

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE
HUAMANGA**

FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y CIVIL

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



TESIS

**Eficacia en la predicción de los parámetros de resistencia al corte a
partir del comportamiento físico en suelos granulares empleando
redes neuronales artificiales - experimental, Perú 2023.**

Para optar el título profesional de:

INGENIERO CIVIL

PRESENTADO POR:

Bach. Jhon Paul HUACCACHI PUMALLIHUA

ASESOR:

Msc. Ing. Ángel Hugo, VILCHEZ PEÑA

AYACUCHO - PERÚ

2024

DEDICATORIA

A la memoria de Alissa Cabana Huaccachi (familiar). Su recuerdo es una fuente constante de inspiración y fortaleza en mi vida académica y personal. Aunque ahora no está físicamente presente, su legado vive en los recuerdos de todos de los que conocimos. Este trabajo es un humilde tributo a su memoria y al impacto profundo e imperecedero que ha tenido en mi vida y a la de sus padres (tíos del investigador) y hermanos (primos del investigador).

AGRADECIMIENTO

Para mis padres, que siempre me han dado apoyo y han sacrificado tanto por mí. Este trabajo es una forma de mostrarles cuánto los agradezco.

A todos mis maestros y a quienes me han guiado, especialmente al Ing. Ms. Hugo Vílchez Peña, gracias por mostrarme el camino con tanta paciencia y por compartir su sabiduría.

RESUMEN

Para este estudio se entrenó, validó y probó un modelo neuronal que predice parámetros de resistencia al corte efectivos (ϕ' y c') en suelos granulares (no cohesivos), para la etapa de entrenamiento y validación se utilizaron 1105 datos secundarios recolectados de investigaciones universitarias (tesis peruanas), y para probar el modelo se usaron 39 datos primarios obtenidos de ensayos de corte directo (ASTM-3080) realizados en laboratorio de suelos. El modelo mostró en la etapa de prueba, entre valores predichos y valores observados un R-cuadrado de 0.86 para el ángulo de fricción efectiva interna y 0.77 para la cohesión efectiva, y con errores inferiores a los umbrales aceptables de 5%. Se concluyó que el modelo neuronal predice o estima eficazmente estos parámetros de corte a partir de la distribución granulométrica, límite de consistencia, densidad seca y contenido de humedad de un suelo granular.

Además, se analizó la importancia relativa de diferentes factores físicos del suelo, como la distribución granulométrica, los límites de consistencia, la densidad seca y contenido de humedad, en el modelo neuronal desarrollado sobre la predicción de la resistencia al corte, se encontró que la distribución granulométrica es la más influyente para el ángulo de fricción y la cohesión (especialmente de porcentaje de partículas finas) y, siendo el contenido de humedad el menos influyente, los métodos análisis de sensibilidad y de gradiente de entrada son las que se usaron para determinar la importancia relativa de las características de entrada frente a la salida del modelo neuronal. Estos análisis proporciona una perspectiva sobre cómo las características físicas del suelo afectan la resistencia al corte y, por ende, la estabilidad de las estructuras soportadas por estos tipos de suelos.

El estudio excluyó suelos arcillosos y consolidados debido a sus características adicionales necesarias para el modelado, sugiriendo la creación de modelos específicos para estos suelos en futuras investigaciones.

ABSTRAC

For this study, a neural model that predicts effective shear strength parameters (ϕ' and c') in granular (non-cohesive) soils was trained, validated and tested. For the training and validation stage, 1105 secondary data collected from university research (Peruvian theses) were used, and to test the model, 39 primary data obtained from direct shear tests (ASTM-3080) carried out in a soil laboratory were used. The model showed in the test stage, between predicted values and observed values, an R-square of 0.86 for the internal effective friction angle and 0.77 for effective cohesion, and with errors below the acceptable thresholds of 5%. It is concluded that the neural model effectively predicts or estimates these shear parameters from the particle size distribution, consistency limit, dry density and moisture content of a granular soil.

Furthermore, the relative importance of different soil physical factors such as particle size distribution, consistency limits, dry density and moisture content in the developed neural model on shear strength prediction was analyzed. It was found that particle size distribution is the most influential for friction angle and cohesion (especially for percentage of fine particles) and moisture content being the least influential. Sensitivity analysis and input gradient methods were used to determine the relative importance of input versus output characteristics of the neural model. These analyses provide insight into how soil physical characteristics affect shear strength and hence the stability of structures supported by these soil types.

The study excluded clayey and consolidated soils due to their additional characteristics needed for modeling, suggesting the creation of specific models for these soils in future research.

CONTENIDO

1. PLANTEAMIENTO DEL PROBLEMA.....	1
1.1. DESCRIPCIÓN DEL PROBLEMA.	1
1.2. DELIMITACIÓN DEL PROBLEMA.	2
1.2.1. Espacial (geográfica)	2
1.2.2. Temporal.....	2
1.2.3. Unidad de estudio.	2
1.2.4. Temática	2
1.3. FORMULACIÓN DEL PROBLEMA.	3
1.3.1. Problema general.	3
1.3.2. Problemas específicos	3
1.4. JUSTIFICACIÓN DEL ESTUDIO	4
1.5. IMPORTANCIA DEL ESTUDIO	4
1.6. LIMITACIONES DE LA INVESTIGACIÓN.	4
1.7. OBJETIVOS.	5
1.7.1. Objetivo general.....	5
1.7.2. Objetivos específicos.	5
2. MARCO TEÓRICO.....	6
2.1. ANTECEDENTES.....	6
2.1.1. Investigaciones internacionales.....	6
2.1.2. Investigaciones nacionales.	9
2.2. BASES TEÓRICAS.....	13
2.3.1. Tipos de suelos.....	13
2.3.2. Sistemas de clasificación de suelos	17
2.3.3. Comportamiento físico de los suelos	18
2.3.4. Resistencia al corte de un suelo	31
2.3.5. Ensayo de corte directo	38
2.3.6. Inteligencia artificial	40
2.3. MARCO CONCEPTUAL.	49
2.3.7. Suelo granular	49
2.3.8. Comportamiento físico del suelo.	50
2.3.9. Parámetros de resistencia al corte.	51
3. MATERIAL Y MÉTODOS DE INVESTIGACIÓN.....	52
3.1. MÉTODO	52
3.2. ORIENTACIÓN DE INVESTIGACIÓN.	52
3.3. ENFOQUE.....	52
3.4. NIVEL DE INVESTIGACIÓN.	52
3.5. TIPO DE INVESTIGACIÓN	53
3.6. DISEÑO DE INVESTIGACIÓN.....	53
3.7. POBLACIÓN, MUESTRA Y UNIDAD DE ESTUDIO.	53
3.7.1. Población	53
3.7.2. Muestreo	54
3.7.3. Muestra.	54
3.7.4. Unidad de estudio	54
3.8. HIPÓTESIS.....	55

3.8.1.	Hipótesis general.....	55
3.8.2.	Hipótesis específicas.	55
3.9.	OPERACIONALIZACIÓN DE VARIABLE	56
3.10.	TÉCNICAS E INSTRUMENTO DE RECOLECCIÓN DE DATOS.	57
3.11.	TÉCNICAS DE PRE-PROCESAMIENTO DE DATOS.....	57
3.12.	TÉCNICAS ESTADÍSTICAS PARA EL PROCESAMIENTO DE INFORMACION.	58
3.13.	DESARROLLO DE LA TESIS.....	60
3.13.1.	Recolección de datos.....	60
3.13.2.	Pre procesamiento de datos.....	60
3.13.3.	Entrenamiento y validación de la red neuronal	69
4.	RESULTADOS Y DISCUSIÓN.....	72
4.1.	RESULTADOS	72
4.1.1.	Rendimiento del modelo (entrenamiento y validación).....	72
4.1.2.	Resultados de ensayos-experimentales.	75
4.1.3.	Resultados de análisis de influencia.....	77
4.2.	DISCUSIÓN, INTERPRETACIÓN Y CONTRASTACIÓN DE HIPÓTESIS.....	80
4.3.1.	Discusión y Estrategia para contrastación de hipótesis general	80
4.3.2.	Discusión y Estrategia para contrastación de hipótesis específicos	86
5.	CONCLUSIONES	90
6.	RECOMENDACIONES.....	92
7.	Bibliografía	94
ANEXO		98

LISTA DE CUADROS

Cuadro N° 1.	<i>Different ANN models and their statistical performances</i>	6
Cuadro N° 2.	<i>Importancia relativa de diferentes entradas del modelo neuronal</i>	7
Cuadro N° 3.	<i>Estadística, descripción básica</i>	7
Cuadro N° 4.	<i>Matriz de correlación entre parámetros</i>	8
Cuadro N° 5.	<i>Evaluación estadística en RMSE.</i>	8
Cuadro N° 6.	<i>Validada conjunto de datos</i>	9
Cuadro N° 7.	<i>Resultados de correlación.</i>	12
Cuadro N° 8.	<i>Información recopilado del SEACE</i>	12
Cuadro N° 9.	<i>Entradas y salidas utilizadas.</i>	13
Cuadro N° 10.	<i>Clasificación por tamaño de partículas</i>	14
Cuadro N° 11.	<i>Resumen de factores que afectan a $\emptyset$</i>	18
Cuadro N° 12.	<i>U.S standard sieve sizes (ASTM 2010)</i>	20
Cuadro N° 13.	<i>Gradación de grava y arena</i>	21
Cuadro N° 14.	<i>Valores ϕ representativos según el tipo de suelo normalmente consolidado.</i>	22
Cuadro N° 15.	<i>Resumen de ángulo de fricción por clasificación de suelo.</i>	22
Cuadro N° 16.	<i>Influencia de granulometría y angulosidad sobre ángulo de fricción máximo</i>	22
Cuadro N° 17.	<i>Hidraulic conductivity</i>	22
Cuadro N° 18.	<i>Contenido de humedad típica.</i>	26
Cuadro N° 19.	<i>Relación contenido de humedad y los tipos de suelo</i>	27
Cuadro N° 20.	<i>Grado de saturación de la arena</i>	28
Cuadro N° 21.	<i>Densidades tipicos, suelos saturados.</i>	29
Cuadro N° 22.	<i>Compacidad máxima y mínima de suelos granulares</i>	30
Cuadro N° 23.	<i>Valores típicos de ángulo de fricción drenado para arenas y limos.</i>	31
Cuadro N° 24.	<i>Influencia de granulometría y angulosidad sobre ángulo de fricción máximo</i>	31
Cuadro N° 25.	<i>Criterios de falla</i>	34
Cuadro N° 26.	<i>Cohesión en suelos arcillosos</i>	36
Cuadro N° 27.	<i>Clasificación SUCS considerados suelos granulares.</i>	50
Cuadro N° 28.	<i>Tipo de muestra</i>	54
Cuadro N° 29.	<i>Resumen de la recolección de datos</i>	60
Cuadro N° 30.	<i>Resumen final de limpieza de datos</i>	61
Cuadro N° 31.	<i>Reducción de datos</i>	61
Cuadro N° 32.	<i>Visualización de data- resumida</i>	62
Cuadro N° 33.	<i>Medidas de tendencia central</i>	63
Cuadro N° 34.	<i>Medidas de dispersión</i>	64
Cuadro N° 35.	<i>Condición de asimetría por cada indicador</i>	65
Cuadro N° 36.	<i>División de datos</i>	68
Cuadro N° 37.	<i>Reporte de métricas de error en entrenamiento y validación para $(\phi'$ y $c')$</i>	72
Cuadro N° 38.	<i>Reporte de métricas de error en entrenamiento para $(\phi'$ y $c')$</i>	73
Cuadro N° 39.	<i>Reporte de métricas de error en entrenamiento para $(\phi'$ y $c')$</i>	74

Cuadro N° 40.	<i>Muestra de suelos granulares para la prueba del modelo predictivo.</i>	<i>75</i>
Cuadro N° 41.	<i>Comparación de los resultados.....</i>	<i>76</i>
Cuadro N° 42.	<i>Rango de niveles de confiabilidad de un modelo predictivo</i>	<i>81</i>
Cuadro N° 43.	<i>Categorías de la eficacia.</i>	<i>82</i>
Cuadro N° 44.	<i>Reporte de prueba estadístico F (ϕ' y c').</i>	<i>84</i>
Cuadro N° 45.	<i>Métricas de error etapa de prueba.</i>	<i>85</i>
Cuadro N° 46.	<i>Valores de coeficiente de determinación y métricas de error.....</i>	<i>85</i>
Cuadro N° 47.	<i>Resultado de importancia relativa de acuerdo al análisis de gradiente de entrada.</i>	<i>86</i>
Cuadro N° 48.	<i>Resultado de importancia relativa de acuerdo al análisis de sensibilidad de entrada</i>	<i>86</i>

LISTA DE FIGURAS

<i>Figura 1.</i>	<i>Resistencia sobre consolidad y normalmente consolidadas.....</i>	<i>17</i>
<i>Figura 2.</i>	<i>Curva de la distribución granulométrica obtenida en un análisis con mallas.....</i>	<i>19</i>
<i>Figura 3.</i>	<i>Distribución granulométrica mediante tamices.</i>	<i>19</i>
<i>Figura 4.</i>	<i>Distribución granulométrica.....</i>	<i>21</i>
<i>Figura 5.</i>	<i>Cambios de estado en funcion a volumen y contenido de agua de un suelo.....</i>	<i>23</i>
<i>Figura 6.</i>	<i>Copa de Casagrande LL y rodillos para LP.</i>	<i>24</i>
<i>Figura 7.</i>	<i>Correlacion IP y angulo de friccion.</i>	<i>24</i>
<i>Figura 8.</i>	<i>Correlacion entre índice plasticp Ip y Ø.....</i>	<i>25</i>
<i>Figura 9.</i>	<i>Correlacion entre índice plasticp Ip y senØ.</i>	<i>25</i>
<i>Figura 10.</i>	<i>Cono de arena.</i>	<i>30</i>
<i>Figura 11.</i>	<i>Esfuerzo cortante vs esfuerzo normal efectivo y totales.....</i>	<i>33</i>
<i>Figura 12.</i>	<i>Deformacion vs esfuerzo cortante.</i>	<i>34</i>
<i>Figura 13.</i>	<i>Envolvente de falla de Mohr y criterio de rotura de Mohr-Coulomb.....</i>	<i>35</i>
<i>Figura 14.</i>	<i>Equipo de corte directo</i>	<i>38</i>
<i>Figura 15.</i>	<i>Criterio de falla de Mohr-Coulomb de una prueba de corte directo</i>	<i>38</i>
<i>Figura 16.</i>	<i>Esquema de rango de los IA.</i>	<i>41</i>
<i>Figura 17.</i>	<i>Machine learning.</i>	<i>41</i>
<i>Figura 18.</i>	<i>Modelo SLP.....</i>	<i>44</i>
<i>Figura 19.</i>	<i>Modelo MLP.....</i>	<i>44</i>
<i>Figura 20.</i>	<i>Modelo RNC.....</i>	<i>45</i>
<i>Figura 21.</i>	<i>Modelo RNR.....</i>	<i>45</i>
<i>Figura 22.</i>	<i>Modelo RCP.</i>	<i>45</i>
<i>Figura 23.</i>	<i>Estructura simple de una red neuronal.....</i>	<i>46</i>
<i>Figura 24.</i>	<i>Esquema de red neuronal y red neuronal de aprendizaje profundo.</i>	<i>47</i>
<i>Figura 25.</i>	<i>Diferentes funciones de activación.....</i>	<i>48</i>
<i>Figura 26.</i>	<i>Vizualizacion del conjunto de datos por cada indicador.....</i>	<i>63</i>
<i>Figura 27.</i>	<i>Histogramas por cada indicador.....</i>	<i>64</i>
<i>Figura 28.</i>	<i>Distribución de datos de cada indicador frente a otros.....</i>	<i>66</i>
<i>Figura 29.</i>	<i>Gradiente de color de la correlación Pearson entre indicadores.....</i>	<i>67</i>
<i>Figura 30.</i>	<i>Transformación logarítmica.....</i>	<i>68</i>
<i>Figura 31.</i>	<i>Arquitectura de la red</i>	<i>71</i>
<i>Figura 32.</i>	<i>Perdida vs época.....</i>	<i>72</i>
<i>Figura 33.</i>	<i>Entrenamiento de angulo de friccion interna</i>	<i>73</i>
<i>Figura 34.</i>	<i>Entrenamiento de la cohesion</i>	<i>73</i>
<i>Figura 35.</i>	<i>Validacion de angulo de friccion interna.....</i>	<i>74</i>
<i>Figura 36.</i>	<i>Validacion de la cohesion</i>	<i>74</i>
<i>Figura 37.</i>	<i>Gradiente por cada entrada</i>	<i>77</i>
<i>Figura 38.</i>	<i>Influencia sobre el ángulo de fricción interna y cohesión.</i>	<i>78</i>
<i>Figura 39.</i>	<i>Importancia relativa de los propiedades fisicas sobre angulo de friccion interna.....</i>	<i>78</i>
<i>Figura 40.</i>	<i>Importancia relativa de los propiedades fisicas sobre la cohesion.</i>	<i>79</i>

Figura 41.	Importancia relativa por análisis de sensibilidad de entrada	79
Figura 42.	Grafica de ángulo de fricción interna Real vs predicha	83
Figura 43.	Grafica de Cohesion Real vs predicha.....	83
Figura 44.	Grafica de distribucion aleatoria residuos de angulo de friccion.....	83
Figura 45.	Grafica de distribucion aleatoria residuos de Cohesion.	84

INTRODUCCION

La resistencia al corte de los suelos es un parámetro crucial en la ingeniería geotécnica, que influye significativamente en el diseño de cimentaciones con el fin de garantizar la estabilidad de las estructuras. La determinación de estos parámetros, específicamente el ángulo de fricción y la cohesión, se obtiene de ensayos de laboratorio, estos pueden ser costosos y que requieran de tiempo considerable (hasta días). Bajo este contexto, la modelización computacional y, en particular, el uso de redes neuronales artificiales (RNA) emergen como una alternativa prometedora para la predicción de estos parámetros, aprovechando la creciente disponibilidad de datos y el avance en técnicas de inteligencia artificial-machine Learning.

Este estudio se centra en la obtención de los parámetros de corte en suelos no cohesivos bajo el enfoque de RNA (redes neuronales artificiales) basándose de datos físicos del suelo como la distribución granulométrica, límites de Atterberg (consistencia), la densidad y la humedad. A través de una metodología robusta que incluye el entrenamiento, validación y prueba del modelo de RNA, esta investigación busca no solo validar la eficacia del modelo neuronal en este campo, sino también profundizar en la comprensión de cómo las propiedades físicas del suelo influye en su resistencia mecánica al corte.

Los avances en inteligencia artificial y machine learning han abierto nuevas avenidas para la modelización de comportamientos complejos en diversos campos de la ciencia y la ingeniería. En la ingeniería geotécnica, la implementación de estas técnicas promete revolucionar los métodos de análisis y diseño, ofreciendo herramientas más precisas y rápidas. Con este estudio, se aspira a contribuir a la literatura existente proporcionando evidencia de la utilidad de las RNA en la predicción de parámetros de resistencia al corte de un suelo no cohesivo, enfatizando la importancia significativa de las características físicas del suelo en el modelo predictivo.

1. PLANTEAMIENTO DEL PROBLEMA.

1.1.DESCRIPCIÓN DEL PROBLEMA.

A lo largo de la historia se utilizaron modelos matemáticos para describir el comportamiento del suelo, entre ellas obtener los parámetros de resistencia al corte de un suelo. En estos tiempos para determinar estos parámetros se requiere de ensayos de laboratorio especiales (de manera experimental) ya que son más representativas que los modelos matemáticos como: corte directo, compresión triaxial, *Cone Penetration Testing* [ensayo de penetración en cono] (CPT), *Standard Penetration Test* [ensayo de penetración estándar] (SPT), *Lightweight Dynamic Penetrometer* [penetrómetro dinámico ligero] (DPL), etc. En cierto modo, estos ensayos tienen su propio grado de precisión, por lo que son muy utilizados en diferentes países, siendo así estandarizados por organizaciones como *American Society for Testing and Materials* [Sociedad Estadounidense para Pruebas y Materiales] (ASTM). Cabe mencionar que los parámetros de resistencia al corte de un suelo son fundamentales en la ingeniería geotécnica y civil, ya que influyen directamente en la estabilidad y el comportamiento de las estructuras que se apoyan o interactúan con el suelo ya sea en casos como diseño de cimentaciones, estabilidad de taludes, análisis de retención de tierra, túneles, excavaciones, selección de material de relleno, interacción de suelo-estructura, entre otros.

En el país de Perú, entre muchos ensayos ya mencionados, el ensayo de **corte directo** es uno de los ensayos más utilizados en determinar los parámetros de resistencia al corte de un suelo, el procedimiento del ensayo de corte directo tiene desventajas, al igual que los muchos tipos de ensayos, tales como: **ser costoso, no ser inmediato, requiere de un equipo de laboratorio (lugar fijo), falta de representatividad a escala del campo, sensibilidad en la manipulación de muestra, solo representa una condición de ensayo, no representa la anisotropía, entre otros.** A pesar de las limitaciones asociadas con el equipo de corte directo, los resultados obtenidos de este ensayo son confiables y ampliamente aceptados por la comunidad de ingeniería geotécnica.

El ensayo de corte directo se utilizó por décadas, y se sigue utilizando en el país de Perú. Y está estandarizado por la Norma Técnica del Perú NTP 339.171, por lo mismo se tiene gran cantidad de datos (*big data*), ya sea en informes de laboratorio, tesis, expedientes técnicos, etc. Por este motivo se plantea un modelo basado en aprendizaje automático “redes neuronales artificiales” alimentado por estos datos que fueron almacenados a lo largo de los años, para estimar o predecir los parámetros de resistencia al corte de un suelo granular a partir de

ensayos simples que describen propiedades físicas del suelo, proponiendo así un modelo confiable para la predicción de estos parámetros.

Dando lugar así una posible solución a la necesidad de obtener de estos parámetros de resistencia al corte de un suelo granular con menos costo, que requiera de menor tiempo (horas), ya que es un modelo computarizado y con una precisión aceptable en el ámbito de la ingeniería geotécnica.

1.2. DELIMITACIÓN DEL PROBLEMA.

1.2.1. *Espacial (geográfica)*

Teniendo en cuenta la recopilación de bases de datos de las investigaciones universitarias llevadas a cabo en Perú, aquellas informaciones que concierne a para esta investigación, se decidió que se delimitar el alcance de este estudio solo al ámbito del país de **Perú**, como la delimitación espacial es amplia por ende será necesaria que la obtención de la muestra para el entrenamiento del modelo computarizado también sea amplio.

1.2.2. *Temporal*

La información obtenida comprende un período que va desde el año 2013 hasta el presente 2023 (periodo de 10 años), y esta investigación se realizó a finales del año 2023.

1.2.3. *Unidad de estudio.*

Según (Supo & Zacarías, 2020), definen “es el individuo o conjunto de individuos de donde se obtiene el dato”. Por lo cual la unidad de estudio son los **suelos granulares**.

1.2.4. *Temática*

Teniendo definida la unidad de estudio de esta investigación, se delimitará de forma temática de la siguiente manera. En este estudio se excluye los suelos cohesivos y orgánicos (arcillas y materias descompuestas). La razón de esta exclusión se debe a que los suelos cohesivos, contienen minerales que actúan como material cementante, el cual impacta significativamente en la resistencia del suelo, ya que esta unión cementante puede ser débil o hasta comparadas con rocas débiles (Budhu, 2015, pág. 246). Además, es importante señalar

que la unión cementante en las arcillas no se ve influenciada por propiedades físicas, sino que está más relacionada con procesos que involucran reacciones químicas debido a la composición mineral de las arcillas.

En este estudio no analiza a los suelos sobre consolidados debido a que estos suelos para predecir su parámetro de resistencia al corte están influenciados, por la consolidación del suelo a lo largo de su historia (propiedad mecánica del suelo), más no por sus mismas propiedades físicas. Otra delimitación importante se hace en las condiciones del ensayo de corte directo.

Este estudio se centra específicamente en condiciones de Consolidado Drenado (CD), la elección de estas condiciones se debe a tres motivos: los suelos granulares presentan una permeabilidad bastante alta, el equipo de corte directo fue diseñado para este tipo de pruebas.

1.3.FORMULACIÓN DEL PROBLEMA.

1.3.1. *Problema general.*

¿Se podrá predecir con un nivel de eficacia alta los parámetros de resistencia al corte en suelos granulares a partir de su comportamiento físico, empleando redes neuronales artificiales?

1.3.2. *Problemas específicos*

- ✓ ¿Cuál es la importancia relativa de la distribución granulométrica en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?
- ✓ ¿Cuál es la importancia relativa de los límites de consistencia en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?
- ✓ ¿Cuál es la importancia relativa de la densidad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?
- ✓ ¿Cuál es la importancia relativa de la humedad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?

1.4. JUSTIFICACIÓN DEL ESTUDIO

A falta de un modelo neuronal eficaz en la estimación de parámetros de resistencia al corte de un suelo granular, esta investigación pretende dar hincapié a este problema.

La presente investigación es viable, ya que se tiene un gran conjunto de datos “*big data*” para el modelo en redes neuronales, y se someterá a prueba para determinar su eficacia de este modelo.

Los beneficiarios de este estudio serán profesionales en sector de la construcción que tendrán una alternativa para obtener valores confiables de parámetros de resistencia al corte de un suelo granular, siendo así menos costoso, inmediato y válido en cualquier parte de Perú. También esta investigación pretende dar otra alternativa al profesional de una obra pública o privada en el control de calidad o veracidad de los valores del ensayo de corte directo que proporcionan los laboratoristas.

El estudio aporta de manera disciplinaria en la predicción de un valor muy importante en la ingeniería geotécnica, que son los parámetros de resistencia al corte en suelos granulares a partir de simples ensayos que describen físicamente a un suelo, resultando así más económica y con un alto porcentaje de confiabilidad en un corto tiempo.

1.5. IMPORTANCIA DEL ESTUDIO

La importancia de este estudio radica en tener una alternativa o herramienta en la obtención de los parámetros de resistencia al corte de un suelo granular, a partir de ensayos simples, económicos y de procesos rápidos. Mediante un modelo de redes neuronales artificiales, con una eficacia en la predicción aceptable para el ámbito de ingeniería civil. A fin de ser utilizadas en diseños de obras civiles que requieran, como en cimentaciones superficiales en viviendas, edificaciones, muros de contención o en estabilidad de taludes, etc.

1.6. LIMITACIONES DE LA INVESTIGACIÓN.

La dificultad en la viabilidad de las fuentes es en la recolección de los datos e información útil para la alimentación del modelo neuronal, donde no se tuvo accesibilidad a todas las investigaciones universitarias del Perú (repositorio), relacionadas con el tema de estudio.

La limitación en recursos se da a conocer que, por cuestiones económicas, solo se puso a prueba en 39 muestras que se sometieron al experimento. Ya que un ensayo entre corte directo, granulometría, límites de consistencia, cono de arena, etc., representan un alto coste por una muestra, involuntariamente este podría afectar en la exactitud de la eficacia del modelo neuronal.

1.7. OBJETIVOS.

1.7.1. *Objetivo general.*

Predecir los parámetros de resistencia al corte en suelos granulares, a partir de su comportamiento físico mediante el uso de redes neuronales artificiales, con un alto nivel de eficacia.

1.7.2. *Objetivos específicos.*

- ✓ Determinar la importancia relativa de la distribución granulométrica en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.
- ✓ Determinar la importancia relativa de los límites de consistencia en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.
- ✓ Determinar la importancia relativa de la densidad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.
- ✓ Determinar la importancia relativa de la humedad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.

2. MARCO TEÓRICO.

2.1. ANTECEDENTES.

Vara Horna (2010), señala que: Los antecedentes son una revisión crítica de las diversas investigaciones que se han realizado anteriormente. Informan sobre qué tanto se sabe del tema y qué aspectos se han investigado y dejado de investigar (p. 203).

2.1.1. Investigaciones internacionales.

En el artículo llamado “*Artificial neural network applications in geotechnical engineering [Aplicaciones de redes neuronales artificiales en ingeniería geotécnica.]*”, donde menciona que el método computacional denominado red neuronal artificial (RNA) ha sido aplicado con muchos éxitos en diversos problemas de ingeniería geotécnica y de suelos. Con satisfactorios rendimientos en las estimaciones de valores o parámetros geotécnicos que son utilizados en diseño de pilotes, compactación del suelo, estructuras de contención de tierra, estabilidad de taludes, diseño de túneles y aberturas subterráneas, asentamiento de estructuras, permeabilidad del suelo, evaluación de licuefacción y conductividad hidráulica, hinchamiento del suelo y clasificación de suelos (Mohamed A. et al., 2001).

Los investigadores del artículo “*Prediction of residual friction angle of clays using artificial neural network*” [Predicción del ángulo de fricción residual de las arcillas mediante una red neuronal artificial] (Sarat Kumar y Pradir Kumar, 2008), presentaron varios modelos de red neuronal para estimar o predecir el ángulo de fricción residual a partir de fracción de arcilla y los límites de Atterberg (CF, LL, PI, ΔPI). La alimentación de los 54 datos es de un estudio realizado por Wesley (2003). Probaron distintos modelos de RNA utilizando diferentes combinaciones de las variables de entrada mencionadas.

Cuadro N° 1. Different ANN models and their statistical performances

Models	Inputs	Coefficient of correlation (R)		Coefficient of efficiency (R2)	
		Training	Testing	Training	Testing
Model 1	LL, CF	0.851	0.829	0.741	0.543
Model 2	LL, PI, CF	0.902	0.883	0.813	0.652
Model 3	LL, PI, CF, ΔPI	0.926	0.885	0.807	0.761
Model 4	CF, ΔPI	0.906	0.942	0.826	0.868

Tomada de (Sarat Kumar y Pradir Kumar, 2008).

En el artículo presenta métodos de análisis de sensibilidad del modelo, según el método de Garson y el enfoque del peso de conexión, metodologías para determinar los parámetros de entrada más importantes. Se desprende que el ΔPI es el parámetro más importante para predecir el valor ϕ_r según los métodos de análisis de sensibilidad (Sarat Kumar y Pradir Kumar, 2008).

Cuadro N° 2. Importancia relativa de diferentes entradas del modelo neuronal

Parameters	Garson's algorithm		Connection weight approach	
	Relative importance (%)	Ranking of inputs as per relative importance	value as per Connection weight approach	Ranking of inputs as per relative importance
CF	33.6%	2	-8.55	2
ΔPI	66.33%	1	-9.65	1

Tomada de (Sarat Kumar y Pradir Kumar, 2008)

Concluyendo que el modelo RNA con CF y ΔPI como parámetros de entrada es el "mejor" modelo, basado en parámetros estadísticos, en coeficiente de correlación y en coeficiente de eficiencia, para las dos etapas establecidos por el autor entrenamiento y prueba. También se concluyó partir de los análisis de sensibilidad; algoritmo de Garson (análisis de importancia) y enfoques de peso de conexión, el autor consiguió en su resultado que ΔPI es el parámetro de entrada más influyente. (Sarat Kumar y Pradir Kumar, 2008)

En este artículo ***“Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods” [Predicción de parámetros de resistencia al corte de suelos mediante redes neuronales artificiales y métodos de regresión multivariante]*** de (Khanlari et al., 2011). Una comparación de dos métodos, redes neuronales artificiales (ANN, siglas en ingles) y la regresión multivariada (MR, siglas en ingles) para la estimación de los parámetros de resistencia al corte del suelo.

Se menciona que obtuvieron muestras de suelo de la provincia de Hamedan, situada en la parte occidental de Irán. Ya que estas, se han llevado a cabo una serie de pruebas de laboratorio para determinar las propiedades. Las pruebas realizadas incluyeron la distribución granulométrica, los límites de Atterberg, la densidad y la prueba de cizallamiento directo. Estos parámetros se han medido en 200 muestras.

Cuadro N° 3. Estadística, descripción básica

Estadística	≤ 200 (%)	≤ 40 (%)	≤ 4 (%)	PI	f g/cm ³	C kg/cm ²	θ°
Minimo	16.45	27.51	39	0	1.22	0.01	10.20
Maximo	87.2	96.73	99	22.05	2.17	0.34	32.17
Medium	42.96	63.62	91.38	7.6	1.77	0.10	23.32
Desviación estándar	14.09	16.18	15.28	5.95	0.17	0.06	5.25
n	200	200	200	200	200	200	200

Tomada de (Khanlari et al., 2011)

Cuadro N° 4. Matriz de correlación entre parámetros

parámetros	≤ 4	≤ 40	≤ 200	PI	ρ	C	$\emptyset$
≤ 4	1	0.77	0.44	0.37	-0.10	-0.47	0.28
≤ 40		1	0.77	0.55	-0.12	-0.81	0.55
≤ 200			1	0.70	-0.11	-0.83	0.79
PI				1	-0.03	-0.63	0.67
ρ					1	0.16	-0.01
C						1	-0.66
$\emptyset$							1

Nota: Además elaboraron una matriz de correlaciones, para cuantificar el grado de relación lineal entre las variables, correlación bivalente, (Khanlari et al., 2011).

Para realizar modelos RNA los autores tomaron ciertos porcentajes para el entrenamiento, validación y prueba (entrenamiento, el 65% de los datos para ϕ y el 70% de los datos para C), un conjunto de validación cruzada (15%) y un conjunto de prueba (20% para ϕ y 15% para C). Se evaluaron los dos modelos ANN y MR, con criterios estadísticos como: *root mean square error (RMSE)*, *mean absolute error (MAE)* and *t-test*. A continuación se resume los resultados en los siguientes cuadros, solo con RMSE como medida para no extenderse demasiado. (Khanlari et al., 2011).

Cuadro N° 5. Evaluación estadística en RMSE.

parámetros	Ángulo de fricción $\emptyset^\circ$			Cohesión C kg/cm ²		
	ANN		MLR	ANN		MLR
	Training	Testing	Error	Testing	Training	Error
.(i) ≤ 200	2.91	3.04	2.860	2.91	0.036	0.0416
.(ii) ≤ 200 y ≤ 40	2.43	2.55	2.528	2.43	0.034	0.0402
.(iii) ≤ 200 , ≤ 40 y PI	2.41	2.58	2.506	2.41	0.019	0.0395
.(iii) ≤ 200 , ≤ 40 , PI y ≤ 4	2.11	2.26	2.408	2.11	0.033	0.0395
.(iii) ≤ 200 , ≤ 40 , PI, ≤ 4 y ρ	2.45	2.51	2.385	2.45	0.037	0.0393

Nota: Evaluación estadística RMSE de los modelos ANN y MLR, en fase de entrenamiento y prueba para estimación de $\emptyset$ y C

Estos investigadores concluyeron que el rendimiento de los modelos RNA y MLR para la estimación de ϕ demostró que los tres modelos MLR (i, ii y v) resultaran con mejores rendimientos que los mismos modelos en RNA. El modelo iii tiene un rendimiento similar o semejante a ambos métodos, RNA y MLR, pero el modelo iv de RNA tiene mejores resultados (mejores predicciones) que el mismo modelo en MLR.

Para la estimación de C (cohesión) indica que todos los modelos de RNA tienen mejores resultados que los modelos de MLR. Además, al comparar los rendimientos de los modelos RNA y MLR indicó que la RNA era más adecuada o preciso para estimar la cohesión, pero para la estimación del ángulo de fricción el uso de los métodos RNA y MLR tiene una

capacidad aceptable o de precisión moderada. Los autores de este estudio sugieren o incentivan el uso de estos modelos para la estimación de los parámetros de resistencia al corte (parámetros de corte) de los suelos (Khanlari et al., 2011).

Otro interesante estudio ***“Shear Strength Prediction of Soil based on Probabilistic Neural Network” [Predicción de la resistencia al corte del suelo basada en una red neuronal probabilística]***, (Sushama Kiran y Tripathy, 2016). Donde aplicaron la red neuronal probabilística (PNN) en la estimación de la resistencia al corte, cohesión "c" y ángulo de fricción interna " ϕ ". Donde las variables de entrada utilizadas por estos autores para desarrollar el modelo con propiedades de índice tales como: densidad seca "DD", índice de plasticidad "PI", contenido de agua "w", % de arcilla "CP", % de limo "STP", % de grava "GP", % de arena "SP" del suelo analizado.

Las muestras de suelo fueron tomados de Ranchi, capital de Jharkhand-India. Se recogieron 300 muestras de suelo de diversos lugares, que incluyen muestras alteradas y no alteradas. Los datos se dividieron aleatoriamente. Los datos aleatorios se dividieron en un conjunto de datos de entrenamiento (85%) y de prueba (15%).

Cuadro N° 6. Validada conjunto de datos

Sl. No.	PI	GP%	SP%	STP%	CP%	BD	w	C _{observed}	C _{predicted}	Φ _{observed}	Φ _{predicted}
1	11.2	0	18	69	13	2.02	24.2	0.41	0.45	15.0	14.54
2	9.6	0	35	57	8	1.98	22.8	0.22	0.28	19.5	19.25
3	12.7	0	10	76	14	1.9	19.5	0.4	0.45	13.5	13.91
4	6.2	0	42	55	3	2.02	20.2	0.05	0.00	27.5	27.5
5	14.79	3.5	63.64	26.86	6	2.03	16.52	0.13	0.10	23.0	25.6
6	11.41	8.78	66.46	20.76	4	2.05	16.24	0.1	0.10	28.0	25.6

Tomadas de (Sushama Kiran & Tripathy, 2016).

Se describe en un cuadro, realizados por los autores del artículo, los resultados de la validación con otros 6 casos, muy apartes de los datos anteriores, se comprobó que la PNN entrenada es capaz de predecir satisfactoriamente la resistencia al corte.

Concluyeron que los modelos de redes neuronales probabilísticas generan una mayor precisión de predicción para su aplicación práctica (Sushama Kiran & Tripathy, 2016).

2.1.2. Investigaciones nacionales.

Los Autores de la tesis denominado ***“parámetros de resistencia al corte de suelos a partir de sus propiedades físicas, utilizando redes neuronales artificiales y equipo triaxial,***

UNH” (Boza Capani & Merino Ortiz, 2018), con el objetivo de determinar la variación y correlación de los parámetros de resistencia al corte de suelos a partir de sus propiedades físicas utilizaron las Redes Neuronales. Recolectaron 39 muestras representativas para el estudio, suelos que forman las laderas del Campus de la Universidad Nacional de Huancavelica, esto en la ciudad de Huancavelica-Perú.

Realizaron los ensayos triaxiales no consolidado no drenado (UU), también los ensayos básicos como análisis granulométrico, límites de Atterberg, contenido de humedad y la densidad de un suelo. Los autores realizaron el entrenamiento del modelo de Red Neuronal supervisada, su esquema simple del modelo estableció que las variables de entrada fueron (propiedades físicas) y variables de salida (parámetros de resistencia al corte).

Los autores dividieron los datos, el 70% de datos para el entrenamiento, 15% validación y el 15 % restante para la prueba del modelo, usando el software Matlab. La arquitectura de la red de una capa de entrada conformado por 11 neuronas de la variable **propiedad física del suelo**: (1) contenido de humedad, (2) peso específico, (3) limite líquido, (4) limite plástico, (5) índice plástico, (6) %grava gruesa, (7)%grava fina, (8) %arena fina, (9) %arena media, (10) % arena gruesa, (11) % finos; capa oculta formado por 10 neuronas; y la capa de salida por 2 neuronas de la variable **parámetros de resistencia al corte**: (1) ángulo de fricción, (2) cohesión. El tipo de Red Neuronal Artificial fue Feed – Forward Backpropagacion según describen los autores, función de aprendizaje LEARNGD, el indicador de error MSE y función de transferencia sigmoidea de la tangente hiperbólica TANSIG.

Los resultados en entrenamiento $R=0.94$, validación $R=0.997$ y prueba $R=0.96$, siendo R el coeficiente de determinación, simplificado R -cuadrado. Y en este estudio se utilizó la estadística inferencial, en sus resultados la medida del nivel de significancia del modelo de Red Neuronal Artificial fue 0,01, demostrando el estudio que es menor al nivel de confianza de 0,05 Concluyendo que existe adecuada dependencia y correlación de los parámetros de corte del suelos (ángulo de fricción interna y cohesión) y sus partir de sus propiedades físicas (Boza Capani & Merino Ortiz, 2018).

Un factor muy importante en que los resultados tengan un nivel de significancia de 0,01 es el manejo de muestras muy semejantes, ya que los suelos se extrajo de una pequeña área para ser analizados, siendo no muy variables. Asimismo, no llevo a cabo un análisis estadístico minucioso antes del entrenamiento y la validación.

En el trabajo titulado “*Diseño de una red neuronal artificial no supervisada para la estimación de parámetros de resistencia al corte de suelos a partir de sus propiedades físicas*”, propone como objetivo una solución tecnológica alternativa mediante red neuronal artificial (RNA) en Software Matlab, para estimar los parámetros de resistencia al corte de

suelos (el ángulo de fricción y la cohesión). El autor obtuvo la base de datos, cuya información proviene de proyectos regionales de Telecomunicaciones y de proyectos particulares, de la empresa *DELTA PROJEKT INGENIERIA Y CONSTRUCCIÓN E.I.R.L.*

Su metodología consistió en Creación de la base de datos, recopilados de estudios de mecánica de suelos de los Laboratorios Geotécnicos de los proyectos regionales de telecomunicaciones, diseño de la RNA en el software MATLAB, mediante la arquitectura de la capa de Kohonen (aprendizaje no supervisado).

El autor de la investigación en sus resultados, obtuvo con respecto a la “cohesión” un coeficiente de correlación de Pearson de 0.69 y error medio del 5.15% con respecto a los resultados del laboratorio, y para el “ángulo de fricción” con un coeficiente de correlación de Pearson de 0.82 y un error del 9.00%.

Concluyo que se puede dimensionar las zapatas o cimentaciones de las torres de telecomunicaciones, en base o referentes a los resultados de la RNA, evitando el tiempo de espera que se necesitaría si se realizaría en laboratorio de suelos. Con este método se puede mejorar el tiempo y calidad de entrega de anteproyectos. Por consiguiente se aumentó la capacidad de manejo de proyectos de la empresa (aumento de eficiencia) Delta Projekt ingeniería y construcción E.I.R.L. (Solís Galvez, 2023).

En esta tesis: “**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%, Óptimo contenido de humedad, Máxima densidad seca) a partir de sus propiedades físicas: Granulometría y límites de consistencia usando un software basado en algoritmos de redes neuronales artificiales. Se tomaron la información de los diferentes estudios (expedientes técnicos) de carreteras pertenecientes a una institución estatal, Provias Nacional del Perú, así consiguiendo 212 números de muestras.

Siendo las variables independiente y dependiente: propiedad física y propiedad mecánica, respectivamente. Una vez recolectado la base de datos procedió a realizar el entrenamiento mediante las variables de entrada porcentajes de grava, arena, finos, limite líquido, limite plástico, índice de plasticidad y variables 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.

En esta sección se describe la arquitectura de la red neuronal: 6 neuronal como capa de entrada, 4 neuronal como capa de salida, con la asistencia del software NeuralTools, se obtuvo redes neuronales de tipos GRNN y MLFN.

Cuadro N° 7. Resultados de correlación.

Análisis de regresión de cada modelo neuronal	Factor de ajuste o correlación R2		
	entrenamiento	Validación laboratorio	correlación
CBR al 100% de MDS	0.706	0.732	bueno
CBR al 100% de MDS	0.823	0.823	Bueno
OCH %	0.843	0.845	bueno
MDS g/cm3	0.925	0.927	excelente

Tomados de (Manrique Dávila, 2019).

Concluye, que desarrollar un modelo neuronal es eficaz en predecir las propiedades mecánicas de suelos con errores mínimos, proponiéndose como una alternativa en el estudio de la mecánica de suelos (Manrique Dávila, 2019).

El estudio de Manrique, no llevo a cabo un análisis estadístico, para la normalización de los datos antes del entrenamiento y la validación. Además los datos para el entrenamiento y validación no son aleatorios, sino fueron elegidos de manera arbitraria. Cabe resaltar el vasto de datos que tuvo tal investigación.

El trabajo de investigación llamado **“Desarrollo de un modelo de redes neuronales artificiales para predecir las propiedades mecánicas del suelo”** de (Valderrama Purizaca, 2020), con 285 muestras de suelo se obtuvieron de los expedientes técnicos de obras de

Cuadro N° 8. Información recopilado del SEACE

Lugar	Big data		
	Expedientes	Muestras	Ensayos
<i>Chiclayo</i>	21	179	1074
<i>Ferreñafe</i>	4	35	210
<i>Lambayeque</i>	11	71	426
Total	36	285	1710

pavimentación que fueron realizadas en las provincias de Chiclayo, Ferreñafe y Lambayeque, reunida del Sistema Electrónico de Contrataciones del Estado (SEACE). Con esa data se desarrollan modelos de redes neuronales artificiales para la predecir las propiedades mecánicas del suelo de la región Lambayeque.

Al igual que la tesis anterior, elaborado por (Manrique Dávila, 2019), las variables de entrada fueron de los ensayos de contenido de humedad, contenido de sales, análisis granulométrico y límites de consistencia; y las variables de la máxima densidad, el óptimo contenido de humedad, la relación de soporte de California al 95 %, y al 100 %.

Sobre la arquitectura de la red, el autor realizo 6 modelos de red, donde difieren en su arquitectura (específicamente en número de entrada y salida), a continuación un cuadro extraído por esta tesis.

Cuadro N° 9. Entradas y salidas utilizadas.

Modelo	Parámetros											
	H	S	G	A	F	LL	PL	PI	MDD	OMC	CBR95	CBR100
MARK 1	X	X	X	X	X	X	X	X	-	-	-	Y
MARK 2	X	X	X	X	X	X	X	X	-	-	Y	-
MARK 3	X	X	X	X	X	X	X	X	X	X	-	Y
MARK 4	X	X	X	X	X	X	X	X	X	X	Y	-
MARK 5	X	X	X	X	X	X	X	X	Y	-	-	-
MARK 6	X	X	X	X	X	X	X	X	-	Y	-	-

Nota: X= propiedades usadas como entrada; Y= propiedades usadas como salida

En este estudio se evaluó la precisión de los modelos de ANN al cambiar la cantidad de neuronas en cada capa oculta. El aumento de la cantidad de neuronas ocultas mejora la exactitud de las predicciones en el entrenamiento y validación, pero llega a uno óptimo después puede causar un efecto contrario de los modelos de ANN desarrollados. Y así consiguiendo los mejores resultados obtenidos en esta tesis, con un coeficiente de determinación en CBR al 100 % de MDD un $R^2 = 0.88$ y CBR al 95 % un $R^2 = 0.92$.

El autor concluyo que: es importante de tener definido las propiedades que se pueden predecir y utilizarse como variables de entrada para la predicción de dicha propiedad mecánica. Se demostró la elevada capacidad de las ANN para predecir propiedades del suelo en base a propiedades fáciles de medir, los modelos propuestos pueden usarse en proyectos reales cuando se quiere obtener estas propiedades de manera rápida (Valderrama Purizaca, 2020).

El estudio de Valderrama, no normalizo los datos antes del entrenamiento y la validación. Cabe resaltar el vasto de datos que tuvieron tal investigación, la aleatoriedad de los datos y su análisis estadístico para el entrenamiento y validación. Un gran método que hizo en el entrenamiento es la optimización de las capas ocultas de la red neuronal.

2.2. BASES TEÓRICAS.

2.3.1. Tipos de suelos

Los suelos pueden categorizarse de diversas maneras, dependiendo a sus propiedades y características, ya que estas definiciones serán necesarias para el entendimiento de esta investigación.

 Tipos de suelo Según el tamaño de las partículas, permeabilidad y adherencia: suelos cohesivos y no cohesivos.

Suelos granulares - No cohesivos

“Granular Soils are gravels, sands and silts that can stand on a slope steeper than 3: 1 H/V, without spalling or slumping” [las gravas, arenas y limos son clasificados como suelos granulares, se caracterizan por la capacidad de permanecer en una inclinación inferiores a 1/3 de talud. sin experimentar desprendimientos o deslizamientos]. Los suelos granulares carecen de fuerza cohesiva. Por lo general, no se pueden excavar con taludes pronunciados (aunque algunos suelos granulares húmedos pueden mostrar cierta cohesión aparente y sostenerse temporalmente en una pendiente vertical). Además, no son maleables en estado húmedo y se desmoronan fácilmente cuando están secos, son conceptos de acuerdo a (Department of Commerce-National Bureau of Standards [NBS], 1980) y (Code of Federal Regulations Safety [CFR]; Health Regulations for Construction, 1926).

Según AASTHO (1945, citado en Bowles, 1981), los materiales granulares son aquellas que tienen 35% o menos del material fino que pasan el tamiz N° 200 (75 μ m). Además añade (Budhu, 2010), que estos suelos se distinguen por contar con partículas de mayor tamaño y una menor cohesión entre ellas, destacándose por su capacidad de drenaje rápido.

Para Das y Sobhan (2018), dejan entender que los suelos granulares están mayormente constituidos por partículas que abarcan desde arcillas gruesas (mayores a 2 μ m), que se caracterizan por su eficiente capacidad de drenaje, poca adherencia, el ángulo de fricción interna mayor, y una cohesión menor en comparación con los suelos de textura fina.

Las partículas no tienden a juntarse ni adherirse, las partículas son relativamente grandes, también llamados suelos no cohesivos o friccionantes (arenas, gravas y limos) (GrupoCipsa, s.f.).

Cuadro N° 10. Clasificación por tamaño de partículas.

Name of organization	Grain size (mm)			
	Gravel	Sand	Silt	Clay
Massachusetts Institute of Technology (MIT)	>2	2 to 0.06	0.06 to 0.002	<0.002
U.S. Department of Agriculture (USDA)	>2	2 to 0.005	0.005 to 0.002	<0.002
American Association of State Highway and Transportation Officials (AASHTO)	76.2 to 2	2 to 0.075	0.075 to 0.002	<0.002
Unified Soil Classification System (U.S. Army Corps of Engineers, U.S. Bureau of Reclamation, and American Society for Testing and Materials)	76.2 to 4.75	4.75 to 0.075	Fines (silt and clay) < 0.075	

Note: Se encuentran aberturas de tamiz de 4,75 mm en un tamiz N° 4 de EE. UU.; aberturas de 2 mm en un tamiz N°10 de EE. UU.; Aberturas de 0,075 mm en un tamiz N° 200, (Das y Sobhan, Principles of Geotechnical Engineering., 2018).

Suelos cohesivos

Los suelos cohesivos son arcillas o alto contenido de arcilla que tienen fuerza cohesiva. No se desmoronan, pueden excavarse con pendientes laterales verticales, son plásticos (pueden moldearse en varias formas y enrollarse en hilos) cuando están húmedos y son difíciles de romper cuando están secos (NBS, 1980), agregando al concepto anterior (CFR, 1926), los suelos cohesivos incluyen limo arcilloso, arcilla arenosa, arcilla limosa, arcilla y arcilla orgánica. Para (Barnes, 1995), los suelos cohesivos son aquellas que están constituidos en un gran porcentaje por partículas muy pequeñas (minerales de arcilla), que constituyen la microestructura o micro tejido del suelo.

Con un concepto similar a las anteriores “*The term clay is commonly used to describe any cohesive soil deposit with sufficient clay minerals present*” [El término arcilla se usa comúnmente para describir cualquier depósito de suelo cohesivo con suficientes minerales arcillosos presentes] (Bowles, 1997, p. 23).

Según AASTHO (1945, citado en Bowles, 1981), los materiales limo-arcillosos son aquellas que su material fino pasan más del 35% el tamiz N° 200 (75 µm).

Otras de las definición lo estable, que los suelos cohesivos constituidos por partículas muy pequeñas donde predominan los efectos electroquímicos superficiales. Las partículas tienden a juntarse (interacción agua y partícula) en suelos plásticos como las arcillas (GrupoCipsa, s.f.) y (IngeCivil, 2018).

 *Tipos de suelo según la composición de materia orgánica: suelos inorgánicos y orgánicos.*

Suelos orgánicos

Según Das (2012), los suelos orgánicos suelen localizarse en zonas de baja profundidad, en lugares donde el agua subterránea está a nivel o sobre el terreno, favoreciendo desarrollo de plantas acuáticas, cuya descomposición contribuye a la formación de suelo orgánico. Exhiben las siguientes características:

-  El contenido de agua entre 200 y 300%. Y son altamente compresibles.
-  Sometidos a cargas, el asentamiento es muy grande, y gran parte de esta deriva de su consolidación secundaria.

Para [Scott \(1980\)](#), el suelo orgánico está formado por materia orgánica que proviene de restos de plantas o animales (*humus*) descompuestos por bacterias. Se concentra en los 0,3 a 0,5 m, mientras la turba puede encontrarse a profundidades significativas, en lugares donde la descomposición habitual se ve interrumpida por la ausencia de oxígeno.

- »» Absorbe grandes cantidades de agua, hasta cinco veces su propio peso. Lo que puede llegar a gran reducción de su volumen por ende a un asentamiento general del terreno si se llega a drenar su contenido de agua, descenso del nivel freático o por secado.
- »» Posee muy baja resistencia al corte, lo que resta resistencia de cualquier otro tipo de suelo con el que se combine.
- »» Inhiben el fraguado del cemento, por ende no pueden estabilizarse con cemento ([p. 4](#)).

Las sustancias orgánicas del suelo varían desde residuos macroscópicos de plantas y animales completamente y parcialmente descompuestos, también contiene humus microscópico ([Gieseck, 1975](#)). Los suelos con grandes partículas orgánicas, tales como la turba, pueden almacenar mucha agua debido a su estructura porosa y suelta, así como al hecho de que muchas de estas partículas tienen cavidades repletas de agua. ([Terzaghi et al., Soil mechanics in engineering practice, 1996](#)). Influyendo en diversas propiedades del suelo; su estructura, compresibilidad, resistencia al corte, capacidad para retener agua, actividad biológica, y las tasas de infiltración de agua y aire. ([Venegas Sepúlveda, 2008](#)).

En área de ingenierías de suelos, geológica y geotécnica, la definición de suelos orgánicos puede variar respecto a áreas como agricultura. Para ([Huat et al., 2014](#)), los suelos orgánicos contienen 20% de restos vegetales por lo menos, se caracteriza por baja resistencia al corte y son altamente compresibles, lo que los hace problemáticos para las obras de construcción. Por ese motivo ([Escuela de ingenieros militares, 1989](#)), afirma que no se utilizan como material para obras de ingeniería.

Suelos inorgánicos

Los suelos inorgánicos son aquellos que tienen una proporción baja o insignificante de materia orgánica descompuesta ([Huat et al., 2014](#)). Están compuestos principalmente por minerales inorgánicos, como arcillas, limos y arenas. Estos suelos se caracterizan por tener propiedades físicas y químicas que difieren a suelos orgánicos, tienen mejor comportamiento bajo el enfoque de interacción estructura-suelo.

📖 Tipos de suelo según el comportamiento de consolidación: consolidados y sobre consolidados.

Se identifica por el grado de sobre consolidación OCR (over consolidation ratio, en inglés):

$$OCR = \frac{\sigma_{max}}{\sigma_{act}}$$


δ_{max} : Esfuerzo máximo.

δ_{act} : Esfuerzo actual.

OCR = 1 para suelos normalmente consolidados.

OCR > 1 para suelos sobre consolidados.

Figura 1. Resistencia sobre consolidad y normalmente consolidadas.



Nota: imagen tomada de (Das, 2012, p. 56)

Suelos normalmente consolidados

Son aquellos que han experimentado en el pasado tensiones máximas equivalentes a las actuales; suelos que han sido sometidos a cargas (Duque Escobar, 2003).

Suelos sobre consolidados

Son aquéllos que han sido cargados y descargados, las tensiones máximas históricas que han soportado han sido mayores que las actuales (Duque Escobar, 2003).

2.3.2. Sistemas de clasificación de suelos

Los sistemas de clasificación de suelos agrupan con base a propiedades ingenieriles comunes como la distribución granulométrica, el límite líquido y el límite plástico. Los dos sistemas de clasificación principales de uso actual son: el sistema de la “American Association

of State Highway and Transportation Officials” (AASHTO) y el “Unified Soil Classification System” (SUCS), también es el sistema de la ASTM.

El sistema de la AASHTO se emplea usualmente para la clasificación de las capas del pavimento de una carretera. No se utiliza en la construcción de cimentaciones (Das, 2012, p. 17).

Sistema de la AASHTO

El Sistema de clasificación de suelos de la AASHTO fue propuesto originalmente en Highway Research Board’s Committee on Classification of Materials for Subgrades and Granular Type Roads (1945), en ASTM D-3282. Fue propuesto para suelos presentes en las carreteras, ya sea en los componentes de subrasante y granulares (Das, 2012, p. 18) .

Sistema Unificado

El Sistema unificado de clasificación de suelos lo propuso A. Casagrande en 1942 y luego de ser revisado se adoptó el United States Bureau of Reclamation y el US Army Corps of Engineers. Actualmente el sistema se utiliza en todo el trabajo geotécnico (Das, 2012, p. 19).

2.3.3. Comportamiento físico de los suelos

Son acciones, respuestas o cambios observables en un objeto, sustancia en respuesta a influencias externas o condiciones ambientales.

En la siguiente tabla tomado de (Holtz et al., 2011), resume los efectos de algunos factores que afectan al ángulo de fricción interna de un suelo.

Cuadro N° 11. Resumen de factores que afectan a ϕ


FACTOR	EFEECTO
Relación de vacío, e	$e \uparrow ; \phi \downarrow$
Angularidad, A	$A \uparrow ; \phi \uparrow$
Distribución granulométrica, Cu	$Cu \uparrow ; \phi \uparrow$
Rugosidad, R	$R \uparrow ; \phi \uparrow$
Contenido de humedad, w	$w \uparrow ; \phi \downarrow$ (levemente)
Tamaño de partícula, S	No afecta (constante e o Cu)
Sobre consolidado	Efecto pequeño

Tomado de (Holtz et al., 2011)

Distribución granulométrica

Se determina por lo general mediante un análisis granulométrico mediante mallas, para suelos gruesos (para tamaños mayores de malla N° 200); y análisis del hidrómetro, para suelos finos (partículas menores de 75µm) (Das, 2012, p. 17).

Figura 2. Curva de la distribución granulométrica obtenida en un análisis con mallas.



Nota: Recopilado de (Das, 2012, pág. 17).

Conceptos y aspectos generales del ensayo, según normas técnicas

El análisis distribución granulométrica, se rigen por ensayos que están normalizados por entidades internacionales como ASTM D422 *Standard Test Method for Particle-Size Analysis* o por países como en Perú NTP 339.128 *Suelos. Método de ensayo para el análisis granulométrico*.

El análisis granulométrico se emplea para medir la variedad en el tamaño de las partículas de un suelo. Consiste en hacer pasar una muestra de suelo seco y desmenuzado por una serie de tamices de aberturas decrecientes. Se mide el suelo que queda en cada tamiz y se calcula el porcentaje acumulativo que pasa por ellos (ASTM D422, 1998).

Figura 3. Distribución granulométrica mediante tamices.



Nota: Tomado de (Fayat Group, 2019), http://dynapac.blog/latinoamerica/wp-content/uploads/2019/01/Imagen2_1.jpg

Cuadro N° 12. U.S standard sieve sizes (ASTM 2010)

U.S Standard Sieve N°	Sieve opening (mm)	U.S Standard Sieve N°	Sieve opening (mm)	U.S Standard Sieve N°	Sieve opening (mm)
3 in	75 mm	4°	4.75 mm	40°	425 um
2 in	50 mm	8°	2.35 mm	50°	300 um
1.5 in	37.5 mm	10°	2.00 mm	60°	250 um
1 in	25.0 mm	16°	1.18 mm	100°	150 um
¾ in	19.0 mm	20°	850 um	140°	106 um
3/8 in	9.5 mm	30°	600 um	200°	75 um

Nota: Tomado de (Holtz et al., 2011, p. 34). La tabla contiene una lista de los números de mallas utilizadas en Estados Unidos y en nuestro país y el tamaño correspondiente de sus aberturas.

Grava. Es la partícula sólida del suelo tamaño superiores a 4.75 mm (Tamiz N° 4) y menores a 7.5 cm ó 3 pulgadas (tamiz de 3”).

Arena. Está compuesto por partículas tamaño inferiores a 4.75 mm (tamiz N° 4) y superiores a 0.075 milímetros de diámetro (tamiz N° 200) y tiene una textura rasposa.

Finos. Se le denomina a las partículas limosas y/o arcillosas igual o inferior a 0,075 mm (pasan por el tamiz 200). Estos suelos contienen limos, minerales de arcilla, como caolinitas, illitas, esmectitas y materia orgánica, entre otros (ASTM D422, 1998).

Coefficiente de uniformidad (Cu). Mide qué tan uniforme es la muestra. Cu igual a 1 corresponde a que las partículas tienen el mismo tamaño o son similares. Este coeficiente se calcula por medio de la siguiente formula:

$$Cu = \frac{D_{60}}{D_{10}}$$

Coefficiente de curvatura (Cc). Mide la curvatura de la curva granulométrica. Cuando el coeficiente está dentro del rango 1 y 3 se consideran bien gradados. Cuando el coeficiente esta por fuera del rango, que tiene saltos o cambios fuertes de pendiente indica que hay ciertos valores de diámetro que predominan. Se calcula por medio de la siguiente formula:

$$Cc = \frac{D_{30}^2}{D_{10} * D_{60}}$$

D60: es el diámetro para el cual el 60% de las partículas son más finas.

D10: es el diámetro para el cual el 10% de las partículas son más finas.

D30: es el diámetro para el cual el 30% de las partículas son más finas.

Estos conceptos Cu y Cc encontrados en (González Ovalle, 2014) y (ASTM D422, 1998).


Cuadro N° 13. Gradación de grava y arena.

Well graded	Gravel content > sand content	$Cu \geq 4 \wedge 1 \leq Cc \leq 3$
	Sand content > gravel content	$Cu \geq 6 \wedge 1 \leq Cc \leq 3$
Poorly graded	Gravel content > sand content	$Cu < 4$ y/o $1 > Cc > 3$
	Sand content > gravel content	$Cu < 6$ y/o $1 > Cc > 3$

Nota: extraído de (Budhu, *Soil mechanics fundamentals*, 2015, p. 08).

La forma de la curva de gradación indica la variedad de partículas en un suelo. La curva de gradación de un suelo mal graduado es casi vertical u horizontal, es la ausencia de ciertos tamaños de grano, se diagnostica mediante un cambio repentino de pendiente en la curva o puede presentar varios cambios repentinos como se muestra en la Figura. El valor mínimo de Cu es 1 que representa a un conjunto de partículas del mismo tamaño. Mientras que una curva con una pendiente ligera son aquellas que son bien graduados (Budhu, 2015, p. 12).

Figura 4. Distribución granulométrica.



Tomado de (Budhu, 2015, p. 12).

Influencia de la distribución granulométrica sobre parámetros de resistencia

Para una clasificación de suelo, la distribución granulométrica define si un suelo pertenece a gravas, arena, limos o arcillas, por consiguiente para este tipo de suelos tienen un efecto grande en los parámetros de resistencia al corte. Muchos autores estiman un aproximado de valores referidos al ángulo de fricción interna, por el tipo de suelo. Como por ejemplo en los siguientes cuadros.

Cuadro N° 14. Valores ϕ representativos según el tipo de suelo normalmente consolidado.

Material	Φ° , suelto	Φ° , denso
Arena, granos redondos, uniforme	27.5	34
Arena, granos angulares, bien graduado	33	45
Gravas arenosas	35	50
Arena limosa	27-33	30-34
Limo inorganico	27-30	30-35

Nota: extraído de (Terzaghi & Peck, 1973, p. 106) , se citó en (Arora, 2004).

Cuadro N° 15. Resumen de ángulo de fricción por clasificación de suelo.

Clasificación	Angulo de fricción interna $\emptyset^\circ$			
	Angulo de talud natural $\emptyset_i^\circ$	Resistencia natural $\emptyset_{cr}^\circ$	Resistencia máxima	
			Media compacta $\emptyset^\circ$	Compacta $\emptyset^\circ$
Grava y arena	32 - 36	32 - 36	36 - 42	40 - 48
Arena bien graduada	30 - 34	30 - 34	34 - 40	38 - 46
Arena uniforme fina a media	26 - 30	26 - 30	30 - 34	32 - 36
Limo (no plástico)	26 - 30	26 - 30	28 - 32	30 - 34

Nota: dentro de cada gama se asignan los valores menores si las partículas son redondeadas y si existe un contenido importante de arcilla blanda o mica, mientras que los valores más elevados corresponden a partículas duras, angulosas. (Hough, 1957), como se citó en (Lambe y Whitman, 2012, p. 163).

En el siguiente cuadro se puede ver la influencia de la gradación de las partículas del suelo, estos valores representan en gran medida a suelos granulares.

Cuadro N° 16. Influencia de granulometría y angulosidad sobre ángulo de fricción máximo

Forma y granulometría	Φ° , suelto	Φ° , compacta
Redondeada, uniforme	30	37
Redondeada, bien graduada	34	40
Angulosa, uniforme	35	43
Angulosa, bien graduada	39	45

Nota: extraído de (Lambe y Whitman, 2012, p. 161).

Cuadro N° 17. Hidraulic conductivity.


Type of soil	k (m/s)
gravel	$10^{-3} - 10^{-1}$
sand	$10^{-6} - 10^{-3}$
silt	$10^{-8} - 10^{-6}$
clay	$10^{-10} - 10^{-8}$

Otro de los aspecto que cabe recalcar es la influencia en la conductividad hidráulica del material, ya que para en suelos granulares unos de sus características es su alta permeabilidad (Verruijt, 2006).

Límites de consistencia

“También conocidos como límites de Atterberg o límites de plasticidad, caracterizan el comportamiento de los suelos finos”, (Instituto Profesional Centro De Formación Técnica, 2015). Es comportamiento de un suelo frente a contenido de agua, ya sea como semilíquido, plástico, semisólido o sólido (Das, 2012, p. 15).

Figura 5. Cambios de estado en función a volumen y contenido de agua de un suelo



Nota: extraído de (Budhu, 2015, p. 36).

Además Das (2012, p. 15) y Barnes (1995, p. 26), coinciden en la definición de que cuando el suelo cambia de un estado líquido a un estado plástico, el contenido de humedad cuando ocurre tal cambio se define como límite líquido (LL), si el suelo cambia de un estado plástico a uno semisólido límite plástico (LP) y de un estado semisólido a uno sólido se define como límite de contracción (LC).

$$IP = LL - LP$$


Conceptos y procedimientos generales del ensayo, según las normas técnicas

El ensayo para determinar los límites de consistencia, está estandarizado por entidades internacionales como ASTM (D-4318: *Standard Test Methods for Liquid Limit, Plastic Limit, and Plasticity Index of Soils*) o por países como en Perú NTP 339.129 *suelos. Método de ensayo para determinar el límite líquido, límite plástico e índice de plasticidad de suelos*.

El límite líquido se determina usando el uso de copa de Casagrande; y se define como el contenido de humedad en el que se cierra una ranura de 12.7 mm con 25 golpes, con una frecuencia de 2 golpes por segundo y una altura de caída de 1 cm.

El límite plástico es el contenido de humedad donde el suelo cambia de un estado semisólido a un estado plástico, es cuando el suelo se agrieta al formar un rollito de 3.18 mm de diámetro. El índice de plasticidad IP es la diferencia entre el límite líquido y el límite plástico [ASTM D4318 \(2000\)](#).

Figura 6. *Copa de Casagrande LL y rodillos para LP.*




Nota: extraído de ASTM D4318 (American Society for Testing and Materials, 2000, pp. 10-18).

Influencia de los límites de consistencia sobre parámetros de resistencia

Existen muchos autores que estudiaron la relación y la influencia de los límites de consistencia en los parámetros de resistencia al suelo.


En la siguiente figura se tiene una relación frente al ángulo de fricción interna, con una relación de tipo parabólica, según la gráfica describe una correlación negativa ([Terzaghi y Peck, 1973, p. 111](#)).

Figura 7. *Correlacion IP y angulo de friccion.*



Nota. Relación entre ϕ en condiciones drenadas e índice plástico para arcillas de sensibilidad mediana a baja, (Terzaghi y Peck, Mecanica de suelos en la ingeniería practica, 1973).

Figura 8. Correlacion entre índice plasticp I_p y ϕ .




Nota: Datos de varias fuentes Ladd et al. (1977), Bjerrum y Simons (1960), Kanja y Wolle (1977), Olsen et al. (1986), estos citados en (Bowles, *Foundation analysis and design*, 1997, p. 108).

Una relación que se utiliza comúnmente según (Arora, 2004, p. 344) es.

$$\text{sen}\phi' = 0.814 - 0.234\log_{10}I_p$$

En la siguiente figura se muestra la tendencia del ángulo de fricción efectivo ϕ' , en arcillas normalmente consolidadas (Bjerrum y Simons, 1960; Kenney, 1959), citado en (Das, 2012, p. 55). Si bien se trata de suelos arcillosos, cabe resaltar la influencia negativa del índice plástico en el ángulo de fricción interna efectivo.

Figura 9. Correlacion entre índice plasticp I_p y $\text{sen}\phi$.



Nota: Datos de varias fuentes consolidadas (Bjerrum y Simons, 1960; Kenney, 1959), citado en (Das, 2012, p. 55).

Un dato interesante expuesto por Budhu (2015), que los límites dependen del tipo de mineral predominante. Si la montmorillonita es el mineral predominante, el límite líquido puede exceder el 100%, por ende afectan negativamente al ángulo de fricción interna (p. 38).

Según Scott (1980) hace mención a materiales cementantes intergranulares (minerales como óxido de hierro, sílice o calcita), el mineral forma un cemento entre las partículas, aumentando la resistencia al corte (cohesión) y reduciendo la compresibilidad del suelo (p. 04).

Contenido de humedad

Relación existente entre el peso del agua y el peso seco del suelo, puede ser expresada en porcentaje, (Terzaghi y Peck, 1973, p. 25), (Arora, 2004, p. 15), (Gardner et al., 1973) y (Crespo Villalaz, 2004, p. 64).

$$w\% = \frac{M_w}{M_{ss}} * 100$$

W%: Contenido de humedad en porcentaje.

Mw: Masa de agua.

Mss: Masa de suelo seco.

Los contenidos de humedad de los suelos naturales dependerán de su grado de saturación, pero pueden variar considerablemente desde menos del 5% para una arena "seca" hasta varios cientos para una arcilla montmorillonítica o una turba. Se presenta una tabla con los rangos de humedad para condiciones naturales, sin incluir la saturación (nivel freático).

Cuadro N° 18. Contenido de humedad típica.

Tipo de suelo	Contenido de humedad %
Arena húmeda	5-15
Arena mojada	15-25
Limo húmedo	10-20
Limo mojado	20-30
Arcilla NC de baja plasticidad	20-40
Arcilla NC de alta plasticidad	50-90
Arcilla OC de baja plasticidad	10-20
Arcilla OC de alta plasticidad	20-40
Arcilla orgánica	50-100
Arcilla de muy alta plasticidad	100-200
turbas	100-1000

Nota: NC: Normalmente Consolidado, OC: Sobre Consolidado, Tomado de (Barnes, 1995, p. 25).

Conceptos y procedimientos generales del ensayo, según las normas técnicas

Para determinar el contenido de agua o contenido de humedad, está estandarizado por entidades internacionales como ASTM (D-2216: *Standard Test Methods for Laboratory Determination of Water (Moisture) Content of Soil and Rock by Mass*) o por países como en Perú NTP 339.127 *suelos. Método de ensayo para determinar el contenido de humedad de un suelo*.

El procedimiento según la norma ASTM D2216 para determinar la humedad en suelos requiere preparar una muestra del material, pesarla antes y después de secarla completamente en un horno a una temperatura controlada de $110 \pm 5^\circ\text{C}$. La diferencia de peso antes y después del secado se utiliza para calcular el contenido de agua y esto se compara con el peso seco del suelo, ofreciendo así una medida de la humedad presente en el suelo (ASTM D2216).

Correlaciones e influencia de contenido de agua sobre otras variables.

La influencia negativa del contenido de agua en los parámetros de resistencia es mínima en suelos con escasas partículas finas, mientras que en suelos de tipo limoso o aquellos con muchas partículas finas la influencia es marcada, debido al debilitamiento del cementante a causa del efecto del agua.

Cuadro N° 19. Relación contenido de humedad y los tipos de suelo

Tabla 3.1 Relación de vacíos, contenido de humedad y peso unitario seco para algunos tipos de suelo en estado natural

Tipo de suelo	Relación de vacíos, e	Contenido natural de humedad en un estado saturado (%)	Peso unitario seco, γ_d (kN/m ³)
Arena uniforme floja	0.8	30	14.5
Arena uniforme densa	0.45	16	18
Arena limosa angular de grano flojo	0.65	25	16
Arena limosa angular de grano denso	0.4	15	19
Arcilla dura	0.6	21	17
Arcilla blanda	0.9–1.4	30–50	11.5–14.5
Loess	0.9	25	13.5
Arcilla orgánica suave	2.5–3.2	90–120	6–8
Cajón glacial	0.3	10	21

Encontrado en (Das, Fundamentos de ingeniería geotécnica., 2015, p. 55)

Grado de Saturación de los suelos

La definición de saturación según (Terzaghi y Peck, 1973), es una medida cuantitativa de la proporción de los poros del suelo que están llenos de agua, expresado en porcentajes.

$$S = \frac{V_w}{V_e} * 100$$

V_w : es el volumen de agua en los poros del suelo,

V_e : es el volumen total de poros en el suelo.

Un suelo está completamente saturado cuando el 100% de sus poros están llenos de agua ($S = 100\%$). En este estado, no hay aire en los poros del suelo. Un suelo parcialmente saturado tendrá un grado de saturación menor al 100%, lo que significa que algunos de los poros están llenos de aire o gases.

Cuadro N° 20. Grado de saturación de la arena.

Tipo de suelo	Grado de saturación %
seca	0
Ligeramente húmedo	1-25
Húmedo	26-50
Muy húmeda	51-75
Mojada	76-99
Saturada	100

Nota: Tomado de (Terzaghi et al., Soil mechanics in enginnering practice, 1996).

Los efectos de la saturación sobre la resistencia al corte de un suelo, es principalmente por presión de poros. Un suelo saturado, presión de poros generalmente es positiva afecta en la disminución del grado de contacto y la fuerza de atracción intergranular de un suelo. Mientras un suelo no saturado puede un suelo tener presión negativa (presión de succión) que junta las partículas del suelo, por ende, la tensión normal efectiva aumenta (la tensión normal total es constante) (Budhu, 2015, p. 239).

Densidad de un suelo

“The density of a substance is the mass per unit volume of that substance” [La densidad de una sustancia es la masa por unidad de volumen de esa sustancia], definición ubicado en (Das, 2012) y (Verruijt, 2006).

Jaramillo (2002). Expresa sin citar ningún autor que, la densidad de cualquier material se entiende como su masa por unidad de volumen. En el caso de los suelos, que son porosos por naturaleza, podemos hablar de dos tipos de densidad. La primera, denominada densidad real, se refiere únicamente a la masa de las partículas sólidas. La segunda, conocida como densidad aparente, considera no solo la masa de estas partículas sino también cómo están dispuestas u organizadas.

Densidad real (Dr)

La densidad real, refiere al peso de las partículas sólidas en el suelo en relación con su volumen, excluyendo la organización y los espacios porosos; esto implica que está influenciada por la composición mineral y la presencia de elementos como materia orgánica y óxidos de hierro. Crespo Villalaz (2004), Forsythe (1985), Montenegro Gonzales y Malagon Dimas (1990), Motta et al. (1990).

Densidad aparente (γ_d)

Es la densidad del suelo que se calcula teniendo en cuenta el espacio ocupado por los poros al cuantificar el volumen de la muestra de suelo, razón por la cual depende de la organización que presente la fracción sólida del mismo y está afectada por su textura, su estructura, su contenido de materia orgánica, su humedad (en especial en suelos con materiales expansivos) y su grado de compactación, principalmente [Crespo Villalaz \(2004\)](#), [Forsythe \(1985\)](#), [Montenegro Gonzales y Malagon Dimas \(1990\)](#), [Motta et al. \(1990\)](#).

La densidad aparente de un suelo dependerá de la densidad de las partículas, las distancias entre las partículas o el estado de empaquetamiento y el grado de saturación o la cantidad de agua y aire en los espacios vacíos. Se muestra valores típicos para suelos saturados en la Tabla [\(Barnes, 1995, p. 24\)](#).

Cuadro N° 21. Densidades típicas, suelos saturados.

Tipo de suelo	Densidad g/cm ³
Grava y arena	1.6-2.2
Limo	1.6-2.0
Arcilla suelta	1.7-2.0
Arcilla densa	1.9-2.3
Turba	2.0-2.3
Roca intacta débil	1.8-2.1
Roca débil triturada	2.4-2.7
Roca dura intacta	1.9-2.2
Roca dura triturada	1.6-2.0

Peso específico seco (γ_d)

El peso específico seco de un suelo es una propiedad física que describe la masa de un suelo seco por unidad de volumen. La fórmula para el peso específico seco (γ_d) es:

$$\gamma_d = \frac{W_s}{V}$$

γ_d : Peso específico seco.

W_s : Peso del suelo sólido seco.

V : Volumen de la muestra.

Esta propiedad es esencial en la mecánica de suelos y la ingeniería geotécnica, ya que proporciona información sobre la compactación y densidad de un suelo, lo que a su vez influye en sus propiedades de resistencia y deformación [\(Lambe y Whitman, 2012\)](#) y [\(Das y Sobhan, 2018\)](#).

Cuadro N° 22. Compacidad máxima y mínima de suelos granulares.

<u>Forma y granulometría</u>	<u>Relación de vacíos</u>		<u>Porocidad (%)</u>		<u>Peso específico seco g/cm³</u>	
	e_{min}	e_{max}	n_{min}	n_{max}	Yd_{min}	Yd_{max}
Arena de Ottawa normalizada	0.50	0.80	33	44	1.47	1.76
Arena limpia uniforme	0.40	1.0	29	50	1.33	1.89
Limo inorgánico	0.40	1.1	29	52	1.28	1.89
Arena Limosa	0.30	0.90	23	47	1.39	2.03
Arena fina a gruesa	0.20	0.95	17	49	1.36	2.21
Arena micácea	0.40	1.2	29	55	1.22	1.92
Arena limosa y grava	0.14	0.85	12	46	1.42	2.34

Nota: Describe la densidad aparente seco, fuente Basic soils Engineering (Hough, 1957), citado en (Lambe y Whitman, 2012).


Conceptos y procedimientos generales del ensayo, según las normas técnicas

Uno de los ensayos que se obtiene la densidad aparente de un suelo es ASTM (D-1556: *Standard Test Method for Density and Unit Weight of Soil in Place by Sand-Cone Method*) o NTP 339.143 suelos. *Método de ensayo estándar para la densidad y peso unitario del suelo in-situ mediante el método del cono de arena, normalizado en Perú.*

Consiste en un frasco de vidrio o plástico con un embudo adherido al cuello del frasco. El procedimiento resumido para una prueba de cono de arena es el siguiente:

- 🔧 Llene el frasco con arena estándar (una arena con densidad conocida) y determine la masa del aparato de cono de arena con el frasco lleno de arena.
- 🔧 Determine la masa de arena para llenar el cono.
- 🔧 Excave un pequeño agujero en el suelo y determine la masa del suelo excavado.
- 🔧 Determine el contenido de agua del suelo excavado.
- 🔧 Llene el orificio con arena estándar invirtiendo el aparato de cono de arena sobre el orificio y abriendo la válvula.
- 🔧 Determine la masa del aparato de cono de arena con la arena restante en el recipiente.

Figura 10. Cono de arena.



Nota: Conseguido de (Budhu, Soil mechanics fundamentals, 2015, p. 137).

Correlaciones e influencia de densidad sobre los parámetros de resistencia del suelo

El efecto que produce la densidad sobre la resistencia de un suelo, es cuando más denso sea un material más resistente al corte será un suelo, reflejado en el aumento del ángulo de fricción interna efectivo y la cohesión, extraído de (Das y Sobhan, 2018, pp. 470-471).

Cuadro N° 23. Valores típicos de ángulo de fricción drenado para arenas y limos.

Tipo de suelo	Φ°
Arena: granos redondeados	
suelto	27-30
Intermedio	30-35
Denso	35-38
Arena: granos angulosos	
suelto	30-35
Intermedio	35-40
Denso	40-45
Grava con poca arena	34-48
Limo inorganico	26-35

Nota: extraído de (Das y Sobhan, Principles of Geotechnical Engineering., 2018, p. 470).

Para arenas, el ángulo de fricción suele variar de 26° a 45°, aumentando con la densidad relativa de compactación (Das, 2015, p. 230).

Cuadro N° 24. Influencia de granulometría y angulosidad sobre ángulo de fricción máximo

Empaquetamiento	Densidad relativa (%)	Angulo de fricción efectiva Φ°
Muy suelto	Menor a 20	Menor a 30
Suelto	20-40	30-35
Compacto	40-60	35-40
Denso	60-80	40-45
Muy denso	Más de 80	Más de 45

Nota: extraído de (Das, Fundamentos de ingeniería geotécnica., 2015, p. 230).

2.3.4. Resistencia al corte de un suelo

Es la última o máxima resistencia que el suelo puede soportar antes de la falla. Se ha expresado como la resistencia interna que ofrece la masa de suelo por área unitaria para resistir la falla al deslizamiento a lo largo de cualquier plano dentro de él (Das, 2015, p. 228) y (Valerio salas, 2011).

A continuación se describen brevemente los aportes de importantes personalidades, para la mecánica de suelos:

Otto Mohr:

Aunque el enfoque de Mohr no fue principalmente en la mecánica de suelos, su aporte crucial se encuentra en la resistencia de materiales. Desarrolló el círculo de Mohr, una herramienta gráfica utilizada para representar gráficamente las tensiones y los esfuerzos de un material en un punto específico. En mecánica de suelos, el círculo de Mohr se aplica para analizar el estado de esfuerzos y deformaciones en suelos, lo que es esencial para el diseño y análisis de estructuras geotécnicas.

Charles-Augustin de Coulomb:

Coulomb realizó importantes aportaciones al entendimiento de la resistencia al corte de los suelos. Formuló la teoría del corte y estableció principios fundamentales para el análisis de la estabilidad de taludes y cimentaciones. Introdujo conceptos clave como la cohesión y la fricción en el estudio de la resistencia al corte de los suelos.

Karl von Terzaghi:

Terzaghi es reconocido como el "padre de la mecánica de suelos". Sus contribuciones fueron esenciales para el desarrollo de la ingeniería geotécnica moderna. Introdujo conceptos como la consolidación, permeabilidad y capacidad portante de los suelos. Desarrolló teorías para analizar el comportamiento de los suelos bajo carga y formuló principios prácticos para el diseño de cimientos y estructuras sobre suelos.

Terzaghi introdujo y definió conceptos claves como el ángulo de fricción interna y la cohesión efectivo-total como parámetros críticos para entender y predecir el comportamiento mecánico de los suelos.


$$\sigma' = \sigma - u$$

σ' : Esfuerzo efectivo

σ : Esfuerzos totales

u : Presión de poros

Figura 11. Esfuerzo cortante vs esfuerzo normal efectivo y totales




Tomado de (Das y Sobhan, *Principles of Geotechnical Engineering.*, 2018)

Descrito a las personalidades importantes, el esfuerzo cortante en los suelos es una variable importante de la ingeniería geotécnica. Por consecuencia, tanto las estructuras como los taludes deben ser estables y seguros frente a un colapso, cuando éstos sean aplicados a máximas cargas (Holtz et al., 2011).

El comportamiento de deformación de este elemento se representa mediante una gráfica de esfuerzo cortante versus deformación cortante, recordar que el esfuerzo normal es constante. A tensiones cortantes pequeñas, la respuesta es lineal hasta que se alcanza el límite elástico; más allá de este punto comienza a producirse deformación plástica (endurecimiento por trabajo). Después del límite elástico, el esfuerzo cortante continúa aumentando y finalmente alcanza un valor máximo (o punto de falla), es decir, la resistencia cortante máxima del elemento correspondiente al esfuerzo normal aplicado. Una mayor deformación por corte hace que la tensión de corte disminuya (ablandamiento por trabajo) a un valor último que representa un estado crítico en el que el material falla mientras se mantiene un volumen constante. Los planos de falla pueden desarrollarse antes o después del estado crítico, lo que lleva a una resistencia al corte constante llamada resistencia residual. Sin embargo, este estado sólo se puede alcanzar con cepas muy grandes. En suelos sobreconsolidados, los planos de falla pueden desarrollarse inmediatamente después del punto pico y es posible que no se obtenga el estado crítico y el estado del elemento se desplace hacia el residual. Un suelo normalmente consolidado puede no tener una resistencia máxima y el estado crítico puede obtenerse con deformaciones relativamente bajas (Aysen, 2002, p. 114).

Figura 12. Deformacion vs esfuerzo cortante.



Nota: Conseguido de (Aysen, 2002, p. 114).

Existen modelos que interpretan el esfuerzo al corte de un suelo, a continuación se hace mención a los tres modelos.

Cuadro N° 25. Criterios de falla.

Nombre	Criterios de falla	Suelo	Mejor uso para	Interpretación de datos de ensayo
Coulomb.	La falla ocurre por deslizamiento inminente por fricción en un plano.	Material rígido y friccional	Suelos sobreconsolidados estratificados o fisurados o un suelo donde existe un plano previo a la falla	Corte directo
Morh-Coulomb	La falla ocurre por deslizamiento inminente por fricción en el plano de máxima oblicuidad de la tensión efectiva principal.	Material rígido y friccional	Resistencia a largo plazo (condición drenada) de suelos sobreconsolidados de grano fino y densos de grano grueso	Triaxial
Tresca	La falla ocurre cuando se alcanza la mitad de la diferencia máxima de tensión principal.	Material sólido homogéneo	Resistencia a corto plazo (condición no drenada) de suelos de grano fino	Triaxial

Nota: extraído de (Budhu, Soil mechanics fundamentals, 2015, p. 254)

En esta investigación extenderemos el concepto del Criterio de falla de Mohr-Coulomb.

Criterio de falla de Mohr-Coulomb

Mohr (1900), presentó una teoría para la ruptura en los materiales. Esta teoría sostiene que un material falla debido a una combinación crítica de esfuerzo normal y esfuerzo cortante, y no de cualquier esfuerzo máximo normal o cortante solo.

$$\tau_f = f(\sigma)$$

τ_f : esfuerzo cortante en el plano de falla
 δ : esfuerzo normal en el plano de falla

La anterior función es una curva. Con fin de simplificar la mayoría de los problemas de mecánica de suelos, el esfuerzo cortante sobre el plano de falla estableció como una función lineal del esfuerzo normal (Coulomb, 1776), citado en (Das, 2015, p. 229).

Ecuación de falla Mohr-Coulomb.


$$\tau_f = c + \sigma * \tan \phi$$

c : cohesión

ϕ : Esfuerzo

ϕ : ángulo de fricción interna

Figura 13. Envolvente de falla de Mohr y criterio de rotura de Mohr-Coulomb.



Nota: Conseguido de (Das, Fundamentos de ingeniería geotécnica., 2015, p. 230).

El modelo de Mohr-Coulomb establece que la rotura del terreno es por cizallamiento (o falla) del suelo. Cuando una porción de suelo está sometida a una tensión normal-vertical-axial (σ_1) y a una radial-horizontal-confinamiento (σ_3), si aumentamos la tensión vertical, según sean las propiedades resistentes y la tensión horizontal, el terreno “fallará” una vez superada su resistencia al esfuerzo cortante. Ojo, no aplicamos ningún esfuerzo cortante (τ), este se produce en el plano de falla debido al entorno tensional (σ_1 y σ_3).

Ecuación de Coulomb en términos de esfuerzos efectivos, se tiene:

$$\sigma = \sigma' + u \quad ; \quad \tau_f = c' + \sigma' \tan \phi'$$

En la cual los parámetros c' y ϕ' son propiedades del esqueleto del suelo, denominadas cohesión efectiva y ángulo de fricción efectiva, respectivamente.

Condiciones de ensayo

Existen tres tipos de condiciones para la determinación de resistencia al corte:

- Prueba lenta - Prueba con consolidación y con drenaje (CD)
- Prueba rápida – Prueba con consolidación y sin drenaje (CU)
- Prueba rápida - Prueba sin consolidación y sin drenaje (UU)

Características de corte de suelos sin cohesión

La resistencia al corte de suelos no cohesivos, como arenas y limos no plásticos, se debe principalmente a la fricción entre partículas. En arenas densas, el entrelazamiento entre las partículas también contribuye significativamente a la resistencia.

Características de corte de suelos cohesivos

Las características de corte de un suelo cohesivo dependen de si un suelo está normalmente consolidado o sobreconsolidado. La curva tensión-deformación de una arcilla sobreconsolidada es similar a la de una arena densa y la de una arcilla normalmente consolidada es idéntica a la de una arena suelta. Para arcillas muy sobreconsolidadas, se desarrolla una presión de poro negativa durante el corte y la resistencia no drenada es mayor que la resistencia drenada.

Cuadro N° 26. Cohesión en suelos arcillosos

N°	suelo	Cohesión (kN/m ²)
1	Arcilla muy blanda	<12
2	Arcilla medianamente blanda	12-25
3	Arcilla compacto	50-100
4	Muy compacto	100-200
5	Duro	>200

Encontrado en (Arora, 2004, p. 345)

Para suelos no cohesivos y normalmente consolidados, estas tres pruebas CD, CU y UU dan el mismo resultado, esté la muestra saturada o no, si la aplicación del corte sea lenta, esta afirmación claro es de forma teórica, poniendo en la práctica existe una ligera variación. Para materiales cohesivos, los parámetros de suelos están muy marcado por la influencia por el tipo de prueba, por el grado de saturación, y por que el material esté sobre consolidado o normalmente consolidado. Para suelos sobreconsolidados se distinguen dos grupos de parámetros de resistencia: uno para pruebas bajo cargas menores a la de preconsolidación y otro para aquellas sobre esta presión. En presencia de esfuerzos de preconsolidación en suelos cohesivos, se recomienda realizar seis o más pruebas para asegurar la correcta identificación de los parámetros de resistencia al corte.

Estimaciones de ángulo de fricción por esfuerzo efectivo y de la cohesión efectiva.

Brinch Hansen (1970, se citó en Thinh, 2001), proporcionó la siguiente correlación para suelos granulares.

$$\phi'^0 = 26^\circ + 10Dr + 0.4Cu + 1.6 \log (D50)$$

Dr : densidad relativa (fracción)

Cu : coeficiente de uniformidad

D50 : tamaño medio del grano, en mm (es decir, el diámetro a través del cual pasa 50% del suelo) (Thinh , 2001).

Sin embargo, en el caso de arena limpia, es razonable suponer $c' = c = 0$ e $\phi' = \phi$. La magnitud de ϕ' o ϕ en un suelo arenoso varía de 25° a 45° dependiendo del tipo de suelo y la densidad, mientras que, en un suelo arcilloso, puede variar de 0 a 25° dependiendo del tipo de suelo, contenido de humedad y condiciones de drenaje. En condiciones sin drenaje, la cohesión (c ,) varía de 10 kPa a 100 kPa o más, dependiendo de la densidad del suelo (Aysen, 2002, pág. 116).

Según (Das, 2008, pág. 374), “the shear strength of a soil can be defined as $s = c + \sigma' \tan \phi$. For granular soils with $c = 0$ ” [la resistencia al corte de un suelo se puede definir como $s = c + \sigma' \tan \phi$. Para suelos granulares con $c = 0$].

El valor de c' para arena y limo inorgánico es 0. Para arcillas normalmente consolidadas, c' se puede aproximar a 0. Las arcillas sobreconsolidadas tienen valores de c' mayores que 0. El ángulo de fricción, ϕ' se refiere al ángulo de fricción de drenado.

Para arcillas normalmente consolidadas, el ángulo de fricción ϕ' varía generalmente entre 20° y 30° . Para arcillas sobreconsolidadas, la magnitud de ϕ' disminuye. Para arcillas naturales sobreconsolidadas no cementadas, con una presión de preconsolidación aproximadamente menor a 10.2 kg/cm², la magnitud de c' está en el intervalo de 0.051 a 0.153 kg/cm² (Das, 2015, pág. 229).

El esfuerzo cortante puede ser determinado de muchas maneras, algunos de los ensayos más comunes como la veleta (ASTM D 4648), ensayos de penetración estándar SPT (ASTM D 1586), compresión uniaxial (ASTM D 2166), corte directo (ASTM D 3080 y ASTM D 6528) y los ensayos de compresión triaxial (ASTM D 4767 y ASTM D 2850).

En la literatura de mecánica de suelos, la mayoría de los autores concuerdan que el valor de c' para arenas es igual a cero y en suelos granulares cercanas a cero. Para arcillas sobre consolidadas $c' \gg 0$.

En este trabajo de investigación, como se mencionó en la delimitación temática, se toma solo las pruebas consolidadas drenadas, que se realizaran en equipo de corte directo ASTM D 3080. Por lo que los parámetros de resistencia al corte, están en términos de esfuerzos efectivos c' y ϕ' .

El ensayo de corte directo a menudo se realiza en condiciones de drenaje no restringido. Esto puede no reflejar completamente las condiciones del campo, donde el drenaje puede estar restringido y afectar la resistencia al corte del suelo. Es importante reconocer estas desventajas y considerarlas al interpretar los resultados del ensayo de corte directo. En muchos casos, se recomienda utilizar múltiples métodos de prueba y considerar la información de manera integral para obtener una evaluación más completa de las propiedades del suelo.

2.3.5. Ensayo de corte directo


El ensayo de corte directo implica provocar el deslizamiento de una sección del suelo respecto a otra a través de un plano de falla ya establecido, aplicando una fuerza horizontal creciente, mientras se mantiene una carga vertical sobre el plano de deslizamiento, este proceso se repite para 3 o 4 cargas verticales.

Figura 14. Equipo de corte directo



Nota: Equipo en la que se realiza ensayo de corte directo. Tomado de konstrutecnia, <https://konstrutecnia.com/p/ensayo-de-corte-directo-926>.

Figura 15. Criterio de falla de Mohr-Coulomb de una prueba de corte directo



Nota, Prueba de corte directo en arena: a) diagrama esquemático del equipo de prueba; b) gráfica de los resultados de la prueba para obtener el ángulo de fricción Tomada de (Das, Fundamentos de ingeniería de cimentaciones, 2012, pág. 48).

La carga normal se aplica para dar un esfuerzo normal de 25 kN/m². Luego se aplica una carga de corte con un grado de deformación constante. Para pruebas sin drenaje, la velocidad generalmente está entre 1,0 mm y 2,00 mm por minuto. Para pruebas con drenaje, la velocidad de deformación depende del tipo de suelo. Para suelos arenosos se podrá tomar como 0,2 mm/minuto; mientras que para suelos arcillosos generalmente es entre 0,005 y 0,02 mm/min. La prueba se repite bajo una tensión normal de 50, 100, 200 y 400 kN/m (Arora, 2004).

Elección de condiciones de prueba y parámetros de corte

Las condiciones de prueba y los parámetros de corte deben elegirse para representar las condiciones de campo lo más fielmente posible.

En el caso de suelos de grano grueso, el drenaje se produce rápidamente durante la aplicación de la carga. Las pruebas en estos suelos generalmente se llevan a cabo en condiciones drenadas y, por lo tanto, las pruebas con drenaje consolidado son más comunes. Sin embargo, en algunos casos especiales, cuando grandes masas de arenas finas y saturadas están sujetas a cargas rápidas debido a terremotos u otras causas, las condiciones sin drenaje son más relevantes (Arora, 2004).

Para Arora (2004), Se pueden realizar pruebas de corte directo para cualquiera de las tres condiciones de drenaje. Para la prueba U-U, se utilizan rejillas planas y la muestra se corta rápidamente. Para la prueba CU se utilizan rejillas perforadas. La muestra se consolida bajo la carga normal y una vez completada la consolidación, se corta rápidamente en aproximadamente 5 a 10 minutos. En una prueba de CD, la muestra se consolida bajo la carga normal y luego se corta lentamente para que se disipe el exceso de presión de agua de los poros. Una prueba de CD puede tardar algunas horas en suelos sin cohesión. Para suelos cohesivos, puede tardar de 2 a 5 días.

El ensayo de corte directo se realiza generalmente en suelos no cohesivos como ensayo CD. Es cómodo de realizar y da buenos resultados en los parámetros de fuerza. Ocasionalmente se utiliza para determinar los parámetros de resistencia del limo y la arcilla en condiciones no consolidadas, sin drenaje y con drenaje consolidado, pero no ofrece la flexibilidad de una prueba de compresión triaxial, como se explica más adelante (Arora, 2004, pág. 15).

Conceptos y procedimientos generales del ensayo, según las normas técnicas

El ensayo para determinar los parámetros de resistencia mediante el ensayo de corte directo, que están normalizados por entidades internacionales como ASTM D 3080 Direct Shear Test of Soils Under Consolidated Drained Conditions o por países como en Perú NTP 339.171 Suelos. Método de ensayo estándar para ensayo de corte directo de suelos bajo condiciones consolidadas drenadas.

Preparación de la muestra: Se toma una muestra representativa del suelo, se prepara adecuadamente y se coloca en la caja de corte directo, ajustando sus dimensiones y humedad para el ensayo.

Aplicación de carga normal: Se ejerce una carga vertical sobre la muestra para simular el peso de las capas de suelo superiores o estructuras, ajustando la magnitud de esta carga según el objetivo del estudio.

Ejecución del corte: Manteniendo fija la parte superior de la caja y con la carga normal ya aplicada, se mueve horizontalmente la parte inferior a una velocidad constante, generando un plano de corte en la muestra.

Medición y registro: Se mide la fuerza de corte requerida para el deslizamiento y el desplazamiento horizontal, así como la carga normal, durante el ensayo.

Cálculo de propiedades: Utilizando los datos obtenidos, se calculan la cohesión y el ángulo de fricción interna del suelo, basándose en la resistencia al corte en relación con la carga normal.

Repetición con diversas cargas normales: Para una evaluación completa, el ensayo se realiza varias veces con diferentes cargas, permitiendo elaborar una curva de envolvente de falla para extraer los valores precisos de cohesión y ángulo de fricción interna.


2.3.6. Inteligencia artificial

La inteligencia artificial (IA) se basa a la idea de que las máquinas (ordenadores) procesan información como inteligencia humana mediante la creación y la aplicación de algoritmos creados en un entorno dinámico de computación. O bien, dicho de forma sencilla, la IA consiste en intentar que los ordenadores piensen y actúen como los humanos. Para conseguirlo, se necesitan tres componentes fundamentales:

-  Sistemas computacionales
-  Datos y gestión de los mismos
-  Algoritmos de IA avanzados (código)

Cuanto mayor sea el parecido al comportamiento humano que queremos conseguir, más datos y capacidad de procesamiento se necesitará (NetApp, s.f).

Figura 16. Esquema de rango de los IA.



Recopilado: de Bismart. <https://landing.bismart.com/inteligencia-artificial>


Machine Learning (ML) [aprendizaje automático]

Según Arthur Samuel, el aprendizaje automático se define como “el campo de estudio que da a las computadoras la capacidad de aprender sin estar explícitamente programado”. El aprendizaje automático se basa en diferentes algoritmos para resolver problemas de datos cabe señalar que hay ningún tipo de algoritmo de talla única que sea mejor para resolver un problema.

El Machine Learning es la práctica de programación de computadoras para aprender de los datos (Russell, 2018).

El tipo de algoritmo empleado depende en el tipo de problema que desea resolver, el número de variables, el tipo de modelo que le conviene más y así sucesivamente.

Figura 17. Machine learning.



Recopilado: de https://t4.ftcdn.net/jpg/05/44/23/33/240_F_544233360_Aqrxp2b6wtklkEBMtVpI0J8eVReDFilH.jpg

El aprendizaje automático es un concepto también amplio ya que engloba muchas variedades técnicas y algoritmos para el aprendizaje de la computadora. Sus subdisciplinas de machine learning se pueden clasificar de diversas maneras, dependiendo de los criterios

utilizados (por tipo de algoritmo, el tipo de datos, el tipo de aprendizaje, etc.). Aclarando que no hay una clara clasificación de las subdisciplinas.

Subdisciplinas clasificados por tipo de aprendizaje.

-  Aprendizaje Supervisado.
-  Aprendizaje no Supervisado
-  Aprendizaje por refuerzo.

Aprendizaje supervisado

El aprendizaje supervisado, también conocido como Machine Learning supervisado, es una subcategoría del Machine Learning y la inteligencia artificial. Se define por el uso de conjuntos de datos etiquetados para entrenar algoritmos que clasifiquen datos o predigan resultados de forma precisa. A medida que los datos se introducen en el modelo, este ajusta sus ponderaciones hasta que dicho modelo se haya ajustado adecuadamente, lo que ocurre como parte del proceso de validación cruzada, hasta que el error se haya minimizado lo suficiente.

La regresión es un tipo de aprendizaje supervisado que se utiliza para comprender la relación entre variables dependientes e independientes.

Los algoritmos supervisados más importantes:

-  K-Vecinos Más Próximos
-  Regresión Lineal
-  Redes Neuronales
-  Máquinas de Vectores de Soporte
-  Regresión Logística
-  Árboles de Decisión y Árboles Aleatorios (Russell, 2018).

Aprendizaje no supervisado

El aprendizaje supervisado, también conocido como Machine Learning supervisado, es una subcategoría del Machine Learning y la inteligencia artificial. Se define por el uso de conjuntos de datos etiquetados para entrenar algoritmos que clasifiquen datos o predigan resultados de forma precisa. A medida que los datos se introducen en el modelo, este ajusta sus ponderaciones hasta que dicho modelo se haya ajustado adecuadamente, lo que ocurre como parte del proceso de validación cruzada, hasta que el error se haya minimizado lo suficiente.

La regresión es un tipo de aprendizaje supervisado que se utiliza para comprender la relación entre variables dependientes e independientes.

Los algoritmos no supervisados más importantes son:

-  Clustering: Medias k, Análisis Jerárquico de Cluster.
-  Regla de asociación: Eclat, A priori.
-  Visualización y reducción de dimensionalidad: Núcleo PCA, distribuido de t PCA (Russell, 2018).

Aprendizaje por refuerzo

Es cuando un agente “Sistema AI” (Inteligencia Artificial) observará el ambiente, ejecutando diferentes acciones, y luego recibe recompensas a cambio. Con este tipo, el agente debe aprender por sí mismo. Es llamado una póliza (Russell, 2018).

Cabe indicar que existe un sub conjunto en machine learning, es utilizada dentro de estas clasificaciones, es el Deep Learning, ese sub conjunto debe más como una técnica

Cabe indica que el aprendizaje profundo es un tipo específico de aprendizaje automático, con lo cual la clasificación anterior puede estar dentro de esta. La diferencia es que el machine learning es un conjunto de herramientas estadísticas y matemáticas A continuación definimos el aprendizaje profundo (Deep Learning).

Deep Learning [aprendizaje profundo]


En 2006 de la mano de Geoffrey Hinton, que desarrolló una forma más eficiente de entrenar los modelos de deep learning, utilizando un aprendizaje por capas, la primera capa aprende características primitivas, que son enviadas a la siguiente capa, la cual se entrena para reconocer características más complejas y así sucesivamente hasta entrenar todas las capas del modelo. Este avance permitió entrenar arquitecturas mucho más profundas que las utilizadas hasta el momento y, por ello, se popularizó el término deep learning o aprendizaje profundo. A partir de entonces, las RNAs empezaron a aportar resultados muy superiores a los obtenidos con otras técnicas de aprendizaje automático y se han ido convirtiendo en una de las ramas más destacadas de la IA.

Modelos de aprendizaje profundo:

-  Modelo de perceptron de una capa (SLP)
-  Modelo de perceptron Multicapa (MLP)
-  Redes neuronales convolucionales (CNN)
-  Redes neuronales recurrentes (RNR)
-  Redes de creencia profunda (RNN) (Russell, 2018).

Modelo de perceptrón de una capa (SLP). Es el modelo más simple de redes neuronales, y es la base de modelos más sofisticados (redes profundas) que han sido desarrollados en este campo. Usualmente se usa en la clasificación de problemas con fin de “etiquetar” (pueden ser binarias o multinomiales) (Russell, 2018).


Figura 18. Modelo SLP.



Recopilado: de <https://blog.josemarianoalvarez.com/2018/06/10/el-perceptron-como-neurona-artificial/>.

Modelo de perceptrón Multicapa (MLP). Contiene muchas capas formando una red neuronal multicapa con el fin de pre-alimentarse. Se distingue del el otro modelo, ya que contiene el algoritmo de propagación hacia atrás (Russell, 2018).


Figura 19. Modelo MLP.



Recopilado: de <https://flutter.droppages.com/Apuntes/Dart/Perceptr%C3%B3n%20multicapa>.

Redes neuronales convolucionales (RNC). Son simplemente modelos que se usan para las aplicaciones de procesamiento de imagen computarizado. Tienen a las neuronas ordenadas en tres dimensiones (profundidad, altura, ancho) (Russell, 2018).


Figura 20. Modelo RNC.



Recopilado: de <https://www.datacamp.com/es/tutorial/introduction-to-convolutional-neural-networks-cnns>.

Redes neuronales recurrentes (RNR). Este tipo de modelo es una red neuronal artificial, o RNA (ANN) en las que las conexiones entre unidades forman un ciclo. Este modelo se usa para reconocimiento de lenguaje y escritura (Russell, 2018).


Figura 21. Modelo RNR.



Recopilado: de http://personal.cimat.mx:8181/~mriviera/cursos/aprendizaje_profundo/RNN_LSTM/introduccion_rnn.html.

Redes de creencia profunda RCP. Su estructura de la red Tiene cada sub red de cada capa escondida. Generalmente son un modelo multicapa (Russell, 2018).

Figura 22. Modelo RCP.




Recopilado: de <https://ia.smartecorganic.com.co/deep-learning/>.

Redes Neuronales artificiales

Un modelo sencillo de la neurona a lo más compleja, el fin es modelar correctamente el comportamiento global de toda la red, las características más relevantes, que entran en juego en su interacción con toda la red.

Figura 23. Estructura simple de una red neuronal.



Recopilado: de <https://estructurando.net/2012/04/30/inteligencia-artificial-aplicada-a-las-estructuras-otras-bestias-parte-i/>.

Lo que hace cada peso sináptico es simplemente multiplicar a su entrada correspondiente y define la importancia relativa de cada entrada (Izaurieta & Saavedra, s.f).

.

Menciona que la neuroredes se caracterizan principalmente por:

- ✓ Tener una inclinación natural a adquirir el conocimiento a través de la experiencia, el cual es almacenado, al igual que en el cerebro, en el peso relativo de las conexiones interneuronales.
- ✓ Tienen una altísima plasticidad y gran adaptabilidad, son capaces de cambiar dinámicamente junto con el medio.
- ✓ Poseen un alto nivel de tolerancia a fallas, es decir, pueden sufrir un daño considerable y continuar teniendo un buen comportamiento, al igual como ocurre en los sistemas biológicos.


Tener un comportamiento altamente no-lineal, lo que les permite procesar información procedente de otros fenómenos no-lineales (Izaurieta & Saavedra, s.f).

Capas de la red

- **Capa de entrada:** Se corresponde con el vector de datos de entrada. Si disponemos de un vector x de datos, cada elemento del vector ($x_1, x_2, x_3, \dots, x_n$) constituye una neurona de entrada.
- **Capa de salida:** Es la capa en la que se realiza la operación objetivo, por ejemplo, la clasificación. En ese caso, la capa de salida tiene tantas neuronas como clases presente el problema a tratar. Cada neurona tiene asociado un peso y un bias.

- **Capas ocultas:** Son las que contienen todos los cálculos intermedios de la red. Están formadas por neuronas ocultas, cada una de las cuales tiene un peso y un bias, al igual que las neuronas de la capa de salida. el número de capas ocultas es variable y no determinado. De hecho, la capacidad para manejar un gran número de capas ocultas es lo que hace profundo a este tipo de aprendizaje y cabe mencionar aquí sus beneficios.

Figura 24. Esquema de red neuronal y red neuronal de aprendizaje profundo.



Recopilado: de FotureSpace.

Forward y back propagation en Deep Learning son dos de los procesos más importantes en el desarrollo de este campo del manejo de los macrodatos.

Feedforward.

El feed-forward o pasada hacia delante consiste en calcular la salida de nuestra red con los valores actuales de los pesos. Para ello, siguiendo con nuestro ejemplo, lo que hacemos es alimentar (feed forward) la red con nuestro elemento de entrenamiento.

Algoritmo de retropropagación o backpropagation.

El proceso de aprendizaje consiste en propagar hacia atrás el error entre la salida obtenida y la salida esperada, que se pretende vaya disminuyendo en el transcurso de las iteraciones. Para calcular dicho error, se recurre habitualmente a la función del error cuadrático medio, que se define como:

$$e(n) = \frac{1}{2} \sum_{i=1}^{ns} (si(n) - yi(n))^2$$

Siendo: n cada una de las muestras de ejemplo; n_s el número de neuronas de la capa de salida; s_i e y_i la salida esperada y obtenida, respectivamente, en la neurona i de la capa de salida. Una vez calculado el error en cada muestra, $e(n)$, el objetivo es minimizarlo. Para ello, aplicando el método del descenso del gradiente, cada peso de la red w se actualiza para cada patrón de entrada n , siendo a la tasa de aprendizaje, de acuerdo a la siguiente expresión:


$$w(n) = W(n - 1) - a \frac{\partial e(n)}{\partial w}$$

Funciones de activación.

Es una función que transmite la información generada por la combinación lineal de los pesos y las entradas, es decir son la manera de transmitir la información por las conexiones de salida. La información puede transmitirse sin modificaciones, función identidad, o bien que no transmita la información. Como el objetivo es que la red neuronal sea capaz de resolver problemas cada vez más complejos. Entre las funciones de activación más conocidas.

-  Función Escalón, (similar a la función binaria.)
-  Fórmula de la función escalón
-  Función Sigmoidal.
-  Fórmula de la función sigmoideal
-  Función Rectificadora (ReLU).
-  Fórmula de la función rectificadora
-  Función Tangente Hiperbólica.
-  Fórmula de la función tangente hiperbólica
-  Funciones de Base Radial. (Gaussianas, multicuadráticas, multicuadráticas inversas...)

Figura 25. Diferentes funciones de activación.



Tomada de <https://keepcoding.io/blog/funcion-de-activacion-en-deep-learning/>

Esta función de activación es un elemento clave en las redes neuronales artificiales, pues es la que les otorga flexibilidad, proporcionándoles la capacidad de estimar complejas relaciones no lineales en los datos. La elección de la función de activación es una decisión trascendente, dada que cada función se ajusta mejor a unos u otros problemas. No obstante, estas funciones tienen un elevado coste computacional y en los últimos años se han visto reemplazadas por la función rectificadora (Rectified Linear Unit, ReLU) (González Muñiz, 2018),

Función ReLU. Introducida en el año 2000 por Hahnloser con motivaciones biológicas y matemáticas. Esta función tiene un menor coste computacional, pues en lugar de hacer cálculos con exponenciales, utiliza una simple operación de máximo. Adicionalmente, su forma, lineal y no saturada, proporciona a las redes la capacidad para evitar los problemas de bajo gradiente y permite acelerar la convergencia del entrenamiento. Por todo ello, la función ReLU se ha convertido en la más empleada para la activación de las capas ocultas (González Muñiz, 2018).

$$ReLU(a) = \max(0, a)$$

2.3. MARCO CONCEPTUAL.

Según Velásquez y Rey (2003), citado en (Supo Condori y Caverro Aybar, 2014). Es aquella a través del cual se definen las variables y términos con la cual está basado una investigación. Este proceso es necesario para no dejar margen alguno a las ambigüedades en enfoques o teorías sobre un mismo objeto de estudio y un mismo término (p. 291) .

2.3.7. Suelo granular

No existe una línea divisoria clara entre suelos cohesivos y no cohesivos. El término suelo cohesivo se utiliza para arcillas y limos plásticos, y el término suelo no cohesivo, para limos, arenas y gravas no plásticos (Arora, 2004, pág. 10).

Para esta investigación, los suelos granulares están compuestos por grava, arena, limo y con escaso o nulo contenido de arcilla, se caracteriza por su alta permeabilidad. Este tipo de suelo no presenta mucha resistencia cohesiva y, en ocasiones mostrar cierta cohesión aparente cuando este húmedo.

En la siguiente sección mencionaremos los diferentes suelos según la clasificación SUCS, que abarcan a un suelo granular, para esta investigación.

Cuadro N° 27. Clasificación SUCS considerados suelos granulares.

Empaquetamiento	SUCS
Grava	GW, GP, GW-GM, GW-GC, GP-GM, GP-GC, GM, GC y GC-GM
Arena	SW, SP, SW-SM, SW-SC, SP-SM, SP-SC, SM, SC y SC-SM
Limo	ML

Nota: Elaboración propia de acuerdo a la base teórica.

2.3.8. Comportamiento físico del suelo.

Es la conducta o respuesta del suelo frente a los cambios físicos que pueda presentar dicho material. Para esta investigación el comportamiento físico de un suelo, se medirán mediante indicadores como límites de consistencia, distribución granulométrica, humedad, densidad aparente.

Distribución granulométrica.

Es la distribución de las estructuras sólidas del suelo como las partículas de grava, arena y arcilla son las que conforman su estructura, no se incluye el componente de aire y agua.

Límites de consistencia.

Comportamiento de un material en sus estados semilíquido, plástico, semisólido o sólido. Para esta investigación tomaremos los indicadores LL, LP e IP que describirán la consistencia del suelo.

Contenido de humedad.

Definida como la relación existente entre el peso del agua y el peso seco del suelo, se expresara en porcentajes.

Saturación (sumersión).

Estado del suelo en que sus espacios intergranular están llenos de agua. Cabe recalcar que para esta investigación, no evalúa el grado de saturación, por lo que se asumirá si un suelo está saturado cuando el suelo este sumergido en el agua.

Densidad.

Para esta investigación conceptualizaremos esta dimensión con un indicador único que mida que es el peso específico seco del suelo.

Peso específico seco. “Es la relación entre el peso y su volumen del suelo seco” (Das, 2012).

2.3.9. Parámetros de resistencia al corte.

Son aquellos parámetros que caracteriza al plano de falla (función lineal) de la combinación crítica del esfuerzo normal y esfuerzo cortante” (Coulomb, 1776).

Para esta investigación se toma los parámetros de resistencia al corte efectivos, además de esfuerzo cortante máximo.

Cohesión (condición drenada).

Propiedad mecánica de un suelo al ofrecer resistencia a cambiar de forma, debido a la ligazón de las partículas. Para esta investigación esta cohesión es producto de condición de ensayo drenado.

Ángulo de fricción interna (condición drenada).

La resistencia al desplazamiento producida por la interferencia de las partículas en un plano de falla, rozamiento y reacomodo de las partículas. Para esta investigación el ángulo de fricción es producto de condición de ensayo drenado.

3. MATERIAL Y MÉTODOS DE INVESTIGACIÓN.

3.1. MÉTODO

El método será **inductivo**, según Caballero Romero (2014), define “aquella orientación que va desde los casos particulares a lo general; es decir, que parte de los datos o elementos individuales, se sintetiza y se llega a un enunciado general que explica y comprende esos casos particulares”.

En este estudio los casos particulares son los resultados de ensayos simples como: granulometría, límites de consistencia, humedad y peso específico del suelo, que al desarrollar con un modelo neuronal predecirá un caso general como parámetros de resistencia al corte.

3.2. ORIENTACIÓN DE INVESTIGACIÓN.

Tendrá una orientación **aplicada**, según Jonh Hayman (como se citó en Caballero Romero, 2014). “La investigación aplicada cuyo propósito fundamental es dar solución a problemas prácticos” (p. 39).

Este estudio pretende dar una alternativa en la obtención de los parámetros de resistencia al corte a partir de simples ensayos, mediante un modelo neuronal.

3.3. ENFOQUE.

La investigación se desarrollará bajo un enfoque cuantitativo, según Hernández Sampieri, et al. (2014), “Utiliza la recolección de datos para probar hipótesis con base en la medición numérica y el análisis estadístico, con el fin establecer pautas de comportamiento y probar teorías”.

La base de datos a recopilados son mediciones numéricas y serán modeladas mediante redes neuronales que es una serie de algoritmos matemáticos computacional, con el fin de determinar su predicción.

3.4. NIVEL DE INVESTIGACIÓN.

Predictivo, Según Supo & Zacarías (2020), “se encarga de la estimación de eventos generalmente adversos”.

En este estudio que se realiza es de nivel predictivo ya que cuantifica el grado de eficacia al estimar los parámetros de resistencia al corte de un suelo granular de un modelo neuronal frente a casos experimentales (caso real).

3.5. TIPO DE INVESTIGACIÓN

Según Supo & Zacarías (2020) “Es la clasificación exhaustiva y excluyente, donde no hay ningún estudio que pertenezca a los dos grupos”.

Para esta investigación se mencionan los tipos de investigación que le corresponde.

- »» Según la Intervención del investigador: **Experimental.**
- »» Según el número de mediciones de la variable de estudio: **Transversal.**
- »» Según la planificación de toma de datos: **Retrospectivo.**
- »» Según el propósito de estudio: **Aplicada.**
- »» Según número de variables de interés: **Analítico.**

3.6. DISEÑO DE INVESTIGACIÓN

De acuerdo a Hernández Sampieri, et al. (2014), Se refiere a los pasos, etapas y estrategias que se aplican para el logro de los objetivos planteados, este consiste en el planteamiento de una serie de actividades sucesivas, organizadas, adaptadas a los particulares de cada móvil de investigación, para indicar los pasos o pruebas a efectuar, así como las técnicas para recolectar y analizar datos.

En esta investigación no se tiene un grupo control pero si la intervención del investigador, por lo tanto el diseño de investigación es **causi-experimento**.

3.7. POBLACIÓN, MUESTRA Y UNIDAD DE ESTUDIO.

3.7.1. Población

Según Lepkowski (2008, citado por Hernández Sampieri et al. 2014), “es el conjunto de todos los casos que concuerdan con determinadas especificaciones”.

La universo de este estudio está formada por **suelos granulares típicos de Perú**.

3.7.2. Muestreo

La técnica de muestreo es **no probabilístico-intencional**, según [Hernández Sampieri, et al. \(2014\)](#), menciona que es “Subgrupo de la población en la que la elección de los elementos no depende de la probabilidad, sino de las características de la investigación”.

Para este estudio el sub grupo será seleccionada de manera intencional (sin probabilidad), la cantidad de las investigaciones (muestras) serán determinadas por la cantidad de base de datos recopilados, ya que para que un modelo red neuronal aprenda se necesita gran cantidad de datos para su entrenamiento, prueba y verificaciones, según autores que realizaron modelos neuronales para este tipo de estudio la cantidad mínima de base de datos están entre 200 a 500 para que el modelo neuronal aprenda y que sus resultados sean certeros.

3.7.3. Muestra.

[Hernández Sampieri, et al. \(2014\)](#), comentaron “es el subgrupo del universo o población del cual se recolectan los datos y que debe ser representativo de ésta”.

Por lo tanto la muestra son aquellas **registro de suelos granulares de repositorio de universidades del Perú y suelos granulares de grupo experimental**.

Cuadro N° 28. Tipo de muestra.

<i>Muestra</i>	<i>muestreo</i>	<i>fuentes</i>	<i>Unidad de estudio</i>	<i>Tamaño de muestra</i>
<i>Muestra documental</i>	No probabilístico	<i>Secundaria: Repositorios de universidades del Perú</i>	<i>Suelos granulares</i>	1105
<i>Muestra experimental</i>	No probabilístico	<i>Primarias: Laboratorio de suelos</i>	<i>Suelos granulares</i>	39

Nota: Elaboración propia, mediante el cuadro se exhibe la cantidad de datos a procesarse..

3.7.4. Unidad de estudio

Según [Supo & Zacarías \(2020\)](#) menciona que es el “individuo o conjunto de individuo de se obtiene el dato, que va ser objeto de medición y se refiere al que o quien es sujeto de interés en una investigación”.

En esta investigación la unidad de estudio son los **suelos granulares**, ya que de esta se obtiene valores medibles como los parámetros de corte, distribución granulométrica, límites de consistencia y densidad.

3.8. HIPÓTESIS.

3.8.1. *Hipótesis general.*

Si mediante la aplicación de redes neuronales artificiales, será posible predecir con nivel de eficacia alta los parámetros de resistencia al corte en suelos granulares, basándose en su comportamiento físico.

3.8.2. *Hipótesis específicas.*

- »» Si la importancia relativa de la distribución granulométrica es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.
- »» Si la importancia relativa de los límites de consistencia es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.
- »» Si la importancia relativa de la densidad es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.
- »» Si la importancia relativa de la humedad es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.

3.9. OPERACIONALIZACIÓN DE VARIABLE

TITULO: Eficacia en la predicción de los parámetros de resistencia al corte a partir del comportamiento físico en suelos granulares empleando redes neuronales artificiales-experimental, Perú 2023								
TIPO: VARIABLE	DEFINICIÓN CONCEPTUAL	NATURALEZA Y GRADO DE COMPLEJIDAD	ESCALA DE MEDICIÓN ESTADÍSTICA	DEFINICIÓN OPERACIONAL	DIMENSIÓN	INDICADORES	UNID	INSTRUMENTOS
<u>Predictora:</u> Comportamiento físico	Es la conducta o respuesta del material a los cambios físicos. Estas se caracterizan por el tamaño de las partículas, textura, densidad, humedad, etc	*Cuantitativa-continua. *Compleja	De razón	El comportamiento físico del suelo granular se caracterizaran por las dimensiones establecidas (estructura del suelo, densidad, límites de consistencia) y estas son medidas por ensayos según las normas ASTM y NTP su recolección de datos será a base de fichas, estos indicadores serán datos de entrada en un modelo neuronal.	<i>Distribución Granulométrica</i>	Porcentaje de grava gruesa	%	Ficha de recolección de datos de Análisis Granulométrico por Tamizado (ASTM D-422).
						Porcentaje de grava fina	%	
						Porcentaje de arena gruesa	%	
						Porcentaje de arena mediana	%	
						Porcentaje de arena fina	%	
						Porcentaje de partículas finas	%	
					<i>Densidad seca</i>	Peso específico aparente/ Densidad aparente	kg/cm ³	Ficha de recolección de datos de los Ensayo densidad y el peso unitario del suelo (ASTM D-4254).
					<i>Humedad</i>	Contenido de Humedad	%	Ficha de recolección de datos de los Ensayo para determinar contenido de humedad (ASTM- D 2216)
					<i>Límites de consistencia</i>	Limite Liquido	%	Ficha de recolección de datos de los Ensayo de Limites de atterberg (ASTM D4318).
						Índice plástico	%	
<u>evaluada:</u> Parámetros de resistencia al corte	El parámetro de corte de un suelo, son indicadores que caracterizan la resistencia de un suelo.	*Cuantitativa-continua. *Compleja	De razón	Los parámetros como cohesión y Angulo de fricción interna son indicadores que caracterizaran a la variable, estos indicadores serán datos de salida de un modelo neuronal	Cohesión		Kg/cm ²	Ficha de recolección de datos de los Ensayo de corte directo ASTM D3080).
					Angulo de fricción interna		(°)	

3.10. TÉCNICAS E INSTRUMENTO DE RECOLECCIÓN DE DATOS.

Falcón & Herrera (2005), se refiere a la técnica como "el procedimiento o forma particular de obtener datos o información". La técnica conduce a la obtención de datos, la cual debe ser resguardada mediante un instrumento de recolección de datos, según el mismo autor, "son dispositivos o formatos (en papel o digital), que se utiliza para obtener, registrar o almacenar información" (p. 12).

Los datos para este estudio fueron sacados de fuentes primarias y secundarias, para la técnica de recolección de datos, distinguiremos para estos dos tipos de fuente.

Para fuentes secundarias: Los datos fueron extraídas de investigaciones científicas (tesis), publicadas en repositorios de cada universidad peruana. Por lo tanto la técnica de recolección de datos es **documental**, estos serán usados para el entrenamiento y validación del modelo neuronal.

Para fuentes primarias: Los datos se han recolectado de los ensayos de suelos de laboratorio (experimental). Por lo tanto la técnica de recolección de datos es **observacional**, estos serán necesarios para determinar la eficacia de la predicción del modelo neuronal.

Para recolección de datos de forma documentaria, el instrumento donde son registrados esos datos, son las llamadas **fichas bibliográficas**. Para la recolección de datos de ensayos realizados para la prueba el instrumento donde se registra son las **guías de observación**. Estas son herramientas fueron utilizadas para registrar sistemáticamente los datos relevantes sobre las variables y otros datos de interés. Estas fichas permitieron organizar los datos y luego para el pre procesamiento. En el anexo N°5 y 8, se aprecia estas fichas con los datos en registro.

3.11. TÉCNICAS DE PRE-PROCESAMIENTO DE DATOS.

La base de cualquier ML es la calidad e integridad de los datos, sobre la cantidad. Se destaca la importancia del pre procesamiento para garantizar que tengan la consistencia, integridad y relevancia de los datos. Además, los pre-procesos aseguran que los datos de entrada se alineen con los requisitos del modelo de ML, lo cual es fundamental para lograr una alta precisión en las predicciones.

Los pasos a seguir serán de acuerdo a la situación de los datos y su uso, aquí los pasos más importantes del pre procesamiento de datos.

-  Integración y exploración de datos
-  Limpieza de datos.
-  Reducción de datos
-  Tabulación de datos
-  Transformación de datos
-  División de datos

3.12. TÉCNICAS ESTADÍSTICAS PARA EL PROCESAMIENTO DE INFORMACION.

Para la el tratamiento estadístico donde se evalúa los valores predichos sobre los valores experimentales realizadas en este estudio. Se decide una evaluación en la precisión y la distancia significativa entre esos valores.

Coefficiente de determinación: representado como (R cuadrado), es una medida estadística que indica la proporción de la variación sobre dos variables, mide qué tan bien las predicciones del modelo se ajustan a los datos reales (ensayos-experimentales). En esencia, indica la proporción de la variabilidad de los datos que el modelo es capaz de explicar.

$$R^2 = 1 - \frac{S_e}{S_y}$$

S_y: es la varianza total de los datos observados.

S_e: es la varianza de los residuos (la diferencia entre los datos observados y los estimados por el modelo)

Para el enfoque de predicción el R² puede ser una medida de la precisión predictiva del modelo. Otra forma de ver R² es que representa el efecto combinado de la variable exógena sobre la(s) variable(s) endógena(s). Este efecto varía de 0 a 1, donde 1 representa una precisión predictiva completa, mientras que un R² cercano a 0 sugiere que el modelo no predice bien los datos. Para la elección de la prueba estadística, se necesita probar la significancia del valor de R-cuadrado, para este estudio se realiza la prueba F y Análisis de Residuos valores predichos y valores observados (ensayos-experimental), que se realizó en el laboratorio de suelos.

La prueba F: evalúa si la proporción de variabilidad explicada por las predicciones es significativamente mayor que por azar. Esta prueba calcula la estadística F comparando la varianza explicada por los valores predichos con la varianza residual (no explicada), y determina si el valor de F es significativamente diferente a cero. Un valor alto de la estadística “F” y un valor bajo “p” se traduce que los valores predichos explican una cantidad significativa de la variabilidad en los valores observados (experimental), indicando que el modelo desarrollado a base de redes neuronales artificiales tiene una capacidad predictiva real y no debido al azar. La siguiente Fórmula de la Prueba F para R^2 .

$$F = \frac{\left(\frac{R^2}{k}\right)}{\left(\frac{1 - R^2}{n - k - 1}\right)}$$

R^2 : Coeficiente de determinación del modelo.

k : Número de variables predictoras (excluyendo la intersección).

n : Número total de observaciones

Elección de nivel de significancia. El nivel de significancia define el umbral para rechazar la hipótesis nula, es decir, es la probabilidad de cometer un error tipo I (rechazar la hipótesis nula cuando es verdadera). En muchas disciplinas, es común usar niveles de significancia de 0.05, 0.01, o 0.10. Estos umbrales han sido adoptados por convención y sirven como puntos de referencia útiles para muchos investigadores. Para esta investigación enfocado a la significancia de R-cuadrado se decidió un α de 0.01 implica que estás dispuesto a aceptar un 1% de probabilidad de cometer un error tipo I.

$$\alpha = 0.01$$

Análisis de Residuos: son las diferencias entre los valores observados y los valores predichos por el modelo predictor. Los residuos deben tener valores pequeños y distribuidos aleatoriamente alrededor del cero. Lo que indicaría que las predicciones del modelo son precisas. Si los residuos no son aleatorios y muestran patrón sistemático, esto conllevaría a modificar el diseño del modelo ya que se sugiere que el modelo no captura alguna variable de entrada (indicadores para este estudio). En resumen, el análisis de residuos es una herramienta esencial para verificar la adecuación de un modelo predictivo y para asegurar que un $\hat{y}$ alto refleje una verdadera capacidad predictiva, más allá de simplemente ajustar bien los datos de entrenamiento.

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

3.13. DESARROLLO DE LA TESIS.

3.13.1. *Recolección de datos.*

Como se mencionó en el capítulo anterior, sobre técnica de recolección de datos, siendo de manera documentaria para el entrenamiento y validación del modelo neuronal. Donde se extrajo todos los datos requeridos, de los ensayos realizados en estudios de investigación, que fueron publicados en repositorios de cada universidad del Perú, se presenta el resumen en cuadro la información extraída de las diversas tesis.

Cuadro N° 29. Resumen de la recolección de datos

<i>Tipo de fuente</i>	<i>descripción</i>	<i>Técnica de recolección</i>	<i># datos</i>
<i>Fuente secundaria</i>	<i>Recolectados de ensayos experimentales, realizadas en 166 tesis (sección de anexos y/o resultados), y fueron publicadas en repositorio de cada universidad peruana</i>	<i>documental</i>	<i>1441</i>
<i>Fuente primaria.</i>	<i>Recolectados de ensayos en laboratorio de suelos, ya que es un ambiente controlado (experimental).</i>	<i>observacional</i>	<i>39</i>

Nota. Elaboración propia

3.13.2. *Pre procesamiento de datos*

Integración y exploración de datos

La integración de datos es una combinación de procesos técnicos que se utilizan para combinar datos de diferentes fuentes. Y la exploración se refiere a una rápida examinación de la situación de los datos donde se puede detectar errores, valores atípicos, etc.

Como los datos fueron recolectados de fuentes primarias y secundarias, a una ficha bibliográfica y guía de observación, se integró a un solo formato de registro, también se realizó una exploración total, donde se localiza aquellos datos incompletos, incorrectos, duplicados, erróneos, etc.

Limpieza de datos.

Consiste en eliminar, tratar y/o solventar estos datos incompletos, incorrectos, valores atípicos, valores faltantes y/o valores erróneos. A continuación para el este estudio se ciñó estos criterios de tratar estos datos.

-  El dato erróneo es identificada, ya sea por errores de escritura, formato distinto, etc. Estas son eliminadas o modificadas.
-  El dato duplicado es identificada, de acuerdo a la ubicación de la calicata, esta información es eliminada.
-  El dato incompleto es identificada por falta de 4 a más indicadores de los 11 indicadores que tiene una muestra, estas son eliminadas. Aquellas informaciones incompletas que faltan datos de menos de 4 indicadores, se completan con procesos estadísticos o de regresión, de acuerdo al tipo de suelo.
-  El dato incorrecto es identificada y eliminada de acuerdo a la base teórica, específicamente no cumpliendo el mínimo y máximo rango que fueron propuestos por autores reconocidos, según el tipo de suelo.

Cuadro N° 30. Resumen final de limpieza de datos

Total de datos recolectados	1441	
Datos modificados	239	
Datos originales	866	
Datos eliminados	436	
Datos limpios	1105	Estos datos son las que serán utilizadas

Nota. Elaboración propia

Reducción de datos.

De los 1105 datos, cada dato recolectada contiene 26 indicadores, estos fueron reducidos a solo 12, fueron reducidos ya que algunos son dependientes y otros innecesarios, estas 12 llamados indicadores miden las dimensiones-variables que se están evaluando en este estudio, más detalles en el anexo N° 6.

Cuadro N° 31. Reducción de datos

	indicadores	cantidad
Total de Indicadores	Nombre de calicata, % pasas 3/4", 4#, 10#, 40#, 200#, %Grava gruesa, %Grava fina, %Arena gruesa, %Arena mediana, %Arena fina, % finos, Cu, Cc, condición de gradación, LL, LP, IP, densidad seca, humedad, densidad húmeda, ángulo de fricción efectiva, cohesión, Clasificación SUCS, condición de prueba, Norma estandarizada de corte directo.	26
Indicadores necesarias	%Grava gruesa, %Grava fina, %Arena gruesa, %Arena mediana, %Arena fina, % finos, LL, IP, densidad seca, humedad, ángulo de fricción efectiva, cohesión.	12

Nota. Elaboración propia

Ya reducido con los indicadores necesarios se resume en el siguiente cuadro que contiene los 1105 datos con los 12 indicadores, recordando que cada dato describe las propiedades físicas y parámetros de un determinado suelo.

Cuadro N° 32. Visualización de data- resumida

N°	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
1	0.0	0.00	20.27	10.28	66.77	2.69	0.0	0.0	1.91	0.46	42.19	2.84
2	0.0	0.00	0.62	16.40	78.69	4.29	0.0	0.0	1.59	0.39	36.93	1.37
3	0.0	0.00	0.39	10.30	85.41	3.90	0.0	0.0	1.66	0.24	36.30	3.82
4	0.0	0.00	0.52	10.53	85.38	3.57	0.0	0.0	1.63	0.36	34.00	1.57
5	0.0	0.06	2.63	11.90	82.12	3.29	0.0	0.0	1.55	1.29	33.25	2.65
...	...	...	...	...	...	...	...	...	...	...	...	...
1101	0.0	8.66	31.00	42.00	15.68	2.66	0.0	0.0	1.68	2.70	39.82	4.90
1102	0.0	19.77	26.90	46.00	3.09	4.24	0.0	0.0	1.76	0.90	38.71	3.73
1103	0.0	20.57	11.00	27.20	36.99	4.24	0.0	0.0	1.59	24.60	28.78	0.00
1104	0.0	24.56	16.40	33.40	21.63	4.01	0.0	0.0	1.62	22.40	31.88	0.00
1105	0.0	9.84	24.20	37.00	22.97	5.99	0.0	0.0	1.62	6.00	33.69	0.00

Nota. Elaboración propia


Tabulación de datos

Se realizó una estadística descriptiva con los 1105 datos, con el fin de tomar mejores decisiones en los siguientes pasos. Se sabe que en estadística se puede presentar por 4 categorías importantes:

- »» Medidas de tendencia Central
- »» Medida de dispersión
- »» Medida de distribución
- »» Medida de forma.

A continuación se muestra las medidas, gráficas y diagramas de la estadística descriptiva aplicadas al conjunto de datos. La implementación de las medidas de tendencia central, dispersión y de distribución fueron importantes para decisiones en elegir el tipo de transformación que es crucial para el pre procesamiento; en el diseño del modelo neuronal, para elegir optimizadores y funciones de activación adecuadas, y da una prematura idea de la arquitectura del modelo ajustado a las características de los datos; además contribuyo en aseguramiento y verificación de la calidad de los datos post-limpieza. Los detalles ver en **anexo N 2**, codificado en lenguaje de programación **Python**, a continuación un resumen de los reportes estadísticos de los 1105 datos.

Figura 26. Visualización del conjunto de datos por cada indicador



Nota. Elaboración propia

Medidas de tendencia central y dispersión.

Estas medidas estadísticas son una herramienta para comprender las características de los 1105 datos recolectados documentariamente, son fundamentales para el entendimiento y comprensión de la naturaleza de los datos. Las medidas de tendencia central como la media, que representa el promedio de los datos; la mediana, que indica el valor medio de datos ordenados; y la moda, el valor que aparece con mayor frecuencia. En cambio las medidas de dispersión, como el rango, la varianza, la desviación estándar, ofrecen una visión de cuán dispersos o próximos están a la medida de tendencia central.

La comprensión de estas medidas es crucial ya que, influye en la decisión de elegir el tipo de transformación o escalamiento. Además, el análisis de estas medidas permite identificar anomalías o patrones inusuales en los datos, como valores atípicos, que podrían influir en los resultados del análisis.

Cuadro N° 33. Medidas de tendencia central

MEDIDAS CENTRALES	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP DENSIDAD	SECA	HUMEDAD	Ø'	C'
media	7.09	16.31	8.98	15.35	32.524	19.75	14.60	4.09	1.634	14.075	30.158	7.445
mediana	0.00	9.84	7.31	13.00	24.010	12.60	17.00	0.00	1.620	12.000	30.500	4.710
moda	0.00	0.00	0.00	0.00	0.000	18.17	0.00	0.00	1.550	20.000	30.000	0.000

Nota. Elaboración propia

Cuadro N° 34. Medidas de dispersión


	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ϕ	C'
std	14.0	20.2	8.0	11.6	28.4	20.3	15.2	5.7	0.2	10.6	6.0	8.4
min	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	1.0	0.0	10.3	0.0
25%	0.0	0.0	2.3	6.8	10.5	4.4	0.0	0.0	1.5	5.3	26.5	1.0
50%	0.0	9.8	7.3	13.0	24.0	12.6	17.0	0.0	1.6	12.0	30.5	4.7
75%	6.0	24.6	14.0	21.9	48.8	28.3	27.1	7.6	1.8	20.9	34.0	11.8
max	70.3	87.7	35.0	74.0	98.9	93.1	64.6	36.0	2.3	63.1	50.0	72.6
varianza	196.0	410.0	63.0	134.0	804.0	410.0	231.0	33.0	0.0	112.0	36.0	71.0
count	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0


Nota. Elaboración propia

Medidas de distribución y de correlación entre indicadores

En las gráficas de distribución, los llamados histogramas se puede apreciar que la mayoría de los indicadores son asimétricos sesgados hacia la derecha, menos la densidad seca y el ángulo de fricción interna. Es comprensible que los datos sean sesgados a la derecha como el limite líquido y índice plástico, ya que para suelos granulares son muy bajas, por lo que si caracteriza la naturaleza de ese tipo de suelos. Igualmente la cohesión teóricamente la cohesión para suelos granulares tienden a cero, por ende la mayoría tiene la cohesión de valor 0. Estas graficas ayudaran a decidir qué tipo de transformación es adecuada para estos datos.

Figura 27. *Histogramas por cada indicador*





Nota. Elaboración propia


Cuadro N° 35. Condición de asimetría por cada indicador

Condic.	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ϕ'	C'
Distribucion Simetrica	No	No	No	No	No	No	No	No	Si	No	Si	No

Nota. Elaboración propia

Se visualiza la correlación existente entre cada indicador, facilitando así la comprensión de las relaciones entre sí. Este estadístico no solo revela la fuerza y dirección de las asociaciones entre los indicadores, además proporciona insights valiosos para la toma de decisiones para un futuro diseño del modelo neuronal, ya que al examinar estos vínculos, se pueden identificar patrones y tendencias del comportamiento entre los distintos indicadores.

Figura 28. Distribución de datos de cada indicador frente a otros.




Nota. Elaboración propia

Para una comprensión más simple se visualiza la gradiente de color, donde indica de manera visual la fuerza de correlación entre los indicadores, con esta visualización ya podemos entender de manera intuitiva que indicadores influirían más que las otras sobre los parámetros de resistencia al corte: ángulo de fricción y cohesión, como la fuerte correlación existente entre porcentaje de partículas finas de un suelo y los parámetros de resistencia al corte, al igual pero en menor medida la densidad seca y los límites de consistencia.

Detalles adicionales sobre las técnicas estadísticas empleadas, transformación de datos, se encuentran documentados en el anexo N° 2, codificados en el lenguaje de programación Python. Este documento incluye un compendio de los reportes estadísticos elaborados a partir de los 1105 registros de datos.

Figura 29. *Gradiente de color de la correlación Pearson entre indicadores*




Nota. Elaboración propia

Transformación de datos

La transformación de los datos es necesaria cuando entre las variables existen diferentes escalas o existen demasiadas o pocas variables, entonces se realiza una normalización o una estandarización de los datos mediante técnicas de reducción o aumento de la dimensión, así como el escalamiento simple o multidimensional. El uso de la normalización o de una estandarización dependerá de la naturaleza de los datos, y de las intenciones de un estudio.

Para los indicadores % Grava gruesa, % Grava fina, % Arena gruesa, % Arena mediana, % Arena fina, % Finos, LL, IP, humedad y cohesión, se observó una distribución asimétrica sesgada a la derecha. Teniendo esto en cuenta, se decidió aplicar la normalización logarítmica a estos 10 indicadores para tratar este tipo de asimetrías. Por otro lado, para los otros dos indicadores, que son la densidad seca y el ángulo de fricción interna, no se realizó esta normalización, ya que su distribución es simétrica.

Figura 30. Transformación logarítmica



Nota. Elaboración propia

Después de la normalización, se decidió realizar el escalamiento de todos los indicadores, dado que presentan diferentes unidades y rangos. Por ejemplo, los valores de densidad seca varían desde 1.0 hasta 2.3, a diferencia del porcentaje de partículas finas que varía desde 0.1 hasta 93.1. Si se trataran con los mismos valores, existiría una ligera ventaja del indicador de partículas finas frente a la densidad seca en el modelo neuronal. Para evitar ese inconveniente, se decidió realizar el escalamiento Max-Min [0,1]

División de datos pre procesados.

Para la división de información, se basó de acuerdo a la literatura, como [Amazon Machine Learning \(2024\)](#) y muchos investigadores establecieron un rango de 70-80% para entrenamiento y 30-20% para validación, teniendo eso en cuenta lo anterior se divide de la siguiente manera.

Cuadro N° 36. División de datos

fases	Representación en %	cantidad
Entrenamiento y ajuste	70%	773
Validación	30%	332
total		1105

Nota. Elaboración propia

Además la separación de estos datos para estos dos grupos es de forma aleatoria, ya que ayuda a garantizar que tanto el conjunto de entrenamiento como el de validación sean representativos del conjunto de datos completo.

3.13.3. *Entrenamiento y validación de la red neuronal*

En la sección anterior tuvo el fin de entender la naturaleza y comportamiento de los indicadores involucrados, gracias a la estadística descriptiva que es importante en el proceso de toma de decisiones, destacando ser útil para el diseño de la arquitectura de la red, asegurando así un modelo robusto y bien fundamentado.

Se realizó la codificación del modelo neuronal en sitio abierto de lenguajes y librerías llamado **Anaconda**, el lenguaje de programación elegido es **Python**, realizado en un entorno informativo llamado **Jupyterlab**. Más detalle en anexo N 3.

```
##ARQUITECTURA

#Iniciar modelo
Kback.clear_session()
#Modelo de la red neuronal
modelo = Sequential()

modelo.add(Dense(200, input_dim=10, kernel_initializer='he_uniform'))
modelo.add(BatchNormalization())
modelo.add(ReLU()) # Utiliza ReLU como capa para mayor flexibilidad
modelo.add(Dropout(0.2))

modelo.add(Dense(100))
modelo.add(BatchNormalization())
modelo.add(ReLU())
modelo.add(Dropout(0.2))

modelo.add(Dense(50))
modelo.add(BatchNormalization())
modelo.add(ReLU())
modelo.add(Dropout(0.2))
# Capa de salida
modelo.add(Dense(2, activation='linear'))

# Compilador de la red neuronal
modelo.compile(loss='mean_squared_error', optimizer='adam',
metrics=['mae', 'mse'])

# Resumen del modelo
modelo.summary()

# Visualizar la arquitectura del modelo
plot_model(modelo, to_file='modelo.png', show_shapes=True,
show_layer_names=True)

##DATA SEPARATION FOR TRAINING AND VALIDATION
```

```

datosRNN=df.values    #devuelve los datos a forma iterable

## data training
X_entr=datosRNN[0:773,0:10]
Y_entr=datosRNN[0:773,10:12]

## data validation
X_val=datosRNN[773:1105,0:10]
Y_val=datosRNN[773:1105,10:12]

#Entrenamiento de la red neuronal, {validation_data=(X_val, Y_val)-
validation_split=0.1}
#dat_val=0.1
batch_size = X_entr.shape[0]
# Configuración de callbacks
early_stopping = EarlyStopping(monitor='val_loss', patience=10,
verbose=1, mode='min')
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.2,
patience=5, verbose=1, mode='min', min_lr=0.001)

history =
modelo.fit(X_entr,Y_entr,batch_size=batch_size,epochs=1500,verbose=0,validation_data=(X_val,Y_val))

```


Diseño del modelo neuronal

La arquitectura de una red neuronal se refiere a la estructura y disposición organizativa de sus capas y neuronas, incluyendo cómo estas están interconectadas y cómo fluye la información a través de ellas. Esta arquitectura define las reglas de operación de la red y determina cómo procesa los datos de entrada para producir los resultados deseados. A continuación se tiene la arquitectura de la red neuronal.

Para programación del modelo neuronas, se dio utilidad las librerías de **Keras**, **Scikit-learn** y **Tensoflow**, y para otras operaciones **NumPy**, **Pandas**, **Matplotlib**, **Seaborn**, etc.

Los códigos de programación realizados en este estudio de forma detallada se encuentran en el anexo N 3.

Figura 31. *Arquitectura de la red*



Nota. Elaboración propia, Imagen generada de lenguaje Python.


4. RESULTADOS Y DISCUSIÓN.

4.1.RESULTADOS

4.1.1. Rendimiento del modelo (entrenamiento y validación).

Una vez desarrollada la arquitectura optima de la red neuronal y realizada la separación aleatoria del conjunto de datos para entrenamiento y validación del modelo, se evaluó el desempeño del modelo mediante la gráfica N° 27, donde muestra la disminución de la función de pérdida a medida que avanzan las iteraciones (épocas). Se utilizaron técnicas de regularización como la deserción (dropout) y la normalización de lotes (batch normalization) por lo que el modelo diseñado o desarrollado en este estudio no incurrió en el sobreajuste [*overfitting*] o sub ajuste [*underfitting*], lo cual indica que se logró un equilibrio adecuado entre la complejidad del modelo y su capacidad de generalización a partir de datos de entrada.

Figura 32. Pérdida vs época




Nota. Imagen generada de Python, describe la reducción de la pérdida del error a lo largo de las iteraciones-épocas.

Cuadro N° 37. Reporte de métricas de error en entrenamiento y validación para (ϕ' y c').

Etapa	Pérdida	MAE	MSE
Entrenamiento	0.020	0.110	0.020
Validación	0.016	0.097	0.016


Para visualizar mejor el proceso del entrenamiento y la validacion del modelo diseñado, se presenta una grafica de serie temporal que describe las predicciones de los valores de **entrenamiento** frente a los datos proporcionados para los parametros de angulo de friccion interna y de cohesion.

Figura 33. *Entrenamiento de angulo de friccion interna*



Nota. Imagen generada de Python, que describe la pérdida del error a lo largo de las iteraciones-épocas.

Figura 34. *Entrenamiento de la cohesion*



Nota. Imagen generada de Python, que describe la pérdida del error a lo largo de las iteraciones-épocas.


Cuadro N° 38. *Reporte de métricas de error en entrenamiento para (ϕ' y c').*

Entrenamiento	Perdida (MSE)	MAE	RMSE
Angulo de fricción interna efectiva	0.0055	0.0579	0.0747
Cohesión efectiva	0.0185	0.1064	0.1360

Nota. Resultados de error en etapa de entrenamiento para cada uno de los parámetros de corte.


También se describe en el grafica de tipo serie de tiempo, de las predicciones de los valores de **validación** frente a los datos proporcionados para los parámetros de ángulo de fricción interna y de cohesión.

Figura 35. *Validacion de angulo de friccion interna*



Nota. Imagen generada de Python, que describe la pérdida del error a lo largo de las iteraciones-épocas.

Figura 36. *Validacion de la cohesion*



Nota. Imagen generada de Python, que describe la pérdida del error a lo largo de las iteraciones-épocas.

Cuadro N° 39. Reporte de métricas de error en entrenamiento para (ϕ' y c').

Validación	Perdida (MSE)	MAE	RMSE
Angulo de fricción interna efectiva	0.0072	0.0669	0.0849
Cohesión efectiva	0.0241	0.1265	0.1553

Nota. Resultados de error en etapa de entrenamiento para cada uno de los parámetros de corte.

4.1.2. Resultados de ensayos-experimentales.

Con el fin de determinar la eficacia del modelo diseñado en predecir los parámetros de resistencia al corte a partir de propiedades físicas, se tomó una muestra pequeña, que consta de 39 suelos no cohesivos, extraídas de manera intencional (no probabilístico), se realizó ensayos en un laboratorio de suelos siguiendo los estándares según la normativa técnica peruana (NTP) e internacional (ASTM), tanto para determinar los parámetros de corte y propiedades físicas. En el cuadro se resumen los diferentes suelos no cohesivos que fueron extraídas, cabe precisar que el investigador dio mayor importancia en la variabilidad de la muestra según el tipo de suelo mas no del lugar de procedencia, por ello se tiene más suelos de la región de Ayacucho, claro también influyo la cercanía del lugar. Más detalle sobre esta muestra, con los ensayos experimentados en el laboratorio de suelos ver en el **anexo N 7, N 8 y N 9**.

Cuadro N° 40. Muestra de suelos granulares para la prueba del modelo predictivo.

items	proyectos	lugar	cantidad
1	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho	Huamanga-Ayacucho	9
2	Mejoramiento y Ampliación del Servicio de Transitabilidad Mollepata – Pongora en los distritos de Ayacucho y Jesús Nazareno de la Provincia de Huamanga – Departamento de Ayacucho	Huamanga-Ayacucho	3
3	Mejoramiento de la carretera con asfalto tramo centro poblado de carmen alto-yanama, del distrito de carmenalto provincia de huamanga.	Huamanga-Ayacucho	5
4	Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central	Pichari-Cusco	6
5	Mejoramiento del servicio educativo en la i.e. n° 22489 del distrito de paracas - provincia de pisco - departamento de ica	Pisco-Ica	1
6	Creacion del servicio de mejoramiento de los servicios de educación primaria en la i.e. n 36059 de huancalpi del distrito de vilca - huancavelica - huancavelica	Huancavelica-Huancavelica	2
7	Proyecto Privado en la ciudad de Andahuaylas para construccion de casas.	Andahuaylas-Apurimac	5
8	Creación del servicio educativo del nivel inicial n° 38059 de barrios altos del distrito de ayacucho, provincia de huamanga	Huamanga-Ayacucho	3
9	Privado. Proyeccion de construccion privada domicilio 5 pisos	Ciudad de Huancayo-Junin	2
10	Construccion de cobertura de la institucion deportiva en la I.E.S San Luis Gonzaga en la localidad de Conayre y Villa Progreso en Distrito de Conayre-Huanta-Ayacucho	Huanta - Ayacucho	3

Nota. Elaboracion propia

Para la etapa de prueba del modelo, predice los parámetros de resistencia al corte de un suelo granular a partir de las propiedades física (ensayos realizados en un laboratorio de suelos). A continuación se evidencia los dos resultados valores predichos y valores observados de los parámetros de corte.

Cuadro N° 41. Comparación de los resultados

N~ datos	valores predichos		valores reales	
	ángulo de fricción efectiva (°)	Cohesión efectiva (Kpa)	ángulo de fricción efectiva (°)	Cohesión efectiva (Kpa)
1	33.21	0.95	33.70	0.80
2	34.08	0.41	34.80	0.40
3	30.32	1.72	30.20	2.00
4	33.78	1.13	34.50	1.10
5	30.32	1.78	31.98	2.40
6	29.15	1.99	29.85	2.00
7	32.78	1.30	32.80	1.50
8	31.30	9.07	32.40	9.02
9	31.94	1.54	31.70	2.00
10	31.58	1.53	30.96	1.37
11	27.32	2.87	24.82	1.16
12	29.95	2.01	30.47	1.66
13	29.74	0.74	28.06	7.17
14	35.74	0.66	35.04	4.95
15	29.44	0.72	28.10	6.87
16	26.77	6.27	27.59	6.20
17	32.09	0.84	33.03	0.20
18	30.98	1.45	32.40	1.42
19	31.41	1.48	32.44	6.70
20	35.53	0.42	35.81	0.11
21	29.39	1.22	33.46	5.52
22	37.49	0.77	37.42	0.00
23	39.23	1.01	40.30	1.48
24	28.73	1.93	32.44	6.70
25	28.96	19.20	31.06	19.45
26	29.70	9.64	29.42	9.62
27	28.17	15.92	24.49	15.30
28	33.76	1.01	39.96	7.37
29	35.34	10.50	36.58	10.05
30	32.18	1.29	32.60	1.30
31	33.10	0.78	33.70	0.80
32	32.69	0.63	32.50	0.60
33	18.96	2.75	18.60	2.50
34	29.24	1.87	28.45	2.00
35	30.10	1.66	30.50	2.07
36	31.25	1.75	31.70	3.87
37	37.58	11.32	38.45	11.50
38	22.21	11.28	20.48	11.06
39	39.36	0.48	40.72	0.48

Nota. Elaboracion propia

4.1.3. Resultados de análisis de influencia.

Para determinar la importancia relativa de cada uno de las variables predictoras sobre las endógenas, se aplica el análisis de sensibilidad (análisis de influencia) en el modelo neuronal ya que esto da a conocer como diferentes entradas afectan las salidas del modelo. Dado su complejidad y la interacción no lineal entre sus nodos entre capas de neuronas del modelo, no es posible determinar directamente en cuanto influye una neurona de entrada a la de salida, por ende existe diversos métodos de análisis, para esta investigación se realiza el **análisis de sensibilidad de entrada y gradiente de entrada**.

Análisis de gradiente de entrada.

Al calcular el gradiente del parámetro de resistencia al corte con respecto a cada propiedad física de entrada, este método permite identificar cuáles de estas propiedades tienen un impacto mayor o menor en la resistencia al corte predicha, proporcionando así insights cruciales sobre la relación entre las propiedades físicas y parámetros de corte del suelo.

Figura 37. Gradiente por cada entrada




Nota. Imagen generada de Python, que describe el análisis de sensibilidad de entrada.

En el siguiente diagrama, se presenta un análisis de gradiente de entrada que muestra la influencia de los indicadores de la variable predictora sobre los parámetros de

resistencia al corte de un suelo, variables endógenas. En este análisis, los elementos coloreados en verde indican una influencia positiva, mientras de rojo señalan una influencia negativa. Estos resultados son congruentes con la base teórica existente a mecánica de suelos, lo que refuerza la validez de las observaciones realizadas en este estudio realizado.


Figura 38. *Influencia sobre el ángulo de fricción interna y cohesión.*



Nota. Elaboración propia


Para determinar la importancia relativa de las variables predictoras, mediante este análisis descrito anteriormente, se calculó el gradiente promedio utilizando datos de validación para cada uno de los indicadores de la variable. Para facilitar la comprensión, estos gradientes promedios se convirtieron en valores absolutos para luego relativizar frente a los demás, expresándolas en porcentajes.

Figura 39. *Importancia relativa de los propiedades físicas sobre angulo de fricción interna.*



Nota. Elaboración propia

Figura 40. *Importancia relativa de los propiedades físicas sobre la cohesión.*




Nota. Elaboración propia

Análisis de sensibilidad de entrada

El análisis de sensibilidad de entrada evalúa cuánto cambia la respuesta de un modelo ante variaciones en sus variables de entrada, donde se busca comprender la influencia de las incertidumbres en las predicciones del modelo. Identifica la entrada que tiene el mayor impacto en la salida.

Figura 41. *Importancia relativa por análisis de sensibilidad de entrada*



Nota. Elaboración propia

4.2. DISCUSIÓN, INTERPRETACIÓN Y CONTRASTACIÓN DE HIPÓTESIS.

4.3.1. *Discusión y Estrategia para contrastación de hipótesis general*

Para este estudio, la contrastación de hipótesis se basa en refutar o aceptar la hipótesis nula, o plantear una hipótesis alternativa de acuerdo a los resultados finales obtenidos.

Es importante mencionar que la **eficacia** es un término muy amplio, para esta investigación se refiere a que tan precisa y fiable son las predicciones del modelo neuronal desarrollado. Por lo cual, se realizaron estas medidas estadísticas: coeficiente de determinación (R-cuadrado) y métricas de error (MAE, RMSE).

Es necesario determinar el umbral o intervalo de confianza en donde un modelo predictivo se hace llamar eficacia alta, moderada o es ineficaz, ya que el término de eficacia es un concepto amplio y su significancia depende del enfoque o disciplina en que se aplique. Para determinar este límite, se sustenta de diversas metodologías, para este estudio se valida de acuerdo a la literatura especializada.

No se encontró en la literatura especializada cuanto de R-cuadrado (predicho vs observados) como mínimo es recomendable para que el modelo pueda predecir con alta eficacia al ángulo de fricción interna y la cohesión enfocados específicamente al ingeniería geotécnica, pero si existe para un enfoque amplio como sugiere (Baecher y Christian, 2003, citado en Xing, 2013), que los análisis probabilísticos o estadísticos proporcionan un enfoque alternativo. Teniendo en cuenta la idea anterior, en la literatura especializada algunos autores establecieron niveles o rangos de confiabilidad teniendo en cuenta el coeficiente de determinación R-cuadrado, claro no enfocados a fines de ingeniería geotécnica, sino de forma estadística. Como (Chin, 1998), recomienda para aquellos valores de R-cuadrado superiores a 0,67 son fuertes, los valores de R-cuadrado entre 0,19 y 0,33 son moderados y de R-cuadrado inferiores a 0,19 son indeseables. Mientras (Hair et al., 2014), valores de R^2 de 0,75, 0,50 o 0,25 describen como sustanciales, moderados o débiles, respectivamente. Para (Chicco et al., 2021), valores como R-cuadrado = 0,8 indican un muy buen desempeño del modelo de regresión, además añade que el R-cuadrado es útil en comparar el rendimiento predictivo.

Cuadro N° 42. Rango de niveles de confiabilidad de un modelo predictivo

Coefficiente R2	R2 en porcentajes	Categorías
$0.0 \leq R^2 < 0.25$	$0.0\% \leq R^2 < 25\%$	Débiles/ Indeseables
$0.25 \leq R^2 < 0.5$	$25\% \leq R^2 < 50\%$	Moderado
$0.50 \leq R^2 < 0.75$	$50\% \leq R^2 < 75\%$	Aceptable
$0.75 \leq R^2 \leq 1.0$	$75\% \leq R^2 \leq 100\%$	Sustanciales/Fuertes

Nota. Concepto tomado de (Hair et al., 2014) para este estudio, enfocados a modelos predictivos.

La medición de propiedades geotécnicas como la cohesión, el ángulo de fricción interna y otros aspectos geotécnicos, mediante pruebas de laboratorio demuestran grandes variaciones e incertidumbres (Nadim, 2007, Parker et al., 2008, como se citó en (Xing, 2013). Además enfatiza (Duncan, 2000), que el análisis determinista tradicional no explica completamente la seguridad de las geoestructuras ya que no considera variaciones o incertidumbres de estas propiedades del suelo. Se entiende que hay escasa literatura o investigación sobre las consideraciones de incertidumbre presentes en las pruebas de laboratorio, especialmente en cuanto al margen de error permitido para determinar los parámetros de resistencia al corte en ensayos de laboratorio, por lo que para este estudio consideraremos un **error máximo de 5%** ya que es más aceptado por la comunidad de ingeniería, aclarando que este error máximo planteado no es especialmente para los parámetros de corte estudiados.

Es evidente que existe una carencia de literatura o investigación que aborde de manera exhaustiva las consideraciones de incertidumbre inherentes a las pruebas de laboratorio, particularmente en lo que respecta al margen de error aceptable para los parámetros de resistencia al corte en ensayos geotécnicos. Ante esta situación, Para este estudio, se ha decidido adoptar un margen de error máximo del 5%, una elección respaldada por su amplia aceptación dentro de la comunidad de ingeniería. Sin embargo, es importante destacar que este margen de error no se limita exclusivamente a los parámetros de corte, sino que abarca un espectro más amplio de la geotecnia. No obstante, es importante tener en cuenta que este margen de error establecido es solo un punto de partida y no debe considerarse como una solución definitiva. Se alienta a futuras investigaciones a profundizar en este tema y a desarrollar metodologías más sofisticadas para abordar la incertidumbre que son permitidas en las pruebas de laboratorio en determinar estos parámetros de resistencia al corte.

Para el ángulo de fricción interna de un suelo granular, el rango va desde los 12° a los 55° aproximadamente, teniendo eso en cuenta el error máximo permitido es:

$$Er_{max} = 2.2^{\circ}$$

Para la cohesión de un suelo granular, el rango va desde los 0 kpa a los 70 kpa aproximadamente, teniendo eso en cuenta el error máximo permitido es:

$$Er_{max} = 3.5 \text{ kpa}$$

Al establecer este margen de error, se busca proporcionar una guía práctica y realista para la evaluación de la precisión y fiabilidad de los resultados obtenidos en pruebas de laboratorio. Además, se pretende fomentar la transparencia y la consistencia en la interpretación de datos geotécnicos, promoviendo así un enfoque más robusto y confiable en el diseño y análisis de estructuras geotécnicas, resumiendo todo lo anterior llamaremos que el modelo predictivo es de eficacia alta, moderado y baja si cumple estas condiciones.

Cuadro N° 43. Categorías de la eficacia.

Nivel de eficiencia de un modelo predictivo	Condición de intervalo de confianza
Eficiencia alta	Cumple las dos condiciones: R-cuadrado sustancial (75% -100%), y dentro del error permitido (<5%).
Eficiencia moderada	Cumple con una de las dos condiciones de R-cuadrado sustancial, y dentro del error permitido (<5%).
Eficiencia baja	No cumple ninguna de las dos condiciones de R-cuadrado sustancial, y dentro del error permitido (<5%).

Nota: Lo establecido en el cuadro se sustenta en los párrafos anteriores.

Hipotesis general


H0: Si mediante la aplicación de redes neuronales artificiales, no será posible predecir con nivel de eficacia alto los parámetros de resistencia al corte en suelos granulares, basándose en su comportamiento físico.

Hi: Si mediante la aplicación de redes neuronales artificiales, será posible predecir con un nivel de eficacia alto los parámetros de resistencia al corte en suelos granulares, basándose en su comportamiento físico.

A continuación se da a conocer los resultados finales de acuerdo a las medidas estadísticas planteadas.


Coefficiente de determinación.

Figura 42. *Gráfica de ángulo de fricción interna Real vs predicha*



Nota. Elaboración propia


Figura 43. *Gráfica de Cohesion Real vs predicha*



Nota. Elaboración propia


Análisis de los residuos de los valores predichos y valores observados (experimental), para los dos parámetros de resistencia al corte:

Figura 44. *Gráfica de distribución aleatoria residuos de angulo de friccion.*



Nota. Elaboración propia, en la gráfica los residuos son aleatorios y cercanas a cero lo que demuestra buen desempeño del modelo neuronal desarrollado para ángulo de fricción interna efectiva.

Figura 45. *Gráfica de distribución aleatoria residuos de Cohesion.*



Nota. Elaboración propia, en la gráfica los residuos no son aleatorios pero son cercanas a cero lo que demuestra moderado desempeño del modelo neuronal desarrollado para cohesión efectiva.

Para evaluar la significancia de coeficiente de determinación R^2 de los datos predichos vs observados de los parámetros de corte en suelos granulares obtenidos en este estudio (probabilidad de que los resultados reflejan un fenómeno real, y no simplemente producto del azar) se realizó la prueba F.

Cuadro N° 44. Reporte de prueba estadístico F (ϕ' y c').

Parámetro	Alfa	F estadístico	P-valor	Condición del modelo
Angulo de fricción interna efectiva	0.01	7.959	0.00006	Valor R-cuadrado significativo
Cohesión efectiva	0.01	4.201	0.00128	Valor R-cuadrado significativo

Nota. Resultados de significancia de R-cuadrado, reporte del código en Python.

Cabe mencionar que existen artículos relacionados al tema estudiado, que obtuvieron resultados de R^2 mayores a 0.9, Estas son aquellos que fueron entrenados, validados y probados con datos generados (por software, generados por modelos matemáticos, etc.) o datos de muestras de áreas muy pequeñas con lo que para estos existiría muy poca incertidumbre en los datos por ende el modelo neuronal desarrollados en esos artículos un R^2 elevado cercanas a 1, tal modelo neuronal tendría más útil solo para esos casos, mientras lo que se desarrolló en este estudio pretendió estimar los parámetros de corte para todo tipo de suelos granulares.

Métricas de error.

Las métricas de error calculadas en la etapa de prueba (comparación valores predichas y valores del ensayo-experimental) en este estudio se muestran en el siguiente cuadro:

Cuadro N° 45. *Métricas de error etapa de prueba.*

Parámetros	MAE	MSE	RMSE
Angulo de fricción interna efectiva	1.211	3.059	1.749
Cohesión efectiva	1.092	4.598	2.144

Nota. Resultados de significancia de R-cuadrado, reporte del código en Python.

Se obtuvo que R-cuadrado en la predicción de los parámetros de corte es mayor al umbral establecido de $R^2=0.75$, y el error (MAE, RMSE) son menores al 2.2° establecido para ϕ' y 3.5 Kpa para c' :

Por lo que se interpreta de acuerdo a este resultado que el modelo desarrollado predice con una alta eficacia los parámetros de corte; Angulo de fricción interna efectiva y la cohesión efectiva, para suelos granulares. Recordando que los rangos de la eficacia establecido en este estudio se sustentan de acuerdo a la literatura.

Otros estudios enfocados al tema investigado, los resultados de las métricas de error se visualizan en el siguiente cuadro. También nos sirve que el error del modelo desarrollado en este estudio no difiere por mucho con los que obtuvieron otros autores, con lo que en cierta forma validaría los resultados de error logrados en este estudio.

Cuadro N° 46. *Valores de coeficiente de determinacion y metricas de error.*

Autor	Método	$\phi' \text{ (Deg)}$			$c' \text{ (kg/cm}^2\text{)}$		
		MAE	RMSE	R2	MAE	RMSE	R2
Khanlari et al., 2011	ANN	1.94	2.51	-	0.028	0.037	-
Sarat Kumar & Pradir Kumar, 2008	ANN (ϕ_r)	-	-	0.87	-	-	-
Mojtaba Mohammadi et al., 2020	ANN-MLP	1.83	2.293	0.845	0.053	0.080	0.885

Por lo tanto se acepta la hipótesis de la investigación teniendo los resultados de las dos medidas estadísticas: el coeficiente de determinación R^2 significativo (sustentado por las pruebas de permutación y de residuos) y métricas de error calculados. Según el cuadro N° 46 se contrasta o se acepta para este estudio la hipótesis de la investigación y se rechaza la hipótesis nula.

4.3.2. *Discusión y Estrategia para contrastación de hipótesis específicos*

Para este estudio, la contrastación de hipótesis específicos se basó en los resultados obtenidos en la “importancia relativa de entrada” de una red neuronal, en un contexto de redes neuronales, la importancia relativa de los coeficientes de entrada se refiere a la contribución o importancia que cada variable de entrada (para esta investigación: indicadores) tiene en la predicción de un modelo neuronal desarrollado. Puede ser evaluada de varias maneras, para este estudio se optó por Análisis de Gradiente y Análisis de Sensibilidad (Permutación).

Cuadro N° 47. Resultado de importancia relativa de acuerdo al análisis de gradiente de entrada.

predictoras	ANALISIS DE GRADIENTE		ANALISIS DE GRADIENTE	
	Angulo de fricción interna efectiva		Cohesión efectiva	
	Importancia relativa (%)	Ranking de entrada según la importancia relativa	Importancia relativa (%)	Ranking de entrada según la importancia relativa
Distribución granulométrica	56.8%	1	56.6%	1
Límites de consistencia	14.21%	3	18.78%	2
Densidad	18.21%	2	10.91%	4
Humedad	10.77%	4	13.71%	3

Nota: Los resultados obtenidos son del proceso de análisis de gradiente de entrada desarrollados en lenguaje Python.

Fuente: Desarrollado por el autor de este estudio.

Cuadro N° 48. Resultado de importancia relativa de acuerdo al análisis de sensibilidad de entrada

predictoras	ANALISIS DE SENSIBILIDAD		ANALISIS DE SENSIBILIDAD	
	Angulo de fricción interna efectiva		Cohesión efectiva	
	Importancia relativa (%)	Ranking de entrada según la importancia relativa	Importancia relativa (%)	Ranking de entrada según la importancia relativa
Distribución granulométrica	58.3%	1	57.8%	1
Límites de consistencia	13.7%	3	18.5%	2
Densidad	17.6%	2	10.4%	4
Humedad	10.1%	4	13.2%	3

Nota: Los resultados obtenidos son del proceso de análisis de sensibilidad del modelo desarrollados en lenguaje Python.

Fuente: Desarrollado por el autor de este estudio.

Hipótesis específica 01.

Hi (1): Si la importancia relativa de la distribución granulométrica es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.

H0 (1): Si la importancia relativa de la distribución granulométrica es menor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces no es significativamente influyente.

La importancia relativa para la dimensión llamada **distribución granulométrica** resultó un **56.8% (Met. De gradiente)** y **58.3% (Met. De sensibilidad)** de importancia relativa en la predicción del ángulo de fricción interna efectiva y un **56.6% (Met. De gradiente)** y **57.8% (Met. De sensibilidad)** para la predicción de la cohesión efectiva, lo que le convierte en la dimensión más influyente (entre las dimensiones evaluadas en este estudio) en la predicción de parámetros de corte en un suelo granular.

Cabe destacar la gran importancia relativa en la predicción del modelo desarrollado, del indicador cuantitativo llamado de **partículas finas** del suelo, dentro de la dimensión **distribución granulométrica**, ya que solo este indicador representa una importancia relativa de **11.07% (Met. De gradiente)** y **11.4% (Met. De sensibilidad)** en la predicción del ángulo de fricción interna efectiva y **19.29% (Met. De gradiente)** y **19.8% (Met. De sensibilidad)** para la predicción de la cohesión efectiva, siendo esta uno de los indicadores más importante de las 10 que se evaluaron para este estudio, las cuales describen el comportamiento físico de un suelo (variable predictora).

De acuerdo a los resultados obtenidos se acepta la hipótesis específica de la investigación Hi(1), donde la importancia relativa de la dimensión llamada **distribución granulométrica** es mayor a 5% en el modelo neuronal siendo así significativamente influyente para la predicción de los parámetros de resistencia al corte de acuerdo al análisis de sensibilidad y gradiente de entrada.

Hipótesis específica 02.

Hi (2): Si la importancia relativa de los límites de consistencia es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.

H0 (2): Si la importancia relativa de los límites de consistencia es menor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces no es influyente.

Para **límites de consistencia** la predicción de los parámetros de resistencia al corte de acuerdo a los dos análisis de gradiente y sensibilidad de entrada resulta un **14.2% y 13.7%** de importancia relativa respectivamente, en la predicción del ángulo de fricción interna efectiva y **18.78% y 18.5%** para la predicción de la cohesión efectiva. Siendo esta el segundo dimensión más importante de las 4 en la predicción de la cohesión efectiva, según el modelo desarrollado.

De acuerdo a los resultados obtenidos se acepta la hipótesis específica de la investigación Hi (2) ya que la importancia relativa de la dimensión llamada **límites de consistencia** es mayor al 5% en el modelo neuronal siendo así significativamente influyente, para la predicción de los parámetros de resistencia al corte de un suelo granular, este de acuerdo al análisis de sensibilidad y análisis gradiente de entrada.

Hipótesis específica 03.

Hi (3): Si la importancia relativa de la densidad es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.

H0 (3): Si la importancia relativa de la densidad es menor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces no es influyente.

Para la **densidad seca aparente** en la predicción de los parámetros de resistencia al corte de acuerdo a los dos análisis de gradiente y sensibilidad de entrada resulta **14.2% y 13.7%** de importancia relativa respectivamente, en la predicción del ángulo de fricción interna efectiva y **14.2% y 13.7%** para la predicción de la cohesión efectiva. Siendo esta el segundo dimensión más importante de las 4 en la predicción del Angulo de fricción interna efectiva, según el modelo desarrollado.

Se acepta la hipótesis específica de la investigación Hi(3) ya que la importancia relativa de la dimensión llamada **densidad seca aparente** es mayor al 5% en el modelo neuronal siendo así significativamente influyente, para la predicción de los parámetros de resistencia de acuerdo al análisis de sensibilidad y gradiente de entrada.

Hipótesis específica 04.

Hi (4): Si la importancia relativa de la humedad es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.

H0 (4): Si la importancia relativa de la humedad es menor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces no es influyente.

Para el **contenido de humedad** en la predicción de los parámetros de resistencia al corte de acuerdo a los dos análisis de gradiente y sensibilidad de entrada resulta **10.77% y 10.1%** de importancia relativa respectivamente, en la predicción del ángulo de fricción interna efectiva y **13.71% y 13.2%** para la predicción de la cohesión efectiva. Siendo esta el tercer dimensión más importante de las 4 en la predicción de la cohesión efectiva y el menos importante para predecir el Angulo de fricción interna efectiva, según el modelo desarrollado. Cabe mencionar que el contenido de humedad sea menos importante en relación a las otras 3, pero es significativamente importante ya que su importancia supera el 5%.

Se acepta la hipótesis específica de la investigación Hi(4) ya que la importancia relativa de la dimensión llamada **contenido de humedad** es mayor al 5% en el modelo neuronal siendo así significativamente influyente, para la predicción de los parámetros de resistencia de acuerdo al análisis de sensibilidad y gradiente de entrada.

5. CONCLUSIONES

El modelo neuronal desarrollado en este estudio se sustenta con la comparación de los valores predichos por el modelo y los datos observados en los ensayos resulta un R-cuadrado de **0.86**, un Error Medio Absoluto de 1.21° , Raíz del Error Cuadrático Medio de 1.75° para ángulo de fricción efectiva interna y R-cuadrado de **0.77**, un Error Medio Absoluto de 1.09 kpa, Raíz del Error Cuadrático Medio de 2.14 kpa para cohesión efectiva, estos resultados están dentro del umbral establecido por literatura especializada. Con lo que se concluye que el modelo neuronal desarrollado (**entrenado y validado**) a base de datos recolectados de investigaciones realizadas en universidades peruanas (tesis) y **probado** con datos observados (ensayo-experimental con equipo de corte directo), predice con una **eficacia alta** los parámetros de resistencia al corte (ϕ' y c') en suelos granulares a partir de su comportamiento físico (*distribución granulométrica, límite de consistencia, densidad seca y contenido de humedad*), aquel modelo neuronal se ha centrado para ensayos de corte directo (directrices a ASTM-D 3080).

En este estudio de investigación se determinó la **importancia relativa de la distribución granulométrica mayor a los 5%** en el modelo neuronal diseñado para predecir los parámetros de resistencia al corte (ϕ' y c') en suelos granulares, aquel modelo se ha centrado en ensayos de corte directo (ASTM-D 3080). Tal conclusión se debe a los resultados obtenidos de análisis de gradiente y análisis de sensibilidad de entrada (características de entrada o indicadores para este estudio), por lo que implica que la **distribución granulométrica es significativamente influyente**. Además la distribución granulométrica es dimensión de la variable comportamiento físico, más influyente en el modelo neuronal desarrollado a comparación que las otras dimensiones límite de consistencia, contenido de humedad y densidad seca aparente. Además, es relevante mencionar que de los seis indicadores (% Grava gruesa, % G. fina, % Arena gruesa, % A. mediana, % A. fina y % partículas finas) que cuantifican la dimensión llamada distribución granulométrica, el indicador más influyente es el % de partículas finas.

Otra de las conclusiones para este estudio de investigación es que se determinó la **importancia relativa del límite de consistencia mayor a los 5%** en el modelo neuronal diseñado para predecir los parámetros de resistencia al corte (ϕ' y c') en suelos granulares, aquel modelo se ha enfocado en ensayos de corte directo (ASTM-D 3080). Esta conclusión

se debe a los resultados obtenidos de análisis de gradiente y análisis de sensibilidad de entrada (características de entrada o indicadores para este estudio), en consecuencia el ***límite de consistencia es significativamente influyente***. Además el límite de consistencia es la segunda dimensión del variable comportamiento físico más influyente en el modelo neuronal desarrollado para predecir la cohesión efectiva (c'), y la tercera para predecir ángulo de fricción efectiva (ϕ').

También se determinó la ***importancia relativa de la densidad seca mayor a los 5%*** en el modelo neuronal diseñado para predecir los parámetros de resistencia al corte (ϕ' y c') en suelos granulares, aquel modelo se ha centrado en ensayos de corte directo (ASTM-D 3080). Esta conclusión se debe a los resultados obtenidos de análisis de gradiente y análisis de sensibilidad de entrada (características de entrada o indicadores para este estudio), en consecuencia la ***densidad seca es significativamente influyente***. Además la densidad seca es la segunda dimensión del variable comportamiento físico más influyente en el modelo neuronal desarrollado en la predicción del ángulo de fricción efectiva (ϕ'), y la menos influyente que las otras dimensiones ya mencionadas, en la predicción de cohesión efectiva (c').

Finalmente este estudio de investigación determinó la ***importancia relativa del contenido de humedad mayor a los 5%*** en el modelo neuronal desarrollado para predecir los parámetros de resistencia al corte (ϕ' y c') en suelos granulares, aquel modelo se ha enfocado en ensayos de corte directo (ASTM-D 3080). Esta conclusión se debe a los resultados obtenidos de análisis de gradiente y análisis de sensibilidad de entrada, en consecuencia el ***contenido de humedad es significativamente influyente***. Además se puede generalizar que el contenido de humedad es la menos influyente que las otras dimensiones, en la predicción de parámetros de resistencia al corte (ϕ' y c'), eso no involucra que no sea ***significativamente influyente ya que esta sobre los 5%***.

6. RECOMENDACIONES

Se recomienda a ingenieros geotécnicos y de suelos o investigadores interesados, si desea utilizar el modelo neuronal desarrollado en este estudio para la predicción de los parámetros de corte (ϕ' y c') a partir de su comportamiento físico tales ensayos como: Análisis Granulométrico por Tamizado, ensayo de Límites de Atterberg, ensayo de determinación de contenido de humedad y de densidad, realizar estos ensayos siguiendo estrictamente los procedimientos establecidos en estándares internacionales de ASTM con el fin de tener lo menos incertidumbre posible en los datos, para luego tener una eficacia alta en la predicción del modelo neuronal en los parámetros de corte a partir de los ensayos mencionados. Para futuros estudios se podría mejorar el modelo neuronal de manera significativa si se entrena y valida con datos de fuentes primarias (ensayos recopilados), y probarlos en diferentes laboratorios (control), por lo que esta opción aumentaría la precisión en la predicción de los parámetros de corte (ϕ' y c').

La práctica común (no especificado en norma ASTM 3080) realizado por la comunidad de ingeniería enfocados en suelos de este país, que para aquellos suelos con presencia de partículas de grava, se tamiza con la malla N° 4 obteniendo una muestra de suelo adecuado para equipos de corte directo más comunes y más comercializados (diámetro 2") que fueron diseñados para arenas, limos y arcillas (para suelos con partículas menores iguales a malla N° 4 o 4.75 mm), es aceptado esta forma de procedimiento para suelos con presencia de grava teniendo en cuenta que los resultados obtenidos son conservadores (corresponde al especialista en mecánica de suelos decidir sobre los resultados sin que lleve a sobre dimensionar la estructura), teniendo esto en cuenta en este estudio no se incluyó datos de ensayos de corte directo especialmente para gravas, como ensayos de corte directo de gran escala que se practica últimamente en suelos con presencia de partículas de gran tamaño como gravas. Eso no significa que los resultados estimados en este estudio para gravas sean erróneo, como se mencionó antes. Los resultados que se obtiene del modelo neuronal desarrollado en este estudio, son más conservadores y se sugiere la decisión del ingeniero responsable en tomar dichos valores (parámetros de corte ϕ' y c'). Por lo tanto para investigaciones futuras se recomienda aumentar para su entrenamiento, validación y aprobación con resultados de corte directo a gran escala para suelos con presencia de grava (GW, GP, GW-GM, GW-GC, GP-GM, GP-GC, GM, GC y GC-GM).

Como ya se aclaró en el estudio sobre la exclusión de los suelos arcillosos y suelos consolidados, por lo que el modelo neuronal desarrollado en esta investigación no fue entrenado con este tipo de suelos ya que conlleva ciertos datos adicionales como la composición química o mineral, proporción de arcilla y limo, condición de drenaje, grado de consolidación y entre otros. Por consiguiente se exhorta a la comunidad científica enfocados a suelos, en crear una modelo neuronal predictor los parámetros de corte considerando tales suelos. Además otra de las propuestas de investigaciones futuras, incluir o crear un modelo neuronal predictor considerando ensayos de triaxial considerando los tres tipos de prueba UU, CU, CD.

Los suelos no cohesivos que fueron extraídas para la ***etapa de prueba*** (muestra que consta de 39 diferentes suelos), el investigador trato dar mayor importancia para la variabilidad en tipo de suelo mas no del lugar de procedencia esto por las limitaciones económicas del investigador, por ello para futuras investigaciones se sugiere probar con un tamaño de muestra mucho más grande (más de 250, sugerido por el autor) y de diferentes puntos del país de Perú (abarcando mayor área), teniendo esos datos (fuente primaria) el modelo neuronal a desarrollarse tendría mayor precisión en los resultados, claro con estos nuevos datos se sugiere realizar una Validación cruzada a fin que influyera en el entrenamiento y validación del antiguo modelo neuronal.

7. Bibliografía

- AASHTO. (2008). *Classification of Soils and Soil-Aggregate Mixtures for Highway Construction Purposes. M145-91.* . Washington DC.
- American Society for Testing and Materials. (2000). *Standard Test Methods for Liquid Limit, Plastic Limit, and Plasticity Index of Soils.* (ASTM D4318). <https://www.astm.org/d4318-00.html>
- American Society for Testing and Materials, [ASTM D422]. (1998). Standard Test Method for Particle-Size Analysis. *ASTM D422*. <https://www.astm.org/d0422-63r98.html>
- Arora, K. R. (2004). *Soil mechanics and foundation engineering* (6 ed.). Nai SARAK.
- Aysen, A. (2002). *Soil mechanics: Basic concepts and engineering applications*. Swets & Zeitlinger B. V.
- Barnes, G. E. (1995). *Soil mechanics principles and practice*. MACMILLAN.
- Bowles, J. E. (1981). *Manual de laboratorio de suelos en ingeniería civil*. Bogota, Colombia: McGraw-Hill.
- Bowles, J. E. (1997). *Foundation analysis and design*. McGraw-Hill .
- Boza Capani , M., & Merino Ortiz, R. (2018). *parámetros de resistencia al corte de suelos a partir de sus propiedades físicas, utilizando redes neuronales artificiales y equipo triaxial, UNH*. [Tesis de pregrado, Universidad Nacional de Huancavelica UNH]. <https://repositorio.unh.edu.pe/items/27d74174-b7b7-435c-86c0-4704120ef527>
- Budhu, M. (2010). *Soil Mechanics and Foundations*. (3 ed.). John Wiley & Sons.
- Budhu, M. (2015). *Soil mechanics fundamentals*. USA: Wiley Blackwell.
- Caballero Romero, A. (2014). *Metodología integral innovadora para planes y tesis*. Mexico: CENGAGE Learning.
- Chicco, D., J. Warrens, M., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, 623. <https://doi.org/https://doi.org/10.7717/peerj-cs.623>
- Chin, W. W. (1998). *The partial least squares approach to structural equation modelling*. Lawrence Erlbaum Associates Publishers: Mahwah.
- Code of Federal Regulations Safety [CFR]; Health Regulations for Construction. (1926). *Soil classification-excavations*. <https://www.osha.gov/laws-regs/regulations/standardnumber/1926/1926SubpartPAppA>
- Coulomb, A. (1776). *Teoría de Coulomb*.
- Crespo Villalaz, C. (2004). *Mecánica de suelos y cimentaciones*. Limusa noriega.
- Das, B. M. (2008). *Advanced soil mechanics* (3 ed.). Taylor & Francis Group.
- Das, B. M. (2012). *Fundamentos de ingeniería de cimentaciones* (7 ed.). Cengage Learning.
- Das, B. M. (2015). *Fundamentos de ingeniería geotécnica*. (4 ed.). CENGAGE Learning.
- Das, B. M., & Sobhan, K. (2018). *Principles of Geotechnical Engineering*. (9 ed.). Cengage Learning.
- Department of Commerce-National Bureau of Standards [NBS]. (1980). *Soil classification for construction practice in shallow trenching*. U. S.: Building Science Series 121 (NBS BSS 121).

- Duque Escobar, G. (2003). *Manual de geología para ingenieros*. Universidad Nacional de Colombia. <http://www.bdigital.unal.edu.co/1572/>
- Escuela de ingenieros militares. (1989). Manual de laboratorio de suelos. *Cap.(1)*.
- Falcón, J. C., & Herrera, R. (2005). *Análisis del ato Estadístico (Guía didáctica)*. Caracas: Universidad Bolivariana de Venezuela.
- Fayat Group. (01 de 2019). Dynapac: http://dynapac.blog/latinoamerica/wp-content/uploads/2019/01/Imagen2_1.jpg
- Forsythe, W. (1985). *Manual de laboratorio de Física de Suelos* (1 ed.). Instituto Interamericano de cooperación para la Agricultura (IICA) . <https://repositorio.iica.int/handle/11324/7841>
- Garder, W. H., Baver, L. D., & Garder, W. R. (1973). *Física de suelos*. Hispano-Americana.
- Giesecking, J. E. (1975). *Organic components*. Springer.
- González Muñiz, A. (2018). Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales. *Universidad de Oviedo*.
- González Ovalle, K. (2014). *Análisis granulométrico de un material poroso*. Bogota: Universidad de los Andes.
- GrupoCipsa. (s.f.). *Diferencias entre suelos cohesivos y granulares*. <https://www.cipsa.com.mx/26/noticias/diferencias-entre-suelos-cohesivos-y-granulares/>
- Hair, J., Sarstedt, M., & Volker, K. (2014). Partial Least Squares Structural Equation Modeling (PLS-SEM): An Emerging Tool in Business Research. *European Business Review*, <https://www.researchgate.net/publication/258046807>
- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, M. D. (2014). *Metodología de la investigación*. Mexico: McGRAW-HILL / INTERAMERICANA EDITORES S.A.
- Holtz, R. D., Kovacs, W. D., & Sheahan, T. C. (2011). *An introduction to geotechnical engineering* (2 ed.). Pearson.
- Hough, B. K. (1957). *Basic soils engineering*. The Ronald Press Company.
- Huat, B. B., Prasad, A., Asadi, A., & kazemian, S. (2014). Geotechnics of organic soils and peat. *Researchgate*. https://www.researchgate.net/publication/328076548_Geotechnics_of_Organic_Soils_and_Peat
- IngeCivil. (09 de 08 de 2018). *Información sobre los suelos cohesivos*. <https://www.ingecivil.net/2018/08/09/informacion-sobre-los-suelos-cohesivos/>
- Instituto Profesional Centro De Formación Técnica. (2015). *Propiedades, índices de los suelos*. Universidad Tecnológica De Chile, Dirección de ingeniería-Area de construcción. <https://www.astm.org/d4318-00.html>
- Izaurieta , F., & Saavedra, C. (s.f). Redes neuronales artificiales. *universidad de concepcion, chile*.
- Jaramillo Jaramillo, D. F. (2002). *Introducción a la ciencia del suelo*. universidad nacional de colombia.
- Khanlari, G. R., Heidari, M., Momeni, A. A., & Abdilor, Y. (2011). Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods. *ScienceDirect, Engineering Geology*(131-132), 11-18.

- Lambe, W. T., & Whitman, R. V. (2012). *Mecánica de suelos* (1 ed.). LIMUSA.
- Manrique Dávila, M. (2019). *Predicción de propiedades mecánicas de suelos utilizando redes neuronales artificiales*. [Tesis de pregrado, Universidad Continental].
<https://repositorio.continental.edu.pe/handle/20.500.12394/7191>
- Mohamed A., S., Mark B., J., & Holger R., M. (2001). artificial neural network applications in geotechnical engineering. *Australian geomechanics*.
https://www.academia.edu/19630807/artificial_neural_network_applications_in_geotechnical_engineering?sm=b
- Montenegro Gonzales, H., & Malagon Dimas, C. (1990). *Propiedades físicas de los suelos*. Instituto Geográfico Agustín Codazzi IGAC.
- Morh, O. (1900). Welche Umstände Bedingen die Elastizitätsgrenze und den Bruch eines Materiales. *Zeitschrift des Vereines Deutscher Ingenieure*, 44(1), 1524-1530, 1572-1577.
- Motta, B., Montenegro G., H., & Rodriguez T., C. (1990). *Métodos analíticos del laboratorio de suelos* (5 ed.). Instituto Geográfico Agustín Codazzi IGAC.
- NetApp. (s.f). ¿Qué es la inteligencia artificial?: <https://www.netapp.com/es/artificial-intelligence/what-is-artificial-intelligence/>
- Olden, J. D., Joy, M. K., & Death, R. G. (2004). An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Economic Modelling*, 178(3), 389-397.
- Russell, R. (2018). *Deep Learning. Fundamentos del aprendizaje profundo para principiantes*.
- Russell, R. (2018). *Machine Learning. Guía Paso a Paso Para Implementar Algoritmos de Machine Learning Con python*.
- Sarat Kumar, D., & Pradir Kumar, B. (2008). Predition of residual friction angle of clays using Artificial Neural Network. *ScienceDirect., Enginnering Geology*(100), 142-145.
<https://www.sciencedirect.com/science/article/abs/pii/S0013795208000768?via%3Dihub#preview-section-cited-by>
- Scott, C. R. (1980). *Soil mechanics and foundations* (3 ed.). Applied science publishers LTD.
- Solis Galvez, E. M. (2023). *Diseño de una red neuronal artificial no supervisada para la estimación de parámetros de resistencia al corte de suelos a partir de sus propiedades físicas*. [Suficiencia profesional pregrado, Universidad Nacional Mayor].
<https://cybertesis.unmsm.edu.pe/handle/20.500.12672/19800>
- Supo Condori, F., & Cavero Aybar, H. N. (2014). *Fundamentos Teóricos Y Procedimentales De La Investigación Científica En Ciencias Sociales*. El universitario.
- Supo, J., & Zacarías, H. (2020). *METODOLOGÍA DE LA INVESTIGACIÓN CIENTÍFICA*. Mexico: Independently Published.
- Sushama Kiran, B. L., & Tripathy, S. S. (2016). Shear Strength Prediction of Soil based on Probabilistic Neural Network. *Indian Journal of Science and Technology*, 9(49), 1-6.
<https://indjst.org/articles/shear-strength-prediction-of-soil-based-on-probabilistic-neural-network>
- Terzaghi, K., & Peck, R. B. (1973). *Mecanica de suelos en la ingeniería practica* (2 ed.). El ateneo S.A.
- Terzaghi, K., Peck, R. B., & Mesri, G. (1996). *Soil mechanics in enginnering practice* (3 ed.). Jhon Wiley y Sons.

- Thinh , K. D. (2001). How Reliable is Your Angle of Internal Friction?" Proceedings. *XV International Conference on Soil Mechanics and Geotechnical Engineering*, 1(1), 76-76.
- Valderrama Purizaca, F. j. (2020). *Desarrollo de un modelo de redes neuronales artificiales para predecir las propiedades mecánicas del suelo*. [Tesis de pregrado, Universidad Señor de Sipan]. <https://repositorio.uss.edu.pe/handle/20.500.12802/8395>
- Valerio salas, O. (2011). Ensayos triaxiales para suelos: Metodos y materiales. *e-Dialnet*, Vol 1(1), 14-24. <https://dialnet.unirioja.es/servlet/articulo?codigo=6240951>
- Vara Horna, A. (2010). *¿còmo evaluar la rigurosidad cientifica de las tesis doctorales?* Lima, Peru: Fondo editorial Universidad de San Martin de Porres USMP.
- Venegas Sepúlveda, A. P. (2008). *Caracterización de la materia orgánica de suelos de praderas naturales y cultivadas de la IX región*. UCHILE. <https://repositorio.uchile.cl/handle/2250/105696>
- Verruijt, A. (2006). *Soil Mechanics*. Delft University of Technology. <https://geo.verruijt.net/>
- Wesley , L. D. (2003). Residual strength of clays and correlations using Atterberg limit. . *Geotechnique*, 53(7), 669-672.
- Xing, Z. W. (2013). Trivariate analysis of soil ranking-correlated characteristics and its application to probabilistic stability assessments in geotechnical engineering problems. *Soils and Foundations*, 53(4), 540-556. <https://doi.org/https://www.sciencedirect.com/science/article/pii/S003808061300070X>

ANEXO N°1

MATRIZ DE CONSISTENCIA

TITULO: Eficacia en la predicción de los parámetros de resistencia al corte a partir del comportamiento físico en suelos granulares empleando redes neuronales artificiales-experimental, Perú 2023

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLES	METODOLOGÍA	POBLACIÓN Y MUESTRA
¿Se podrá predecir con un nivel de eficacia alta los parámetros de resistencia al corte en suelos granulares a partir de su comportamiento físico empleando redes neuronales artificiales?	Predecir los parámetros de resistencia al corte en suelos granulares, a partir de su comportamiento físico mediante el uso de redes neuronales artificiales, con un alto nivel de eficacia.	Si mediante la aplicación de redes neuronales artificiales, será posible predecir con nivel de eficacia alta los parámetros de resistencia al corte en suelos granulares, basándose en su comportamiento físico .	Variable Independiente (predictora) comportamiento físico Dimensiones: <i>*Distribución granulométrica.</i> <i>* Límites de consistencia</i> <i>*Densidad</i> <i>*Humedad</i>	Método: inductivo. Orientación de investigación: Aplicada. Enfoque: Cuantitativo. Nivel de la investigación: Predictivo. Tipos de Investigación Según la Intervención del investigador: Experimental. Según el número de mediciones de la variable de estudio: Transversal. Según el control de la medición: Retrospectivo. Según el propósito de estudio: Aplicada. Según número de variables de interés: Analítico.	Población: Suelos granulares típicos de Perú. Muestra cuantitativa: Registro de suelos granulares de repositorio de universidades del Perú y suelos granulares de grupo experimental. Unidad de estudio: Suelo granular. Técnicas de muestreo: No probabilístico-intencional. Técnicas de recolección de datos: Documentación - observación. Instrumento de recolección de datos: retroactivo-proyectivo (fichas de recolección de datos y guía de observación). Técnicas procesamiento de información: 1. Coeficiente de determinación 2. Análisis de entradas Delimitación temporal: 2023.
Problemas específicos	Objetivos específicos	Hipótesis específicos			
¿Cuál es la importancia relativa de la distribución granulométrica en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?	Determinar la importancia relativa de la distribución granulométrica en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.	Si la importancia relativa de la distribución granulométrica es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.			
¿Cuál es la importancia relativa de los límites de consistencia en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?	Determinar la importancia relativa de los límites de consistencia en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.	Si la importancia relativa de los límites de consistencia es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.	Variable Dependiente (evaluada) Parámetros de resistencia al corte Dimensiones: <i>* Cohesión(kg/cm2)</i> <i>*Angulo de fricción interna (Ø)</i>		
¿Cuál es la importancia relativa de la densidad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?	Determinar la importancia relativa de la densidad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.	Si la importancia relativa de la densidad es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.			
¿Cuál es la importancia relativa de la humedad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte de suelos granulares?	Determinar la importancia relativa de la humedad en un modelo neuronal diseñado para predecir los parámetros de resistencia al corte en suelos granulares.	Si la importancia relativa de la humedad es mayor al 5% en un modelo neuronal que predice los parámetros de resistencia al corte de un suelo granular, entonces es significativamente influyente.		Diseño de Investigación (Cuasi-experimento).	

ANEXO N° 2 ESTADISTICA DE DATOS

In [1]:

```
##IMPORT PACKAGES

import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import pyplot
import numpy as np
import seaborn as sns
#PARA QUANTILE
import pylab
import scipy.stats as stats
from scipy import stats

from sklearn import preprocessing
from sklearn.preprocessing import PowerTransformer
#redes neuronales

#para tabular
from tabulate import tabulate
```

In [2]:

```
#IMPORT from DATA
dataset_import = pd.read_csv('DATASET.csv')
df=pd.DataFrame(round(dataset_import,3))
df
```

Out[2]:

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
0	0.0	0.00	20.27	10.28	66.77	2.69	0.0	0.0	1.91	0.46	42.19	2.84
1	0.0	0.00	0.62	16.40	78.69	4.29	0.0	0.0	1.59	0.39	36.93	1.37
2	0.0	0.00	0.39	10.30	85.41	3.90	0.0	0.0	1.66	0.24	36.30	3.82
3	0.0	0.00	0.52	10.53	85.38	3.57	0.0	0.0	1.63	0.36	34.00	1.57
4	0.0	0.06	2.63	11.90	82.12	3.29	0.0	0.0	1.55	1.29	33.25	2.65
...	...	...	...	...	...	...	...	...	...	...	...	...
1100	0.0	8.66	31.00	42.00	15.68	2.66	0.0	0.0	1.68	2.70	39.82	4.90
1101	0.0	19.77	26.90	46.00	3.09	4.24	0.0	0.0	1.76	0.90	38.71	3.73
1102	0.0	20.57	11.00	27.20	36.99	4.24	0.0	0.0	1.59	24.60	28.78	0.00
1103	0.0	24.56	16.40	33.40	21.63	4.01	0.0	0.0	1.62	22.40	31.88	0.00
1104	0.0	9.84	24.20	37.00	22.97	5.99	0.0	0.0	1.62	6.00	33.69	0.00

1105 rows × 12 columns

In [3]:

```
## grafico de datos
fig = plt.figure(figsize=(20, 3))
ax1 = fig.add_subplot(1, 4, 1)
ax2 = fig.add_subplot(1, 4, 2)
ax3 = fig.add_subplot(1, 4, 3)
ax4 = fig.add_subplot(1, 4, 4)

fig2 = plt.figure(figsize=(20, 3))
ax5 = fig2.add_subplot(1, 4, 1)
ax6 = fig2.add_subplot(1, 4, 2)
ax7 = fig2.add_subplot(1, 4, 3)
ax8 = fig2.add_subplot(1, 4, 4)

fig3 = plt.figure(figsize=(20, 3))
ax9 = fig3.add_subplot(1, 4, 1)
ax10 = fig3.add_subplot(1, 4, 2)
ax11 = fig3.add_subplot(1, 4, 3)
ax12 = fig3.add_subplot(1, 4, 4)

ax1.set_title("GRAVA GRUESA")
ax1.plot(df["GRAVA GRUESA"], linewidth=0, marker="+", color="orange", markersize=3)
ax2.set_title("GRAVA FINA")
ax2.plot(df["GRAVA FINA"], linewidth=0, marker="+", color="orange", markersize=3)
ax3.set_title("ARENA GRUESA")
ax3.plot(df["ARENA GRUESA"], linewidth=0, marker="+", color="orange", markersize=3)
ax4.set_title("ARENA MEDIANA")
ax4.plot(df["ARENA MEDIANA"], linewidth=0, marker="+", color="orange", markersize=3)


ax5.set_title("ARENA FINA")
ax5.plot(df["ARENA FINA"], linewidth=0, marker="+", color="blue", markersize=3)
ax6.set_title("PART. FINOS")
ax6.plot(df["PART. FINOS"], linewidth=0, marker="+", color="blue", markersize=3)
ax7.set_title("LIMITE LIQUIDO")
ax7.plot(df["LL"], linewidth=0, marker="+", color="blue", markersize=3)
ax8.set_title("INDICE PLASTICO")
ax8.plot(df["IP"], linewidth=0, marker="+", color="blue", markersize=3)
```

```

ax9.set_title("D. SECA")
ax9.plot(df["D. SECA"], linewidth=0, marker="o", color="yellow", markersize=3)
ax10.set_title("HUMEDAD")
ax10.plot(df["HUMEDAD"], linewidth=0, marker="o", color="yellow", markersize=3)
ax11.set_title("ANGULO DE FRICCION EFECTIVA")
ax11.plot(df["ANGULO"], linewidth=0, marker="o", color="yellow", markersize=3)
ax12.set_title("COHESION EFECTIVA")
ax12.plot(df["COHESION"], linewidth=0, marker="o", color="yellow", markersize=3)
plt.savefig("descrip3.png")

plt.show()

```



```

In [4]: ##### TABULACION DE DATOS MEDIANTE ESTADISTICA DESCRIPTIVA

## TENDENCIA CENTRAL
media=round(df.mean(),3)
mediana=round(df.median(),3)
moda=round(df.mode(),3)
moda=moda.loc[0]
moda=moda.tolist()
media=media.tolist()
mediana=mediana.tolist()

matriz=[media,mediana,moda]
df_Mcentral=pd.DataFrame(matriz,index=["media", "mediana", "moda"],columns=["GRAVA GRUESA", "GRAVA FINA", "ARENA GRUESA", "ARENA MEDIANA", "ARENA FINA", "PART. FINOS", "LL", "IP", "DENSIDAD SECA", "HUMEDAD", "ANGULO", "COHESION"])
df_Mcentral

```

```

Out[4]:

```

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	DENSIDAD SECA	HUMEDAD	ANGULO	COHESION
media	7.089	16.313	8.98	15.345	32.524	19.75	14.606	4.09	1.634	14.075	30.158	7.445
mediana	0.000	9.840	7.31	13.000	24.010	12.60	17.000	0.00	1.620	12.000	30.500	4.710
moda	0.000	0.000	0.00	0.000	0.000	18.17	0.000	0.00	1.550	20.000	30.000	0.000

```

In [5]: ##MEDIDA DE DISPERSION

varianza=round(np.var(df,ddof=1))
varianza=pd.Series(varianza,name="varianza")
Ndatos=df.count()
Ndatos=pd.Series(Ndatos,name="count")
Mdispersion=round(df.describe(),1)
Mdispersion=Mdispersion.iloc[2:,:]
MMdispersion=Mdispersion.append(varianza)
MMdispersion=MMdispersion.append(Ndatos)
MMdispersion

```

```

Out[5]:

```

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
std	14.0	20.2	8.0	11.6	28.4	20.3	15.2	5.7	0.2	10.6	6.0	8.4
min	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	1.0	0.0	10.3	0.0
25%	0.0	0.0	2.3	6.8	10.5	4.4	0.0	0.0	1.5	5.3	26.5	1.0


	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
50%	0.0	9.8	7.3	13.0	24.0	12.6	17.0	0.0	1.6	12.0	30.5	4.7
75%	6.0	24.6	14.0	21.9	48.8	28.3	27.1	7.6	1.8	20.9	34.0	11.8
max	70.3	87.7	35.0	74.0	98.9	93.1	64.6	36.0	2.3	63.1	50.0	72.6
varianza	196.0	410.0	63.0	134.0	804.0	410.0	231.0	33.0	0.0	112.0	36.0	71.0
count	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0	1105.0

In [6]:

```
##CORRELACION ENTRE INDICADORES

#Graficar datos
Etiq_Xi = ["GRAVA GRUESA", "GRAVA FINA", "ARENA GRUESA", "ARENA MEDIANA", "ARENA FINA", "PART. FINOS", "LL", "IP", "D. SECA", "HUMEDAD", "ANGULO", "COHESION"]

sns.pairplot(df, vars=Etiq_Xi)
plt.savefig("im_relacion.png")
#diag_kind="hist"
```



In [7]:

```
##MATRIZ DE CORRELACION
df_corr=df.corr(method='spearman')
df_corr=round(df_corr,3)
df_corr
```


Out[7]:

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
GRAVA GRUESA	1.000	0.425	0.254	-0.019	-0.479	-0.067	0.118	0.152	0.247	0.022	0.165	0.025

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
GRAVA FINA	0.425	1.000	0.445	0.009	-0.769	-0.117	0.095	0.108	0.464	-0.122	0.305	-0.024
ARENA GRUESA	0.254	0.445	1.000	0.453	-0.478	-0.175	-0.057	-0.004	0.432	-0.310	0.497	-0.048
ARENA MEDIANA	-0.019	0.009	0.453	1.000	-0.061	-0.087	-0.061	-0.020	0.067	-0.162	0.097	-0.039
ARENA FINA	-0.479	-0.769	-0.478	-0.061	1.000	-0.164	-0.266	-0.290	-0.349	0.018	-0.177	-0.158
PART. FINOS	-0.067	-0.117	-0.175	-0.087	-0.164	1.000	0.629	0.612	-0.307	0.428	-0.596	0.677
LL	0.118	0.095	-0.057	-0.061	-0.266	0.629	1.000	0.893	-0.186	0.351	-0.463	0.647
IP	0.152	0.108	-0.004	-0.020	-0.290	0.612	0.893	1.000	-0.130	0.263	-0.410	0.661
D. SECA	0.247	0.464	0.432	0.067	-0.349	-0.307	-0.186	-0.130	1.000	-0.403	0.584	-0.177
HUMEDAD	0.022	-0.122	-0.310	-0.162	0.018	0.428	0.351	0.263	-0.403	1.000	-0.512	0.148
ANGULO	0.165	0.305	0.497	0.097	-0.177	-0.596	-0.463	-0.410	0.584	-0.512	1.000	-0.422
COHESION	0.025	-0.024	-0.048	-0.039	-0.158	0.677	0.647	0.661	-0.177	0.148	-0.422	1.000

In [8]:

```
##MATRIZ DE CORRELACION ESCALA COLOR
df_corrabs=abs(df.corr(method='spearman'))
df_corrabs
sns.heatmap(df_corrabs,xticklabels=df_corrabs.columns,yticklabels=df_corrabs.columns,cmap='Reds')
plt.savefig("im_relacio2.png")
```



In [18]:

```
##MEDIDAS DE DISTRIBUCION- HISTOGRAMAS
sns.displot(data=df, x="GRAVA GRUESA",kde=True, color="blue",height=4)

sns.displot(data=df, x="GRAVA FINA",kde=True, color="blue",height=4)
sns.displot(data=df, x="ARENA GRUESA",kde=True,color="blue",height=4)






sns.displot(data=df, x="ARENA MEDIANA",kde=True,color="yellow",height=4)






sns.displot(data=df, x="ARENA FINA",kde=True,color="yellow",height=4)
sns.displot(data=df, x="PART. FINOS",kde=True,color="yellow",height=4)
sns.displot(data=df, x="LL",kde=True,color="black",height=4)



sns.displot(data=df, x="IP",kde=True,color="black",height=4)
sns.displot(data=df, x="D. SECA",kde=True,color="black",height=4)
sns.displot(data=df, x="HUMEDAD",kde=True,color="orange",height=4)

sns.displot(data=df, x="ANGULO",kde=True,color="orange",height=4)
sns.displot(data=df, x="COHESION",kde=True,color="orange",height=4)

plt.show()
```







```
In [10]: ###TRANSFORMACION DE DATOS
###TRANSFORMACION LOGARITMICA SOLO A DATOS SESGADOS

# Asumiendo que 'data' es tu DataFrame y 'feature' es la columna sesgada
df_trans=df.copy()

# Nombrar las columnas a las cuales deseas aplicar la transformación logarítmica.
# Reemplaza 'columna1', 'columna2', ..., 'columna9' con los nombres reales de tus columnas.
columnas_para_transformar = ['GRAVA GRUESA', 'GRAVA FINA', 'ARENA GRUESA', 'ARENA MEDIANA', 'ARENA FINA', 'PART. FINOS',
                              'LL', 'IP', 'HUMEDAD', 'COHESION']

# Aplicar la transformación logarítmica directamente solo a esas columnas seleccionadas.
for columna in columnas_para_transformar:
    df_trans[columna] = np.log1p(df_trans[columna])
df_trans
```

```
Out[10]:
```

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
0	0.0	0.000000	3.057298	2.423031	4.216120	1.305626	0.0	0.0	1.91	0.378436	42.19	1.345472
1	0.0	0.000000	0.482426	2.856470	4.378144	1.665818	0.0	0.0	1.59	0.329304	36.93	0.862890
2	0.0	0.000000	0.329304	2.424803	4.459103	1.589235	0.0	0.0	1.66	0.215111	36.30	1.572774
3	0.0	0.000000	0.418710	2.444952	4.458756	1.519513	0.0	0.0	1.63	0.307485	34.00	0.943906
4	0.0	0.058269	1.289233	2.557227	4.420285	1.456287	0.0	0.0	1.55	0.828552	33.25	1.294727
...	...	...	...	...	...	...	...	...	...	...	...	...
1100	0.0	2.267994	3.465736	3.761200	2.814210	1.297463	0.0	0.0	1.68	1.308333	39.82	1.774952
1101	0.0	3.033510	3.328627	3.850148	1.408545	1.656321	0.0	0.0	1.76	0.641854	38.71	1.553925
1102	0.0	3.071303	2.484907	3.339322	3.637323	1.656321	0.0	0.0	1.59	3.242592	28.78	0.000000
1103	0.0	3.241029	2.856470	3.538057	3.119276	1.611436	0.0	0.0	1.62	3.152736	31.88	0.000000
1104	0.0	2.383243	3.226844	3.637586	3.176803	1.944481	0.0	0.0	1.62	1.945910	33.69	0.000000

1105 rows × 12 columns

```
In [19]: # Lista de las variables que deseas graficar.
columns_figdisplot = ['GRAVA GRUESA', 'GRAVA FINA', 'ARENA GRUESA', 'ARENA MEDIANA', 'ARENA FINA', 'PART. FINOS',
                      'LL', 'IP', 'D. SECA', 'HUMEDAD', 'ANGULO', 'COHESION']

# Número total de columnas para tus gráficos. Esto se calcula en función del número de variables.
num_columns = len(columns_figdisplot)

# Definir el número de filas y columnas para los subplots.
# Aquí, queremos 3 filas, y el número de columnas depende del total de variables.
# El cálculo del número de columnas se hace para ajustarse al número de variables, asegurándose de que todas quepan.
num_rows = 3
columns_per_row = -(-num_columns // num_rows) # Cálculo para redondear hacia arriba.


# Configurar el tamaño de la figura. Ajusta el ancho y alto según necesites.
fig, axes = plt.subplots(num_rows, columns_per_row, figsize=(15, 10))
```

```
# Aplanar el array de 'axes' para facilitar su uso en un bucle, en caso de que sea multidimensional.
axes = axes.flatten()

# Iterar sobre la lista de variables y los axes para crear un histplot para cada una.
for i, column in enumerate(columns_figdisplot):
    sns.histplot(data=df_trans, x=column, kde=True, color="blue", ax=axes[i])
    axes[i].set_title(column) # Añade un título a cada subgráfico para identificar la variable.

# Ocultar los subplots vacíos si los hay.
for i in range(len(columns_figdisplot), len(axes)):
    axes[i].set_visible(False) # Oculta los axes no utilizados.

plt.tight_layout() # Ajusta automáticamente los subgráficos para que encajen en la figura.
plt.savefig("imagen f.png")
plt.show()
```



```
In [12]: ##TRANSFORMACION POR ESCALA MIN Y MAX

df_trans2=df_trans.copy()

from sklearn.preprocessing import MinMaxScaler

# Asumiendo que df_trans2 es tu DataFrame y ya lo has definido.

# Inicializa el escalador Min-Max
scaler = MinMaxScaler()

# Ajusta el escalador a los datos y luego transforma los datos
df_trans2_scaled = scaler.fit_transform(df_trans2)

# Convertir el array resultante de nuevo en un DataFrame
df_trans2_scaled = pd.DataFrame(df_trans2_scaled, columns=df_trans2.columns)

# Mostrar las primeras filas del DataFrame escalado para verificar

df_trans2_scaled
```

```
Out[12]:
```

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
0	0.0	0.000000	0.853155	0.561231	0.915777	0.272039	0.0	0.0	0.700000	0.090961	0.803275	0.313029
1	0.0	0.000000	0.134624	0.661625	0.950971	0.352999	0.0	0.0	0.453846	0.079151	0.670781	0.200754
2	0.0	0.000000	0.091894	0.561641	0.968556	0.335785	0.0	0.0	0.507692	0.051704	0.654912	0.365911
3	0.0	0.000000	0.116843	0.566308	0.968480	0.320114	0.0	0.0	0.484615	0.073907	0.596977	0.219603
4	0.0	0.012991	0.359767	0.592313	0.960124	0.305903	0.0	0.0	0.423077	0.199150	0.578086	0.301223
...	...	...	...	...	...	...	...	...	...	...	...	...
1100	0.0	0.505655	0.967132	0.871182	0.611271	0.270205	0.0	0.0	0.523077	0.314469	0.743577	0.412949

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
1101	0.0	0.676329	0.928871	0.891784	0.305948	0.350864	0.0	0.0	0.584615	0.154275	0.715617	0.361526
1102	0.0	0.684755	0.693426	0.773465	0.790058	0.350864	0.0	0.0	0.453846	0.779386	0.465491	0.000000
1103	0.0	0.722596	0.797113	0.819496	0.677534	0.340775	0.0	0.0	0.476923	0.757788	0.543577	0.000000
1104	0.0	0.531350	0.900468	0.842550	0.690029	0.415633	0.0	0.0	0.476923	0.467717	0.589169	0.000000

1105 rows × 12 columns

In [13]:

```
# Ahora, extraer los valores mínimos y máximos utilizados para la transformación
data_min = scaler.data_min_
data_max = scaler.data_max_

# Para revertir la transformación, necesitarás estos valores mínimos y máximos.
# Vamos a imprimirlos para verlos.
print("Mínimos:", data_min)
print("Máximos:", data_max)
```

```
Mínimos: [ 0.         0.         0.         0.         0.         0.09531018
 0.         0.         1.         0.         10.3         0.         ]
Máximos: [ 4.26689633  4.48525989  3.58351894  4.31735477  4.60386934  4.54435805
 4.18281321  3.61091791  2.3         4.16044436  50.         4.29823733]
```

In [14]:

```
## GURADAR LOS DATOS PREPROCESADOS A UN CSV

# Guardar el DataFrame en un archivo CSV
df_trans2_scaled.to_csv('df_trans2_scaled.csv', index=False)
```

In [15]:


```
##DATOS COMO QUEDAN DESPUES DE TRANSFORMAR
import scipy.stats as stats











# Histogramas para cada variable
for column in df_trans2_scaled.columns:
    plt.figure(figsize=(10, 4))


    # Histograma
    plt.subplot(1, 2, 1)
    sns.histplot(df_trans2_scaled[column], kde=True)
    plt.title(f'Histograma de {column}')

    # Gráfico Q-Q
    plt.subplot(1, 2, 2)
    stats.probplot(df_trans2_scaled[column], dist="norm", plot=plt)
    plt.title(f'Gráfico Q-Q de {column}')

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







```
In [16]: dff=pd.DataFrame(datos_robust_scaler,columns=["GRAVA FINA","ARENA GRUESA","ARENA MEDIANA","ARENA FINA","PART. FINOS","LL","IP","D. SECA","HUMEDAD","ANGULO","COHESION"])
dff=round(dff,3)
dff
```

ANEXO 03

MODELO DE RED NEURONAL ARTIFICIAL

importe de paquetes

In [1]:

```
##IMPORT PACKAGES

import pandas as pd
import matplotlib.pyplot as plt
from matplotlib import pyplot
import numpy as np
import seaborn as sns
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_score

#PARA QUANTILE
import pylab
import scipy.stats as stats
from scipy import stats

from sklearn import preprocessing
from sklearn.preprocessing import PowerTransformer

####redes neuronales
from keras.models import Sequential
#from keras.layers import Dense
from keras import backend as Kback
import tensorflow as tf
from tensorflow.keras.layers import Dense, Flatten, Dropout, ReLU, BatchNormalization
from keras.callbacks import EarlyStopping, ReduceLROnPlateau
from tensorflow.keras.utils import plot_model
from tensorflow.keras.regularizers import l2
from sklearn.utils import shuffle

#para tabular
from tabulate import tabulate
```

IMPORTADO DATOS PREPROCESADOS

In [2]:

```
#IMPORT from DATA
dataset_import = pd.read_csv('OFICIALDATASET.csv')
df=pd.DataFrame(round(dataset_import,3))
df=df.copy()
df
```

Out[2]:

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION
0	0.000	0.608	0.857	0.872	0.624	0.425	0.000	0.000	0.569	0.506	0.518	0.590
1	0.435	0.384	0.193	0.327	0.955	0.406	0.000	0.000	0.392	0.334	0.498	0.480
2	0.305	0.587	0.813	0.752	0.701	0.642	0.779	0.664	0.485	0.666	0.634	0.377
3	0.000	0.000	0.082	0.554	0.810	0.858	0.831	0.748	0.454	0.603	0.320	0.610
4	0.000	0.000	0.000	0.135	1.000	0.056	0.631	0.000	0.315	0.785	0.521	0.000
...	...	...	...	...	...	...	...	...	...	...	...	...
1100	0.000	0.618	0.874	0.824	0.708	0.340	0.000	0.000	0.562	0.474	0.539	0.407
1101	0.756	0.667	0.772	0.684	0.448	0.627	0.857	0.800	0.392	0.693	0.658	0.574
1102	0.904	0.660	0.613	0.716	0.340	0.264	0.820	0.589	0.323	0.677	0.522	0.319
1103	0.000	0.000	0.400	0.578	0.738	0.890	0.750	0.374	0.177	0.869	0.455	0.626
1104	0.000	0.179	0.842	0.867	0.784	0.235	0.000	0.000	0.515	0.301	0.643	0.288

1105 rows × 12 columns

ARQUITECTURA/DISEÑO DEL MODELO NEURONAL

EL DISEÑO SE REALIZO LO MAS OPTIMO POSIBLE PARA QUE EL ENTRENAMIENTO NO SE SOBRE AJUSTE, ADEMÁS LA ARQUITECTURA ESTÁ DISEÑADA PARA UN MENOR COSTO COMPUTACIONAL CON LOS OPTIMIZADORES NECESARIOS

In [3]:

```
##ARQUITECTURA

#Iniciar modelo
Kback.clear_session()
#Modelo de la red neuronal
modelo = Sequential()

modelo.add(Dense(200, input_dim=10, kernel_initializer='he_uniform'))
modelo.add(BatchNormalization())
modelo.add(ReLU()) # Utiliza ReLU como capa para mayor flexibilidad
modelo.add(Dropout(0.2))

modelo.add(Dense(100))
modelo.add(BatchNormalization())
modelo.add(ReLU())
modelo.add(Dropout(0.2))

modelo.add(Dense(50))
modelo.add(BatchNormalization())
modelo.add(ReLU())
modelo.add(Dropout(0.2))
# Capa de salida
modelo.add(Dense(2, activation='linear'))

# Compilador de la red neuronal
modelo.compile(loss='mean_squared_error', optimizer='adam', metrics=['mae', 'mse'])


# Resumen del modelo
modelo.summary()

# Visualizar la arquitectura del modelo
plot_model(modelo, to_file='modelo.png', show_shapes=True, show_layer_names=True)
```

Model: "sequential"

Layer (type)	Output Shape	Param #
=====		
dense (Dense)	(None, 200)	2200
batch_normalization (Batch Normalization)	(None, 200)	800
re_lu (ReLU)	(None, 200)	0
dropout (Dropout)	(None, 200)	0
dense_1 (Dense)	(None, 100)	20100
batch_normalization_1 (Batch Normalization)	(None, 100)	400
re_lu_1 (ReLU)	(None, 100)	0
dropout_1 (Dropout)	(None, 100)	0
dense_2 (Dense)	(None, 50)	5050
batch_normalization_2 (Batch Normalization)	(None, 50)	200
re_lu_2 (ReLU)	(None, 50)	0
dropout_2 (Dropout)	(None, 50)	0
dense_3 (Dense)	(None, 2)	102
=====		
Total params: 28,852		
Trainable params: 28,152		
Non-trainable params: 700		

Out[3]:





dense_3	input:	(None, 50)
Dense	output:	(None, 2)

```
In [4]: ##DATA SEPARATION FOR TRAINING AND VALIDATION
datosRNN=df.values #devuelve los datos a forma iterable

## data training
X_entr=datosRNN[0:773,0:10]
Y_entr=datosRNN[0:773,10:12]

## data validation
X_val=datosRNN[773:1105,0:10]
Y_val=datosRNN[773:1105,10:12]

## data evaluation
#X_eval=datosRNN[0:1105,0:9]
#Y_eval=datosRNN[0:1105,9:11]
```

```
In [5]: #Entrenamiento de la red neuronal, {validation_data=(X_val, Y_val)-validation_split=0.1}
#dat_val=0.1
batch_size = X_entr.shape[0]
# Configuración de callbacks
early_stopping = EarlyStopping(monitor='val_loss', patience=10, verbose=1, mode='min')
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.2, patience=5, verbose=1, mode='min', min_lr=0.001)

history = modelo.fit(X_entr,Y_entr,batch_size=batch_size,epochs=1500,verbose=0,validation_data=(X_val,Y_val))
```

VISUALIZACION METRICAS/RESIDUOS DEL APRENDIZAJE DEL MODELO NEURONAL

```
In [6]: ## GRAFICA ENTRE ENTRENAMIENTO Y VALIDACION
fig = plt.figure(figsize=(20, 15))
plt.subplot(1,3,1)
plt.plot(history.history['loss'], label='Entrenamiento')
plt.plot(history.history['val_loss'], label='Validación')
plt.ylabel('Loss [LOSS]')
plt.xlabel('Épocas')
plt.legend()

plt.subplot(1,3,2)
plt.plot(history.history['mae'], label='Entrenamiento')
plt.plot(history.history['val_mae'], label='Validación')
plt.ylabel('Mean Abs Error [MAE]')
plt.xlabel('Épocas')
plt.legend()


plt.subplot(1,3,3)
plt.plot(history.history['mse'], label='Entrenamiento')
plt.plot(history.history['val_mse'], label='Validación')
plt.ylabel('Mean Square Error [MSE]')
plt.xlabel('Épocas')
plt.legend()

ax = plt.gca()
ax.yaxis.set_label_position("right")
ax.yaxis.tick_right()

plt.show()

# Luego, extraemos las últimas métricas de entrenamiento del historial para reportarlas.
print("MEDIDAS DE ERROR AL FINAL DEL ENTRENAMIENTO")
print("La pérdida final de entrenamiento es: {:.3f}".format(history.history['loss'][-1]))
print("El error medio absoluto final de entrenamiento es: {:.3f}".format(history.history['mae'][-1]))
print("El error cuadrático medio final de entrenamiento es: {:.3f}".format(history.history['mse'][-1]))

print("MEDIDAS DE ERROR AL FINAL DE LA VALIDACIÓN")
print("La pérdida final de validación es: {:.3f}".format(history.history['val_loss'][-1]))
print("El error medio absoluto final de validación es: {:.3f}".format(history.history['val_mae'][-1]))
print("El error cuadrático medio final de validación es: {:.3f}".format(history.history['val_mse'][-1]))
```



MEDIDAS DE ERROR AL FINAL DEL ENTRENAMIENTO
 La pérdida final de entrenamiento es: 0.016
 El error medio absoluto final de entrenamiento es: 0.100
 El error cuadrático medio final de entrenamiento es: 0.016
 MEDIDAS DE ERROR AL FINAL DE LA VALIDACIÓN
 La pérdida final de validación es: 0.016
 El error medio absoluto final de validación es: 0.095
 El error cuadrático medio final de validación es: 0.016

```
In [7]: # Asumiendo resultados de entr_loss, entr_mae, entr_mse, val_loss, val_mae, val_mse
# TRAINING
print("MEDIDAS DE ERROR ENTRENAMIENTO")
entr_loss, entr_mae, entr_mse = modelo.evaluate(X_entr, Y_entr, verbose=1)
# VALIDATION
print("MEDIDAS DE ERROR VALIDACION")
val_loss, val_mae, val_mse = modelo.evaluate(X_val, Y_val, verbose=1)

# Métricas
metrics = ['MAE', 'MSE', 'RMSE']

# Valores para el conjunto de entrenamiento
train_values = [entr_mae, entr_mse, np.sqrt(entr_mse)]

# Valores para el conjunto de validación
val_values = [val_mae, val_mse, np.sqrt(val_mse)]

# Configuración de la gráfica
x = np.arange(len(metrics))
width = 0.35

fig, ax = plt.subplots()
rects1 = ax.bar(x - width/2, train_values, width, label='Entrenamiento')
rects2 = ax.bar(x + width/2, val_values, width, label='Validación')

# título y etiquetas personalizadas de los ejes
ax.set_ylabel('Valores')
ax.set_title('Comparación entre entrenamiento y validación por métrica')
ax.set_xticks(x)
ax.set_xticklabels(metrics)
ax.legend()

# Función para etiquetar
def autolabel(rects):
    """Adjunta una etiqueta de texto encima de cada barra en *rects*, mostrando su altura."""
    for rect in rects:
        height = rect.get_height()
        ax.annotate('{}'.format(round(height, 3)),
                    xy=(rect.get_x() + rect.get_width() / 2, height),
```

```

xytext=(0, 3), # desplazamiento vertical de 3 puntos
textcoords="offset points",
ha='center', va='bottom')

autolabel(rects1)
autolabel(rects2)

fig.tight_layout()

plt.show()

#plt.figure(figsize=(15, 10))
#plt.plot(Y_entr, Label="y-original")
#plt.plot(Y_entr_RN, Label="y-entrenamiento")
#plt.legend()
#plt.show()
#entr=history.history['mse']
#val=history.history['val_mse']
#print(entr)
#print(val)
print("MEDIDAS DE ERROR ENTRENAMIENTO")
print("La perdida es : %.3f " % entr_loss)
print("El error medio absoluto es : %.3f " % entr_mae)
print("El error medio cuadratico es : %.3f " % entr_mse)

print("MEDIDAS DE ERROR VALIDACION")
print("La perdida es : %.3f " % val_loss)
print("El error medio absoluto es : %.3f " % val_mae)
print("El error medio cuadratico es : %.3f " % val_mse)


```

MEDIDAS DE ERROR ENTRENAMIENTO

25/25 [=====] - 0s 3ms/step - loss: 0.0105 - mae: 0.0762 - mse: 0.0105

MEDIDAS DE ERROR VALIDACION

11/11 [=====] - 0s 4ms/step - loss: 0.0157 - mae: 0.0950 - mse: 0.0157



MEDIDAS DE ERROR ENTRENAMIENTO

La perdida es : 0.011

El error medio absoluto es : 0.076

El error medio cuadratico es : 0.011

MEDIDAS DE ERROR VALIDACION

La perdida es : 0.016

El error medio absoluto es : 0.095

El error medio cuadratico es : 0.016

In [8]: `modelo.save('mi_modelo.h5')`

In [9]: `#mse_krr = mean_squared_error(Y, y_prede)`
`Y_entr_RN = modelo.predict(X_entr)`
`Y_val_RN = modelo.predict(X_val)`

25/25 [=====] - 0s 3ms/step

11/11 [=====] - 0s 3ms/step

In [10]: `from sklearn.metrics import mean_squared_error`
`from sklearn.metrics import mean_absolute_error`

`N_val = X_val.shape[0]`
`print("numero de datos para validacion: %.3f" % N_val)`

`## ENTRENAMIENTO-----Y_ORIGINAL VS Y_PREDICHO (ANGULO DE FRICCION INTERNA)`

`yRNN1=Y_entr_RN[0:773,0:1]`

`ydata1=Y_entr[0:773,0:1]`

`print("=====MEDIDAS DE ERROR PARA ANGULO DE FRICCION INTERNA=====")`

`print("ERROR CUADRATICO MEDIO ENTRENAMIENTO=",mean_squared_error(ydata1,yRNN1))`

`print("ERROR MEDIO ABS ENTRENAMIENTO=",mean_absolute_error(ydata1,yRNN1))`

```

print("ERROR DE RAIZ CUADRADA MEDIO ENTRENAMIENTO=",np.sqrt(mean_squared_error(ydata1,yRNN1)))

plt.figure(figsize=(20, 10))
plt.subplot(1,1,1).set_title("TRAINING OF ANGULO FRICCION INTERNA", fontsize=30)
plt.plot(ydata1,label="y-entrenamiento", marker="*", color="blue", markersize=1)
plt.plot(yRNN1,label="y-entrenamientoRN", marker="*", color="orange", markersize=1)
plt.legend()
#plt.savefig("entre3.png")
plt.show()


## ENTRENAMIENTO-----Y_ORIGINAL VS Y_PREDICHO (ANGULO DE FRICCION INTERNA)
yRNN2=Y_entr_RN[0:773,1:2]
ydata2=Y_entr[0:773,1:2]
print("=====MEDIDAS DE ERROR PARA COHESION====")
print("ERROR CUADRATICO MEDIO ENTRENAMIENTO=",mean_squared_error(ydata2,yRNN2))
print("ERROR MEDIO ABS ENTRENAMIENTO=",mean_absolute_error(ydata2,yRNN2))
print("ERROR DE RAIZ CUADRADA MEDIO ENTRENAMIENTO=",np.sqrt(mean_squared_error(ydata2,yRNN2)))

plt.figure(figsize=(20, 10))
plt.subplot(1,1,1).set_title("TRAINING OF COHESION", fontsize=30)
plt.plot(ydata2,label="y-entrenamiento", marker="*", color="aqua", markersize=1)
plt.plot(yRNN2,label="y-entrenamientoRN", marker="*", color="chocolate", markersize=1)
plt.legend()
#plt.savefig("entre4.png")
plt.show()

```


numero de datos para validacion:332.000
 =====MEDIDAS DE ERROR PARA ANGULO DE FRICCION INTERNA===
 ERROR CUADRATICO MEDIO ENTRENAMIENTO= 0.00472569190272694
 ERROR MEDIO ABS ENTRENAMIENTO= 0.05294276925740236
 ERROR DE RAIZ CUADRADA MEDIO ENTRENAMIENTO= 0.06874366809188276

TRAINING OF ANGULO FRICCION INTERNA



=====MEDIDAS DE ERROR PARA COHESION====
 ERROR CUADRATICO MEDIO ENTRENAMIENTO= 0.016298747786385168
 ERROR MEDIO ABS ENTRENAMIENTO= 0.09951541774925253
 ERROR DE RAIZ CUADRADA MEDIO ENTRENAMIENTO= 0.12766654920685044

TRAINING OF COHESION



In [11]:

```
N_val = X_val.shape[0]
print("numero de datos para validacion:%.3f" % N_val)

## VALIDACION-----Y_ORIGINAL VS Y_PREDICHO (ANGULO DE FRICCION INTERNA)
yRNN3=Y_val_RN[0:332,0:1]
ydata3=Y_val[0:332,0:1]
print("=====MEDIDAS DE ERROR PARA ANGULO DE FRICCION INTERNA====")
print("ERROR CUADRATICO MEDIO VALIDACION=",mean_squared_error(ydata3,yRNN3))
print("ERROR MEDIO ABS VALIDACION=",mean_absolute_error(ydata3,yRNN3))
print("ERROR DE RAIZ CUADRADA MEDIO VALIDACION=",np.sqrt(mean_squared_error(ydata3,yRNN3)))

plt.figure(figsize=(20, 10))
plt.subplot(1,1,1).set_title("VALIDATION OF ANGULO FRICCION INTERNA", fontsize=30)
plt.plot(ydata3,label="y-validacion", marker="*", color="blue", markersize=1)
plt.plot(yRNN3 ,label="y-validacionRN", marker="*", color="orange", markersize=1)
plt.legend()
#plt.savefig("entre1.png")
plt.show()

## VALIDACION-----Y_ORIGINAL VS Y_PREDICHO (ANGULO DE FRICCION INTERNA)
yRNN4=Y_val_RN[0:332,1:2]
ydata4=Y_val[0:332,1:2]
print("=====MEDIDAS DE ERROR PARA COHESION====")
print("ERROR CUADRATICO MEDIO VALIDACION=",mean_squared_error(ydata4,yRNN4))
print("ERROR MEDIO ABS VALIDACION=",mean_absolute_error(ydata4,yRNN4))
print("ERROR DE RAIZ CUADRADA MEDIO VALIDACION=",np.sqrt(mean_squared_error(ydata4,yRNN4)))

plt.figure(figsize=(20, 10))
plt.subplot(1,1,1).set_title("VALIDATION OF COHESION", fontsize=30)
plt.plot(yRNN4,label="y-validacion", marker="*", color="aqua", markersize=1)
plt.plot(ydata4,label="y-validacionRN", marker="*", color="chocolate", markersize=1)
plt.legend()
#plt.savefig("entre2.png")
plt.show()

#Loss, mae, mse = modelo.evaluate(X_val, Y_val, verbose=0)
#mse_krr = mean_squared_error(Y, y_prede)


#print('RNA: ',Y_eval_RN.T)
#print('Reales: ',Y_eval)

#print("El error promedio es : %.3f " % Loss)
#print("mae: %.3f" % mae)
#print("mse: %.3f" % mse)

#plt.plot(Y_val, Label="y-original")
#plt.plot(Y_val_RN, Label="y-predicted")
#plt.legend()
#plt.show()
```


```
numero de datos para validacion:332.000
=====MEDIDAS DE ERROR PARA ANGULO DE FRICCION INTERNA====
ERROR CUADRATICO MEDIO VALIDACION= 0.006860659450506365
ERROR MEDIO ABS VALIDACION= 0.0643352408405281
ERROR DE RAIZ CUADRADA MEDIO VALIDACION= 0.08282909784916388
```

VALIDATION OF ANGULO FRICCION INTERNA



=====MEDIDAS DE ERROR PARA COHESION===
 ERROR CUADRATICO MEDIO VALIDACION= 0.024488137797794823
 ERROR MEDIO ABS VALIDACION= 0.12569120268739134
 ERROR DE RAIZ CUADRADA MEDIO VALIDACION= 0.15648686142227666

VALIDATION OF COHESION



In [36]:

```
#IMPORT from DATA
dataset_import2= pd.read_csv('DATAEXPERIMENTAL.csv')
df_prueba=pd.DataFrame(round(dataset_import2,3))
df_prueba
```

Out[36]:

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD
0	20.91	22.05	16.45	29.68	9.74	1.17	0.00	0.00	1.73	16.70
1	54.89	14.99	6.51	13.22	7.95	2.44	0.00	0.00	1.79	16.40
2	12.24	36.83	14.55	17.85	6.68	11.85	23.63	4.72	1.80	16.70
3	15.97	29.50	19.86	22.45	7.46	4.76	0.00	0.00	1.80	17.50
4	2.19	39.32	13.02	17.81	5.57	22.09	22.90	4.39	1.80	20.21
5	17.64	28.94	14.33	15.26	7.47	16.36	27.14	9.63	1.70	30.30
6	30.82	32.84	12.48	12.75	4.69	6.42	21.09	0.00	1.80	18.20
7	0.00	8.37	22.02	39.21	12.39	18.01	23.58	0.00	1.68	29.60
8	47.90	23.99	8.14	7.55	3.85	8.57	29.16	7.42	1.77	27.60
9	34.16	26.75	9.79	12.27	4.48	12.55	24.24	0.00	1.68	32.50

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD
10	0.00	7.93	11.20	20.37	13.53	46.97	58.71	15.76	1.68	20.97
11	0.00	2.06	1.95	35.59	38.04	22.36	22.20	3.60	1.79	21.80
12	0.00	1.94	4.03	48.43	30.41	15.19	0.00	0.00	1.56	24.80
13	0.00	0.00	1.87	53.74	38.15	6.24	0.00	0.00	1.72	19.80
14	0.00	1.78	3.59	41.10	35.28	18.25	0.00	0.00	1.56	28.40
15	0.00	6.31	8.57	17.40	17.37	50.35	33.12	7.78	1.48	31.20
16	36.38	18.38	8.12	15.40	13.35	8.37	0.00	0.00	1.70	20.80
17	49.34	13.93	8.24	9.92	6.53	12.04	26.71	3.16	1.59	24.20
18	40.71	22.74	7.27	9.67	7.32	12.29	30.47	1.00	1.57	24.20
19	39.18	14.29	10.28	15.69	10.06	10.50	0.00	0.00	1.50	31.02
20	48.68	14.63	4.26	12.09	8.72	11.62	26.75	2.65	1.50	32.10
21	1.81	12.54	8.04	42.13	27.35	8.13	0.00	0.00	1.70	26.40
22	61.45	12.98	4.74	7.72	5.83	7.28	0.00	0.00	2.50	5.70
23	5.06	15.93	9.97	17.00	17.07	34.97	39.95	0.00	1.57	40.20
24	21.17	13.29	8.07	13.11	19.20	25.16	38.93	6.43	1.68	19.50
25	17.97	22.14	12.94	21.10	12.47	13.38	20.14	6.46	1.68	29.60
26	0.00	19.82	25.84	24.86	9.61	19.87	35.64	15.15	1.50	25.70
27	39.70	22.65	9.41	16.37	7.48	4.39	31.78	0.00	1.70	18.50
28	55.27	18.98	8.21	12.35	4.26	0.93	0.00	0.00	1.76	24.90
29	56.17	18.82	6.24	7.35	6.36	5.06	43.78	10.40	1.75	27.90
30	46.02	17.64	7.69	16.25	9.94	2.46	41.79	0.00	1.75	20.80
31	19.26	28.39	9.29	20.70	19.39	2.97	0.00	0.00	1.70	22.40
32	0.00	1.51	1.74	17.86	38.63	40.26	41.71	8.48	1.16	47.10
33	9.45	19.22	11.84	18.95	13.82	26.72	23.49	5.64	1.66	24.59
34	3.11	11.13	14.29	33.29	14.56	23.62	28.66	6.32	1.68	25.70
35	57.79	14.19	5.69	4.94	2.86	14.53	27.77	9.08	1.73	26.78
36	0.70	4.80	6.70	26.60	53.40	7.80	0.00	0.00	1.85	13.10
37	0.00	0.00	4.80	10.60	11.50	73.10	28.60	3.80	1.31	38.61
38	0.00	30.00	57.80	6.80	4.53	0.87	0.00	0.00	2.20	2.90

In [37]:

```
df_pruebaTrans=df_prueba.copy()
# Reemplaza 'columna1', 'columna2', ..., 'columna9' con los nombres reales de tus columnas.
columnas_para_transformar = ['GRAVA GRUESA','GRAVA FINA', 'ARENA GRUESA', 'ARENA MEDIANA', 'ARENA FINA', 'PART. FINOS',
                              'LL', 'IP', 'HUMEDAD']

# Aplicar la transformación logarítmica directamente solo a esas columnas seleccionadas.
for columna in columnas_para_transformar:
    df_pruebaTrans[columna] = np.log1p(df_pruebaTrans[columna])
print(df_pruebaTrans)
```

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	\
0	3.086943	3.137666	2.859340	3.423611	2.373975	
1	4.023385	2.771964	2.016235	2.654649	2.191654	
2	2.583243	3.633102	2.744061	2.936513	2.038620	
3	2.831447	3.417727	3.037833	3.154870	2.135349	
4	1.160021	3.696848	2.640485	2.934389	1.882514	
5	2.925310	3.399195	2.729812	2.788708	2.136531	
6	3.460095	3.521644	2.601207	2.621039	1.738710	
7	0.000000	2.237513	3.136363	3.694116	2.594508	
8	3.889777	3.218476	2.212660	2.145931	1.578979	
9	3.559909	3.323236	2.378620	2.585506	1.701105	
10	0.000000	2.189416	2.501436	3.061988	2.676215	
11	0.000000	1.118415	1.081805	3.599775	3.664587	
12	0.000000	1.078410	1.615420	3.900558	3.447126	
13	0.000000	0.000000	1.054312	4.002595	3.667400	
14	0.000000	1.022451	1.523880	3.740048	3.591267	
15	0.000000	1.989243	2.258633	2.912351	2.910719	
16	3.621136	2.964242	2.210470	2.797281	2.663750	
17	3.918800	2.703373	2.223542	2.390596	2.018895	
18	3.730741	3.167161	2.112635	2.367436	2.118662	
19	3.693369	2.727199	2.423031	2.814810	2.403335	
20	3.905602	2.749192	1.660131	2.571849	2.274186	
21	1.033184	2.605648	2.201659	3.764219	3.344627	
22	4.134366	2.637628	1.747459	2.165619	1.921325	

23	1.801710	2.829087	2.395164	2.890372	2.894253
24	3.098740	2.659560	2.204972	2.646884	3.005683
25	2.942859	3.141563	2.634762	3.095578	2.600465
26	0.000000	3.035914	3.289893	3.252697	2.361797
27	3.706228	3.163363	2.342767	2.854745	2.137710
28	4.030162	2.994732	2.220290	2.591516	1.660131
29	4.046029	2.986692	1.979621	2.122262	1.996060
30	3.850573	2.925310	2.162173	2.847812	2.392426
31	3.008648	3.380654	2.331173	3.077312	3.015045
32	0.000000	0.920283	1.007958	2.937043	3.679586
33	2.346602	3.006672	2.552565	2.993229	2.695978
34	1.413423	2.495682	2.727199	3.534854	2.744704
35	4.073972	2.720637	1.900614	1.781709	1.350667
36	0.530628	1.757858	2.041220	3.317816	3.996364
37	0.000000	0.000000	1.757858	2.451005	2.525729
38	0.000000	3.433987	4.074142	2.054124	1.710188

	PART. FINOS	LL	IP	D. SECA	HUMEDAD
0	0.774727	0.000000	0.000000	1.73	2.873565
1	1.235471	0.000000	0.000000	1.79	2.856470
2	2.553344	3.203965	1.743969	1.80	2.873565
3	1.750937	0.000000	0.000000	1.80	2.917771
4	3.139400	3.173878	1.684545	1.80	3.054473
5	2.854169	3.337192	2.363680	1.70	3.443618
6	2.004179	3.095125	0.000000	1.80	2.954910
7	2.944965	3.201933	0.000000	1.68	3.421000
8	2.258633	3.406517	2.130610	1.77	3.353407
9	2.606387	3.228430	0.000000	1.68	3.511545
10	3.870576	4.089500	2.818995	1.68	3.089678
11	3.151025	3.144152	1.526056	1.79	3.126761
12	2.784394	0.000000	0.000000	1.56	3.250374
13	1.979621	0.000000	0.000000	1.72	3.034953
14	2.957511	0.000000	0.000000	1.56	3.380995
15	3.938665	3.529884	2.172476	1.48	3.471966
16	2.237513	0.000000	0.000000	1.70	3.081910
17	2.568022	3.321793	1.425515	1.59	3.226844
18	2.587012	3.449035	0.693147	1.57	3.226844
19	2.442347	0.000000	0.000000	1.50	3.466361
20	2.535283	3.323236	1.294727	1.50	3.499533
21	2.211566	0.000000	0.000000	1.70	3.310543
22	2.113843	0.000000	0.000000	2.50	1.902108
23	3.582685	3.712352	0.000000	1.57	3.718438
24	3.264232	3.687128	2.005526	1.68	3.020425
25	2.665838	3.051167	2.009555	1.68	3.421000
26	3.038313	3.601141	2.781920	1.50	3.284664
27	1.684545	3.489819	0.000000	1.70	2.970414
28	0.657520	0.000000	0.000000	1.76	3.254243
29	1.801710	3.801762	2.433613	1.75	3.363842
30	1.241269	3.756304	0.000000	1.75	3.081910
31	1.378766	0.000000	0.000000	1.70	3.152736
32	3.719894	3.754433	2.249184	1.16	3.873282
33	3.322154	3.198265	1.893112	1.66	3.242202
34	3.203559	3.389799	1.990610	1.68	3.284664
35	2.742774	3.359333	2.310553	1.73	3.324316
36	2.174752	0.000000	0.000000	1.85	2.646175
37	4.305416	3.387774	1.568616	1.31	3.679082
38	0.625938	0.000000	0.000000	2.20	1.360977

```
In [38]: #sea datos de transformacion max-min
data_min=pd.DataFrame([ 0,0,0,0,0,0.09531018,0,0,1.,0])
data_max=pd.DataFrame([ 4.26689633,4.48525989,3.58351894,4.31735477,4.60386934,4.54435805,4.18281321,3.61091791,2.3,4.
data_min=data_min.transpose()
data_max=data_max.transpose()

xcal_scaled = (df_pruebaTrans - data_min.values) / (data_max.values - data_min.values)

# Mostrar los resultados
xcal_scaled
```

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD
0	0.723463	0.699550	0.797914	0.792988	0.515648	0.152711	0.000000	0.000000	0.561538	0.690687
1	0.942930	0.618016	0.562641	0.614879	0.476046	0.256271	0.000000	0.000000	0.607692	0.686578
2	0.605415	0.810009	0.765745	0.680165	0.442806	0.552485	0.765983	0.482971	0.615385	0.690687
3	0.663585	0.761991	0.847724	0.730742	0.463816	0.372131	0.000000	0.000000	0.615385	0.701312
4	0.271865	0.824221	0.736841	0.679673	0.408898	0.684211	0.758790	0.466514	0.615385	0.734170
5	0.685583	0.757859	0.761768	0.645930	0.464073	0.620101	0.797834	0.654593	0.538462	0.827704
6	0.810916	0.785159	0.725881	0.607094	0.377663	0.429051	0.739963	0.000000	0.615385	0.710239
7	0.000000	0.498859	0.875219	0.855643	0.563549	0.640509	0.765498	0.000000	0.523077	0.822268
8	0.911618	0.717567	0.617455	0.497048	0.342968	0.486244	0.814408	0.590047	0.592308	0.806021
9	0.834309	0.740924	0.663766	0.598863	0.369495	0.564408	0.771832	0.000000	0.523077	0.844031

	GRAVA GRUESA	GRAVA FINA	ARENA GRUESA	ARENA MEDIANA	ARENA FINA	PART. FINOS	LL	IP	D. SECA	HUMEDAD
10	0.000000	0.488136	0.698039	0.709228	0.581297	0.848556	0.977691	0.780687	0.523077	0.742632
11	0.000000	0.249353	0.301883	0.833792	0.795980	0.686824	0.751684	0.422623	0.607692	0.751545
12	0.000000	0.240434	0.450792	0.903460	0.748745	0.604418	0.000000	0.000000	0.430769	0.781257
13	0.000000	0.000000	0.294211	0.927094	0.796591	0.423531	0.000000	0.000000	0.553846	0.729478
14	0.000000	0.227958	0.425247	0.866282	0.780054	0.643329	0.000000	0.000000	0.430769	0.812652
15	0.000000	0.443507	0.630284	0.674568	0.632233	0.863860	0.843902	0.601641	0.369231	0.834518
16	0.848658	0.660885	0.616843	0.647916	0.578589	0.481497	0.000000	0.000000	0.538462	0.740765
17	0.918419	0.602724	0.620491	0.553718	0.438521	0.555784	0.794153	0.394779	0.453846	0.775601
18	0.874345	0.706127	0.589542	0.548353	0.460192	0.560053	0.824573	0.191959	0.438462	0.775601
19	0.865587	0.608036	0.676160	0.651976	0.522025	0.527537	0.000000	0.000000	0.384615	0.833171
20	0.915326	0.612939	0.463268	0.595700	0.493973	0.548426	0.794498	0.358559	0.384615	0.841144
21	0.242140	0.580936	0.614385	0.871881	0.726482	0.475665	0.000000	0.000000	0.538462	0.795719
22	0.968940	0.588066	0.487638	0.501608	0.417328	0.453700	0.000000	0.000000	1.153846	0.457189
23	0.422253	0.630752	0.668383	0.669477	0.628657	0.783848	0.887525	0.000000	0.438462	0.893760
24	0.726228	0.592956	0.615309	0.613080	0.652860	0.712270	0.881495	0.555406	0.523077	0.725986
25	0.689695	0.700419	0.735244	0.717008	0.564843	0.577770	0.729453	0.556522	0.523077	0.822268
26	0.000000	0.676865	0.918062	0.753401	0.513003	0.661490	0.860937	0.770419	0.384615	0.789498
27	0.868600	0.705280	0.653762	0.661225	0.464329	0.357208	0.834323	0.000000	0.538462	0.713966
28	0.944518	0.667683	0.619584	0.600256	0.360595	0.126366	0.000000	0.000000	0.584615	0.782186
29	0.948237	0.665890	0.552424	0.491565	0.433561	0.383543	0.908901	0.673960	0.576923	0.808529
30	0.902429	0.652205	0.603366	0.659620	0.519655	0.257574	0.898033	0.000000	0.576923	0.740765
31	0.705114	0.753725	0.650526	0.712777	0.654894	0.288479	0.000000	0.000000	0.538462	0.757788
32	0.000000	0.205179	0.281276	0.680288	0.799238	0.814687	0.897586	0.622884	0.123077	0.930978
33	0.549955	0.670345	0.712307	0.693302	0.585590	0.725289	0.764621	0.524274	0.507692	0.779292
34	0.331253	0.556419	0.761039	0.818755	0.596173	0.698632	0.810411	0.551275	0.523077	0.789498
35	0.954786	0.606573	0.530376	0.412685	0.293377	0.595063	0.803128	0.639880	0.561538	0.799029
36	0.124359	0.391919	0.569613	0.768483	0.868045	0.467390	0.000000	0.000000	0.653846	0.636032
37	0.000000	0.000000	0.490540	0.567710	0.548610	0.946294	0.809927	0.434409	0.238462	0.884300
38	0.000000	0.765616	1.136911	0.475783	0.371467	0.119268	0.000000	0.000000	0.923077	0.327123

In [39]:

```
#xcal1 = xcal.transpose()
#print(xcal)
y_krm = modelo.predict(xcal_scaled)

print('y_norm :', y_krm) # grados / Kpa

#14.3
type(y_krm)
```

2/2 [=====] - 0s 4ms/step

```
y_norm : [[0.5769608 0.1552844]
[0.5988867 0.09524346]
[0.50425047 0.40063584]
[0.5913807 0.26271707]
[0.5041757 0.41499704]
[0.4748395 0.46326762]
[0.5662971 0.3033498 ]
[0.52906454 0.31910837]
[0.5451022 0.35744733]
[0.5360966 0.35635695]
[0.42865056 0.6682775 ]
[0.39423835 0.4685626 ]
[0.48974597 0.17286691]
[0.48954943 0.15323167]
[0.48204452 0.16728729]
[0.41477185 0.5291544 ]
[0.5488602 0.19604099]
[0.5209603 0.3383059 ]
[0.5316651 0.34323472]
[0.48429477 0.0978795 ]
[0.48088235 0.2843426 ]
[0.51623404 0.17825902]
[0.6530901 0.23430137]
```

```
[0.4641813  0.44825244]
[0.4700871  0.5113861 ]
[0.4886159  0.38150164]
[0.45015267 0.44590324]
[0.5909801  0.23423287]
[0.6307207  0.1167639 ]
[0.5510578  0.29999363]
[0.574412   0.18089786]
[0.56391704 0.14752632]
[0.21811464 0.64026254]
[0.47719562 0.4339044 ]
[0.49880695 0.38600153]
[0.52779675 0.40756625]
[0.5361355  0.30707043]
[0.2998938  0.52973366]
[0.73193353 0.11251888]]
```

Out[39]: numpy.ndarray

In [40]:

```
data_min2=pd.DataFrame([ 10.3,0])
data_max2=pd.DataFrame([ 50.,4.29823733])
data_min=data_min2.transpose()
data_max=data_max2.transpose()

y_original = y_krm * (data_max.values - data_min.values) + data_min.values

y_original[0,1]= np.expml(y_original[0,1])
y_original = np.where(y_original < 0, 0, y_original)
print(y_original)
print('      grados', '      Kpa') # grados / Kpa
```

```
[[33.20534384  0.94878998]
 [34.07580311  0.409379 ]
 [30.31874353  1.72202792]
 [33.7778144   1.12922031]
 [30.31577619  1.78375577]
 [29.15112849  1.9912342 ]
 [32.78199542  1.3038694 ]
 [31.30386208  1.3716035 ]
 [31.94055651  1.53639344]
 [31.58303394  1.53170674]
 [27.31742715  2.87241531]
 [29.95126261  2.01399327]
 [29.74291519  0.74302301]
 [35.7351123   0.65862606]
 [29.43716736  0.71904048]
 [26.76644264  6.27443128]
 [32.08974963  0.84263069]
 [30.98212277  1.45411901]
 [31.40710394  1.47530428]
 [35.52650245  0.42070932]
 [29.39102916  1.22217192]
 [37.7944914   0.76619955]
 [39.22767774  1.00708291]
 [28.72799777  1.92669537]
 [28.96245831  19.1980588]
 [29.69805124  9.63978461]
 [28.17106082  15.9165979]
 [33.76191047  1.00678848]
 [35.3396108   10.5018789]
 [32.17699528  1.28944384]
 [33.10415593  0.77754194]
 [32.68750652  0.63410315]
 [18.95915138  2.75200037]
 [29.24466614  1.86502413]
 [30.10263605  1.65912617]
 [31.25353079  1.75181647]
 [37.58457914  11.319861 ]
 [22.20578372  11.2769209]
 [39.35776131  0.48363284]]
      grados      Kpa
```

In [41]:

```
df_EXPORTFINAL= pd.DataFrame(y_original, columns=['ANGULO DE FRICCION INTERNA', 'COHESION'])
nombre_archivo_excel = "resultadosFINAL.xlsx"
df_EXPORTFINAL.to_excel(nombre_archivo_excel, index=False)
print(f'Resultados exportados exitosamente a {nombre_archivo_excel}')
```

Resultados exportados exitosamente a resultadosFINAL.xlsx

In []:

ANEXO N 4 HIPOTESIS

In [2]:

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.metrics import r2_score

# Suponiendo que tienes un archivo 'datos.csv' con dos columnas: 'Y_real' y 'Y_predicha'
# Asegúrate de que el archivo esté en el mismo directorio que este script o proporciona la ruta completa.

# Cargar datos
datos = pd.read_csv('R-CUADRADO.csv')
datos=pd.DataFrame(round(datos,3))
print(datos.columns)
datos
```

```
Index(['ANGULO OBSERVADO', 'ANGULO PREDICHO', 'COHESION OBSERVADO',
      'COHESION PREDICHO'],
      dtype='object')
```

Out[2]:

	ANGULO OBSERVADO	ANGULO PREDICHO	COHESION OBSERVADO	COHESION PREDICHO
0	33.70	33.21	0.800	0.95
1	34.80	34.08	0.400	0.41
2	30.20	30.32	2.000	1.72
3	34.50	33.78	1.100	1.13
4	31.98	30.32	2.400	1.78
5	29.85	29.15	2.000	1.99
6	32.80	32.78	1.500	1.30
7	32.40	31.30	9.020	9.07
8	31.70	31.94	2.000	1.54
9	30.96	31.58	1.370	1.53
10	24.82	27.32	1.161	2.87
11	30.47	29.95	1.656	2.01
12	28.06	29.74	7.170	0.74
13	35.04	35.74	4.950	0.66
14	28.10	29.44	6.873	6.72
15	27.59	26.77	6.202	6.27
16	33.03	32.09	0.195	0.84
17	32.40	30.98	1.420	1.45
18	32.44	31.41	6.700	1.48
19	35.81	35.53	0.106	0.42
20	33.46	29.39	5.520	1.22
21	37.42	37.49	0.000	0.77
22	40.30	39.23	1.482	1.01
23	32.44	28.73	6.700	1.93
24	31.06	28.96	19.453	19.20
25	29.42	29.70	9.622	9.64
26	24.49	28.17	15.300	15.92
27	39.96	33.76	7.370	1.01
28	36.58	35.34	10.046	10.50
29	32.60	32.18	1.300	1.29
30	33.70	33.10	0.800	0.78
31	32.50	32.69	0.600	0.63
32	18.60	18.96	2.500	2.75
33	28.45	29.24	2.000	1.87

	ANGULO OBSERVADO	ANGULO PREDICHO	COHESION OBSERVADO	COHESION PREDICHO
34	30.50	30.10	2.070	1.66
35	31.70	31.25	3.870	1.75
36	38.45	37.58	11.502	11.32
37	20.48	22.21	11.062	11.28
38	40.72	39.36	0.482	0.48


```
In [3]: # Calcular el coeficiente de determinación R^2
R2 = r2_score(datos['ANGULO OBSERVADO'], datos['ANGULO PREDICHO'])
print(f"Coeficiente de determinación R^2: {R2}")

# Generar gráfica
plt.figure(figsize=(10, 6))
sns.scatterplot(x='ANGULO OBSERVADO', y='ANGULO PREDICHO', data=datos)
# Corrección: ajuste de los nombres de las columnas para la línea de referencia
plt.plot([datos['ANGULO OBSERVADO'].min(), datos['ANGULO OBSERVADO'].max()], [datos['ANGULO PREDICHO'].min(),
plt.title('Gráfica de Ángulo de Fricción Efectiva Real vs Predicha')
plt.xlabel('ANGULO OBSERVADO')
plt.ylabel('ANGULO PREDICHO')

plt.text(x=0.05, y=0.95, s=f'$R^2 = {R2:.2f}$', transform=plt.gca().transAxes,
        fontsize=14, verticalalignment='top', bbox=dict(boxstyle='round,pad=0.5', edgecolor='black', facecol

plt.savefig("r2_c.png")
plt.show()
```

Coeficiente de determinación R^2: 0.860096026987128



```
In [4]: from scipy.stats import f
# Calcular la estadística F
n = len(datos['ANGULO OBSERVADO'])
k = 10

F_statistic = (R2*R2 / k) / ((1 - R2*R2) / (n - k - 1))
print(f"Estadística F: {F_statistic}")

# Calcular el valor p correspondiente a la estadística F
df1 = k # Grados de Libertad
df2 = n - k - 1
p_value = 1 - f.cdf(F_statistic, df1, df2)
print(f"Valor p: {p_value}")

# Nivel de significancia
alpha = 0.01

# Conclusión
if p_value < alpha:
    print(" El modelo es significativo.")
else:
    print(" El modelo no es significativo.")
```

Estadística F: 7.959513093129578
Valor p: 6.587289268611407e-06
El modelo es significativo.


```
In [5]: # Calcular el coeficiente de determinación R^2
R21 = r2_score(datos['COHESION OBSERVADO'], datos['COHESION PREDICHO'])
print(f"Coeficiente de determinación R^2: {R21}")

# Generar gráfica
plt.figure(figsize=(10, 6))
sns.scatterplot(x='COHESION OBSERVADO', y='COHESION PREDICHO', data=datos)
# Corrección: ajuste de los nombres de las columnas para la línea de referencia
plt.plot([datos['COHESION OBSERVADO'].min(), datos['COHESION OBSERVADO'].max()], [datos['COHESION PREDICHO'].min(), datos['COHESION PREDICHO'].max()])
plt.title('Gráfica de Cohesion Efectiva Real vs Predicha')
plt.xlabel('COHESION OBSERVADO')
plt.ylabel('COHESION PREDICHO')

plt.text(x=0.05, y=0.95, s=f'$R^2 = {R21:.2f}$', transform=plt.gca().transAxes,
         fontsize=14, verticalalignment='top', bbox=dict(boxstyle='round,pad=0.5', edgecolor='black', facecolor='white'))

plt.savefig("r2_fhi.png")
plt.show()
```

Coeficiente de determinación R^2: 0.7746262707258553



```
In [6]: import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

# Cargar datos
datos = pd.read_csv('R-CUADRADO.csv')
datos = pd.DataFrame(round(datos, 3))
print(datos.columns)
print(datos)

# Calcular los residuos
datos['RESIDUOS'] = datos['ANGULO OBSERVADO'] - datos['ANGULO PREDICHO']



# Plot: Histograma de los residuos
plt.figure(figsize=(14, 6))

# Histograma de residuos
plt.subplot(1, 2, 1)
sns.histplot(datos['RESIDUOS'], bins=20, kde=True, color='blue')
plt.title('Histograma de Residuos ANGULO DE FRICCION EFECTIVA')
plt.xlabel('Residuos')
plt.ylabel('Frecuencia')
plt.savefig("historesi_fhi.png")
# Plot: Residuos vs. Predicciones
plt.subplot(1, 2, 2)
sns.scatterplot(x='ANGULO PREDICHO', y='RESIDUOS', data=datos, alpha=0.5)
plt.title('Residuos vs. Predicciones ANGULO DE FRICCION EFECTIVA')
plt.xlabel('Predicciones')
plt.ylabel('Residuos')
plt.axhline(y=0, color='r', linestyle='--')
```

```
plt.tight_layout()
plt.savefig("plot_fhi.png")
plt.show()
```

```
Index(['ANGULO OBSERVADO', 'ANGULO PREDICHO', 'COHESION OBSERVADO',
      'COHESION PREDICHO'],
      dtype='object')
```

	ANGULO OBSERVADO	ANGULO PREDICHO	COHESION OBSERVADO	COHESION PREDICHO
0	33.70	33.21	0.800	0.95
1	34.80	34.08	0.400	0.41
2	30.20	30.32	2.000	1.72
3	34.50	33.78	1.100	1.13
4	31.98	30.32	2.400	1.78
5	29.85	29.15	2.000	1.99
6	32.80	32.78	1.500	1.30
7	32.40	31.30	9.020	9.07
8	31.70	31.94	2.000	1.54
9	30.96	31.58	1.370	1.53
10	24.82	27.32	1.161	2.87
11	30.47	29.95	1.656	2.01
12	28.06	29.74	7.170	0.74
13	35.04	35.74	4.950	0.66
14	28.10	29.44	6.873	6.72
15	27.59	26.77	6.202	6.27
16	33.03	32.09	0.195	0.84
17	32.40	30.98	1.420	1.45
18	32.44	31.41	6.700	1.48
19	35.81	35.53	0.106	0.42
20	33.46	29.39	5.520	1.22
21	37.42	37.49	0.000	0.77
22	40.30	39.23	1.482	1.01
23	32.44	28.73	6.700	1.93
24	31.06	28.96	19.453	19.20
25	29.42	29.70	9.622	9.64
26	24.49	28.17	15.300	15.92
27	39.96	33.76	7.370	1.01
28	36.58	35.34	10.046	10.50
29	32.60	32.18	1.300	1.29
30	33.70	33.10	0.800	0.78
31	32.50	32.69	0.600	0.63
32	18.60	18.96	2.500	2.75
33	28.45	29.24	2.000	1.87
34	30.50	30.10	2.070	1.66
35	31.70	31.25	3.870	1.75
36	38.45	37.58	11.502	11.32
37	20.48	22.21	11.062	11.28
38	40.72	39.36	0.482	0.48



In [7]:

```
# Cargar datos
datos = pd.read_csv('R-CUADRADO.csv')
datos = pd.DataFrame(round(datos, 3))
print(datos.columns)
print(datos)

# Calcular los residuos
datos['RESIDUOS'] = datos['COHESION OBSERVADO'] - datos['COHESION PREDICHO']

# Plot: Histograma de Los residuos
plt.figure(figsize=(14, 6))

# Histograma de residuos
```

```
plt.subplot(1, 2, 1)
sns.histplot(datos['RESIDUOS'], bins=20, kde=True, color='blue')
plt.title('Histograma de Residuos COHESION')
plt.xlabel('Residuos')
plt.ylabel('Frecuencia')



# Plot: Residuos vs. Predicciones
plt.subplot(1, 2, 2)
sns.scatterplot(x='ANGULO PREDICHO', y='RESIDUOS', data=datos, alpha=0.5)
plt.title('Residuos vs. Predicciones COHESION')
plt.xlabel('Predicciones')
plt.ylabel('Residuos')
plt.axhline(y=0, color='r', linestyle='--')

plt.tight_layout()
plt.savefig("plot_c.png")
plt.show()
```

```
Index(['ANGULO OBSERVADO', 'ANGULO PREDICHO', 'COHESION OBSERVADO',
      'COHESION PREDICHO'],
      dtype='object')

```

	ANGULO OBSERVADO	ANGULO PREDICHO	COHESION OBSERVADO	COHESION PREDICHO
0	33.70	33.21	0.800	0.95
1	34.80	34.08	0.400	0.41
2	30.20	30.32	2.000	1.72
3	34.50	33.78	1.100	1.13
4	31.98	30.32	2.400	1.78
5	29.85	29.15	2.000	1.99
6	32.80	32.78	1.500	1.30
7	32.40	31.30	9.020	9.07
8	31.70	31.94	2.000	1.54
9	30.96	31.58	1.370	1.53
10	24.82	27.32	1.161	2.87
11	30.47	29.95	1.656	2.01
12	28.06	29.74	7.170	0.74
13	35.04	35.74	4.950	0.66
14	28.10	29.44	6.873	6.72
15	27.59	26.77	6.202	6.27
16	33.03	32.09	0.195	0.84
17	32.40	30.98	1.420	1.45
18	32.44	31.41	6.700	1.48
19	35.81	35.53	0.106	0.42
20	33.46	29.39	5.520	1.22
21	37.42	37.49	0.000	0.77
22	40.30	39.23	1.482	1.01
23	32.44	28.73	6.700	1.93
24	31.06	28.96	19.453	19.20
25	29.42	29.70	9.622	9.64
26	24.49	28.17	15.300	15.92
27	39.96	33.76	7.370	1.01
28	36.58	35.34	10.046	10.50
29	32.60	32.18	1.300	1.29
30	33.70	33.10	0.800	0.78
31	32.50	32.69	0.600	0.63
32	18.60	18.96	2.500	2.75
33	28.45	29.24	2.000	1.87
34	30.50	30.10	2.070	1.66
35	31.70	31.25	3.870	1.75
36	38.45	37.58	11.502	11.32
37	20.48	22.21	11.062	11.28
38	40.72	39.36	0.482	0.48



In [8]:

```
import pandas as pd
from sklearn.metrics import mean_absolute_error, mean_squared_error
import numpy as np

# Cargar datos
datos = pd.read_csv('R-CUADRADO.csv')
datos = pd.DataFrame(round(datos, 3))
print(datos.columns)
print(datos)

# Calcular las métricas de error para ANGULO
mae_angulo = mean_absolute_error(datos['ANGULO OBSERVADO'], datos['ANGULO PREDICHO'])
mse_angulo = mean_squared_error(datos['ANGULO OBSERVADO'], datos['ANGULO PREDICHO'])
rmse_angulo = np.sqrt(mse_angulo)

# Calcular las métricas de error para COHESION
mae_cohesion = mean_absolute_error(datos['COHESION OBSERVADO'], datos['COHESION PREDICHO'])
mse_cohesion = mean_squared_error(datos['COHESION OBSERVADO'], datos['COHESION PREDICHO'])
rmse_cohesion = np.sqrt(mse_cohesion)

# Crear un DataFrame con los resultados
resultados = pd.DataFrame({
    'Métrica': ['MAE', 'MSE', 'RMSE'],
    'Ángulo': [mae_angulo, mse_angulo, rmse_angulo],
    'Cohesión': [mae_cohesion, mse_cohesion, rmse_cohesion]
})

print(resultados)
```

```
Index(['ANGULO OBSERVADO', 'ANGULO PREDICHO', 'COHESION OBSERVADO',
      'COHESION PREDICHO'],
      dtype='object')
  ANGULO OBSERVADO  ANGULO PREDICHO  COHESION OBSERVADO  COHESION PREDICHO
0             33.70             33.21             0.800             0.95
1             34.80             34.08             0.400             0.41
2             30.20             30.32             2.000             1.72
3             34.50             33.78             1.100             1.13
4             31.98             30.32             2.400             1.78
5             29.85             29.15             2.000             1.99
6             32.80             32.78             1.500             1.30
7             32.40             31.30             9.020             9.07
8             31.70             31.94             2.000             1.54
9             30.96             31.58             1.370             1.53
10            24.82             27.32             1.161             2.87
11            30.47             29.95             1.656             2.01
12            28.06             29.74             7.170             0.74
13            35.04             35.74             4.950             0.66
14            28.10             29.44             6.873             6.72
15            27.59             26.77             6.202             6.27
16            33.03             32.09             0.195             0.84
17            32.40             30.98             1.420             1.45
18            32.44             31.41             6.700             1.48
19            35.81             35.53             0.106             0.42
20            33.46             29.39             5.520             1.22
21            37.42             37.49             0.000             0.77
22            40.30             39.23             1.482             1.01
23            32.44             28.73             6.700             1.93
24            31.06             28.96             19.453             19.20
25            29.42             29.70             9.622             9.64
26            24.49             28.17             15.300             15.92
27            39.96             33.76             7.370             1.01
28            36.58             35.34             10.046             10.50
29            32.60             32.18             1.300             1.29
30            33.70             33.10             0.800             0.78
31            32.50             32.69             0.600             0.63
32            18.60             18.96             2.500             2.75
33            28.45             29.24             2.000             1.87
34            30.50             30.10             2.070             1.66
35            31.70             31.25             3.870             1.75
36            38.45             37.58             11.502             11.32
37            20.48             22.21             11.062             11.28
38            40.72             39.36             0.482             0.48
Métrica  Ángulo  Cohesión
0      MAE  1.210513  1.091590
1      MSE  3.059095  4.598462
2      RMSE  1.749027  2.144403
```

In []:

N° TESIS	TÍTULO DE TESIS	AUTOR(S)	UNIVERSIDAD	AÑO	LINK	LUGAR DE ESTUDIO (DISTRITO, PROVINCIA)	NOMBRE DE CALICATA	GRANULOMETRIA			% QUE PASAN					DIAMETROS			LIMITE		DENSIDAD Y HUMEDAD		CLASIF.	PARAMETROS		velocidad de ensayo	NORMA	N° DATOS
								% GRAVA	% ARENA	% FINOS	3/4" 19.0mm	4# 4.75mm	10# 2.0mm	40# 0.425mm	200# 0.075mm	D60	D30	D10	LL	LP	D. SECA	H%		ANG.	C(kg/cm2)			
							C-2	15.60	44.22	40.17	87.33	84.40	82.00	67.33	64.17	24.25	SR	SR	25	15	1.76	19.05	SC	36.29	0.1239			621
6	SISTEMA DE REFORZAMIENTO CON GAVIONES O SISTEMA TERRAMESH® GRID PARA LA ESTABILIDAD DEL TALUD EN LA CARRETERA CASMA - HUARAZ DEL KM 95+540 AL 95+600, ANCASH - 2017.	EMERSON HENRY LOPEZ DE LA CRUZ	UNIVERSIDAD NACIONAL SANTIAGO ANTUNEZ DE MAYOLO	2017	https://repositorio.unasam.edu.pe/handle/UNASAM/4436	CARRETERA CASMA - HUARAZ DEL KM 95+540 AL 95+600, ANCASH - 2017.	C-1	43.08	39.99	16.93	75.82	56.92	42.00	23.80	16.94	6.20	0.93	SR	35	18	1.51	12.06	GC	36.41	0.1100			622
							C-5	49.51	31.04	19.45	74.69	50.49	40.41	27.52	19.45	8.32	0.64	SR	33	16	1.81	16.13	GC	38.70	0.0300			623
							C-6(1)	38.13	37.23	24.65	82.54	61.87	50.34	34.35	24.65	4.23	0.22	SR	36	19	1.79	11.99	GC	30.79	0.1800			624
							C-6(2)	44.58	33.70	21.72	77.75	55.42	45.54	30.88	21.72	6.79	0.36	SR	33	17	1.88	11.99	GC	31.19	0.1200			625
7	EVALUACIÓN SÍSMICA - GEOTÉCNICA PARA LA GENERACIÓN DE MAPAS DE ZONIFICACIÓN DE LOS TERRENOS DEL ASENTAMIENTO HUMANO LAS DELICIAS DEL DISTRITO DE PARAMONGA - 2021.	GUERRERO APOLINARIO, MARÍA DEL CARMEN	UNIVERSIDAD NACIONAL SANTIAGO ANTUNEZ DE MAYOLO	2021	https://repositorio.unasam.edu.pe/handle/UNASAM/4967	DISTRITO DE PARAMONGA	C-1 (2)	88.60	3.14	8.26	29.65	11.40	10.21	9.08	8.26	28.45	19.11	1.63	30	21	1.73	7.91	GP-GC	25.71	0.2100			626
							C-3 (2)	72.16	2.20	25.64	39.93	27.84	27.11	26.53	25.64	28.22	9.40	SR	29	23	1.73	17.14	GM	19.34	0.4500			627
							C-4	77.87	7.83	14.29	30.67	22.13	19.98	17.03	14.29	41.20	17.81	SR	29	17	1.48	29.40	GC	25.59	0.1900			628
8	ANÁLISIS DE ALTERNATIVAS TÉCNICO ECONÓMICAS PARA ESTABILIZAR EL TALUD UBICADO EN EL KM 3+310 AL KM 3+490 DE LA VÍA CHONTAYOC - TINYASH, DISTRITO DE INDEPENDENCIA - HUARAZ - ANCASH	PACCINI SÁNCHEZ JEAN CARLOS	UNIVERSIDAD NACIONAL SANTIAGO ANTUNEZ DE MAYOLO	2018	https://repositorio.unasam.edu.pe/handle/UNASAM/2471	CENTRO POBLADO CHONTAYOC TINYASH, DISTRITO INDEPENDENCIA, PROVINCIA HUARAZ - ANCASH	C-1	4.56	58.04	37.40	100.00	95.44	88.27	57.90	37.40	0.50	SR	SR	35	20	1.56	11.09	SC	25.54	0.2100			629
							C-2	19.47	36.20	44.33	94.30	80.53	74.05	56.97	44.33	0.56	SR	SR	38	25	1.69	20.47	SM	25.60	0.2300			630
							C-3	18.44	37.30	44.26	86.90	81.56	76.50	58.95	44.26	0.45	SR	SR	41	26	1.69	13.64	SM	25.44	0.2300			631
							C-4	11.49	41.11	47.40	100.00	88.51	77.68	60.29	47.40	0.41	SR	SR	43	31	1.53	17.51	SM	23.48	0.1900			632
							C-5	19.87	37.64	42.49	100.00	80.13	70.79	53.77	42.49	0.82	SR	SR	41	28	1.66	17.45	SM	24.01	0.2100			633
9	APLICACIÓN DEL PROGRAMA GEOSLOPE PARA EL ANÁLISIS DE LA ESTABILIDAD DE TALUDES EN LA I.E. LA LIBERTAD	SÁNCHEZ PEREZ, María Regina	UNIVERSIDAD NACIONAL SANTIAGO ANTUNEZ DE MAYOLO	2014	https://repositorio.unasam.edu.pe/handle/UNASAM/1176	I.E. LA LIBERTAD, DISTRITO DE HUARAZ, ANCASH	C-1	60.63	34.52	4.85	56.87	39.37	32.86	15.45	4.85	21.77	1.54	0.25	NP	NP	1.79	3.78	GP	29.37	0.0800			634
10	MODELAMIENTO DEL HIDROGRAMA DE RUPTURA MEDIANTE CARACTERÍSTICAS HIDROMÉTRICAS Y PROPIEDADES MECÁNICAS DEL SUELO DEL DIQUE NATURAL DE LA LAGUNA PALCACOCHA, HUARAZ. 2019	ALVAREZ BENAUTE, MICHELLE IRENE	UNIVERSIDAD NACIONAL SANTIAGO ANTUNEZ DE MAYOLO	2019	https://repositorio.unasam.edu.pe/handle/UNASAM/4337	DIQUE NATURAL DE LA LAGUNA PALCACOCHA, HUARAZ	C-1	45.50	29.10	25.40	77.60	54.50	46.80	36.50	25.40	6.90	0.10	SR	16.89	14.68	1.63	7.43	GM	28.60	0.1100			635
11	ANÁLISIS DE INTERACCIÓN SÍSMICA SUELO ESTRUCTURA PARA REDUCIR ESFUERZOS EN LOS ELEMENTOS ESTRUCTURALES EN EDIFICACIONES REGULARES E IRREGULARES CON ZAPATAS AISLADAS EN HUARAZ.	EFFRAIN MANUEL LOPEZ SOTELO	UNIVERSIDAD NACIONAL SANTIAGO ANTUNEZ DE MAYOLO	2013	https://repositorio.unasam.edu.pe/handle/UNASAM/883	HUARAZ	C-1	52.68	23.27	24.05	68.61	47.32	42.05	33.21	24.05	12.11	0.25	SR	22.83	20.08	1.72	6.04	GM	30.45	0.0700			636
12	CRITERIOS PARA LA EVALUACION DE LA VULNERABILIDAD SISMICA DE PUENTES DE CONCRETO ARMADO EN LA ZONA URBANA DE LA CIUDAD DE HUARAZ - SUB CUENCA DEL RIO QUILLCAY	MARCO ANTONIO SALAZAR CELESTINO	UNIVERSIDAD NACIONAL SANTIAGO ANTUNEZ DE MAYOLO	2016	https://repositorio.unasam.edu.pe/handle/UNASAM/2601	CIUDAD DE HUARAZ - SUB CUENCA DEL RIO QUILLCAY	C-1	57.82	40.71	1.47	72.11	42.18	30.62	9.99	1.47	11.52	2.02	0.44	NP	NP	1.83	4.52	GP	25.30	0.1700			637
							C-2	28.51	38.32	33.17	84.77	71.49	64.03	49.01	33.17	1.40	SR	SR	24.41	18.61	1.70	12.57	SC-SM	26.22	0.1400			638
							C-1	49.50	31.97	18.53	69.58	50.50	43.19	25.52	18.53	11.76	0.66	SR	24.8	16.35	1.62	12.65	GC	24.00	0.0500			639

N° TESIS	TITULO DE TESIS	AUTOR(S)	UNIVERSIDAD	AÑO	LINK	LUGAR DE ESTUDIO (DISTRITO, PROVINCIA)	NOMBRE DE CALICATA	GRANULOMETRIA			% QUE PASAN					DIAMETROS			LIMITES		DENSIDAD Y HUMEDAD		CLASIF.	PARAMETROS		velocidad de ensayo	NORMA	N° DATOS
								% GRAVA	% ARENA	% FINOS	3/4" 19.0mm	4# 4.75mm	10# 2.0mm	40# 0.425mm	200# 0.075mm	D60	D30	D10	LL	LP	D. SECA	H%		ANG.	C(kg/cm2)			
	VALORES TÍPICOS						C 6 - M 1 C 7 - M 1 C 8 - M 1	0.00 0.60 2.50	94.10 92.80 88.80	5.90 6.60 8.70	100.00 100.00 100.00	100.00 99.40 97.50	100.00 97.20 90.30	85.50 69.30 55.70	5.90 6.60 8.70	0.28 0.35 0.52	0.17 0.19 0.22	0.09 0.09 0.08	18.17 18.11 18.01	NP NP NP	1.40 1.48 1.54	** ** **	SP-SM SP-SM SW-SM	28.10 25.00 26.40	0.0000 0.0400 0.0400			718 719 720
29	ANÁLISIS COMPARATIVO ENTRE LA CAPACIDAD PORTANTE DETERMINADA CON EL ENSAYO DE CORTE DIRECTO Y EL ENSAYO DE PENETRACIÓN ESTÁNDAR, DEL SUELO PARA EL PROYECTO SISTEMA DE SANEAMIENTO RURAL EN EL DISTRITO DE JESUS -CAJAMARCA	LIZZ KATHERINE VÁSQUEZ ENEQUE	UNIVERSIDAD NACIONAL DE CAJAMARCA	2023	https://repositorio.unc.edu.pe/handle/20.500.14074/5440	DISTRITO DE JESUS - CAJAMARCA	C-1 C-2 C-3	0.31 0.12 1.81	23.59 47.51 26.65	76.10 52.37 71.54	100.00 100.00 100.00	99.69 99.88 98.19	99.32 97.84 97.74	97.18 87.38 95.56	76.10 52.37 71.54	SR 0.15 SR	SR SR SR	SR SR SR	34 30 33	26 25 26	1.34 1.45 1.31	37.54 27.08 31.67	ML ML ML	20.78 24.85 18.27	0.3140 0.2720 0.3060			721 722 723
30	ZONIFICACIÓN GEOTECNICA DE LOS SUELOS DE FUNDACIÓN, MEDIANTE EL ENSAYO DE CORTE DIRECTO Y DPL EN LA URBANIZACIÓN LOS GIRASOLES - JAEN - 2016	José Wilfredo Cotrina Velásquez	UNIVERSIDAD NACIONAL DE CAJAMARCA	2017	https://repositorio.unc.edu.pe/handle/20.500.14074/1054	LOS GIRASOLES, JAEN- CAJAMARCA	C - 1 C - 2 C - 3 C - 4 C - 5	27.50 0.03 36.76 50.03 51.71	23.47 17.18 20.65 20.46 44.86	49.03 82.79 42.59 29.51 3.43	86.51 100.00 86.38 76.78 77.23	72.50 99.97 63.24 49.97 48.29	67.72 99.40 57.91 43.21 44.20	57.25 96.06 49.37 33.56 28.78	49.03 82.79 42.59 29.51 3.43	0.59 SR 2.80 8.10 9.00	SR SR SR 0.90 0.50	SR SR SR SR 0.16	31 38 26 23 19	25 34 22 19 NP	1.91 n.r n.r n.r n.r	11.41 ** ** ** **	GM ML GM GC-GM GP	32.94 33.39 11.09 28.36 15.29	0.4500 0.4900 1.0900 0.1500 0.2000			724 725 726 727 728
31	RIESGO GEOTÉCNICO DE DESLIZAMIENTO EN LOS TALUDES DEL TERRENO DEL COLEGIO "SAN CARLOS" - BAMBAMARCA	ZAMORA GARCÍA, ANGEL IVÁN MATEO	UNIVERSIDAD NACIONAL DE CAJAMARCA	2019	https://repositorio.unc.edu.pe/handle/20.500.14074/2903	COLEGIO "SAN CARLOS", BAMBAMARCA CAJAMARCA	ST, PURPUR	0.00	63.57	36.43	100.00	100.00	98.69	75.76	36.43	0.52	SR	SR	36.75	25.13	2.40	1.40	SM	29.83	0.0000			729 *
32	GRADO DE ESTABILIDAD DE LOS TALUDES CRÍTICOS DE LA CARRETERA BAÑOS DEL INCA - LLACANORA	Ronald Alexis Tarrillo Membrillo	UNIVERSIDAD NACIONAL DE CAJAMARCA	2018	https://repositorio.unc.edu.pe/handle/20.500.14074/1995	CARRETERA BAÑOS DEL INCA , LLACANORA- CAJAMARCA	C-01	4.49	49.94	45.57	100.00	95.51	93.22	87.58	45.57	0.18	SR	SR	26.9	20.66	n.r	15.80	SC-SM	36.87	0.5200			730 *
33	ALTERACIÓN DE LAS PROPIEDADES FÍSICO MECÁNICAS DE SUELOS POR LA ACTIVIDAD EXTRACTIVA DE ARCILLA UTILIZADA PARA LA FABRICACIÓN DE LADRILLO ARTESANAL EN EL CENTRO POBLADO SANTA BÁRBARA - CAJAMARCA.	YVONNE KATHERINE FERNÁNDEZ LEÓN	UNIVERSIDAD NACIONAL DE CAJAMARCA	2019	https://repositorio.unc.edu.pe/handle/20.500.14074/3484	CENTRO POBLADO SANTA BÁRBARA - CAJAMARCA.	C-1 C-2	9.82 28.66	55.66 36.46	34.52 34.88	100.00 88.78	90.18 71.34	82.70 65.96	64.00 54.44	34.52 34.88	0.36 0.82	SR SR	SR SR	42.3 33.9	20.79 28.5	1.86 0.81	11.27 26.25	SC SM	10.00 20.86	0.2100 0.0020		ASTM 3080 ASTM 3080	731 732 *
34	EVALUACIÓN GEOTÉCNICA DE LOS SUELOS DE FUNDACIÓN EN LA ZONA URBANA DEL CENTRO POBLADO SAN MIGUEL DE LAS NARANJAS - JAEN	ÓSCAR ELÍ VÁSQUEZ VÁSQUEZ	UNIVERSIDAD NACIONAL DE CAJAMARCA	2014	https://repositorio.unc.edu.pe/handle/20.500.14074/689	CENTRO POBLADO SAN MIGUEL DE LAS NARANJAS , JAEN - CAJAMARCA	C 2 - M2 C 3 - M2 C 4 - M1 C 5 - M1 C 6 - M1 C 7 - M1 C 8 - M1 C 9 - M1 C 10 - M1 C 11 - M1 C 12 - M1 C 14 - M2 C 15 - M2 C 16 - M2 C 17 - M2 C 18 - M1 C 19 - M1 C 20 - M1 C 21 - M1	10.00 5.02 1.32 68.68 0.00 2.98 51.54 36.87 39.25 2.75 35.01 37.82 28.68 59.90 21.46 38.46 27.47 30.68 7.23	65.31 8.60 9.78 6.00 9.97 11.57 24.73 30.90 48.10 1.30 33.03 42.48 44.96 31.83 63.71 43.46 52.17 47.26 45.55	24.69 86.38 88.90 25.32 90.03 85.45 23.73 32.23 12.65 95.95 31.96 19.70 26.36 8.27 14.83 18.08 20.36 22.06 47.22	100.00 100.00 100.00 100.00 100.00 100.00 75.53 96.77 94.79 100.00 79.71 95.06 96.11 91.64 95.93 87.60 100.00 94.44 100.00	90.00 94.98 98.68 31.32 100.00 97.02 48.46 63.13 60.75 97.25 64.99 62.18 71.32 40.10 78.54 61.54 72.53 69.32 69.32	68.67 94.52 95.71 28.18 100.00 91.59 41.77 50.11 35.14 97.05 56.32 40.28 56.41 25.62 70.54 29.49 69.67 48.15 48.15	38.48 90.11 91.20 26.27 99.59 86.98 36.18 42.34 20.18 96.58 42.63 23.97 37.99 12.02 52.07 25.11 56.49 32.99 76.14	24.69 86.38 88.90 25.32 90.03 85.45 23.73 32.23 12.65 95.95 31.96 19.70 26.36 8.27 14.83 18.08 20.36 22.06 47.22	1.30 SR SR 10.40 SR SR 10.50 3.80 4.60 SR 2.90 4.30 2.46 10.57 0.64 4.50 0.54 3.29 0.18	0.18 SR SR 3.50 SR SR 0.19 SR 1.30 SR SR 0.17 0.18 0.26 0.15 2.05 0.14 0.26 SR	SR SR SR SR SR SR SR SR SR SR SR SR SR SR SR SR SR SR SR	35 28 58 37 33 51 17 36 31 24 32 28 24 23 22 28 37 49 33 45	31 24 44 31 24 43 14 28 25 NP 23 24 18 22 24 21 42 25 28	1.40 1.29 1.30 1.53 1.61 1.05 1.65 1.61 1.76 1.67 1.60 1.74 1.48 1.50 1.72 1.45 1.27 1.44 1.15	7.02 21.06 27.12 6.18 14.76 54.53 16.22 7.80 3.41 6.13 9.63 3.10 10.27 5.68 15.25 26.56 22.56 13.61 43.02	SM ML MH GM ML MH GM GM SM ML GC SM SC-SM GW-GM SM SC SC-SM SM	22.94 12.87 7.74 33.18 10.45 5.92 32.40 30.31 24.95 8.36 30.31 24.80 21.36 32.84 27.36 26.07 24.53 26.24 25.16	0.1780 0.2100 0.1900 0.2300 0.1500 0.2600 0.2500 0.2000 0.1460 0.2700 0.2000 0.1480 0.1200 0.2100 0.0700 0.1500 0.2800 0.0300 0.0900		ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080	733 734 735 736 737 738 739 740 741 742 743 744 745 746 747 748 749 750 751
							C 2 - M 2	26.57	24.31	49.12	91.30	73.43	67.03	58.32	49.12	0.55	SR	SR	30	20	1.50	15.96	GC	29.70	0.1100		ASTM 3080	752

N° TESIS	TITULO DE TESIS	AUTOR(S)	UNIVERSIDAD	AÑO	LINK	LUGAR DE ESTUDIO (DISTRITO, PROVINCIA)	NOMBRE DE CALICATA	GRANULOMETRIA			% QUE PASAN					DIAMETROS			LIMITES		DENSIDAD Y HUMED.		CLASIF.	PARAMETROS		velocidad de ensayo	NORMA	N° DATOS
								% GRAVA	% ARENA	% FINOS	3/4" 19.0mm	4# 4.75mm	10# 2.0mm	40# 0.425mm	200# 0.075mm	D60	D30	D10	LL	LP	D. SECA	H%		USCS	ANG.			
35	EVALUACIÓN DEL COMPORTAMIENTO ESTRUCTURAL DE LA TRIBUNA DEL ESTADIO VÍCTOR MONTTOYA SEGURA EN LA CIUDAD DE JAÉN – CAJAMARCA – PERÚ	RAMÍREZ CRUZ YALEMI LIBERTAD	UNIVERSIDAD NACIONAL DE CAJAMARCA	2019	https://repositorio.unc.edu.pe/handle/20.500.14074/2796	CIUDAD DE JAÉN – CAJAMARCA – PERÚ																						*
36	INFLUENCIA DE LOS PARÁMETROS CONDICIONANTES Y DESENCADENANTES EN EL DESLIZAMIENTO DE MASAS DE SUELOS EN LA QUEBRADA HUAYLLAPAMPA	FERNANDO ANDRÉ CARRASCO VICTORIA.	UNIVERSIDAD NACIONAL DE CAJAMARCA	2017	https://repositorio.unc.edu.pe/handle/20.500.14074/1491	QUEBRADA HUAYLLAPAMPA - CAJAMARCA	C-2 C-4	1.17 44.70	60.13 28.33	38.70 26.97	100.00 91.25	98.83 55.30	93.48 40.60	67.73 30.38	38.70 26.97	0.30 5.83	SR 0.42	SR SR	30 34	22 20	1.53 1.58	13.99 10.36	SC GC	11.20 8.30	0.1900 0.6200		ASTM 3080 ASTM 3080	753 754
37	ESTUDIO PATOLÓGICO DEL EDIFICIO DE LA UNIVERSIDAD NACIONAL DE CAJAMARCA - SEDE JAÉN – LOCAL CENTRAL	EDWIN SÁNCHEZ ZULUETA	UNIVERSIDAD NACIONAL DE CAJAMARCA	2018	https://repositorio.unc.edu.pe/handle/20.500.14074/1990	CIUDAD DE JAÉN – CAJAMARCA – PERÚ	C 1 -E1	8.09	47.41	44.50	100.00	91.91	80.23	65.78	44.50	0.27	SR	SR	34.99	23.33	1.74	13.68	SC	21.50	0.1500		ASTM 3080	755
38	EVALUACIÓN GEODINÁMICA DE LADERAS Y TALUDES ENTRE SUNUDÉN - SAN MIGUEL .- JANGALÁ, PROVINCIA DE SAN MIGUEL, OPTO - CAJAMARCA	WILSON MICHAEL HERNÁNDEZ BECERRA	UNIVERSIDAD NACIONAL DE CAJAMARCA	2016	https://repositorio.unc.edu.pe/handle/20.500.14074/114	PROVINCIA DE SAN MIGUEL, OPTO - CAJAMARCA.	C 1- M2 C 2- M1	1.80 0.84	58.47 17.80	39.73 81.36	100.00 100.00	98.20 99.16	89.40 96.88	57.30 89.28	39.73 81.36	0.50 SR	SR SR	SR SR	33 45	24 36	1.46 1.41	16.71 25.48	SM ML	29.20 19.50	0.0300 0.1000		ASTM 3080 ASTM 3080	756 757
39	MEJORAMIENTO DEL SERVICIO EDUCATIVO PRIMARIA DE LA I.E. N° 80152, DEL CASERÍO DE PUENTE PIEDRA, DISTRITO DE HUAMACHUCO, PROVINCIA DE SÁNCHEZ CARRIÓN - LA LIBERTAD	ADRIANA CECILIA ESPEJO CHAVARRIA	UNIVERSIDAD NACIONAL DE CAJAMARCA	2013	https://repositorio.unc.edu.pe/handle/20.500.14074/652	PROVINCIA DE SÁNCHEZ CARRIÓN - LA LIBERTAD	C 1- E2 C 2- E3 C 3- E2 C 4- E2	2.53 0.00 0.00 0.00	53.94 55.99 59.68 58.16	43.53 44.01 40.32 41.84	100.00 100.00 100.00 100.00	97.47 100.00 100.00 100.00	96.51 99.37 98.73 97.40	90.17 84.71 82.95 77.96	43.53 44.01 40.32 41.84	0.16 0.18 0.18 0.19	SR SR SR SR	SR SR SR SR	44.84 40.87 38.88 39.71	23.16 34.55 32.99 24.83	1.25 1.42 1.43 1.23	24.30 25.11 25.96 23.68	SC SM SM SC	25.64 23.27 23.75 26.57	0.2016 0.2300 0.2148 0.1931		ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080	758 759 760 761
40	AMPLIACIÓN Y MEJORAMIENTO DEL SERVICIO DE AGUA POTABLE Y DISPOSICIÓN SANITARIA DE EXCRETAS EN EL C.P. PIRIAS, CASERÍOS Y SECTORES, DISTRITO DE CHIRINOS SAN IGNACIO - CAJAMARCA	Rivera Arcila Elizabeth	UNIVERSIDAD NACIONAL DE CAJAMARCA	2013	https://repositorio.unc.edu.pe/handle/20.500.14074/114	DISTRITO DE CHIRINOS SAN IGNACIO - CAJAMARCA	C 10- M1 ALC 7- M2	4.21 19.49	50.93 31.94	44.86 48.57	100.00 94.48	95.79 80.51	92.90 74.95	71.49 60.37	44.86 48.57	0.29 0.41	SR SR	SR SR	20.53 42.12	17.69 31.56	1.63 1.55	13.89 14.85	SM SM	34.27 30.40	0.0040 0.0800		ASTM 3080 ASTM 3080	762 763
41	EVALUACIÓN DE SUELOS CON FINES DE CIMENTACIÓN EN LOS SECTORES 1 Y 5 DE LA CIUDAD DE CHOTA, 2021.	DELÍ MILÁN TARRILLO BUSTAMANTE	UNIVERSIDAD NACIONAL AUTÓNOMA DE CHOTA	2021	https://repositorio.unach.edu.pe/handle/20.500.1414/2/410	CIUDAD DE CHOTA- CAJAMARCA	C 4- M1 C 6- M1 C 8- M1 C 9- M1 C 10- M1 C 11- M1 C 12- M1 C 13- M1 C 14- M1 C 15- M1 C 16- M1 C 17- M1 C 18- M1	21.02 15.62 0.00 3.48 23.71 23.58 1.17 4.40 3.29 4.07 5.78 6.92 2.84	21.59 15.16 36.47 35.82 23.09 26.32 39.08 27.30 30.47 28.12 37.97 39.07 31.39	57.39 69.22 63.53 60.70 53.20 50.10 59.75 68.30 66.24 67.81 56.25 54.01 65.77	93.92 100.00 100.00 100.00 87.92 89.04 100.00 100.00 100.00 100.00 100.00 100.00 100.00	78.98 84.38 79.90 96.52 76.29 76.42 95.12 95.60 91.23 91.17 94.22 93.08 97.16	67.62 73.17 88.05 80.47 58.11 56.42 83.64 89.54 79.18 79.45 77.95 84.08 80.90	57.39 69.22 63.53 60.70 53.20 50.10 59.75 68.30 66.24 67.81 56.25 54.01 65.77	0.14 SR SR SR 0.58 0.77 0.08 SR SR SR 0.17 SR	SR SR SR SR SR SR SR SR SR SR SR SR SR	SR SR SR SR SR SR SR SR SR SR SR SR SR	44 37 36 36 35 37 35 28 27 28 37 24 19	30 28 25 24 25 24 30 23 22 22 26 19	1.06 1.53 1.46 1.48 1.38 1.47 1.48 1.43 1.33 1.06 1.36 1.13 1.48	50.46 9.41 12.67 24.42 21.64 27.36 23.78 23.78 19.12 50.46 7.34 22.73 23.60	ML ML ML ML ML ML ML ML ML CL-ML ML CL-ML ML	24.30 26.30 27.47 24.66 26.44 25.07 27.78 24.84 28.57 24.31 24.27 24.83 27.78	0.2800 0.2100 0.3200 0.2500 0.4600 0.2400 0.1540 0.3100 0.2100 0.3100 0.4000 0.7400 0.1540	0.25 0.25 0.25 0.25 0.25 0.25 0.25 0.25 0.25 0.25 0.25 0.25 0.25	ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080	764 765 766 767 768 769 770 771 772 773 774 775 776	
	Evaluación de la Capacidad Portante del SUELO EN LA CIUDAD DE CHOTA	Rafael Fernandez, BUSTAMANTE	UNIVERSIDAD NACIONAL AUTÓNOMA DE CHOTA		https://repositorio.unach.edu.pe/handle/20.500.1414/2/410	CIUDAD DE CHOTA- CAJAMARCA	C 01 C 03 C 04 C 05	17.80 0.00 0.90 61.20	46.70 79.90 79.50 33.90	35.50 20.10 19.60 4.90	95.20 100.00 100.00 59.80	82.20 100.00 99.70 38.80	75.10 99.70 97.10 31.90	60.10 84.60 81.00 9.90	35.50 20.10 19.60 4.90	0.42 0.31 0.33 19.80	SR 0.16 0.19 1.80	SR NP NP NP	34 NP NP NP	16 NP NP NP	1.56 1.59 1.60 2.03	13.90 18.53 18.30 3.10	SC SM SM GP	39.93 37.60 37.23 n.r	0.0000 0.0000 0.0100 n.r	0.50 0.50 0.50 0.50	ASTM 3080 ASTM 3080 ASTM 3080 ASTM 3080	777 778 779 780

N° TESIS	TITULO DE TESIS	AUTOR(S)	UNIVERSIDAD	AÑO	LINK	LUGAR DE ESTUDIO (DISTRITO, PROVINCIA)	NOMBRE DE CALICATA	GRANULOMETRIA			% QUE PASAN					DIAMETROS			LIMITES		DENSIDAD Y HUME		CLASIF.	PARAMETROS		velocidad de ensayo	NORMA	N°DATOS
								% GRAVA	% ARENA	% FINOS	3/4" 19.0mm	4# 4.75mm	10# 2.0mm	40# 0.425mm	200# 0.075mm	D60	D30	D10	LL	LP	D. SECA	H%	USCS	ANG.	C(kg/cm2)			
						PAMPA BAJA-TACNA	TA_A_4053	69.24	28.30	2.46	100.00	30.76			2.46	SR	SR	SR	21	NP	n.r	2.80	GP	34.60	0.0000		ASTM 3080	1283
						ADORES SANTA ROSA-TACNA	TA_A_4062	0.00	29.64	70.36	100.00	100.00			70.36	SR	SR	SR	33	27	n.r	33.60	ML	22.70	0.1800		ASTM 3080	1284
						ACO-JUNIN	U_A_1014	50.48	29.89	19.63	100.00	49.52			19.63	SR	SR	SR	23	NP	n.r	18.30	GM	33.70	0.0700		ASTM 3080	1285
						SANTA ROSA-JUNIN	JU_A_1025	71.72	23.01	5.27	100.00	28.28			5.27	SR	SR	SR	27	14	n.r	11.20	GP-GC	33.50	0.1100		ASTM 3080	1286
						JAMANCACA CHICO-JUNIN	JU_A_1077	0.00	16.61	83.39	100.00	100.00			83.39	SR	SR	SR	34	19	n.r	11.10	CL	14.60	0.2800		ASTM 3080	1287
						JEVO MOROCOCHA-JUNIN	U_A_1092	44.89	36.84	18.27	100.00	55.11			18.27	SR	SR	SR	22	NP	n.r	15.50	GM	32.30	0.0500		ASTM 3080	1288
						PUMPUNYA-JUNIN	JU_A_1334	67.83	24.93	7.24	100.00	32.17			7.24	SR	SR	SR	27	NP	n.r	5.80	GP-GM	34.00	0.0500		ASTM 3080	1289
						CRUZ PAMPA-JUNIN	JU_A_1360	40.57	13.29	46.14	100.00	59.43			46.14	SR	SR	SR	60	26	n.r	22.40	GC	32.00	0.1600		ASTM 3080	1290
						TITIRE-MOQUEGUA	MQ_T_0003	2.77	49.83	47.40	100.00	97.23			47.40	SR	SR	SR	25	NP	n.r	43.30	SM	29.10	0.0800		ASTM 3080	1291
						AJOYANI-PUNO	PU_A_2026	75.69	20.35	3.96	100.00	24.31			3.96	SR	SR	SR	21	15	n.r	4.60	GP	34.90	0.0700		ASTM 3080	1292
						HUATASANI-PUNO	PU_A_2045	0.00	3.10	96.90	100.00	100.00			96.90	SR	SR	SR	26	21	n.r	21.50	CL-ML	12.70	0.2900		ASTM 3080	1293
						AYRAMPUNI-PUNO	PU_A_2067	41.43	47.69	10.88	100.00	58.57			10.88	SR	SR	SR	32	17	n.r	27.80	SP-SC	33.10	0.1300		ASTM 3080	1294
						QUILCAPUNCU-PUNO	PU_A_2068	62.23	34.55	3.22	100.00	37.77			3.22	SR	SR	SR	18	NP	n.r	4.80	GW	35.50	0.0000		ASTM 3080	1295
						N JUAN DE CUTURAPI-PUNO	PU_A_2085	59.54	23.03	17.43	100.00	40.46			17.43	SR	SR	SR	21	NP	n.r	20.50	GM	34.00	0.0500		ASTM 3080	1296
						LUQUINA CHICO-PUNO	PU_A_2144	0.00	45.15	54.85	100.00	100.00			54.85	SR	SR	SR	29	21	n.r	9.90	CL	13.70	0.2800		ASTM 3080	1297
						HUARIJUYO-PUNO	PU_A_2157	71.82	24.11	4.07	100.00	28.18			4.07	SR	SR	SR	21	NP	n.r	9.60	GP	34.90	0.0000		ASTM 3080	1298
						SANTA ANA-PUNO	PU_A_2166	0.00	11.37	88.63	100.00	100.00			88.63	SR	SR	SR	32	18	n.r	28.10	CL	14.60	0.2700		ASTM 3080	1299

NUM. MUESTRA	G. GRUESA	G. FINA	A. GRUESA	A. MEDIANA	A. FINA	S. FINO	GRADUADO	LL	IP	D. SECA	HUMEDAD	ANGULO	COHESION	USCS
1046	0.00	0.00	13.00	22.12	38.53	26.35	P	26.00	10.00	1.41	10.30	28.30	13.73	SC
1047	0.00	0.00	15.05	34.33	8.76	41.86	P	22.00	6.00	1.49	10.10	29.20	12.75	SC-SM
1048	0.00	3.48	6.58	12.29	58.54	19.11	P	20.00	0.00	1.59	8.60	28.30	3.92	SM
1049	0.00	0.00	16.64	26.12	32.16	25.08	P	35.00	18.00	1.56	14.80	29.90	11.77	SC
1050	0.00	39.61	8.35	1.43	10.20	40.41	P	25.00	9.00	1.65	18.20	30.40	18.63	GC
1051	0.00	0.00	2.26	6.99	31.23	59.52	P	30.00	0.00	1.46	14.90	22.60	16.67	ML
1052	0.00	69.24	3.51	11.63	13.16	2.46	P	21.00	0.00	1.73	2.80	34.60	0.00	GP
1053	0.00	0.00	2.37	7.03	20.24	70.36	P	33.00	6.00	1.47	33.60	22.70	17.65	ML
1054	0.00	50.48	4.95	5.43	19.51	19.63	P	23.00	0.00	1.80	18.30	33.70	6.86	GM
1055	0.00	71.72	12.14	2.59	8.28	5.27	P	27.00	13.00	1.74	11.20	33.50	10.79	GP-GC
1056	0.00	44.89	7.08	9.04	20.72	18.27	P	22.00	0.00	1.74	15.50	32.30	4.90	GM
1057	0.00	67.83	12.86	0.31	11.76	7.24	P	27.00	0.00	2.01	5.80	34.00	4.90	GP-GM
1058	0.00	40.57	11.86	0.00	1.43	46.14	P	40.00	14.00	1.70	22.40	32.00	25.50	GC
1059	0.00	2.77	8.87	14.57	26.39	47.40	P	25.00	0.00	1.66	43.30	29.10	7.85	SM
1060	0.00	75.69	3.81	10.81	5.73	3.96	P	21.00	11.00	1.76	4.60	34.90	0.98	GP
1061	0.00	41.43	13.57	34.12	0.00	10.88	P	32.00	15.00	1.70	7.80	33.10	12.75	SP-SC
1062	0.00	62.23	15.80	18.75	0.00	3.22	W	18.00	0.00	1.77	4.80	35.50	0.00	GW
1063	0.00	59.54	4.49	4.65	13.89	17.43	P	21.00	0.00	1.82	20.50	34.00	4.90	GM
1064	0.00	71.82	3.81	10.81	9.49	4.07	P	21.00	0.00	1.76	9.60	34.90	0.00	GP
1065	35.00	35.20	24.80	0.00	0.00	5.00	W	0.00	0.00	2.00	1.50	41.00	3.63	GW
1066	35.00	35.20	21.80	5.20	0.00	2.80	W	0.00	0.00	1.97	2.00	39.00	2.65	GW
1067	35.00	35.20	17.80	10.50	0.00	1.50	W	0.00	0.00	1.85	15.00	38.00	0.49	GW
1068	28.00	42.18	21.45	1.47	1.80	5.10	W	18.60	10.70	1.85	9.26	35.20	2.45	GW-GC
1069	38.00	27.00	27.50	0.00	0.00	7.50	W	14.00	4.00	2.19	3.10	39.70	1.96	GW-GC
1070	19.00	44.00	24.20	2.21	0.00	10.59	W	34.00	11.41	1.92	17.00	37.40	9.81	GW-GC
1071	48.00	19.20	27.40	0.00	0.00	5.40	W	18.00	4.15	1.95	11.11	38.50	2.94	GW-GC
1072	47.00	24.30	23.47	0.00	0.00	5.23	W	20.00	7.20	2.19	12.96	39.80	3.43	GW-GC
1073	24.00	47.00	20.50	1.00	2.50	5.00	W	15.20	5.50	1.96	0.00	36.60	0.00	GW-GC
1074	50.00	11.50	31.61	0.89	0.90	5.10	W	14.00	5.30	2.27	1.70	40.80	0.98	GW-GC
1075	8.00	60.65	20.90	2.95	1.30	6.20	W	16.00	4.80	1.84	9.26	35.00	2.45	GW-GC
1076	45.00	21.50	27.60	0.90	0.00	5.00	W	14.90	6.60	2.00	3.70	41.50	0.98	GW-GC
1077	19.00	34.35	15.48	16.17	7.50	7.50	W	16.00	6.10	1.69	14.81	33.00	3.92	GW-GC
1078	25.00	20.70	12.76	21.54	13.10	6.90	W	19.00	4.90	1.71	16.67	32.00	4.41	GW-GC
1079	17.00	44.00	18.19	5.11	7.00	8.70	W	26.00	5.30	1.76	25.93	34.00	6.86	GW-GM
1080	39.00	22.00	28.52	0.00	0.00	10.48	W	35.00	7.60	1.95	23.30	39.30	8.83	GW-GM
1081	7.00	38.70	12.76	19.24	15.60	6.70	W	0.00	0.00	1.72	10.37	32.00	2.75	GW-GM
1082	0.00	15.44	17.90	35.30	29.57	1.79	W	0.00	0.00	1.63	3.40	32.83	0.00	SW
1083	0.00	14.87	29.20	41.00	10.28	4.65	W	0.00	0.00	1.74	4.00	39.72	4.90	SW
1084	0.00	23.28	24.40	40.00	8.63	3.69	W	0.00	0.00	1.65	4.50	37.06	2.94	SW
1085	0.00	20.12	19.30	31.20	24.85	4.53	W	0.00	0.00	1.59	24.30	30.80	2.99	SW
1086	0.00	15.18	15.70	29.30	35.10	4.72	W	0.00	0.00	1.63	22.00	29.86	0.00	SW
1087	0.00	23.32	26.20	35.00	14.87	0.61	W	0.00	0.00	1.93	5.30	44.89	3.92	SW
1088	0.00	21.80	27.60	32.00	15.50	3.10	W	0.00	0.00	1.74	4.60	41.79	1.47	SW
1089	0.00	1.23	19.40	41.30	35.94	2.13	W	0.00	0.00	1.67	2.50	35.84	2.45	SW
1090	0.00	12.58	21.30	25.60	35.52	5.00	W	0.00	0.00	1.45	22.50	27.98	0.00	SW
1091	0.00	23.47	20.00	40.00	15.56	0.97	W	0.00	0.00	1.90	2.80	45.53	0.20	SW
1092	0.00	4.50	14.70	34.60	41.56	4.64	W	0.00	0.00	1.63	25.00	30.75	1.57	SW
1093	0.00	9.09	16.60	32.80	38.15	3.36	W	0.00	0.00	1.62	16.80	32.16	0.00	SW
1094	0.00	21.24	16.10	35.60	22.56	4.50	W	0.00	0.00	1.58	26.60	31.67	0.00	SW
1095	0.00	23.66	27.40	38.60	6.48	3.86	W	0.00	0.00	1.62	2.80	35.65	3.28	SW
1096	0.00	19.08	30.00	30.00	15.91	5.01	W	0.00	0.00	1.72	2.40	37.72	0.00	SW
1097	0.00	13.31	9.70	27.60	44.69	4.70	W	0.00	0.00	1.61	11.50	29.01	0.00	SW
1098	0.00	17.35	23.50	36.20	22.30	0.65	W	0.00	0.00	1.70	2.90	33.32	0.00	SW
1099	0.00	7.86	32.50	38.00	18.91	2.73	W	0.00	0.00	1.78	3.50	43.71	3.92	SW
1100	0.00	20.67	30.30	41.00	5.97	2.06	W	0.00	0.00	1.74	2.70	39.67	0.29	SW
1101	0.00	8.66	31.00	42.00	15.68	2.66	W	0.00	0.00	1.68	2.70	39.82	4.90	SW
1102	0.00	19.77	26.90	46.00	3.09	4.24	W	0.00	0.00	1.76	0.90	38.71	3.73	SW
1103	0.00	20.57	11.00	27.20	36.99	4.24	W	0.00	0.00	1.59	24.60	28.78	0.00	SW
1104	0.00	24.56	16.40	33.40	21.63	4.01	W	0.00	0.00	1.62	22.40	31.88	0.00	SW
1105	0.00	9.84	24.20	37.00	22.97	5.99	W	0.00	0.00	1.62	6.00	33.69	0.00	SW

ANEXO N° 7

FOTOGRAFIAS DE TRABAJO EN LABORATORIO



FOTOGRAFIAS 01 y 02 ANEXO. Se evidencia las partes del caja de corte directo.



FOTOGRAFIAS 03 y 04 ANEXO. Se evidencia el manejo del equipo del corte directo por parte del tesista.



FOTOGRAFIAS 05 y 06 ANEXO. Se evidencia el ensayo de consistencia (LL) del suelo con metodo copa de Casagrande.



FOTOGRAFIAS 07 y 08 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras Construcción de cobertura de la institucion deportiva en la I.E.S San Luis Gonzaga en la localidad de Conayre.



FOTOGRAFIAS 09 y 10 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras Construcción de cobertura de la institucion deportiva en la I.E.S San Luis Gonzaga en la localidad de Conayre.



FOTOGRAFIAS 11 y 12 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras Construcción de cobertura de la institucion deportiva en la I.E.S San Luis Gonzaga en la localidad de Conayre.



FOTOGRAFIAS 13 y 14 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras "Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central".



FOTOGRAFIAS 15 y 16 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras "Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central".





FOTOGRAFIAS 17 y 18 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras “Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central”.



FOTOGRAFIAS 19 y 20 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras “Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho”.




FOTOGRAFIAS 21 y 22 ANEXO. Se evidencia el ensayo de Corte Directo una de las muestras “Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho”.




FOTOGRAFIAS 23 y 24 ANEXO. Se evidencia el corte del suelo para muestra “Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central”.




FOTOGRAFIAS 25 y 26 ANEXO. Se evidencia el corte del suelo para muestra “Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central”.



FOTOGRAFIAS 27 ANEXO. Se evidencia el corte del suelo para muestra “Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho”.



FOTOGRAFIAS 28 y 29 ANEXO. Se evidencia el corte del suelo para muestra "Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho".



FOTOGRAFIAS 30 y 31 ANEXO. Se evidencia el corte del suelo para muestra "Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho".




FOTOGRAFIAS 32 ANEXO. Se evidencia el corte del suelo para muestra “Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho”.”.



FOTOGRAFIAS 33 y 34 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificación y corte directo.




FOTOGRAFÍAS 35 y 36 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificación y corte directo.



FOTOGRAFÍAS 37 y 38 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificación y corte directo.



FOTOGRAFIAS 39 y 40 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificacion y corte directo.



FOTOGRAFIAS 41 y 42 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificacion y corte directo.



FOTOGRAFÍAS 43 y 44 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificación y corte directo.



FOTOGRAFÍAS 45 y 46 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificación y corte directo.



FOTOGRAFIAS 47 y 48 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificacion y corte directo.



FOTOGRAFIAS 49 y 50 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificacion y corte directo.




FOTOGRAFÍAS 51 y 52 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificación y corte directo.



FOTOGRAFÍAS 53 y 54 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificación y corte directo.



FOTOGRAFIAS 55 y 56 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificacion y corte directo.



FOTOGRAFIAS 57 ANEXO. Se evidencia las muestras de los suelos recolectados para ensayos de clasificacion y corte directo.

ANEXO N° 9 CORTE DIRECTO



**Ensayos de Laboratorio en Mecánica de Suelos, Concreto y Asfalto,
Elaboración de Expedientes Técnicos de Ingeniería Civil, Ambiental,
Ejecución, Supervisión de Obras Civiles y Peritajes.**

VERSIÓN 1

PÁGINA 1

FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

MODULO 2 - Z1

GRAVA BIEN GRADUADA CON ARENA

INFORMACIÓN GENERAL

No. ENSAYO	150
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta M-22
MATERIAL	GW - GRAVA BIEN GRADUADA CON ARENA
PROFUNDIDAD	1.5



RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)				
HUMEDAD FINAL (%)	18.500	18.500	18.500	
PESO UNITARIO (g/cm ³)	1.700	1.700	1.700	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.548	0.548	0.490	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	35.030	69.665	123.242	
COHESIÓN (kPa)	7.370	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	39.960			



GEOTECNIA &
INGENIERIA S.A.C.

Msc. Ing. Angel Hugo Vilchez Peña
INGENIERO TÉCNICO - CIP: 64442





FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	05/08/2023	MODULO 2 - Z2	GRAVA BIEN GRADUADA CON ARENA

INFORMACIÓN GENERAL

No. ENSAYO	152
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta M-22
	GW - GRAVA BIEN GRADUADA CON ARENA
PROFUNDIDAD	1.5M

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD (%)	24.900	24.900	24.900	
PESO UNITARIO (g/cm ³)	1.760	1.760	1.760	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.548	0.548	0.548	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	38.928	68.925	124.974	
COHESIÓN (kPa)	10.046	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	36.577			





FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	05/08/2023	MODULO 2 - Z3	GRAVA MAL GRADUADA CON LIMO

INFORMACIÓN GENERAL

No. ENSAYO	138
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta
	GP-GM GRAVA MAL GRADUADA CON LIMO
PROFUNDIDAD	1.5M

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	27.900	27.900	27.900	
PESO UNITARIO (g/cm ³)	1.750	1.750	1.750	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	36.476	61.392	127.907	0.000
COHESIÓN (kPa)	1.296	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	32.602			





FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	05/08/2023	MODULO 6 - Z5	GRAVA MAL GRADUADA

INFORMACIÓN GENERAL

No. ENSAYO	139
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta
	GP GRAVA MAL GRADUADA
PROFUNDIDAD	1.5M

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)	7.080	7.080	7.080	
HUMEDAD FINAL (%)	20.800	20.800	20.800	
PESO UNITARIO (g/cm ³)	1.750	1.750	1.750	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.548	0.548	0.548	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	41.493	69.369	133.065	
COHESIÓN (kPa)	0.804	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	33.700			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

05/08/2023

MODULO 6 - Z7



ARENA MAL GRADUADA

INFORMACIÓN GENERAL

No. ENSAYO	142
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta
	SP ARENA MAL GRADUADA
PROFUNDIDAD	1.5M

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)	12.650	12.650	12.650	
HUMEDAD FINAL (%)	22.400	22.400	22.400	
PESO UNITARIO (g/cm ³)	1.700	1.700	1.700	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.548	0.548	0.548	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	25.071	45.292	101.769	
COHESIÓN (kPa)	0.585	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	32.500			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

05/08/2023

MODULO 6 - Z 10



ARENA LIMOSA

INFORMACIÓN GENERAL

No. ENSAYO	145
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta
	SM ARENA LIMOSA
PROFUNDIDAD	1.5M

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)	15.890	15.890	15.890	
HUMEDAD FINAL (%)	27.100	27.100	27.100	
PESO UNITARIO (g/cm ³)	1.660	1.660	1.660	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.548	0.346	0.202	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	31.819	53.249	118.461	
COHESIÓN (kPa)	2.504	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	18.605			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

05/08/2023

MODULO 5 - Z 2



ARENA ARCILLOSA CON LIMO

INFORMACIÓN GENERAL

No. ENSAYO	138
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta
	SC-SM ARENA ARCILLOSA CON LIMO
PROFUNDIDAD	1.5M

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	27.900	27.900	27.900	
HUMEDAD FINAL (%)	24.590	24.590	24.590	
PESO UNITARIO (g/cm ³)	1.660	1.660	1.660	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	36.476	61.392	107.907	0.000
COHESIÓN (kPa)	2.000	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	28.450			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

15/08/2023

MODULO 5 - Z 3

ARENA LIMOSA



INFORMACIÓN GENERAL

No. ENSAYO	152
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho
SONDEO	Calicata abierta
	SM ARENA LIMOSO
PROFUNDIDAD	1.5M


RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)	12.650	12.650	12.650	
HUMEDAD FINAL (%)	30.500	30.500	30.500	
PESO UNITARIO (g/cm ³)	1.682	1.682	1.682	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.548	0.548	0.548	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	25.071	45.292	106.769	
COHESIÓN (kPa)	2.072	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	30.510			

GEOTECNIA & INGENIERIA S.A.C.
Msc. Ing. Angel Hugo Vilchez Peña
INGENIERO TÉCNICO - CIP 64442



FECHA DE IMPRESIÓN		ID. MUESTRA		MATERIAL
FECHA DE ENSAYO	05/08/2023	MODULO 5 - Z 5		GRAVA ARCILLOSA
INFORMACIÓN GENERAL				
No. ENSAYO	138			
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul			
PROYECTO	Mejoramiento de los Servicios de Formación Profesional en Ingeniería Agroindustrial de la Universidad Nacional de San Cristóbal de Huamanga, distrito de Ayacucho, Provincia de Huamanga, Departamento de Ayacucho			
SONDEO	Calicata abierta			
MATERIAL	GC GRAVA ARCILLOSA			
PROFUNDIDAD	1.5M			
RESULTADOS DEL ENSAYO				
	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD FINAL (%)	26.780	26.780	26.780	
PESO UNITARIO (g/cm³)	1.730	1.730	1.730	0.000
ÁREA (mm²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	32.030	69.665	123.542	0.000
COHESIÓN (kPa)	3.869	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	31.709			



FECHA DE IMPRESIÓN

2024-02-10

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

2023-12-03

M-22

SM Arena Limosa



INFORMACIÓN GENERAL

No. ENSAYO	192
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento y Ampliación del Servicio de Transitabilidad Mollepata –Pongora en los distritos de Ayacucho y Jesús Nazareno de la Provincia de Huamanga – Departamento de Ayacucho
SONDEO	Calicata abierta M-22
PROFUNDIDAD	2.0 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD FINAL (%)				
PESO UNITARIO (g/cm ³)	1.680	1.680	1.680	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	35.030	69.665	123.542	0.000
COHESIÓN (kPa)	19.448	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	31.057			

GEOTECNIA & INGENIERIA S.A.C.
Msc. Ing. Angel Hugo Vilchez Peña
INGENIERO TÉCNICO - CIP 64442



FECHA DE IMPRESIÓN	2024-02-01	ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	2023-02-02	M-19	SC-SM



INFORMACIÓN GENERAL

No. ENSAYO	235
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento y Ampliación del Servicio de Transitabilidad Mollepata –Pongora en los distritos de Ayacucho y Jesús Nazareno de la Provincia de Huamanga – Departamento de Ayacucho
COORDENADAS	
MATERIAL	SC-SM Arena Arcillosa con presencia de limos
PROFUNDIDAD	1.8m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)	21.212	21.212	21.212	
HUMEDAD FINAL (%)	29.600	29.600	29.600	
PESO UNITARIO (g/cm ³)	1.680	1.680	1.680	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.548	0.548	0.548	
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	
ESFUERZO DE CORTE (kPa)	26.741	38.484	70.082	
COHESIÓN (kPa)	9.620	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	29.450			

GEOTECNIA & INGENIERIA S.A.C.
Msc. Ing. Angel Hugo Vilchez Peña
INSALE TÉCNICO CIP: 64442



FECHA DE IMPRESIÓN	2024-02-01	ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	2023-02-02	M-10	SC



INFORMACIÓN GENERAL

No. ENSAYO	236
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento y Ampliación del Servicio de Transitabilidad Mollepata –Pongora en los distritos de Ayacucho y Jesús Nazareno de la Provincia de Huamanga – Departamento de Ayacucho
COORDENADAS	
MATERIAL	SC Arena Arcillosa
PROFUNDIDAD	1.8m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	25.700	25.700	25.700	
HUMEDAD FINAL (%)	25.700	25.700	25.700	
GRADO SATURACIÓN (%)				
PESO UNITARIO (g/cm ³)	1.500	1.500	1.500	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.586	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	34.389	65.472	102.327	0.000

COHESIÓN (kPa)	15.300	OBSERVACIONES
ÁNGULO DE FRICCIÓN	24.494	



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

27/07/2023

chillico M-1



GRAVA MAL GRADADA LIMOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de la carretera con asfalto tramo centro poblado de carmen alto-yanama, del distrito de carmenalto provincia de huamanga.
MATERIAL	GP-GM: GRAVA MAL GRADADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)				
HUMEDAD FINAL (%)	16.700	16.700	16.700	
PESO UNITARIO (g/cm ³)	1.800	1.800	1.800	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.250	0.250	0.250	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	31.132	62.857	109.824	
COHESIÓN (kPa)	2.004	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	30.203			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

04/03/2023

Quillico 2



GRAVA MAL GRADUADA LIMOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul
PROYECTO	Mejoramiento de la carretera con asfalto tramo centro poblado de carmen alto-yanama, del distrito de carmenalto provincia de huamanga.
MATERIAL	GP-GM: GRAVA MAL GRADUADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	13.835	13.835	13.835	
HUMEDAD FINAL (%)	17.500	17.500	17.500	
PESO UNITARIO (g/cm ³)	1.800	1.800	1.800	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	36.313	75.586	150.580	0.000
COHESIÓN EFECTIVA (kPa)	1.100	OBSERVACIONES		
ÁNGULO DE FRICCIÓN EFECTIVA	34.500			





FECHA DE IMPRESIÓN	ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	20/07/2023	Prog. 0+250
		GRAVA ARCILLOSA CON LIMO

INFORMACIÓN GENERAL



PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Mejoramiento de la carretera con asfalto tramo centro poblado de carmen alto-yanama, del distrito de carmenalto provincia de huamanga.
MATERIAL	GC-GM: GRAVA ARCILLOSA CON LIMO
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
PESO UNITARIO (g/cm ³)	1.800	1.800	1.800	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	32.810	64.515	120.771	0.000
COHESIÓN (kPa)	2.404	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	31.982			



FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL	
FECHA DE ENSAYO	04/03/2023	PROG. 0+530	GRAVA ARCILLOSA	
INFORMACIÓN GENERAL				
PROPOSITO	TESIS			
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul			
PROYECTO	Mejoramiento de la carretera con asfalto tramo centro poblado de carmen alto-yanama, del distrito de carmenalto provincia de huamanga.			
MATERIAL	GC: GRAVA ARCILLOSA			
SONDEO	Calicata abierta			
PROFUNDIDAD	1.5 m			
RESULTADOS DEL ENSAYO				
	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD FINAL (%)	30.300	30.300	30.300	
PESO UNITARIO (g/cm ³)	1.700	1.700	1.700	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	31.576	49.141	108.593	0.000
COHESIÓN EFECTIVA (kPa)	1.998	OBSERVACIONES		
ÁNGULO DE FRICCIÓN EFECTIVA	29.845			





FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	04/03/2023	PROG 0+720	GRAVA BIEN GRADUADA LIMOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul
PROYECTO	Mejoramiento de la carretera con asfalto tramo centro poblado de carmen alto-yanama, del distrito de carmenalto provincia de huamanga.
MATERIAL	GW-GM: GRAVA BIEN GRADUADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)				
HUMEDAD FINAL (%)	18.200	18.200	18.200	
PESO UNITARIO (g/cm ³)	1.800	1.800	1.800	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	35.030	69.660	135.242	0.000
COHESIÓN (kPa)	1.502	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	32.805			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

2023-08-03

PA 01B



Arena Arcillosa

INFORMACIÓN GENERAL

No. ENSAYO	192
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central
MATERIAL	SC : ARENA ARCILLOSA
SONDEO	Calicata abierta
PROFUNDIDAD	2.0 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	20.968	20.968	20.968	
HUMEDAD FINAL (%)	20.968	20.968	20.968	
PESO UNITARIO (g/cm ³)	1.682	1.682	1.682	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	29.071	45.292	91.769	0.000
COHESIÓN (kPa)	1.162	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	24.820			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

12/08/2023

PA-02



ARENA LIMOSA

INFORMACIÓN GENERAL

No. ENSAYO	195
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central
MATERIAL	SM : ARENA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	2.0 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	10.200	10.200	10.200	
HUMEDAD FINAL (%)	21.800	21.800	21.800	
PESO UNITARIO (g/cm ³)	1.794	1.794	1.794	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	20.741	38.484	68.946	0.000
COHESIÓN (kPa)	1.656	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	30.472			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

19/08/2023

PA-06



ARENA LIMOSA

INFORMACIÓN GENERAL

No. ENSAYO	198
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central
MATERIAL	SM : ARENA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	2.0 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)				
HUMEDAD FINAL (%)	24.800	24.800	24.800	24.800
PESO UNITARIO (g/cm ³)	1.558	1.558	1.558	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	31.132	63.449	109.824	0.000
COHESIÓN (kPa)	7.170	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	28.064			





FECHA DE IMPRESIÓN		ID. MUESTRA		MATERIAL
FECHA DE ENSAYO	25/08/2023	PA-07A		

INFORMACIÓN GENERAL

No. ENSAYO	200
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central
MATERIAL	SW-SM : ARENA BIEN GRADUADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5M

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	5.079	5.079	5.079	
HUMEDAD FINAL (%)	19.800	19.800	19.800	
GRADO SATURACIÓN (%)				
PESO UNITARIO (g/cm ³)	1.720	1.720	1.720	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.822	0.822	0.822	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	38.286	76.227	140.862	0.000
COHESIÓN (kPa)	4.950	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	35.036			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

29/08/2023

PA-08



ARENA LIMOSA

INFORMACIÓN GENERAL

No. ENSAYO	201
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central
MATERIAL	SM : ARENA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	2.0 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)				
HUMEDAD FINAL (%)	28.400	28.400	28.400	
PESO UNITARIO (g/cm ³)	1.558	1.558	1.558	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	31.132	62.857	109.824	0.000
COHESIÓN (kPa)	6.873	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	28.103			



FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	30/08/2023	RESERVORIO	ARENA LIMOSA

INFORMACIÓN GENERAL

No. ENSAYO	201
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación y mejoramiento de los servicios de agua potable y saneamiento básico en 9 comunidades del centro poblado de puerto mayo y quisto central
MATERIAL	SM : ARENA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m





GEOTECNIA &
INGENIERIA S.A.C.



Msc. Ing. Angel Hugo Vilchez Peña
INSTRUMENTISTA TECNICO - GIP-64442

RESULTADOS DEL ENSAYO



	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	20.968	20.968	20.968	
HUMEDAD FINAL (%)	31.200	31.200	31.200	
PESO UNITARIO (g/cm ³)	1.482	1.482	1.482	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	25.071	45.292	81.899	0.000
COHESIÓN (kPa)	6.202	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	27.590			



FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL	
FECHA DE ENSAYO	05/04/2023	C1-M1	ARENA BIEN GRADUADA	
INFORMACIÓN GENERAL				
PROPOSITO	TESIS			
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul			
PROYECTO	Mejoramiento del servicio educativo en la i.e. n° 22489 del distrito de paracas - provincia de pisco - departamento de ica			
MATERIAL	SW : ARENA BIEN GRADUADA			
SONDEO	Calicata abierta			
PROFUNDIDAD	1.5 m			
RESULTADOS DEL ENSAYO				
	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD (%)	18.900	18.900	18.900	
PESO UNITARIO (g/cm ³)	1.870	1.870	1.870	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.250	0.250	0.250	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	40.486	91.868	165.530	
COHESIÓN EFECTIVA (kPa)	0.480	OBSERVACIONES		
ÁNGULO DE FRICCIÓN EFECTIVA	40.720			



FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL	
FECHA DE ENSAYO	05/05/2023	C1-M1	ARENA MAL GRADUADA LIMOSA	
INFORMACIÓN GENERAL				
PROPOSITO	TESIS			
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul			
PROYECTO	Creacion del servicio de mejoramiento de los servicios de educación primaria en la i.e. n 36059 de huancalpi del distrito de vilca - huancavelica - huancavelica			
MATERIAL	SP-SM: ARENA MAL GRADUADA LIMOSA			
SONDEO	Calicata abierta			
PROFUNDIDAD	1.5 m			
RESULTADOS DEL ENSAYO				
	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD (%)	13.100	13.100	13.100	
PESO UNITARIO (g/cm ³)	1.850	1.850	1.850	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.250	0.250	0.250	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	49.486	91.868	165.530	
COHESIÓN EFECTIVA (kPa)	11.502	OBSERVACIONES		
ÁNGULO DE FRICCIÓN EFECTIVA	38.450			





FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	05/05/2023	C1-M2	LIMO INORGANICO

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creacion del servicio de mejoramiento de los servicios de educación primaria en la i.e. n 36059 de huancalpi del distrito de vilca - huancavelica - huancavelica
MATERIAL	ML: LIMO INORGANICO
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD (%)	20.610	20.610	20.610	
PESO UNITARIO (g/cm ³)	1.710	1.710	1.710	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.250	0.250	0.250	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	25.071	42.292	78.899	
COHESIÓN (kPa)	11.060	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	20.480			





FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	05/03/2023	C1	ARENA BIEN GRADADA LIMOSA

INFORMACIÓN GENERAL



PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación del servicio educativo del nivel inicial n° 38059 de barrios altos del distrito de ayacucho, provincia de huamanga
MATERIAL	SW - SM: ARENA BIEN GRADADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD (%)	26.400	26.400	26.400	
PESO UNITARIO (g/cm ³)	1.710	1.710	1.710	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	18.452	38.089	74.205	0.000
COHESIÓN (kPa)	0.000	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	37.419			



FECHA DE IMPRESIÓN		ID. MUESTRA		MATERIAL
FECHA DE ENSAYO	10/03/2023	C2		GRAVA MAL GRADADA ARCILLOSA
INFORMACIÓN GENERAL				
PROPOSITO	TESIS			
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul			
PROYECTO	Creación del servicio educativo del nivel inicial n° 38059 de barrios altos del distrito de ayacucho, provincia de huamanga			
MATERIAL	GP-GC: GRAVA MAL GRADADA ARCILLOSA			
SONDEO	Calicata abierta			
PROFUNDIDAD	1.5 m			
RESULTADOS DEL ENSAYO				
	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	21.212	21.212	21.212	
HUMEDAD FINAL (%)	25.700	25.700	25.700	
PESO UNITARIO (g/cm ³)	1.794	1.794	1.794	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	26.741	38.484	86.539	0.000
COHESIÓN (kPa)	1.482	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	40.302			
		 Msc. Ing. Angel Hugo Vilchez Peña INGENIERO TÉCNICO - CIP- 64442		





FECHA DE IMPRESIÓN		ID. MUESTRA		MATERIAL
FECHA DE ENSAYO	15/03/2023	C3		ARENA ARCILLOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Creación del servicio educativo del nivel inicial n° 38059 de barrios altos del distrito de ayacucho, provincia de huamanga
MATERIAL	SC : ARENA ARCILLOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	6.061	6.061	6.061	
HUMEDAD FINAL (%)	40.200	40.200	40.200	
PESO UNITARIO (g/cm ³)	1.570	1.570	1.570	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	20.722	41.789	67.988	0.000
COHESIÓN (kPa)	6.700	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	32.439			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

30/05/2023

C-1

GRAVA MAL GRADADA LIMOSA



INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Proyecto Privado en la ciudad de Andahuaylas para construcción de casas
MATERIAL	GP-GM: GRAVA MAL GRADADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

Msc. Ing. Angel Hugo Vilchez Peña
INGENIERO EN GEOTECNIA S.A.C.
INSTRUMENTAL TECNICO - CIP: 64442

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	8.065	8.065	8.065	
HUMEDAD FINAL (%)	20.800	20.800	20.800	
PESO UNITARIO (g/cm ³)	1.700	1.700	1.700	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.548	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	19.349	38.089	74.205	0.000
COHESIÓN (kPa)	0.195	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	33.028			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

28/05/2023

C-2


GRAVA LIMOSA

INFORMACIÓN GENERAL


PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Proyecto Privado en la ciudad de Andahuaylas para construccion de casas.
MATERIAL	GM: GRAVA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	21.212	21.212	21.212	
HUMEDAD FINAL (%)	24.200	24.200	24.200	
PESO UNITARIO (g/cm ³)	1.594	1.594	1.594	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.202	0.548	0.548	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	26.741	38.484	72.082	0.000
COHESIÓN (kPa)	1.420	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	32.403			



GEOTECNIA & INGENIERIA S.A.C.
Msc. Ing. Angel Hugo Vilchez Peña
CONSABLE TÉCNICO - CIP 64442





FECHA DE IMPRESIÓN		ID. MUESTRA		MATERIAL
FECHA DE ENSAYO	28/05/2023	C-3		GRAVA LIMOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Proyecto Privado en la ciudad de Andahuaylas para construccion de casas.
MATERIAL	GM: GRAVA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	6.061	6.061	6.061	
HUMEDAD FINAL (%)	24.200	24.200	24.200	
PESO UNITARIO (g/cm ³)	1.570	1.570	1.570	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	20.722	41.789	67.988	0.000
COHESIÓN (kPa)	6.700	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	32.439			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

27/05/2023

C-4



GRAVA BIEN GRADADA LIMOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Proyecto Privado en la ciudad de Andahuaylas para construccion de casas.
MATERIAL	GW-GM: GRAVA BIEN GRADADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD INICIAL (%)	8.065	8.065	8.065	
HUMEDAD FINAL (%)	31.020	31.020	31.020	
GRADO SATURACIÓN (%)				
PESO UNITARIO (g/cm ³)	1.503	1.503	1.503	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.250	0.250	0.250	
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	
ESFUERZO DE CORTE (kPa)	18.092	35.277	70.406	
COHESIÓN (kPa)	0.106	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	35.813			



**GEOTECNIA &
INGENIERIA S.A.C.**

Msc. Ing. Angel Hugo Vilchez Peña

CONSABLE TECNICO - CIP 64442

FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

25/05/2023

C-5



GRAVA BIEN GRADADA LIMOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon paul
PROYECTO	Proyecto Privado en la ciudad de Andahuaylas para construccion de casas.
MATERIAL	GW-GM: GRAVA BIEN GRADADA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	8.065	8.065	8.065	
HUMEDAD FINAL (%)	32.100	32.100	32.100	
PESO UNITARIO (g/cm ³)	1.503	1.503	1.503	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	23.884	36.327	71.135	0.000
COHESIÓN (kPa)	5.520	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	33.457			



FECHA DE IMPRESIÓN

ID. MUESTRA

MATERIAL

FECHA DE ENSAYO

25/11/2023

ZONA 2

GRAVA BIEN GRADADA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul
PROYECTO	Proyecto Privado en la ciudad de Andahuaylas para construccion de una vivienda.
MATERIAL	GW: GRAVA BIEN GRADADA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m



RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)				
HUMEDAD FINAL (%)	16.400	16.400	16.400	
PESO UNITARIO (g/cm ³)	1.790	1.790	1.790	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	35.030	69.660	135.242	0.000
COHESIÓN (kPa)	0.408	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	34.800			





GEOTECNIA &
INGENIERIA S.A.C.

Msc. Ing. Angel Hugo Vilchez Peña
INGENIERO TÉCNICO - CIP: 64442





FECHA DE IMPRESIÓN		ID. MUESTRA		MATERIAL
FECHA DE ENSAYO	28/11/2023	ZONA 1		ARENA MAL GRADADA
INFORMACIÓN GENERAL				
PROPOSITO	TESIS			
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul			
PROYECTO	Proyecto Privado en la ciudad de Andahuaylas para construccion de una vivienda.			
MATERIAL	SP: ARENA MAL GRADADA			
SONDEO	Calicata abierta			
PROFUNDIDAD	1.5 m			

RESULTADOS DEL ENSAYO				
	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD INICIAL (%)	13.835	13.835	13.835	
HUMEDAD FINAL (%)	16.700	16.700	16.700	
PESO UNITARIO (g/cm ³)	1.730	1.730	1.730	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	0.000
ESFUERZO DE CORTE (kPa)	31.132	63.449	139.824	0.000
COHESIÓN EFECTIVA (kPa)	0.804	OBSERVACIONES		
ÁNGULO DE FRICCIÓN EFECTIVA	33.704			



FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL	
FECHA DE ENSAYO	04/06/2023	C 01	ARENA LIMOSA	
INFORMACIÓN GENERAL				
PROPOSITO	TESIS			
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul			
PROYECTO	Mejoramiento de la carretera con asfalto tramo centro poblado de carmen alto-yanama, del distrito de carmenalto provincia de huamanga.			
MATERIAL	SM: ARENA LIMOSA			
SONDEO	Calicata abierta			
PROFUNDIDAD	1.5 m			
RESULTADOS DEL ENSAYO				
	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD (%)	29.600	29.600	29.600	
PESO UNITARIO (g/cm ³)	1.680	1.680	1.680	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	20.722	41.789	67.988	0.000
COHESIÓN EFECTIVA (kPa)	9.024	OBSERVACIONES		
ÁNGULO DE FRICCIÓN EFECTIVA	32.439			



FECHA DE IMPRESIÓN		ID. MUESTRA		MATERIAL
FECHA DE ENSAYO	12/06/2023	C 02		GRAVA BIEN GRADADA CON ARCILLA



INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul
PROYECTO	Construcción de cobertura de la institución deportiva en la I.E.S San Luis Gonzaga en la localidad de Conayre y Villa Progreso en Distrito de Conayre-Huanta-Ayacucho
MATERIAL	GW-GC: GRAVA BIEN GRADADA CON ARCILLA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	0.000
HUMEDAD (%)	27.600	27.600	27.600	
PESO UNITARIO (g/cm ³)	1.770	1.770	1.770	0.000
ÁREA (mm ²)	2026.828	2026.828	2026.828	0.000
VELOCIDAD (mm/min)	0.250	0.250	0.250	0.000
ESFUERZO NORMAL (kPa)	25.644	49.836	98.220	0.000
ESFUERZO DE CORTE (kPa)	23.452	38.089	72.205	0.000
COHESIÓN (kPa)	2.005	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	31.704			

GEOTECNIA & INGENIERIA S.A.C.
Msc. Ing. Angel Hugo Vilchez Peña
CONSULE TECNICO - CIP-64442





FECHA DE IMPRESIÓN		ID. MUESTRA	MATERIAL
FECHA DE ENSAYO	04/06/2023	C 03	GRAVA LIMOSA

INFORMACIÓN GENERAL

PROPOSITO	TESIS
CLIENTE	Bach. Huaccachi Pumallihua Jhon Paul
PROYECTO	Construcción de cobertura de la institución deportiva en la I.E.S San Luis Gonzaga en la localidad de Conayre y Villa Progreso en Distrito de Conayre-Huanta-Ayacucho
MATERIAL	GM: GRAVA LIMOSA
SONDEO	Calicata abierta
PROFUNDIDAD	1.5 m

RESULTADOS DEL ENSAYO

	ÍTEM 1	ÍTEM 2	ÍTEM 3	ÍTEM 4
DIÁMETRO ó LADO (mm)	50.800	50.800	50.800	
HUMEDAD (%)	32.500	32.500	32.500	
PESO UNITARIO (g/cm ³)	1.680	1.680	1.680	
ÁREA (mm ²)	2026.828	2026.828	2026.828	
VELOCIDAD (mm/min)	0.250	0.250	0.250	
ESFUERZO NORMAL (kPa)	49.836	98.220	194.988	
ESFUERZO DE CORTE (kPa)	31.132	63.449	119.824	
COHESIÓN (kPa)	1.373	OBSERVACIONES		
ÁNGULO DE FRICCIÓN	30.964			





ACTA DE SUSTENTACIÓN DE TESIS N° 068-2024-FIMGC

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO CIVIL

En la Universidad Nacional de San Cristóbal de Huamanga de la ciudad de Ayacucho, en cumplimiento a la **Resolución Decanal N° 615-2024-FIMGC-D**, a los diecinueve días del mes de setiembre de 2024, siendo las 10:00 a.m, reunidos en el Auditorio de la Escuela Profesional de Ingeniería Civil, bajo la presidencia del MSc. Ing. Javier Francisco TAIPE CARBAJAL y los miembros; MSc. Ing. José Ernesto ESTRADA CÁRDENAS, MSc. Ing. Ángel Hugo VILCHEZ PEÑA y MSc. Ing. Hemerson LIZARBE ALARCÓN, actuando como secretario docente el MSc. Ing. Kelvis BERROCAL ARGUMEDO, para proceder a la sustentación de tesis para optar el Título Profesional de Ingeniero Civil, del bachiller en Ciencias de la Ingeniería Civil:

Jhon Paul HUACCACHI PUMALLIHUA


Quien presentó la tesis denominada:

Eficacia en la predicción de los parámetros de resistencia al corte a partir del comportamiento físico en suelos granulares empleando redes neuronales artificiales-experimental, Perú 2023

Los señores miembros del jurado luego de expuesto la tesis y absueltas las preguntas, delibera y lo declaran:

APROBADO CON NOTA DIECISÉIS (16)

Siendo las 11:30 a.m. del día 19 de setiembre de 2024, culmina el acto de sustentación de tesis, y en conformidad a lo actuado los miembros del jurado firmamos al pie del presente.



MSc. Ing. Javier Francisco TAIPE CARBAJAL
Presidente



MSc. Ing. José Ernesto ESTRADA CÁRDENAS
Miembro



MSc. Ing. Hemerson LIZARBE ALARCÓN
Miembro



MSc. Ing. Ángel Hugo VILCHEZ PEÑA
Miembro- Asesor



MSc. Ing. Kelvis BERROCAL ARGUMEDO
Secretario docente de la FIMGC

cc:
Archivo

**UNSCH**FACULTAD DE
INGENIERÍA
DE MINAS, GEOLOGÍA Y CIVIL

"Año del Bicentenario, de la consolidación de nuestra Independencia, y de la conmemoración de las heroicas batallas de Junín y Ayacucho"

CONSTANCIA DE ORIGINALIDAD DE TRABAJO DE INVESTIGACIÓN

CONSTANCIA N° 125-2024-FIMGC/ASIH


El que suscribe; responsable verificador de originalidad de trabajos de tesis de pregrado con el software Turnitin, de la Escuela Profesional de **Ingeniería Civil** de la **Facultad de Ingeniería de Minas, Geología y Civil**; en cumplimiento a la **Resolución de Consejo Universitario N° 039-2021-UNSCH-CU**, Reglamento de Originalidad de Trabajos de Investigación de la Universidad Nacional San Cristóbal de Huamanga y **Resolución Decanal N° 476-2023-FIMGC-UNSCH-D**, deja constancia de originalidad de trabajo de investigación, que el/la Sr./Srta.

Apellidos y Nombres : JHON PAUL HUACCACHI PUMALLIHUA
Escuela Profesional : INGENIERÍA CIVIL
Título de la Tesis : EFICACIA EN LA PREDICCIÓN DE LOS PARÁMETROS DE RESISTENCIA AL CORTE A PARTIR DEL COMPORTAMIENTO FÍSICO EN SUELOS GRANULARES EMPLEANDO REDES NEURONALES ARTIFICIALES-EXPERIMENTAL, PERÚ 2023
Evaluación de la Originalidad : 9 % Índice de Similitud
Identificador de la entrega : 2526358606

Por tanto, según los Artículos 12, 13 y 17 del Reglamento de Originalidad de Trabajos de Investigación, es **PROCEDENTE** otorgar la **Constancia de Originalidad** para los fines que crea conveniente.

En señal de conformidad y verificación se firma la presente constancia

Ayacucho, 20 de noviembre del 2024


UNIVERSIDAD NACIONAL DE
SAN CRISTÓBAL DE HUAMANGA
Facultad de Ingeniería de Minas, Geología y Civil
Msc. Ing. Alex Sander IRCAÑAUPA HUAMANI
Verificador de Originalidad de Trabajos de Tesis de Pregrado
Escuela de Formación Profesional de Ingeniería Civil

Con depósito para Sustentación y Trámites
Cc. Archivo.

FACULTAD DE INGENIERÍA DE MINAS, GEOLOGÍA Y CIVIL
Av. Independencia S/N Ciudad Universitaria
Central Tel. 066 312510
Anexo 151

EFICACIA EN LA PREDICCIÓN DE LOS PARÁMETROS DE RESISTENCIA AL CORTE A PARTIR DEL COMPORTAMIENTO FÍSICO EN SUELOS GRANULARES EMPLEANDO REDES NEURONALES ARTIFICIALES- EXPERIMENTAL, PERÚ 2023

por Jhon Paul HUACCACHI PUMALLIHUA

Fecha de entrega: 20-nov-2024 12:03p.m. (UTC-0500)

Identificador de la entrega: 2526358606

Nombre del archivo: TE_JHON_PAUL_HUACCACHI_PUMALLIHUA.pdf (10.89M)

Total de palabras: 141859

Total de caracteres: 515486

EFICACIA EN LA PREDICCIÓN DE LOS PARÁMETROS DE RESISTENCIA AL CORTE A PARTIR DEL COMPORTAMIENTO FÍSICO EN SUELOS GRANULARES EMPLEANDO REDES NEURONALES ARTIFICIALES-EXPERIMENTAL, PERÚ 2023

INFORME DE ORIGINALIDAD

9%

INDICE DE SIMILITUD

0%

FUENTES DE INTERNET

6%

PUBLICACIONES

4%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

Submitted to Universidad Nacional de San
Cristóbal de Huamanga

Trabajo del estudiante

3%

2

Paredes Ceron, Andrea Carolina. "Evaluacion
experimental del efecto de la compactacion
en la resistencia a corto plazo de arena
limosa (SM) A-2-4 (PR-108)", Proquest,
20111108

Publicación

2%

3

Submitted to Universidad Continental

Trabajo del estudiante

1%

4

Cabezas Gonzalez, Rodolfo Enrique.
"Modelacion Numerica Del Comportamiento
Mecanico De Lastres Mineros.", Pontificia
Universidad Catolica de Chile (Chile), 2021

Publicación

1%

5

#N/A. "Informe de Gestión Ambiental para el Mejoramiento del Servicio de Agua para Riego en las Comunidades de Ancahuasi, San Martín, Chamanquilla, San Rafael, Chaquilcasa-IGA0020201", R.D.G. N° 078-2018-MIDAGRI-DVDIAR-DGAAA, 2022

Publicación

<1 %

6

CONSULRORIA CARRANZA E.I.R.L.. "PMA del Proyecto de Construcción y Funcionamiento de la Base de Operaciones Kiteni-IGA0005729", R.D. N° 47-2010-MEM/AEE, 2020

Publicación

<1 %

7

Vicente Eduardo Capa Guachón. "Estudio experimental y numérico del comportamiento de excavaciones ejecutadas mediante la técnica de suelo claveteado (soil nailing) en suelos de la ciudad de Quito (Ecuador).", Universitat Politècnica de València, 2021

Publicación

<1 %

8

HERRERA VILLAVICENCIO JUVENAL. "Programa de Reconversión y Manejo de Áreas Degradadas del Proyecto Construcción del Relleno Sanitario de Echarati - Cercado - Provincia de La Convención - Cusco, Componentes 4B, 4C y 4D-IGA0013661", R.G.R.N.G.A. N° 017-2020-GRNGA-MPLC, 2021

Publicación

<1 %

9

Das, Braja. "Soil Mechanics Laboratory Manual", Soil Mechanics Laboratory Manual, 2022

Publicación

<1 %

10

Rodriguez, Yam. "Geotechnical characterization of fly ash and bottom ash from AES, Puerto Rico", Proquest, 2014.

Publicación

<1 %

11

ANDRADE CAYCHO EDGAR. "EIA-SD del Proyecto Infraestructura de Disposición Final de Residuos Sólidos No Municipales y Municipales Yacucatina - San Martín-IGA0000038", R.D. N° 1485-2015/DEPA/DIGESA/SA, 2020

Publicación

<1 %

12

KNIGHT PIESOLD CONSULTORES S.A.. "EIA del Proyecto Constancia-IGA0000697", R.D. N° 390-2010-MEM-AAM, 2020

Publicación

<1 %

13

[documentop.com](https://documenttop.com)

Fuente de Internet

<1 %

14

Moreno Rondoy, Rita Clara. "Evaluación de riesgos en la estabilidad de taludes de la Costa Verde", Pontificia Universidad Catolica del Peru (Peru), 2023

Publicación

<1 %

15

Mehdi Ghayoumi. "Deep Learning in Practice",
CRC Press, 2021

Publicación

<1 %

16

Mori, Sylvia Daniela Cayetano. "La aplicacion
Del Control Simultaneo Permite La Ejecucion
Efectiva De Los Proyectos De Saneamiento
Incluidos o No En El: Pmo De Las Eps, Para
Brindar Los Servicios De Agua y Alcantarillado
En El ambito Urbano, En El Periodo 2014 -
2019.", Pontificia Universidad Catolica del
Peru - CENTRUM Catolica (Peru), 2021

Publicación

<1 %

Excluir citas

Activo

Excluir coincidencias < 30 words

Excluir bibliografía

Activo