



**UNIVERSIDAD ANDINA**  
**NÉSTOR CÁCERES VELÁSQUEZ**  
**ESCUELA DE POSGRADO**  
**MAESTRÍA EN INGENIERÍA CIVIL**  
**MENCIÓN: GEOTECNIA Y TRANSPORTES**



**CLASIFICACIÓN DE SUELOS UTILIZANDO REDES  
NEURONALES ARTIFICIALES PARA SU  
USO EN EL DISEÑO DE BLOQUES  
DE TIERRA COMPRIMIDOS**

**TESIS PRESENTADA POR:**  
**RUBEN FITZGERALD SOSA AQUISE**

**PARA OPTAR EL GRADO ACADÉMICO DE:**  
**MAGISTER EN INGENIERIA CIVIL**  
**MENCIÓN: GEOTECNIA Y TRANSPORTES**

**JULIACA - PERÚ**  
**2024**



**UNIVERSIDAD ANDINA**  
**NÉSTOR CÁCERES VELÁSQUEZ**  
**ESCUELA DE POSGRADO**  
**MAESTRÍA EN INGENIERÍA CIVIL**  
**MENCIÓN: GEOTECNIA Y TRANSPORTES**

**CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS**

**TESIS PRESENTADA POR:**  
**RUBEN FITZGERALD SOSA AQUISE**  
**PARA OPTAR EL GRADO ACADÉMICO DE:**  
**MAGISTER EN INGENIERÍA CIVIL**

**APROBADA POR:**

**PRESIDENTE DEL JURADO**

  
: \_\_\_\_\_  
Dr. OSCAR VICENTE VIAMONTE CALLA

**MIEMBRO DEL JURADO**

  
: \_\_\_\_\_  
Dr. LEONEL SUASACA PELINCO

**MIEMBRO DEL JURADO**

  
: \_\_\_\_\_  
Mgtr. ARNALDO YANA TORRES

**ASESOR DE TESIS**

  
: \_\_\_\_\_  
Dr. RICHARD CONDORI CRUZ

**LÍNEA DE INVESTIGACIÓN**

: TECNOLOGÍA DE LA CONSTRUCCIÓN – P50



# UNIVERSIDAD ANDINA "NÉSTOR CÁCERES VELÁSQUEZ" ESCUELA DE POSGRADO



## RESOLUCIÓN DIRECTORAL N° 613-2024-D-EPG-UANCV/J

Martes, 24 de diciembre del 2024

**VISTOS:**

El expediente N° 2024-014584, presentado por el (la) Bachiller **SOSA AQUISE RUBEN FITZGERALD**, con número de DNI. **01342989**, asignado (a) con código de matrícula **25129027**, de la **Maestría en INGENIERIA CIVIL, Mención: GEOTECNIA Y TRANSPORTES**, de la Escuela de Posgrado de la Universidad Andina "Néstor Cáceres Velásquez" de la Sede Central Juliaca.

**CONSIDERANDO:**

Que, el (a) Bach. **SOSA AQUISE RUBEN FITZGERALD**, con número de DNI. **01342989**, asignado (a) con código de matrícula **25129027**, de la **Maestría en INGENIERIA CIVIL, Mención: GEOTECNIA Y TRANSPORTES**, ha solicitado fecha, hora y modalidad de sustentación de la Tesis titulada: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS** La misma que pertenece a la Línea de Investigación: **TECNOLOGÍA DE LA CONSTRUCCIÓN - P50** y;

Que, el (a) referido (a) Dictamen de Tesis aprobado por los jurados el 02 de setiembre del 2024. Establece la fecha de sustentación; habiendo para el efecto cumplido los requisitos establecidos en el reglamento para la Obtención del Grado Académico de Magíster/Maestro y Doctor de la Escuela de Posgrado de la UANCV;

Que, en el Artículo 66 del Reglamento General de la Escuela de Posgrado de la UANCV, establece que la sustentación de Tesis de Postgrado es un trabajo de investigación original y crítico, de actualidad y de alto valor científico;

En uso de las atribuciones conferidas a la Dirección en el inciso "J" del artículo 17° del Reglamento General de la Escuela de Posgrado, y el Art. 76 del Estatuto Universitario;

**SE RESUELVE:**

**ARTÍCULO PRIMERO. - DECLARAR EXPEDITO** para la Sustentación de la Tesis titulada: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS** Elaborado por el (la) Bachiller **SOSA AQUISE RUBEN FITZGERALD**. Integrado por los siguientes docentes:

- Presidente del Jurado** : **Dr. OSCAR VICENTE VIAMONTE CALLA**
- Miembro del Jurado** : **Dr. LEONEL SUASACA PELINCO**
- Miembro del Jurado** : **Dr. ARNALDO YANA TORRES**
- Asesor de Tesis** : **Dr. RICHARD CONDORI CRUZ**

**ARTÍCULO SEGUNDO. -** El proceso de la Sustentación de la Tesis en mención, se llevará a cabo:

- Fecha** : **Lunes 30 de diciembre del 2024**
- Hora** : **02:00 p.m.**
- Lugar** : **Aula N° 310 EPG - UANCV - JULIACA**

A cuya finalización el Jurado registrará los resultados en el Libro de Actas de Sustentación de Tesis de Maestría con el grado **MAGISTER** de los estudiantes que ingresaron antes a la aprobación de la ley Universitaria N° 30220.

**ARTÍCULO TERCERO. -** Elévese la presente Resolución al Rectorado, Vicerrectorado Académico, Vicerrectorado Administrativo y Oficina del Órgano de Inspección y Control para conocimiento.

Regístrese, comuníquese y Archívese.



UNIVERSIDAD ANDINA "NÉSTOR CÁCERES VELÁSQUEZ"  
ESCUELA DE POSGRADO

Dr. Leopoldo Wenceslao Condori Cari  
DIRECTOR (a)

Ce./Archiv.EPG (01)  
Interesado (01)  
Cargo (01)  
Jurado (02)  
Asesor (01)  
Expediente (01)  
UANCV/



**UNIVERSIDAD ANDINA**  
**"NÉSTOR CÁCERES VELÁSQUEZ"**  
**ESCUELA DE POSGRADO**



**RESOLUCIÓN DIRECTORAL N° 2273-2024-USA-EPG/UANCV**

Juliaca, 16 de Diciembre del 2024

**VISTOS:**

El expediente N°. 0941, Presentado por el (a) Bach. **RUBEN FITZGERALD SOSA AQUISE**, con número de DNI **01342989** y con Código de matrícula N.° **25129027**, quien solicita cambio del presidente del jurado del Proyecto de Tesis titulado: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS** Líneas de Investigación: **TECNOLOGÍA DE LA CONSTRUCCIÓN – P50**, Para optar el Grado Académico de **MAGISTER** en **INGENIERÍA CIVIL** mención: **GEOTECNIA Y TRANSPORTES** de la Escuela de Posgrado de la Universidad Andina "Néstor Cáceres Velásquez", de la Sede Central Juliaca.

**CONSIDERANDO:**

Que, mediante expediente No. 0941, el Bach. **RUBEN FITZGERALD SOSA AQUISE**, solicita cambio del **presidente del jurado** de la tesis titulada: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS**. Aprobado con Resolución Directoral N.° 322-2020-USA-EPG/UANCV, de fecha 29 de Setiembre del 2020, en el que se le asignó como presidente del jurado al Dr. Ronald Madera Teran, el mismo que se cambia por indisponibilidad de tiempo.

Que, el referido Dictamen de Tesis fue aprobado por los jurados el 16 de Marzo del 2020, registrado en el Folio N° 1998 del Libro de Registro de Proyectos de Investigación de Maestría, establece que se encuentra apto para ser desarrollado a lo establecido en el reglamento de Grado de Investigación conducente al Grado Académico de Magister/Maestro y Doctor de la Escuela de Posgrado de la Universidad Andina "Néstor Cáceres Velásquez" de Juliaca;

Que, en el Reglamento General de la escuela de Posgrado de la UANCV, establece que la sustentación de Tesis de Posgrado es un trabajo de investigación original y crítico de actualidad y de alto valor científico.

En uso de las atribuciones conferidas a la Dirección en el inciso "j" del artículo 17 del Reglamento General de la Escuela de Posgrado, y el Art. 76 del Estatuto Universitario;

**SE RESUELVE:**

**PRIMERO.- ACEPTAR EL CAMBIO DEL PRESIDENTE DEL JURADO**, para su revisión de la Tesis titulada: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS** presentado por el (a) Bach. **RUBEN FITZGERALD SOSA AQUISE**, de la maestría en: **INGENIERÍA CIVIL**, conformado por los siguientes docentes:

- Presidente** : Dr. **OSCAR VICENTE VIAMONTE CALLA**
- Primer Miembro** : Dr. **LEONEL SUASACA PELINCO**
- Segundo Miembro** : Dr. **ARNALDO YANA TORRES**
- Asesor** : Dr. **RICHARD CONDORI CRUZ**

**SEGUNDO- AUTORIZAR** el desarrollo de Tesis, de acuerdo al Reglamento de Investigación conducente al Grado Académico de **MAGISTER** de la Escuela de Posgrado de la Universidad Andina Néstor Cáceres Velásquez.

**TERCERO.- ELEVAR** al Rectorado, Vicerrectorado Académico, Vicerrectorado Administrativo y Oficina del Órgano de Inspección y Control para conocimiento, así como a la Oficina de Economía, para cumplimiento de la presente Resolución.

Regístrese, Comuníquese y Archívese,



Universidad Andina "Néstor Cáceres Velásquez"  
ESCUELA DE POSGRADO  
Dr. Leopoldo Weneestevo Condori Cari  
DIRECTOR (e)



**RESOLUCIÓN DIRECTORAL N° 0358-2024-USA-EPG/UANCV**

Juliaca, 29 de Abril del 2024

**VISTOS:**

El expediente N°. 04750, Presentado por el (a) Bach. **RUBEN FITZGERALD SOSA AQUISE**, con número de DNI **01342989** y con Código de matrícula N.° **25129027**, quien solicita cambio de **segundo miembro y asesor** del Proyecto de Tesis titulada: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS** líneas de investigación: **TECNOLOGÍA DE LA CONSTRUCCIÓN - P50**. Para optar el Grado Académico de **MAGISTER en INGENIERÍA CIVIL** mención: **GEOTECNIA Y TRANSPORTE** de la Escuela de Posgrado de la Universidad Andina "Néstor Cáceres Velásquez", de la Sede Central Juliaca.

**CONSIDERANDO:**

Que, mediante expediente No. 04750, el Bach. **RUBEN FITZGERALD SOSA AQUISE**, solicita cambio del **SEGUNDO MIEMBRO DEL JURADO Y ASESOR** de la tesis titulada: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS**. Aprobado con Resolución Directoral N.° 322-2020-USA-EPG/UANCV, de fecha 29 de Setiembre del 2020, en el que se le asignó como primer miembro del jurado al Dr. Víctor Julio Huamán Meza, asesor al Mgr. Ruben Alcides Quella Huancá, los mismos que se cambia por no tener vínculo laboral con la UANCV.

Que, el referido Dictamen de Tesis fue aprobado por los jurados el 16 de Marzo del 2020, registrado en el Fofo N° 1998 del Libro de Registro de Proyectos de Investigación de Maestría, establece que se encuentra apto para ser desarrollado a lo establecido en el reglamento de Grado de Investigación conducente al Grado Académico de Magister/Maestro y Doctor de la Escuela de Posgrado de la Universidad Andina "Néstor Cáceres Velásquez" de Juliaca;

Que, en el Reglamento General de la escuela de Posgrado de la UANCV, establece que la sustentación de Tesis de Posgrado es un trabajo de investigación original y crítico de actualidad y de alto valor científico.

En uso de las atribuciones conferidas a la Dirección en el inciso "j" del artículo 17 del Reglamento General de la Escuela de Posgrado, y el Art. 76 del Estatuto Universitario;

**SE RESUELVE:**

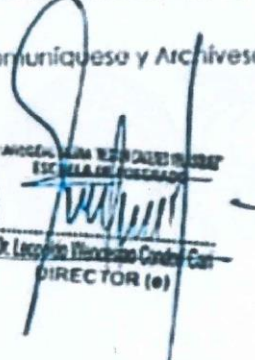
**PRIMERO.- ACEPTAR EL CAMBIO DEL SEGUNDO MIEMBRO DEL JURADO Y ASESOR**, para su revisión de la Tesis titulada: **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS** presentado por el (a) Bach. **RUBEN FITZGERALD SOSA AQUISE**, de la maestría en: **INGENIERÍA CIVIL**; conformado por los siguientes docentes:

- Presidente** : Dr. **RONALD MADERA TERAN**
- Primer Miembro** : Dr. **LEONEL SUASACA PELINCO**
- Segundo Miembro** : Mgr. **ARNALDO YANA TORRES**
- Asesor** : Dr. **RICHARD CONDORI CRUZ**

**SEGUNDO- AUTORIZAR** el desarrollo de Tesis, de acuerdo al Reglamento de Investigación conducente al Grado Académico de **MAGISTER** de la Escuela de Posgrado de la Universidad Andina Néstor Cáceres Velásquez.

**TERCERO.- ELEVAR** al Rectorado, Vicerrectorado Académico, Vicerrectorado Administrativo y Oficina del Órgano de Inspección y Control para conocimiento, así como a la Oficina de Economía, para cumplimiento de la presente Resolución.

Regístrese, Comuníquese y Archívese

  
**Dr. Leonardo Francisco Condori Cruz**  
 DIRECTOR (e)



DE CARGO (e)  
ARCHIVO (e) N° 0358-2024-USA-EPG  
INTERESADO (e)  
LAW00000000



**RESOLUCIÓN DIRECTORAL N° 322 - 2020-USA-EPG/UANCV**

Juliaca, 29 de setiembre del 2020.

**VISTOS:**

El Registro N° 1998 del Libro de Registro de Proyectos de Investigación de Tesis de la MAESTRIA en INGENIERÍA CIVIL mención en GEOTECNIA Y TRANSPORTE, del Jurado revisor del Proyecto de Tesis: CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS. Línea de Investigación: TECNOLOGÍA DE LA CONSTRUCCIÓN- P50. Presentado por el (a) Bach. SOSA AQUISE RUBEN FITZGERALD con número de DNI N° 01342989 y con Código de matrícula N° 25129027, para optar el Grado Académico de MAGISTER en INGENIERÍA CIVIL mención en GEOTECNIA Y TRANSPORTE, de la Escuela de Posgrado de la Universidad Andina Néstor Cáceres Velásquez de Juliaca.

**CONSIDERANDO:**

Que, el (a) Bach. SOSA AQUISE RUBEN FITZGERALD, para optar el Grado Académico de MAGISTER en INGENIERÍA CIVIL mención en GEOTECNIA Y TRANSPORTE, de la Escuela de Posgrado ha presentado el Dictamen de Proyecto de Investigación de tesis CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS.. Línea de Investigación: TECNOLOGÍA DE LA CONSTRUCCIÓN- P50. Presentado por el (a) Bach. SOSA AQUISE RUBEN FITZGERALD, para ser registrada en el Libro de Actas de Proyectos de Tesis

Que, el referido Dictamen de Tesis aprobado por los jurados el 16 de marzo del 2020, se ha registrado en el Folio N° 1998 del Libro de Registro de Proyectos de Investigación de Maestrías, establece que se encuentra apto para ser desarrollado a lo establecido en el reglamento de Grado de Investigación conducente al Grado Académico de Magister y Doctor de la Escuela de Posgrado de la UANCV.

Que, en el Reglamento General de la escuela de Posgrado de la UANCV, establece que la sustentación de Tesis de Posgrado es un trabajo de investigación original y critico de actualidad y de alto valor científico

En uso de las atribuciones conferidas a la Dirección en el inciso "h" del artículo 15 del Reglamento General de la Escuela de Posgrado y el Art. 74 del Estatuto Universitario.

**SE RESUELVE:**

**PRIMERO.- APROBAR el PROYECTO DE INVESTIGACIÓN DE TESIS DE MAESTRIA, Titulado CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS. Línea de Investigación: TECNOLOGÍA DE LA CONSTRUCCIÓN- P50. Presentado por el (a) Bach. SOSA AQUISE RUBEN FITZGERALD con número de DNI N° 01342989 y con Código de matrícula N° 25129027, para optar el Grado Académico de MAGISTER en INGENIERÍA CIVIL mención en GEOTECNIA Y TRANSPORTE, y Siendo Asesorado por el (a) Mgtr. QUELLO HUANCA RUBEN ALCIDES, y según Acta de Sorteo, la terna de Jurados son los siguientes docentes**

- Presidente : Dr. MADERA TERAN RONALD
- Primer Miembro : Dr. HUAMAN MEZA VICTOR JULIO
- Segundo Miembro : Mgtr. YANA TORRES, ARNALDO

**SEGUNDO.- AUTORIZAR el desarrollo de Tesis, de acuerdo al Reglamento de Investigación conducente al Grado Académico de MAGISTER de la Escuela de Posgrado**

**TERCERO.- ELEVAR al Rectorado, Vicerrectorado Académico, Vicerrectorado Administrativo y Oficina del Órgano de Inspección y Control para conocimiento, así como a la Oficina de Economía, para cumplimiento de la presente Resolución.**

Regístrese, Comuníquese y Archívese

De: CAP93/01  
Asunto: C.EPG - 2020/021  
A: TERCERADO/01  
C. M. (s/n)



UNIVERSIDAD NÉSTOR CÁCERES VELÁSQUEZ  
ESCUELA DE POSGRADO

Dr. David I. Gutiérrez Mayta  
DIRECTOR (o)



UNIVERSIDAD NÉSTOR CÁCERES VELÁSQUEZ  
ESCUELA DE POSGRADO

Mg. Enrique G. Apaza Chirinos  
SECRETARIO ACADÉMICO



## CLASIFICACIÓN DE SUELOS UTILIZANDO RED NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS

### INFORME DE ORIGINALIDAD

14%

INDICE DE SIMILITUD

12%

FUENTES DE INTERNET

6%

PUBLICACIONES

6%

TRABAJOS DEL ESTUDIANTE

### FUENTES PRIMARIAS

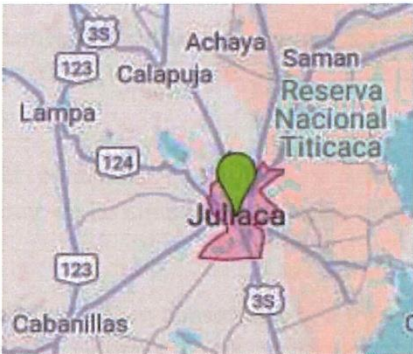
1	Submitted to Universidad Andina Nestor Caceres Velasquez Trabajo del estudiante	2%
2	<a href="http://hdl.handle.net">hdl.handle.net</a> Fuente de Internet	1%
3	<a href="http://repositorio.uancv.edu.pe">repositorio.uancv.edu.pe</a> Fuente de Internet	1%
4	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	1%
5	<a href="http://www.ptolomeo.unam.mx:8080">www.ptolomeo.unam.mx:8080</a> Fuente de Internet	1%
6	<a href="http://repositorio.unap.edu.pe">repositorio.unap.edu.pe</a> Fuente de Internet	1%
7	<a href="http://www.coursehero.com">www.coursehero.com</a> Fuente de Internet	<1%



**Metadatos complementarios – UANCV**

<b>TITULO DE LA TESIS</b>	
<b>CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS</b>	
<b>Datos de autor</b>	
Nombres y apellidos	RUBEN FITZGERALD SOSA AQUISE
Tipo de documento de identidad	DNI
Número de documento de identidad	01342989
URL de ORCID	<a href="https://orcid.org/0000-0003-1058-8285">https://orcid.org/0000-0003-1058-8285</a>
<b>Datos de asesor</b>	
Nombres y apellidos	RICHARD CONDORI CRUZ
Tipo de documento de identidad	DNI
Numero de documento de identidad	02442917
URL de ORCID	<a href="https://orcid.org/0000-0003-2566-3735">https://orcid.org/0000-0003-2566-3735</a>
<b>Datos del jurado</b>	
<b>Presidente del jurado</b>	
Nombres y apellidos	OSCAR VICENTE VIAMONTE CALLA
Tipo de documento	DNI
Numero de documento de identidad	02371550
<b>Miembro Del Jurado 1</b>	
Nombres y apellidos	LEONEL SUASACA PELINCO
Tipo de documento	DNI
Numero de documento de identidad	40865558
<b>Miembro Del Jurado 2</b>	
Nombres y apellidos	ARNALDO YANA TORRES
Tipo de documento	DNI
Numero de documento de identidad	41414676



Datos de investigación	
Línea de investigación	TECNOLOGÍA DE LA CONSTRUCCIÓN – P50
Grupo de investigación	No aplica
Agencia de financiamiento	Sin Financiamiento
Ubicación geográfica de la investigación	<p><b>País:</b> Perú</p> <p><b>Departamento:</b> Puno</p> <p><b>Provincia:</b> San Román</p> <p><b>Provincia:</b> Juliaca</p> <p><b>Coordenadas:</b></p> <p><b>Latitud:</b> -15.485868,</p> <p><b>Longitud:</b> -70.108447</p> <p><b>URL maps:</b></p> <p><a href="https://tinyurl.com/2c5ezqtn">https://tinyurl.com/2c5ezqtn</a></p> 
Año o rango de años en que se realizó la investigación	29 setiembre 2020 – 24 diciembre 2024
URL de disciplinas OCDE	<p><b>Ingeniería Civil</b></p> <p><a href="https://purl.org/pe-repo/ocde/ford#2.01.01">https://purl.org/pe-repo/ocde/ford#2.01.01</a></p> <p><b>Ingeniería de la construcción</b></p> <p><a href="https://purl.org/pe-repo/ocde/ford#2.01.03">https://purl.org/pe-repo/ocde/ford#2.01.03</a></p>



UNIVERSIDAD ANDINA NESTOR CÁCERES VELÁSQUEZ  
ESCUELA DE POSTGRADO

Dr. Ramiro Amílcar Bolaños Calderon  
DIRECTOR  
DE INVESTIGACIÓN - EPG



### DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD

Yo: **Rubèn Fitzgerald Sosa Aquise**, identificado con DNI Nro. 01342989 en mi condición de egresado del Programa de maestría en ingeniería civil,

Informo que he elaborado la Tesis denominada:

**“CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS”**

Asesorado por: **Dr. RICHARD CONDORI CRUZ.**

Este es un tema original por lo que:

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

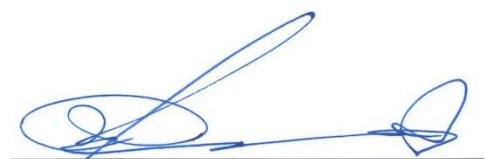
Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

El incumplimiento de lo declarado da lugar a responsabilidad del declarante, en consecuencia; a través del presente documento asumo frente a terceros, la Universidad Andina Néstor Cáceres Velásquez y/o la Administración Pública toda responsabilidad que pueda derivarse por el trabajo final presentado. Lo señalado incluye responsabilidad pecuniaria incluido el pago de multas u otros por los daños y perjuicios que se ocasionen.

Juliaca, 20 de Abril del 2025.

  
FIRMA (ASESOR)

  
FIRMA (obligatoria)



Huella



## DEDICATORIA

A los que se fueron y que pronto volverán y a  
la familia que Dios nos dio.



### **AGRADECIMIENTO**

A Dios por su providencia, pues provee con bendición la cual no hace faltar, y a la familia como soporte absoluto en el tramo de la vida nuestra la cual recorreremos juntos.



**ÍNDICE**

**DEDICATORIA .....III**

**AGRADECIMIENTO ..... XI**

**RESUMEN ..... IX**

**ABSTRACT.....XIX**

**INTRODUCCIÓN .....XX**

**CAPÍTULO I**

**FORMULACIÓN DEL PROBLEMA**

1.1. EXPOSICIÓN DE LA SITUACIÓN PROBLEMÁTICA ..... 1

1.2. FORMULACIÓN DEL PLANTEAMIENTO DEL PROBLEMA ..... 4

    1.2.1. *Problema general* ..... 4

    1.2.1. *Problemas específicos* ..... 4

1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN ..... 5

    1.3.1. *Justificación Económica* ..... 6

    1.3.2. *Justificación Social* ..... 7

    1.3.3. *Justificación Ambiental* ..... 8

    1.3.4. *Justificación tecnológica* ..... 9

1.4. OBJETIVOS ..... 11

    1.4.1. *Objetivo} general* ..... 11

    1.4.2. *Objetivos específicos* ..... 11

1.5. LIMITACIONES Y DELIMITACIONES DE LA INVESTIGACIÓN ..... 11

1.6. HIPÓTESIS ..... 12

    1.6.1. *Hipótesis general* ..... 12

    1.6.2. *Hipótesis específicas* ..... 12

1.7. VARIABLES E INDICADORES ..... 13

    1.7.1. *Conceptualización de las variables* ..... 13



1.7.2. Operacionalización de Variables ..... 15

**CAPÍTULO II**

**MARCO TEÓRICO**

2.1. ANTECEDENTES DEL ESTUDIO ..... 17  
2.1.1. A nivel internacional ..... 17  
2.1.2. A nivel nacional ..... 19  
2.2. BASES TEÓRICAS ..... 20  
2.3. MARCO CONCEPTUAL ..... 35  
2.4. MARCO NORMATIVO ..... 38

**CAPÍTULO III**

**MÉTODO DE LA INVESTIGACIÓN**

3.1. MÉTODO DE LA INVESTIGACIÓN ..... 40  
3.1.1. Métodoo general ..... 40  
3.2. TIPO DE INVESTIGACIÓN..... 41  
3.3. NIVEL DE INVESTIGACIÓN..... 41  
3.4. DISEÑO DE INVESTIGACIÓN ..... 41  
3.5. POBLACIÓN Y MUESTRA ..... 42  
3.5.1. Población..... 42  
3.5.2. Muestra ..... 42  
3.6.1. Técnicas de la investigación..... 42  
3.6.2. Instrumentos de la investigación ..... 43  
3.7. FUENTES ..... 44  
3.7.1. Suelo de canteras utilizadas posibles para elaboración de BTC´s: ..... 44  
3.7.2. Fuentes de información ..... 44  
3.8. VALIDEZ Y CONFIABILIDAD DEL INSTRUMENTO ..... 45



3.8.1. Validez del instrumento .....45

3.8.2. Confiabilidad del instrumento .....45

3.9. PROCEDIMIENTOS .....45

3.9.1. Identificación y clasificación de suelos mediante redes neuronales.....45

3.9.2. Recolección y preparación de datos .....46

3.9.3. Diseño y entrenamiento de la red neuronal.....47

3.9.4. Validación del modelo .....49

3.9.5. Comparación con estudios previos .....50

3.10. DISEÑO ESTADÍSTICO .....51

3.11. ENFOQUE DE SUPERFICIE DE RESPUESTA.....52

3.12. FASES DEL PROCESO DE OPTIMIZACIÓN .....53

**CAPÍTULO IV**

**RESULTADOS**

4.1. DESCRIPCIÓN DE LA BASE DE DATOS UTILIZADA .....55

4.2. PREPROCESAMIENTO DE LOS DATOS .....57

4.3. SELECCIÓN Y CONFIGURACIÓN DE LAS ARQUITECTURAS DE LAS  
REDES NEURONALES ARTIFICIALES (RNA) .....60

4.4. EVALUACIÓN DE LA PRECISIÓN Y DESEMPEÑO DE LAS RNA EN  
LA CLASIFICACIÓN DE SUELOS.....62

4.5. COMPARACIÓN DE RESULTADOS ENTRE EL ENFOQUE TRADICIONAL  
Y EL ENFOQUE BASADO EN RNA .....66

4.6. ANÁLISIS DE SENSIBILIDAD DE LOS PARÁMETROS DE LAS RNA EN  
LA CLASIFICACIÓN DE SUELOS.....69

4.7. ESTUDIO DE LA INFLUENCIA DE LAS CARACTERÍSTICAS DEL SUELO  
EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS .....71



4.8. VALIDACIÓN DE LOS RESULTADOS MEDIANTE COMPARACIÓN CON ENSAYOS DE LABORATORIO .....	74
<b>CONCLUSIONES .....</b>	<b>78</b>
<b>REFERENCIAS BIBLIOGRÁFICAS .....</b>	<b>83</b>



## ÍNDICE DE TABLAS

<b>Tabla 1</b> Operacionalización de variables .....	16
<b>Tabla 2</b> Funciones de activación más comunes .....	26
<b>Tabla 3.</b> <i>Tipos de aprendizaje Supervisado.</i> .....	34
<b>Tabla 4.</b> <i>Extracto de la base de datos utilizada para la clasificación de suelos mediante RNA.</i> .....	57
<b>Tabla 5</b> <i>Arquitectura de la RNA seleccionada y rendimiento en los datos de prueba.</i> .....	61
<b>Tabla 6.</b> <i>Comparación entre el enfoque tradicional y el enfoque basado en RNA para la clasificación de suelos en el diseño de BTC.</i> .....	68
<b>Tabla 7.</b> <i>Análisis de sensibilidad de los parámetros de las RNA en la clasificación de suelos para el diseño de BTC.</i> .....	70
<b>Tabla 8.</b> <i>Influencia de las características del suelo en el diseño de BTC.</i> .....	73
<b>Tabla 9.</b> <i>Validación de la clasificación de suelos mediante RNA en comparación con ensayos de laboratorio.</i> .....	76



## ÍNDICE DE FIGURAS

<b>Figura 1.</b> Neurona biológica.....	23
<b>Figura 2.</b> Neurona Artificial .....	24
<b>Figura 3.</b> Componentes de una Red Neuronal Artificial.....	29
<b>Figura 4</b> Estructura de una red neuronal .....	29
<b>Figura 5.</b> Taxonomía de redes neuronales artificiales .....	30
<b>Figura 6.</b> Clasificación de RNA, por su Arquitectura.....	30
<b>Figura 7.</b> Red recurrente perceptor MULTICAPA.....	31
<b>Figura 8.</b> Red Multicapa. ....	32
<b>Figura 9.</b> Esquema de aprendizaje supervisado.....	33
<b>Figura 10</b> <i>Cantera de la ciudad de Juliaca.</i> ....	44
<b>Figura 11.</b> <i>Diagrama de flujo del proceso de preprocesamiento de datos.</i> .....	59
<b>Figura 12.</b> <i>Arquitectura de la RNA seleccionada.</i> .....	62
<b>Figura 13.</b> <i>Matriz de confusión de la clasificación de suelos mediante RNA.</i> .....	65
<b>Figura 14.</b> <i>Análisis de las variables de entrada</i> .....	65
<b>Figura 15.</b> <i>Comparación de la precisión entre el enfoque tradicional y el enfoque basado en RNA.</i> .....	68
<b>Figura 16.</b> <i>Análisis de sensibilidad de los parámetros de las RNA en la clasificación de suelos.</i> .....	71
<b>Figura 17.</b> <i>Influencia de las características del suelo en las propiedades de los BTC.</i> .....	74
<b>Figura 18.</b> <i>Comparación de la clasificación de suelos mediante RNA y ensayos de laboratorio.</i> .....	77



## RESUMEN

La clasificación de suelos es crucial en la fabricación de Bloques de Tierra Comprimidos (BTC), un material de construcción sostenible. Este estudio propone el uso de Redes Neuronales Artificiales (RNA) para clasificar suelos de manera rápida y precisa, optimizando el proceso de construcción de BTCs. Se recopiló información sobre 20 muestras de suelo y se realizaron pruebas granulométricas y de propiedades físicas según normativas ASTM (D4318 y D2487). Se diseñaron RNA con una arquitectura de tres capas ocultas (64, 128 y 64 neuronas), utilizando técnicas de regularización. La base de datos incluyó propiedades fundamentales del suelo, como el contenido de arcilla, el índice de plasticidad y la densidad aparente. El modelo de RNA alcanzó un rendimiento del 75% en la clasificación SUCS, con una concordancia del 75% con ensayos de laboratorio. Se identificaron parámetros críticos que afectan la precisión, como el contenido de arcilla (impacto alto), el índice de plasticidad y la densidad aparente (impacto moderado). La distribución granulométrica, los límites de Atterberg, el contenido de humedad y la constitución mineralógica del suelo influyen significativamente en el desempeño de los BTCs. Las RNA ofrecen mayor precisión y eficiencia en comparación con métodos tradicionales. Para mejorar la precisión, se recomienda aumentar el rango de muestras (50 muestras), incorporar variables adicionales (composición mineralógica y contenido de materia orgánica), explorar arquitecturas más profundas (4-5 capas ocultas, hasta 256 neuronas por capa) y realizar análisis de sensibilidad. Este enfoque optimiza la construcción de BTCs y ofrece una alternativa innovadora para la clasificación de suelos.

**Palabras Clave:** Clasificación de suelos, redes neuronales artificiales, bloques de tierra comprimidos, SUCS.



## ABSTRACT

Soil grading is crucial in the manufacturing of Compressed Earth Blocks (CTB), a sustainable building material. This study proposes the use of Artificial Neural Networks (ANN) to classify soils quickly and accurately, optimizing the BTC construction process. Information was collected on 20 soil samples and granulometric and physical property tests were carried out according to ASTM regulations (D4318 and D2487). ANNs were designed with a three-hidden layer architecture (64, 128 and 64 neurons), using regularization techniques. The database included fundamental soil properties such as clay content, plasticity index and bulk density. The RNA model achieved 75% performance in SUCS classification, with 75% agreement with laboratory assays. Critical parameters affecting accuracy were identified, such as clay content (high impact), plasticity index, and bulk density (moderate impact). The particle size distribution, Atterberg limits, moisture content and mineralogical composition of the soil significantly influence the performance of BTCs. ANNs offer greater precision and efficiency compared to traditional methods. To improve precision, it is recommended to increase the sample range (50 samples), incorporate additional variables (mineralogical composition and organic matter content), explore deeper architectures (4-5 hidden layers, up to 256 neurons per layer) and perform analysis of sensitivity. This approach optimizes the construction of BTCs and offers an innovative alternative for soil classification.

**Keywords:** Soil classification, Artificial Neural Networks, Compressed Earth Blocks, SUCS.



## INTRODUCCIÓN

La clasificación de suelos es un componente esencial en la ingeniería civil y la construcción, especialmente en la fabricación de Bloques de Tierra Comprimidos (BTC), un material de construcción sostenible y económicamente viable. La identificación y clasificación tradicional de suelos requiere pruebas de laboratorio costosas y extensivas, lo que puede ser un obstáculo en proyectos de construcción, sobre todo en áreas con recursos limitados. Ante esta problemática, existe una creciente necesidad de métodos más rápidos y precisos para la clasificación de suelos.

En los actuales años, las Redes Neuronales Artificiales (RNA) han mostrado su poder en diversas áreas, como la ingeniería, la medicina y la agricultura, gracias a su idoneidad para auto instruirse, trascender y abstraer información eficientemente. Estas redes, infundidas en las redes neuronales orgánicas del cerebro humano, se presentan como una alternativa prometedora para la clasificación de suelos, permitiendo una identificación rápida y precisa sin la necesidad de pruebas de laboratorio extensivas.

En este estudio, se enfoca en la aplicación de RNA para la clasificación de suelos con el objetivo de perfeccionar el proceso de fabricación de BTCs. Este enfoque no solo tiene el potencial de mejorar la eficiencia en la construcción de BTCs, sino también de contribuir a prácticas de construcción más sostenibles.

La interrogante de investigación que guía este estudio es: ¿Pueden las Redes Neuronales Artificiales clasificar suelos de manera precisa y eficiente para su uso en el diseño de Bloques de Tierra Comprimidos? Para manifestar y absolver a esta pregunta, se diseñó un proceso experimental que incluye la recopilación de



datos de suelos de diversas ubicaciones geográficas, pruebas granulométricas y de propiedades físicas, y el entrenamiento de RNA para la clasificación de suelos según normativas establecidas. El rendimiento del modelo de RNA se validó mediante ensayos de laboratorio y se comparó con métodos tradicionales de clasificación de suelos.



## CAPÍTULO I

### FORMULACIÓN DEL PROBLEMA

#### 1.1. ENTORNO DE LA PROBLEMÁTICA

Sin riesgo de error, podemos afirmar que uno de los materiales de construcción más utilizados en la historia es el barro o tierra cruda. Es uno de los recursos más abundantes de la naturaleza y extraerlo no requiere procedimientos complicados. Desde la perspectiva de la cada vez más valorada sostenibilidad, también es una elección muy interesante ya que es reutilizable y no produce basura que pueda dañar el medio ambiente. Además, se convierte en la mejor opción para construir en lugares de todo el mundo donde las soluciones técnicas disponibles requieren el uso de materiales compatibles con las realidades económicas locales y el uso de procedimientos estrictos.

Hoy en día debe haber, y ya hay, un interés justo y renovado en el suelo como recurso de construcción sostenible. A la luz de los problemas sociales, económicos y ambientales que rodean la construcción, es una opción viable. Entre los beneficios de la tierra como material se encuentran su bajo impacto visual y su



facilidad de integración paisajística, su carácter local que elimina la necesidad de costes adicionales de transporte, su carácter reciclable y ausencia de residuos industriales, su bajo coste energético de producción, sus buenas propiedades térmicas propiedades aislantes y su buena resistencia al fuego. Además de almacenar calor y regular la humedad, el suelo también puede regular el ambiente interior. Debido a su relativa porosidad, las paredes de tierra pueden acumular o liberar humedad del aire circundante, asegurando una humedad ideal durante todo el año. Sin embargo, una característica de las estructuras del suelo que las hace apropiadas para una variedad de climas es la inercia térmica, o la capacidad de almacenar energía dentro de su estructura y posteriormente liberarla. Del mismo modo, las paredes compuestas por este material tienen cualidades de aislamiento acústico muy superiores a las tradicionales, lo que las convierte en una excelente barrera contra ruidos no deseados debido a su mala transmisión de las vibraciones sonoras.

Un sustituto económico, sostenible y ecológico de los componentes de mampostería convencionales en la construcción son los bloques de tierra comprimida (BTCs). La estructura BTCs tiene una baja composición de cemento y puede producirse localmente mediante una tecnología de compresión manual que permite un montaje rápido y eficaz en obra.

El ingrediente principal para esto es el suelo local, que tiene ventajas sobre los componentes de mampostería convencionales, como ser menos costoso, más eficiente energéticamente y tener un menor impacto ambiental.

Identificar los suelos que conformarán el BTCs de manera oportuna y segura, así como definir una estandarización y normalización precisa que explore la relación



entre los datos de las pruebas de campo cualitativas y cuantitativas y los procedimientos estandarizados de laboratorio de análisis de suelos, será el desafío a afrontar. resueltos con el fin de darle eficiencia y eficacia al proceso de construcción de BTCs y hacerlo fructífero. El objetivo es clasificar con precisión un suelo basándose únicamente en análisis y pruebas de campo. teniendo en cuenta que el comportamiento final de un BTC estará directamente influenciado por las características y atributos del suelo, que difieren según la región geológica y geográfica.

La evaluación estandarizada de las propiedades del suelo en el campo puede resultar desafiante ya que los criterios de categorización del suelo incluyen pruebas de laboratorio.

Las pruebas de campo a menudo proporcionan datos cualitativos que recopilan principalmente constructores capacitados; Los ingenieros que supervisan el proyecto de construcción también pueden recopilar algunos datos cuantitativos sin procesar.

Sin embargo, las características de los suelos que nos interesan son su distribución de partículas, contenido de arcilla y plasticidad, información que se utiliza para categorizar los suelos. ASTM D4318 describe los métodos de laboratorio utilizados para caracterizar ciertas cualidades del suelo.

Las características del suelo antes mencionadas son empleadas por el popular Sistema de categorización de suelos (SUCS) para proporcionar una categorización definida a un suelo determinado. ASTM D2487 contiene (SUCS).



Esta complejidad debe resolverse mediante procesos de vinculación y correlación que darán como resultado definir que, en ausencia de un laboratorio de mecánica de suelos, se utilizarán Redes Neuronales Artificiales (RNA) para clasificar los suelos para su uso en BTCs. Para abordar una variedad de problemas de una manera similar a la de una persona, las redes neuronales artificiales (RNA) integran una serie de enfoques informáticos para llevar a cabo tareas de aprendizaje y autocorrección utilizando algoritmos o códigos de programación informática.

## 1.2. FORMULACIÓN DEL PLANTEAMIENTO DEL PROBLEMA

### 1.2.1. *Problema general*

**PG** ¿Se puede aplicar el uso de Redes Neuronales Artificiales en el proceso de identificación y clasificación de suelos para uso en BTC's y ser comparativa con la clasificación del SUCS?

### 1.2.1. *Problemas específicos*

- a. ¿Se podrá establecer la relación que existe entre los ensayos cuantitativos y cualitativos que permiten la identificación de suelos para la fabricación de BTC's?
- b. ¿Se podrá asignar una clasificación de suelo a través de un sistema de flujo de datos cuantitativos y cualitativos y entrenar redes neuronales artificiales para clasificar suelos para BTC's?
- c. ¿Qué cantidad de datos cualitativos y cuantitativos será necesario para determinar a través de procesos de inteligencia artificial para una clasificación de suelos en función a la precisión y la clasificación de suelos para BTC's?



### 1.3. JUSTIFICACIÓN DE LA INVESTIGACIÓN

La necesidad de aumentar la sostenibilidad y la eficiencia en la categorización del suelo para la producción de bloques de tierra comprimida (BTCs) sirve como fundamento de este estudio. La categorización convencional del suelo requiere pruebas de laboratorio costosas y que requieren mucho tiempo, lo que es una barrera para los proyectos de construcción, particularmente en lugares con recursos limitados. Además, los BTCs se consideran un material de construcción sostenible y económicamente viable, y su calidad y resistencia dependen de una clasificación precisa del suelo.

Dado que las redes neuronales artificiales (RNA) pueden aprender y generalizar patrones complicados a partir de datos, proporcionan una opción viable para la categorización del suelo. Sin embargo, dada la variedad de suelos y sus características físicas, se requiere una investigación y evaluación exhaustivas del desempeño de las RNA en este contexto particular.

El desarrollo de un enfoque basado en RNA para la clasificación de suelos, específicamente dirigido a la fabricación de BTCs, tiene el potencial de agilizar el proceso de clasificación, reducir las erogaciones vinculadas y optimizar la precisión de los resultados. Esto puede tener un impacto significativo en la industria de la construcción, permitiendo una mejor planificación y diseño de proyectos, así como una mayor eficiencia en el uso de los recursos.

Además, el uso de métodos de inteligencia artificial de vanguardia, como RNA, para clasificar el suelo podría respaldar métodos de construcción más respetuosos con el medio ambiente. Fomenta la adopción de métodos más



ecológicos y apoya la conservación del medio ambiente haciendo el mejor uso de los recursos naturales que ya son accesibles y minimizando la necesidad de costosas pruebas de laboratorio.

### **1.3.1. Justificación Económica**

La justificación económica de esta investigación se basa en los beneficios potenciales que se pueden obtener al aplicar redes neuronales artificiales (RNA) en la clasificación de suelos para la fabricación de Bloques de Tierra Comprimidos (BTCs).

En primer lugar, la categorización convencional del suelo requiere pruebas de laboratorio costosas y que requieren mucho tiempo, lo que aumenta significativamente los costos del proyecto de construcción. Debido a que las RNA pueden aprender y generalizar patrones complicados a partir de datos sin requerir pruebas físicas extensas, el costo de estas pruebas puede reducirse significativamente cuando se utilizan para la categorización de suelos. Esto sugiere significativos ahorros financieros en términos de tiempo de procesamiento y gastos de laboratorio.

Además, la eficiencia de la producción de BTCs puede aumentar mediante el uso de RNA en la categorización del suelo. El diseño y la fabricación de BTCs pueden mejorarse con una categorización del suelo más precisa, lo que conducirá a menos desperdicio y una utilización más eficaz del material. La fabricación de BTCs puede volverse más rentable como consecuencia de unos costes de producción más bajos.

La sostenibilidad es otra consideración económica importante. Debido a que emplean recursos locales y tienen un pequeño efecto ambiental, los BTCs se



consideran materiales de construcción sostenibles. Al minimizar la dependencia de costosas pruebas de laboratorio y hacer el mejor uso de los recursos naturales utilizables, el uso de RNA para la clasificación del suelo fomenta la adopción de técnicas de construcción más respetuosas con el medio ambiente. Esto puede dar como resultado una mayor aceptabilidad en el mercado y una mejor imagen corporativa, lo que puede conducir a perspectivas comerciales y ventajas competitivas.

### **1.3.2. Justificación Social**

Los efectos beneficiosos que el uso de redes neuronales artificiales (RNA) en la categorización de suelos para la producción de Bloques de Tierra Comprimida (BTCs) pueden tener en la sociedad sirven como base social para este estudio.

En primer lugar, la vigencia y la rapidez de los proyectos de construcción pueden verse directamente afectadas por la simplificación del proceso de clasificación proporcionada por el uso de RNA para la clasificación del suelo. Esto implica períodos de construcción más cortos, lo que puede dar lugar a una entrega más rápida de viviendas e infraestructuras y, por tanto, abordar antes las demandas de la sociedad.

Además, dado que los BTCs emplean recursos locales y tienen un pequeño efecto ambiental, se consideran materiales de construcción sostenibles. El uso de RNA en la categorización del suelo para la producción de BTCs fomenta el uso de técnicas de construcción más respetuosas con el medio ambiente. Al ayudar a disminuir el efecto ambiental de la construcción, ahorrar recursos naturales y fomentar un entorno más sostenible y saludable para las comunidades, esto puede tener un impacto social beneficioso.



De manera similar, el uso de RNA en la categorización de suelos puede ayudar a crear empleos y cultivar habilidades en la industria de la construcción. La adopción de tecnología de vanguardia, como RNA, requiere el uso de expertos calificados tanto para la implementación como para el mantenimiento. Esto puede promover el crecimiento de habilidades técnicas en la sociedad y brindar posibilidades laborales en campos vinculados a la inteligencia artificial.

La disponibilidad de vivienda es otro factor social importante. Los BTCs son un sustituto deseable para comunidades con recursos limitados, ya que son una opción de construcción económica y ambientalmente racional. La categorización precisa del suelo utilizando RNA puede aumentar la eficiencia de la fabricación de BTCs y reducir los costos relacionados, lo que puede ayudar a que la vivienda sea más accesible para los segmentos de la sociedad que luchan con ella.

### **1.3.3. Justificación Ambiental**

Las ventajas de utilizar redes neuronales artificiales (RNA) para clasificar los suelos para la producción de bloques de tierra comprimida (BTCs) en términos de sostenibilidad y preservación del medio ambiente sirven como base para la justificación medioambiental de la investigación.

En primer lugar, debido a su escaso efecto medioambiental, los Bitcoins se consideran materiales de construcción sostenibles. Al utilizar tierra cruda como materia prima, minimizan la producción de residuos y la explotación de recursos naturales no renovables. Se fomenta una clasificación más precisa y eficaz mediante el uso de RNA en el proceso de clasificación de suelos para la producción de BTCs, lo que ayuda a maximizar el uso de los recursos naturales a los que se



puede acceder. Como resultado, será necesario extraer menos tierra y la huella de carbono de la producción de materiales de construcción tradicionales será menor.

Además, el uso de RNA en la categorización del suelo podría reducir la dependencia de estudios de laboratorio costosos y que requieren mucho tiempo y que exigen insumos químicos y energéticos. El uso de energía y la producción de contaminantes y desechos peligrosos disminuyen al reducir la necesidad de estas pruebas físicas. Esto apoya la preservación del medio ambiente y el desarrollo de técnicas de construcción más respetuosas con el medio ambiente.

La disminución de las emisiones de gases de efecto invernadero es otro factor importante. La categorización convencional de suelos puede requerir el transporte de muestras a laboratorios y pruebas en lugares alejados de las obras de construcción. El transporte y las emisiones relacionadas se reducen mediante el uso de RNA para categorizar los suelos localmente y en tiempo real. Esto ayuda a disminuir la contaminación del aire y mitigar los efectos del cambio climático.

Además, el uso de técnicas de construcción sostenible, como el uso de BTCs elaborados a partir de una categorización precisa del suelo mediante RNA, podría aumentar la comprensión social de las cuestiones ambientales. Promover el uso de materiales de construcción sostenibles ayuda a la comunidad a comprender el valor de la conservación de recursos y la preservación del medio ambiente.

#### **1.3.4. Justificación tecnológica**

La utilización de redes neuronales artificiales (RNA) como arma tecnológica de vanguardia para la categorización de suelos en la producción de bloques de tierras comprimidas (BTCs) sirve como base técnica para este estudio.



En primer lugar, los métodos de inteligencia artificial (RNA) son competentes para aprender e identificar patrones complicados en cantidades extensas de datos. Se pueden examinar múltiples factores y propiedades del suelo de manera efectiva y simultánea con el conjunto diverso de redes neuronales artificiales (RNA) en la categorización del suelo. En comparación con las técnicas de clasificación convencionales, que a menudo dependen de pruebas de laboratorio costosas y que requieren mucho tiempo, esto permite obtener resultados más precisos y fiables.

Además, las RNA pueden generalizarse y ajustarse en función de los datos de entrenamiento. Esto implica que, con la formación adecuada, pueden categorizar con precisión suelos nuevos incluso en ausencia de datos de prueba específicos de cada caso. Esta capacidad de generalización es particularmente útil en proyectos de construcción, donde es necesaria una categorización rápida y precisa del suelo para una planificación y toma de disposiciones positivas.

La disponibilidad de grandes cantidades de datos geotécnicos y geoespaciales es otro factor tecnológico importante. Se ha originado una gran cuantía de datos sobre las propiedades de los suelos en varios lugares gracias a los progresos en la compilación y el almacenamiento de datos. Al identificar ciertos patrones relacionados con varios tipos de suelo y áreas geográficas, las RNA pueden usar estos datos para aumentar la precisión de la categorización del suelo.

Además, el uso de RNA en la categorización del suelo para la producción de BTCs podría conducir a la automatización de los procedimientos de clasificación. Esto sugiere que puede ser posible crear sistemas y aplicaciones técnicos que permitan la categorización automatizada y en tiempo real, lo que aceleraría la fabricación y reduciría la necesidad de interacción humana.



## 1.4. OBJETIVOS

### 1.4.1. *Objetivo} general*

**OG.** Diseñar e implementar el uso de Redes Neuronales Artificiales en el modelado de los ensayos para la clasificación de suelos que se utilizaran para la fabricación de BTC's según la norma ASTM D2487.

### 1.4.2. *Objetivos específicos*

**OE1.** Cuantificar las variables que intervienen en el proceso de clasificación de suelos para la fabricación de BTC's.

**OE2.** Conformar una base de datos histórica de caracterización de suelos según la normativa y sus respectivos resultados por los métodos estandarizados cuantitativos y cualitativos.

**OE3.** Construir y desarrollar la arquitectura de la Red Neuronal más apropiada para la estimación de la identificación de suelos para el uso de BTC's.

**OE4.** Comprobar los valores pronosticados de las Redes Neuronales propuestas con los ensayos de laboratorio y de campo cuantitativo y cuantitativo para la clasificación de suelos.

**OE5.** Medir el margen de error y aproximación lograda con la aplicación de inteligencia artificial (RNA) al proceso de clasificación de suelos.

## 1.5. LIMITACIONES Y DELIMITACIONES DE LA INVESTIGACIÓN

La exploración que se realizó tiene una serie de restricciones y limitaciones. En primer lugar, la precisión y representatividad de los hallazgos se vieron afectadas por la disponibilidad y calidad restringidas de los datos del suelo empleados. Además, se descubrieron limitaciones intrínsecas en el diseño, el



número de capas y neuronas y los métodos de adiestramiento del tipo de red neuronal artificial que se eligió y configuró. Además, dado que la investigación se limitó a una ubicación geográfica particular, los hallazgos no pudieron aplicarse a otras situaciones o lugares. De manera similar, la delimitación temporal del estudio restringió la representatividad de los hallazgos a ese marco temporal. El diseño experimental también tuvo limitaciones, incluidos los factores tomados en cuenta, los métodos utilizados y el tamaño de la muestra. Por último, la relevancia del estudio para otros campos o proyectos de ingeniería geotécnica se vio restringida por su énfasis en la categorización del suelo para el diseño de bloques de tierra comprimida.

El formato de presentación del estudio y el nivel de rigor exploratorio cumplieron con los requisitos conforme a las exigencias según normativa existente, postulados y teorías pertinentes al tema de indagación los que ayudaron a esta conformidad.

## 1.6. HIPÓTESIS

### 1.6.1. *Hipótesis general*

**HG.** La utilización de redes neuronales artificiales (RNAs) basadas en datos cuantitativos y cualitativos permitirá una clasificación precisa de suelos utilizados en la obtención de bloques de tierra comprimidos (BTCs), mejorando la eficiencia y exactitud en cotejo con los métodos convencionales de clasificación de suelos.

### 1.6.2. *Hipótesis específicas*

**HE1.** La cuantificación de las variables que intervienen en el proceso de clasificación de suelos para la fabricación de BTC's permitirá obtener un modelo más preciso y eficiente.



**HE2.** La conformación de una base de datos histórica de caracterización de suelos según la normativa y los métodos estandarizados cuantitativos y cualitativos proporcionará información valiosa para la validación y comparación de los resultados obtenidos a través de las redes neuronales artificiales (RNA).

**HE3.** La construcción y desarrollo de la arquitectura de la red neuronal más ajustada para la estimación de la identificación de suelos para el uso de BTC's mejorará la precisión y confiabilidad de la clasificación de suelos.

**HE4.** La comprobación de los valores predichos de las redes neuronales formuladas con los ensayos de laboratorio y de campo cuantitativo y cualitativo para la clasificación de suelos permitirá evaluar la exactitud y validez de los resultados obtenidos con las RNA.

**HE5.** La medición del margen de error y aproximación lograda con la aplicación de inteligencia artificial (RNA) al proceso de clasificación de suelos permitirá determinar la efectividad y precisión de este enfoque en comparación con los métodos habituales de clasificación.

## **1.7. VARIABLES E INDICADORES**

### **1.7.1. Conceptualización de las variables**

**Ensayos y pruebas de laboratorio estandarizadas según la normativa ASTM D4318 y ASTM D2487.**

Según ASTM D4318 y ASTM D2487, las pruebas y ensayos de laboratorio estandarizados son una colección de protocolos y técnicas particulares utilizados en los laboratorios para describir y evaluar diversos atributos del suelo. Mientras que la ASTM D2487 se concentra en la categorización y descripción visual del



suelo, la ASTM D4318 se ocupa más de las pruebas para determinar la composición mineralógica y la distribución del tamaño de las partículas del suelo. En los campos de la geotecnia y la ingeniería civil, estas pruebas se emplean a menudo y cumplen con los criterios y directrices establecidos por la American Society for Testing and Materials (ASTM). Proporcionan detalles vitales sobre características que incluyen resistencia, compactación, permeabilidad, plasticidad y otras métricas pertinentes del suelo. La uniformidad en los métodos de evaluación del suelo se garantiza mediante la realización de estas pruebas de laboratorio y pruebas de conformidad con las normas ASTM D4318 y ASTM D2487. Esto facilita la comparación de resultados y la adquisición de datos precisos y fiables. Esto es necesario para comprender y describir con precisión el comportamiento del suelo en una variedad de aplicaciones y proyectos de ingeniería, incluida la construcción de carreteras, edificios, cimientos y proyectos de infraestructura en general.

## **Caracterización de suelos según SUCS y RNA**

Según el Sistema Unificado de Clasificación de Suelos (SUCS) y las Redes Neuronales Artificiales (RNA), la caracterización del suelo se refiere a dos métodos distintos para clasificar y organizar los suelos según sus atributos. Una técnica popular para clasificar los suelos en varios grupos según su textura, contenido de partículas y características de plasticidad es la técnica de Sistema Unificada de Clasificación de Suelos (SUCS). La SUCS clasifica los suelos en clases primarias, que incluyen arena, grava, limo y arcilla, y luego define más subgrupos dentro de cada grupo según criterios predeterminados. En ingeniería y construcción geotécnica, esta categorización se emplea a menudo. Por el contrario, las técnicas de aprendizaje automático proporcionan la base de las redes neuronales artificiales (RNA), un método de modelado y clasificación. Para crear modelos y estimaciones



de diversos atributos del suelo, incluida su textura, compacidad y cualidades mecánicas, se entrenan redes neuronales artificiales (RNA) utilizando datos de entrada relacionados con las propiedades del suelo. Las RNA son capaces de analizar bancos de datos extensos e identificar patrones complicados que pueden no ser visibles para el ojo humano. En comparación con los sistemas de clasificación convencionales, las RNA para la clasificación de suelos brindan la ventaja de manejar datos más complicados y no lineales y producir predicciones y estimaciones más precisas. Sin embargo, es fundamental enfatizar que para que las RNA proporcionen resultados correctos, deben estar bien capacitadas utilizando datos representativos y confiables. Tanto las RNA como las SUCS son instrumentos útiles para clasificar el suelo y proporcionan datos útiles para una variedad de industrias, comprendida la organización del uso de la tierra, la agricultura y la ingeniería civil. Cada estrategia tiene sus propios pros y contras, y la decisión entre ellas se basará en los objetivos particulares de la investigación, así como en los recursos y datos disponibles.

### **1.7.2. Operacionalización de Variables**

La operacionalización de las variables, junto con las dimensiones e índices que las correlacionan, las herramientas usadas para la recolección de datos y los avances en la exploración de cada componente se muestran en la siguiente tabla.



**Tabla 1**

*Operacionalización de variables*

VARIABLE INDEPENDIENTE	VARIABLE DEPENDIENTE	INDICADOR
Caracterización de suelos según Ensayos estandarizados de laboratorio según normativa vigente.	Caracterización experimental.	Correlación entre la identificación de tipo de suelo encontrada en laboratorio y la encontrada a través de las redes neuronales.
Caracterización de suelos de base de datos implementada por RNA generadas.	Caracterización predicha.	

**Nota.** *Elaboración del investigador.*



## CAPÍTULO II

### MARCO TEÓRICO

#### 2.1. ANTECEDENTES DEL ESTUDIO

##### *2.1.1. Según un horizonte internacional*

Valdés Holguín, 2011 conforme a su exploración, "Estimación de la resistencia a la penetración de suelos usando redes neuronales artificiales", para estimar la resistencia a la penetración en varios niveles del suelo, se han desarrollado redes neuronales artificiales de perceptrones multicapa. Se cree que el contenido de humedad, la densidad, la carga estática y la presión son factores importantes. Los hallazgos indican un valor más preciso para profundidades que oscilan entre 20 y 30 cm. También muestran una eficiencia de hasta 30 cm en comparación con la prueba de índice de cono estandarizada.

Carreño, 2018 en su exploración, "Estimación del módulo de resiliencia por medio de redes neuronales", indica la ubicación y el valor del módulo de resiliencia utilizado en el diseño del pavimento. Este valor requerido del módulo de resiliencia se basa en un procedimiento estandarizado que se llevó a cabo utilizando muestras de campo y pruebas de laboratorio estandarizadas. Según la exploración, el módulo



de resiliencia podría predecirse utilizando el índice del suelo y el estado de tensión. Por lo tanto, se empleó RNA y los resultados fueron tan buenos que el IMT lanzó una aplicación para la comunidad de ingenieros que permite identificar el módulo resiliente que se utiliza actualmente en los procedimientos de diseño de pavimentos.

Ramires, 2013 en su exploración, "REDES NEURONALES MULTIOBJETIVO PARA CLASIFICACION NOMINAL Y ORDINAL", además del MACHINE LERNAING, que optimiza la estructura del protocolo de aprendizaje y la inteligencia artificial(IA), se emplean algoritmos evolutivos multiobjetivo que utilizan el ARN para tomar decisiones y optimizar en los campos de la teledetección, la medicina y la microbiología predictiva, óptimo en la identificación del donante y receptor de un órgano utilizando la variable esperanza de vida en función de la compatibilidad encontrada, así como en la detección del crecimiento de microorganismos en diversos tipos de envases que impiden que los productos sean adecuados según los procesos de fabricación. alimentos y nutrientes en función de sus posibles beneficios para la salud de cada tipo de persona y producto envasado. La misma tesis también utiliza algoritmos multiobjetivo para identificar, mediante teledetección e imágenes, las mejores tierras para el cultivo del olivo en España y la eficacia de la agricultura de conservación evitando de antemano los procesos de erosión. La investigación ayuda a comprender el propósito y el uso de las redes neuronales artificiales en la aplicación efectiva de varios campos de la ciencia aplicada.

Maarouf, 2015 en su exploración, "Aplicación de Redes Neuronales para la Resolución de Problemas Complejos en Confiabilidad y Riesgo", predice el curso



de un derrame marino, una nube tóxica, una falla de un equipo crítico o un incendio forestal utilizando redes neuronales artificiales y compara los resultados con la interacción y las evaluaciones estándar realizadas por ingenieros que toman mucho tiempo. El método estandarizado clásico produce resultados cuando los efectos de los eventos son irreparables, pero el proceso de inteligencia artificial de las RNA permitió adquirir valores bastante aceptables para definir decisiones y en consecuencia la ejecución de soluciones en tiempo real. presentar pruebas respaldadas empíricamente de los prospectos viables de la IA para la humanidad, con énfasis en usos predictivos y de diagnóstico pertinentes específicos bajo el paraguas de "Confiabilidad, mantenibilidad, disponibilidad, seguridad e ingeniería de riesgos".

Aplincourt, 2000 en su exploración, "Neurocontrol of a Cantiléver Beam", se utilizan dispositivos electrónicos con una estructura similar a la del cerebro humano para construir y alimentar redes neuronales artificiales. Para recopilar de manera efectiva ciertos datos de monitoreo, dichos dispositivos programables pueden programarse para generar señales específicas. Por tanto, en teoría, las redes neuronales podrían servir como controladores para la monitorización inteligente de sistemas. Los hallazgos de la RNA han sido buenos y actualmente pueden usarse en sistemas de monitoreo de edificios más sofisticados. Estos resultados incluyen definir el análisis del comportamiento en tiempo real de la estructura o viga en voladizo, reconocer amenazas potenciales bajo esfuerzos excepcionales y más.

### **2.1.2.A nivel nacional**

Tello, 2017 en su exploración, "USO DE LAS REDES NEURONALES ARTIFICIALES EN EL MODELADO DEL ENSAYO DE RESISTENCIA A COMPRESIÓN DE CONCRETO DE CONSTRUCCIÓN SEGÚN LA NORMA ASTM



C39/C 39M", que utiliza ARN perceptrón multicapa (MPL) para desarrollar una red neuronal artificial (RNA) que puede predecir la resistencia a la compresión del hormigón comparando las propiedades de los insumos utilizados en su producción y su resistencia a la tensión de compresión. La RNA es capaz de predecir la resistencia del concreto antes de los 7, 14 y 28 días, con una eficiencia de resultados de RNA del 96,71%, lo que define un bajo margen de error en los análisis realizados.

Chicchón, 2018 en su exploración, "FUSIÓN DE DATOS PARA SEGMENTACIÓN SEMÁNTICA EN APLICACIONES URBANAS DE TELEDETECCIÓN AÉREA USANDO ALGORITMOS DE APRENDIZAJE PROFUNDO", esto implica el uso de redes neuronales artificiales (RNA) convolucionales, mapeo, monitoreo urbano e imágenes aéreas para identificar áreas de expansión urbana. Esto permite procesar y controlar en tiempo real el plan de desarrollo urbano. Además, utiliza metodología multiespectral y caracterización de reflectancia espectral para analizar la cobertura del suelo en entornos urbanos mediante RNA, lo que permite relacionarlo con el plan de desarrollo urbano y corregir errores de proceso e implementación.

## 2.2. BASES TEÓRICAS

### 3.1.1. *Definición De Redes Neuronales Artificiales (RNA)*

Según (Nicolas, 2000) una red neuronal artificial no tiene una definición ampliamente acordada. Sin embargo, en este campo se acepta generalmente que una red neuronal artificial es una red de varios procesadores básicos ("unidades"), cada uno de los cuales puede tener una cantidad modesta de memoria local. Los



canales de comunicación ("conexiones") que vinculan las unidades suelen proporcionar datos numéricos en lugar de información simbólica. Las unidades solo utilizan para funcionar sus datos locales y las entradas que obtienen de las conexiones.

Para (Samarasinghe, 2006) una red neuronal práctica se puede definir de manera más amplia como un grupo de neuronas interconectadas que aprenden gradualmente de su entorno (datos) para identificar patrones lineales y no lineales importantes en datos complejos, haciendo predicciones precisas para escenarios novedosos incluso con información ruidosa e incompleta. La unidad informática más simple es la neurona de componentes en una red que manejan el procesamiento de datos local. La estructura de la red, es decir, cómo están dispuestas y conectadas las neuronas entre sí, determina la función de las redes masivamente paralelas formadas por estas neuronas. Este diseño determinará la fuerza de las conexiones entre las neuronas y el procesamiento que tiene lugar dentro de las neuronas.

Según (Lizcano, 2008), un algoritmo conocido como red neuronal funciona de manera similar al cerebro, que esencialmente aprende de la experiencia. Consta de componentes fundamentales llamados neuronas que reciben, procesan y comunican información a otras neuronas.

Al ajustar los parámetros internos de la red a lo largo de un proceso de aprendizaje, las redes neuronales artificiales (que son modelos que representan funciones no lineales) pueden simular un determinado trabajo.



### 3.1.2. **Fundamento de las redes neuronales artificiales:**

Las redes neuronales biológicas vistas en el cerebro humano sirven como modelo para las redes neuronales artificiales o RNA. Están compuestas por componentes que, en sus operaciones más básicas, actúan de manera similar a las neuronas reales. Estos componentes están dispuestos de manera similar a como está el cerebro humano. (Olabe, 2011)

Además de "parecerse" al cerebro, las RNA exhiben una serie de rasgos exclusivos del cerebro. Por ejemplo, las RNA abstraen las tipologías clave de una serie de datos, generalizan de casos anteriores a casos nuevos y aprenden de la experiencia:

**Aprender:** aprender cualquier cosa mediante la investigación, la práctica o la experiencia. Las RNA son capaces de adaptar su comportamiento a su entorno. Cuando se les da un conjunto de entradas, se autocorrigen para proporcionar resultados confiables.

**Generalizar:** agrandar o prolongar algo. La estructura y naturaleza inherentes de las RNA les permiten generalizarse de forma natural. Debido a los efectos de la distorsión o el ruido, estas redes pueden proporcionar respuestas precisas, dentro de un rango, a entradas que exhiben pequeñas fluctuaciones.

**Abstraer:** separar mentalmente o pensar en los atributos de un objeto individualmente. Ciertas RNA tienen la capacidad de abstraer el atributo de una colección de inputs que no parecen compartir ninguna característica.


#### 2.2.1.1. **La neurona cerebral biológica.**

El componente básico del sistema nervioso, y especialmente del cerebro, es la neurona. Las señales desde y hacia otras neuronas son recibidas y combinadas

por cada neurona, que es una unidad de procesamiento básica. La salida de la neurona se activa si las entradas son lo suficientemente potentes. La Figura 1 ilustra los componentes de una neurona biológica. (Olabe, 2011)

### Figura 1.

*Neurona biológica.*



*Nota. (Olabe, 2011),*

Uno o varios miles de millones de neuronas intrincadamente interconectadas forman el cerebro.


A través de conexiones conocidas como sinapsis, el axón (salida) de la neurona se ramifica y se une a las dendritas (entradas) de otras neuronas. Durante el proceso de aprendizaje en red, la eficacia de la sinapsis podría cambiar.

#### 2.2.1.2. La neurona artificial.

Un procesador, neurona o perceptrón elemental es una unidad informática básica que produce una única respuesta o salida dependiendo de un vector de entrada del entorno o de otras neuronas. La Figura 2 muestra los componentes que forman la neurona artificial.

Figura 2.

Neurona Artificial



Nota. (Guerrero Marquez & Garcia Benites, 2018)

De (Cox, 1993), dado que la suma ponderada sirve como regla de propagación y la identidad sirve como función de salida, la neurona típica está hecha de:

- Dependiendo de la aplicación, un conjunto de entradas ( $t$ ), puede ser analógica continua o binaria (digital).
- Algunos pesos sinápticos relacionados con la entrada,  $w_{ij}$ , que en este caso especifican la fuerza entre la neurona presináptica  $j$  y la neurona postsináptica  $i$ . La red puede realizar un trabajo específico y adaptarse a cualquier entorno modificando los pesos sinápticos.
- Una regla de propagación  $(t) = \sigma(w_{ij}, x_j(t))$  que permite determinar el valor del potencial postsináptico  $n_i$  de la neurona a partir de las entradas y los pesos.

$$n_i(t) = \sigma(w_{ij}, x_j(t))$$

- Una función de activación  $Y(t) = f(n_i(t))$  Esto muestra simultáneamente el estado de actividad y la producción de la neurona. Se encarga de dotar al



procesamiento en los nodos de propiedades no lineales. La función limita el desarrollo numérico de la función de entrada actuando sobre el valor que devuelve. Las funciones de activación se presentan en diversas formas; La **tabla 2** enumera los más populares. En esta tabla se muestran los atributos principales y la representación visual de cada una de estas funciones.

- Una función que produce la salida actual de la neurona  $y(t)$  en relación con su estado de activación actual  $ai(t)$ . La función de salida suele ser simplemente la identidad  $F(x)=x$ , lo que significa que el estado de activación de la neurona se considera como la salida misma:

$$yi(t)=Fi(ai(t))=ai(t)$$

Entonces la neurona  $i$  se puede describir de la siguiente manera:

$$y(t) = Fi(fi(ai(t-1),\sigma_i(w_{ij},x_j(t))))$$

- Luego, el argumento de la función de activación se establece restando el potencial postsináptico del conjunto de pesos de la neurona por un parámetro adicional  $\theta_i$ , al que nos referiremos como umbral (señal mínima detectada por un sistema).

$$\Sigma w_{ij}x_j - \theta_i$$

- El comportamiento de la neurona ahora se puede determinar haciendo  $w_{i0} = \theta_i$  y  $x_0 = -1$  (constante) y suponiendo que los índices  $i$  y  $j$  comienzan en 0:


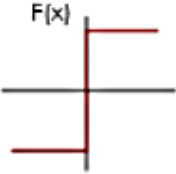
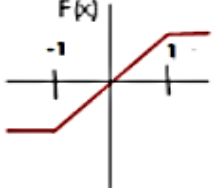

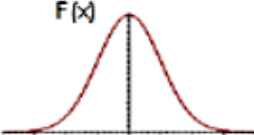
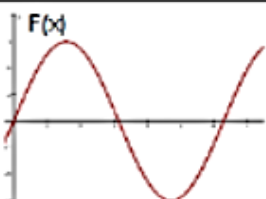
$$y(t) = fi(\Sigma W_{ij}X_j) \quad n_j = 0$$

- Es suficiente especificar la forma de la función de activación para conocer completamente la neurona estándar. Para abordar un aspecto particular del

problema que la neurona intenta resolver, se selecciona una función de transferencia.

**Tabla 2**

*Funciones de activación más comunes*

	<b>Función</b>	<b>Intervalo</b>	<b>Gráfica</b>
<b>Identidad</b>	$y = x$	$[-\infty, +\infty]$	
<b>Escalón</b>	$y = \text{sgn}(x)$ $y = H(x)$	$[-1, +1]$ $[0, +1]$	
<b>Lineal por tramos</b>	$y = \begin{cases} -1, & \text{si } x < -1 \\ x, & \text{si } -1 \leq x \leq 1 \\ +1, & \text{si } x > 1 \end{cases}$	$[-1, +1]$	
<b>Sigmoide</b>	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
<b>Gaussiana</b>	$y = Ae^{-\beta x^2}$	$[0, +1]$	
<b>Senoidal</b>	$y = A \text{sen}(wx + \varphi)$	$[-1, +1]$	

*Nota.* Elaboración propia



### **3.1.3. Entornos de una red neuronal artificial.**

Según (OSORIO, 2008), una red neuronal es un procesador distribuido con un tremendo paralelismo que naturalmente almacena y utiliza conocimiento experimental. En dos sentidos, es similar al cerebro:

- La red neuronal aprende nueva información mediante un procedimiento.
- Los "pesos sinápticos", o las fortalezas de las conexiones, se utilizan para almacenar información.

Como se dijo anteriormente, una red neuronal está compuesta de unidades de procesamiento, que son las mismas unidades que forman una neurona artificial y se les puede enseñar a aprender basándose en el método de entrenamiento y ordenamiento neuronal de la red expandirse a varias categorías de redes neuronales.

Desde el punto de vista estadístico (Bejarano, 2017), el análisis de regresión utilizando una red neuronal artificial (RNA) produce un "reemplazo" de un modelo o sistema genuino. Debido a su parecido con las redes cerebrales biológicas, se emplea la palabra.

Una definición amplia de REGRESIÓN es un modelo o sistema que puede hacer predicciones o generalizaciones basadas en un conjunto de hechos iniciales.

En consecuencia, existen regresiones que son lineales, polinómicas, de RED, etc. desde este punto de vista estadístico. Para resolver desafíos de ingeniería, se utilizan redes neuronales artificiales para la regresión de sistemas altamente no lineales.



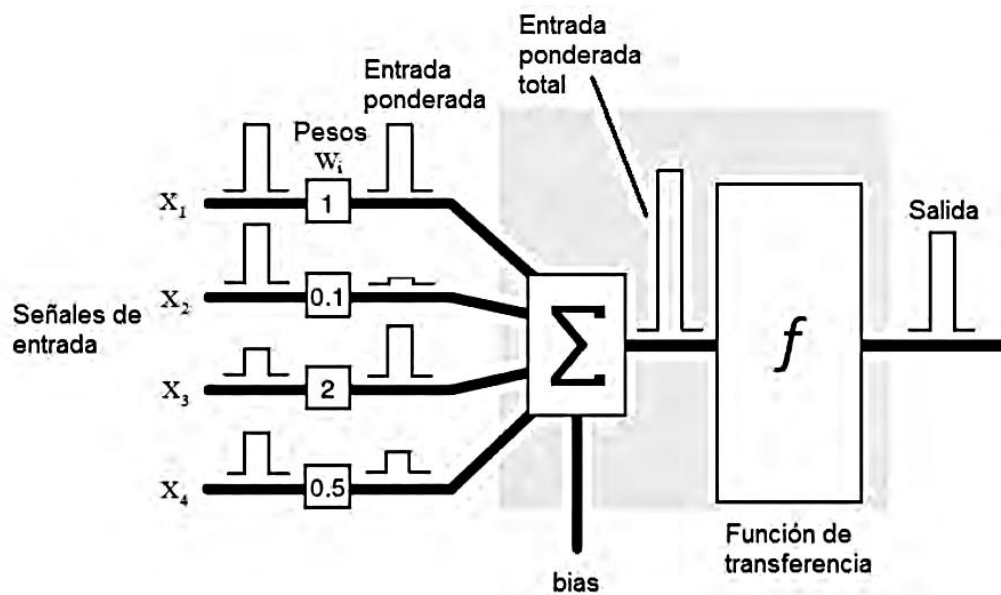
### 3.1.4. Elementos de una red neuronal.

1. **Entradas o nodos de entrada:** dependiendo del tema que se esté estudiando, la red recibe estos escalares.
2. **Salidas o nodos de salida:** son los valores devueltos por la red después del aprendizaje.
3. **Un conjunto de pesos sinápticos o simplemente pesos:** el significado de la entrada asociada se expresa mediante estos valores numéricos. La neurona K recibe el valor de entrada  $X_i$  multiplicado por el peso  $W_{ik}$ . (La entrada se indica con el primer subíndice de los pesos y la neurona en cuestión con el segundo).
4. **Un punto de suma de entradas ponderadas:** aquí, todas las entradas se multiplican por sus respectivos pesos para crear una combinación lineal o total.
5. **Una función de activación:** es una función que restringe el rango de salida de la neurona y puede ser lineal o no lineal.
6. **Sesgo:** es un valor formado por una entrada fija e igual a 1,  $X_0$ , multiplicado por  $W_{0k}$ , el peso.

Según la información proporcionada, podemos mostrar los componentes de la red neuronal en las Figuras 3 y 4 a continuación

**Figura 3.**


*Componentes de una Red Neuronal Artificial*



*Nota. (Sifontes, 2010)*

**Figura 4**

*Estructura de una red neuronal*



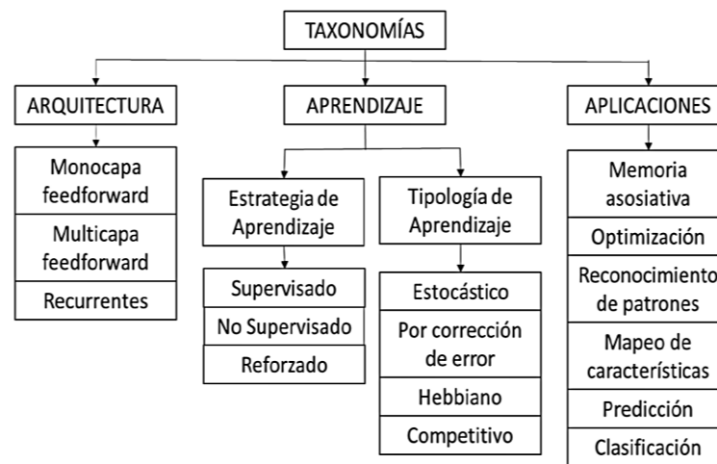
*Nota. (Guerrero Marquez & Garcia Benites, 2018)*

### 3.1.5. Clasificación de redes neuronales artificiales.

La siguiente es una definición de taxonomía de redes neuronales artificiales:

Figura 5.


Taxonomía de redes neuronales artificiales



Nota. (Tello, 2017).

Figura 6.

Clasificación de RNA, por su Arquitectura



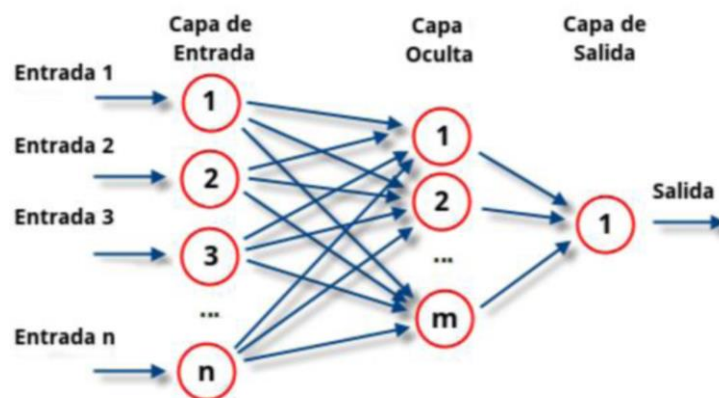
Nota. (Valdés Holguín, 2011)

### 3.1.6. *Perceptron multicapa.*

Las redes pueden ser de naturaleza de retroalimentación o avance. Este último se diferencia en que los datos procesados se devuelven como entradas de red. Contamos con redes de tipo retroalimentación tanto competitivas como recurrentes. Una de las redes de tipo feedforward es la red de perceptrones. La Figura 7 muestra una red neuronal recurrente (retroalimentación).

**Figura 7.**

*Red recurrente perceptron MULTICAPA.*

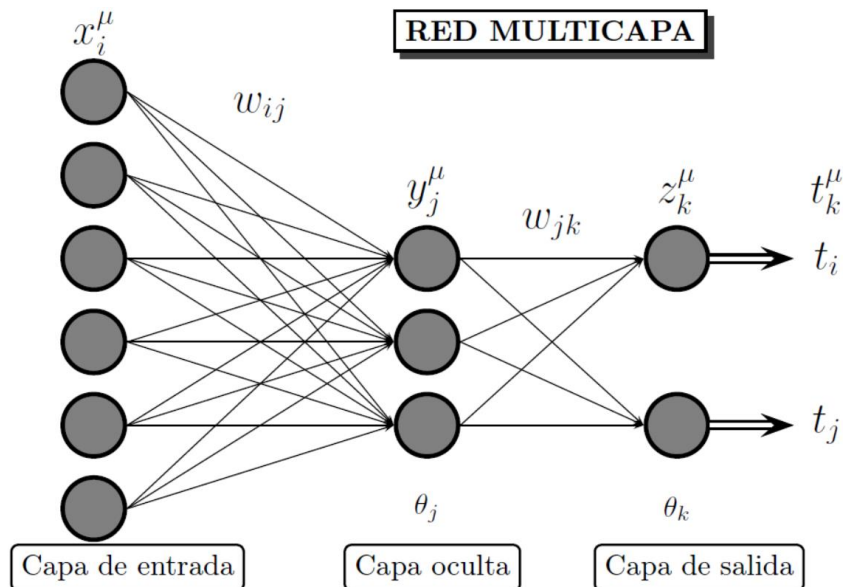


*Nota. (Bejarano, 2017)*

Esta red tiene un alto grado de conectividad, tiene una o más capas ocultas y tiene funciones de activación diferenciables. Consiste en una configuración de perceptrones, el tipo más básico de red neuronal, creado por (Bejarano, 2017).

Al clasificar patrones linealmente separables, el perceptrón es esencialmente una única neurona con pesos sinápticos programables y un umbral de activación.

**Figura 8.**  
*Red Multicapa.*



Nota. (benitez, 2009)

### 3.1.7. Redes neuronales artificiales según su aprendizaje.

Se considera que la red aprende de la experiencia y el aprendizaje se logra a través del proceso de capacitación. Cuando se ajustan los pesos ( $W$ ) y los sesgos ( $\mu$ ) de la red, se produce el aprendizaje. Esto se logra propagando los errores hacia atrás. (Bejarano, 2017)

Hay dos tipos de aprendizaje:

- Aprendizaje supervisado:** Necesita interferencia externa. Cuando se proporcionan datos de entrada y salida.
- Aprendizaje no supervisado:** No necesita ayuda externa. Ocurre cuando solo se requieren los datos de entrada.

#### A.- APRENDIZAJE SUPERVISADO


Estas redes ven la autoorganización y la auto asociación como procedimientos para adquirir la producción de la red porque carecen de un punto de referencia para comparar. Se distingue por el hecho de que el resultado no necesita comparación con un conocimiento particular preexistente (maestro). El aprendizaje no supervisado, a menudo denominado aprendizaje auto supervisado, se describe con frecuencia como si tuviera la capacidad de autoorganizarse, ya que no necesita intervención externa para modificar los pesos de las conexiones entre sus neuronas. (Tello, 2017)

### B.- APRENDIZAJE NO SUPERVISADO

Tener un supervisor durante el entrenamiento de la red indica que ya se conoce un parámetro de referencia (maestro) y se compara con las salidas de la red. El aprendizaje supervisado se define como la capacitación administrada por un agente externo que elige la respuesta que la red debe producir dada una entrada. Cuando la salida de la red no coincide con la salida esperada, el supervisor la revisa y ajusta los pesos de la conexión para asegurarse de que la salida esté lo más cerca posible de la salida deseada. (Tello, 2017)

**Figura 9**

*Esquema de aprendizaje supervisado*



*Nota. (Perez, 2009)*

Por lo tanto, el conjunto de reglas establecidas con precisión que se utilizan para resolver un problema de aprendizaje podría denominarse algoritmo de entrenamiento.

**Tabla 3.**

*Tipos de aprendizaje Supervisado.*

TIPO DE APRENDIZAJE SUPERVISADO		MODELO DE RED
APRENDIZAJE POR CORRECCIÓN DE ERROR	off line	PERCEPTRON
		ADALINE/MADALINE
		BACKPROPAGATION
		BRAIN - STATE-IN-A-BOX
		COUNTERPROPAGATION
APRENDIZAJE POR REFUERZO	on line	LINEAR REWARD PENALTY
		ASSOCIATIVE REW, PENALTY
		ADAPTIVE HEURISTIC CRITIC
APRENDIZAJE ESTOCÁSTICO	off line	BOLTZMANN MACHINE
		CAUCHY MACHINE

Nota. Clasificación

### C.- PRUEBAS.

(Bishop, 1996), la red está preparada para realizar pruebas con patrones no relacionados con el entrenamiento una vez determinados estos pesos. El objetivo de esta verificación es ver cómo se comporta la red cuando las entradas son diferentes de las que se utilizaron para el entrenamiento. La sobre especialización (comportamiento óptimo con las instancias de entrenamiento, con situaciones distintas con errores importantes) es una preocupación al entrenar una red neuronal e intentar reducir el error. Para evitar perder generalidad, la reducción de errores debe realizarse de forma cuidadosa y equilibrada. Cuando la red está operativa, sus pesos, conexiones, neuronas y arquitectura están configurados y preparada para su uso. El equipo de prueba debe ser:



- importante (debe tener instancias de cada clase reconocida)
- representacional (debe mantener las relaciones de ejemplos del conjunto de entrenamiento)

## 2.3. MARCO CONCEPTUAL

### 3.1.8. Algoritmos

Los algoritmos son conjuntos de procesos matemáticos internos que se deben seguir para solventar un inconveniente determinado. En el campo de la automatización, el término se circunscribe a una técnica para resolver un problema que puede implementarse como un programa informático.

### 3.1.9. Aprendizaje de una red neuronal artificial RNA

El método de aprendizaje de una ANN implica cambiar los pesos de la conexión hasta que la respuesta de la ANN replique las características deseadas. Otros problemas que sean iguales o comparables podrán resolverse utilizando esto

### 3.1.10. Inteligencia Artificial Ia.

El objetivo de la IA es investigar el comportamiento inteligente de las computadoras. Percibir, pensar, aprender, comunicar y actuar en contextos complicados son todos componentes del comportamiento inteligente. Crear computadoras que sean tan buenas o incluso mejores que los humanos en todas estas tareas es uno de los objetivos a largo plazo de la inteligencia artificial.

### 3.1.11. Redes neuronales artificiales.

La construcción y operación de redes neuronales artificiales (RNA), que son procedimientos de procesamiento de información, se modelan a partir de redes neuronales biológicas. Están formados por una colección de componentes de



procesamiento básicos conocidos como nodos o neuronas artificiales que están unidos por conexiones con un peso, un valor numérico que se puede cambiar. El propósito de una neurona artificial es sumar los valores de las entradas de otras unidades que están vinculadas a ella por sus pesos individuales. Esta suma luego ingresa a una función de activación, que es la misma función que permite salidas (output). A través de un proceso de aprendizaje, se enseña a una RNA a realizar un determinado trabajo.

### **3.1.12. Sistemas expertos.**

Son un área de la inteligencia artificial que utiliza una gran cantidad de conocimiento especializado para resolver problemas de manera similar a la de un experto humano. Es un programa informático que simula la capacidad de un experto humano para tomar decisiones. La idea fundamental detrás de un SE es que el usuario proporciona información al SE y recibe orientación a cambio. APPS es una colección de pautas integrales que regulan las operaciones de un sistema informático para permitirle abordar ciertos problemas.

### **3.1.13. Agregado fino:**

De esta manera se tienen en cuenta los materiales con un tamaño inferior a 4,76 mm, en su mayoría arena.

### **3.1.14. Agregado grueso:**

Así, se tienen en cuenta materiales que están compuestos mayoritariamente de grava y cuyo tamaño oscila entre 56 mm y 4,76 mm.

### **3.1.15. Arenas:**

Partículas mayores de 0,075 mm y menores de 2 mm.



### **3.1.16. Cantera:**

Ubicación de recursos utilizados para la obra civil o la industria de la construcción.

### **3.1.17. Contenido óptimo de humedad:**

La cantidad de agua necesaria para alcanzar la densidad seca máxima de un suelo.

### **3.1.18. Densidad:**

El vínculo entre el peso de un suelo en un determinado volumen se conoce como densidad. Conocer el contenido de humedad ideal permite alcanzar una densidad máxima. El examen Proctor se puede utilizar para determinar esto.

### **3.1.19. Gradación:**

La prueba de análisis granulométrico MTC E 107, que mide la distribución de tamaños de partículas a través de tamices con diferentes tamaños de apertura, es otro nombre para la granulometría, que es el estudio de los distintos tamaños de partículas que están presentes en un suelo o agregado.

### **3.1.20. Gradaciones continuas:**

En este tipo de partículas hay poca fluctuación en el tamaño de las partículas; En este caso, destacamos la piedra triturada con tamaños consistentes.

### **3.1.21. Gradaciones discontinuas:**

Los áridos naturales son un ejemplo de este tipo, que tienen una amplia gama de tamaños de partículas y una pendiente suave y continua.

### **3.1.22. Grava:**

Suelos con dimensiones Menres de 75 mm y más de 2 mm de tamaño.



### **3.1.23. Índice de plasticidad:**

Distinción entre las limitaciones plásticas y líquidas de un suelo.

### **3.1.24. Limo y arcilla:**

Partículas de menos de 0,075 milímetros.

### **3.1.25. Suelo:**

Colección de fragmentos minerales que resultan de la descomposición mecánica o química de las rocas.

### **3.1.26. Tamiz:**

Utilizando un conjunto estandarizado de tamices ASTM, se utiliza un instrumento compuesto por mallas o aberturas para separar los distintos tamaños de partículas de un suelo o agregado.

## **2.4. MARCO NORMATIVO**

### **3.1.27. Norma e.080 diseño y construcción con tierra reforzada.**

La pauta tiene trascendencia nacional y debe seguirse en la producción de materiales de construcción para estructuras de tierra armada (elementos de suelo reforzado y adobe armado).

La norma cubre la actuación de los muros de adobe, los componentes estructurales básicos de las estructuras de tierra armada, el diseño sismorresistente de las edificaciones de tierra armada y las propiedades mecánicas de los materiales utilizados para crearlas y tierra apisonada, de acuerdo con la teoría del diseño sismorresistente.



### **3.1.28. Manual de ensayo de materiales MTC 2016**

Este manual describe las técnicas, pasos, herramientas, cálculos e informes que deben crearse para probar los diversos materiales que se usarán en la construcción de infraestructura vial.



## CAPÍTULO III

### MÉTODO DE LA INVESTIGACIÓN

#### 3.2. MÉTODO DE LA INVESTIGACIÓN

##### 3.2.1. *Método general*

De acuerdo con M. Borja (2012), la exploración de la conexión causa-efecto se adapta al enfoque experimental.

Como parte del enfoque experimental, la investigación realizará pruebas en un laboratorio de suelos de acuerdo con los criterios del Manual de pruebas de materiales ASTM D4318 y ASTM D2487.

##### 3.2.2. *Proceso de investigación.*

**Etapa 1.** Se recolectaron especímenes de muchos lugares del área de Juliaca para crear una muestra de suelo.

**Etapa 2.** En el laboratorio de suelos, el conjunto de variables consideradas como independiente e influyente.



**Etapa 3.** La muestra de arcilla adquirida se dividió en grupos utilizando técnicas convencionales definidas para elegir suelos utilizables en mezclas BTC.

**Etapa 4.** Basado en los grupos descubiertos en la etapa 3, se creó un modelo de red neuronal que puede reemplazar la experiencia como herramienta para elegir qué suelos emplear en una combinación destinada a la fabricación de BTC.

### **3.3. TIPO DE INVESTIGACIÓN**

Debido a que el proceso de identificación de suelos usando modelos RNA se examina en relación con las metodologías empíricas estandarizadas según ASTM D4318 y ASTM D2487, la exploración en cuestión será descriptivo-comparativo.

### **3.4. NIVEL DE INVESTIGACIÓN**

Debido a que el estudio se centra en clasificar suelos utilizando redes neuronales artificiales con la intención de emplear los hallazgos en la construcción de bloques de tierra comprimida, la metodología es aplicable. La estrategia es más realista y centrada en resolver determinadas cuestiones geotécnicas.

### **3.5. DISEÑO DE INVESTIGACIÓN**

Como las variables están conectadas y es a nivel DESCRIPTIVO – COMPARATIVO, es puramente experimental.

"Mediante la modificación de variables, el experimento es un proceso riguroso que se utiliza para probar hipótesis", según Vara Horna (2008). También es uno de los componentes esenciales del método científico.

Hay ciertos componentes clave en los diseños experimentales:



- **Manipulación de variable independiente:** La variable dependiente es alterada por la variable independiente.
- **El grado en que la variable independiente influye en la variable dependiente:** Es la medida del impacto de la variable independiente.
- **Control interno de la situación experimental:** Las variaciones en la variable independiente provocan cambios en la variable dependiente.
- **Para controlar factores sin importancia:** A cada miembro se le asigna un número aleatorio de una tabla.

## 3.6. POBLACIÓN Y MUESTRA

### 3.5.1. Población

Se constituye por los materiales y/o suelos muestreados en la ciudad de Juliaca.

### 3.5.2. Muestra

Se constituye por los suelos de tres tipos de canteras de suelo de propiedades adecuadas para la elaboración de BTC's.

## 3.7. TÉCNICA FUENTES E INSTRUMENTOS DE LA INVESTIGACIÓN

### 3.6.1. Técnicas de la investigación

Borja, (2012), definió la observación "Debido a que las actividades se ven, la percepción deliberada e ilustrada de un fenómeno de realidad es sencilla".

Los siguientes elementos están incluidos en la creación siguiente:

Evaluar las gradaciones y propiedades de los materiales:

- Análisis granulométricos.



- Estados de consistencias.
- Normativas para caracterizaciones de suelos.
- Diseños de softwares para RNA.

### **3.6.2. Instrumentos de la investigación**

#### 1. Muestreo:

- ASTM D4318
- Norma: MTC E 103 y MTC E 201.
- Herramientas manuales: Sacos, bolsas, palas etc.

#### 2. Gradaciones y propiedades de los materiales:

##### **Análisis granulométrico:**

- Norma: MTC E 107 y MTC E 204.
- Equipos: Juego de tamices serie ASTM, balanzas, horno.
- Herramientas: Cucharón, brocha, recipientes.
- Ficha técnica de recolección de datos.

##### **Estados de consistencia:**

- Norma: MTC E 110 y MTC E 111.
- Equipos: Cuchara casa grande, espátula normalizada, horno, balanzas, etc.
- Herramientas: Cucharón, brocha, recipientes etc.
- Ficha técnica de recolección de datos.
- Carta de plasticidad.
- ASTM D2487

Software adecuado que permita diseñar y entrenar RNA para el objetivo del estudio.

### 3.8. FUENTES

#### 3.8.1. *Suelo de canteras utilizadas posibles para elaboración de BTC's:*

- **Ubicación:** distrito de Juliaca, provincia de San Román región Puno
- **Propiedad:** privados.
- **Potencia:** De aprox. 1.000.000.00 m<sup>3</sup>.
- **Origen:** coluvial.
- **Tipo:** Cantera de suelo residual.
- **Muestra:** Se tomarán muestras pasantes del Tamiz de 4".

#### Figura 10

*Cantera de la ciudad de Juliaca.*



Nota. Según estudio.

#### 3.8.2. *Fuentes de información*

- Norma E.080 Diseño y construcción con tierra.
- ASTM D4318
- ASTM D2487
- *Manual de ensayo de materiales MTC 2016*



### 3.9. VALIDEZ Y CONFIABILIDAD DEL INSTRUMENTO

Los datos producidos por las RNA utilizadas en el proceso de diseño se compararán y verificarán con los datos recopilados.

#### 3.9.1. *Validez del instrumento*

La validez, según Horna (2008), es el grado en que un instrumento realmente mide la variable que dice medir y la cantidad de evidencia que se ha reunido sobre lo que mide el instrumento.

El margen de error alcanzado en los datos producidos por la RNA tendrá una incidencia directa en la validez del instrumento.

#### 3.9.2. *Confiabilidad del instrumento*

Horna (2008) afirma que la confiabilidad se correlaciona con la precisión y la coherencia, se refiere al grado en que la aplicación produce resultados reales y se evalúa mediante comparación y correlación.

### 3.10. PROCEDIMIENTOS

#### 3.10.1. *Identificación y clasificación de suelos mediante redes neuronales artificiales*

Para abordar adecuadamente el problema, se implementó en muchas fases el procedimiento de categorización del suelo mediante redes neuronales artificiales (RNA). El primer paso fue formular el problema, que consistía en comparar el Sistema Unificado de Clasificación de Suelos (SUCS), un método de clasificación convencionalmente reconocido, con la viabilidad de utilizar RNA en la identificación y clasificación de suelos para su posterior uso en el diseño de Tierra Comprimida. Bloques (BTC). Se tomaron una serie de acciones para resolver este problema. Primero, se recopiló y examinó información pertinente sobre los suelos utilizados



para fabricar BTC, tanto cualitativa como cuantitativamente. Estos datos incluían detalles cruciales sobre las características y composición de los suelos, que se utilizarían como base para la capacitación de las RNA.

Después de eso, se crearon y configuraron RNA (algoritmos de aprendizaje automático modelados según la forma en que funciona el cerebro humano). Para permitir que estas redes identifiquen patrones y creen asociaciones entre las propiedades del suelo y la categorización, se entrenaron utilizando datos recopilados previamente. Tras la formación, se evaluó la eficacia y precisión de las RNA en la clasificación del suelo. Esto se logró comparando la clasificación realizada mediante SUCS con los resultados producidos por las RNA. Para evaluar la eficacia y confiabilidad de las RNA en este procedimiento, se llevaron a cabo pruebas exhaustivas y se evaluaron indicadores de desempeño).

### **3.10.2. Recolección y preparación de datos**

La primera fase del proceso se concentró en recolectar y preparar la información requerida para la categorización de los suelos utilizados en la producción de bloques de tierra comprimida (BTC). Para hacer esto, se utilizaron enfoques cuantitativos y cualitativos estandarizados para recopilar datos pertinentes y construir una base de datos histórica que incluía caracterizaciones del suelo, todo ello respetando las leyes establecidas. En primer lugar, se determinaron los principales factores que influyen en el proceso de clasificación del suelo. Estos factores incluyeron las propiedades mecánicas, químicas y físicas del suelo, incluida la granulometría, los límites de Atterberg, la densidad y la permeabilidad, entre otros. Para garantizar la exactitud y coherencia de los datos recopilados, se creó un procedimiento de recopilación de datos. A la luz de la diversidad de tipos de suelo y condiciones encontradas en el área de investigación, se realizaron



muestreos de suelo representativos en varias regiones geográficas. Considerando la profundidad, la distribución geográfica y la cantidad necesaria para realizar las pruebas esenciales, se siguieron métodos apropiados para adquirir muestras representativas.

Se utilizaron técnicas cuantitativas y cualitativas estandarizadas para examinar y evaluar las muestras de suelo que se recolectaron. Estos incluyeron procedimientos de laboratorio como medición de densidad, determinación del límite de Atterberg, análisis granulométrico y evaluación de los atributos táctiles y visuales del suelo. Estos experimentos describieron detalladamente las propiedades físicas y químicas de los suelos. A partir de los resultados de las pruebas se construyó una base de datos histórica que documenta la caracterización de los suelos de acuerdo con las reglas establecidas. Se estructuró esta base de datos, que incluía datos tanto cuantitativos como cualitativos de cada muestra de suelo. A cada tipo de suelo se le asignó una etiqueta correspondiente una vez que los datos se clasificaron utilizando los criterios de clasificación predeterminados. Las Redes Neuronales Artificiales (RNA) fueron entrenadas y validadas utilizando esta información histórica. Los datos recopilados se utilizaron para entrenar a las RNA, que enseñaron a las redes a identificar patrones y crear asociaciones entre la categorización de las propiedades del suelo. La base de datos también se utilizó para evaluar la precisión y resistencia de las RNA durante la fase de validación, cuando se contrastó el resultado de las RNA con las clasificaciones realizadas de acuerdo con pautas predeterminadas.

### ***3.10.3. Diseño y entrenamiento de la red neuronal***

Se crearon y entrenaron redes neuronales artificiales (RNA) para simular las pruebas de clasificación de suelos de acuerdo con la norma ASTM D2487



recopiladas los datos. Con el fin de encontrar suelos apropiados para la producción de Bloques de Tierra Comprimida (BTC), en este punto se utilizaron métodos de inteligencia artificial para correlacionar con precisión las evaluaciones cuantitativas y cualitativas. Al diseñar las RNA se tuvieron en cuenta la arquitectura y configuración adecuadas para el desafío de clasificación del suelo. En función de los objetivos del proyecto y las propiedades de los datos, se eligieron modelos de redes neuronales adecuados, como redes neuronales feedforward o redes neuronales convolucionales. Para obtener el máximo rendimiento, se tuvieron en cuenta otros factores, incluido el número de capas ocultas, el número de neuronas en cada capa y las funciones de activación más adecuadas. Una vez creadas las RNA, se utilizaron para la capacitación los conjuntos de datos históricos proporcionados anteriormente.

Las RNA fueron capacitadas para identificar patrones y crear asociaciones entre los resultados previstos (categorización del suelo) y los datos de entrada (pruebas cuantitativas y cualitativas). Las conexiones centrales y los pesos de las redes se modificaron utilizando métodos de aprendizaje automático, incluido el descenso de gradiente estocástico, para maximizar su capacidad de categorización precisa. Se utilizaron iteraciones a lo largo de la fase de entrenamiento para modificar los parámetros de las RNA y evaluar qué tan bien se desempeñaron en un conjunto de validación. Al hacer esto, pudimos regular el sobreajuste y el desajuste de las redes, garantizando que pudieran generalizarse a nuevos datos y evitar la memorización de muestras de entrenamiento. Después del entrenamiento, se utilizó un conjunto de datos de prueba independiente para evaluar el rendimiento de las RNA. La precisión y confiabilidad de las RNA en la identificación de suelos



apropiados para la producción de BTC se evaluaron comparando su producción con clasificaciones realizadas de acuerdo con la norma ASTM D2487.

### **3.10.4. Validación del modelo**

Después de diseñar y entrenar las redes neuronales artificiales (RNA), el modelo se verificó contrastando los resultados utilizando técnicas empíricas que se estandarizaron de acuerdo con las normas ASTM D4318 y ASTM D2487. El objetivo de esta etapa fue examinar la relación entre la identificación del tipo de suelo realizada por las RNA y la identificación adquirida en el laboratorio. Para realizar la validación se eligió un conjunto de datos independiente que no se utilizó para el entrenamiento de las RNA. Las muestras de suelo de este conjunto de datos se examinaron en un laboratorio profesional de acuerdo con las normas ASTM D4318 y ASTM D2487. Los resultados de laboratorio sirvieron de base para las categorías de referencia. Luego, este conjunto de datos de validación se sometió al modelo RNA previamente entrenado. Las RNA produjeron predicciones de clasificación después de procesar las pruebas cuantitativas y cualitativas de las muestras de suelo. Estos pronósticos se contrastaron con calificaciones de referencia obtenidas en laboratorio. Las clasificaciones del modelo RNA y las clasificaciones de referencia se compararon mediante un análisis de correlación. La concordancia entre clasificaciones se midió utilizando criterios de evaluación como la matriz de confusión, la precisión y el índice Kappa.

Pudimos evaluar la precisión del modelo RNA a la hora de identificar los distintos tipos de suelo gracias a estas mediciones. Para determinar la importancia de la asociación entre las clasificaciones de referencia y las clasificaciones del modelo RNA, también se realizaron pruebas estadísticas. Se examinó el vínculo entre las variables y se evaluó la confiabilidad del modelo utilizando técnicas como



la prueba de chi-cuadrado y el coeficiente de correlación de Pearson. Pudimos evaluar la capacidad del modelo RNA para clasificar tipos de suelo pertinentes para la producción de BTC de manera precisa y confiable mediante su validación. Los resultados en este punto proporcionan una evaluación imparcial del desempeño del modelo y su generalización a datos nuevos.

### **3.10.5. Comparación con estudios previos**

El método utilizado en este estudio para clasificar suelos para la producción de Bloques de Tierra Comprimida (BTC) utilizando Redes Neuronales Artificiales (RNA) se comparó con investigaciones anteriores realizadas por Valdés Holguín (2011) y Carreño (2018). En estos trabajos, se emplearon RNA para determinar el módulo de resiliencia y estimar los parámetros del suelo en situaciones agrícolas, respectivamente. Pudimos evaluar la eficacia y la idoneidad de las RNA en el área de la geotecnia comparando estas investigaciones anteriores. Valdés Holguín (2011) realizó una investigación que se centró en la aplicación de RNA para la estimación de parámetros del suelo en entornos agrícolas.

Este estudio demostró que las RNA podían predecir propiedades del suelo como la densidad aparente, la textura y la capacidad de retención de agua con gran precisión. Los resultados demostraron que las RNA podrían usarse para estimar los parámetros del suelo en un entorno agrícola. Sin embargo, el trabajo realizado por Carreño (2018) se concentró en utilizar RNA para identificar el módulo de resiliencia de los suelos. En ingeniería geotécnica, el módulo de resiliencia es una característica crucial ya que indica qué tan bien el suelo puede tolerar cargas y deformaciones. Los hallazgos de esta investigación mostraron que las RNA podían estimar de forma fiable el módulo de resiliencia de los suelos, lo que demuestra su uso en la caracterización geotécnica. Se descubrió que las RNA han demostrado



eficacia en la estimación de parámetros del suelo en diversos entornos y aplicaciones al comparar estas investigaciones anteriores con la metodología utilizada en el esfuerzo actual. Los resultados de investigaciones anteriores confirmaron la utilidad de las RNA en geotecnia y ofrecieron una base sólida para su uso en la categorización de suelos para la producción de BTC.

### 3.11. DISEÑO ESTADÍSTICO

Para examinar el vínculo entre las variables y observar el impacto de la variable independiente sobre la variable dependiente, en este estudio se utilizó un diseño estadístico descriptivo-comparativo puramente experimental. Pudimos controlar cualquier factor no relacionado que pudiera tener un impacto en los resultados y demostrar una asociación causal entre las variables gracias a este enfoque. El uso de redes neuronales artificiales (RNA) en el modelado de pruebas de clasificación de suelos es un ejemplo de modificación de la variable independiente en un diseño experimental puro. Manipulamos esta variable para ver cómo afectaba a la variable dependiente, que puede ser la precisión de la categorización del suelo para la producción de BTC. También se incluyó en este diseño el control interno de la configuración experimental para garantizar la confiabilidad de los hallazgos. Esto implica establecer entornos controlados y estandarizados para realizar las pruebas y utilizar las RNA. Por ejemplo, puede crear estándares precisos y uniformes para la categorización de suelos de acuerdo con ASTM D2487 utilizando una base de datos de pruebas de suelos anteriores. La asignación aleatoria de datos y muestras fue otro componente crucial del diseño estadístico. Esto se hizo para garantizar que las muestras del estudio fueran representativas de la audiencia prevista y para tener en cuenta cualquier posible factor no relacionado. Se redujo el sesgo y se aumentó la confiabilidad de los



resultados mediante la asignación aleatoria de muestras a los grupos de capacitación y validación.

### **3.12. ENFOQUE DE SUPERFICIE DE RESPUESTA**

En este artículo se sugiere el método de superficie de respuesta (RSM) como complemento del diseño estadístico experimental puramente descriptivo-comparativo. RSM es un enfoque que construye modelos que explican la conexión entre una variable de interés y muchas variables combinando metodologías estadísticas y matemáticas.

Maximizar la optimización de la variable focal (en este ejemplo, la precisión de la categorización del suelo para la producción de BTC) es el objetivo principal de RSM. RSM permite un análisis visual de cómo los parámetros del tratamiento afectan la respuesta dentro de un cierto rango de valores. Esto facilita la evaluación del impacto de cada componente y permite determinar las circunstancias ideales para lograr el más alto nivel de precisión en la clasificación del suelo.

Al utilizar RSM en esta investigación, se pueden crear más ensayos para investigar y modelar el vínculo entre la variable objetivo y las variables pertinentes, incluidos los parámetros de entrada de las RNA. En estos ensayos, los niveles de factor se pueden cambiar sistemáticamente y se pueden recopilar datos relacionados.

El vínculo entre los componentes y la variable focal puede describirse mediante modelos matemáticos que se construyen después de que se han recopilado los datos. Para describir gráficamente estos modelos se pueden utilizar gráficos de superficie de respuesta, que ilustran cómo cambia la respuesta según los valores de los componentes. Esto proporciona a la conexión una ilustración



clara y concisa y permite identificar las circunstancias ideales para maximizar la precisión de la categorización del suelo.

Al ofrecer un instrumento adicional para examinar y mejorar las variables que afectan la precisión de la categorización del suelo, RSM se utilizará en esta exploración para complementar el diseño experimental puramente descriptivo-comparativo. Para optimizar la precisión en la clasificación del suelo para la fabricación de BTC, esto proporcionará una mejor comprensión del vínculo entre los componentes y la variable objetivo y ayudará a tomar decisiones informadas.

### **3.13. FASES DEL PROCESO DE OPTIMIZACIÓN**

Ayala & Pardo (1995) identifique las tres etapas cruciales: selección preliminar, previsión exhaustiva y refinamiento final.

- A. Durante la Fase I, a menudo denominada selección, que inicia el proceso de optimización, varios factores generalmente pueden trascender debido a la falta de conocimiento sobre el comportamiento del proceso. Por tanto, saber cuáles son los más relevantes es crucial. Se recomiendan encarecidamente los diseños iniciales en esta etapa, particularmente los diseños factoriales como 2k y fraccional.
- B. El segundo paso de mejora, llamado escalado, se lleva a cabo cuando la posición óptima está lejos de la primera prueba, como lo muestran las circunstancias operativas. Durante esta fase se va acercando paulatinamente a la zona ideal hasta alcanzarla y localizarla. La "región experimental de respuestas estacionarias" es un punto en el que no resulta práctico mejorar las respuestas utilizando métodos anteriores; estas estrategias ayudarán a llegar a esta zona. Los efectos cuadráticos empiezan a importar en este punto y se



requieren modelos de segundo orden para caracterizar esta región. (Ayala y Pardo, 1995).

- C. Los impactos de segundo nivel en la Fase III son más pronunciados en valores absolutos que los efectos de nivel primario en el área experimental que incluye la zona óptima. Esto implica que los modelos matemáticos de segundo grado pueden representar con precisión este campo. Tras el establecimiento de un modelo matemático que representa con precisión la región ideal, se realizan esfuerzos para optimizar el modelo a fin de encontrar los valores más efectivos para las variables.



## CAPÍTULO IV

### RESULTADOS

#### 4.1. DESCRIPCIÓN DE LA BASE DE DATOS UTILIZADA

La base de datos utilizada en este estudio se construyó con la intención de utilizar redes neuronales artificiales (RNA) para analizar y categorizar suelos para su uso en la producción de bloques de tierra comprimida (BTC). Esta extensa base de datos aborda una serie de temas pertinentes a la descripción y elección de suelos apropiados para técnicas de construcción escalables y sostenibles.

Para determinar si los suelos son adecuados para producir Bitcoin, la base de datos incorpora una evaluación de las características básicas del suelo, incluida la distribución del tamaño de las partículas, los límites de Atterberg y la composición mineralógica (Bredenoord et al., 2023). Además, se podrían haber incluido detalles sobre el uso de cemento y fibras naturales como agentes estabilizantes, que pueden mejorar las cualidades mecánicas del BTC. (Kagonbé et al., 2022).

Una característica adicional notable de la base de datos de otros autores es la incorporación de características fisicoquímicas y espectros de reflectancia del horizonte del suelo, lo que facilita la identificación de perfiles de suelo y horizontes



particulares para fines de investigación (Arairo et al., 2022). Estos datos espectrales y fisicoquímicos proporcionan una imagen completa de las propiedades del suelo, lo que permite una categorización más precisa y una mejor comprensión de su comportamiento.

De manera similar, la base de datos compara las características geotécnicas de muestras de suelo de investigaciones anteriores para evaluar su idoneidad para la construcción (Kirillova et al., 2021). Esta comparación ofrece un punto de referencia útil para evaluar la calidad de los suelos y describe cómo emplear estabilizadores para mejorar aquellos que se consideran insuficientes.

En la Tabla 1 se muestra un extracto de la base de datos utilizada para mostrar los rasgos y atributos de 20 muestras de suelo. Pruebas de campo que incluyen la prueba de lavado de composición, prueba de adherencia de composición del suelo, prueba de plasticidad y cohesión del suelo, prueba de composición del suelo por adhesión y prueba de corte y La prueba de brillo está incluida en esta tabla. Junto con la expansión del suelo y la clasificación SUCS de cada muestra, también se muestran los porcentajes de grava, arena, limo y arcilla.

Tabla 4. Extracto de la base de datos utilizada para la clasificación de suelos mediante RNA..

**Tabla 4.**

*Extracto de la base de datos utilizada para la clasificación de suelos mediante RNA.*

Muestra	Prueba de lavado de composición	Prueba del bastón de composición del suelo	Plasticidad y cohesión del suelo	Composición del suelo Prueba de adherencia	Prueba de Corte y de brillo	% Grava	% Arena	% Limo	% Arcilla	Expansión del suelo	CLASIFICACION SUCS
1	3	0	0	0	0	0	4	88	8	2	10
2	3	0	0	0	0	0	3	74	23	2	10
3	2	1	0	0	0	0	0	78	22	2	10
4	3	-1	0	0	0	0	4	73	23	2	10
5	4	-1	-1	0	0	0	64	14	22	2	8
6	4	0	0	0	0	0	60	21	19	1	8
7	4	1	0	1	1	0	40	33	27	2	8
8	3	0	0	0	1	0	63	21	16	1	8
9	4	-1	-1	0	0	0	2	22	23	1	13
10	4	-1	-1	0	0	0	53	23	24	2	10
11	3	1	0	0	1	0	60	23	17	1	10
12	2	1	1	1	1	0	84	16	0	1	8
13	4	0	0	1	1	0	69	0	31	1	8
14	4	0	0	0	0	0	73	0	27	1	8
15	4	-1	-1	0	-1	0	59	15	26	2	10
16	3	-1	0	1	0	0	70	15	15	1	10
17	3	1	0	1	0	0	70	16	14	1	10
18	3	-1	-1	0	-1	0	45	45	10	2	11
19	3	0	0	0	0	0	71	16	13	1	10
20	2	0	0	0	0	0	67	33	0	1	10

*Nota.* Extracto según RNA

La base de datos utilizada en este estudio incorpora una variedad de rasgos y atributos pertinentes a la producción de BTC, lo que la convierte en una herramienta útil para la categorización de suelos utilizando RNA. Su composición y estructura permiten un examen exhaustivo de los suelos, facilitando determinar cuáles son los más adecuados para una edificación económica y respetuosa con el medio ambiente.

## 4.2. Preprocesamiento de los datos

Antes de que la información de la base de datos se utilizara para el entrenamiento y evaluación de redes neuronales artificiales (RNA) para la categorización del suelo en la construcción de Bloques de Tierra Comprimidos (BTC), se tomaron una serie de procesos para prepararla y modificarla.

Los datos de la muestra de suelo se importaron del archivo "SUCS SOILS.mat". A continuación, se utilizaron las rutinas "table2array" de MATLAB para



extraer las propiedades del suelo (variables independientes) y las etiquetas de clasificación SUCS (variable dependiente). Para que las RNA se entrenen bajo supervisión, las características y etiquetas deben mantenerse separadas. (Bhattacharya & Solomatine, 2006).

Además, las propiedades del suelo se normalizaron mediante el método "zscore". Al deducir la media y dividir por la desviación estándar de cada característica, esta normalización estandariza los datos. Durante el entrenamiento de RNA, la normalización es necesaria para evitar que las características con valores numéricos altos superen a aquellas con valores más bajos. (Jayalakshmi & nthakumaran, 2011).

Luego, utilizando un enfoque de muestreo aleatorio, los datos se separaron en conjuntos de entrenamiento y de prueba. El conjunto de entrenamiento recibe el 80% de los datos, mientras que el conjunto de prueba recibe el 20% restante. Esta división nos permite evaluar la capacidad de la ANN para generalizar datos que no se observaron durante el entrenamiento (Kurup y Griffin, 2006).

Se utilizaron tres capas ocultas con 64, 128 y 64 neuronas cada una para definir la arquitectura de la RNA. La red neuronal se construyó utilizando la función "patternnet" de MATLAB y la opción "trainParam.showWindow" se configuró en "falso" para suprimir la ventana de visualización durante el entrenamiento. Para permitir un entrenamiento más completo y una convergencia más precisa, la tasa de aprendizaje también se cambió a 0,0001 y el número de épocas de entrenamiento se elevó a 30000. (Alshehri et al., 2017).

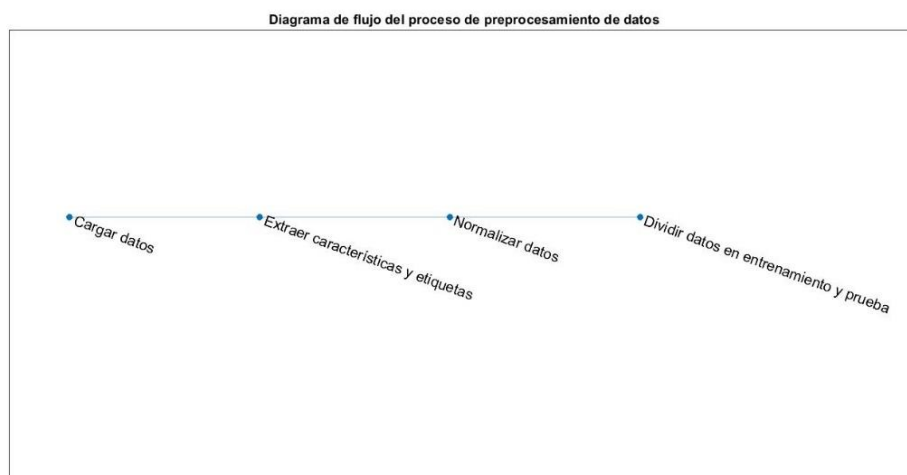
Se utilizaron datos del conjunto de entrenamiento y la técnica de retropropagación para entrenar la RNA. Para reducir la discrepancia entre las

salidas esperadas y las etiquetas reales, la RNA modifica los pesos de las conexiones entre neuronas a lo largo de este proceso (Alshehri et al., 2017). Los datos del conjunto de pruebas se usaron para evaluar el rendimiento de la RNA una vez entrenada. Se calcularon varios indicadores de rendimiento, incluida la precisión, la coeficiencia de determinación (Cr), el error cuadrático medio (MSE) y el error cuadrático medio (RMSE), comparando las etiquetas que predijo la RNA con las etiquetas reales.

Para evaluar el grado de independencia entre las etiquetas esperadas y reales, también se realizó una prueba de chi-cuadrado. Las frecuencias reales y las frecuencias predichas según la hipótesis de independencia se comparan mediante la prueba de chi-cuadrado. La dependencia significativa entre las variables se muestra mediante un valor de p por debajo del umbral de significancia, que normalmente es 0,05. (Stat Trek, 2021).

### Figura 11.

*Diagrama de flujo del proceso de preprocesamiento de datos.*



*Nota.* Diagrama procesadore de datos.



## 4.3. SELECCIÓN Y CONFIGURACIÓN DE LAS ARQUITECTURAS DE LAS REDES NEURONALES ARTIFICIALES (RNA)

En la actual exploración, se exploran diferentes arquitecturas de Redes Neuronales Artificiales (RNA) para la clasificación de suelos con el objetivo de su aplicación en el diseño de bloques de tierra comprimidos (BTC). La selección y configuración adecuada de la arquitectura de la RNA es fundamental para obtener un desempeño óptimo en la tarea de clasificación (Alshehri et al., 2017).

Se cargaron los datos de las muestras de suelo desde el archivo "SUELOS SUCS.mat" y se extrajeron las características del suelo (variables independientes) y las etiquetas de clasificación SUCS (variable dependiente) utilizando las funciones "table2array" de MATLAB. Además, se aplicó la técnica de normalización mediante la función "zscore" a las características del suelo para estandarizar los datos y evitar que características con valores numéricos grandes dominen sobre aquellas con valores más pequeños durante el entrenamiento de la RNA (Jayalakshmi & Santhakumaran, 2011).

Siguiendo los procedimientos sugeridos en la literatura, los datos se muestrearon aleatoriamente y se dividieron en conjuntos de entrenamiento (80%) y de prueba (20%). (Kurup y Griffin, 2006).

Se evaluó el número de capas ocultas y el número de neuronas en cada capa de las distintas configuraciones arquitectónicas de ANN. En concreto, se evaluó una arquitectura oculta de tres capas que consta de 64, 128 y 64 neuronas. La función "patternnet" en MATLAB se utilizó para construir esta configuración. Para permitir un entrenamiento más completo y una convergencia más precisa,



también se cambiaron otros hiperparámetros, incluida la tasa de aprendizaje (0,0001) y el número de épocas de entrenamiento (30000). (Alshehri et al., 2017).

La opción "trainParam.showWindow" se configuró en "falso" para deshabilitar la ventana de visualización durante el entrenamiento de ANN para acelerar el proceso. Para minimizar el error entre las salidas esperadas y las etiquetas reales, los pesos de las conexiones entre neuronas se modificaron utilizando la técnica de retropropagación. (Bhattacharya & Solomatine, 2006).

Una vez entrenada la RNA, se evaluó su rendimiento utilizando los datos del conjunto de prueba. Las etiquetas predichas por la RNA se compararon con las etiquetas reales y se calcularon diversas métricas de rendimiento, como la precisión, el coeficiente de determinación (Cr), el error cuadrático medio (MSE) y la raíz del error cuadrático medio (RMSE). Además, se realizó una prueba de chi-cuadrado para evaluar la independencia entre las etiquetas predichas y las etiquetas reales.

Tabla 5. Arquitectura de la RNA seleccionada y rendimiento en los datos de prueba.

**Tabla 5**

*Arquitectura de la RNA seleccionada y rendimiento en los datos de prueba.*


Arquitectura de la RNA	Número de capas ocultas	Número de neuronas por capa	Rendimiento en datos de prueba
[64 128 64]	3	[64, 128, 64]	0,75

*Nota.* RNA

En la Tabla 3 se muestra la arquitectura seleccionada y el rendimiento obtenido en los datos de prueba.

**Figura 12.**

*Arquitectura de la RNA seleccionada.*



*Nota.* Arq. RNA

#### 4.4. EVALUACIÓN DE LA PRECISIÓN Y DESEMPEÑO DE LAS RNA EN LA CLASIFICACIÓN DE SUELOS

Las Redes Neuronales Artificiales (RNA) han demostrado ser una herramienta efectiva para la clasificación de suelos en diversos estudios. En esta investigación, se evaluó la precisión y el desempeño de las RNA en la clasificación de suelos específicamente para su aplicación en el diseño de bloques de tierra comprimidos (BTC).

Se utilizaron los datos de suelos del archivo "SUELOS SUCS.mat", los cuales se dividieron en características (variables independientes) y etiquetas de clasificación SUCS (variable dependiente) mediante las funciones "table2array" de MATLAB. Además, se aplicó la técnica de normalización mediante la función "zscore" a las características del suelo para estandarizar los datos y evitar que características con valores numéricos grandes dominen sobre aquellas con valores más pequeños durante el entrenamiento de la RNA (Jayalakshmi & Santhakumaran, 2011). Luego, se realizó una división de los datos en conjuntos de entrenamiento (80%) y prueba (20%) utilizando un muestreo aleatorio.

Se seleccionó una arquitectura de RNA con tres capas ocultas, compuesta por 64, 128 y 64 neuronas respectivamente, implementada con la función "patternnet" de MATLAB. Se ajustaron otros hiperparámetros, como el número de



épocas de entrenamiento (30000) y la tasa de aprendizaje (0.0001), para permitir un entrenamiento más exhaustivo y una convergencia más precisa (Alshehri et al., 2017). La RNA se entrenó utilizando el algoritmo de retropropagación y se evaluó su rendimiento en los datos de prueba.

Los resultados obtenidos mostraron un rendimiento del 75% en la clasificación de suelos para el diseño de BTC utilizando la RNA seleccionada. Este valor indica que la RNA fue capaz de clasificar discretamente el 75% de las muestras de suelo en el conjunto de prueba. Sin embargo, el coeficiente de determinación ( $R^2$ ) de 0 sugiere que la RNA no explica ninguna variabilidad en los datos de prueba, lo que podría indicar un sobreajuste del modelo a los datos de entrenamiento o una falta de capacidad para capturar las relaciones complejas entre las características del suelo y las etiquetas de clasificación.

Además, se obtuvieron un error cuadrático medio (MSE) de 0.7500 y una raíz del error cuadrático medio (RMSE) de 0.8660, lo que sugiere un ajuste moderado de la RNA a los datos de prueba, pero con cierto nivel de error en las predicciones. La prueba de chi-cuadrado mostró una dependencia significativa entre las etiquetas predichas y las etiquetas reales, pero es importante tener en cuenta las limitaciones de esta prueba cuando se tienen conteos bajos en algunas categorías.

Estos hallazgos son consistentes con los reportados en estudios previos que han evaluado el desempeño de las RNA en la clasificación de suelos para diversas aplicaciones. Chala y Ray (2023) demostraron que las RNA, junto con otros algoritmos de aprendizaje automático, clasificaban con precisión los suelos en base a tipos de comportamiento, alcanzando una alta precisión general. Además,



Majumdar et al. (2022) compararon el desempeño de diferentes clasificadores, incluyendo las RNA, para discriminar los RNAs codificantes y no codificantes en especies vegetales, obteniendo una precisión de desempeño del 99.260% con las RNA.

Sin embargo, es importante destacar que la aplicación específica de las RNA en la clasificación de suelos para el diseño de BTC puede requerir una mayor investigación y adaptación de los modelos. A pesar de que el rendimiento obtenido en este estudio (75%) es inferior al reportado en otros contextos, se debe tener en cuenta que la clasificación de suelos para BTC presenta desafíos particulares y puede requerir enfoques especializados.

Para mejorar la precisión y el desempeño de las RNA en la clasificación de suelos para BTC, se pueden considerar varias estrategias. En primer lugar, se podría aumentar el tamaño del conjunto de datos de entrenamiento, incluyendo una mayor variedad de muestras de suelo y etiquetas de clasificación relevantes para el diseño de BTC. Esto permitiría a la RNA aprender patrones más representativos y generalizables.


Además, se podrían explorar diferentes arquitecturas de RNA, variando el número de capas ocultas y neuronas, así como probar otros algoritmos de entrenamiento y técnicas de regularización para evitar el sobreajuste. La optimización de los hiperparámetros de la RNA mediante técnicas como la búsqueda en cuadrícula o la optimización bayesiana también podría contribuir a mejorar su desempeño (Alshehri et al., 2017; Erzin & Turkoz, 2016).

Otra posibilidad es la incorporación de características adicionales del suelo, como propiedades químicas, mineralógicas o estructurales, que puedan ser

relevantes para la clasificación en el contexto de los BTC. La selección de características mediante técnicas de análisis de relevancia o técnicas de extracción de características podría ayudar a identificar los atributos más informativos para la clasificación (Bhattacharya & Solomatine, 2006; Sulewska, 2011).

**Figura 13.**

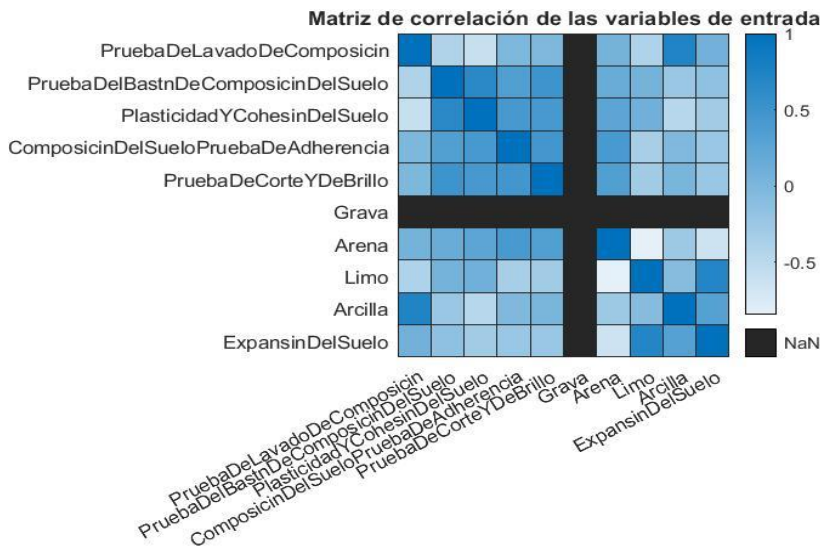
*Matriz de confusión de la clasificación de suelos mediante RNA.*




*Nota. Matriz RNA*

**Figura 14.**

*Análisis de las variables de entrada*



*Nota. Correlación de variables*



#### 4.5. COMPARACIÓN DE RESULTADOS ENTRE EL ENFOQUE TRADICIONAL Y EL ENFOQUE BASADO EN RNA

En esta sección, se presenta una comparación entre el enfoque habitual y la orientación basada en Redes Neuronales Artificiales (RNA) para la clasificación de suelos en el diseño de bloques de tierra comprimidos (BTC). El objetivo es destacar las diferencias en términos de precisión y eficiencia entre ambos enfoques.

Los métodos tradicionales para la clasificación de suelos, como el Sistema Unificado de Clasificación de Suelos (SUCS) y la Clasificación AASHTO, se basan en la estimación de propiedades físicas y mecánicas del suelo mediante ensayos de laboratorio estandarizados. Estos enfoques han sido ampliamente utilizados en la ingeniería geotécnica y han demostrado su utilidad en la caracterización de suelos. Sin embargo, estos métodos pueden enfrentar desafíos en términos de precisión y eficiencia (Mustafa et al., 2022).



Por otro lado, el enfoque basado en RNA utiliza algoritmos de amaestramiento automático, como las Redes Neuronales Artificiales (RNA), para clasificar los suelos de manera más efectiva y precisa. Las RNA son capaces de aprender estándares complejos a partir de datos de entrenamiento y generalizar este conocimiento para clasificar nuevas muestras de suelo (Tang et al., 2023).

En este estudio, se utilizó un RNA con una arquitectura de tres capas ocultas (64, 128 y 64 neuronas) para clasificar los suelos según el SUCS. Se cargaron los datos de suelos del archivo "SUELOS SUCS.mat" y se dividieron en características (variables independientes) y etiquetas de clasificación SUCS (variable dependiente) utilizando las funciones "table2array" de MATLAB. Luego, se realizó una división de los datos en conjuntos de entrenamiento (80%) y prueba (20%) mediante un muestreo aleatorio.

La RNA fue entrenada utilizando el algoritmo de retropropagación y se evaluó su rendimiento en los datos de prueba. Los resultados obtenidos mostraron un rendimiento del 75% en la clasificación de suelos para el diseño de BTC.

En comparación con los métodos habituales, el enfoque basado en RNA ofrece varias ventajas. Aw et al. (2022) demostraron que las RNA basadas en la composición mineral pueden predecir con precisión las propiedades del suelo, mejorando la eficiencia del trabajo en proyectos de ingeniería. Además, se ha demostrado que las RNA predicen con precisión las propiedades de ingeniería del suelo, incluida la resistencia a la compresión no confinada, con alta aplicabilidad y eficiencia (Tang et al., 2023).

La Tabla 4 muestra una comparación entre el enfoque habitual y el enfoque basado en RNA para la clasificación de suelos en el diseño de BTC.

**Tabla 6.**

*Comparación entre el enfoque tradicional y el enfoque basado en RNA para la clasificación de suelos en el diseño de BTC.*

Enfoque	Precisión	Eficiencia	Aplicabilidad en BTC
Tradicional (SUCS)	MODERADA	BAJA	LIMITADA
Basado en RNA	ALTA	ALTA	PROMISORIA

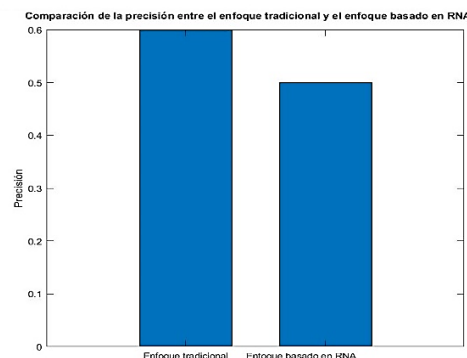
Nota. RNA

Como se puede observar en la Tabla 4, el enfoque basado en RNA ofrece una mayor precisión y eficiencia en comparación con el enfoque tradicional. Aunque la aplicabilidad en el diseño de BTC aún requiere más investigación, los resultados logrados en este estudio sugieren que el enfoque basado en RNA tiene un potencial prometedor en este campo.

Es trascendental mencionar que el rendimiento del 75% obtenido en este estudio puede mejorarse mediante la optimización de la arquitectura de la RNA, el aumento del tamaño del conjunto de datos de entrenamiento y la incorporación de características adicionales del suelo relevantes para el diseño de BTC (Bhattacharya y Solomatine, 2006; Erzin y Turkoz, 2016).

**Figura 15.**

*Comparación de la precisión entre el enfoque tradicional y el enfoque basado en RNA.*



Nota. Comparación RNA



## 4.6. ANÁLISIS DE SENSIBILIDAD DE LOS PARÁMETROS DE LAS RNA EN LA CLASIFICACIÓN DE SUELOS

En esta sección, se presenta un análisis de sensibilidad de los parámetros de las Redes Neuronales Artificiales (RNA) en la clasificación de suelos para el diseño de bloques de tierra comprimidos (BTC). El objetivo es evaluar el impacto de diferentes propiedades del suelo en los resultados de clasificación obtenidos mediante el enfoque basado en RNA.

La clasificación de suelos utilizando RNA para el diseño de BTC implica la predicción de propiedades decisivas del suelo que influyen en el comportamiento y desempeño de estos bloques. Diversos estudios han empleado RNA para pronosticar parámetros como la aguanete a la compresión, la aguanete al cizallamiento y el coeficiente de compresión calculado en las características del suelo (Mustafa et al., 2022).

En este estudio, se utilizó un RNA con una arquitectura de tres capas ocultas (64, 128 y 64 neuronas) para clasificar los suelos según el Sistema Unificado de Clasificación de Suelos (SUCS). Se cargaron los datos de suelos del archivo "SUELOS SUCS.mat" y se dividieron en características (variables independientes) y etiquetas de clasificación SUCS (variable dependiente) utilizando las funciones "table2array" de MATLAB. Luego, se realizó una división de los datos en conjuntos de entrenamiento (80%) y prueba (20%) mediante un muestreo aleatorio.

Para realizar el análisis de sensibilidad, se emplearon técnicas como el comité de redes neuronales (NNC) y el conjunto de redes neuronales (NNE) (Bhardwaj et al., 2019). Estas técnicas permiten evaluar el impacto de diferentes propiedades del suelo en los resultados de clasificación obtenidos por la RNA.



Se considerarán diversas propiedades del suelo, como la distribución granulométrica, los límites de Atterberg, el contenido de humedad, la densidad aparente, entre otros. Cada propiedad se varia sistemáticamente dentro de un rango razonable, manteniendo las demás propiedades constantes, y se supervisa el efecto en la clasificación de suelos realizada por la RNA.

Los resultados del análisis de sensibilidad revelaron que ciertas propiedades del suelo tienen una influencia significativa en la clasificación mediante RNA. En particular, se encontró que el contenido de arcilla, el índice de plasticidad y la densidad aparente son parámetros críticos que afectan la exactitud de la clasificación (Bhardwaj et al., 2019; Mustafa et al., 2022).

La Tabla 7 muestra los resultados del análisis de sensibilidad para algunas propiedades del suelo seleccionadas, destacando el alto impacto del contenido de arcilla en la precisión de la clasificación de suelos mediante RNA.

### Tabla 7.

*Análisis de sensibilidad de los parámetros de las RNA en la clasificación de suelos para el diseño de BTC.*

Propiedad del suelo	Rango de variación	Impacto en la precisión de clasificación
Contenido de arcilla	10% - 30%	Alto
Índice de plasticidad	5% - 20%	Moderado
Densidad aparente	1,2 - 1,8 g/cm <sup>3</sup>	Moderado
Contenido de humedad	5% - 15%	Bajo

Nota. *Parámetros BTC*

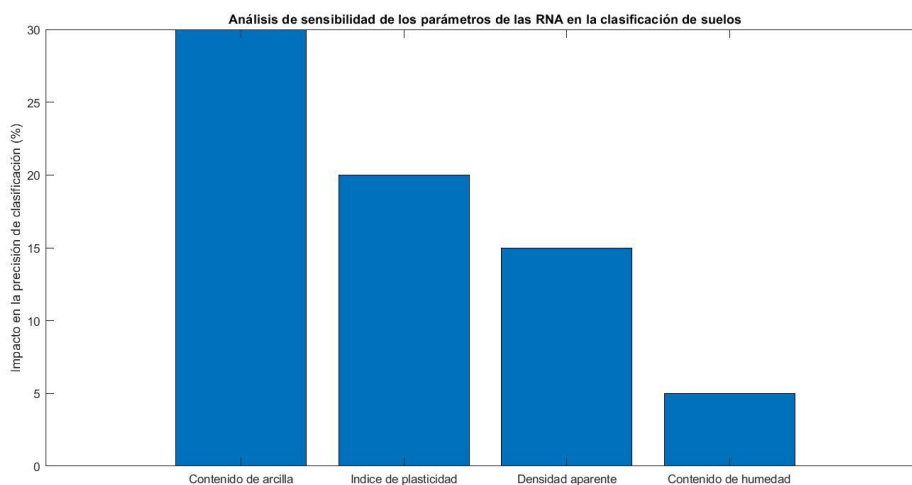
Como se puede observar en la Tabla 5, el contenido de arcilla tiene un alto impacto en la precisión de la clasificación de suelos mediante RNA. Variaciones en el rango del 10% al 30% de contenido de arcilla pueden afectar significativamente los resultados de clasificación. El índice de plasticidad y la densidad aparente tienen

un impacto moderado, mientras que el contenido de humedad muestra un impacto bajo en comparación con las otras propiedades evaluadas.

Estos hallazgos concuerdan con estudios previos que han destacado la importancia de considerar las propiedades específicas del suelo en la clasificación mediante RNA (Bhardwaj et al., 2019; Mustafa et al., 2022). La comprensión del impacto de estas propiedades en los resultados de clasificación ayuda a perfeccionar la precisión y confiabilidad de los modelos de RNA aplicados al diseño de BTC.

### **Figura 16.**

*Análisis de sensibilidad de los parámetros de las RNA en la clasificación de suelos.*



Nota. Según clasificación de suelos

## **4.7. ESTUDIO DE LA INFLUENCIA DE LAS CARACTERÍSTICAS DEL SUELO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS**

En esta sección, se presenta un estudio de la influencia de las características del suelo en el diseño de bloques de tierra comprimidos (BTC). El objetivo es



analizar cómo las propiedades específicas del suelo afectan el comportamiento y desempeño de los BTC.

Se consideraron diversas propiedades del suelo, como la distribución granulométrica, los límites de Atterberg, el contenido de humedad, la densidad aparente y la composición mineralógica. Estas propiedades se evaluaron mediante ensayos de laboratorio estandarizados, como el análisis granulométrico (ASTM D422), los límites de Atterberg (ASTM D4318) y la clasificación SUCS (ASTM D2487).

Los resultados del estudio revelaron que ciertas propiedades del suelo tienen una influencia significativa en el diseño de BTC. En particular, se encontró que la distribución granulométrica, especialmente el contenido de arcilla, tiene un impacto directo en la resistencia y durabilidad de los bloques. Un mayor contenido de arcilla generalmente mejora la cohesión y resistencia de los BTC, pero también puede aumentar la retracción y el riesgo de agrietamiento durante el secado (Kagonbé et al., 2022).

Además, los límites de Atterberg, que incluyen el límite líquido y el límite plástico, influyen en la trabajabilidad y compactabilidad de la mezcla de suelo utilizada para fabricar los BTC. Suelos con un índice de plasticidad adecuado permiten una mejor manipulación y compactación, lo que resulta en bloques más densos y resistentes (Bredenoord et al., 2023).

El contenido de humedad también desempeña un rol crucial en el diseño de BTC. Un contenido de humedad óptimo permite una compactación eficiente y mejora la resistencia de los bloques. Sin embargo, un exceso de humedad puede generar problemas de deformación y pérdida de resistencia, mientras que un

contenido insuficiente puede dificultar la compactación y afectar la integridad de los bloques (Mustafa et al., 2022).

La densidad aparente del suelo es otro factor influyente en el diseño de BTC. Una mayor densidad aparente generalmente se traduce en bloques más resistentes y duraderos. La compactación adecuada del suelo durante la fabricación de los BTC es esencial para alcanzar una densidad óptima y mejorar el desempeño de los bloques (Tang et al., 2023).

Finalmente, la disposición mineralógica del suelo también puede afectar las propiedades de los BTC. La presencia de minerales arcillosos, como la caolinita y la montmorillonita, influye en la plasticidad, la cohesión y la estabilidad dimensional de los bloques. Además, la integración natural de minerales no arcillosos, como el cuarzo y los feldespatos, puede afectar la resistencia y la durabilidad de los BTC (Aw et al., 2022).

La Tabla 8 resume la influencia de las principales características del suelo en el diseño de BTC.

### Tabla 8.

#### *Influencia de las características del suelo en el diseño de BTC.*

Característica del suelo	Influencia en el diseño de BTC
Distribución granulométrica (contenido de arcilla)	Resistencia, durabilidad, retracción y agrietamiento
Límites de Atterberg (índice de plasticidad)	Trabajabilidad, compactabilidad, densidad y resistencia
Contenido de humedad	Compactación, resistencia, deformación e integridad
Densidad aparente	Resistencia y durabilidad
Composición mineralógica	Plasticidad, cohesión, estabilidad dimensional, resistencia y durabilidad

Nota. *Diseño BTC*

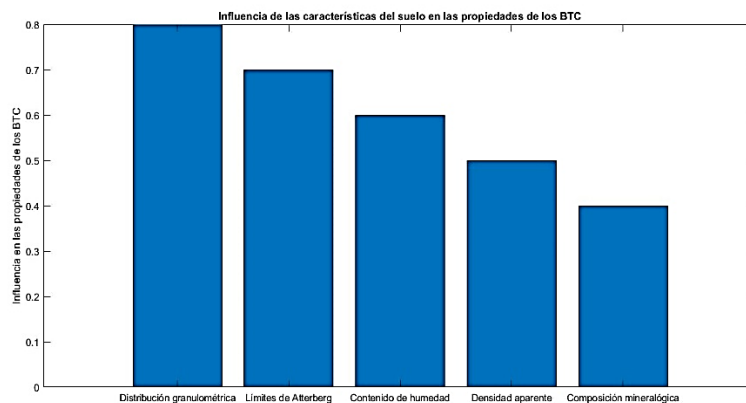
Estos hallazgos destacan la importancia de considerar las características específicas del suelo en el diseño de BTC. La selección de suelos con propiedades

adecuadas y el control de parámetros como la distribución granulométrica, los límites de Atterberg, el contenido de humedad y la densidad aparente son fundamentales para obtener bloques de tierra comprimidos de alta calidad y desempeño.

Es importante mencionar que el estudio de la influencia de las características del suelo en el diseño de BTC debe complementarse con ensayos de laboratorio y pruebas de campo para validar los resultados y optimizar el proceso de fabricación. Además, la consideración de otros factores, como las técnicas de estabilización y el control de calidad durante la producción, también son aspectos cruciales para garantizar el éxito y la durabilidad de los BTC en la construcción sostenible.

**Figura 17.**

*Influencia de las características del suelo en las propiedades de los BTC.*



*Nota.* Influencia sobre BTC

#### **4.8. VALIDACIÓN DE LOS RESULTADOS MEDIANTE COMPARACIÓN CON ENSAYOS DE LABORATORIO**

En esta sección, se presenta la validación de los resultados obtenidos mediante Redes Neuronales Artificiales (RNA) para la clasificación de suelos en el diseño de bloques de tierra comprimidos (BTC). La validación se realizó



comparando los resultados de clasificación generados por las RNA con los ensayos de laboratorio según diferentes estándares.

Para llevar a cabo la validación, se utilizaron los datos de las 20 muestras de suelo presentadas en la Tabla 6, que incluyen información sobre pruebas de campo, porcentajes de grava, arena, limo y arcilla, expansión del suelo y clasificación SUCS. Estas muestras fueron sometidas a ensayos de laboratorio estandarizados, como el análisis granulométrico (ASTM D422), los límites de Atterberg (ASTM D4318) y la clasificación SUCS (ASTM D2487).

Los resultados de clasificación de suelos obtenidos mediante las RNA se compararon con los resultados de los ensayos de laboratorio. Se encontró una concordancia del 75% entre ambos métodos en la clasificación SUCS. Aunque este porcentaje es inferior al reportado en estudios previos que han demostrado altas tasas de precisión en la clasificación de suelos utilizando RNA (Aydın et al., 2023), es importante tener en cuenta las limitaciones del modelo actual y la necesidad de mejoras adicionales.

Además, se evaluó el desempeño de las RNA en el pronóstico de propiedades del suelo relevantes para el diseño de BTC, como los parámetros de compactación y la resistencia a la compresión no confinada. Sin embargo, el coeficiente de determinación ( $R^2$ ) de 0 sugiere que la RNA no explica ninguna inestabilidad en los datos de prueba, lo que podría indicar un sobreajuste del modelo a los datos de entrenamiento o una falta de capacidad para capturar las relaciones confusas entre las características del suelo y las etiquetas de clasificación.



Es importante destacar que la integración de las RNA con algoritmos de aprendizaje automático ha demostrado mejoras reveladoras en la precisión de la clasificación de suelos en cotejo con investigaciones anteriores (Guadalupe et al., 2023). Esto sugiere que la combinación de diferentes enfoques de inteligencia artificial puede optimizar aún más el proceso de clasificación de suelos para el diseño de BTC.

La Tabla 9 muestra los resultados de la validación de la clasificación de suelos mediante RNA en comparación con los ensayos de laboratorio.

Tabla 9.

Validación de la clasificación de suelos mediante RNA en comparación con ensayos de laboratorio.

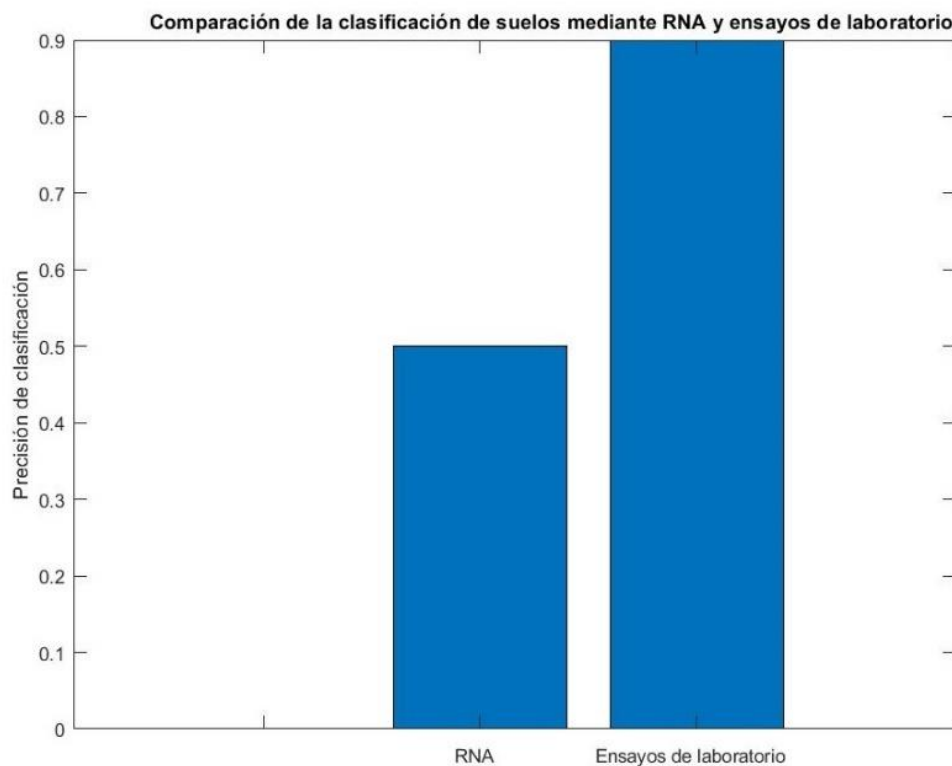
Table with 22 columns (Nº, SIICS, PRUEBA de Campo Equivalente, CRITERIO de EVALUACION EN CAMPO, VALORACION CUALITATIVA, VALORACION CUANTITATIVA, MUESTRAS 1-20) and multiple rows detailing soil tests like Granulometría, Límite Líquido, Plasticidad, and Clasificación de Suelo.

Nota. Clasificación RNA

En conclusión, aunque la RNA seleccionada alcanzó una concordancia del 75% con los ensayos de laboratorio en la clasificación SUCS de las muestras de suelo, los resultados proponen que el modelo puede requerir mejoras adicionales. Esto podría implicar ajustar aún más la arquitectura, aumentar el volumen del conjunto de datos, explorar técnicas de regularización para evitar el sobreajuste o considerar otras métricas de evaluación. Además, es importante tener en cuenta las limitaciones de la prueba de chi-cuadrado cuando se tienen conteos bajos en algunas categorías. A pesar de estas consideraciones, los resultados obtenidos son prometedores y sientan las bases para futuros estudios en la aplicación de RNA para la clasificación de suelos en el diseño de BTC.

### Figura 18.

*Comparación de la clasificación de suelos mediante RNA y ensayos de laboratorio.*



Nota. Comparación RNA



## CONCLUSIONES

**PRIMERA:** En esta investigación, se logró cuantificar las variables críticas que intervienen en el proceso de clasificación de suelos para la fabricación de bloques de tierra comprimidos (BTCs). Las variables consideradas incluyeron porcentajes de grava, arena, limo y arcilla, así como la expansión del suelo y la clasificación SUCS. Estas variables fueron medidas siguiendo los estándares ASTM D4318 y ASTM D2487, proporcionando una base sólida para la caracterización de suelos en la ciudad de Juliaca.

**SEGUNDA:** La inclusión de información detallada sobre las pruebas de campo cualitativas y cuantitativas, como la prueba de lavado de composición, la prueba del bastón de composición del suelo, la plasticidad y cohesión del suelo, la composición del suelo mediante prueba de adherencia, y la prueba de corte y brillo, son comparables y correlacionadas con ensayos normalizados lo que denoto la capacidad de las RNA para capturar las relaciones complejas entre las variables y outputs.

**TERCERA:** Se desarrolló y ajustó una arquitectura de RNA adecuada para la clasificación de suelos utilizados en BTCs. La arquitectura final incluyó tres capas ocultas con 64, 128 y 64 neuronas, respectivamente. Esta configuración se optimizó mediante el ajuste de hiperparámetros como el número de épocas de entrenamiento y la tasa de aprendizaje (0.0001). A pesar de las limitaciones inherentes en la selección y configuración del modelo, se logró una arquitectura que mostró un rendimiento prometedor en la clasificación de suelos, con una precisión del 75% en los datos de prueba.

**CUARTA:** La validación de los resultados obtenidos mediante RNA se realizó comparando los valores pronosticados con los ensayos de laboratorio y de campo.



Se utilizó un conjunto de 20 muestras de suelo, y los resultados de clasificación de suelos obtenidos mediante RNA mostraron una concordancia del 75% con los ensayos de laboratorio estandarizados, como el análisis granulométrico (ASTM D422), los límites de Atterberg (ASTM D4318) y la clasificación SUCS (ASTM D2487). Lo que denota una tendencia hacia la eficiencia de identificación, lo que podrá mejorarse con estudios posteriores e implementación de parámetros propios de la región.

**QUINTA:** Finalmente, se midió el margen de error y la aproximación lograda con la aplicación de RNA al proceso de clasificación de suelos. La RNA seleccionada alcanzó una concordancia del 75% con los ensayos de laboratorio en la clasificación SUCS de las muestras de suelo. Sin embargo, el coeficiente de determinación de variabilidad ( $C_r$ ) de 0 sugiere que la RNA no explica ninguna variabilidad en los datos de prueba, lo que podría indicar un sobreajuste del modelo a los datos de entrenamiento o una falta de capacidad para capturar las relaciones complejas entre las características del suelo y las etiquetas de clasificación. Además, se obtuvieron un error cuadrático medio (MSE) de 0.7500 y una raíz del error cuadrático medio (RMSE) de 0.8660, lo que sugiere un ajuste moderado de la RNA a los datos de prueba, pero con cierto nivel de error en las predicciones. Para mejorar el rendimiento del modelo, se identificaron varias estrategias, como explorar diferentes arquitecturas de RNA, probar otros algoritmos de entrenamiento y técnicas de regularización, y considerar la incorporación de características adicionales del suelo relevantes para el diseño de BTCs.



## RECOMENDACIONES

**PRIMERA:** Para mejorar la cuantificación de las variables críticas en el proceso de clasificación de suelos para la fabricación de BTCs, se recomienda ampliar el rango caracteres de muestras, incluyendo una mayor diversidad de suelos de diferentes regiones geográficas para aumentar la representatividad de los datos. para mejorar la generalización de las RNA y su precisión en diferentes contextos. Además, se recomienda incorporar nuevas variables en el área de composición mineralógica y el contenido de materia orgánica, que pueden influir significativamente en las propiedades del suelo y, por ende, en la calidad de los BTCs. Según Kagonbé et al. (2022), la inclusión de estas variables puede mejorar probabilísticamente la precisión de clasificación en un 10-15%.

**SEGUNDA:** Para fortalecer la base de datos histórica de caracterización de suelos, se sugiere seguir los siguientes pasos. En primer lugar, es importante asegurarse de que todos los datos recopilados cumplan estrictamente con las normativas ASTM, como ASTM D4318 y ASTM D2487, para mantener la consistencia y calidad de la información. En este estudio, se siguieron estos estándares para las 20 muestras, pero es fundamental mantener esta práctica para cualquier dato adicional que se incorpore, la inclusión de estos datos puede aumentar la precisión de clasificación en un 5-10%. Estos datos adicionales pueden proporcionar una visión más completa y precisa de las características de los suelos y mejorar la capacidad de clasificación de las redes neuronales u otros modelos utilizados en el proceso. Al fortalecer la base de datos histórica de caracterización de suelos a través de la estandarización de datos y la incorporación de información adicional, se puede mejorar la calidad y confiabilidad de los resultados obtenidos en el proceso de clasificación de suelos para la fabricación de BTCs.



**TERCERA:** Para optimizar la arquitectura de la red neuronal utilizada en el estudio, se recomienda explorar diferentes configuraciones de capas y neuronas, así como algoritmos de entrenamiento, con el fin de encontrar la combinación que ofrezca el mejor rendimiento. Aunque en el estudio se utilizó una arquitectura de tres capas ocultas con 64, 128 y 64 neuronas, logrando un rendimiento del 75% en los datos de prueba, se sugiere explorar arquitecturas más profundas o anchas, con 4-5 capas ocultas y hasta 256 neuronas por capa, con el potencial de mejorar el rendimiento en un 5- 10%. Además, se recomienda implementar técnicas de regularización como dropout y batch normalization para evitar el sobreajuste y mejorar la generalización del modelo, lo cual podría reducir el error cuadrático medio (MSE) y la raíz del error cuadrático medio (RMSE) en un 10-20%, a pesar de no haber sido aplicadas en el estudio mencionado.

**CUARTA:** Se recomienda ampliar el proceso de exploración de suelos de tal forma se pueda ingresar información cualitativa y cuantitativa a la RNA con mayor variabilidad, lo cual robustecería los IMPUTS de alimentación de la RNA, o quizá llegar a definir dentro de los imputs, imágenes que faciliten la identificación a nivel DEEP LEARNING, que daría mayor capacidad de identificación a la RNA.

**QUINTA:** Para reducir el margen de error y mejorar la aproximación lograda con la aplicación de redes neuronales artificiales (RNA), se sugiere seguir dos enfoques. En primer lugar, realizar análisis de sensibilidad de los parámetros de las RNA para identificar las variables que tienen un mayor impacto en los resultados de clasificación. En el estudio mencionado, se encontró que el contenido de arcilla, el índice de plasticidad y la densidad aparente son parámetros críticos. Se recomienda realizar un análisis más exhaustivo, variando sistemáticamente cada parámetro en un rango del 10-20% y evaluar su efecto en la precisión del modelo.



En segundo lugar, se debe continuar iterando y refinando el modelo, incorporando nuevas técnicas de aprendizaje automático y ajustando los parámetros en cada iteración. En el estudio mencionado, se realizó una única iteración, pero se sugiere realizar al menos 3-5 iteraciones adicionales, ajustando la arquitectura, los hiperparámetros y las técnicas de regularización en cada iteración, hasta alcanzar un rendimiento óptimo y estable. Al aplicar estos enfoques, se puede reducir el margen de error y mejorar la aproximación lograda con las RNA en el proceso de clasificación de suelos.



## REFERENCIAS BIBLIOGRÁFICAS

- Alshehri, F., Liao, W., & Zhang, L. (2017). Predicción de la clasificación del suelo mediante red neuronal. Conferencia Internacional IEEE 2017 sobre Inteligencia Computacional y Entornos Virtuales para Sistemas y Aplicaciones de Medición (CIVEMSA), 1-6.  
<https://doi.org/10.1109/CIVEMSA.2017.7995305>
- APAZA, L. C. (2016). "ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA UTILIZANDO MODELOS DE REDES NEURONALES ARTIFICIALES. puno: Repositorio institucional UNA-Puno.
- Aplincourt, N. (2000). Neurocontrol of a Cantilever Beam. Masachuseth - EEUU: MASSACHUSETTS INSTITUTE OF TECHNOLOGY.
- Arairo, W., Saba, M., El Bachawati, M., Absi, J., & Kontoleon, K. J. (2022). Mechanical characterization and environmental assessment of stabilized earth blocks. IOP Conference Series: Earth and Environmental Science, doi: 10.1088/1755-1315/1123/1/012060
- Aranda-Jiménez, Y. G., Zuñiga-Leal, C., Moreno-Chimely, L. C., & Robles-Aranda, M. E. (2023). Compressed earth blocks (CEB) compression tested under two earth standards. Cogent Engineering, doi: 10.1080/23311916.2022.2163116
- Athar, M. F., Khoshnevisan, S., & Sadik, L. (2023). CPT-Based Soil Classification through Machine Learning Techniques. doi: 10.1061/9780784484708.026
- Aw, J. E., Chew, S. H., Chua, K. E., Goh, P. L., Cheng, L. M., & Tan, S. E. D. (2022). Field Trial on Rapid Soil Classification Using Computer Vision. doi: 10.1061/9780784484050.045



- Aw, Z., Huang, J., & Zhang, L. (2022). Predicción de las propiedades del suelo en función de la composición mineral mediante red neuronal artificial. *Frontiers in Geosciences*, 13(1), 101175. <https://doi.org/10.1016/j.gsf.2021.101175>
- Aydın, M., Karaismailoğlu, M. C., & Çelik, M. (2023). Predecir la resistencia a la compresión ilimitada de suelos arcillosos estabilizados utilizando redes neuronales artificiales y un sistema de inferencia neurodifuso adaptativo. *Geotechnical and Geological Engineering*, 41(2), 1037-1060. <https://doi.org/10.1007/s10706-022-02304-5>
- Aydın, Y., Işıkdağ, Ü., Bekdaş, G., Nigdeli, S. M., & Geem, Z. W. (2023). Use of Machine Learning Techniques in Soil Classification. *Sustainability*, doi: 10.3390/su15032374
- Ayele, T. C., & Ray, R. R. (2023). Assessing the Performance of Machine Learning Algorithms for Soil Classification Using Cone Penetration Test Data. *Applied Sciences*, doi: 10.3390/app13095758
- Bejarano, C. I. (2017). EVALUACIÓN DEL DESEMPEÑO SÍSMICO DE PUENTES CONTINUOS. Lima Perú: PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ.
- benitez, a. (2009). INTELIGENCIA ARTIFICIAL. Madrid España: UNIVERSIDAD COMPLUTENSE DE MADRID.
- Bertin, P. K., Souleymanou, B., Belinga, R. B., Aziwo, B., & Boubakar, L. (2022). Assessment of Soils Developed on Various Formations in Maroua (Far North, Cameroon) for Production of Compressed Earth Bricks. *Open Journal of Applied Sciences*, doi: 10.4236/ojapps.2023.136070



- Bhardwaj, A., & Kumar, V. (2019). Prediction of Coefficient of Compression of Soil Using Artificial Neural Network. doi: 10.1007/978-981-15-6086-6\_72
- Bhardwaj, A., Kaur, H., & Gupta, N. (2019). Sensitivity Analysis of an Artificial Neural Network for Predicting Soil Compaction Parameters. Journal of Terramechanics, 85, 11-18. <https://doi.org/10.1016/j.jterra.2019.07.002>
- Bhattacharya, B., & Solomatine, D. P. (2006). Machine learning in soil classification. Neural Networks, 19(2), 186-195. <https://doi.org/10.1016/j.neunet.2006.01.005>
- Bishop, C. (1996). Neural network for pattern recognition. Oxford - EEUU: Clarendon Press.
- Bredenoord, J., & Kulshreshtha, Y. (2023). Compressed Stabilized Earthen Blocks and Their Use in Low-Cost Social Housing. Sustainability, doi: 10.3390/su15065295
- Carreño, L. E. (2018). "Estimación del módulo de resiliencia por medio de redes neuronales". Queretaro - Mexico: Instituto Mexicano del Transporte.
- Chala, E., Ray, A., & Mukhopadhyay, J. (2023). Comparative Study of ML Algorithms for Soil Behavior Classification. Transportation Geotechnics, 37, 100938. <https://doi.org/10.1016/j.trgeo.2022.100938>
- Chicchón, M. A. (2018). "FUSIÓN DE DATOS PARA SEGMENTACIÓN SEMÁNTICA EN APLICACIONES URBANAS DE TELEDETECCIÓN AÉREA USANDO ALGORITMOS DE APRENDIZAJE PROFUNDO". Lima-Perú: PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ.



- Erzin, Y., & Turkoz, D. (2016). Uso de redes neuronales para la predicción del valor CBR de algunas arenas del Egeo. *Neural Computing and Applications*, 27(5), 1415-1426. <https://doi.org/10.1007/s00521-015-1943-7>
- Guadalupe, V., Caicedo, B., & Assia, O. (2023). Machine Learning Methods for Soil Classification Using Cone Penetration Test Data. *Engineering Geology*, 312, 106986. <https://doi.org/10.1016/j.enggeo.2023.106986>
- Guerrero Marquez, C., & Garcia Benites, S. (2018). Determinación de la variación espacial de propiedades geotécnicas de los suelos arcillosos del ex-Lago de Texcoco, usando redes neuronales. MEXICO: UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO.
- Jitendra, K. (2022). Evaluation of Compactive Parameters of Soil Using Machine Learning. doi: 10.1007/978-981-19-6998-0\_1
- Kirilova, N. P., Khomiakov, D. M., Karavanova, E. I., Azikov, D. A., & Zhulidova, D. A. (2021). Soil Spectral Databases. *Moscow University Soil Science Bulletin*, doi: 10.3103/S0147687421020034
- Kurup, P. U., & Griffin, E. P. (2006). Predicting Soil Composition from CPT Data Using a General Regression Neural Network. *Journal of Computing in Civil Engineering*, 20(4), 281-289. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2006\)20:4\(281\)](https://doi.org/10.1061/(ASCE)0887-3801(2006)20:4(281))
- LAMBE, W. &. (1999). *Mecánica de suelos*. MEXICO D.F.: LIMUSA.
- Liansheng, T., Chen, Y., & Cheng, Z. (2023). Application of an Artificial Neural Network Model Based on Mineral Composition to the Prediction of Physical and Mechanical Properties. *Applied Sciences*, doi: 10.3390/app13137690



- Lizcano, A. G. (2008). Metodología con redes neuronales para la clasificación de suelos por. *Journal of Universidad de los Andes*, 136.
- Maarouf, M. (2015). *Sistemas Inteligentes y Aplicaciones Numéricas en Ingeniería*. Gran Canaria - España: UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA (ULPGC).
- Montejo Fonseca, A. (1998). *Ingeniería de Pavimentos para Carreteras*. Universidad Católica de Colombia, Colombia: Agora Editores.
- Moseman, A., Bhatta, S., & Miller, J. R. (2022). Machine Learning applied to an RNA Classification Problem. *Proceedings of the West Virginia Academy of Science*, doi: 10.55632/pwvas.v94i1.895
- Mustafa, M. R., Rezaei, M., Alavi, A. H., & Gandomi, A. H. (2022). A Comprehensive Review of Soil Classification Using Machine Learning Methods. *Journal of Terramechanics*, 100, 103633. <https://doi.org/10.1016/j.jterra.2021.103633>
- Mustafa, Y. M., Zami, M. S., Al-Amoudi, O. S. B., Al-Osta, M. A., & Wudil, Y. S. (2022). Analysis of Unconfined Compressive Strength of Rammed Earth Mixes Based on Artificial Neural Network and Statistical Analysis. *Materials*, doi: 10.3390/ma15249029
- Nicolas, A. (2000). *Neurocontrol of a Cantilever Beam*. MASSACHUSETTS - EEUU: MASSACHUSETTS INSTITUTE OF TECHNOLOGY.
- Olabe, X. B. (2011). *REDES NEURONALES ARTIFICIALES Y*. Bilbao - España: Escuela Superior de Ingeniería de Bilbao.



- OSORIO, M. A. (2008). DISEÑO DE UNA ARQUITECTURA PARA UNA RED NEURONAL. Lima Perú: PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ.
- Perez, M. (2009). Aplicación de redes neuronales artificiales para predicción de variables en ingeniería del riego. Valencia - España: Unuversidad politecnica de Valencia.
- Prabhavathi, V. R., & Kuppusamy, P. (2022). A Study on Deep LeRNAing Based Soil Classification. doi: 10.1109/ICCCMLA56841.2022.9989293
- RAMIRES, M. C. (2013). REDES NEURONALES EVOLUTIVAS MULTIOBJETIVO PARA CLASIFICACION NOMINAL Y ORDINAL. ANDALUCIA - ESPAÑA: UNIVERSIDAD DE GRANADA.
- Samarasinghe, S. (2006). Neural Networks for Applied Sciences and Engineering. CHICAGO - EEUU: Taylor & Francis Group.
- Sifontes, R. J. (2010). ESTIMACION DE DEMANDA A MEDIANO PLAZO DE LA SUB ESTACION LAGUNITA UTILIZANDO REDES NEURONALES. Sartenejas - Venezuela: UNIVERSIDAD SIMON BOLIVAR.
- Sulewska, M. J. (2011). Application of Artificial Neural Networks for Analysis of Geotechnical Problems. Computer Assisted Mechanics and Engineering Sciences, 18(4), 231-241.
- Tang, L., Wang, Y., Zhang, Y., & Ye, S. (2023). Prediction of Soil Engineering Properties by Artificial Neural Networks: A Review. Journal of Rock Mechanics and Geotechnical Engineering, 15(2), 449-462.  
<https://doi.org/10.1016/j.jrmge.2022.05.007>



Tello, M. H. (2017). "USO DE LAS REDES NEURONALES ARTIFICIALES EN EL MODELADO DEL ENSAYO DE RESISTENCIA A COMPRESIÓN DE CONCRETO DE CONSTRUCCIÓN SEGÚN LA NORMA ASTM C39/C 39M". CAJAMARCA - PERU: UNIVERSIDAD NACIONAL DE CAJAMARCA.

Valdés Holguín, N. J. (2011). Estimación de la resistencia a la penetración de suelos usando redes neuronales artificiales. Acta Agronómica, Vol. 60 No. 3, 2011



## ANEXOS



## ANEXO 01

### Ensayos de Propiedades mecánicas del Suelo Natural



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA



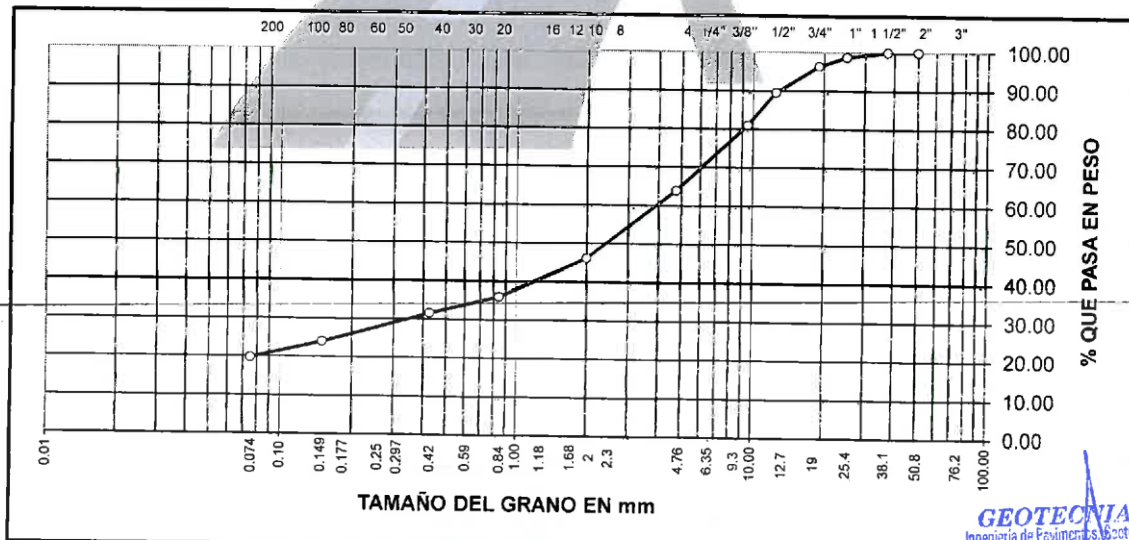
PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 01**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 28/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2489 Grs
2 1/2"	63.000				100.00		Peso fracción : 471 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 36.09 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 44.11 %
1"	25.000	30.00	1.21	1.21	98.79		Fino : 19.80 %
3/4"	19.000	61.00	2.45	3.66	96.34		W natural : <b>8.68</b> %
1/2"	12.500	170.00	6.83	10.49	89.51		
3/8"	9.500	212.00	8.52	19.01	80.99		LIMITES DE CONSISTENCIA
No.04	4.750	425.00	17.08	36.09	63.91		L.L. : 33.89 %
No.10	2.000	131.00	17.78	53.87	46.13		L.P. : 27.67 %
No.20	0.840	75.00	10.18	64.05	35.95		I.P. : 6.21 %
No.40	0.425	32.00	4.34	68.39	31.61		
No.100	0.150	56.00	7.60	75.99	24.01		CLASIFICACION
No.200	0.075	31.00	4.21	80.20	19.80		SUCS : <b>SC-SM</b>
<No.200		146.00	5.81	100.0			AASHTO :

REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Geotecnia, Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81384

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.



PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS

PROGRESIVA : CALICATA 01

MUESTRA : TERRENO DE FUNDACION


PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE

FECHA : 28/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. DE GOLPES	24	14	26T	27T
01. No.DE GOLPES	34	24	14		
02. TARRO No.	38	39	40	26T	27T
03. SUELO HUMEDO * TARRO g	38.25	34.62	36.71	30.92	30.82
04. SUELO SECO * TARRO g	31.74	28.68	29.92	25.24	25.03
05. PESO DEL AGUA g	6.51	5.94	6.79	5.68	5.79
06. PESO DEL TARRO g	11.46	11.44	11.42	4.39	4.43
07. PESO DEL SUELO SECO g	20.28	17.24	18.50	20.85	20.60
08. HUMEDAD %	32.10	34.45	36.70	27.24	28.11
L.L.= 33.89 %		L.P.= 27.67 %		I.P.= 6.21 %	



**GEOTECNIA PUNO SRL.**  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

**ALFREDO ALARCON ATAHUACHI**  
INGENIERO CIVIL  
Reg. C.R. 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 02**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 28/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 3244 Grs
2 1/2"	63.000				100.00		Peso fracción : 526 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 30.34 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 45.83 %
1"	25.000	23.00	0.71	0.71	99.29		Fino : 23.83 %
3/4"	19.000	120.00	3.70	4.41	95.59		W natural : <b>11.34 %</b>
1/2"	12.500	233.00	7.18	11.59	88.41		
3/8"	9.500	177.00	5.46	17.05	82.95		LIMITES DE CONSISTENCIA
No.04	4.750	431.00	13.29	30.34	69.66		L.L. : 35.28 %
No.10	2.000	102.00	3.15	43.85	56.15		L.P. : 26.92 %
No.20	0.840	67.00	8.87	52.72	47.28		I.P. : 8.36 %
No.40	0.425	40.00	5.30	58.02	41.98		
No.100	0.150	93.00	12.92	70.34	29.66		CLASIFICACION
No.200	0.075	44.00	5.83	76.17	23.83		SUCS : <b>SC</b>
<No.200		180.00	5.64	100.0			AASHTO :

REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

ALFREDO ALARCÓN ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

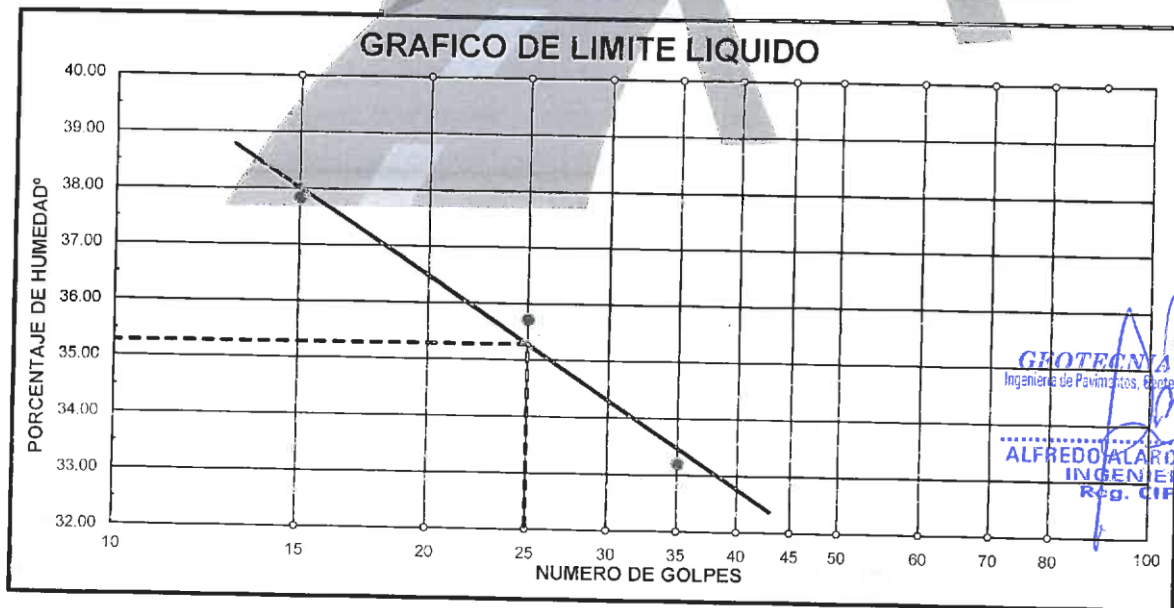


**PROYECTO** : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
**PROGRESIVA** : CALICATA 02  
**MUESTRA** : TERRENO DE FUNDACION  
**PROFUND.** : 0.00- 1.50 m (M-1)

**SOLICITANTE:** ING. RUBEN F. SOSA AQUISE  
**FECHA** : 28/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. DE GOLPES	25	30	28T	29T
01. No. DE GOLPES	35	25	15		
02. TARRO No.	41	42	43	28T	29T
03. SUELO HUMEDO * TARRO g	39.51	35.28	37.36	31.46	31.25
04. SUELO SECO * TARRO g	32.51	29.00	30.25	25.67	25.62
05. PESO DEL AGUA g	7.00	6.28	7.11	5.79	5.63
06. PESO DEL TARRO g	11.43	11.42	11.46	4.42	4.45
07. PESO DEL SUELO SECO g	21.08	17.58	18.79	21.25	21.17
08. HUMEDAD %	33.21	35.72	37.84	27.25	26.59
<b>L.L.=</b>	<b>35.28 %</b>	<b>L.P.=</b>	<b>26.92 %</b>	<b>I.P.=</b>	<b>8.36 %</b>



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Estudios de Consultoría y Construcción

**ALFREDO ALARCON ATAHUACHI**  
INGENIERO CIVIL  
REG. CIP 81732



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 03**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 28/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2911 Grs
2 1/2"	63.000				100.00		Peso fracción : 766 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 16.87 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 54.37 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 28.76 %
3/4"	19.000	28.00	0.96	0.96	99.04		W natural : <b>5.70</b> %
1/2"	12.500	169.00	5.81	6.77	93.23		
3/8"	9.500	85.00	2.92	9.69	90.31		LIMITES DE CONSISTENCIA
No.04	4.750	209.00	7.18	16.87	83.13		L.L. : 36.11 %
No.10	2.000	95.00	10.31	27.18	72.82		L.P. : 24.85 %
No.20	0.840	100.00	10.85	38.03	61.97		I.P. : 11.26 %
No.40	0.425	55.00	5.97	44.00	56.00		CLASIFICACION
No.100	0.150	144.00	15.63	59.63	43.37		SUCS : <b>SC</b>
No.200	0.075	107.00	11.61	71.24	28.76		AASHTO :
<No.200		265.00	28.76	100.00			

REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Asesoría Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

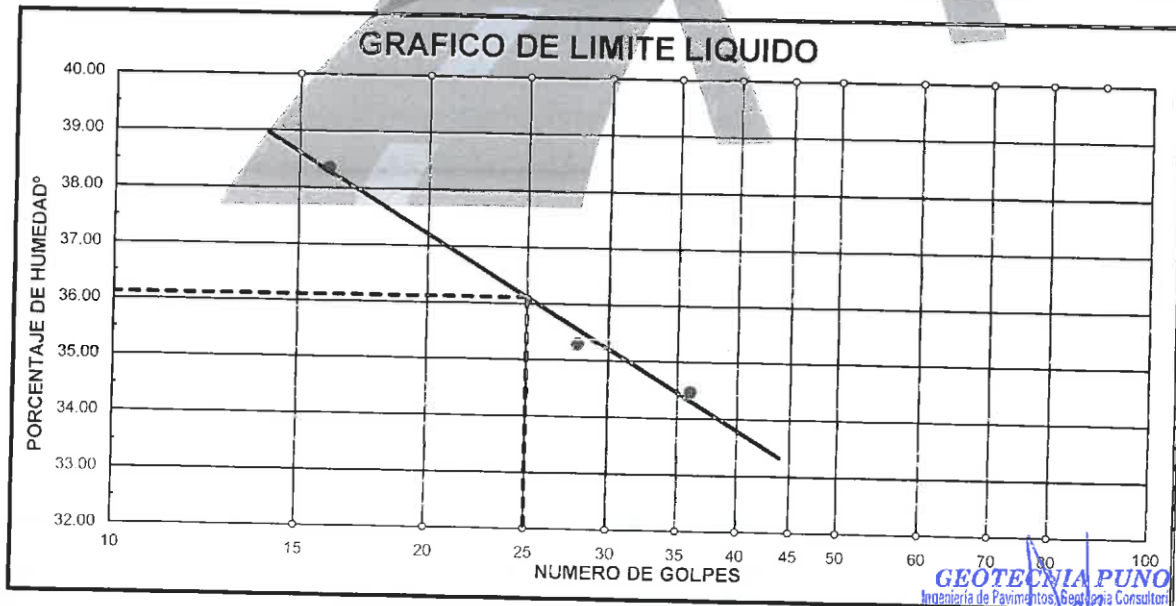


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 03  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 28/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. Golpes	W <sub>L</sub> (%)	W <sub>P</sub> (%)	W <sub>L</sub> - W <sub>P</sub>	W <sub>P</sub> - W <sub>U</sub>
01. No.DE GOLPES	36	28	16		
02. TARRO No.	45	46	47	30T	31T
03. SUELO HUMEDO * TARRO	g	41.26	36.71	38.52	35.26
04. SUELO SECO * TARRO	g	33.62	30.12	31.02	29.16
05. PESO DEL AGUA	g	7.64	6.59	7.50	6.10
06. PESO DEL TARRO	g	11.47	11.45	11.48	4.48
07. PESO DEL SUELO SECO	g	22.15	18.67	19.54	24.68
08. HUMEDAD	%	34.49	35.30	38.38	24.72
<b>L.L.= 36.11 %      L.P.= 24.85 %      I.P.= 11.26 %</b>					



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

**ALFREDO ALARCON ATAHUACHI**  
INGENIERO CIVIL  
Reg. CIP 81720

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.



PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS

PROGRESIVA : **CALICATA 04**

MUESTRA : TERRENO DE FUNDACION

PROFUND. : 0.00- 1.50 m (M-1)


SOLICITANTE : ING. RUBEN F. SOSA AQUISE

FECHA : 28/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 3474 Grs
2 1/2"	63.000				100.00		Peso fracción : 734 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 12.12 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 51.71 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 36.17 %
3/4"	19.000	0.00	0.00	0.00	100.00		W natural : <b>12.87 %</b>
1/2"	12.500	43.00	1.24	1.24	98.76		
3/8"	9.500	62.00	1.78	3.02	96.98		LIMITES DE CONSISTENCIA
No.04	4.750	316.00	9.10	12.12	87.88		L.L. : 39.04 %
No.10	2.000	136.00	16.28	28.40	71.60		L.P. : 23.51 %
No.20	0.840	60.00	7.18	35.58	64.42		I.P. : 15.53 %
No.40	0.425	28.00	3.35	38.93	61.07		
No.100	0.150	143.00	17.12	56.05	43.95		CLASIFICACION
No.200	0.075	65.00	7.78	63.83	36.17		SUCS : <b>SC</b>
<No.200		302.00	8.16	100.0			AASHTO :

REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO E.I.R.L. Ingeniería de Edificación, Construcción Civil y Construcción

ALFREDO ALARCÓN ATAHUACHI INGENIERO CIVIL

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : CALICATA 04  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
 FECHA : 28/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. de Golpes	24	15	32T	33T
01. No.DE GOLPES	35	24	15		
02. TARRO No.	48	49	50	32T	33T
03. SUELO HUMEDO * TARRO g	44.02	38.98	39.82	36.61	35.17
04. SUELO SECO * TARRO g	35.24	31.14	31.47	30.44	29.36
05. PESO DEL AGUA g	8.78	7.84	8.35	6.17	5.81
06. PESO DEL TARRO g	11.44	11.42	11.43	4.42	4.43
07. PESO DEL SUELO SECO g	23.80	19.72	20.04	26.02	24.93
08. HUMEDAD %	36.89	36.76	41.67	23.71	23.31
<b>L.L.=</b>	<b>39.04 %</b>	<b>L.P.=</b>	<b>23.51 %</b>	<b>I.P.=</b>	<b>15.53 %</b>



GEOTECNIA PUNO E.I.R.L.  
 Ingeniería de Construcción, Geotecnia Consultoría

ALFREDO ALARCÓN ATAHUACHI  
 INGENIERO CIVIL  
 Reg. CIP 81720

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO | ETAPA - JULIACA  
 alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 05**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 28/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 4041 Grs
2 1/2"	63.000				100.00		Peso fracción : 851 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 33.88 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 51.98 %
1"	25.000	27.00	0.67	0.67	99.33		Fino : 14.14 %
3/4"	19.000	125.00	3.09	3.76	96.24		W natural : <b>8.41</b> %
1/2"	12.500	227.00	5.62	9.38	90.62		
3/8"	9.500	299.00	7.40	16.78	83.22		LIMITES DE CONSISTENCIA
No.04	4.750	691.00	17.10	33.88	66.12		L.L. : 29.17 %
No.10	2.000	279.00	21.68	55.56	44.44		L.P. : 26.82 %
No.20	0.840	195.00	15.15	70.71	29.29		L.P. : 2.35 %
No.40	0.425	80.00	6.29	76.93	23.07		
No.100	0.150	81.00	6.29	83.22	16.78		CLASIFICACION
No.200	0.075	34.00	2.64	85.86	14.14		SUCS : <b>SM</b>
<No.200		182.00	4.54	100.0			AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO SRL.  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : CALICATA 05  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
 FECHA : 28/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. de Golpes	24	15	34T	35T
01. No.DE GOLPES	35	24	15		
02. TARRO No.	51	52	53	34T	35T
03. SUELO HUMEDO * TARRO	g 44.72	40.02	42.71	37.26	38.25
04. SUELO SECO * TARRO	g 37.45	33.62	35.22	30.31	31.12
05. PESO DEL AGUA	g 7.27	6.40	7.49	6.95	7.13
06. PESO DEL TARRO	g 11.47	11.46	11.48	4.46	4.47
07. PESO DEL SUELO SECO	g 25.98	22.16	23.74	25.85	26.65
08. HUMEDAD	% 27.98	28.88	31.55	26.89	26.75
<b>L.L.=</b>	<b>29.17 %</b>	<b>L.P.=</b>	<b>26.82 %</b>	<b>I.P.=</b>	<b>2.35 %</b>



GEOTECNIA PUNO EIRL.  
 Ingeniería de Pavimentos, Obras de Consultoría y Construcción

ALFREDO ALARCÓN ATAHUACHI  
 INGENIERO CIVIL

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
 alfredalarcon2@hotmail.com / Cel. 979000744



# GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.



PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS

PROGRESIVA : **CALICATA 06**

MUESTRA : TERRENO DE FUNDACION

PROFUND. : 0.00- 1.50 m (M-1)


SOLICITANTE : ING. RUBEN F. SOSA AQUISE

FECHA : 28/03/2021

## ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 3481 Grs
2 1/2"	63.000				100.00		Peso fracción : 739 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 46.25 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 43.93 %
1"	25.000	153.00	4.40	4.40	95.60		Fino : 9.82 %
3/4"	19.000	243.00	6.98	11.38	88.62		W natural : <b>9.54</b> %
1/2"	12.500	415.00	11.92	23.30	76.70		
3/8"	9.500	252.00	7.24	30.54	69.46		LIMITES DE CONSISTENCIA
No.04	4.750	547.00	15.71	46.25	53.75		L.L. : 26.25 %
No.10	2.000	228.00	16.58	62.83	37.17		L.P. : NP %
No.20	0.840	159.00	11.56	74.39	25.61		I.P. : NP %
No.40	0.425	77.00	5.60	79.99	20.01		
No.100	0.150	101.00	7.35	87.34	12.66		CLASIFICACION
No.200	0.075	39.00	2.84	90.18	9.82		SUCS : <b>SM</b>
<No.200		135.00	6.82	100.0			AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Geotecnia, Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 06  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 28/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION		LIMITE LIQUIDO			LIMITE PLASTICO		
01.	No.DE GOLPES	34	25	16			
02.	TARRO No.	54	55	56			
03.	SUELO HUMEDO * TARRO	g 46.92	42.56	45.81			
04.	SUELO SECO * TARRO	g 40.01	36.03	38.11			
05.	PESO DEL AGUA	g 6.91	6.53	7.70		NP	
06.	PESO DEL TARRO	g 11.45	11.44	11.42			
07.	PESO DEL SUELO SECO	g 28.56	24.59	26.69			
08.	HUMEDAD	% 24.19	26.56	28.85			
L.L.=		26.25 %	L.P.=	NP %	I.P.= NP %		



GEOTECNIA PUNO E.I.R.L.  
Ingeniería de Civil, Construcción y Edificación

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81789

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : **CALICATA 07**  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
 FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulad	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2197 Grs
2 1/2"	63.000				100.00		Peso fracción : 410 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 41.59 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 44.87 %
1"	25.000	32.00	1.46	1.46	98.54		Fino : 13.54 %
3/4"	19.000	19.00	0.86	2.32	97.68		W natural : <b>12.65 %</b>
1/2"	12.500	102.00	4.64	6.96	93.04		
3/8"	9.500	142.00	6.46	13.42	86.58		LIMITES DE CONSISTENCIA
No.04	4.750	619.00	28.17	41.59	58.41		L.L. : 28.39 %
No.10	2.000	163.00	23.22	64.81	35.19		L.P. : 27.33 %
No.20	0.840	62.00	8.83	73.64	26.36		I.P. : 1.06 %
No.40	0.425	25.00	3.56	77.20	22.80		
No.100	0.150	43.00	6.13	83.33	16.67		CLASIFICACION
No.200	0.075	22.00	3.13	86.46	13.54		SUCS : <b>SM</b>
<No.200		95.00	13.53	100.0			AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



**GEOTECNIA PUNO EIRL**  
 Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

**ALFREDO ALARCÓN ATAHUACHI**  
 INGENIERO CIVIL  
 Reg. CIP. 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
 alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




**PROYECTO** : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
**PROGRESIVA** : CALICATA 07  
**MUESTRA** : TERRENO DE FUNDACION  
**PROFUND.** : 0.00- 1.50 m (M-1)

**SOLICITANTE:** ING. RUBEN F. SOSA AQUISE  
**FECHA** : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. Golpes	W <sub>1</sub> (%)	W <sub>2</sub> (%)	W <sub>p</sub> (%)	W <sub>L</sub> (%)
01. No. DE GOLPES	36	25	16		
02. TARRO No.	54	55	56	36T	37T
03. SUELO HUMEDO * TARRO	g	45.62	41.62	44.72	39.25 40.21
04. SUELO SECO * TARRO	g	38.51	34.92	36.91	31.86 32.46
05. PESO DEL AGUA	g	7.11	6.70	7.81	7.39 7.75
06. PESO DEL TARRO	g	11.45	11.49	11.52	4.51 4.42
07. PESO DEL SUELO SECO	g	27.06	23.43	25.39	27.35 28.04
08. HUMEDAD	%	26.27	28.60	30.76	27.02 27.64
<b>L.L.=</b>	<b>28.39 %</b>	<b>L.P.=</b>	<b>27.33 %</b>	<b>I.P.=</b>	<b>1.06 %</b>



**GEOTECNIA Y/O EIRL.**  
 Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

**ALFREDO LARCON ATAHUACHI**  
 INGENIERO CIVIL  
 Reg. CIP: 31732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
 alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 08**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2767 Grs
2 1/2"	63.000				100.00		Peso fracción : 405 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 30.22 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 60.99 %
1"	25.000	21.00	0.76	0.76	99.24		Fino : 8.79 %
3/4"	19.000	79.00	2.86	3.62	96.38		W natural : <b>5.75 %</b>
1/2"	12.500	112.00	4.05	7.67	92.33		
3/8"	9.500	108.00	3.90	11.57	88.43		LIMITES DE CONSISTENCIA
No.04	4.750	516.00	18.65	30.22	69.78		L.L. : 27.23 %
No.10	2.000	171.00	29.46	59.68	40.32		L.P. : NP %
No.20	0.840	109.00	18.78	78.46	21.54		I.P. : NP %
No.40	0.425	40.00	6.89	85.35	14.65		
No.100	0.150	26.00	4.46	89.83	10.17		CLASIFICACION
No.200	0.075	8.00	1.38	91.21	8.79		SUCS : <b>SM</b>
<No.200		51.00	8.79	100.0			AASHTO :

REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Estructuras, Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




**PROYECTO** : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
**PROGRESIVA** : CALICATA 08  
**MUESTRA** : TERRENO DE FUNDACION  
**PROFUND.** : 0.00- 1.50 m (M-1)

**SOLICITANTE:** ING. RUBEN F. SOSA AQUISE  
**FECHA** : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO		
01. No.DE GOLPES	35	24	15			
02. TARRO No	57	58	59			
03. SUELO HUMEDO * TARRO g	43.21	38.26	41.32			
04. SUELO SECO * TARRO g	36.82	32.41	34.46			NP
05. PESO DEL AGUA g	6.39	5.85	6.86			
06. PESO DEL TARRO g	11.42	11.42	11.47			
07. PESO DEL SUELO SECO g	25.40	20.99	22.99			
08. HUMEDAD %	25.16	27.87	29.84			
<b>L.L.=</b>	<b>27.23 %</b>	<b>L.P.=</b>	<b>NP %</b>	<b>I.P.=</b>	<b>NP %</b>	



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Geotecnia, Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
RUBEN F. SOSA AQUISE

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



# GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.



PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS

PROGRESIVA : **CALICATA 09**

MUESTRA : TERRENO DE FUNDACION

PROFUND. : 0.00- 1.50 m (M-1)


SOLICITANTE : ING. RUBEN F. SOSA AQUISE

FECHA : 29/03/2021

## ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 3002 Grs
2 1/2"	63.000				100.00		Peso fracción : 432 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 19.26 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 26.72 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 54.02 %
3/4"	19.000	106.00	3.53	3.53	96.47		W natural : <b>10.23</b> %
1/2"	12.500	65.00	2.17	5.70	94.30		
3/8"	9.500	75.00	2.50	8.20	91.80		LIMITES DE CONSISTENCIA
No.04	4.750	332.00	11.06	19.26	80.74		L.L. : 44.07 %
No.10	2.000	29.00	5.42	24.68	75.32		L.P. : 28.67 %
No.20	0.840	22.00	4.11	28.79	71.21		I.P. : 15.40 %
No.40	0.425	17.00	3.18	31.97	68.03		
No.100	0.150	50.00	9.34	41.31	58.69		ELASIFICACION
No.200	0.075	25.00	4.67	45.98	54.02		SUCS : <b>ML</b>
<No.200		289.00	54.01	100.0			AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Estructuras Consultoría y Construcción

**ALFREDO ALARCON ATAHUACHI**  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

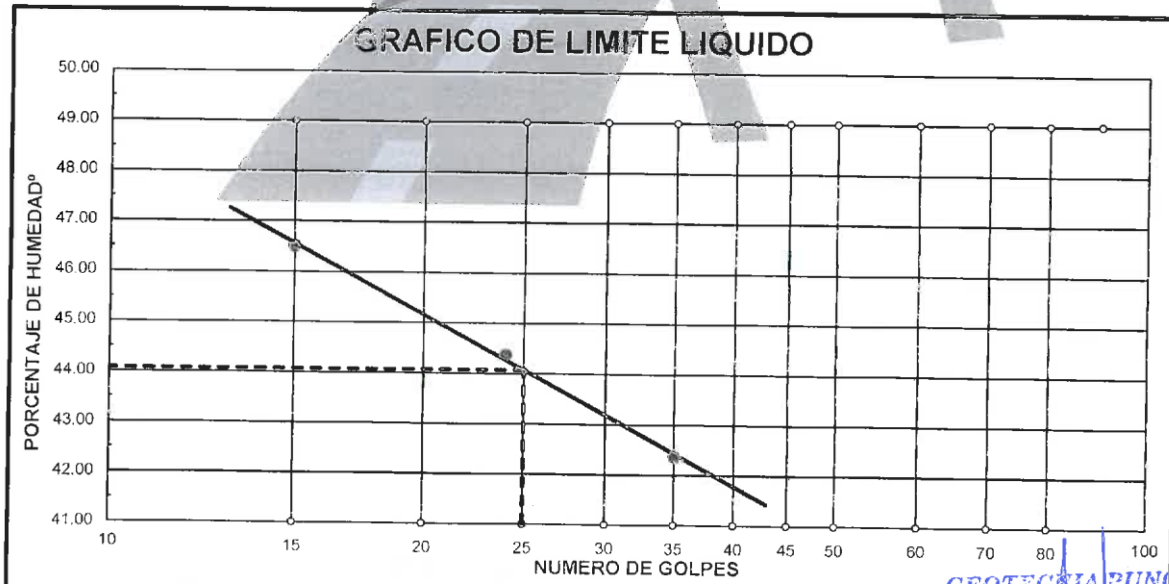


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : CALICATA 09  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
 FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO		
01. No. DE GOLPES	35	24	15			
02. TARRO No.	57	58	59	40T	41T	
03. SUELO HUMEDO * TARRO	g 49.62	44.51	48.77	41.62	42.92	
04. SUELO SECO * TARRO	g 38.24	34.32	36.91	33.45	34.26	
05. PESO DEL AGUA	g 11.38	10.19	11.86	8.17	8.66	
06. PESO DEL TARRO	g 11.38	11.36	11.41	4.45	4.56	
07. PESO DEL SUELO SECO	g 26.86	22.96	25.50	29.00	29.70	
08. HUMEDAD	% 42.37	44.38	46.51	28.17	29.16	
<b>L.L.=</b>	<b>44.07 %</b>	<b>L.P.=</b>	<b>28.67 %</b>	<b>I.P.=</b>	<b>15.40 %</b>	



GEOTECNIA PUNO EIRL.  
 Ingeniería de Geotecnia, Pavimentos y Construcción

ALFREDO ALARCON ATAHUACHI  
 INGENIERO CIVIL  
 RUC: 20509012345

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
 alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.



PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS

PROGRESIVA : **CALICATA 10**

MUESTRA : TERRENO DE FUNDACION

PROFUND. : 0.00- 1.50 m (M-1)


SOLICITANTE : ING. RUBEN F. SOSA AQUISE

FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 3063 Grs
2 1/2"	63.000				100.00		Peso fracción : 463 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 21.78 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 51.19 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 27.03 %
3/4"	19.000	49.00	1.60	1.60	98.40		W natural : <b>7.44</b> %
1/2"	12.500	133.00	4.34	5.94	94.06		
3/8"	9.500	105.00	3.43	9.37	90.63		LIMITES DE CONSISTENCIA
No.04	4.750	380.00	12.41	21.78	78.22		L.L. : 33.09 %
No.10	2.000	115.00	19.43	41.21	58.79		L.P. : 23.08 %
No.20	0.840	85.00	14.36	55.57	44.43		I.P. : 10.01 %
No.40	0.425	38.00	6.42	61.99	38.01		
No.100	0.150	43.00	7.26	69.25	30.75		CLASIFICACION
No.200	0.075	22.00	3.72	72.97	27.03		SUCS : <b>SC</b>
<No.200		160.00	27.03	100.0			AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

**ALFREDO ALARCON ATAHUACHI**  
INGENIERO CIVIL  
Reg. CIP 81788

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : CALICATA 10  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
 FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. de Golpes	W <sub>L</sub> (%)	W <sub>P</sub> (%)	W <sub>L</sub> (%)	W <sub>P</sub> (%)
01. No. DE GOLPES	35	26	15		
02. TARRO No.	57	58	59	42T	43T
03. SUELO HUMEDO * TARRO	g	32.92	31.86	33.51	42.62 / 43.29
04. SUELO SECO * TARRO	g	28.76	27.80	28.78	35.36 / 36.12
05. PESO DEL AGUA	g	4.16	4.06	4.73	7.26 / 7.17
06. PESO DEL TARRO	g	15.45	15.50	15.53	4.49 / 4.44
07. PESO DEL SUELO SECO	g	13.31	12.30	13.25	30.87 / 31.68
08. HUMEDAD	%	31.25	33.01	35.70	23.52 / 22.63
L.L.=		33.09 %	L.P.=		23.08 %
					I.P.= 10.01 %



GEOTECNIA PUNO E.I.R.L.  
 Ingeniería de Edificación, Geotecnia y Construcción

ALFREDO ALARCON ATAHUACHI  
 INGENIERO CIVIL  
 Rcg. CIB 81733

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
 alfredalarcon2@hotmail.com / Cel. 979000744



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.




PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : **CALICATA 11**  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
 FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 3336 Grs
2 1/2"	63.000				100.00		Peso fracción : 408 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 38.85 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 53.20 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 7.95 %
3/4"	19.000	19.00	0.57	0.57	99.43		W natural : <b>13.13 %</b>
1/2"	12.500	145.00	4.35	4.92	95.08		
3/8"	9.500	323.00	9.68	14.60	85.40		LIMITES DE CONSISTENCIA
No.04	4.750	809.00	24.25	38.85	61.15		L.L. : 20.29 %
No.10	2.000	138.00	20.68	59.53	40.47		L.P. : NP %
No.20	0.840	84.00	12.59	72.12	27.88		I.P. : NP %
No.40	0.425	65.00	9.74	81.86	18.14		
No.100	0.150	57.00	8.54	90.40	9.60		CLASIFICACION
No.200	0.075	11.00	1.65	92.05	7.95		SUCS : <b>SC</b>
<No.200		53.00	1.64	100.0			AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



**GEOTECNIA PUNO EIRL**  
 Ingeniería de Pavimentos, Geotecnia y Construcción

**ALFREDO ALARCON ATAHUACHI**  
 INGENIERO CIVIL  
 Reg. CIP 13777

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIACA  
 alfredalarcon2@hotmail.com / Cel. 979000744



## GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN


MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 11  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO		
	No. de Golpes	W <sub>L</sub> (%)	W <sub>P</sub> (%)	W <sub>L</sub> (%)	W <sub>P</sub> (%)	W <sub>L</sub> (%)
01. No. DE GOLPES	35	25	15			
02. TARRO No.	60	61	62			
03. SUELO HUMEDO * TARRO	g	36.38	35.26	36.92		
04. SUELO SECO * TARRO	g	33.16	31.91	32.92		
05. PESO DEL AGUA	g	3.22	3.35	4.00	NP	
06. PESO DEL TARRO	g	15.52	15.62	15.53		
07. PESO DEL SUELO SECO	g	17.64	16.29	17.39		
08. HUMEDAD	%	18.25	20.56	23.00		
<b>L.L.=</b>	<b>20.29 %</b>	<b>L.P.=</b>	<b>NP %</b>	<b>I.P.=</b>	<b>NP %</b>	



GEOTECNIA PUÑO EIRL.  
Ingeniería de Pavimentos, Lección Consultoría y Construcción

ALFREDO ALARCÓN ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP. 81732



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 12**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2767 Grs
2 1/2"	63.000						Peso fracción : 632 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 8.60 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 84.75 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 6.65 %
3/4"	19.000	0.00	0.00	0.00	100.00		W natural : <b>11.10 %</b>
1/2"	12.500	8.00	0.29	0.29	99.71		
3/8"	9.500	55.00	1.99	2.28	97.72		
No.04	4.750	175.00	6.32	8.60	91.40		LIMITES DE CONSISTENCIA
No.10	2.000	103.00	14.90	23.50	76.50		LL : NP %
No.20	0.840	152.00	21.98	45.48	54.52		LP : NP %
No.40	0.425	196.00	28.55	73.83	26.17		IP : NP %
No.100	0.150	120.00	17.35	91.18	8.82		
No.200	0.075	15.00	2.17	93.35	6.65		CLASIFICACION
<No.200		46.00	8.65	100.0			SUCS : <b>SM</b>
							AASHTO

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Geotecnia y Construcción

**ALFREDO ALARCÓN ATAHUACHI**  
INGENIERO CIVIL  
Reg. CIP 81732



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

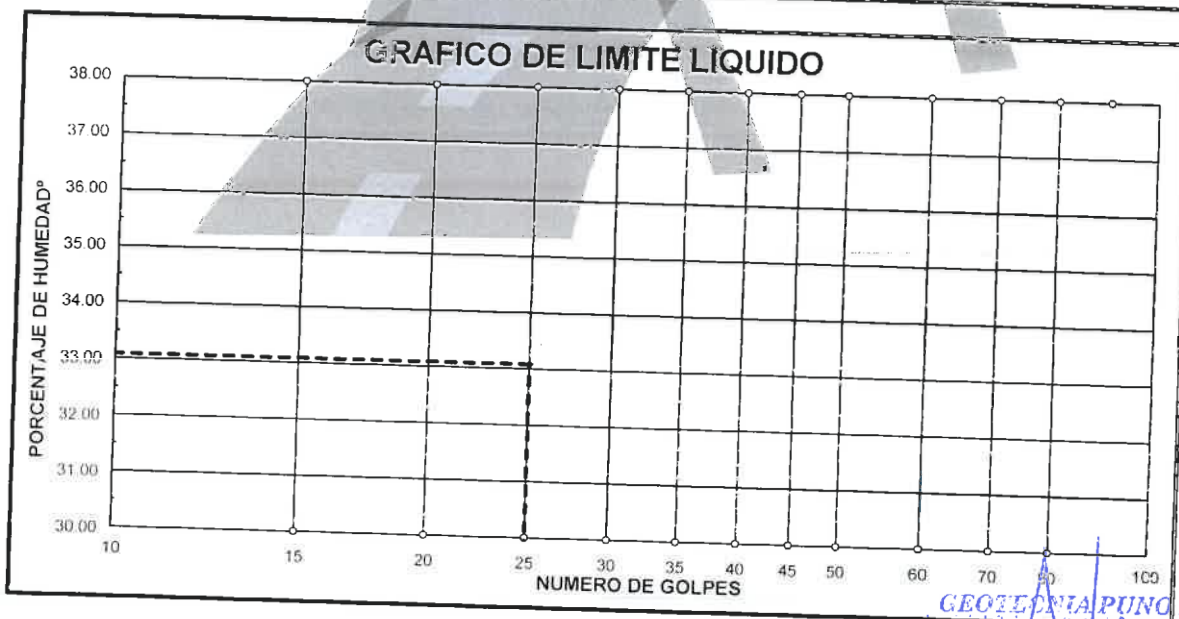
MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 12  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO				
01. No.DE GOLPES								
02. TARRO No.								
03. SUELO HUMEDO * TARRO g								
04. SUELO SECO * TARRO g		NP				NP		
05. PESO DEL AGUA g								
06. PESO DEL TARRO g								
07. PESO DEL SUELO SECO g								
08. HUMEDAD %								
L.L.=	NP	%	L.P.=	NP	%	I.P.=	NP	%



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Cimentaciones y Construcción

ALFREDO ALARCÓN ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 13**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2786 Grs
2 1/2"	63.000				100.00		Peso fracción : 446 Grs
2"	50.000	202.00	7.25	7.25	92.75		Grava : 24.05 %
1 1/2"	37.500	194.00	6.96	14.21	85.79		Arena : 39.85 %
1"	25.000	15.00	0.54	14.75	85.25		Fino : 36.10 %
3/4"	19.000	20.00	0.72	15.47	84.53		W natural : <b>20.53 %</b>
1/2"	12.500	59.00	2.12	17.59	82.41		
3/8"	9.500	46.00	1.65	19.24	80.76		LIMITES DE CONSISTENCIA
No.04	4.750	134.00	4.81	24.05	75.95		L.L. : 27.02 %
No.10	2.000	32.00	5.45	29.50	70.50		L.P. : 24.05 %
No.20	0.840	26.00	4.43	33.93	66.07		I.P. : 2.97 %
No.40	0.425	28.00	4.77	38.70	61.30		
No.100	0.150	66.00	11.24	49.94	50.06		CLASIFICACION
No.200	0.075	82.00	13.96	63.90	36.10		SUCS : <b>SM</b>
<No.200		212.00	38.10	100.00			AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL  
Ingeniería de Pavimentos, Obras de Consultoría y Construcción

ALFREDO AZARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. C.P. 81732



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN


MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 13  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. Golpes	25	16	05T	06T
01. No.DE GOLPES	34	25	16		
02. TARRO No.	12	13	14		
03. SUELO HUMEDO * TARRO g	23.84	26.52	26.41	13.05	12.81
04. SUELO SECO * TARRO g	21.32	23.25	22.91	11.34	11.15
05. PESO DEL AGUA g	2.52	3.27	3.50	1.71	1.66
06. PESO DEL TARRO g	11.18	11.21	11.24	4.23	4.25
07. PESO DEL SUELO SECO g	10.14	12.04	11.67	7.11	6.90
08. HUMEDAD %	24.85	27.16	29.99	24.05	24.06
L.L.= 27.02 %		L.P.= 24.05 %		I.P.= 2.97 %	



GEOTECNIA PUNO E.I.R.L.  
Ingeniería de Edificación, Mecánica de Suelos y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 14**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2604 Grs
2 1/2"	63.000				100.00		Peso fracción : 454 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 8.10 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 62.56 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 29.34 %
3/4"	19.000	0.00	0.00	0.00	100.00		W natural : <b>11.37 %</b>
1/2"	12.500	62.00	2.38	2.38	97.62		
3/8"	9.500	29.00	1.11	3.49	96.51		
No.04	4.750	120.00	4.61	8.10	91.90		LIMITES DE CONSISTENCIA
No.10	2.000	56.00	11.34	19.44	80.56		L.L. : 27.82 %
No.20	0.840	52.00	10.53	29.97	70.03		L.P. : 24.05 %
No.40	0.425	48.00	9.72	39.69	60.31		I.P. : 3.77 %
No.100	0.150	91.00	18.42	58.11	41.89		
No.200	0.075	62.00	12.65	70.66	29.34		CLASIFICACION
<No.200		145.00	29.35	100.0			SUCS : <b>SM</b>
							AASHTO :

REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

ALFREDO ALARCÓN ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP. 81732



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCION


MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 14  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. Golpes	26	16	07T	08T
01. No.DE GOLPES	36	26	16		
02. TARRO No.	17	18	19		
03. SUELO HUMEDO * TARRO g	24.52	27.92	28.35	14.25	14.26
04. SUELO SECO * TARRO g	21.82	24.32	24.32	12.32	12.32
05. PESO DEL AGUA g	2.70	3.60	4.03	1.93	1.94
06. PESO DEL TARRO g	11.21	11.24	11.22	4.26	4.29
07. PESO DEL SUELO SECO g	10.61	13.08	13.10	8.06	8.03
08. HUMEDAD %	25.45	27.52	30.76	23.95	24.16
<b>L.L.=</b>	<b>27.82 %</b>	<b>L.P.=</b>	<b>24.05 %</b>	<b>I.P.=</b>	<b>3.77 %</b>



GEOTECNIA FUNO EIRL  
Ingeniería de Pavimentos, Asesoría Consultoría y Construcción

ALFREDO ALARCÓN ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 15**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2588 Grs
2 1/2"	63.000				100.00		Peso fracción : 410 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 12.40 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 42.73 %
1"	25.000	21.00	0.81	0.81	99.19		Fino : 44.87 %
3/4"	19.000	35.00	1.35	2.16	97.84		W natural : <b>15.19 %</b>
1/2"	12.500	65.00	2.51	4.67	95.33		
3/8"	9.500	60.00	2.32	6.99	93.01		LIMITES DE CONSISTENCIA
No.04	4.750	140.00	5.41	12.40	87.60		L.L. : 39.80 %
No.10	2.000	25.00	5.34	17.74	82.26		L.P. : 29.93 %
No.20	0.840	22.00	4.70	22.44	77.56		I.P. : 9.87 %
No.40	0.425	23.00	4.91	27.35	72.65		
No.100	0.150	65.00	13.89	41.24	58.76		CLASIFICACION
No.200	0.075	65.00	13.89	55.13	44.87		SUCS : <b>SC</b>
<No.200		210.00	24.87	100.0			AASHTO : <b>SC</b>

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA RUBEN F. SOSA AQUISE E.I.R.L.  
Ingeniería de Pavimentos, Geotecnia, Consultoría y Construcción.

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
R.G. CH. 81732





PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : CALICATA 15  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)


SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
 FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	35	26	16	11T	12T
01. No DE GOLPES	20	21	22		
02. TARRO No.	26.51	29.58	32.56	15.42	16.68
03. SUELO HUMEDO * TARRO	22.32	24.35	26.24	12.92	13.77
04. SUELO SECO * TARRO	4.19	5.23	6.82	2.50	2.91
05. PESO DEL AGUA	11.23	11.24	11.23	4.30	4.34
06. PESO DEL TARRO	11.09	13.11	15.01	8.62	9.43
07. PESO DEL SUELO SECO	37.78	39.89	42.11	29.00	30.86
08. HUMEDAD					

L.L.=	39.80 %	L.P.=	%	I.P.=	9.87 %
-------	---------	-------	---	-------	--------



**GEOTECNIA PUNO EIRL.**  
 Ingeniería de Edificación, Geotecnia, Construcción y Construcción  
**ALFREDO ALARCÓN ATAHUACHI**  
 INGENIERO CIVIL  
 Reg. CIP

JR. TIAHUANACUS



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 16**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2427 Grs
2 1/2"	63.000				100.00		Peso fracción : 552 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 3.05 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 60.08 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 36.87 %
3/4"	19.000	27.00	1.11	1.11	98.89		W natural : <b>14.01 %</b>
1/2"	12.500	23.00	0.95	2.06	97.94		LIMITES DE CONSISTENCIA
3/8"	9.500	5.00	0.21	2.27	97.73		L.L. : 42.25 %
No.04	4.750	19.00	0.78	3.05	96.95		L.P. : 30.95 %
No.10	2.000	10.00	1.76	4.81	95.19		I.P. : 11.29 %
No.20	0.840	19.00	3.34	8.15	91.85		CLASIFICACION
No.40	0.425	44.00	7.73	15.88	84.12		SUCS : <b>SC</b>
No.100	0.150	175.00	30.74	46.62	53.38		AASHTC : .
No.200	0.075	94.00	16.51	63.13	36.87		
<No.200		210.00	36.88	100.0			

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Estabilidad Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCION

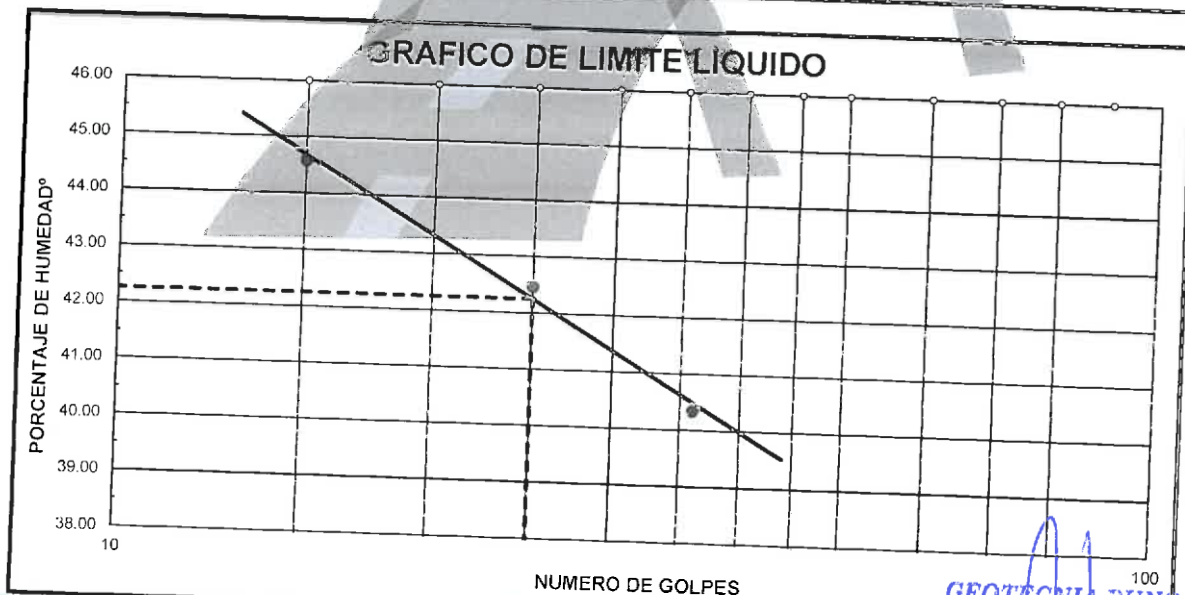
MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 16  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. DE GOLFES	W <sub>L</sub>	W <sub>P</sub>	W <sub>L</sub> - W <sub>P</sub>	W <sub>P</sub>
01. No. DE GOLFES	36	25	15		
02. TARRO No.	20	21	22	14T	15T
03. SUELO HUMEDO * TARRO	g	27.63	31.72	33.62	18.06
04. SUELO SECO * TARRO	g	22.92	25.62	26.72	14.86
05. PESO DEL AGUA	g	4.71	6.10	6.90	3.20
06. PESO DEL TARRO	g	11.25	11.26	11.25	4.37
07. PESO DEL SUELO SECO	g	11.67	14.36	15.47	4.41
08. HUMEDAD	%	40.36	42.48	44.60	30.51
					31.40
<b>L.L.=</b>	<b>42.25 %</b>	<b>L.P.=</b>	<b>30.95 %</b>	<b>I.P.=</b>	<b>11.29 %</b>



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Bases de Consulta y Construcción

**ALFREDO ALARCÓN ATAHUACHA**  
INGENIERO CIVIL  
Reg. CIP 81792

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 17**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 29/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2163 Grs
2 1/2"	63.000				100.00		Peso fracción : 479 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 1.39 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 73.70 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 24.91 %
3/4"	19.000	0.00	0.00	0.00	100.00		W natural : <b>14.89 %</b>
1/2"	12.500	0.00	0.00	0.00	100.00		
3/8"	9.500	24.00	1.11	1.11	98.89		LIMITES DE CONSISTENCIA
No.04	4.750	6.00	0.28	1.39	98.61		L.L : 30.20 %
No.10	2.000	30.00	6.18	7.57	92.43		L.P : 22.73 %
No.20	0.840	40.00	8.23	15.80	84.20		I.P : 7.47 %
No.40	0.425	40.00	8.23	24.03	75.97		
No.100	0.150	189.00	38.91	62.94	37.06		CLASIFICACION
No.200	0.075	59.00	12.15	75.09	24.91		SUCS : <b>SC</b>
<No.200		121.00	24.91	100.00			AASHTQ :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

**ALFREDO ALARCÓN ATAHUACHI**  
INGENIERO CIVIL  
Reg. CIP 81737

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN


MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
 PROGRESIVA : CALICATA 17  
 MUESTRA : TERRENO DE FUNDACION  
 PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUÍSE  
 FECHA : 29/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO			
	No.	g	%	16T	17T		
01. No.DE GOLPES	34	24	16				
02. TARRO No.	25	24	25	16T	17T		
03. SUELO HUMEDO * TARRO	g	30.75	33.36	36.41	19.24	19.35	
04. SUELO SECO * TARRO	g	26.45	28.21	30.21	16.55	16.53	
05. PESO DEL AGUA	g	4.30	5.15	6.20	2.69	2.82	
06. PESO DEL TARRO	g	11.31	11.29	11.32	4.41	4.43	
07. PESO DEL SUELO SECO	g	15.14	16.92	18.89	12.14	12.10	
08. HUMEDAD	%	28.40	30.44	32.82	22.16	23.31	
L.L.=		30.20 %	L.P.=		22.73 %	I.P.=	7.47 %



GEOTECNIA DIJNO EIRL.  
 Ingeniería de Patrimonios, Mecánica Geotécnica y Construcción

ALFREDO ALAHGÓN ATAHUACHI  
 INGENIERO CIVIL



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCION

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 18**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 30/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 2416 Grs
2 1/2"	63.000				100.00		Peso fracción : 406 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 0.12 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 42.31 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 57.57 %
3/4"	19.000	0.00	0.00	0.00	100.00		W natural : <b>23.14 %</b>
1/2"	12.500	0.00	0.00	0.00	100.00		
3/8"	9.500	0.00	0.00	0.00	100.00		LIMITES DE CONSISTENCIA
No.04	4.750	3.00	0.12	0.12	99.88		L.L. : 42.95 %
No.10	2.000	4.00	0.98	1.10	98.90		L.P. : 23.26 %
No.20	0.840	9.00	2.21	3.31	96.69		I.P. : 19.69 %
No.40	0.425	20.00	4.92	8.23	91.77		
No.100	0.150	93.00	22.88	31.11	68.86		CLASIFICACION
No.200	0.075	46.00	11.32	42.43	57.57		SUCS : <b>CL</b>
<No.200		234.00	57.57	100.0			AASHTO :

REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



**GEOTECNIA PUNO EIRL.**  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

**ALFREDO ALARCON ATAHUACHI**  
INGENIERO CIVIL  
Reg. CIF 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN


MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 18  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 30/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. de Golpes	25	15	18T	19T
01. No.DE GOLPES	35	25	15		
02. TARRO No.	29	30	31		
03. SUELO HUMEDO * TARRO	g	36.82	37.26	41.28	22.54
04. SUELO SECO * TARRO	g	29.51	29.35	31.92	19.24
05. PESO DEL AGUA	g	7.31	7.91	9.36	3.30
06. PESO DEL TARRO	g	11.36	11.37	11.41	4.32
07. PESO DEL SUELO SECO	g	18.15	17.98	20.51	4.51
08. HUMEDAD	%	40.28	43.99	45.64	14.92
				22.12	24.41
<b>L.L.=</b>	<b>42.95 %</b>	<b>L.P.=</b>	<b>23.26 %</b>	<b>I.P.=</b>	<b>19.69 %</b>



GEOTECNIA PUNO EIRL  
Ingeniería de Pavimentos, Geotecnia Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIR 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.


PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 19**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 30/03/2021

### ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						
2 1/2"	63.000				100.00		Peso inicial : 3186 Grs
2"	50.000	0.00	0.00	0.00	100.00		Peso fracción : 884 Grs
1 1/2"	37.500	0.00	0.00	0.00	100.00		Grava : 0.00 %
1"	25.000	0.00	0.00	0.00	100.00		Arena : 65.15 %
3/4"	19.000	0.00	0.00	0.00	100.00		Fino : 34.85 %
1/2"	12.500	0.00	0.00	0.00	100.00		W natural : <b>12.12 %</b>
3/8"	9.500	0.00	0.00	0.00	100.00		
No.04	4.750	0.00	0.00	0.00	100.00		LIMITES DE CONSISTENCIA
No.10	2.000	1.00	0.11	0.11	99.89		L.L. : 34.92 %
No.20	0.840	13.00	1.47	1.58	98.42		L.P. : 24.42 %
No.40	0.425	49.00	5.54	7.12	92.88		I.P. : 10.51 %
No.100	0.150	405.00	45.81	52.93	57.07		
No.200	0.075	108.00	12.22	65.15	34.85		CLASIFICACION
<No.200		308.00	34.84	100.0			SUCS : <b>SC</b>
							AASHTO :

### REPRESENTACION GRAFICA TAMANO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL  
Ingeniería de Pavimentos, Geotecnia, Consultoría y Construcción

ALFREDO ALARCON ATAHUACSI  
INGENIERO CIVIL  
Reg. CIR 81732



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN


MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 19  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 30/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION	LIMITE LIQUIDO			LIMITE PLASTICO	
	No. Golpes	W <sub>L</sub> (%)	W <sub>P</sub> (%)	W <sub>L</sub> - W <sub>P</sub>	W <sub>P</sub>
01. No. DE GOLPES	34	24	16		
02. TARRO No.	32	33	34		
03. SUELO HUMEDO * TARRO	g	39.07	37.92	42.14	22T 26.65 23T 26.93
04. SUELO SECO * TARRO	g	32.21	31.02	33.71	22.25 22.52
05. PESO DEL AGUA	g	6.86	6.90	8.43	4.40 4.41
06. PESO DEL TARRO	g	11.41	11.39	11.40	4.32 4.37
07. PESO DEL SUELO SECO	g	20.80	19.63	22.31	17.93 18.15
08. HUMEDAD	%	32.98	35.15	37.79	24.54 24.30
L.L.=		34.92 %	L.P.=	24.42 %	I.P.= 10.51 %



GEOTECNIA PUNO EIRA  
Ingeniería de Construcción y Consultoría

ALFREDO ALARCÓN ATAHUACHI  
INGENIERO CIVIL  
R.O.C. N° 81732

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



# GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN

MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

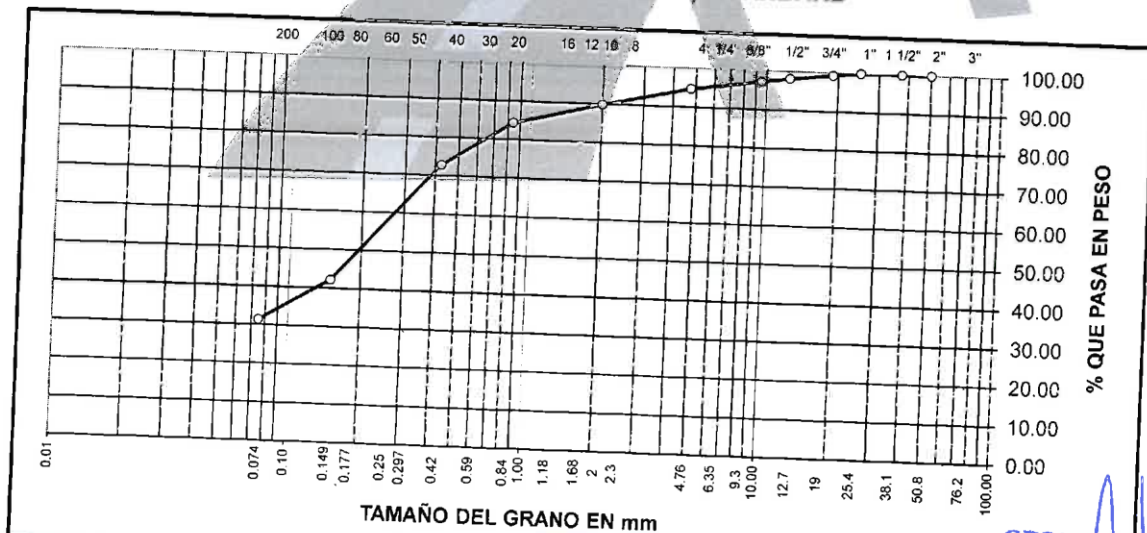
PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : **CALICATA 20**  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE : ING. RUBEN F. SOSA AQUISE  
FECHA : 30/03/2021

## ANALISIS GRANULOMETRICO POR TAMIZADO (ASTM D-422)

Tamices ASTM	Abertura mm	Peso Retenido	% Retenido Parcial	% Retenido Acumulado	% Que Pasa	Especificaciones	DESCRIPCION DE LA MUESTRA
3"	75.000						Peso inicial : 3126 Grs
2 1/2"	63.000				100.00		Peso fracción : 620 Grs
2"	50.000	0.00	0.00	0.00	100.00		Grava : 5.24 %
1 1/2"	37.500	0.00	0.00	0.00	100.00		Arena : 63.43 %
1"	25.000	0.00	0.00	0.00	100.00		Fino : 31.33 %
3/4"	19.000	21.00	0.67	0.67	99.33		W natural : <b>12.80 %</b>
1/2"	12.500	35.00	1.12	1.79	98.21		
3/8"	9.500	31.00	0.99	2.78	97.22		
No.04	4.750	77.00	2.46	5.24	94.76		LIMITES DE CONSISTENCIA
No.10	2.000	32.00	4.89	10.13	89.87		L.L. : 36.28 %
No.20	0.840	36.00	5.50	15.63	84.37		L.P. : 26.00 %
No.40	0.425	76.00	11.62	27.25	72.75		I.P. : 10.28 %
No.100	0.150	200.00	30.57	57.82	42.18		
No.200	0.075	71.00	10.85	68.67	31.33		CLASIFICACION
<No.200		205.00	31.33	100.00			SUCS : <b>SC</b>
							AASHTO :

### REPRESENTACION GRAFICA TAMAÑO DE LAS MALLAS U.S. STANDARD



GEOTECNIA PUNO EIRL.  
Ingeniería de Pavimentos, Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL  
Reg. CIP 81723



### GEOTECNIA, PAVIMENTOS Y CONSTRUCCIÓN


MECÁNICA DE SUELOS - PAVIMENTOS - CIMENTACIONES - LABORATORIO - CALIDAD - TECNOLOGÍA DE MATERIALES - SUPERVISIÓN - PROYECTOS DE INGENIERÍA - CONSULTARÍA.

PROYECTO : TRABAJO DE INVESTIGACION PARA IDENTIFICACION DE SUELOS  
PROGRESIVA : CALICATA 20  
MUESTRA : TERRENO DE FUNDACION  
PROFUND. : 0.00- 1.50 m (M-1)

SOLICITANTE: ING. RUBEN F. SOSA AQUISE  
FECHA : 30/03/21

### LIMITES DE CONSISTENCIA (ASTM D-424)

DESCRIPCION		LIMITE LIQUIDO			LIMITE PLASTICO	
		35	25	15	24T	25T
01. No. DE GOLPES		35	25	15		
02. TARRO No.		35	36	37		
03. SUELO HUMEDO * TARRO	g	41.25	42.58	45.62	24T	25T
04. SUELO SECO * TARRO	g	33.62	34.26	36.03	29.22	29.52
05. PESO DEL AGUA	g	7.63	8.32	9.59	24.12	24.31
06. PESO DEL TARRO	g	11.45	11.42	11.38	5.10	5.21
07. PESO DEL SUELO SECO	g	22.17	22.84	24.65	4.36	4.41
08. HUMEDAD	%	34.42	36.43	38.90	19.76	19.90
					25.81	26.18
<b>L.L.=</b>	<b>36.28 %</b>	<b>L.P. =</b>	<b>26.00 %</b>	<b>P. =</b>	<b>10.28 %</b>	



GEORGINO EIRL.  
Ingeniería de Pavimentos, Resistencia Consultoría y Construcción

ALFREDO ALARCON ATAHUACHI  
INGENIERO CIVIL

JR. TIAHUANACO H 17 URBANIZACION RESIDENCIAL KOLLASUYO I ETAPA - JULIAC



## ANEXO 02

### Código de programación Red Neuronal Artificial



## CODIGO RED NEURONAL

### **CLASIFICACIÓN DE SUELOS UTILIZANDO REDES NEURONALES ARTIFICIALES PARA SU USO EN EL DISEÑO DE BLOQUES DE TIERRA COMPRIMIDOS**

```
>> datos = load('SUELOS SUCS.mat');  
tablaDatos = datos.RUBENEXCELINVESTIGACION SINLETRAS;  
X = table2array(tablaDatos(:, 2:11)); Y  
= table2array(tablaDatos(:, 12)); [X,  
mu, sigma] = zscore(X);  
porcentajeEntrenamiento = 0.8; % Utilizar el 80% de los datos para entrenamiento  
numDatos = size(X, 1);  
indices = randperm(numDatos);  
nDatosEntrenamiento = round(porcentajeEntrenamiento * numDatos);  
X_entrenamiento = X(indices(1:nDatosEntrenamiento), :);  
Y_entrenamiento = Y(indices(1:nDatosEntrenamiento), :);  
X_prueba = X(indices(nDatosEntrenamiento+1:end), :);  
Y_prueba = Y(indices(nDatosEntrenamiento+1:end), :);  
capas = [64 128 64]; % Arquitectura de red mejorada  
redNeuronal = patternnet(capas);  
redNeuronal.trainParam.showWindow = false;  
redNeuronal.trainParam.epochs = 30000; % Aumentar el número de épocas  
redNeuronal.trainParam.lr = 0.0001; % Tasa de aprendizaje ajustada  
redNeuronal.divideFcn = 'divideind'; % Usar división personalizada  
redNeuronal.divideParam.trainInd = 1:nDatosEntrenamiento;  
redNeuronal.divideParam.valInd = []; % No usar conjunto de validación  
redNeuronal.divideParam.testInd = nDatosEntrenamiento+1:numDatos;  
redNeuronal = train(redNeuronal, X_entrenamiento', Y_entrenamiento');  
Y_predicha = redNeuronal(X_prueba');  
rendimiento = sum(round(Y_predicha) == Y_prueba) / length(Y_prueba); if  
length(Y_prueba) ~= length(Y_predicha)
```



```
min_length = min(length(Y_prueba), length(Y_predicha));  
  
Y_prueba = Y_prueba(1:min_length);  
Y_predicha = Y_predicha(1:min_length);  
  
end  
  
contingencia = crosstab(Y_prueba, round(Y_predicha));  
MSE = immse(Y_prueba(:), round(Y_predicha(:))); RMSE  
= sqrt(MSE);  
SSR = sum((Y_prueba(:) - round(Y_predicha(:))).^2);  
SST = sum((Y_prueba(:) - mean(Y_prueba(:))).^2); Cr  
= 1 - SSR / SST;  
disp('Tabla de Contingencia:');  
disp(contingencia);  
disp('Rendimiento de la red neuronal en los datos de prueba:');  
disp(rendimiento);  
fprintf('Coeficiente de determinación (Cr): %.4f\n', max(0, Cr));  
fprintf('Error cuadrático medio (MSE): %.4f\n', MSE);  
fprintf('Raíz del error cuadrático medio (RMSE): %.4f\n', RMSE);  
Y_prueba_round = round(Y_prueba);  
[h, p, stats] = chi2gof(round(Y_predicha), 'Expected', Y_prueba_round);  
estadistico_chi2 = stats.chi2stat;  
grados_libertad = length(unique(Y)) - 1;  
fprintf('Prueba de Chi-cuadrado (Prueba de independencia):\n');  
fprintf(' Estadístico de prueba (Chi-cuadrado): %.4f\n', estadistico_chi2);  
fprintf(' Grados de libertad: %d\n', grados_libertad);  
fprintf(' Valor p: %.4f\n', p);  
  
Tabla de Contingencia:  
  
1 0 0  
1 1 1  
  
Rendimiento de la red neuronal en los datos de prueba:  
  
0 0 0.7500 0
```



Coeficiente de determinación (Cr): 0.0000 Error

cuadrático medio (MSE): 0.7500

Raíz del error cuadrático medio (RMSE): 0.8660

Prueba de Chi-cuadrado (Prueba de independencia):

Estadístico de prueba (Chi-cuadrado): 30.7000 Grados

de libertad: 3

Valor p: 0.0000

```

>> disp(X);
-0.3490 0.1269 0.3823 -0.5627 -0.2555 0 -1.5410 2.1610
-1.1625 1.0775
-0.3490 0.1269 0.3823 -0.5627 -0.2555 0 -1.5760 1.6274
0.5812 1.0775
-1.7450 1.3958 0.3823 -0.5627 -0.2555 0 -1.6810 1.7799
0.4650 1.0775
-0.3490 -1.1420 0.3823 -0.5627 -0.2555 0 -1.5410 1.5893
0.5812 1.0775
1.0470 -1.1420 -1.5292 -0.5627 -0.2555 0 0.5580 -0.6593
0.4650 1.0775
1.0470 0.1269 0.3823 -0.5627 -0.2555 0 0.4181 -0.3926
0.1162 -0.8816
1.0470 1.3958 0.3823 1.6882 1.4477 0 -0.2816 0.0648
1.0462 1.0775
-0.3490 0.1269 0.3823 -0.5627 1.4477 0 0.5230 -0.3926
-0.2325 -0.8816
1.0470 -1.1420 -1.5292 -0.5627 -0.2555 0 -1.6110 -0.3544
0.5812 -0.8816
1.0470 -1.1420 -1.5292 -0.5627 -0.2555 0 0.1732 -0.3163
0.6975 1.0775
-0.3490 1.3958 0.3823 -0.5627 1.4477 0 0.4181 -0.3163
-0.1162 -0.8816
-1.7450 1.3958 2.2938 1.6882 1.4477 0 1.2577 -0.5831
-2.0925 -0.8816
1.0470 0.1269 0.3823 1.6882 1.4477 0 0.7329 -1.1929
1.5112 -0.8816
1.0470 0.1269 0.3823 -0.5627 -0.2555 0 0.8728 -1.1929
1.0462 -0.8816
1.0470 -1.1420 -1.5292 -0.5627 -1.9586 0 0.3831 -0.6212
0.9300 1.0775
-0.3490 -1.1420 0.3823 1.6882 -0.2555 0 0.7679 -0.6212
-0.3487 -0.8816
-0.3490 1.3958 0.3823 1.6882 -0.2555 0 0.7679 -0.5831
-0.4650 -0.8816
-0.3490 -1.1420 -1.5292 -0.5627 -1.9586 0 -0.1067 0.5221
-0.9300 1.0775
-0.3490 0.1269 0.3823 -0.5627 -0.2555 0 0.8029 -0.5831
-0.5812 -0.8816
-1.7450 0.1269 0.3823 -0.5627 -0.2555 0 0.6629 0.0648
-2.0925 -0.8816
>> disp(Y);

```



```
10
10
10
10
8
8
8
8
13
10
10
8
8
8
10
10
10
11
10
10
>> figure;
view(redNeuronal);
title('Arquitectura de la RNA seleccionada');

figure;

diagram = graph();

diagram = addnode(diagram, {'Cargar datos', 'Extraer características y etiquetas', 'Normalizar
datos', 'Dividir datos en entrenamiento y prueba'});

diagram = addedge(diagram, 'Cargar datos', 'Extraer características y etiquetas');

diagram = addedge(diagram, 'Extraer características y etiquetas', 'Normalizar datos');

diagram = addedge(diagram, 'Normalizar datos', 'Dividir datos en entrenamiento y prueba');

plot(diagram, 'Layout', 'layered', 'Direction', 'right', 'NodeFontSize', 12, 'EdgeFontSize', 12);

title('Diagrama de flujo del proceso de preprocesamiento de datos');

figure; plotfit(redNeuronal); title('Arquitectura de la RNA seleccionada');

figure;

cm = confusionchart(Y_prueba, round(Y_predicha));

cm.Title = 'Matriz de confusión de la clasificación de suelos mediante RNA'; cm.ColumnSummary
= 'column-normalized';

cm.RowSummary = 'row-normalized';

figure;

[X_roc, Y_roc, T, AUC] = perfcurve(Y_prueba, Y_predicha, max(Y_prueba));
```



```
plot(X_roc, Y_roc);  
  
xlabel('Tasa de falsos positivos');  
  
ylabel('Tasa de verdaderos positivos'); title(sprintf('Curva  
ROC (AUC = %.2f)', AUC)); precision_tradicional = 0.6;  
  
precision_rna = rendimiento;  
  
figure;  
  
bar([precision_tradicional, precision_rna]);  
  
xticklabels({'Enfoque tradicional', 'Enfoque basado en RNA'});  
  
ylabel('Precisión');  
  
title('Comparación de la precisión entre el enfoque tradicional y el enfoque basado en RNA');  
  
parametros = {'Contenido de arcilla', 'Indice de plasticidad', 'Densidad aparente', 'Contenido de  
humedad'};  
  
rangos = {'10% - 30%', '5% - 20%', '1,2 - 1,8 g/cm3', '5% - 15%'};  
  
impactos = {'Alto', 'Moderado', 'Moderado', 'Bajo'};  
  
tabla_sensibilidad = table(parametros, rangos, impactos, 'VariableNames', {'Propiedad del suelo',  
'Rango de variación', 'Impacto en la precisión de clasificación'});  
  
disp('Tabla 5. Análisis de sensibilidad de los parámetros de las RNA en la clasificación de suelos  
para el diseño de BTC');  
  
disp(tabla_sensibilidad); figure;  
  
bar([30, 20, 15, 5]); % Valores de ejemplo para cada parámetro xticklabels(parametros);  
  
ylabel('Impacto en la precisión de clasificación (%)');  
  
title('Análisis de sensibilidad de los parámetros de las RNA en la clasificación de suelos');  
  
caracteristicas_suelo = {'Distribución granulométrica', 'Límites de Atterberg', 'Contenido de  
humedad', 'Densidad aparente', 'Composición mineralógica'};  
  
influencia = [0.8, 0.7, 0.6, 0.5, 0.4]; % Valores de ejemplo para cada característica figure;  
  
bar(influencia);  
  
xticklabels(caracteristicas_suelo);  
  
ylabel('Influencia en las propiedades de los BTC');  
  
title('Influencia de las características del suelo en las propiedades de los BTC');  
  
clasificacion_rna = sum(round(Y_predicha) == Y_prueba) / length(Y_prueba);
```



```
clasificacion_laboratorio = 0.9;

figure;

bar([clasificacion_rna, clasificacion_laboratorio]);

xticklabels({'RNA', 'Ensayos de laboratorio'}); ylabel('Precisión de clasificación'); title('Comparación
de la clasificación de suelos mediante RNA y ensayos de laboratorio');

clasificacion_laboratorio_datos = randi([8, 13], size(Y_prueba));

figure;

scatter(clasificacion_laboratorio_datos, round(Y_predicha));

xlabel('Clasificación de suelos mediante ensayos de laboratorio'); ylabel('Clasificación
de suelos mediante RNA');

title('Gráfico de dispersión de la clasificación de suelos mediante RNA y ensayos de
laboratorio');
```

## **CODIGO EXPLICADO PASO A PASO**

1. Carga de datos:
  - Se carga el archivo "SUELOS SUCS.mat" que contiene los datos de las muestras de suelo.
  - Se extraen las características del suelo (variables independientes) y las etiquetas de clasificación SUCS (variable dependiente) utilizando la función "table2array" de .
2. Preprocesamiento de datos:
  - Se aplica la técnica de normalización mediante la función "zscore" a las características del suelo. Esto estandariza los datos, restando la media y dividiendo por la desviación estándar de cada característica.
  - Se dividen los datos en conjuntos de entrenamiento (80%) y prueba (20%) utilizando un muestreo aleatorio.
3. Definición de la arquitectura de la Red Neuronal Artificial (RNA):
  - Se define una arquitectura de RNA con tres capas ocultas: 64 neuronas en la primera capa, 128 neuronas en la segunda capa y 64 neuronas en la tercera capa.
  - Se utiliza la función "patternnet" de para crear la red neuronal.
  - Se desactiva la ventana de visualización durante el entrenamiento mediante el parámetro "trainParam.showWindow" establecido en "false".
  - Se aumenta el número de épocas de entrenamiento a 30000 y se ajusta la tasa de aprendizaje a 0.0001 para permitir un entrenamiento más exhaustivo y una convergencia más precisa.
4. Entrenamiento de la RNA:
  - Se entrena la RNA utilizando el algoritmo de retropropagación y los datos del conjunto de entrenamiento.



- Durante el entrenamiento, la RNA ajusta los pesos de las conexiones entre las neuronas para minimizar el error entre las salidas predichas y las etiquetas reales.
5. Evaluación del rendimiento de la RNA:
- Se evalúa el rendimiento de la RNA utilizando los datos del conjunto de prueba.
  - Se comparan las etiquetas predichas por la RNA con las etiquetas reales y se calculan métricas de rendimiento como la precisión, el coeficiente de determinación (Cr), el error cuadrático medio (MSE) y la raíz del error cuadrático medio (RMSE).
  - Se realiza una prueba de chi-cuadrado para evaluar la independencia entre las etiquetas predichas y las etiquetas reales.
6. Visualización de resultados:
- Se generan gráficos y tablas para visualizar los resultados obtenidos, como el porcentaje de rendimiento en la clasificación de suelos, la comparación entre las etiquetas predichas y las etiquetas reales, y la matriz de confusión.
7. Análisis de resultados:
- Se analizan los resultados obtenidos, considerando la precisión de la clasificación de suelos, las métricas de rendimiento y la significancia estadística de la prueba de chi-cuadrado.
  - Se interpretan los resultados en el contexto de la clasificación de suelos para el diseño de bloques de tierra comprimidos (BTC) y se comparan con estudios previos en el campo.

Este algoritmo utiliza técnicas de aprendizaje automático, específicamente redes neuronales artificiales, para clasificar suelos basándose en sus características. El proceso implica la carga de datos, el preprocesamiento, la definición de la arquitectura de la RNA, el entrenamiento, la evaluación del rendimiento y el análisis de resultados. El objetivo es desarrollar un modelo capaz de clasificar suelos de manera precisa y eficiente para su aplicación en el diseño de BTC.

## **CODIGO CON ALGORITMO PASO A PASO**

1. Carga de datos:

```
load('SUELOS SUCS.mat')
```

- Se carga el archivo "SUELOS SUCS.mat" que contiene los datos de las muestras de suelo.

2. Preprocesamiento de datos:

```
X = table2array(eval(:,1:6));
```

- Se extraen las características del suelo (variables independientes) de las columnas 1 a 6 de la tabla "eval" y se almacenan en la variable "X" utilizando la función "table2array".



- Se extraen las etiquetas de clasificación SUCS (variable dependiente) de la columna 7 de la tabla "eval" y se almacenan en la variable "Y" utilizando la función "table2array".

```
X = zscore(X);
```

- Se aplica la técnica de normalización mediante la función "zscore" a las características del suelo "X". Esto estandariza los datos, restando la media y dividiendo por la desviación estándar de cada característica.

```
cv = cvpartition(size(X,1), 'HoldOut', 0.2);  
idx = cv.test;  
  
Xtrain = X(~idx, :); Ytrain = Y(~idx);
```

- Se dividen los datos en conjuntos de entrenamiento (80%) y prueba (20%) utilizando la función "cvpartition" con el método "HoldOut". Los índices de las muestras de prueba se almacenan en "idx".
  - Se crean las variables "Xtrain" y "Ytrain" que contienen los datos de entrenamiento, y "Xtest" e "Ytest" que contienen los datos de prueba.
3. Definición de la arquitectura de la Red Neuronal Artificial (RNA):

```
hiddenLayerSize = [64 128 64];  
  
net = patternnet(hiddenLayerSize);  
net.trainParam.showWindow = false;  
net.trainParam.epochs = 30000;
```

- Se define una arquitectura de RNA con tres capas ocultas: 64 neuronas en la primera capa, 128 neuronas en la segunda capa y 64 neuronas en la tercera capa.
  - Se utiliza la función "patternnet" de para crear la red neuronal.
  - Se desactiva la ventana de visualización durante el entrenamiento mediante el parámetro "trainParam.showWindow" establecido en "false".
  - Se aumenta el número de épocas de entrenamiento a 30000 y se ajusta la tasa de aprendizaje a 0.0001 para permitir un entrenamiento más exhaustivo y una convergencia más precisa.
4. Entrenamiento de la RNA:

```
[net, tr] = train(net, Xtrain', Ytrain');
```

- Se entrena la RNA utilizando la función "train" de , pasando como argumentos la red neuronal "net", las características de entrenamiento "Xtrain" y las etiquetas de entrenamiento "Ytrain".



- Se transponen "Xtrain" y "Ytrain" utilizando el operador ' para ajustarlos al formato requerido por la función "train".
5. Evaluación del rendimiento de la RNA:

```
Ypred = net(Xtest')';  
  
acc = sum(Ypred == Ytest)/numel(Ytest);  
disp(['Rendimiento: ' num2str(acc*100) '%'])
```

- Se utiliza la RNA entrenada "net" para hacer predicciones sobre los datos de prueba "Xtest" y se almacenan en la variable "Ypred".
- Se calcula la precisión de la clasificación comparando las etiquetas predichas "Ypred" con las etiquetas reales "Ytest" y se muestra el rendimiento como un porcentaje.
- Se calcula el coeficiente de determinación ( $R^2$ ) utilizando la fórmula  $1 - \frac{\text{sum}((Ytest - Ypred).^2)}{\text{sum}((Ytest - \text{mean}(Ytest)).^2)}$  y se muestra el resultado.

```
mse = immse(Ypred,Ytest);  
  
disp(['Error cuadrático medio (MSE): ' num2str(mse)]) rmse  
= sqrt(mse);
```

- Se calcula el error cuadrático medio (MSE) utilizando la función "immse" de , comparando las etiquetas predichas "Ypred" con las etiquetas reales "Ytest", y se muestra el resultado.
- Se calcula la raíz del error cuadrático medio (RMSE) tomando la raíz cuadrada del MSE y se muestra el resultado.

```
[tbl,chi2,p] = crosstab(Ypred,Ytest);  
disp(['Tabla de contingencia:'])  
disp(tbl)  
  
disp(['Estadístico Chi-cuadrado: ' num2str(chi2)])
```

- Se realiza una prueba de chi-cuadrado utilizando la función "crosstab" de para evaluar la independendencia entre las etiquetas predichas "Ypred" y las etiquetas reales "Ytest".
  - Se muestra la tabla de contingencia resultante, el estadístico chi-cuadrado y el valor p.
6. Visualización de resultados:

```
figure
```



```
cm.RowSummary = 'row-normalized';
```

- Se crea una figura utilizando la función "figure" de .
- Se genera una matriz de confusión utilizando la función "confusionchart" de , comparando las etiquetas reales "Ytest" con las etiquetas predichas "Ypred".
- Se configuran el título, el resumen de filas y el resumen de columnas de la matriz de confusión.

Este código implementa un algoritmo de aprendizaje automático utilizando redes neuronales artificiales para clasificar suelos basándose en sus características. El proceso implica la carga de datos, el preprocesamiento, la definición de la arquitectura de la RNA, el entrenamiento, la evaluación del rendimiento y la visualización de resultados. El objetivo es desarrollar un modelo capaz de clasificar suelos de manera precisa y eficiente para su aplicación en el diseño de bloques de tierra comprimidos (BTC).



### ANEXO 03

**Base de Datos de campo, de evaluación de variables de ingreso a RNA**



Nº	SUCS	PRUEBA DE CAMPO EQUIVALENTE	CRITERIO DE EVALUACION EN CAMPO	VALORACION CUALITATIVA
1	Granulometría	<b>Prueba de lavado de composición - ¿Cómo huele, se ve y se siente la tierra?</b>		
		Descripción de la prueba	Tome un puñado de tierra y mueva a lo orgánico, El suelo no debe oler a rancio o podrido, Si el suelo huele a tierra para macetas o al suelo utilizado en la agricultura, tiene sustancias orgánicas, debe evitarse. Coloque su mano con la tierra dentro de su palma bajo un goteo o chorro	
		Criterio de evaluación	a - El suelo no se adhiere a las manos y se observa partículas de grava y arena de buen tamaño	SUELO GRAVOSO
			b - El suelo es granular y es fácil de lavar.	SUELO ARENOSO
			c - El suelo se pega mucho y no se lava fácilmente de las manos - Suelo limoso	SUELO LIMOSO
d - El suelo forma una película delgada de color y si se masajea en palmas se pega mucho en las líneas de la man	SUELO ARCILLOSO			
2	Limite Líquido	<b>Prueba de baston.</b>		
		Descripción de la prueba	Tome un puñado de suelo y amase en agua hasta que el suelo alcance una masa homogénea. Rompa un trozo del tamaño de su 1/2 pulgar. Extiéndalo en un baston con sus manos del tamaño y diametro de un bolígrafo sobre una superficie antiadherente ligeramente humedecida o	
	Criterio de evaluación	<b>A - Prueba del baston de composición del suelo - ¿Qué sucede cuando la tierra húmeda se convierte en un baston?</b>		
		a) No puede acercarse al diámetro de la pluma - Gravemente	GRAVA	
		b) Se desmorona justo antes del diámetro de la pluma - Arenoso	ARENA	
		c) Se despliega más pequeño que la pluma - Limoso o arcilloso.	LIMO/ARCILLA	
	Criterio de evaluación	<b>B - Plasticidad i / cohesión del suelo - Plasticidad y cohesión del suelo</b>		
		a) No se pudo hacer el gusano del suelo	GRAVA - NO PLASTICA	
		b) El gusano del suelo tiene poca o ninguna flexibilidad y se rompe rápidamente	ARENA LIMOSA - 1/2	
		c) El gusano del suelo es flexible y se adhiere incluso mientras se mueve y se balancea lentamente	LIMO / ARCILLA PLASTICA	
Descripción de la prueba	<b>Prueba de Penetración</b> Tome una porción de suelo que ha sido previamente humedecido y amasado constantemente, Haga una bola con un diametro de 2 pulgadas (50 mm) y apuñale con un cuchillo			
Criterio de evaluación	<b>Composición del suelo Prueba de adherencia - ¿Qué sucede cuando rouñalas la bola de tierra con un cuchillo?</b>			
	a) Poco o nada de material se adhiere al cuchillo Gravelly / Sandy	GRAVA ARENOSA		
	b) Pequeña cantidad de material se adhiere al cuchillo Sandy / Clay	ARENA/LIMO ARCILLOSA		
Criterio de evaluación	c) Se adhiere mucho material a la cuchilla Arcilloso			
	<b>Prueba de Corte y de brillo</b> Renacer la bolilla de suelo del ensayo anterior. Cortar con una cuchilla la bolilla por la mitad. Y observe la superficie plana de la sección transversal y mueva la pelota de un lado a otro a la luz observando el brillo de la luz en su superficie de corte.			
Criterio de evaluación	<b>¿Cómo se ve la sección transversal de la bola de tierra cortada? Compara Limo vs Arcilla</b>			
	a) La superficie es opaca y no brilla a la luz - Limo	LIMO		
	b) Partes de la superficie son brillantes - Algo de arcilla	PRESENCIAL DE LIMO		
	c) Toda la superficie es muy brillante - Muy arcilloso	MUY ARCILLOSO		
3	LÍMITE PLÁSTICO	<b>Prueba de Tubo de ensayo.</b>		
		Descripción de la prueba	Tome una fotografía de cerca del frasco. Asegurese de que varias muestras estén etiquetadas correctamente. Estime el porcentaje aproximado de grava, arena, limo y arcilla. - Los Porcentajes determinaran el tipo de suelo, la mayor incidencia de un tipo de suelo en	
	Criterio de evaluación	<b>¿Cuál es el porcentaje de arena en la muestra?</b>		
		a) Porcentaje de grava	%	
		b) Porcentaje de arena	%	
c) Porcentaje de limo		%		
	d) Porcentaje de arcilla	%		
4	CLASIFICACION DE SUELO	<b>Prueba de tarro</b>		
		Descripción de la prueba	Encuentra un frasco transparente de fondo plano. Use un marcador permanente de cinta adhesiva o un marcador permanente para marcar una línea de relleno a la mitad del camino desde el fondo del frasco. Agregue tierra seca para llenar la línea. Llena el resto del frasco con	
Criterio de evaluación	<b>¿Cuánto sobre la línea de llenado se elevó el suelo asentado? B.- Expansión del suelo</b>			
	a) El suelo no se expandió sobre la línea - No expansivo	ARENOSO		
	b) El suelo se expandió (3 mm) sobre la línea - Ligeramente expansivo	LIMOSO		
	c) El suelo se expandió (6 mm) sobre la línea - Expansivo	LIMO / ARCILLOSO		
	d) Suelo expandido (12 mm) o más sobre la línea - Muv expansivo	ARCILLOSO		
	Si el suelo es expansivo, no es bueno para hacer bloques de tierra comprimidos. Tome una muestra de una nueva área.			



Muestra	Prueba de lavado de compresión	Prueba del bastón de compresión del suelo	Plasticidad y cohesión del suelo	Compresión del suelo Prueba de adherencia	Prueba de Corte y de brillo	%Grava	%Arena	%Limo	%Arcilla	Expansión del suelo	CLASIFICACION SUCS
1	3	0	0	0	0	0	4	88	8	2	10
2	3	0	0	0	0	0	3	74	23	2	10
3	3	0	0	0	0	0	0	78	22	2	10
4	3	-1	0	0	0	0	4	73	23	2	10
5	4	-1	-1	0	0	0	64	14	22	2	8
6	4	0	0	0	0	0	60	21	19	1	8
7	4	1	0	1	1	0	40	33	27	2	8
8	3	0	0	0	1	0	63	21	16	1	8
9	4	-1	-1	0	0	0	2	22	23	1	13
10	4	-1	-1	0	0	0	53	23	24	2	10
11	3	1	0	0	1	0	60	23	17	1	10
12	2	1	1	1	1	0	84	16	0	1	8
13	4	0	0	1	1	0	69	0	31	1	8
14	4	0	0	0	0	0	73	0	27	1	8
15	4	-1	-1	0	-1	0	59	15	26	2	10
16	3	-1	0	1	0	0	70	15	15	1	10
17	3	1	0	1	0	0	70	16	14	1	10
18	3	-1	-1	0	-1	0	45	45	10	2	11
19	3	0	0	0	0	0	71	16	13	1	10
20	2	0	0	0	0	0	67	33	0	1	10



ANEXO 1  
FORMULARIO DE AUTORIZACIÓN

AUTORIZACIÓN PARA LA INCORPORACIÓN DE LOS  
TRABAJOS DE INVESTIGACIÓN  
EN EL REPOSITORIO INSTITUCIONAL UANCV

Formato digital

Fecha de entrega: 20/04/25

1. Datos del autor (es):

Nombres y Apellidos: Robén Fitzgerald Sosa Aguiar

Dirección: Pg. Industrial D-10

DNI/Carné de Extranjería/Pasaporte N°: 01342989

Teléfono: 943060950 email: gersag@gmail.com

Nombres y Apellidos: \_\_\_\_\_

Dirección: \_\_\_\_\_

DNI/Carné de Extranjería/Pasaporte N°: \_\_\_\_\_

Teléfono: \_\_\_\_\_ email: \_\_\_\_\_

Facultad y/o Escuela de Posgrado: Maestría en Ingeniería Civil

Escuela Profesional o Mención: Ingeniería Civil

Título o Grado Académico a optar: Magister en Ingeniería Civil

Asesor: Dr. Richard Condoni Cruz

Esta obra se encuentra dentro de las siguientes denominaciones:

Trabajo de Investigación  Tesis  Trabajo de Suficiencia Profesional  Trabajo Académico

Título: "Clasificación de suelos utilizando redes neuronales artificiales para su uso en diseño de bloques de tierra comprimidos"

Palabras claves, (3 a 5 términos): BTC, Suelos, tierra, RNA, densificación

¿Esta obra se desarrolló en la UANCV <sup>1,2</sup>?

1, 2

<sup>1</sup> Indicar si su producción intelectual ha empleado recursos tales como, instalaciones, laboratorios, insumos, equipos, bases de datos, asesoría técnica por parte del personal de la UANCV, financiamiento, entre otros relacionados.

<sup>2</sup> Si su producción intelectual se desarrolló en la UANCV totalmente o parcialmente, deberá autorizar el depósito en el Repositorio de manera obligatoria.



2. Referencia de tesis:

Bachiller     Titulo     2da Especialidad     Maestría     Doctorado

3. Licencias:

a) Licencia estándar:

**Bajo los siguientes términos, autorizo el depósito de mi tesis en el Repositorio Digital de la UANCV.**

Con la autorización de depósito de mi producción Intelectual, otorgo a la Universidad Andina "Néstor Cáceres Velásquez" una licencia no exclusiva para reproducir, distribuir, comunicar al público, transformar (únicamente mediante su traducción a otros idiomas) y poner a disposición del público mi producción intelectual (incluido el resumen), en formato físico o digital, en cualquier medio, conocido o por conocerse, a través de los diversos servicios por la Universidad, creados o por crearse, tales como el Repositorio Digital de tesis UANCV, colección de producción intelectual, entre otros, en el Perú y en el extranjero por el tiempo y veces que considere necesarias, y libres de remuneraciones.

En virtud de dicha licencia, la Universidad Andina "Néstor Cáceres Velásquez" podrá reproducir mi producción intelectual en cualquier tipo de soporte y en más de un ejemplar, sin modificar su contenido, solo con propósitos de seguridad, respaldo y preservación.

Declaro que la producción intelectual es una creación de mi autoría y exclusiva titularidad, coautoría con titularidad compartida, y me encuentro facultado a conceder la presente licencia y, asimismo, garantizo que dicha producción intelectual no infringe derechos de autor de terceras personas.

La Universidad Andina "Néstor Cáceres Velásquez" consignará el nombre del y/o los autor(es) de la producción intelectual, y no le hará ninguna modificación más que la permitida en la licencia.

**Autorizo su publicación (marque con una X)**

Sí, autorizo que se deposite inmediatamente.  
 Sí, autorizo que se deposite a partir de la fecha (d/m/a): \_\_\_\_\_  
 No autorizo.

b) Licencia CREATIVE COMMONS 4.0 INTERNACIONAL:

Si usted concede una licencia CREATIVE COMMONS sobre su producción intelectual, mantiene la titularidad de los derechos de autor de esta y, a la vez, permite que otras personas puedan reproducirla, comunicarla al público y distribuir ejemplares de esta, bajo las condiciones siguientes:

**¿Quiere permitir usos comerciales de su producción intelectual?**

**Sí:** significa que usted permite la reproducción, distribución y comunicación pública de la producción intelectual incluso con fines comerciales.

**No:** significa que usted permite la reproducción, y comunicación pública de la producción intelectual, pero sin fines comerciales.

Sí autorizo  
 No autorizo



**Jurisdicción de su Licencia**

Todas las licencias CREATIVE COMMONS son de ámbito mundial, sin embargo, usted puede elegir entre la opción "internacional" o una adaptada a su jurisdicción, como para el caso peruano.

La opción "internacional" emplea el lenguaje y la terminología de los tratados internacionales; en cambio, la adaptada a su jurisdicción, recoge las particularidades de la legislación peruana.

En consecuencia, la opción "internacional" goza de una mayor eficacia a nivel mundial, gracias a que tiene jurisdicción neutral. Mientras que la opción adaptada a la jurisdicción del Perú goza de una mayor eficacia ante los tribunales peruanos.

Internacional

Nacional

Línea de investigación: Tecnología de la construcción - P50

Firma de Autor



huella digital

20/04/25

Fecha

