000	3.000	9.900	2.185	56.200	48.000
	128+770	C-39 - M-1	GC	59.600	16.800	23.600	27.000	18.000	9.000	12.100	2.111	46.000	40.500
	130+690	C-47 - M-1	GC	71.400	15.300	13.300	27.000	16.000	11.000	8.700	2.134	41.300	28.200
	134+690	C-63 - M-1	GC	71.700	13.600	14.700	31.000	21.000	10.000	7.700	2.099	26.000	23.900
	136+690	C-71 - M-1	GC	57.600	12.700	29.700	37.000	23.000	14.000	9.400	1.899	25.700	21.300
138+690	C-79 - M-1	SC	38.700	25.000	36.300	36.000	24.000	12.000	12.800	1.938	15.500	13.100	

Fuente: Elaboración Propia.

Tabla 20: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
	142+875	C-95 - M-1	GC	53.800	25.200	21.000	43.000	27.000	16.000	14.320	2.060	38.400	32.000
	146+785	C-111 - M-1	CL	-	38.300	61.700	45.000	26.000	19.000	21.530	1.481	3.100	2.300
	148+815	C-119 - M-1	GC	57.100	29.600	13.300	23.000	15.000	8.000	10.500	2.155	46.900	41.100
	150+870	C-127 - M-1	GC-GM	49.700	28.300	22.000	22.000	16.000	6.000	10.100	2.168	52.100	43.100
	150+870	C-127 - M-2	SC	26.100	26.700	47.200	41.000	20.000	21.000	16.700	1.822	19.400	13.200
Estudio definitivo para la rehabilitación y mejoramiento de la carretera Ayacucho – Abancay, tramo: Km 50+000 – Km 98+800	50+000	C-3000-M-02	GW	57.900	28.000	14.100	19.010	NP	NP	8.400	2.279	35.000	30.000
	51+250	C-3005-M-01	GW	66.800	27.200	6.000	18.100	NP	NP	6.600	2.151	64.000	42.000
	53+500	C-3014-M-02	GW	43.000	42.100	14.900	18.150	NP	NP	10.320	2.136	65.000	40.000
	55+000	C-3020-M-02	SM-SC	37.400	42.400	20.200	23.370	18.600	4.770	10.500	2.058	36.000	23.000
	55+750	C-3023-M-02	SM	31.400	51.600	17.000	19.320	NP	NP	10.600	1.889	34.000	19.000
	57+250	C-3029-M-01	CL	6.300	42.500	51.200	47.750	24.570	23.180	18.000	1.792	5.000	3.000
	58+750	C-3035-M-02	SM	11.800	64.200	24.000	17.510	NP	NP	14.250	1.894	37.000	18.000
	60+750	C-3043-M-01	SM	26.700	60.300	13.000	18.040	NP	NP	9.900	1.949	39.000	22.000
	62+750	C-3051-M-03	SM	20.100	68.000	11.900	17.690	NP	NP	13.500	1.970	42.000	22.000
	64+750	C-3059-M-02	SM	10.500	80.800	8.700	17.580	NP	NP	13.920	1.929	38.000	20.000
	65+500	C-3062-M-1	GW	51.900	37.300	10.800	28.000	23.500	4.500	9.000	1.945	25.000	19.000
	66+750	C-3067-M-01	SM	37.600	49.300	13.100	16.520	NP	NP	11.500	2.091	42.000	31.000
	68+750	C-3075-M-02	SC	25.900	40.000	34.100	37.430	20.370	17.060	12.500	1.961	32.000	17.000
	69+500	C-3078-M-02	SM	7.700	77.300	15.000	24.270	20.480	3.790	12.700	1.829	41.000	21.000
	70+750	C-3083-M-01	ML	23.800	12.300	63.900	45.750	28.600	17.150	14.500	1.892	18.000	12.000
	72+750	C-3091-M-01	GW	48.300	44.900	6.800	17.500	NP	NP	10.540	2.103	70.000	43.000
	74+750	C-3099-M-02	GC	41.100	27.200	31.700	29.650	22.410	7.240	6.900	2.156	77.000	54.000
	76+750	C-3107-M-02	GC	36.700	34.100	29.200	33.820	21.430	12.390	7.600	2.151	56.000	42.000
78+750	C-3115-M-01	GC	39.300	20.700	40.000	37.810	22.400	15.410	10.500	2.116	59.000	41.000	
80+750	C-3123-M-02	GC	56.600	13.100	30.300	31.800	20.620	11.180	10.500	2.211	71.000	50.000	

Fuente: Elaboración Propia.

Tabla 21: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
				SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)
Estudio definitivo para la rehabilitación y mejoramiento de la carretera Ayacucho – Abancay, tramo: Km 50+000 – Km 98+800	82+750	C-3131-M-01	GW	34.000	33.100	32.900	34.090	24.550	9.540	9.200	2.116	53.000	41.000
	84+750	C-3139-M-01	GM-GC	35.500	31.800	32.700	24.000	18.530	5.470	10.340	2.136	70.000	53.000
	86+750	C-3147-M-02	CL	2.600	19.200	78.200	48.050	27.550	20.500	13.500	1.856	12.000	9.000
	89+000	C-3156-M-01	CL	3.200	19.800	77.000	46.760	25.270	21.490	15.400	1.810	9.000	7.000
	90+750	C-3163-M-02	CL	3.600	41.800	54.600	36.940	18.240	18.700	16.250	1.725	18.000	15.000
	92+250	C-3169-M-01	ML	-	25.800	74.200	36.180	27.010	9.170	12.800	1.965	13.000	7.000
	94+750	C-3179-M-01	CL	22.200	16.900	60.900	41.000	19.160	21.840	10.500	1.889	15.000	12.000
	96+500	C-3186-M-01	SM	34.400	45.300	20.300	18.300	NP	NP	10.400	1.993	40.000	35.000
	96+750	C-3187-M-01	ML	9.000	12.000	79.000	44.660	35.210	9.450	13.500	1.803	18.000	13.000
98+500	C-3194-M-01	GC	42.000	36.000	22.000	26.850	19.830	7.020	7.500	2.160	74.000	49.000	
Estudio definitivo del proyecto de rehabilitación y mejoramiento de la carretera (Pu 135) Checca - Mazocruz	0+010	C-1 - M1	GM	44.100	42.500	13.400	18.360	NP	NP	7.500	2.107	46.800	30.600
	0+010	C-1 - M2	GM	42.900	36.500	20.600	20.060	NP	NP	6.800	2.072	43.100	34.900
	0+010	C-1 - M3	ML	2.000	46.200	51.800	24.980	NP	NP	15.500	1.542	6.200	4.200
	1+960	C-9 - M2	SC-SM	35.100	49.300	15.600	23.040	17.520	5.520	8.600	1.747	26.900	20.000
	3+960	C-17-M2	SC	15.900	67.900	16.200	24.850	18.010	6.840	9.900	1.718	26.000	18.900
	5+970	C-25-M2	SM	10.800	74.200	15.000	18.380	NP	NP	11.200	1.718	25.000	16.300
	5+970	C-25-M4	SC	1.900	78.000	20.100	47.930	26.030	21.900	10.600	1.769	17.300	12.300
	07+970	C-33-M1	SM	37.400	40.600	22.000	20.000	NP	NP	7.500	2.111	63.500	28.100
	07+970	C-33-M2	SM	24.000	45.000	31.000	34.000	26.000	8.000	11.800	1.861	18.900	15.300
	9+980	C-41-M2	SM	-	56.200	43.800	NP	NP	NP	9.200	1.742	17.600	10.100
	9+980	C-41-M3	SM	-	64.600	35.400	NP	NP	NP	9.400	1.764	27.300	22.100
	11+975	C-49-M2	CL	-	40.400	59.600	44.510	25.760	18.750	13.400	1.553	9.000	6.400
	11+975	C-49-M3	SM	4.700	51.900	43.400	NP	NP	NP	9.400	1.705	24.200	17.000
	13+935	C-57-M2	SC-SM	-	79.500	20.500	27.680	22.220	5.460	7.200	1.903	18.400	12.000
15+955	C-65-M1	GM	44.500	43.300	12.200	NP	NP	NP	5.900	2.193	49.800	38.600	

Fuente: Elaboración Propia.

Tabla 22: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
Estudio definitivo del proyecto de rehabilitación y mejoramiento de la carretera (Pu 135) Checca - Mazocruz	15+955	C-65-M2	ML	0.900	37.400	61.700	18.330	NP	NP	19.700	1.565	5.500	4.300
	15+955	C-65-M3	CL	4.400	39.400	56.200	32.180	19.210	12.970	15.100	1.677	4.300	2.200
	16+455	C-67-M1	GM	52.600	35.000	12.400	NP	NP	NP	6.000	2.205	42.800	30.900
	16+455	C-67-M2	ML	1.300	45.900	52.800	19.110	NP	NP	17.800	1.560	5.600	5.000
	17+935	C-73-M2	SC	-	52.800	47.200	32.470	21.590	10.880	9.400	1.771	19.400	13.500
	17+935	C-73-M3	CL	-	43.300	56.700	45.940	22.220	23.720	13.100	1.548	8.500	5.100
	19+940	C-81-M2	CL	-	49.000	51.000	21.610	13.340	8.270	13.100	1.589	8.100	6.100
	19+940	C-81-M4	SC	3.300	57.900	38.800	20.110	10.880	9.230	9.700	1.789	17.000	12.200
	21+940	C-89-M2	SC	-	56.200	43.800	26.220	14.840	11.380	9.400	1.774	17.700	11.400
	23+925	C-97-M2	ML	-	3.000	97.000	48.000	28.000	20.000	12.500	1.768	3.100	1.900
	23+925	C-97-M3	ML	-	9.000	91.000	47.000	28.000	19.000	13.700	1.783	4.400	2.100
	25+925	C-105-M2	CL	4.300	40.600	55.100	30.270	19.400	10.870	13.700	1.584	9.400	6.700
	25+925	C-105-M3	SC	5.200	49.000	45.800	31.260	19.660	11.600	8.500	1.745	12.300	8.500
	27+920	C-113-M3	SC	4.100	47.600	48.300	36.540	22.730	13.810	9.400	1.778	23.100	18.300
	29+920	C-121-M2	SC	6.900	50.700	42.400	43.880	26.790	17.090	9.700	1.722	21.900	14.700
	29+920	C-121-M3	SM	-	64.600	35.400	NP	NP	NP	10.000	1.724	17.300	11.000
	31+910	C-129-M2	CL	10.900	26.000	63.100	47.650	19.580	28.070	12.700	1.576	6.400	4.200
	33+885	C-137-M2	ML	-	45.800	54.200	40.510	25.540	14.970	13.900	1.536	5.100	2.700
	33+885	C-137-M3	SC	18.500	56.000	25.500	40.200	25.030	15.170	10.600	1.741	16.500	10.800
	35+795	C-145-M3	SM	6.600	69.200	24.200	NP	NP	NP	9.900	1.727	21.900	13.600
36+035	C-146-M2	ML-CL	10.000	36.000	54.000	25.000	19.000	6.000	8.000	1.939	13.400	9.900	
36+035	C-146-M3	SM	26.000	60.000	14.000	NP	NP	NP	9.000	1.977	75.000	47.100	
37+800	C-153-M2	SC	-	54.700	45.300	31.550	21.260	10.290	8.100	1.738	14.700	9.400	
39+785	C-161-M2	SM	16.300	54.800	28.900	NP	NP	NP	9.700	1.779	20.500	14.200	
41+785	C-169-M2	GC-GM	40.100	37.000	22.900	26.190	19.870	6.320	10.900	2.020	33.900	22.600	

Fuente: Elaboración Propia.

Tabla 23: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
Estudio definitivo del proyecto de rehabilitación y mejoramiento de la carretera (Pu 135) Checca - Mazocruz	41+785	C-169-M3	SM	24.800	60.000	15.200	NP	NP	NP	8.700	1.722	20.400	11.300
	43+810	C-177-M2	SM	32.400	43.000	24.600	NP	NP	NP	11.000	1.888	26.900	19.000
	43+810	C-177-M3	SM	6.500	46.500	47.000	NP	NP	NP	12.000	1.560	11.000	7.600
	44+750	CA4-M1	SM	10.200	58.500	31.300	NP	NP	NP	10.900	1.556	25.500	21.900
	46+510	CA11-M1	SM	7.500	62.700	29.800	33.810	NP	NP	11.800	1.564	28.800	20.300
	47+755	C-193-M2	SC	8.200	75.700	16.100	41.680	24.760	16.920	10.200	1.773	17.500	12.900
	47+755	C-193-M3	SM	20.700	65.200	14.100	NP	NP	NP	11.100	1.741	18.600	13.200
	49+770	C-201-M3	SM	11.200	47.300	41.500	NP	NP	NP	9.100	1.735	18.100	13.700
	51+740	C-209-M2	SM	11.600	69.600	18.800	NP	NP	NP	9.600	1.744	11.900	8.700
	53+740	C-217-M2	SM	8.400	58.100	33.500	NP	NP	NP	9.100	1.730	19.500	13.900
	55+750	C-225-M3	SM	23.000	56.400	20.600	NP	NP	NP	9.800	1.783	18.500	13.000
	57+750	C-233-M2	GP	51.600	47.000	1.400	NP	NP	NP	5.700	2.027	50.600	37.500
	58+740	CA16-M2	ML	-	13.000	87.000	26.000	NP	NP	11.000	1.837	13.000	9.700
	58+740	CA16-M3	SM	-	75.000	25.000	NP	NP	NP	11.200	1.830	35.200	21.200
	61+455	C249-M2	SM	25.400	55.600	19.000	NP	NP	NP	9.300	1.750	18.100	12.700
	63+450	C257-M1	GM	42.100	36.500	21.400	NP	NP	NP	5.900	2.146	45.600	34.500
	65+450	C265-M2	ML	4.700	42.600	52.700	30.550	NP	NP	14.300	1.580	8.000	4.900
	67+460	C273-M2	SM	5.700	57.600	36.700	27.430	NP	NP	9.000	1.761	20.500	13.400
	67+460	C273-M4	CL	-	43.300	56.700	30.860	19.380	11.480	13.500	1.595	8.100	5.200
	69+420	C281-M2	ML	10.200	35.900	53.900	NP	NP	NP	13.700	1.572	5.500	3.500
71+490	C289-M3	SM	18.900	51.700	29.400	NP	NP	NP	9.100	1.731	16.100	10.200	
72+745	C294-M1	GM	42.600	41.400	16.000	NP	NP	NP	6.200	2.126	45.100	38.600	
72+745	C294-M2	SM	4.200	48.200	47.600	23.120	NP	NP	13.800	1.591	10.200	8.400	
73+005	C295-M2	SM	7.900	55.100	37.000	NP	NP	NP	9.700	1.748	25.200	15.600	
73+005	C295-M3	SC-SM	23.600	50.600	25.800	27.060	21.200	5.860	9.000	1.746	14.400	10.000	

Fuente: Elaboración Propia.

Tabla 24: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
Estudio de Factibilidad y definitivo para el mejoramiento de la carretera Oyón – Ambo. Sector I: Oyón – Desvío Cerro de Pasco	135+396	C-1-M1	GM	46.880	38.960	14.160	15.000	13.000	2.000	6.200	2.253	57.600	40.600
	135+396	C-1-M2	CL-ML	9.400	35.800	54.800	26.000	21.000	5.000	11.700	1.645	8.200	5.600
	137+200	C-9-M1	GP-GM	48.900	39.200	11.900	15.000	12.000	3.000	6.100	2.217	67.400	45.300
	137+200	C-9-M2	GC-GM	51.100	36.500	12.400	17.000	13.000	4.000	7.700	2.220	57.200	38.600
	141+550	C-41-M1	GC-GM	40.100	35.700	24.200	19.000	13.000	6.000	9.400	2.169	36.400	30.200
	141+550	C-41-M2	GC	46.200	34.700	19.100	27.000	20.000	7.000	7.900	2.204	36.500	29.100
	141+550	C-41-M3	GP-GC	63.300	26.400	10.300	25.000	18.000	7.000	8.300	2.192	36.100	29.400
	143+192	C-49-M1	GC	42.700	40.400	16.900	20.000	12.000	8.000	8.200	2.213	20.300	14.400
	143+192	C-49-M2	SC-SM	34.500	34.600	30.900	26.000	20.000	6.000	13.200	2.027	17.100	10.000
	143+192	C-49-M3	SC	35.600	36.400	28.000	27.000	20.000	7.000	11.300	2.157	23.900	12.800
	145+210	C-57-M1	GM	53.200	30.800	16.000	17.000	14.000	3.000	9.200	2.177	31.900	18.800
	145+210	C-57-M2	SM	30.400	30.500	39.100	37.000	30.000	7.000	15.000	1.990	14.200	11.300
	145+210	C-57-M3	SC	35.200	37.100	27.700	28.000	18.000	10.000	10.500	2.144	13.700	12.100
	147+244	C-65-M1	GP-GC	69.800	21.800	8.400	27.000	18.000	9.000	6.300	2.286	34.500	25.500
	147+244	C-65-M2	GP-GC	59.400	30.900	9.700	32.000	23.000	9.000	8.500	2.239	36.500	29.200
	149+216	C-73-M1	SC-SM	37.400	40.400	22.200	19.000	14.000	5.000	6.300	2.215	28.200	16.200
	151+164	C-81-M1	GM	58.900	28.600	12.500	31.000	24.000	7.000	8.500	2.181	64.900	42.100
	151+164	C-81-M2	GP-GM	66.500	23.200	10.300	31.000	23.000	8.000	7.800	2.154	48.200	29.800
	153+161	C-89-M1	GM	47.300	38.200	14.500	14.000	11.000	3.000	6.300	2.282	48.700	37.900
	155+132	C-97-M1	GC	55.500	31.000	13.500	23.000	16.000	7.000	6.100	2.248	55.700	44.700
159+058	C-113-M1	GC	65.200	19.900	14.900	20.000	13.000	7.000	10.900	2.091	58.000	36.700	
159+058	C-113-M2	GP-GC	62.300	30.700	7.000	21.000	12.000	9.000	6.800	2.231	81.100	52.300	
161+093	C-121-M1	GC	51.900	30.700	17.400	25.000	16.000	9.000	7.400	2.230	65.200	29.400	
164+872	C-137-M1	GC-GM	34.600	34.700	30.700	25.000	19.000	6.000	9.100	2.229	51.200	39.500	
167+688	C-145-M1	GM	48.600	22.400	29.000	19.000	17.000	2.000	9.200	2.118	39.400	31.100	

Fuente: Elaboración Propia.

Tabla 25: Propiedades índice y clasificación de los suelos recopilados (continuación).

Estudio Definitivo de Ingeniería	Progresiva (km)	Calicata y Muestra	Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
			SUCS	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
Estudio de Factibilidad y definitivo para el mejoramiento de la carretera Oyón – Ambo. Sector I: Oyón – Desvío Cerro de Pasco	169+180	C-153-M1	GM	51.100	31.500	17.400	32.000	26.000	6.000	8.300	2.049	57.300	39.400
	169+180	C-153-M2	ML	2.800	47.100	50.100	40.000	29.000	11.000	14.900	1.847	8.500	5.900
	171+134	C-161-M1	GP-GC	59.400	29.300	11.300	23.000	16.000	7.000	7.000	2.204	67.900	38.500
	171+134	C-161-M2	MH	3.200	23.600	73.200	52.000	35.000	17.000	10.200	1.723	6.400	4.800
	173+140	C-169-M1	GC-GM	49.800	34.400	15.800	21.000	16.000	5.000	6.800	2.207	53.000	41.900
	173+140	C-169-M2	CL	4.400	11.800	83.800	29.000	22.000	7.000	18.500	1.527	7.400	5.900
	175+072	C-177-M1	GC-GM	44.900	41.400	13.700	27.000	21.000	6.000	11.000	1.894	61.000	46.700
	175+072	C-177-M2	GM	51.400	27.100	21.500	42.000	32.000	10.000	11.100	1.915	48.700	31.300
	177+134	C-185-M1	SM	22.800	51.000	26.200	36.000	29.000	7.000	14.200	1.781	38.500	25.700
	177+134	C-185-M2	SM	28.100	46.600	25.300	38.000	31.000	7.000	18.800	1.616	23.300	15.500
	179+102	C-193-M1	GP-GM	48.700	42.400	8.900	33.000	25.000	8.000	10.700	1.866	64.800	43.600
	180+907	C-201-M1	GM	51.800	34.200	14.000	35.000	30.000	5.000	9.400	2.185	48.200	38.300

Fuente: Elaboración Propia.

4.1.2. RESULTADOS DE LOS ENSAYOS DE SUELOS EN LABORATORIO PARA DETERMINAR EL RENDIMIENTO DEL MODELO NEURONAL DESARROLLADO

La realización de los ensayos de suelos en laboratorio se hizo con el fin de determinar la capacidad o rendimiento de la red neuronal desarrollada, mediante la comparación de resultados predichos con los obtenidos en laboratorio.

Cabe mencionar que los ensayos realizados se hicieron en base a las normas técnicas peruanas NTP, MTC y las normas americanas ASTM, para así poder tener resultados fiables durante el desarrollo de esta investigación.

Además, se aclara que los cálculos de cada ensayo, así como los certificados de los ensayos de suelos realizados se muestran en los anexos.

Tabla 26: Ensayos de suelos en laboratorio.

ENSAYOS	NORMA NTP	NORMA MTC	NORMA ASTM
PROPIEDADES FÍSICAS			
Contenido de Humedad del suelo	NTP 339.127	MTC E 108	ASTM D 2216
Análisis Granulométrico por Tamizado	NTP 339.128	MTC E 107	ASTM D 422
Límite líquido de los suelos	NTP 339.129	MTC E 110	ASTM D 4318
Límite plástico de los suelos e índice de plasticidad	NTP 339.129	MTC E 111	ASTM D 4318
Clasificación de los suelos métodos SUCS	NTP 339.134		
Clasificación de los suelos método AASHTO	NTP 339.135		
PROPIEDADES MECÁNICAS			
Ensayo de Proctor Modificado	NTP 339.141	MTC E 115	ASTM D 1557
Ensayo de CBR (Relación de Soporte)	NTP 339.145	MTC E 132	ASTM D 1883

Fuente: Elaboración Propia.

4.1.2.1. Contenido de humedad

En la siguiente tabla se resumen los resultados del contenido de humedad del suelo, lo cual nos indica el contenido de agua que contiene ésta.

Tabla 27: Resumen de resultados del contenido de humedad.

CONTENIDO DE HUMEDAD (%)	
Calicata	Muestra - Promedio (%)
C-01	4.81
C-02	3.71
C-03	5.11
C-04	13.50
C-05	8.51
C-06	10.02
C-07	14.70
C-08	14.20
C-09	40.00
C-10	15.50

Fuente: Elaboración Propia.

4.1.2.2. Análisis granulométrico por tamizado

Se registraron los porcentajes pasantes en cada tamiz, para determinar los porcentajes de gravas, arenas y finos.

Tabla 28: Resultado granulométrico del suelo.

SUELO	Calicata		
	Grava 3" - N° 4: %	Arena N° 4 - N° 200: %	Finos < N° 200: %
C-1	46.47	22.20	31.33
C-2	28.90	39.40	31.70
C-3	21.80	48.80	29.40
C-4	0.00	55.60	44.40
C-5	10.10	35.30	54.60
C-6	39.60	33.70	26.70
C-7	0.00	46.50	53.50
C-8	6.60	30.00	63.40
C-9	0.00	18.60	81.40
C-10	34.36	12.70	52.94

Fuente: Elaboración Propia.

4.1.2.3. Límites de Atterberg

A continuación, se muestra el resumen de los resultados obtenidos del límite líquido, límite plástico e índice de plasticidad. Estos resultados son muy importantes porque nos ayudaran a clasificar el suelo.

Tabla 29: Resultados del límite líquido, plástico e índice de plasticidad.

Calicata	Límite Líquido (%)	Límite Plástico (%)	Índice de Plasticidad (%)
C-1	43.23	32.50	10.73
C-2	37.84	32.10	5.74
C-3	24.83	21.70	3.13
C-4	31.84	18.88	12.96
C-5	31.80	20.98	10.82
C-6	37.02	18.41	18.60
C-7	43.03	31.92	11.11
C-8	36.23	21.75	14.47
C-9	36.02	24.49	11.52
C-10	27.66	18.69	8.97

Fuente: Elaboración Propia.

4.1.2.4. Clasificación del suelo según el método SUCS

Para la clasificación del suelo por el método SUCS se consideró la granulometría, los porcentajes pasantes acumulados de las mallas N°4, N°200 y los límites líquido y plástico.

Tabla 30: Clasificación SUCS de muestras representativas.

CLASIFICACION DE SUELOS SEGUN SUCS								
Calicata	Grava 3" - N° 4	Arena N° 4 - N° 200	Finos < N° 200	Límite Líquido (LL)	Límite Plástico (LP)	Índice Plástico (IP)	Clasificación SUCS	Denominación
C-1	46.47	22.20	31.33	43.23	32.50	10.73	GM	Grava limosa con arena
C-2	28.90	39.40	31.70	37.84	32.10	5.74	SC-SM	Arena limosa con grava
C-3	21.80	48.80	29.40	24.83	21.70	3.13	SM	Arena limosa con grava
C-4	0.00	55.60	44.40	31.84	18.88	12.96	SC	Arena arcillosa
C-5	10.10	35.30	54.60	31.80	20.98	10.82	CL	Arcilla arenosa de baja plasticidad
C-6	39.60	33.70	26.70	37.02	18.41	18.60	GC	Grava arcillosa con arena
C-7	0.00	46.50	53.50	43.03	31.92	11.11	ML	Limo arenoso
C-8	6.60	30.00	63.40	36.23	21.75	14.47	CL	Arcilla arenosa de baja plasticidad
C-9	0.00	18.60	81.40	36.02	24.49	11.52	ML	Limo arenoso
C-10	34.36	12.70	52.94	27.66	18.69	8.97	CL	Arcilla arenosa de baja plasticidad

Fuente: Elaboración Propia.

4.1.2.5. Ensayo Proctor Modificado

Mediante este ensayo se determinó el óptimo contenido de humedad y la máxima densidad seca del suelo. Previamente se determinó el método de ensayo para determinar el material con la que se ensayará.

Tabla 31: Resultados del ensayo de Proctor Modificado.

Calicata	Óptimo Contenido de Humedad (%)	Máxima Densidad Seca (gr/cm ³)
C-1	11.85	2.03
C-2	14.22	1.84
C-3	11.50	1.94
C-4	11.45	1.80
C-5	15.08	1.67
C-6	13.45	2.01
C-7	13.82	1.69
C-8	15.94	1.55
C-9	15.64	1.79
C-10	14.80	1.81

Fuente: Elaboración Propia.

4.1.2.6. Ensayo de CBR (Valor Relativo de Soporte)

El valor de CBR se utiliza para evaluar la capacidad de soporte de los suelos de subrasante, y de capas de base, sub-base y de afirmado.

Tabla 32: Resultados del ensayo C.B.R.

Calicata	Óptimo Contenido de Humedad (%)	Máxima Densidad Seca (gr/cm3)	CBR - Penetración 0.1"	
			100 % de la MDS	95 % de la MDS
C-1	11.85	2.03	61.45	39.88
C-2	14.22	1.84	40.63	24.15
C-3	11.50	1.94	39.58	18.06
C-4	11.45	1.80	17.38	16
C-5	15.08	1.67	8.47	5.08
C-6	13.45	2.01	49.22	37.6
C-7	13.82	1.69	16.64	8.25
C-8	15.94	1.55	8.25	5.71
C-9	15.64	1.79	14.75	8.74
C-10	14.80	1.81	20.5	14.60

Fuente: Elaboración Propia.

4.2. ANÁLISIS PRELIMINAR

Habiendo revisado las certificaciones de los ensayos de suelos de los estudios definitivos ejecutados por parte de Provias Nacional, y así como la determinación de las propiedades de los suelos en laboratorio, se pudo desarrollar una base de datos necesaria para la investigación.

Con la base de datos recopilada se procede a desarrollar la estructura de la Red Neuronal Artificial, con ello se procedió a realizar el proceso de entrenamiento del modelo neuronal con ayuda del Software NeuralTools, para la predicción de las propiedades mecánicas del suelo.

4.2.1. SELECCIÓN DE DATOS DE INGRESO

Se presenta los datos de ingreso de los ensayos respectivos de nuestra base de datos recopilada. Se consideró 6 datos de entrada (azul) por cada tipo de suelo encontrado, y un dato de salida que viene a ser una propiedad mecánica del suelo (verde).


Tabla 33: Datos de ingreso (azul) y datos de salida (verde).

Clasificación del suelo	Análisis granulométrico (% de Suelo)			Límites de Consistencia			Proctor Modificado		CBR (0.1")	
	% Grava	% Arena	% Finos	LL (%)	LP (%)	IP (%)	OCH (%)	MDS (gr/cm3)	CBR (100% MDS)	CBR (95% MDS)
SUCS										

Fuente: Elaboración Propia.

Para el ingreso de datos en el Software NeuralTools, se realiza mediante la herramienta “Administrador de conjunto de datos”, donde se define los datos de entrada (independiente) y el de salida (dependiente) como se muestra en la figura.

Figura 44: Administrador de conjunto de datos.

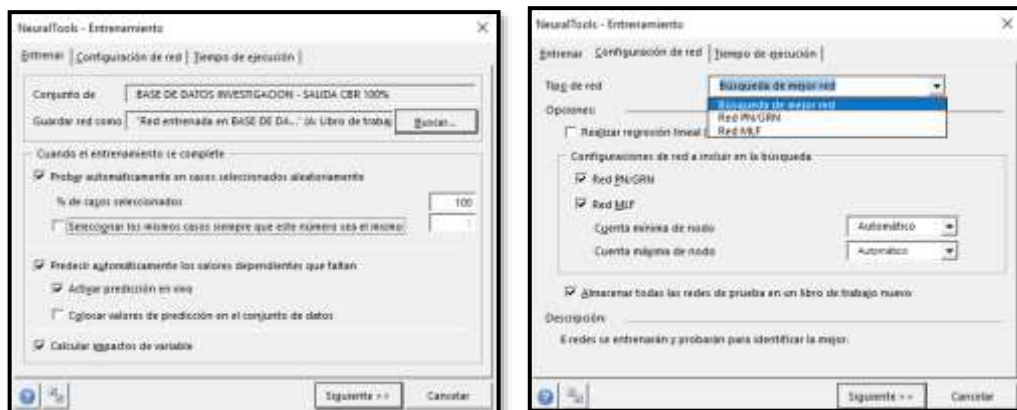


Fuente: NeuralTools.

4.2.2. ARQUITECTURA Y ETAPA DE ENTRENAMIENTO DE LA RED NEURONAL ARTIFICIAL

En esta etapa con los 6 datos de entrada, se buscó un modelo de red neuronal capaz de ajustarse al tipo de dato de salida que se obtuvo con nuestra base de datos recopilada. Así mismo, la función de entrenamiento (entrenar) han sido los 1060 ensayos realizados de nuestra base de datos desarrollada, con lo que se obtuvo redes neuronales del tipo GRNN y MLFN con un numero de nodos o neuronas específicas para cada salida.

Figura 45: Ventana de configuración de entrenamiento.



Fuente: NeuralTools.

Una vez entrenada nuestra base de datos, se desarrolla nuestra arquitectura de Red Neuronal Artificial, la cuales consta de 6 datos de entrada (independiente), capas ocultas con un numero de nodos o neuronas específicas, y un dato de salida (dependiente).

Cabe mencionar que la red neuronal entrenada, se realizó con propiedades del suelo que varían dentro de ciertos rangos. Por lo que, se recomienda que el usuario del modelo neuronal la utilice con suelos cuyas propiedades se encuentran dentro de estos.

Tabla 34: Análisis de regresión lineal utilizando 6 variables de entrada

Variables de entrada	Rangos	
	Inferior	Superior
% Grava	0.0	77.9
% Arena	2.1	80.8
% Finos	1.4	97.9
% Limite Liquido	0.0	68.0
% Limite Plástico	0.0	60.4
% Índice de Plasticidad	0.0	29.4

Fuente: Elaboración Propia.

4.3. RESULTADOS DEL DESARROLLO DE LOS MODELOS DE REDES NEURONALES ARTIFICIALES

Los datos de entrada y salida, son obtenidos de nuestra base de datos ya mencionadas. El cual estos conjuntos de datos obtenidos se han dividido en 2 grupos que son los de entrada y salida, el cual el 80% de los datos de entrada corresponde para el desarrollo del modelo y el 20% de los datos de salida para la prueba del modelo.

En el proceso de entrenamiento de la Red Neuronal se llevó a cabo hasta obtener los adecuados coeficientes de regresión, por lo que por defecto el software detendrá el entrenamiento después de conseguir el mejor rendimiento y con el error mínimo de prueba.

Una vez terminado el proceso de entrenamiento con el algoritmo deseado, se obtiene la estructura de la red neuronal artificial, con lo que mediante estos se puede predecir las propiedades mecánicas del suelo y compararlo con datos de laboratorio que contenga suelos desconocidos en el entrenamiento, con lo que mediante esta comparación estaríamos validando y evaluando la capacidad o rendimiento de la red de predecir valores desconocidos. En la validación de esta investigación se realizó con 10 tipos de suelos diferentes.


A continuación, se muestra las correlaciones de entrenamiento (80% del registro) y la correlación total del modelo (100% del registro), cabe mencionar que para la correlación de validación se presentara 10 muestras de ensayos de laboratorio.

Aquí se realizarán los análisis de regresión mediante las correlaciones obtenidas del modelo neuronal versus las obtenidas de la base de datos, las cuales son las siguientes:

4.3.1. ANÁLISIS DE REGRESIÓN PARA EL CBR AL 100% DE LA MDS.

Análisis de regresión para el entrenamiento (RNA vs Base de datos) con un 80% del registro.

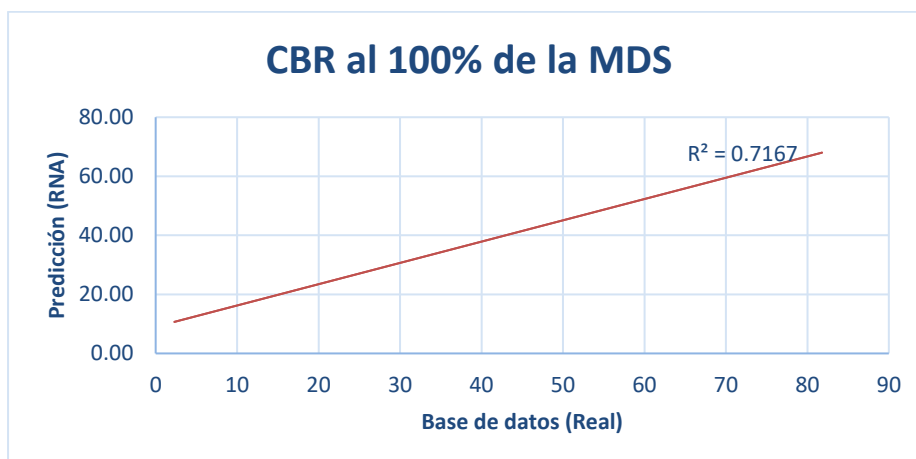
Gráfico 1: Análisis de regresión para el entrenamiento.



Fuente: Elaboración Propia.

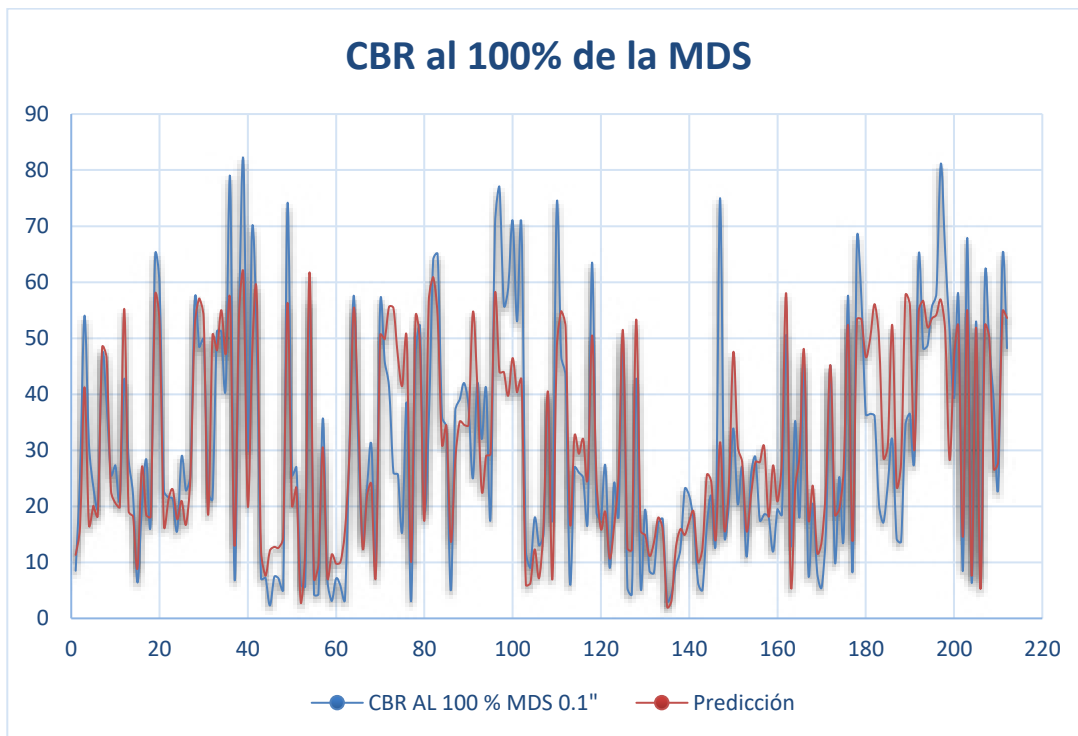
Análisis de regresión para el modelo neuronal (RNA vs Base de datos) con un 100% del registro

Gráfico 2: Análisis de regresión para el modelo total.



Fuente: Elaboración Propia.

Gráfico 3: Análisis de regresión para el modelo total.




Fuente: Elaboración Propia.

Impacto relativo de variable e influentes en el modelo neuronal del CBR al 100% de la MDS

Aquí se mostrarán los variables más influentes en el desarrollo de cada Red Neuronal Artificial.

Gráfico 4: Análisis del impacto relativo de las variables usadas en la investigación.




Fuente: Elaboración Propia.

4.3.2. ANÁLISIS DE REGRESIÓN PARA EL CBR AL 95% DE LA MDS.

Análisis de regresión para el entrenamiento (RNA vs Base de datos) con un 80% del registro.


Gráfico 5: Análisis de regresión para el entrenamiento.



Fuente: Elaboración Propia.


Análisis de regresión para el modelo neuronal (RNA vs Base de datos) con un 100% del registro

Gráfico 6: Análisis de regresión para el modelo total.



Fuente: Elaboración Propia.

Gráfico 7: Análisis de regresión para el modelo total.




Fuente: Elaboración Propia.

Impacto relativo de variable e influyentes en el modelo neuronal del CBR al 95% de la MDS

Aquí se mostrarán los variables más influyentes en el desarrollo de cada Red Neuronal Artificial.

Gráfico 8: Análisis del impacto relativo de las variables usadas en la investigación.




Fuente: Elaboración Propia.

4.3.3. ANÁLISIS DE REGRESIÓN PARA EL ÓPTIMO CONTENIDO DE HUMEDAD (OCH %).

Análisis de regresión para el entrenamiento (RNA vs Base de datos) con un 80% del registro.


Gráfico 9: Análisis de regresión para el entrenamiento.



Fuente: Elaboración Propia.


Análisis de regresión para el modelo neuronal (RNA vs Base de datos) con un 100% del registro

Gráfico 10: Análisis de regresión para el modelo total.



Fuente: Elaboración Propia.

Gráfico 11: Análisis de regresión para el modelo total.




Fuente: Elaboración Propia.

Impacto relativo de variable e influyentes en el modelo neuronal del OCH (%)

Aquí se mostrarán los variables más influyentes en el desarrollo de cada Red Neuronal Artificial.

Gráfico 12: Análisis del impacto relativo de las variables usadas en la investigación.




Fuente: Elaboración Propia.

4.3.4. ANÁLISIS DE REGRESIÓN PARA LA MÁXIMA DENSIDAD SECA (MDS – GR/CM3).

Análisis de regresión para el entrenamiento (RNA vs Base de datos) con un 80% del registro.


Gráfico 13: Análisis de regresión para el entrenamiento.



Fuente: Elaboración Propia.

Análisis de regresión para el modelo neuronal (RNA vs Base de datos) con un 100% del registro


Gráfico 14: Análisis de regresión para el modelo total.



Fuente: Elaboración Propia.

Gráfico 15: Análisis de regresión para el modelo total.

Gráfico 16: Análisis de regresión para el modelo total.




Fuente: Elaboración Propia.

Impacto relativo de variable e influentes en el modelo neuronal del MDS (gr/cm3)

Aquí se mostrarán los variables más influentes en el desarrollo de cada Red Neuronal Artificial.

Gráfico 17: Análisis del impacto relativo de las variables usadas en la investigación.



Fuente: Elaboración Propia.

Tabla 35: Resultados de la búsqueda de la mejor red neuronal.

INFORMACIÓN DE LA MEJOR RED NEURONAL – CBR 100%			
TOPOLOGÍA	% ERROR RMS (ERROR CUADRÁTICO MEDIO)	TIEMPO DE ENTRENAMIENTO	RAZÓN DE PARADA DE ENTRENAMIENTO
GRNN	11.73	00:00:00	Autoparada
MLFN 2 NODOS	9.77	00:00:36	Autoparada
MLFN 3 NODOS	10.44	00:00:36	Autoparada
MLFN 4 NODOS	12.11	00:00:36	Autoparada
MLFN 5 NODOS	10.51	00:00:36	Autoparada
MLFN 6 NODOS	12.69	00:00:36	Autoparada
INFORMACIÓN DE LA MEJOR RED NEURONAL – CBR 95%			
TOPOLOGÍA	% ERROR RMS (ERROR CUADRÁTICO MEDIO)	TIEMPO DE ENTRENAMIENTO	RAZÓN DE PARADA DE ENTRENAMIENTO
GRNN	7.72	00:00:18	Autoparada
MLFN 2 NODOS	7.25	00:00:18	Autoparada
MLFN 3 NODOS	7.75	00:00:18	Autoparada
MLFN 4 NODOS	7.94	00:00:18	Autoparada
MLFN 5 NODOS	7.25	00:00:18	Autoparada
MLFN 6 NODOS	8.40	00:00:18	Autoparada
INFORMACIÓN DE LA MEJOR RED NEURONAL – OCH (%)			
TOPOLOGÍA	% ERROR RMS (ERROR CUADRÁTICO MEDIO)	TIEMPO DE ENTRENAMIENTO	RAZÓN DE PARADA DE ENTRENAMIENTO
GRNN	2.09	00:00:00	Autoparada
MLFN 2 NODOS	2.19	00:00:36	Autoparada
MLFN 3 NODOS	2.76	00:00:36	Autoparada
MLFN 4 NODOS	2.53	00:00:36	Autoparada
MLFN 5 NODOS	2.69	00:00:36	Autoparada
MLFN 6 NODOS	2.66	00:00:36	Autoparada
INFORMACIÓN DE LA MEJOR RED NEURONAL – MDS (gr/cm3)			
TOPOLOGÍA	% ERROR RMS (ERROR CUADRÁTICO MEDIO)	TIEMPO DE ENTRENAMIENTO	RAZÓN DE PARADA DE ENTRENAMIENTO
GRNN	0.12	00:00:00	Autoparada
MLFN 2 NODOS	0.14	00:03:00	Autoparada
MLFN 3 NODOS	0.14	00:03:00	Autoparada
MLFN 4 NODOS	0.13	00:03:00	Autoparada
MLFN 5 NODOS	0.13	00:03:00	Autoparada
MLFN 6 NODOS	0.13	00:03:00	Autoparada

Fuente: Elaboración Propia.

Tabla 36: Resumen de resultados del ajuste de correlaciones de la RNA versus la base de datos recopilada.

Análisis de regresión de cada modelo neuronal	Factor de ajuste o correlación R^2		
	Entrenamiento de la RNA	Prueba de la RNA	Correlación
Análisis de regresión para el CBR al 100% de la MDS.	0.7063	0.7167	Buena
Análisis de regresión para el CBR al 95% de la MDS.	0.8232	0.8077	Buena
Análisis de regresión para el óptimo contenido de humedad OCH (%)	0.8433	0.8030	Buena
Análisis de regresión para la máxima densidad seca MDS (gr/cm ³)	0.9245	0.8878	Excelente

Fuente: Elaboración Propia.

De estas correlaciones mostradas se ve que el modelo neuronal total presenta de buena a excelente correlación para cada red neuronal desarrollada.

4.4. EVALUACIÓN DEL RENDIMIENTO DEL MODELO PROPUESTO CON DATOS DE LABORATORIO (VALIDACIÓN DEL MODELO NEURONAL ARTIFICIAL)

Después del entrenamiento, se llevó a cabo una comparativa de los valores predichos con respecto a los del ensayo de laboratorio. Para lo cual se tomó muestras de diferentes zonas del valle del Mantaro:

Zona 1: Palian

Cerca de las canteras usadas para elaboración de ladrillos.

Tipo de muestra: Arcilla y limos

Cantidad: 250 kg

Zona 2: Chupaca

En el talud de la carretera Chupaca - Cañete

Tipo de muestra: Gravas y arenas

Cantidad: 300 kg


Zona 3: Chupuro

Cantera municipalidad de Chupuro

Tipo de muestra: Grava, arena, arcilla y limo

Cantidad: 200 kg

Figura 46: Mapa de las canteras que se extrajeron las muestras de suelo.



Fuente: Elaboración propia

Se probó el algoritmo de predicción de la red neuronal, esto con el fin de medir la capacidad de predicción del modelo neuronal, esto se realizó utilizando el valor de R^2 .

De acuerdo a Bayomy et al., (2012), los valores de la tabla mostrada a continuación indican cómo se califica un modelo de acuerdo con el valor de R^2 . Los valores de esta tabla también fueron utilizados para calificar la red neuronal.

Tabla 37: Criterio del parámetro R^2 de bondad de ajuste o coeficiente de correlación.

Criterio	R^2
Excelente	> 0.9
Bueno	0.7 – 0.89
Regular	0.4 – 0.69
Mala	0.2 – 0.39
Muy mala	< 0.19

Fuente: Bayomy et al., (2012).


La dispersión de los resultados obtenidos con el entrenamiento mediante Redes Neuronales Artificiales (eje “Y”) y el obtenido con los ensayos de laboratorio (eje “X”), se muestran a continuación.

Con el modelo neuronal óptimo obtenido en el entrenamiento, se procedió a realizar la validez y capacidad de rendimiento del modelo, en la cual se obtuvo los siguientes resultados, donde se realiza la comparación de resultados del CBR al 100%, CBR al 95%, OCH y la MDS del suelo con el modelo neuronal y los ensayos en laboratorio.

Correlación de resultados del CBR al 100% de la MDS


Resultados del CBR al 100% de la MDS, obtenidos con el entrenamiento mediante Redes Neuronales Artificiales (eje “Y”) y el obtenido con los ensayos de laboratorio (eje “X”).

Gráfico 18: Correlación de los datos (CBR al 100% MDS) de RNA y laboratorio



Fuente: Elaboración Propia.

Gráfico 19: Correlación de los datos (CBR al 100% MDS) de RNA y laboratorio.




Fuente: Elaboración Propia.

El gráfico nos muestra la forma de tendencia de los puntos, la cual nos dice que resultó una buena correlación lineal positiva, siendo el bondad de ajuste de $R^2=0.7317$.

Correlación de resultados del CBR al 95% de la MDS


Resultados del CBR al 95% de la MDS, obtenidos con el entrenamiento mediante Redes Neuronales Artificiales (eje "Y") y el obtenido con los ensayos de laboratorio (eje "X").

Gráfico 20: Correlación de los datos (CBR al 95% MDS) de RNA y laboratorio.



Fuente: Elaboración Propia.

Gráfico 21: Correlación de los datos (CBR al 95% MDS) de RNA y laboratorio.




Fuente: Elaboración Propia.

El gráfico nos muestra la forma de tendencia de los puntos, la cual nos dice que resultó una regular correlación lineal positiva, siendo el bondad de ajuste de $R^2=0.8229$.

Correlación de resultados del Óptimo Contenido de Humedad “OCH” (%)


Resultados del Óptimo Contenido de Humedad “OCH” (%), obtenidos con el entrenamiento mediante Redes Neuronales Artificiales (eje “Y”) y el obtenido con los ensayos de laboratorio (eje “X”).

Gráfico 22: Correlación de los datos (OCH) de RNA y laboratorio.



Fuente: Elaboración Propia.

Gráfico 23: Correlación de los datos (OCH) de RNA y laboratorio.




Fuente: Elaboración Propia.

El gráfico nos muestra la forma de tendencia de los puntos, la cual nos dice que resultó una buena correlación lineal positiva, siendo el bondad de ajuste de $R^2=0.8445$.

Correlación de resultados de la Máxima Densidad Seca “MDS” (gr/cm3)


Resultados de la Máxima Densidad Seca “MDS” (gr/cm3), obtenidos con el entrenamiento mediante Redes Neuronales Artificiales (eje “Y”) y el obtenido con los ensayos de laboratorio (eje “X”).

Gráfico 24: Correlación de los datos (MDS) de RNA y laboratorio.



Fuente: Elaboración Propia.

Gráfico 25: Análisis de regresión para la validación (predicción vs real).



Fuente: Elaboración Propia.

El gráfico nos muestra la forma de tendencia de los puntos, la cual nos dice que resultó una buena correlación lineal positiva, siendo el bondad de ajuste de $R^2=0.9265$.

Tabla 38: Resumen de resultados del ajuste de correlaciones de la RNA versus los de laboratorio.

Análisis de regresión de cada modelo neuronal	Factor de ajuste o correlación R^2		
	Modelo Neuronal Entrenado	Validación Laboratorio	Correlación
Análisis de regresión para el CBR al 100% de la MDS.	0.7063	0.7317	Bueno
Análisis de regresión para el CBR al 95% de la MDS.	0.8232	0.8229	Bueno
Análisis de regresión para el óptimo contenido de humedad (OCH %).	0.8433	0.8445	Bueno
Análisis de regresión para la máxima densidad seca (MDS – gr/cm ³)	0.9245	0.9265	Excelente

Fuente: Elaboración Propia.

Tabla 39: Comparación de resultados obtenidos con la RNA y el del laboratorio.

CALICATA	CBR (100% MDS)		CBR (95% MDS)		OCH (%)		MDS (gr/cm ³)	
	Laboratorio (%)	RNA (%)	Laboratorio (%)	RNA (%)	Laboratorio (%)	RNA (%)	Laboratorio (gr/cm ³)	RNA (gr/cm ³)
C-1	61.45	45.15	39.88	31.44	11.85	12.04	2.03	2.04
C-2	40.63	25.48	24.15	16.79	14.22	14.72	1.84	1.87
C-3	39.58	25.13	18.06	16.60	11.50	10.54	1.94	1.88
C-4	17.38	15.67	16.00	14.29	11.45	11.36	1.80	1.75
C-5	8.47	13.58	5.08	4.52	15.08	15.04	1.67	1.64
C-6	49.22	44.86	37.60	35.30	13.45	14.23	2.01	2.09
C-7	16.64	13.20	8.25	4.52	13.82	15.54	1.69	1.62
C-8	8.25	10.30	5.71	4.52	15.94	16.65	1.55	1.54
C-9	14.75	5.33	8.74	4.52	15.64	16.46	1.79	1.72
C10	20.50	34.41	14.60	25.65	14.80	13.60	1.81	1.86

Fuente: Elaboración Propia.

4.5. DISCUSIÓN DE RESULTADOS

4.5.1. DISCUSIÓN 1

La correlación de los datos de CBR al 100% de la MDS obtenidos mediante el entrenamiento y desarrollo de la Red Neuronal Artificial y con la base de datos preparada, tuvo un coeficiente de correlación de Pearson $R^2= 0.7063$.

La correlación de los datos de CBR al 95% de la MDS obtenidos mediante el entrenamiento y desarrollo de la Red Neuronal Artificial y con la base de datos preparada, tuvo un coeficiente de correlación de Pearson $R^2= 0.8232$.

La correlación de los datos de la OCH obtenidos mediante el entrenamiento y desarrollo de la Red Neuronal Artificial y con la base de datos preparada, tuvo un coeficiente de correlación de Pearson $R^2= 0.8433$.

La correlación de los datos de la MDS obtenidos mediante el entrenamiento y desarrollo de la Red Neuronal Artificial y con la base de datos preparada, tuvo un coeficiente de correlación de Pearson $R^2= 0.9245$.

Al respecto Bayomy et al., (2012), recomienda coeficientes de correlación donde se encuentra que un modelo con el valor de R^2 entre 0.70 a 0.89, este califica como una correlación buena y un valor de $R^2 > 0.90$ califica como correlación excelente ; por lo cual los valores indicados son próximos a rangos de correlación buena y excelente.

4.5.2. DISCUSIÓN 2

La base de datos desarrollada con 6 variables de entrada y una de salida, nos determinó resultados buenos ya que los coeficientes de correlación de Pearson están en el rango de Bueno a Excelente.

Al respecto Bayomy et al., (2012), recomienda coeficientes de correlación donde se encuentra que un modelo con el valor de R^2 entre 0.70 a 0.89 este califica como una correlación buena y un valor de $R^2 > 0.90$ califica como correlación excelente; por lo cual los valores indicados son próximos a esos rangos.

4.5.3. DISCUSIÓN 3

El diseño de la topología de la Red Neuronal Artificial, se realizó mediante la búsqueda de la mejor red, opción en la cual NeuralTools entrena y prueba todas las configuraciones de red marcadas, por lo que en esta investigación se incluyó redes PNN y las redes MLFN con cuentas de nodos de 2 a 6 en la capa oculta, mediante el cual se logró disponer de 6 modelos, de las cuales NeuralTools selecciona el mejor. Por lo que para la selección del mejor modelo

se determinó en base a los coeficientes de correlación y al error cuadrático medio, esto en base al entrenamiento del modelo neuronal.

La topología de la Red Neuronal Artificial Óptima con el menor error registrado fue del modelo MLFN de 2 nodos (para CBR al 100%), modelo MLFN de 5 nodos (para CBR al 95%), modelo GRNN (para MDS), modelo GRNN (para el OCH) la cual el promedio de predicción correcta fue del 95.19%. Como se puede observar, el mejor modelo se logró de muchas pruebas de ensayo error realizados con NeuralTools.

Al respecto (Gomez, y otros, 2012), en el artículo de investigación de Aplicación de redes neuronales en la clasificación de arcillas, obtiene de una búsqueda de la mejor red neuronal la cual obtiene una topología de MLFNN de 5 nodos con un promedio de clasificación correcta del 94.12%. En base a esto podemos decir que el diseño de la topología de la Red Neuronal Artificial va a depender de las variables de entrada y salida.

4.5.4. DISCUSIÓN 4

Para la etapa de evaluación y validación, y por consiguiente determinar el nivel de precisión del modelo neuronal se determinó mediante la obtención de los factores de correlación obtenidos mediante el modelo neuronal óptimo y mediante los ensayos de laboratorio, donde se obtuvieron una correlación de Pearson positiva de buena a excelente con coeficiente de correlación de $R^2 = 0.7317$ para CBR al 100%, un $R^2 = 0.8229$ para CBR al 95%, $R^2 = 0.8445$ para el OCH, un $R^2 = 0.9265$ para la MDS, con lo cual queda demostrado que el modelo neuronal artificial es confiable y de una buena precisión.

Al respecto Bayomy et al., (2012), recomienda coeficientes de correlación donde se encuentra que un modelo con el valor de R^2 entre 0.70 a 0.89 este califica como una correlación buena y un valor de $R^2 > 0.90$ califica como correlación excelente; por lo cual los valores indicados son próximos a esos rangos.

CONCLUSIONES

1. La correlación de los datos de las propiedades mecánicas del suelo obtenidos mediante el entrenamiento y desarrollo de las Redes Neuronales Artificiales con la base de datos preparada, tuvieron una correlación de Pearson positiva de buena a excelente con coeficiente de correlación de $R^2 = 0.7063$ para CBR al 100%, un $R^2 = 0.8232$ para CBR al 95%, $R^2 = 0.8433$ para el OCH, un $R^2 = 0.9245$ para la MDS, por lo que queda demostrado que mediante el uso de un software basado en algoritmos de Redes Neuronales Artificiales se puede llegar a determinar las propiedades mecánicas del suelo con un grado alto de precisión.

2. En este trabajo de investigación se usó una base de datos de Provías Nacional y ensayos de la localidad, las que permitieron obtener coeficientes de correlación de buena a excelente, con lo que se concluye que, la base de datos de los ensayos de suelos realizados y supervisados por Provías Nacional es confiable, lo cual nos permitió entrenar el modelo neuronal con una buena precisión.

3. Mediante el entrenamiento del modelo neuronal, tomando como base de datos de los ensayos realizados y supervisados por Provías Nacional, se puede desarrollar la estructura de un modelo neuronal artificial para diseñar la topología del modelo neural que resultó un GRNN y un MLF, que es una red multinivel siempre hacia adelante, lo que nos indica que el promedio de predicción correcta es del 95.19%

4. Para la etapa de evaluación y validación, para determinar el nivel de precisión del modelo neuronal es necesario la obtención de los factores de correlación obtenidos mediante el modelo neuronal óptimo y mediante los ensayos de laboratorio, donde se obtuvieron una correlación de Pearson positiva de buena a excelente con coeficiente de correlación de $R^2 = 0.7317$ para CBR al 100%, un $R^2 = 0.8229$ para CBR al 95%, $R^2 = 0.8445$ para el OCH, un $R^2 = 0.9265$ para la MDS, con lo cual, queda demostrado que el modelo neuronal artificial es confiable y de una buena precisión.

RECOMENDACIONES

1. Alimentar más la base de datos de entrenamiento de la Red Neuronal Artificial, para poder así disminuir el porcentaje de error, con lo cual se obtendría mejores coeficientes de correlación, para que el nivel de precisión de la predicción de las propiedades mecánicas del suelo sea más eficiente, confiable y con el menor error posible.
2. Desarrollar una base de datos con un banco de ensayos que se puedan recopilar en laboratorios especializados de mecánica de suelos, para alimentar mejor a la Red Neuronal Artificial, llegando a obtener mejores niveles de precisión del modelo neuronal artificial.
3. Desarrollar un lenguaje de programación para que los diseños de la topología tengan un nivel de precisión alto, ya que se obtendrían diseños con un menor error cuadrático medio, además de ser redes multinivel.
4. Realizar más ensayos de laboratorio para la etapa de validación y obtención del nivel de precisión del modelo neuronal, para obtener coeficientes de correlación cercanas a 1, siendo más confiables en la predicción de las propiedades mecánicas del suelo.

REFERENCIAS BIBLIOGRÁFICAS

- Alvarez Ledesma, Andeer Andrew. 2015.** *Generación de caudales con modelos de redes neuronales artificiales a partir de las características de una cuenca.* Huancayo : s.n., 2015.
- Anderson, J. 1995.** *An Introduction to Neural Networks.* USA : s.n., 1995.
- Bañon, Blazquez Luis y Bevia Garcia, Jose. 2012.** *Manual de Carreteras.* Lima : s.n., 2012. pág. 328. Vol. II.
- Basogain Olabe, Xabier. 1998.** *Redes Neuronales Artificiales y sus Aplicaciones.* España : Escuela Superior de Ingeniería de Bilbao, EHU, 1998. P3BN11.
- Beltrán Calvo, Gloria Inés. 2012.** *Evaluación estructural de pavimentos flexibles con métodos de inteligencia artificial y auscultación no destructiva.* México, D.F. : s.n., 2012.
- Beltran, G. y Romo, M. 2014.** *Assessing artificial neural network performance in estimating the layer properties of pavements.* s.l. : Ingeniería e investigación, 2014. Vol. Vol. 34.
- Borja S., Manuel. 2012.** *Metodología de la investigación para ingenieros.* Chiclayo : s.n., 2012.
- Braja Das, M. 2013.** *Fundamentos de Ingeniería Geotécnica.* 4ta Ed. Mexico : Cengage Learning Editores, 2013. 978-607-519-373-1.
- Bredenhann, S.J. y Van de Ven, M.F.C. 2004.** *Application of artificial neuronal networks in the bak-calculation of flexivle pavement layer moduli fron deflection measurements.* 2004.
- Ccanto Mallma, Germán. 2010.** *Metodología de la investigación científica en ingeniería civil - ingeniería de transportes.* 3ra. ed. 2010. 0260-89-330-0.
- Ceylan, B. y Gopalakrishnan, K. 2014.** *Neural networks applications in pavement engineering.* s.l. : a recente survey, 2014.
- Charytoniuk, W. 2000.** *Neural Network Based demand forecasting in a deregulatedenvironmen.* [ed.] IEEE Transactions on. s.l. : Industry Applications, 2000. Vol. Vol. 36.
- Crespo Villalaz, Carlos. 2004.** *Mecánica de suelos y cimentaciones.* Mexico : LIMUSA, 2004. 968-18-6489-1.
- Das, Braja M. 2013.** *Fundamentos de Ingeniería Geotécnica.* Cuarta. Mexico : Cengage Learning Editores, 2013. pág. 658. 978-607-519-373-1.
- E.050, Norma Técnica Peruana. 2015.** *Suelos y Cimentaciones.* Lima : MACRO, 2015.
- Flores, L. y Fernandez, F. 2008.** *Las Redes Neuronales Artificiales, Fundamentos teoricos y aplicaciones practicas.* España : Netbiblo, S.L., 2008.
- Freeman, J. y Skapura, D. 1991.** *Neural Networks - Algorithms, Applications and Programming Techniques.* Willington: Adison Wesley : s.n., 1991.

- Goktepe, A., Agar , E. y Lav, H.** *Role of Learning Algorithm in Neuronal Networ-Based Backcalulation of Flexible Pavements.* s.l. : Journal of Computing in Civil Engineering. Vol. Vol. 20. No. 5370-373.
- Gomez, Jairo, y otros. 2012.** *Aplicacion de redes neuronales en la clasificacion de arcillas.* Medellin : s.n., 2012. ISSN 1794-1237.
- Hernandez Sampieri, Roberto, Fernandez Collado, Carlos y Baptista Lucio, Pilar. 2010.** *Metodologia de la investigacion.* 5ta ed. Mexico D.F. : McGRAW-HILL, 2010. 978-607-15-0291-9.
- Hilera, J. y Martinez, V. 1995.** *Redes Neuronales Artificiales, Fundamentos, modelos y aplicaciones.* Madrid : Alfaomega, 1995.
- Montejo, Fonseca Alfonso. 2002.** *INGENIERIA DE PAVIMENTOS PARA CARRETERAS.* Segunda. Colombia : AGORA, 2002. pág. 733. 958-93036-2-9.
- MTC, Ministerio de Transportes y Comunicaciones. 2016.** *Manual de ensayos de materiales.* Lima : s.n., 2016.
- NeuralTools V7.6. 2015.** *Guia para el uso de NeuralTools - Programa auxiliar de redes neuronales para Microsoft Excel.* EE.UU. : Palisade Corporation, 2015.
- NTP 339.127, Norma Tecnica Peruana. 2006.** *Contenido de humedad.* Lima : s.n., 2006.
- NTP 339.128, Norma Tecnica Peruana. 2006.** *SUELOS. Metodo de ensayo para el analisis granulometrico.* Lima : Indecopi, 2006.
- NTP 339.129, Norma Tecnica Peruana. 2006.** *SUELOS. Metodo de ensayo para determinar el limite liquido, limite plastico e indice de plasticidad de suelos.* Lima : Indecopi, 2006.
- NTP 339.145, Norma Tecnica Peruana. 2006.** *Metodo de ensayo de CBR (Relacion de Soporte de California) de suelos compactados en el laboratorio.* Lima : Indecopi, 2006.
- Reddy, M., Sudhakar, R. y Pandey, B. 2004.** *Selection of genetic algorithm parameters for back-calculation of pavement moduli.* s.l. : International Journal of Pavement Engineering, 2004.
- Rojas Godoy, Mauricio Roberto. 2015.** *Predicción de accidentes de tránsito utilizando Redes Neuronales Artificiales y Cuckoo Search.* Valparaiso-Chile : s.n., 2015.
- Sarraute, Carlos. 2007.** *Aplicación de las redes neuronales al reconocimiento de sistemas operativos.* Buenos Aires : s.n., 2007.
- Satish, K. 2007.** *Neural Network - a classroom approach.* New Delhi : McGraw-Hill, 2007.
- Vega Huerta, Hugo Froilán. 2011.** *Redes neuronales para el reconocimiento de la calidad morfologica de mangos exportables para la empresa Biofruit del Perú S.A.C.* Lima : s.n., 2011.

Vila Zuñiga, Rocio. 2017. *Análisis del comportamiento lineal de la estructura del pavimento flexible mediante redes neuronales en la carretera panamericana norte.* Huancayo : s.n., 2017.

Yegnanarayana, B. 2006. *Artificial neural networks.* New Delhi : Prentice - Hall of India, 2006.

ANEXOS

ANEXO 1: PANEL FOTOGRÁFICO DE LOS ENSAYOS DE LABORATORIO

ANEXO 1.1: Ensayos de contenido de humedad (NTP 339.127-MTC E 108)

Figura 47: Determinación del contenido de humedad natural de las muestras.



Fuente: Elaboración Propia

ANEXO 1.2: Ensayos de granulometría por tamizado (NTP 339.128-MTC E 107)

Figura 48: Análisis granulométrico por tamizado de las muestras.



Fuente: Elaboración Propia

ANEXO 1.3: Ensayos de límites de consistencia (NTP 339.129-MTC E110-E111)

Figura 49: Ensayos de límite líquido de las muestras.



Fuente: Elaboración Propia

Figura 50: Ensayos de límite plástico de las muestras.



Fuente: Elaboración Propia

ANEXO 1.4: Ensayos de Proctor Modificado (NTP 339.141-MTC E115)

Figura 51: Ensayo de Proctor Modificado de las muestras.



Fuente: ICCSAH SAC.

Figura 52: Ensayo de Proctor Modificado de las muestras.



Fuente: ICCSAH SAC.

ANEXO 1.5: Ensayos de Relación de Soporte de California CBR (NTP 339.145-MTC E132)

Figura 53: Ensayo de Relación de Soporte de California CBR de las muestras.



Fuente: ICCSAH SAC.

Figura 54: Ensayo de Relación de Soporte de California CBR de las muestras.



Fuente: ICCSAH SAC.

Figura 55: Ensayo de Relación de Soporte de California CBR de las muestras.




Fuente: ICCSAH SAC.

ANEXO 2: CERTIFICADOS DE LOS ENSAYOS REALIZADOS EN LABORATORIO


- ANEXO 2.1: Certificados de ensayos de laboratorio de la calicata C-1

Figura 56: Ensayo de contenido de humedad (Muestra C-1).

			
LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS			
DETERMINACIÓN DE HUMEDAD NATURAL NORMAS TÉCNICAS: MTC E 108, ASTM D 2216			
CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-01
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		
DATOS DE LA MUESTRA			
ENSAYO N°	1	2	3
Nro. DE TARA	T1	T2	T3
PESO TARA + SUELO HUMEDO gr.	1093.10	873.60	645.40
PESO TARA + SUELO SECO gr.	1062.00	835.90	618.80
PESO DE LA TARA gr.	399.40	67.30	67.30
PESO DEL AGUA gr.	31.10	37.70	26.60
PESO SUELO SECO gr.	662.60	768.60	551.50
HUMEDAD %	4.69	4.91	4.82
HUMEDAD NATURAL PROMEDIO %	4.81		
Observaciones:	_____ _____		

Fuente: ICCSAH SAC.

Figura 57: Ensayo de límites de consistencia (Muestra C-1).



INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRAULICA S.A.C.

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

LÍMITES DE CONSISTENCIA
 NORMAS TÉCNICAS: MTC E 110 - MTC E 111, ASTM D 4318, AASHTO T 89 - T 90

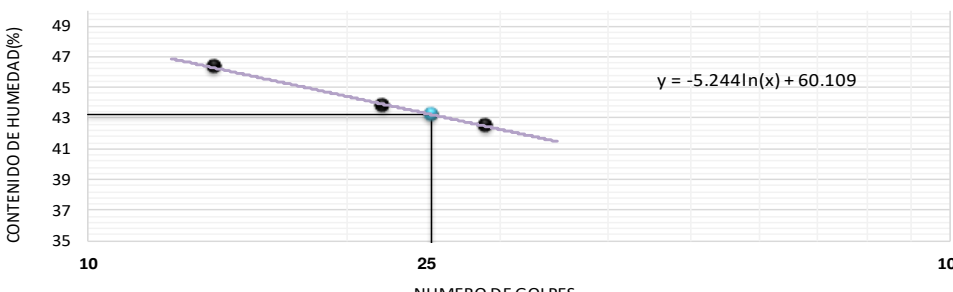
CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-01
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DA VILA		

DATOS DE LA MUESTRA

LIMITE LIQUIDO (MTC E 110, AASHTO T 89)				
Nº TARA	TL4	TL 5	TL 6	
PESO TARA + SUELO HUMEDO (gr.)	38.41	35.32	34.46	
PESO TARA + SUELO SECO (gr.)	31.46	29.65	29.13	
PESO DE AGUA (gr.)	6.95	5.67	5.33	
PESO DE LA TARA (gr.)	16.45	16.71	16.59	
PESO DEL SUELO SECO (gr.)	15.01	12.94	12.54	
CONTENIDO DE HUMEDAD (%)	46.30	43.82	42.50	
NUMERO DE GOLPES	14	22	29	

LIMITE PLÁSTICO (MTC E 111, AASHTO T 90)				
Nº TARA	TP 7	TP 8	TP 9	Promedio
PESO TARA + SUELO HUMEDO (gr.)	30.92	29.12	30.13	
PESO TARA + SUELO SECO (gr.)	27.95	26.49	27.49	
PESO DE LA TARA (gr.)	18.86	18.35	19.37	
PESO DEL AGUA (gr.)	2.97	2.63	2.64	
PESO DEL SUELO SECO (gr.)	9.09	8.14	8.12	
CONTENIDO DE HUMEDAD (%)	32.67	32.31	32.51	32.50

CONTENIDO DE HUMEDAD A 25 GOLPES




$y = -5.244\ln(x) + 60.109$

LIMITES DE CONSISTENCIA	
LIMITE LIQUIDO (%)	43.23
LIMITE PLASTICO (%)	32.50
INDICE DE PLASTICIDAD (%)	10.73

OBSERVACIONES:


Fuente: ICCSAH SAC.

Figura 58: Ensayo de granulometría por tamizado (Muestra C-1).




Fuente: ICCSAH SAC.

Figura 59: Ensayo de Proctor Modificado (Muestra C-1).



Fuente: ICCSAH SAC.

Figura 60: Ensayo de Relación de Soporte de California CBR (Muestra C-1).



INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA S.A.C.

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
 NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO : TRABAJO DE INVESTIGACION **CALICATA:** C-01
PROVINCIA: HUANCAYO **MUESTRA :** M-1
DEPARTAMENTO: JUNIN **PROFUNDIDAD :** 1.00-1.50m
CLIENTE: BACH. MEDALITH MANRIQUE DAVILA

DATOS DE LA MUESTRA

COMPACTACIÓN

Molde N°	5		6		7	
Capas N°	5		5		5	
Golpes por capa N°	10		25		56	
Condición de la muestra	SATURADO	NO SATURADO	SATURADO	NO SATURADO	SATURADO	NOSATURADO
Peso de molde + Suelo húmedo (g)	12248		12269		12653	
Peso de molde + base (g)	7922		7740		7828	
Peso del suelo húmedo (g)	4326		4529		4825	
Volumen del molde (cm ³)	2124		2124		2124	
Densidad húmeda (g/cm ³)	2.037		2.133		2.272	
Tara (N°)	T5		T6		T7	
Peso suelo húmedo + tara (g)	490.0		522.8		781.2	
Peso suelo seco + tara (g)	449.2		478.6		715.8	
Peso de tara (g)	105.4		106.8		164.7	
Peso de agua (g)	40.8		44.2		65.4	
Peso de suelo seco (g)	343.8		371.8		551.1	
Contenido de humedad (%)	11.87		11.89		11.87	
Densidad seca (g/cm ³)	1.821		1.906		2.031	

PENETRACION


PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE N° 10 G				MOLDE N° 25 G				MOLDE N° 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0			0					0		
0.635			58			111					192		
1.270			123			233					405		
1.905			185			350					608		
2.540	70.5		256	255.6	18.7	482	481.9	35.3			838	838.0	61.5
3.810			379			715					1243		
5.080	105.7		509	508.6	24.9	960	960.0	46.9			1669	1669.3	81.6
6.350			614			1158					2014		
7.620			711			1342					2333		
10.160			836			1579					2745		
12.700			909			1715					2983		

Observaciones:

.....

Fuente: ICCSAH SAC.


Figura 61: Ensayo de Relación de Soporte de California CBR (Muestra C-1).



Fuente: ICCSAH SAC.

- ANEXO 2.2: Certificados de ensayos de laboratorio de la calicata C-2

Figura 62: Ensayo de contenido de humedad (Muestra C-2).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-02
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T1	T2	T3
PESO TARA + SUELO HUMEDO gr.	692.60	1380.60	1036.60
PESO TARA + SUELO SECO gr.	673.10	1344.00	1008.55
PESO DE LA TARA gr.	132.70	380.40	256.55
PESO DEL AGUA gr.	19.50	36.60	28.05
PESO SUELO SECO gr.	540.40	963.60	752.00
HUMEDAD %	3.6	3.80	3.73
HUMEDAD NATURAL PROMEDIO %	3.71		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 63: Ensayo de límites de consistencia (Muestra C-2).




Fuente: ICCSAH SAC.

Figura 64: Ensayo de granulometría por tamizado (Muestra C-2).




Fuente: ICCSAH SAC.

Figura 65: Ensayo de Proctor Modificado (Muestra C-2).



Fuente: ICCSAH SAC.

Figura 66: Ensayo de Relación de Soporte de California CBR (Muestra C-2).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
 NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO : TRABAJO DE INVESTIGACION **CALICATA:** C-02
PROVINCIA: HUANCAYO **MUESTRA :** M-1
DEPARTAMENTO: JUNIN **PROFUNDIDAD :** 1.00-1.50m
CLIENTE: BACH. MEDALITH MANRIQUE DAVILA

DATOS DE LA MUESTRA

COMPACTACIÓN

	5	6	7
Molde N°	5	6	7
Capas N°	5	5	5
Golpes por capa N°	10	25	56
Condición de la muestra	SATURADO	NO SATURADO	SATURADO
Peso de molde + Suelo húmedo (g)	11971	11882	12294
Peso de molde + base (g)	7922	7740	7828
Peso del suelo húmedo (g)	4049	4142	4466
Volumen del molde (cm ³)	2124	2124	2124
Densidad húmeda (g/cm ³)	1.907	1.951	2.103
Tara (N°)	T5	T6	T7
Peso suelo húmedo + tara (g)	428.5	526.2	389.1
Peso suelo seco + tara (g)	388.2	473.8	361.1
Peso de tara (g)	105.4	106.8	164.7
Peso de agua (g)	40.3	52.4	28.0
Peso de suelo seco (g)	282.8	367.0	196.4
Contenido de humedad (%)	14.25	14.28	14.26
Densidad seca (g/cm ³)	1.669	1.707	1.841


PENETRACION

PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE N° 10 G				MOLDE N° 25 G				MOLDE N° 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0			0					0		
0.635			13			40					99		
1.270			33			104					256		
1.905			52			161					398		
2.540	70.5		72	71.8	5.3	224	224.4	16.5			554	554.1	40.6
3.810			111			345					852		
5.080	105.7		143	142.7	7.0	446	445.9	21.8			1101	1101.1	53.8
6.350			171			535					1321		
7.620			189			590					1456		
10.160			214			667					1648		
12.700			226			708					1747		

Observaciones: _____

Fuente: ICCSAH SAC.


Figura 67: Ensayo de Relación de Soporte de California CBR (Muestra C-2).



Fuente: ICCSAH SAC.

- ANEXO 2.3: Certificados de ensayos de laboratorio de la calicata C-3

Figura 68: Ensayo de contenido de humedad (Muestra C-3).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-03
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T1	T2	T3
PESO TARA + SUELO HUMEDO gr.	1106.90	768.40	937.65
PESO TARA + SUELO SECO gr.	1056.60	733.70	896.65
PESO DE LA TARA gr.	69.80	74.20	72.00
PESO DEL AGUA gr.	50.30	34.70	41.00
PESO SUELO SECO gr.	986.80	659.50	824.65
HUMEDAD %	5.10	5.26	4.97
HUMEDAD NATURAL PROMEDIO %	5.11		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 69: Ensayo de límites de consistencia (Muestra C-3).




Fuente: ICCSAH SAC.

Figura 70: Ensayo de granulometría por tamizado (Muestra C-3).




Fuente: ICCSAH SAC.

Figura 71: Ensayo de Proctor Modificado (Muestra C-3).



Fuente: ICCSAH SAC.

Figura 72: Ensayo de Relación de Soporte de California CBR (Muestra C-3).



ICCSAH SAC
INGENIERIA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRAULICA SAC.

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-03
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		

DATOS DE LA MUESTRA

COMPACTACIÓN

	5	6	7
Molde Nº	5	6	7
Capas Nº	5	5	5
Golpes por capa Nº	10	25	56

Condición de la muestra	SATURADO	NO SATURADO	SATURADO	NO SATURADO	SATURADO	NOSATURADO
Peso de molde + Suelo húmedo (g)	12052		12038		12424	
Peso de molde + base (g)	7922		7740		7828	
Peso del suelo húmedo (g)	4130		4298		4596	
Volumen del molde (cm ³)	2124		2124		2124	
Densidad húmeda (g/cm ³)	1.945		2.024		2.164	
Tara (Nº)	T5		T6		T7	
Peso suelo húmedo + tara (g)	140.0		321.4		402.5	
Peso suelo seco + tara (g)	136.4		299.3		378.0	
Peso de tara (g)	105.4		106.8		164.7	
Peso de agua (g)	3.6		22.2		24.5	
Peso de suelo seco (g)	31.0		192.5		213.3	
Contenido de humedad (%)	11.54		11.51		11.50	
Densidad seca (g/cm ³)	1.744		1.815		1.941	


PENETRACION

PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE Nº 10 G				MOLDE Nº 25 G				MOLDE Nº 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0			0					0		
0.635			39			44					129		
1.270			48			82					266		
1.905			57			125					400		
2.540	70.5		61	60.6	4.4	170	170.3	12.5			540	539.7	39.6
3.810			73			249					853		
5.080	105.7		91	91.2	4.5	301	301.2	14.7			1147	1146.6	56.0
6.350			98			346					1391		
7.620			103			382					1587		
10.160			112			450					1881		
12.700			121			500					2028		

Observaciones: _____

Fuente: ICCSAH SAC.


Figura 73: Ensayo de Relación de Soporte de California CBR (Muestra C-3).



Fuente: ICCSAH SAC.

- ANEXO 2.4: Certificados de ensayos de laboratorio de la calicata C-4

Figura 74: Ensayo de contenido de humedad (Muestra C-4).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-04
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T1	T2	T3
PESO TARA + SUELO HUMEDO gr.	790.10	869.00	540.50
PESO TARA + SUELO SECO gr.	712.10	775.00	490.60
PESO DE LA TARA gr.	130.30	84.20	120.40
PESO DEL AGUA gr.	78.00	94.00	49.90
PESO SUELO SECO gr.	581.80	690.80	370.20
HUMEDAD %	13.41	13.61	13.48
HUMEDAD NATURAL PROMEDIO %	13.50		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 75: Ensayo de límites de consistencia (Muestra C-4).




Fuente: ICCSAH SAC.

Figura 76: Ensayo de granulometría por tamizado (Muestra C-4).




Fuente: ICCSAH SAC.

Figura 77: Ensayo de Proctor Modificado (Muestra C-4).



Fuente: ICCSAH SAC.

Figura 78: Ensayo de Relación de Soporte de California CBR (Muestra C-4).



ICCSAH SAC
INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA SAC

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-04
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		

DATOS DE LA MUESTRA

COMPACTACIÓN

	5	6	7
Molde Nº	5	6	7
Capas Nº	5	5	5
Golpes por capa Nº	10	25	56

Condición de la muestra	SATURADO	NO SATURADO	SATURADO	NO SATURADO	SATURADO	NOSATURADO
Peso de molde + Suelo húmedo (g)	11674		11725		12091	
Peso de molde + base (g)	7922		7740		7828	
Peso del suelo húmedo (g)	3752		3985		4263	
Volumen del molde (cm ³)	2124		2124		2124	
Densidad húmeda (g/cm ³)	1.767		1.877		2.008	
Tara (Nº)	T5		T6		T7	
Peso suelo húmedo + tara (g)	140.0		220.6		208.9	
Peso suelo seco + tara (g)	136.5		208.9		204.4	
Peso de tara (g)	105.4		106.8		164.7	
Peso de agua (g)	3.6		11.7		4.5	
Peso de suelo seco (g)	31.1		102.1		39.7	
Contenido de humedad (%)	11.43		11.46		11.45	
Densidad seca (g/cm ³)	1.586		1.684		1.801	


PENETRACION

PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE Nº 10 G				MOLDE Nº 25 G				MOLDE Nº 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0			0					0		
0.635			47			52					56		
1.270			58			98					117		
1.905			68			149					176		
2.540	70.5		72	72.1	5.3	203	202.6	14.9			237	237.0	17.4
3.810			87			297					375		
5.080	105.7		109	108.6	5.3	358	358.4	17.5			503	503.5	24.6
6.350			117			412					611		
7.620			122			455					697		
10.160			133			536					826		
12.700			144			595					890		

Observaciones: _____

Fuente: ICCSAH SAC.


Figura 79: Ensayo de Relación de Soporte de California CBR (Muestra C-4).



Fuente: ICCSAH SAC.

- ANEXO 2.5: Certificados de ensayos de laboratorio de la calicata C-5

Figura 80: Ensayo de contenido de humedad (Muestra C-5).



INGENIERIA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRAULICA SAC.

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO : TRABAJO DE INVESTIGACION	CALICATA: C-05
PROVINCIA: HUANCAYO	MUESTRA : M-1
DEPARTAMENTO: JUNIN	PROFUNDIDAD : 1.00-1.50m
CLIENTE: BACH. MEDALITH MANRIQUE DAVILA	


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T94	T72	T83
PESO TARA + SUELO HUMEDO gr.	751.90	977.10	847.50
PESO TARA + SUELO SECO gr.	698.20	905.90	786.10
PESO DE LA TARA gr.	65.90	68.60	65.90
PESO DEL AGUA gr.	53.70	71.20	61.40
PESO SUELO SECO gr.	632.30	837.30	720.20
HUMEDAD %	8.49	8.50	8.53
HUMEDAD NATURAL PROMEDIO %	8.51		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 81: Ensayo de límites de consistencia (Muestra C-5).




Fuente: ICCSAH SAC.

Figura 82: Ensayo de granulometría por tamizado (Muestra C-5).




Fuente: ICCSAH SAC.

Figura 83: Ensayo de Proctor Modificado (Muestra C-5).




Fuente: ICCSAH SAC.

Figura 84: Ensayo de Relación de Soporte de California CBR (Muestra C-5).

 INGENIERIA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRAULICA S.A.C.													
LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS													
RELACIÓN SOPORTE DE CALIFORNIA (C.B.R) NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193													
CONCEPTO :	TRABAJO DE INVESTIGACION				CALICATA:	C-05							
PROVINCIA:	HUANCAYO				MUESTRA :	M-1							
DEPARTAMENTO:	JUNIN				PROFUNDIDAD :	1.00-1.50m							
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA												
DATOS DE LA MUESTRA													
COMPACTACIÓN													
Molde N°	5				6				7				
Capas N°	5				5				5				
Golpes por capa N°	10				25				56				
Condición de la muestra	SATURADO		NO SATURADO		SATURADO		NO SATURADO		SATURADO		NOSATURADO		
Peso de molde + Suelo húmedo (g)	11695				11716				11911				
Peso de molde + base (g)	7922				7740				7828				
Peso del suelo húmedo (g)	3773				3976				4083				
Volumen del molde (cm ³)	2124				2124				2124				
Densidad húmeda (g/cm ³)	1.777				1.872				1.923				
Tara (N°)	T5				T6				T7				
Peso suelo húmedo + tara (g)	140.0				220.6				208.9				
Peso suelo seco + tara (g)	135.5				205.7				203.1				
Peso de tara (g)	105.4				106.8				164.7				
Peso de agua (g)	4.5				14.9				5.8				
Peso de suelo seco (g)	30.1				98.9				38.4				
Contenido de humedad (%)	15.10				15.07				15.08				
Densidad seca (g/cm ³)	1.544				1.627				1.671				
PENETRACION													
PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE N° 10 G				MOLDE N° 25 G				MOLDE N° 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0				0				0		
0.635			23				25				28		
1.270			28				48				57		
1.905			33				73				86		
2.540	70.5		35	35.1	2.6		99	98.8	7.2		116	115.5	8.5
3.810			43				145				183		
5.080	105.7		53	52.9	2.6		175	174.7	8.5		245	245.4	12.0
6.350			57				201				298		
7.620			59				222				340		
10.160			65				261				403		
12.700			70				290				434		
Observaciones: _____													

Fuente: ICCSAH SAC.


Figura 85: Ensayo de Relación de Soporte de California CBR (Muestra C-5).



Fuente: ICCSAH SAC.

- ANEXO 2.6: Certificados de ensayos de laboratorio de la calicata C-6

Figura 86: Ensayo de contenido de humedad (Muestra C-6).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-06
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T461	T151	T154
PESO TARA + SUELO HUMEDO gr.	1442.40	1234.30	1050.50
PESO TARA + SUELO SECO gr.	1346.90	1134.10	977.40
PESO DE LA TARA gr.	391.40	133.20	250.40
PESO DEL AGUA gr.	95.50	100.20	73.10
PESO SUELO SECO gr.	955.50	1000.90	727.00
HUMEDAD %	9.99	10.01	10.06
HUMEDAD NATURAL PROMEDIO %	10.02		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 87: Ensayo de límites de consistencia (Muestra C-6).




Fuente: ICCSAH SAC.

Figura 88: Ensayo de granulometría por tamizado (Muestra C-6).



Fuente: ICCSAH SAC.

Figura 89: Ensayo de Proctor Modificado (Muestra C-6).



ICCSAH SAC
INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA SAC

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

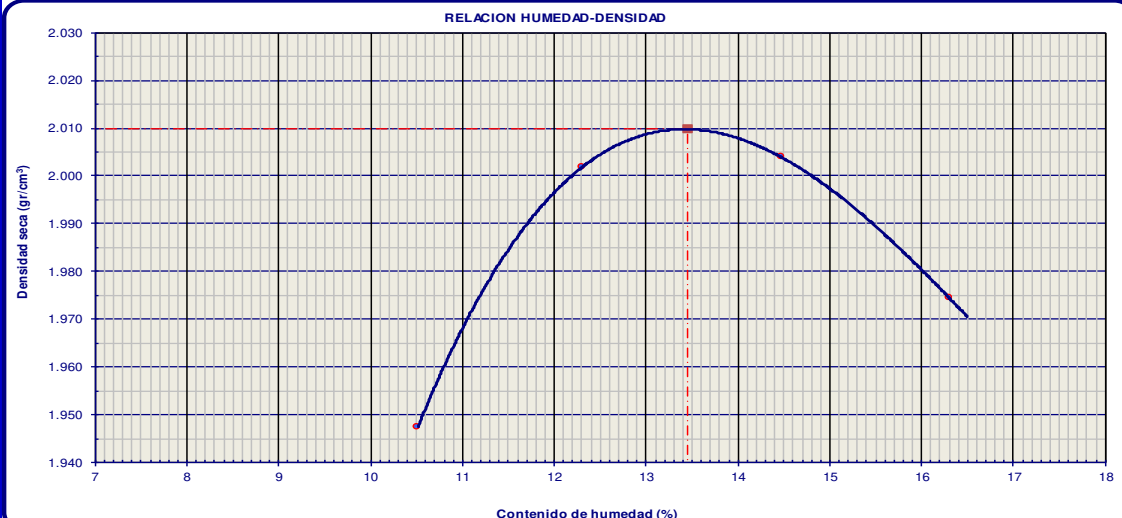
PROCTOR MODIFICADO
NORMAS TÉCNICAS: MTC E 115, ASTM D 1557, AASHTO T 180

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-06
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		

DATOS DE LA MUESTRA

Ensayo N°	1	2	3	4	
Número de Capas	5	5	5	5	
Golpes de Pisón por Capa	56	56	56	56	
Peso suelo húmedo + molde	gr. 7384	7587	7684	7689	
Peso molde + base	gr. 2830	2830	2830	2830	
Peso suelo húmedo compactado	gr. 4554	4757	4854	4859	
Volumen del molde	cm ³ 2116	2116	2116	2116	
Peso volumétrico húmedo	gr/cm ³ 2.152	2.248	2.294	2.296	
Recipiente N°	T9	T10	T5	T1	
Peso del suelo húmedo+tara	gr. 312.5	221.5	209.7	235.4	
Peso del suelo seco + tara	gr. 289.2	203.5	190.0	212.4	
Peso de Tara	gr. 67.6	57.2	53.9	71.3	
Peso de agua	gr. 23.3	18.0	19.7	23.0	
Peso del suelo seco	gr. 221.6	146.3	136.1	141.1	
Contenido de agua	% 10.5	12.3	14.5	16.3	
Peso volumétrico seco	gr/cm ³ 1.947	2.002	2.004	1.974	
				Densidad máxima (gr/cm ³)	2.010
				Humedad óptima (%)	13.45

RELACION HUMEDAD-DENSIDAD



Densidad seca (gr/cm³)


Contenido de humedad (%)

Observaciones:

- Metodo C


Fuente: ICCSAH SAC.

Figura 90: Ensayo de Relación de Soporte de California CBR (Muestra C-6).

 LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS													
RELACIÓN SOPORTE DE CALIFORNIA (C.B.R) NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193													
CONCEPTO : TRABAJO DE INVESTIGACION				CALICATA: C-06									
PROVINCIA: HUANCAYO				MUESTRA : M-1									
DEPARTAMENTO: JUNIN				PROFUNDIDAD : 1.00-1.50m									
CLIENTE: BACH. MEDALITH MANRIQUE DAVILA													
DATOS DE LA MUESTRA													
COMPACTACIÓN													
Molde N°	5			6			7						
Capas N°	5			5			5						
Golpes por capa N°	10			25			56						
Condición de la muestra	SATURADO			NO SATURADO			SATURADO			NOSATURADO			
Peso de molde + Suelo húmedo (g)	12270						12399			12672			
Peso de molde + base (g)	7922						7740			7828			
Peso del suelo húmedo (g)	4348						4659			4844			
Volumen del molde (cm ³)	2124						2124			2124			
Densidad húmeda (g/cm ³)	2.048						2.194			2.281			
Tara (N°)	T-5						T-6			T-7			
Peso suelo húmedo + tara (g)	158.6						237.3			209.2			
Peso suelo seco + tara (g)	147.5						217.2			192.4			
Peso de tara (g)	64.5						67.6			67.6			
Peso de agua (g)	11.2						20.1			16.8			
Peso de suelo seco (g)	83.0						149.6			124.8			
Contenido de humedad (%)	13.44						13.47			13.46			
Densidad seca (g/cm ³)	1.805						1.934			2.010			
PENETRACION													
PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE N° 10 G				MOLDE N° 25 G				MOLDE N° 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0				0				0		
0.635			133				148				160		
1.270			163				277				330		
1.905			193				422				498		
2.540	70.5		195	195.0	14.3		574	573.8	42.1		671	671.2	49.2
3.810			248				840				1061		
5.080	105.7		328	328.4	16.1		1015	1015.1	49.6		1426	1425.9	69.7
6.350			335				1167				1730		
7.620			350				1289				1974		
10.160			382				1517				2339		
12.700			406				1685				2521		
Observaciones: _____ _____													

Fuente: ICCSAH SAC.

Figura 91: Ensayo de Relación de Soporte de California CBR (Muestra C-6).



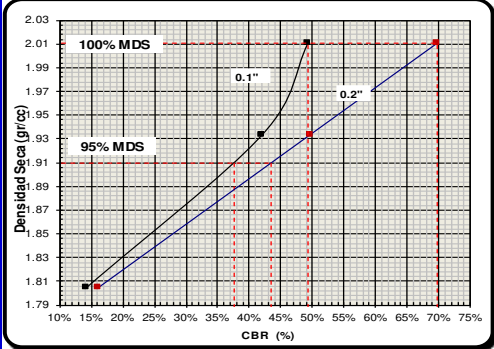
INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA S.A.C.

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

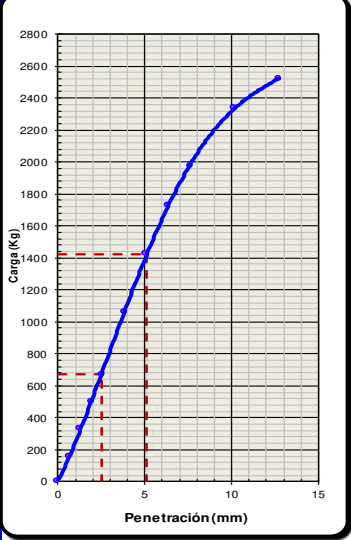
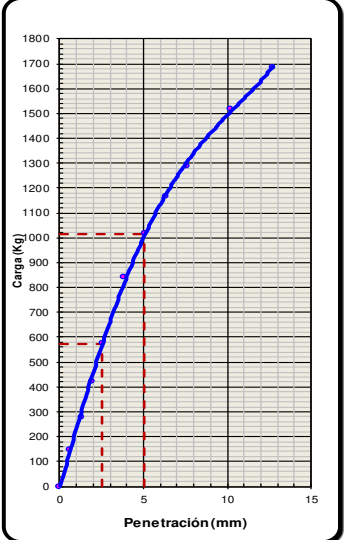
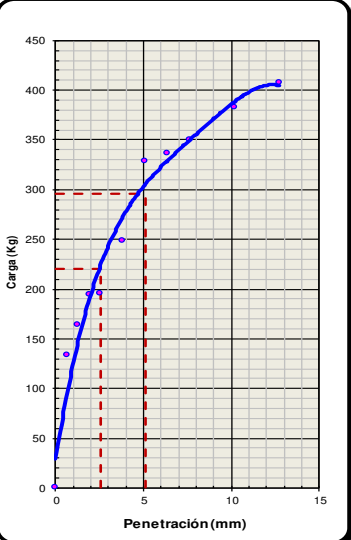
RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
 NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-06
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DA VILA		

DATOS DE LA MUESTRA

<div style="text-align: center; border-bottom: 1px solid black; margin-bottom: 5px;"> DETERMINACIÓN DEL CBR </div> 	<div style="text-align: center; border-bottom: 1px solid black; margin-bottom: 5px;"> DATOS DEL PRÓCTOR MODIFICADO </div> <table style="width: 100%; border-collapse: collapse;"> <tr> <td>PROCTOR MODIFICADO :</td> <td></td> </tr> <tr> <td>MAXIMA DENSIDAD SECA (g/cm³) :</td> <td style="text-align: right;">2.010</td> </tr> <tr> <td>OPTIMO CONTENIDO DE HUMEDAD (%) :</td> <td style="text-align: right;">13.45</td> </tr> <tr> <td>95% MAXIMA DENSIDAD SECA (g/cm³) :</td> <td style="text-align: right;">1.910</td> </tr> </table> <div style="text-align: center; border-bottom: 1px solid black; margin-top: 10px;"> PORCENTAJE DEL CBR </div> <table style="width: 100%; border-collapse: collapse; border: 1px solid black;"> <tr> <td style="border: none;">C.B.R. al 100% de M.D.S.</td> <td style="border: none;">0.1":</td> <td style="border: none;">49.22</td> <td style="border: none;">0.2"</td> <td style="border: none;">69.70</td> </tr> <tr> <td style="border: none;">C.B.R. al 95% de M.D.S.</td> <td style="border: none;">0.1":</td> <td style="border: none;">37.60</td> <td style="border: none;">0.2"</td> <td style="border: none;">43.40</td> </tr> </table> <p style="margin-top: 10px;">OBSERV.: _____</p> <p>_____</p> <p>_____</p>	PROCTOR MODIFICADO :		MAXIMA DENSIDAD SECA (g/cm ³) :	2.010	OPTIMO CONTENIDO DE HUMEDAD (%) :	13.45	95% MAXIMA DENSIDAD SECA (g/cm ³) :	1.910	C.B.R. al 100% de M.D.S.	0.1":	49.22	0.2"	69.70	C.B.R. al 95% de M.D.S.	0.1":	37.60	0.2"	43.40
PROCTOR MODIFICADO :																			
MAXIMA DENSIDAD SECA (g/cm ³) :	2.010																		
OPTIMO CONTENIDO DE HUMEDAD (%) :	13.45																		
95% MAXIMA DENSIDAD SECA (g/cm ³) :	1.910																		
C.B.R. al 100% de M.D.S.	0.1":	49.22	0.2"	69.70															
C.B.R. al 95% de M.D.S.	0.1":	37.60	0.2"	43.40															

EC = 56 GOLPES	EC = 25 GOLPES	EC = 10 GOLPES
-----------------------	-----------------------	-----------------------


 <table style="width: 100%; border-collapse: collapse; border: 1px solid black; margin-top: 5px;"> <tr> <td style="border: none;">CBR (0.1")</td> <td style="border: none; text-align: right;">49.22%</td> </tr> <tr> <td style="border: none;">CBR (0.2")</td> <td style="border: none; text-align: right;">69.70%</td> </tr> </table>	CBR (0.1")	49.22%	CBR (0.2")	69.70%	 <table style="width: 100%; border-collapse: collapse; border: 1px solid black; margin-top: 5px;"> <tr> <td style="border: none;">CBR (0.1")</td> <td style="border: none; text-align: right;">42.08%</td> </tr> <tr> <td style="border: none;">CBR (0.2")</td> <td style="border: none; text-align: right;">49.62%</td> </tr> </table>	CBR (0.1")	42.08%	CBR (0.2")	49.62%	 <table style="width: 100%; border-collapse: collapse; border: 1px solid black; margin-top: 5px;"> <tr> <td style="border: none;">CBR (0.1")</td> <td style="border: none; text-align: right;">14.30%</td> </tr> <tr> <td style="border: none;">CBR (0.2")</td> <td style="border: none; text-align: right;">16.05%</td> </tr> </table>	CBR (0.1")	14.30%	CBR (0.2")	16.05%
CBR (0.1")	49.22%													
CBR (0.2")	69.70%													
CBR (0.1")	42.08%													
CBR (0.2")	49.62%													
CBR (0.1")	14.30%													
CBR (0.2")	16.05%													

Observaciones: _____

Fuente: ICCSAH SAC.

- ANEXO 2.7: Certificados de ensayos de laboratorio de la calicata C-7

Figura 92: Ensayo de contenido de humedad (Muestra C-7).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-07
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T239	T2	T10
PESO TARA + SUELO HUMEDO gr.	896.60	1022.60	947.40
PESO TARA + SUELO SECO gr.	796.20	907.50	843.90
PESO DE LA TARA gr.	108.40	129.80	140.60
PESO DEL AGUA gr.	100.40	115.10	103.50
PESO SUELO SECO gr.	687.80	777.70	703.30
HUMEDAD %	14.60	14.80	14.72
HUMEDAD NATURAL PROMEDIO %	14.70		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 93: Ensayo de límites de consistencia (Muestra C-7).




Fuente: ICCSAH SAC.

Figura 94: Ensayo de granulometría por tamizado (Muestra C-7).




Fuente: ICCSAH SAC.

Figura 95: Ensayo de Proctor Modificado (Muestra C-7).



Fuente: ICCSAH SAC.

Figura 96: Ensayo de Relación de Soporte de California CBR (Muestra C-7).



ICCSAH SAC
INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA SAC.

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-07
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		

DATOS DE LA MUESTRA

COMPACTACIÓN

	5	6	7
Molde N°	5	6	7
Capas N°	5	5	5
Golpes por capa N°	10	25	56

Condición de la muestra	SATURADO	NO SATURADO	SATURADO	NO SATURADO	SATURADO	NOSATURADO
Peso de molde + Suelo húmedo (g)	11710		11785		11915	
Peso de molde + base (g)	7922		7740		7828	
Peso del suelo húmedo (g)	3788		4045		4087	
Volumen del molde (cm ³)	2124		2124		2124	
Densidad húmeda (g/cm ³)	1.784		1.905		1.925	
Tara (N°)	T-5		T-6		T-7	
Peso suelo húmedo + tara (g)	182.9		193.2		197.6	
Peso suelo seco + tara (g)	168.5		177.9		181.8	
Peso de tara (g)	64.5		67.6		67.6	
Peso de agua (g)	14.4		15.3		15.8	
Peso de suelo seco (g)	104.0		110.3		114.2	
Contenido de humedad (%)	13.81		13.85		13.83	
Densidad seca (g/cm ³)	1.567		1.673		1.691	


PENETRACION

PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE N° 10 G				MOLDE N° 25 G				MOLDE N° 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0			0					0		
0.635			45			50					54		
1.270			55			94					112		
1.905			65			143					168		
2.540	70.5		69	69.0	5.1	194	194.1	14.2			227	227.1	16.7
3.810			84			284					359		
5.080	105.7		104	104.0	5.1	343	343.4	16.8			482	482.3	23.6
6.350			112			395					585		
7.620			117			436					668		
10.160			127			513					791		
12.700			137			570					853		

Observaciones: _____

Fuente: ICCSAH SAC.


Figura 97: Ensayo de Relación de Soporte de California CBR (Muestra C-7).



Fuente: ICCSAH SAC.

- ANEXO 2.8: Certificados de ensayos de laboratorio de la calicata C-8

Figura 98: Ensayo de contenido de humedad (Muestra C-8).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-08
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50 m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T356	T170	T104
PESO TARA + SUELO HUMEDO gr.	690.80	738.10	594.30
PESO TARA + SUELO SECO gr.	614.60	663.10	531.30
PESO DE LA TARA gr.	74.20	138.90	87.50
PESO DEL AGUA gr.	76.20	75.00	63.00
PESO SUELO SECO gr.	540.40	524.20	443.80
HUMEDAD %	14.10	14.31	14.20
HUMEDAD NATURAL PROMEDIO %	14.20		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 99: Ensayo de límites de consistencia (Muestra C-8).




Fuente: ICCSAH SAC.

Figura 100: Ensayo de granulometría por tamizado (Muestra C-8).




Fuente: ICCSAH SAC.

Figura 101: Ensayo de Proctor Modificado (Muestra C-8).




Fuente: ICCSAH SAC.

Figura 102: Ensayo de Relación de Soporte de California CBR (Muestra C-8).

 INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA SAC													
LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS													
RELACIÓN SOPORTE DE CALIFORNIA (C.B.R) NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193													
CONCEPTO :		TRABAJO DE INVESTIGACION				CALICATA:		C-08					
PROVINCIA:		HUANCAYO				MUESTRA :		M-1					
DEPARTAMENTO:		JUNIN				PROFUNDIDAD :		1.00-1.50m					
CLIENTE:		BACH. MEDALITH MANRIQUE DAVILA											
DATOS DE LA MUESTRA													
COMPACTACIÓN													
Molde N°	5			6			7						
Capas N°	5			5			5						
Golpes por capa N°	10			25			56						
Condición de la muestra	SATURADO		NO SATURADO		SATURADO		NO SATURADO		SATURADO		NOSATURADO		
Peso de molde + Suelo húmedo (g)	12105				10998				12145				
Peso de molde + base (g)	8642				7297				8327				
Peso del suelo húmedo (g)	3463				3701				3818				
Volumen del molde (cm ³)	2124				2124				2124				
Densidad húmeda (g/cm ³)	1.631				1.743				1.798				
Tara (N°)	TL5				T6				T7				
Peso suelo húmedo + tara (g)	140.0				220.6				208.9				
Peso suelo seco + tara (g)	125.4				199.6				189.5				
Peso de tara (g)	34.0				67.6				67.6				
Peso de agua (g)	14.6				21.0				19.4				
Peso de suelo seco (g)	91.4				132.0				121.9				
Contenido de humedad (%)	15.97				15.93				15.95				
Densidad seca (g/cm ³)	1.406				1.503				1.551				
PENETRACION													
PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE N° 10 G				MOLDE N° 25 G				MOLDE N° 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0				0				0		
0.635			22				25				27		
1.270			27				46				55		
1.905			32				71				83		
2.540	70.5		34	34.2	2.5		96	96.2	7.1		113	112.5	8.3
3.810			42				141				178		
5.080	105.7		52	51.5	2.5		170	170.2	8.3		239	239.1	11.7
6.350			55				196				290		
7.620			58				216				331		
10.160			63				254				392		
12.700			68				282				423		
Observaciones:													

Fuente: ICCSAH SAC.

Figura 103: Ensayo de Relación de Soporte de California CBR (Muestra C-8).

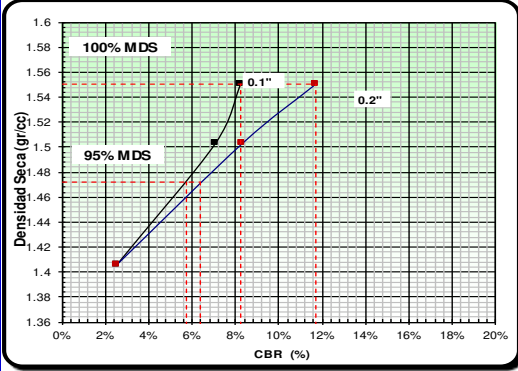


LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

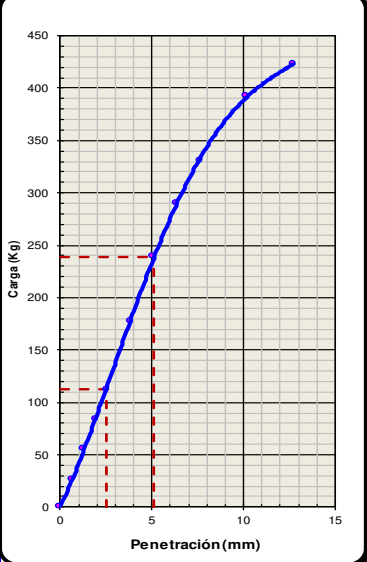
RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
 NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

<p>CONCEPTO : TRABAJO DE INVESTIGACION</p> <p>PROVINCIA: HUANCAYO</p> <p>DEPARTAMENTO: JUNIN</p> <p>CLIENTE: BACH. MEDALITH MANRIQUE DAVILA</p>	<p>CALICATA: C-08</p> <p>MUESTRA : M-1</p> <p>PROFUNDIDAD : 1.00-1.50 m</p>	
---	--	--

DATOS DE LA MUESTRA

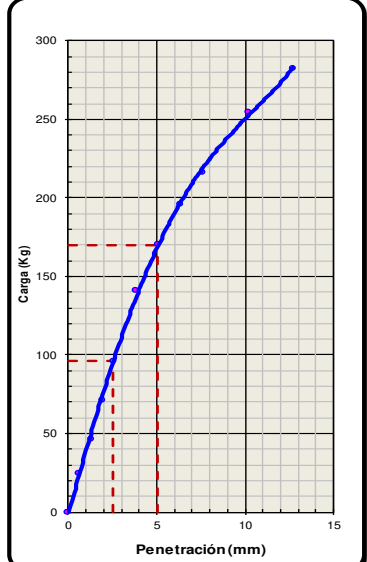
DETERMINACIÓN DEL CBR		DATOS DEL PRÓCTOR MODIFICADO	
		PROCTOR MODIFICADO :	
		MAXIMA DENSIDAD SECA (g/cm ³) :	1.550
		OPTIMO CONTENIDO DE HUMEDAD (%) :	15.94
		95% MAXIMA DENSIDAD SECA (g/cm ³) :	1.473
PORCENTAJE DEL CBR			
C.B.R. al 100% de M.D.S.	0.1":	8.25	0.2" 11.68
C.B.R. al 95% de M.D.S.	0.1":	5.71	0.2" 6.40
<p>OBSERV.: _____</p> <p>_____</p> <p>_____</p> <p>_____</p>			

EC = 56 GOLPES



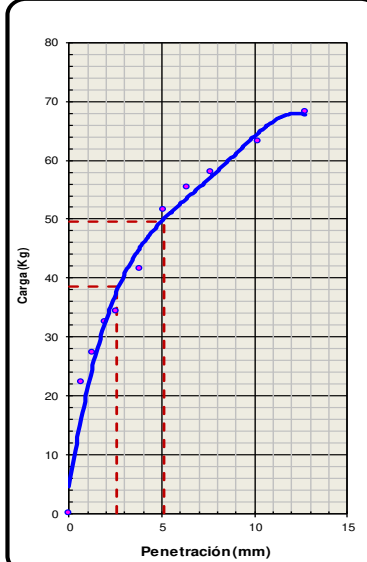
CBR (0.1")	8.25%
CBR (0.2")	11.68%

EC = 25 GOLPES



CBR (0.1")	7.05%
CBR (0.2")	8.32%

EC = 10 GOLPES




CBR (0.1")	2.51%
CBR (0.2")	2.52%

Observaciones: _____

Fuente: ICCSAH SAC.

- ANEXO 2.9: Certificados de ensayos de laboratorio de la calicata C-9

Figura 104: Ensayo de contenido de humedad (Muestra C-9).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-09
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50 m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T35	T140	T19
PESO TARA + SUELO HUMEDO gr.	805.30	1435.00	970.50
PESO TARA + SUELO SECO gr.	595.20	1061.80	725.50
PESO DE LA TARA gr.	70.00	132.70	110.30
PESO DEL AGUA gr.	210.10	373.20	245.00
PESO SUELO SECO gr.	525.20	929.10	615.20
HUMEDAD %	40.00	40.17	39.82
HUMEDAD NATURAL PROMEDIO %	40.00		

Observaciones: _____

Fuente: ICCSAH SAC.

Figura 105: Ensayo de límites de consistencia (Muestra C-9).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

LÍMITES DE CONSISTENCIA
 NORMAS TÉCNICAS: MTC E 110 - MTC E 111, ASTM D 4318, AASHTO T 89 - T 90

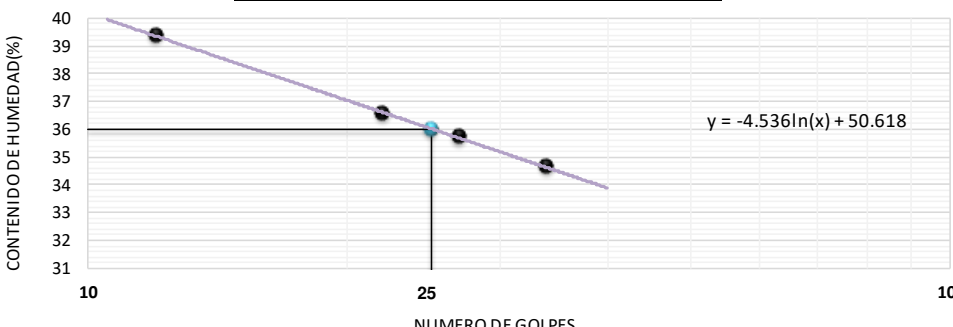
CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-09
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50 m
CLIENTE:	BACH. MEDALITH MANRIQUE DA VILA		

DATOS DE LA MUESTRA

LIMITE LIQUIDO (MTC E 110, AASHTO T 89)					
Nº TARA		T214	T187	T97	T307
PESO TARA + SUELO HUMEDO (gr.)		37.52	30.24	37.02	33.08
PESO TARA + SUELO SECO (gr.)		31.66	26.47	32.23	28.25
PESO DE AGUA (gr.)		5.86	3.77	4.79	4.83
PESO DE LA TARA (gr.)		16.77	16.16	18.81	14.30
PESO DEL SUELO SECO (gr.)		14.89	10.31	13.42	13.95
CONTENIDO DE HUMEDAD (%)		39.36	36.57	35.69	34.62
NUMERO DE GOLPES		12	22	27	34

LIMITE PLÁSTICO (MTC E 111, AASHTO T 90)					
Nº TARA		T56	T16	T25	Promedio
PESO TARA + SUELO HUMEDO (gr.)		30.27	28.64	32.40	
PESO TARA + SUELO SECO (gr.)		27.49	25.88	29.60	
PESO DE LA TARA (gr.)		16.08	14.67	18.17	
PESO DEL AGUA (gr.)		2.78	2.76	2.80	
PESO DEL SUELO SECO (gr.)		11.41	11.21	11.43	
CONTENIDO DE HUMEDAD (%)		24.36	24.62	24.50	24.49

CONTENIDO DE HUMEDAD A 25 GOLPES




LÍMITES DE CONSISTENCIA	
LIMITE LIQUIDO (%)	36.02
LIMITE PLÁSTICO (%)	24.49
INDICE DE PLASTICIDAD (%)	11.52

OBSERVACIONES:


Fuente: ICCSAH SAC.

Figura 106: Ensayo de granulometría por tamizado (Muestra C-9).




Fuente: ICCSAH SAC.

Figura 107: Ensayo de Proctor Modificado (Muestra C-9).



Fuente: ICCSAH SAC.

Figura 108: Ensayo de Relación de Soporte de California CBR (Muestra C-9).



ICCSAH SAC
INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA SAC

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-09
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50 m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		

DATOS DE LA MUESTRA

COMPACTACIÓN

Molde N°	5		6		7	
Capas N°	5		5		5	
Golpes por capa N°	10		25		56	
Condición de la muestra	SATURADO	NO SATURADO	SATURADO	NO SATURADO	SATURADO	NOSATURADO
Peso de molde + Suelo húmedo (g)	11938		12058		12225	
Peso de molde + base (g)	7922		7740		7828	
Peso del suelo húmedo (g)	4016		4318		4397	
Volumen del molde (cm ³)	2124		2124		2124	
Densidad húmeda (g/cm ³)	1.891		2.033		2.071	
Tara (N°)	T5		T6		T7	
Peso suelo húmedo + tara (g)	140.0		220.6		208.9	
Peso suelo seco + tara (g)	129.8		199.9		189.8	
Peso de tara (g)	64.5		67.6		67.6	
Peso de agua (g)	10.2		20.7		19.1	
Peso de suelo seco (g)	65.3		132.3		122.2	
Contenido de humedad (%)	15.67		15.65		15.63	
Densidad seca (g/cm ³)	1.635		1.758		1.791	


PENETRACION

PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE N° 10 G				MOLDE N° 25 G				MOLDE N° 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0			0					0		
0.635			30			44					48		
1.270			49			83					99		
1.905			58			126					149		
2.540	70.5		60	60.2	4.4	172	172.0	12.6			201	201.2	14.8
3.810			74			252					318		
5.080	105.7		104	104.0	5.1	304	304.2	14.9			427	427.3	20.9
6.350			107			350					519		
7.620			113			386					591		
10.160			122			455					701		
12.700			130			505					756		

Observaciones: _____

Fuente: ICCSAH SAC.


Figura 109: Ensayo de Relación de Soporte de California CBR (Muestra C-9).



Fuente: ICCSAH SAC.

- ANEXO 2.10: Certificados de ensayos de laboratorio de la calicata C-10

Figura 110: Ensayo de contenido de humedad (Muestra C-10).



LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

DETERMINACIÓN DE HUMEDAD NATURAL
 NORMAS TÉCNICAS: MTC E 108, ASTM D 2216

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-10
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50 m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		


DATOS DE LA MUESTRA

ENSAYO N°	1	2	3
Nro. DE TARA	T470	T449	T341
PESO TARA + SUELO HUMEDO gr.	1306.80	1318.50	1247.80
PESO TARA + SUELO SECO gr.	1185.20	1192.50	1135.40
PESO DE LA TARA gr.	400.40	379.40	410.50
PESO DEL AGUA gr.	121.60	126.00	112.40
PESO SUELO SECO gr.	784.80	813.10	724.90
HUMEDAD %	15.49	15.50	15.51
HUMEDAD NATURAL PROMEDIO %	15.50		

Observaciones: _____


Fuente: ICCSAH SAC.

Figura 111: Ensayo de límites de consistencia (Muestra C-10).




Fuente: ICCSAH SAC.

Figura 112: Ensayo de granulometría por tamizado (Muestra C-10).




Fuente: ICCSAH SAC.

Figura 113: Ensayo de Proctor Modificado (Muestra C-10).



Fuente: ICCSAH SAC.

Figura 114: Ensayo de Relación de Soporte de California CBR (Muestra C-10).



INGENIERÍA DE CALIDAD EN CONCRETO, SUELOS ASFALTO E HIDRÁULICA S.A.C.

LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
 NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO : TRABAJO DE INVESTIGACION **CALICATA:** C-10
PROVINCIA: HUANCAYO **MUESTRA :** M-1
DEPARTAMENTO: JUNIN **PROFUNDIDAD :** 1.00-1.50 m
CLIENTE: BACH. MEDALITH MANRIQUE DAVILA

DATOS DE LA MUESTRA

COMPACTACIÓN

Molde Nº	5	6	7
Capas Nº	5	5	5
Golpes por capa Nº	10	25	56

Condición de la muestra	SATURADO	NO SATURADO	SATURADO	NO SATURADO	SATURADO	NOSATURADO
Peso de molde + Suelo húmedo (g)	12635		11417		12744	
Peso de molde + base (g)	8642		7297		8327	
Peso del suelo húmedo (g)	3993		4120		4417	
Volumen del molde (cm ³)	2124		2124		2124	
Densidad húmeda (g/cm ³)	1.880		1.940		2.080	
Tara (Nº)	T5		T6		T7	
Peso suelo húmedo + tara (g)	140.0		220.6		208.9	
Peso suelo seco + tara (g)	130.3		200.9		190.7	
Peso de tara (g)	64.5		67.6		67.6	
Peso de agua (g)	9.8		19.7		18.2	
Peso de suelo seco (g)	65.8		133.3		123.1	
Contenido de humedad (%)	14.83		14.81		14.80	
Densidad seca (g/cm ³)	1.638		1.690		1.812	


PENETRACION

PENETRACION mm	CARGA STAND. kg/cm ²	MOLDE Nº 10 G				MOLDE Nº 25 G				MOLDE Nº 56 G			
		CARGA		CORRECCION		CARGA		CORRECCION		CARGA		CORRECCION	
		Dial (div)	kg	kg	%	Dial (div)	kg	kg	%	Dial (div)	kg	kg	%
0.000			0			0					0		
0.635			20			39					64		
1.270			43			81					134		
1.905			65			122					201		
2.540	70.5		89	89.4	6.6	169	168.7	12.4			280	279.5	20.5
3.810			133			250					410		
5.080	105.7		178	178.0	8.7	336	336.0	16.4			551	550.9	26.9
6.350			215			405					665		
7.620			249			470					770		
10.160			293			553					906		
12.700			318			600					984		

Observaciones: _____

Fuente: ICCSAH SAC.

Figura 115: Ensayo de Relación de Soporte de California CBR (Muestra C-10).

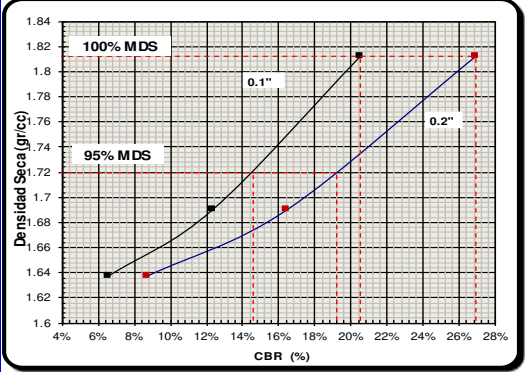


LABORATORIO DE MECÁNICA DE SUELOS Y PAVIMENTOS

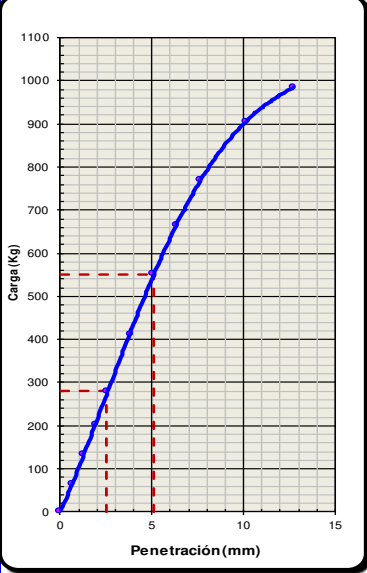
RELACIÓN SOPORTE DE CALIFORNIA (C.B.R)
 NORMAS TÉCNICAS: MTC E 132, ASTM D 1883, AASHTO T 193

CONCEPTO :	TRABAJO DE INVESTIGACION	CALICATA:	C-10
PROVINCIA:	HUANCAYO	MUESTRA :	M-1
DEPARTAMENTO:	JUNIN	PROFUNDIDAD :	1.00-1.50 m
CLIENTE:	BACH. MEDALITH MANRIQUE DAVILA		

DATOS DE LA MUESTRA

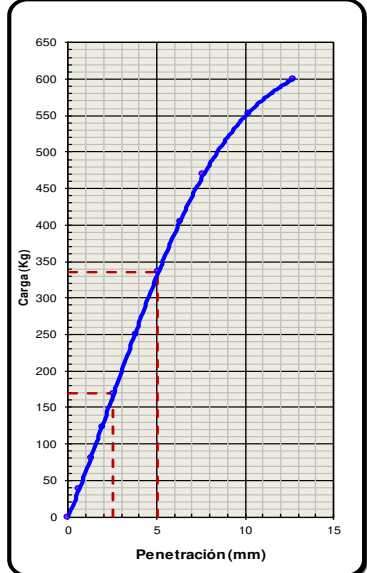
DETERMINACIÓN DEL CBR	DATOS DEL PRÓCTOR MODIFICADO																				
	<table style="width: 100%; border-collapse: collapse;"> <tr> <td>PROCTOR MODIFICADO :</td> <td></td> </tr> <tr> <td>MAXIMA DENSIDAD SECA (g/cm³) :</td> <td style="text-align: right;">1.810</td> </tr> <tr> <td>OPTIMO CONTENIDO DE HUMEDAD (%) :</td> <td style="text-align: right;">14.80</td> </tr> <tr> <td>95% MAXIMA DENSIDAD SECA (g/cm³) :</td> <td style="text-align: right;">1.720</td> </tr> </table> <table style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th colspan="4" style="text-align: center; border: 1px solid black;">PORCENTAJE DEL CBR</th> </tr> </thead> <tbody> <tr> <td style="border: 1px solid black;">C.B.R. al 100% de M.D.S.</td> <td style="border: 1px solid black;">0.1":</td> <td style="border: 1px solid black;">20.50</td> <td style="border: 1px solid black;">0.2" 26.93</td> </tr> <tr> <td style="border: 1px solid black;">C.B.R. al 95% de M.D.S.</td> <td style="border: 1px solid black;">0.1":</td> <td style="border: 1px solid black;">14.60</td> <td style="border: 1px solid black;">0.2" 19.20</td> </tr> </tbody> </table> <p><i>OBSERV.:</i> _____ _____ _____</p>	PROCTOR MODIFICADO :		MAXIMA DENSIDAD SECA (g/cm ³) :	1.810	OPTIMO CONTENIDO DE HUMEDAD (%) :	14.80	95% MAXIMA DENSIDAD SECA (g/cm ³) :	1.720	PORCENTAJE DEL CBR				C.B.R. al 100% de M.D.S.	0.1":	20.50	0.2" 26.93	C.B.R. al 95% de M.D.S.	0.1":	14.60	0.2" 19.20
PROCTOR MODIFICADO :																					
MAXIMA DENSIDAD SECA (g/cm ³) :	1.810																				
OPTIMO CONTENIDO DE HUMEDAD (%) :	14.80																				
95% MAXIMA DENSIDAD SECA (g/cm ³) :	1.720																				
PORCENTAJE DEL CBR																					
C.B.R. al 100% de M.D.S.	0.1":	20.50	0.2" 26.93																		
C.B.R. al 95% de M.D.S.	0.1":	14.60	0.2" 19.20																		

EC = 56 GOLPES



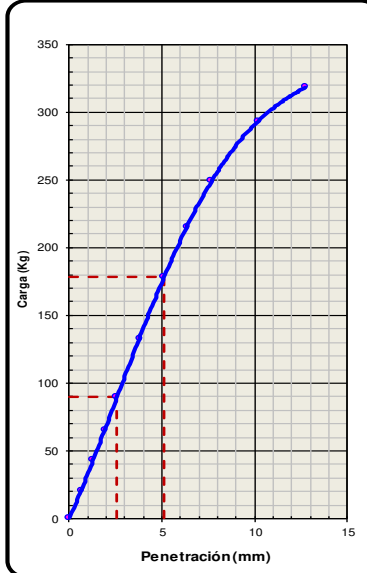
CBR (0.1")	20.50%
CBR (0.2")	26.93%

EC = 25 GOLPES



CBR (0.1")	12.37%
CBR (0.2")	16.42%

EC = 10 GOLPES



CBR (0.1")	6.56%
CBR (0.2")	8.70%

Observaciones: _____

Fuente: ICCSAH SAC.

ANEXO 3: APLICACIÓN PARA PREDECIR LAS PROPIEDADES MECÁNICAS DE SUELOS

- ANEXO 3.1: APLICACIÓN PARA PREDECIR EL CBR AL 100% DE LA MDS DE SUELOS

Figura 116: Aplicación de la Red Neuronal Artificial desarrollada.

RED NEURONAL ARTIFICIAL PARA PREDECIR EL CBR AL 100% DE LA MAXIMA DENSIDAD SECA DEL SUELO						
DATOS DE ENTRADA						DATO DE SALIDA - CBR al 100% de la MDS
ANALISIS GRANULOMETRICO			LIMITES DE CONSISTENCIA			Informe de predicción: "Red entrenada en CBR 100%"
% GRAVA	% ARENA	% FINOS	L. LIQUIDO	L. PLASTICO	I.P.	Predicción
46.47	22.2	31.33	43.23	32.5	10.73	45.15
28.9	39.4	31.7	37.84	32.1	5.74	25.48
21.8	48.8	29.4	24.83	21.7	3.13	25.13
0	55.6	44.4	31.84	18.88	12.96	15.67
10.1	35.3	54.6	31.8	20.98	10.82	13.58
39.6	33.7	26.7	37.02	18.41	18.6	44.86
0	46.5	53.5	43.03	31.92	11.11	13.20
6.6	30	63.4	36.23	21.75	14.47	10.30
0	18.6	81.4	36.02	24.43	11.52	5.33
34.36	12.7	52.94	27.66	18.63	8.97	34.41

Fuente: Elaboración Propia.

- ANEXO 3.2: APLICACIÓN PARA PREDECIR EL CBR AL 95% DE LA MDS DE SUELOS

Figura 117: Aplicación de la Red Neuronal Artificial desarrollada.

RED NEURONAL ARTIFICIAL PARA PREDECIR EL CBR AL 95% DE LA MAXIMA DENSIDAD SECA DEL SUELO						
DATOS DE ENTRADA						DATO DE SALIDA - CBR al 95% de la MDS
ANALISIS GRANULOMETRICO			LIMITES DE CONSISTENCIA			Informe de predicción: "Red entrenada en CBR 95"
% GRAVA	% ARENA	% FINOS	L. LIQUIDO	L. PLASTICO	I.P.	Predicción
46.47	22.2	31.33	43.23	32.5	10.73	31.44
28.9	39.4	31.7	37.84	32.1	5.74	16.79
21.8	48.8	29.4	24.83	21.7	3.13	16.60
0	55.6	44.4	31.84	18.88	12.96	14.29
10.1	35.3	54.6	31.8	20.98	10.82	4.52
39.6	33.7	26.7	37.02	18.41	18.6	35.30
0	46.5	53.5	43.03	31.92	11.11	4.52
6.6	30	63.4	36.23	21.75	14.47	4.52
0	18.6	81.4	36.02	24.43	11.52	4.52
34.36	12.7	52.94	27.66	18.63	8.97	25.65

Fuente: Elaboración Propia.

- ANEXO 3.3: APLICACIÓN PARA PREDECIR EL ÓPTIMO CONTENIDO DE HUMEDAD DE SUELOS

Figura 118: Aplicación de la Red Neuronal Artificial desarrollada.

RED NEURONAL ARTIFICIAL PARA PREDECIR EL OPTIMO CONTENIDO DE HUMEDAD DEL SUELO						
DATOS DE ENTRADA						DATO DE SALIDA - OCH (%)
ANALISIS GRANULOMETRICO			LIMITES DE CONSISTENCIA			Informe de predicción: "Red entrenada en OCH"
% GRAVA	% ARENA	% FINOS	L. LIQUIDO	L. PLASTICO	I.P.	Predicción
46.47	22.2	31.33	43.23	32.5	10.73	12.04
28.9	39.4	31.7	37.84	32.1	5.74	14.72
21.8	48.8	29.4	24.83	21.7	3.13	10.54
0	55.6	44.4	31.84	18.88	12.96	11.36
10.1	35.3	54.6	31.8	20.98	10.82	15.04
39.6	33.7	26.7	37.02	18.41	18.6	14.23
0	46.5	53.5	43.03	31.92	11.11	15.54
6.6	30	63.4	36.23	21.75	14.47	16.65
0	18.6	81.4	36.02	24.49	11.52	16.46
34.36	12.7	52.94	27.66	18.69	8.97	13.60

Fuente: Elaboración Propia.

- ANEXO 3.4: APLICACIÓN PARA PREDECIR LA MÁXIMA DENSIDAD SECA DE SUELOS


Figura 119: Aplicación de la Red Neuronal Artificial desarrollada.

RED NEURONAL ARTIFICIAL PARA PREDECIR LA MAXIMA DENSIDAD SECA DEL SUELO						
DATOS DE ENTRADA						DATO DE SALIDA - MDS (gr/cm3)
ANALISIS GRANULOMETRICO			LIMITES DE CONSISTENCIA			Informe de predicción: "Red entrenada en MDS"
% GRAVA	% ARENA	% FINOS	L. LIQUIDO	L. PLASTICO	I.P.	Predicción
46.47	22.2	31.33	43.23	32.5	10.73	2.04
28.9	39.4	31.7	37.84	32.1	5.74	1.87
21.8	48.8	29.4	24.83	21.7	3.13	1.88
0	55.6	44.4	31.84	18.88	12.96	1.75
10.1	35.3	54.6	31.8	20.98	10.82	1.64
39.6	33.7	26.7	37.02	18.41	18.6	2.09
0	46.5	53.5	43.03	31.92	11.11	1.62
6.6	30	63.4	36.23	21.75	14.47	1.54
0	18.6	81.4	36.02	24.49	11.52	1.72
34.36	12.7	52.94	27.66	18.69	8.97	1.86

Fuente: Elaboración Propia.

ANEXO 4: ESTUDIOS DEFINITIVOS DE INGENIERÍA USADOS EN LA INVESTIGACIÓN

1. Estudio definitivo de ingeniería para la rehabilitación y mejoramiento de la carretera Patahuasi – Yauri – Sicuani, tramo: Negromayo – Yauri – San Genaro



- El estudio definitivo de ingeniería, fue realizada y presentada por la empresa ROUGHTON INTERNATIONAL LIMITED SUCURSAL DEL PERU con RUC: 20514543594.

2. Estudio definitivo para la rehabilitación y mejoramiento de la carretera: Chongoyape –Cochabamba – Cajamarca, tramo: Cochabamba – Chota



- El estudio definitivo de ingeniería, fue realizada y presentada por la empresa HOB CONSULTORES S.A. con RUC: 20101345018.

3. Estudio definitivo para la rehabilitación y mejoramiento de la carretera Ayacucho – Abancay, tramo: Km 50+000 – Km 98+800



- El estudio definitivo de ingeniería, fue realizada y presentada por la empresa CONSORCIO CENTRO II (Molima Consultores SA – Eli Cordova Vilela Ing. Consultor) con RUC: 20518414501.

4. Estudio definitivo del proyecto de rehabilitación y mejoramiento de la carretera (Pu 135) Checca – Mazocruz

GOBIERNO REGIONAL PUNO
Honesto y productivo...

CONTRATO DE SERVICIO DE CONSULTORIA
N°017-2013-CP-GRP

**ESTUDIO DEFINITIVO
PARA EL MEJORAMIENTO
DE LA CARRETERA**

COMPONENTE DE INGENIERIA

PU 135 CHECCA-NAZOCRUZ
PROVINCIA DEL COLLAO- PUNO

INFORME FINAL

**VOLUMEN N°1
MEMORIA
DESCRIPTIVA Y
ESTUDIOS BÁSICOS**

ANEXO C

**SUELOS, CANTERAS,
BOTADEROS Y FUENTES
DE AGUA**

31 JUL 2017

TOMO 1/12


JULIO 2016

CONSULTOR
CONSORCIO COLLAO 63

63 INGENIERIA **AZIZE INGENIERIA**

- El estudio definitivo de ingeniería, fue realizada y presentada por la empresa CONSORCIO COLLAO 63 (Proyectos de Ingeniería 63 y AZIZE Ingenieros SAC) con RUC: 20555204371.

5. Estudio de Factibilidad y definitivo para el mejoramiento de la carretera Oyón – Ambo. Sector I: Oyón – Desvío Cerro de Pasco



- El estudio definitivo de ingeniería, fue realizada y presentada por la empresa CONSORCIO CESEL – SIGT (Cesel SA y SIGT SA Ingenieros Consultores) con RUC: 20548265241.

ANEXO 5: CARTAS DE PERMISO DE USO DE INFORMACIÓN DE LOS PROYECTOS

Lima, 22 de octubre de 2019

Señores:

Bach. Medalith Manrique Dávila

Asunto: Autorizo uso de información.

Yo, **Ing. Hugo Cuzcano Vera**, con **DNI N° 07195933**, representante legal Latinoamérica de la empresa **ROUGHTON INTERNATIONAL LIMITED SUCURSAL DEL PERÚ** con **RUC: 20514543594**, domiciliado en: **calle 31 N° 135 Urb. Corpac Lima, Perú**, ante ud. expongo lo siguiente:

Que, habiendo recibido la carta de su persona pidiendo la autorización de información y la base de datos del proyecto "**ESTUDIO DEFINITIVO DE INGENIERÍA PARA LA PARA LA REHABILITACIÓN Y MEJORAMIENTO DE LA CARRETERA: PATAHUASI-YAURI-SICUANI. TRAMO NEGROMAYO-YAURI-SAN GENARO**" publicado en la web <http://gls.proviasnac.gob.pe>, le autorizo utilizar dicha información, para la realización de su tesis de pregrado titulado "**PREDICCIÓN DE PROPIEDADES MECÁNICAS DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES**".

Atentamente,



Ing. Hugo Cuzcano Vera

CIP N° 8832

DNI N° 07195933

ANEXO 6: MATRIZ DE CONSISTENCIA

MATRIZ DE CONSISTENCIA

PEDICCIÓN DE PROPIEDADES MECÁNICAS DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES

PROBLEMA	OBJETIVOS	HIPÓTESIS	VARIABLES	DIMENSIONES	INDICADORES	METODOLOGÍA
<p>PROBLEMA GENERAL</p> <p>¿Se pueden predecir los resultados de los ensayos relacionados a propiedades mecánicas de los suelos usando modelos de predicción basado en redes neuronales artificiales?</p> <p>PROBLEMAS ESPECÍFICOS</p> <p>¿Qué información se debe recopilar para formar una base de datos para desarrollar una estructura de una Red Neuronal Artificial y el algoritmo que pueda predecir las propiedades mecánicas de los suelos?</p> <p>¿Cómo se puede diseñar la topología de una Red Neuronal Artificial y estimar los pesos utilizando para cada criterio evaluado y poder predecir las propiedades mecánicas del suelo?</p> <p>¿Se puede evaluar y comparar el rendimiento del modelo propuesto con datos reales, para determinar el nivel de precisión del modelo neuronal de predicción de las propiedades mecánicas de los suelos?</p>	<p>OBJETIVO GENERAL</p> <p>Desarrollar un modelo para la predicción de las propiedades mecánicas de los suelos, utilizando una Red Neuronal Artificial.</p> <p>OBJETIVOS ESPECÍFICOS</p> <p>Recolectar una base de datos y desarrollar la estructura de una Red Neuronal Artificial y el algoritmo que pueda predecir las propiedades mecánicas de los suelos.</p> <p>Diseñar la topología de una Red Neuronal Artificial y estimar los pesos utilizando para cada criterio evaluado y poder predecir las propiedades mecánicas del suelo.</p> <p>Evaluar y comparar el rendimiento del modelo propuesto con datos reales, para determinar el nivel de precisión del modelo neuronal de predicción de las propiedades mecánicas de los suelos.</p>	<p>HIPÓTESIS GENERAL</p> <p>Es posible desarrollar modelos de predicción basados en redes neuronales artificiales, para la determinación de las propiedades mecánicas de los suelos.</p> <p>HIPÓTESIS ESPECÍFICAS</p> <p>Existe información para formar una base de datos que nos permite desarrollar una estructura de una Red Neuronal Artificial y el algoritmo de predicción de las propiedades mecánicas de los suelos.</p> <p>Se puede diseñar la topología de una Red Neuronal Artificial y estimar los pesos utilizando para cada criterio evaluado y poder predecir las propiedades mecánicas del suelo.</p> <p>Se puede evaluar y comparar el rendimiento del modelo propuesto con datos reales, para determinar el nivel de precisión del modelo neuronal de predicción de las propiedades mecánicas de los suelos.</p>	<p>VARIABLES INDEPENDIENTES</p> <p>X1: Sistema experto basado en redes neuronales</p> <p>VARIABLE DEPENDIENTE</p> <p>Y1: Propiedades mecánicas del suelo</p>	<ul style="list-style-type: none"> Base de datos (granulometría-límites-% retenidas) Topología de la RNA (evaluar con data por separada y determinar el coeficiente de correlación R) Rendimiento de la RNA (comparar predicción vs real de laboratorio) Capacidad de soporte CBR al 100% Capacidad de soporte CBR al 95% Máxima densidad seca – Optimo contenido de humedad 	<ul style="list-style-type: none"> Límites de consistencia (Exp. Provias Nacional) Granulometría (Exp. Provias Nacional) Tipo de suelo (Exp. Provias Nacional) Factor de correlación para CBR 100% Factor de correlación para CBR 95% Factor de correlación para MDS Y OCH Factor de correlación para CBR 100% Factor de correlación para CBR 95% Factor de correlación para MDS Y OCH Ensayo de compactación Ensayo de penetración Ensayo de expansión Ensayo de compactación Ensayo de penetración Ensayo de expansión Ensayo de Compactación Ensayo de Contenido de humedad 	<p>MÉTODO: Científico</p> <p>TIPO DE INVEST.: Aplicada.</p> <p>NIVEL: Explicativo</p> <p>DISEÑO DE INVEST.</p> <p>Cuasi experimental</p> <p>POBLACIÓN:</p> <p>Tipos de suelo de sistema SUCS</p> <p>MUESTRA/MUESTREO</p> <p>10 muestras de suelo. / No probabilístico e intencional</p> <p>INSTRUMENTOS DE RECOLECCIÓN DE DATOS</p> <p>Formatos Excel de ensayos de suelos. Formatos de recopilación de base de datos.</p> <p>INSTRUMENTOS DE MEDICIÓN</p> <p>Tamices estandarizados Horno eléctrico Copa de Casagrande Molde de Proctor Molde de CBR</p>