

ANÁLISIS DE SUSCEPTIBILIDAD DE DESLIZAMIENTOS DE SUELO  
MEDIANTE EL USO DE REDES NEURONALES ARTIFICIALES  
APLICADA A LA CUENCA DEL ESTERO SAN ALFONSO, SAN JOSÉ DE  
MAIPO, CHILE.

Memoria entregada a la Universidad Mayor en cumplimiento de los requisitos para optar al  
Título de Geólogo

VICENTE EDUARDO ROJAS CABALLERO

**Profesora Guía**

Alejandra Serey Amador

**Profesora Co-guía**

Cristina Ortega Caurapan

**Comisión Evaluadora de Examen**

Carlos Andrade Fuentes

SANTIAGO, CHILE

Junio, 2023

## RESUMEN

El presente trabajo tiene como objetivo principal generar un mapa de susceptibilidad de deslizamientos de suelo, aplicando la metodología de redes neuronales artificiales en la cuenca del estero San Alfonso, San José de Maipo, Chile.

Las remociones en masa son procesos geodinámicos y climáticos que, con reiterada periodicidad, provocan pérdidas humanas, daños económicos y sociales (*Hauser, 1993*), siendo responsables de aproximadamente el 17% de las muertes ocasionadas por amenazas naturales alrededor del mundo (*Lacasse et al., 2010*). Por tales motivos nace la necesidad de generar nuevas herramientas que permitan comprender y analizar estas amenazas naturales con el fin de predecir y/o estimar espacial y temporalmente la ocurrencia y el alcance de estos eventos.

En este trabajo se aplicó la metodología de redes neuronales para evaluar la susceptibilidad de deslizamientos. Se utilizaron ocho factores condicionantes: (1) Geología/Geotecnia, (2) Geomorfología, (3) Pendiente, (4) Distancia a la red de drenaje, (5) Curvatura, (6) Aspecto, (7) Índice de humedad topográfico y (8) Factor LS.

La metodología aplicada consta de seis etapas. En la primera se generó un catastro de los puntos de alta susceptibilidad y los puntos libres de deslizamientos de suelo. En la segunda etapa se seleccionaron los factores condicionantes relevantes para la generación de deslizamientos de suelo en el área de estudio, para posteriormente generar los mapas ráster de cada factor condicionante. En la tercera etapa se realizó el preprocesamiento de la base de datos y se llevó a cabo el análisis exploratorio de datos para tener un primer acercamiento al comportamiento de las variables.

En la cuarta etapa se estableció la arquitectura de la red neuronal convolucional. Luego en la quinta etapa se llevó a cabo el armado, entrenamiento y testeado de la red neuronal artificial. Finalmente, en la sexta etapa, el mapa generado por la red neuronal se envió a un software GIS para definir las clases de susceptibilidad.

Los resultados obtenidos permitieron validar la arquitectura de la red, la cual fue utilizada para la construcción del mapa de susceptibilidad, permitiendo diferenciar 4 grados de susceptibilidad relativa (Baja, Moderada, Alta y Muy Alta), y además identificar los 3 factores condicionantes más relevantes los cuales corresponden a la geología/geotecnia, geomorfología y pendiente.

SOLO USO ACADÉMICO

*En Memoria de Marcela Rojas.*

## TABLA DE CONTENIDOS

<b>CAPÍTULO 1 : INTRODUCCIÓN.....</b>	<b>1</b>
1.1 PROBLEMÁTICA Y MOTIVACIÓN .....	1
1.1.1 Crecimiento Demográfico.....	2
1.1.2 Grado de Conocimiento.....	2
1.1.3 Representatividad .....	2
1.2 UBICACIÓN Y ACCESOS.....	3
1.3 OBJETIVOS .....	4
1.3.1 Objetivo General .....	4
1.3.2 Objetivos Específicos.....	4
1.4 DESCRIPCIÓN ÁREA DE ESTUDIO.....	4
1.4.1 Clima y Vegetación .....	4
1.4.2 Geomorfología.....	5
<b>CAPÍTULO 2 : MARCO GEOLÓGICO.....</b>	<b>8</b>
2.1 GEOLOGÍA REGIONAL .....	8
2.1.1 Rocas Estratificadas .....	8
2.1.2 Rocas Intrusivas.....	9
2.1.3 Depósitos No Consolidados.....	9
2.1.4 Estructuras.....	10
2.2 GEOLOGÍA LOCAL.....	10
2.2.1 Rocas Estratificada.....	11
2.2.2 Intrusivos .....	12
2.2.3 Depósitos no consolidados .....	12
<b>CAPÍTULO 3 : MARCO TEÓRICO .....</b>	<b>14</b>
3.1 REMOCIONES EN MASA .....	14
3.1.1 Clasificación de remociones en masa.....	14
3.1.2 Factores Condicionantes .....	20
3.1.3 Agentes Desencadenantes.....	23
3.1.4 Mapas de Susceptibilidad .....	24
3.2 INTELIGENCIA ARTIFICIAL Y MACHINE LEARNING.....	25
3.2.1 Redes Neuronales Artificiales .....	25
3.2.2 Arquitectura Perceptrón Multicapa .....	28
<b>CAPÍTULO 4 : METODOLOGÍA .....</b>	<b>30</b>
4.1 REVISIÓN BIBLIOGRÁFICA .....	30
4.2 CATASTRO Y MAPEO DE ZONAS DE OCURRENCIA.....	30
4.3 PRESELECCIÓN DE FACTORES CONDICIONANTES .....	31
4.4 ELABORACIÓN DE MAPAS TEMÁTICOS.....	32
4.5 ACONDICIONAMIENTO DE VARIABLES .....	33
4.6 ANÁLISIS EXPLORATORIO DE DATOS.....	35
4.7 APRENDIZAJE Y ENTRENAMIENTO.....	36
4.7.1 Aprendizaje Supervisado.....	37
4.7.2 Aprendizaje No Supervisado.....	37
4.7.3 Jerarquización de Variables.....	40
4.7.4 Validación y Testeo .....	40
4.8 GENERAR MAPA DE SUSCEPTIBILIDAD Y DEFINICIÓN DE CLASES.....	41
4.9 VALIDAR EL DESEMPEÑO DE LA RED NEURONAL Y EL MAPA DE SUSCEPTIBILIDAD.....	41
4.9.1 Matriz de Confusión .....	41
4.9.2 Curva ROC/AUC.....	43
4.9.3 Validación Visual de Mapas.....	44
4.10 ANÁLISIS DE ZONAS DE SUSCEPTIBILIDAD.....	44
<b>CAPÍTULO 5 : RESULTADOS .....</b>	<b>45</b>

5.1 CATASTRO Y MAPEO DE ZONAS DE OCURRENCIA.....	45
5.2 PRESELECCIÓN DE FACTORES CONDICIONANTES .....	48
a) <i>Geología</i> .....	49
b) <i>Geomorfología</i> .....	49
c) <i>Uso de Suelo</i> .....	50
d) <i>Antecedentes</i> .....	50
e) <i>Pendiente</i> .....	50
f) <i>Índice de Humedad Topográfico</i> .....	51
g) <i>Aspecto</i> .....	51
h) <i>Curvatura Planar</i> .....	52
i) <i>Distancia Red de Drenaje</i> .....	53
j) <i>Índice de Rugosidad Topográfico</i> .....	53
k) <i>Factor LS</i> .....	54
5.3 MAPAS TEMÁTICOS.....	54
5.4 ANÁLISIS EXPLORATORIO DE DATOS.....	57
5.4.1 <i>Estadística Descriptiva</i> .....	57
5.4.2 <i>Distribución</i> .....	58
5.4.3 <i>Correlación</i> .....	60
5.5 PRUEBA Y SELECCIÓN DE MODELOS DE RNA .....	61
5.6 JERARQUIZACIÓN DE VARIABLES .....	66
5.7 ANÁLISIS DE SUSCEPTIBILIDAD DE ZONAS DE OCURRENCIA DE DESLIZAMIENTOS DE SUELO.....	67
<b>CAPÍTULO 6 : DISCUSIONES.....</b>	<b>68</b>
6.1 RED NEURONAL ARTIFICIAL .....	68
6.1.1 <i>Tasa de Aprendizaje</i> .....	68
6.1.2 <i>Valor Umbral</i> .....	69
6.1.3 <i>Función de Activación y de Coste</i> .....	69
6.1.4 <i>Numero de Capas</i> .....	70
6.2 CATASTRO DE ZONAS DE OCURRENCIA .....	71
6.3 DEFINICIÓN DE CLASES DE SUSCEPTIBILIDAD.....	71
6.4 FACTORES CONDICIONANTES.....	72
6.4.1 <i>Selección y Descarte de Factores Condicionantes</i> .....	72
6.4.2 <i>Geología/Geotecnia y Geomorfología</i> .....	74
6.4.3 <i>Pendiente y Factor LS</i> .....	75
6.4.3 <i>Distancia Red de Drenaje</i> .....	76
6.4.4 <i>Aspecto</i> .....	76
6.4.5 <i>Índice de Humedad Topográfico y Curvatura</i> .....	77
6.5 EVALUACIÓN DEL MAPA DE SUSCEPTIBILIDAD.....	77
6.5.1 <i>Matriz de Confusión</i> .....	77
6.5.2 <i>Gráficos ROC/AUC</i> .....	78
6.5.3 <i>Comparación Visual de Mapas</i> .....	79
<b>CAPÍTULO 7: CONCLUSIONES.....</b>	<b>86</b>
<b>REFERENCIAS .....</b>	<b>89</b>

## ÍNDICE DE ILUSTRACIONES

FIGURA 1.1. MAPA DE UBICACIÓN Y ACCESOS AL ÁREA DE ESTUDIO, EN AMARILLO RUTA G-25 Y EN ROJO LA CUENCA DEL ESTERO SAN ALFONSO. ....	3
FIGURA 1.2. SEGMENTACIÓN MORFOESTRUCTURAL DEL ÓROGENO ANDINO ENTRE LOS 32°S Y LOS 35°S. BASADO EN CHARRIER & MUÑOZ (1994); GIAMBIAGI ET AL. (2003), (2012); TASSARA & YÁÑEZ (2003) EN QUIROGA (2013). ....	6
FIGURA 1.3. MAPA GEOMORFOLÓGICO REGIONAL DE LA REGIÓN METROPOLITANA. EL RECUADRO NEGRO ENCIERRA EL ÁREA DE ESTUDIO. BÖRGEL (1983). ....	6
FIGURA 1.4. MAPA GEOMORFOLÓGICO LOCAL DE LA CUENCA DEL ESTERO SAN ALFONSO. MODIFICADO DE MUÑOZ (2018). ....	7
FIGURA 2.1. MAPA GEOLÓGICO REGIONAL DE FOCK ET AL. (2005) ADAPTADO DE THIELE (1980), SELLÉS Y GANA (2001) Y SERNAGEOMIN (2002). ....	8
FIGURA 2.2. MAPA GEOLÓGICO/GEOTÉCNICO CUENCA ESTERO SAN ALFONSO. MODIFICADO DE MUÑOZ (2018)...	11
FIGURA 3.1. ESQUEMA CAÍDA DE ROCA. EXTRAÍDO DE PROYECTO MULTINACIONAL ANDINO (2007). ....	16
FIGURA 3.2. ESQUEMA TIPOS DE VOLCAMIENTOS, A) VOLCAMIENTO EN BLOQUE. B) VOLCAMIENTO FLEXURAL. EXTRAÍDO DE PROYECTO MULTINACIONAL ANDINO (2007). ....	16
FIGURA 3.3. ESQUEMA PROPAGACIÓN LATERAL. EXTRAÍDO DE PROYECTO MULTINACIONAL ANDINO (2007). ....	17
FIGURA 3.4. ESQUEMA TIPOS DE DEFORMACIÓN DE LADERAS, A) REPTACIÓN. B) SOLIFLUXIÓN. EXTRAÍDO DE PROYECTO MULTINACIONAL ANDINO (2007). ....	17
FIGURA 3.5. ESQUEMA. A) FLUJO NO CANALIZADO. B) FLUJO CANALIZADO. EXTRAÍDO DE PROYECTO MULTINACIONAL ANDINO (2007). ....	18
FIGURA 3.6. ESQUEMA, A) DESLIZAMIENTO ROTACIONAL. B) DESLIZAMIENTO TRASLACIONAL. EXTRAÍDO DE PROYECTO MULTINACIONAL ANDINO (2007). ....	19
FIGURA 3.7. EJEMPLO MAPA DE SUSCEPTIBILIDAD. A) DESLIZAMIENTOS DE ROCA, B) CAÍDA DE ROCA, LARA ET AL., 2018. ....	24
FIGURA 3.8. ESQUEMA DE LOS COMPONENTES Y FUNCIONAMIENTO DE UNA NEURONA. ....	26
FIGURA 3.9. ESQUEMA DEL FUNCIONAMIENTO Y COMPONENTES DE UNA RED NEURONAL ARTIFICIAL SIMPLIFICADA. ....	29
FIGURA 4.1. EJEMPLOS DE MAPAS TEMÁTICOS, A) DISTANCIA A LA RED DE DRENAJE Y B) ÍNDICE DE HUMEDAD TOPOGRÁFICO. EXTRAÍDO SIN MODIFICACIONES DE FEBY ET AL., 2020. ....	32
FIGURA 4.2. ESQUEMA DE LOS COMPONENTES Y FUNCIONAMIENTO DE UNA NEURONA ARTIFICIAL CON ALGORITMO DE APRENDIZAJE DE RETROPROPAGACIÓN DEL ERROR (BACKPROPAGATION). ....	38
FIGURA 4.3. ESQUEMA DE LOS VALORES CORRESPONDIENTES DE UNA MATRIZ DE CONFUSIÓN. ....	42
FIGURA 4.4. COMPORTAMIENTOS TÍPICOS DE LA CURVA ROC/AUC EN DIFERENTES ESCENARIOS. ELABORADO POR GONZÁLEZ, 2019. ....	43
FIGURA 5.1. A, C Y D) ESCARPES DE REMOCIONES EN MASA EN QUEBRADA SAN ALFONSO. B) DESLIZAMIENTOS EN PRIMER PLANO Y SECUENCIA DE ESCARPES HACIA EL FONDO DEL ESTERO SAN ALFONSO, SOBRE LOS 3000 M.S.N.M. IMÁGENES MODIFICADAS DEL INFORME DEL SERNAGEOMIN, “SOBREVUELO EN LAS CUENCAS ALTAS DEL RÍO MAIPO Y MAPOCHO” (FARIÁS & MARÍN, 2019). ....	46
FIGURA 5.2. MAPA DE PUNTOS CORRESPONDIENTE AL CATASTRO BINARIO, IDENTIFICANDO ZONAS DE OCURRENCIA DE DESLIZAMIENTOS (1) Y NO OCURRENCIA (0). ....	48
FIGURA 5.3. ESQUEMA DE LOS VALORES ANGULARES DE UN MAPA DE ASPECTO. ....	52
FIGURA 5.4. ESQUEMA DEL CÁLCULO DE CURVATURA PLANAR. ....	52
FIGURA 5.5. MAPAS TEMÁTICOS DE FACTORES CONDICIONANTES PARA EL ANÁLISIS DE ZONAS DE OCURRENCIA DE DESLIZAMIENTOS DE SUELO. A) ASPECTO, B) GEOMORFOLOGÍA, C) FACTOR LS, D) DISTANCIA RED DE DRENAJE, E) ANTECEDENTES, F) CURVATURA, G) GEOLOGÍA, H) PENDIENTE, I) ÍNDICE DE RUGOSIDAD DE TERRENO, J) ÍNDICE DE HUMEDAD TOPOGRÁFICO, K) USO DE SUELO. ....	56
FIGURA 5.6. HISTOGRAMAS COMPARATIVOS DE DISTRIBUCIÓN DE VALORES Y FRECUENCIAS, DE LOS FACTORES CONDICIONANTES PARA ZONAS DE OCURRENCIA Y NO OCURRENCIA. ....	58
FIGURA 5.7. GRÁFICO “PAIRPLOT”, REPRESENTACIÓN GRÁFICA DE LA CORRELACIÓN ENTRE FACTORES CONDICIONANTES, VARIABLES CATEGÓRICAS Y VARIABLES NUMÉRICAS. ....	60

FIGURA 5.8. GRÁFICOS DEL ERROR DE ENTRENAMIENTO Y VALIDACIÓN.....	63
FIGURA 5.9. ESQUEMA DE LA ARQUITECTURA DE LA RED NEURONAL INCLUYENDO LOS PESOS SINÁPTICOS ENTRE CADA NODO. ....	65
FIGURA 5.10. ESQUEMA DE LA ARQUITECTURA DE LA RED NEURONAL APLICADA AL ANÁLISIS DE SUSCEPTIBILIDAD DE ZONAS DE OCURRENCIA DE DESLIZAMIENTOS. EL GROSOR DE LOS CONECTORES INDICA LA MAGNITUD ABSOLUTA Y LOS COLORES INDICAN VALORES POSITIVOS (NEGROS) Y NEGATIVOS (GRIS). ....	65
FIGURA 5.11. GRÁFICO DE GARSON, JERARQUÍA DE FACTORES CONDICIONANTES EN VALOR ABSOLUTO.....	66
FIGURA 5.12. MAPA DE SUSCEPTIBILIDAD DE ZONAS DE OCURRENCIA DE DESLIZAMIENTOS DE SUELO EN LA CUENCA DEL ESTERO SAN ALFONSO.....	67
FIGURA 6.1. A) ESQUEMA DE UN PATRÓN DE DATOS LINEAL. B) ESQUEMA DE UN PATRÓN DE DATOS NO LINEAL. ....	70
FIGURA 6.2. GRÁFICOS ROC/AUC PARA EL MODELO RNA.23.....	79
FIGURA 6.3. MAPA DE SUSCEPTIBILIDAD RESULTADO DE LA RNA.23 DIVIDIDO POR ZONAS DE ANÁLISIS. ....	81
FIGURA 6.4. MAPA DE SUSCEPTIBILIDAD DE DESLIZAMIENTOS DE LADERA, PROYECTO SIGMA; CIGIDEN .....	81

## ÍNDICE DE TABLAS

TABLA 3.1. SISTEMA DE CLASIFICACIÓN DE RM DE CRUDEN & VARNES (1996), ACTUALIZADO POR HUNGR ET AL. (2014). ....	15
TABLA 3.2. CLASIFICACIÓN DE REMOCIONES EN MASA SEGÚN VELOCIDAD DE DESPLAZAMIENTO DE CRUDEN & VARNES (1996) Y RESPUESTA HUMANA DE HUNGR (1981) .....	20
TABLA 3.3. FACTORES CONDICIONANTES PARA ANÁLISIS DE SUSCEPTIBILIDAD DE REMOCIONES EN MASA. BASADO EN LARA (2007), MUÑOZ (2013) Y ARENAS ET AL. (2017). ....	20
TABLA 4.1. RESUMEN DE FACTORES CONDICIONANTES PARA REMOCIONES EN MASA. BASADO EN SEPÚLVEDA (1998), LARA (2007), MUÑOZ (2013) Y ARENAS ET AL. (2017). ....	32
TABLA 4.2. NORMALIZACIÓN DE VARIABLES CATEGÓRICAS, MÉTODO DE LA DIVISIÓN DE CATEGORÍAS SEGÚN SU PRESENCIA O AUSENCIA EN EL PUNTO EVALUADO. ....	34
TABLA 4.3. VARIABLE CATEGÓRICA GEOLOGÍA CON SUS CORRESPONDIENTES CATEGORÍAS TRANSFORMADAS A VALORES NUMÉRICOS. ....	35
TABLA 4.4. NORMALIZACIÓN DE VARIABLES CATEGÓRICAS, MÉTODO DE LA DIVISIÓN DE RANGO. ....	35
TABLA 5.1. FACTORES PRESELECCIONADOS PARA EL ANÁLISIS DE ZONAS DE OCURRENCIA DE DESLIZAMIENTOS... ..	49
TABLA 5.2. ESTADÍSTICAS BÁSICAS CALCULADAS PARA FACTORES CONDICIONANTES NUMÉRICOS DE ZONAS DE OCURRENCIA DE DESLIZAMIENTOS Y NO OCURRENCIA. ....	57
TABLA 5.3. RESUMEN DE PARÁMETROS DEL MODELO DE RNA.23 .....	64
TABLA 6.1. ESQUEMA COMPARATIVO DE FACTORES CONDICIONANTES DE DIFERENTES AUTORES Y ESTE TRABAJO. ....	73
TABLA 6.2. MATRIZ DE CONFUSIÓN DE ENTRENAMIENTO Y TESTEO CON UN VALOR UMBRAL DE 0.5 .....	78
TABLA 6.3. FACTORES CONDICIONANTES Y SUS RESPECTIVOS PESOS PONDERADOS PARA ESTE TRABAJO Y EL MAPA SIGMA DE CIGIDEN. ....	80
TABLA 6.4. FACTORES CONDICIONANTES Y SUS RESPECTIVOS PESOS, CALCULADOS PARA EL MAPA SIGMA DEL CIGIDEN.....	80

## ÍNDICE DE ECUACIONES

ECUACIÓN 3.1 .....	27
ECUACIÓN 3.2 .....	27
ECUACIÓN 3.3 .....	27
ECUACIÓN 3.4 .....	28
ECUACIÓN 4.1 .....	34
ECUACIÓN 4.2 .....	38
ECUACIÓN 4.3 .....	38
ECUACIÓN 4.4 .....	39
ECUACIÓN 4.5 .....	39
ECUACIÓN 4.6 .....	39
ECUACIÓN 4.7 .....	39
ECUACIÓN 5.1 .....	51
ECUACIÓN 5.2 .....	53
ECUACIÓN 5.3 .....	54

SOLO USO ACADÉMICO

## AGRADECIMIENTOS

Agradezco a la empresa AFRY, por brindarme la oportunidad de llevar a cabo esta investigación y por su colaboración, especialmente a Carlos Andrade y su ojo crítico, cuya orientación y valiosa retroalimentación me permitió mejorar a lo largo de este proyecto.

A la escuela de geología de la Universidad Mayor, por proporcionarme los recursos necesarios, y darme la libertad para realizar este proyecto. Agradecer especialmente a Daniela Maturana por su apoyo a lo largo de la carrera.

Gracias especialmente a mi profesora guía, Alejandra Serey aka La Profe de Aplicada por su sabiduría y orientación experta. También, por enseñarme la importancia de la divulgación científica y por sus palabras de motivación que hicieron más ameno este proceso y por creer en mí y en este proyecto.

Gracias a Cristina Ortega quien estuvo motivada desde el primer día y acepto a pesar de que no supe ni siquiera como explicarle bien en qué consistía este proyecto. Gracias por su apoyo y asesoramiento, así como por su disposición para brindarme su experiencia y conocimiento.

Gracias infinitas a mis padres, por su amor incondicional, apoyo constante y sacrificios realizados para que pudiera alcanzar mis metas. También a mis hermanos, por aguantarme y darme ánimo. A mis abuelos y mi tía Marcela por creer en mí y regalarme mi primer martillo geológico, el cual me acompañó toda la carrera.

A mis amigos, Fabian y Nacho por su compañía todos estos años, por todo el apoyo y las risas que mantuvieron mi salud mental en niveles “óptimos ¿?”. También al grupo de Paly, Kmi y Frani quienes me dieron un segundo aire en estas etapas finales de la carrera.

Agradezco a todas las personas que, de una u otra manera, contribuyeron en mi formación tanto personal como académica, especialmente al profesor Adrián Maile por enseñarme el valor de la historia y la naturaleza.

Finalmente, gracias a mí por aguantar todos estos años, por nunca rendirme a pesar de las dificultades, por no tener miedo a elegir el camino difícil.

## CAPÍTULO 1 : INTRODUCCIÓN

### 1.1 Problemática y Motivación

Las remociones en masa son procesos geodinámicos y climáticos que, con reiterada periodicidad, provocan pérdidas humanas, daños económicos y sociales (*Hauser, 1993*), siendo responsables de aproximadamente el 17% de las muertes ocasionadas por amenazas naturales alrededor del mundo (*Lacasse et al., 2010*).

En el caso de Chile, el contexto andino nos confronta constantemente a estas amenazas, por lo que para prevenir desastres es necesario realizar una óptima gestión del riesgo, lo que abarca desde el estudio de la dinámica del fenómeno, hasta la condición de vulnerabilidad y resiliencia del elemento a proteger. Por tales motivos nace la necesidad de generar nuevas herramientas que permitan comprender y analizar estas amenazas naturales con el fin de predecir y/o estimar espacial y temporalmente la ocurrencia y el alcance de estos eventos.

Los peligros geológicos pueden analizarse desde el punto de vista de las condiciones intrínsecas del material (estudios de susceptibilidad o determinísticos) y desde el punto de vista de los factores desencadenantes de un fenómeno (estudios de amenaza o probabilísticos) y el objetivo de la zonificación de los peligros geológicos es disminuir los daños asociados a un evento. Para zonificar es necesario evaluar los peligros geológicos que pueden ocurrir en una porción del territorio, es decir, elaborar un diagnóstico, lo que implica conocer la historia del sector dónde se produce la catástrofe e identificar si existen las condiciones para que vuelva a ocurrir (*Fock et al., 2015*).

Dentro de los estudios de dinámica del fenómeno, los mapas de susceptibilidad funcionan como un paso inicial, pero una de las desventajas de estos estudios es que se realizan principalmente con base en análisis cualitativos o semicuantitativos los cuales, si bien pueden seguir una metodología en común, siempre van a estar sujetos a el criterio y la experiencia del profesional a cargo del estudio (*Van Westen et al., 1997*), de modo que, frente a una misma realidad, el resultado del análisis puede variar. Además, debido a la naturaleza subjetiva y contexto dependiente de los métodos cualitativos, puede ser difícil replicar los resultados.

La utilización de redes neuronales artificiales (RNA) en el análisis de factores condicionantes específicos de un área de estudio permite optimizar la realización de estudios, al calibrar los pesos de dichos factores y reducir el sesgo. Aunque esto no elimina el sesgo por completo, sí brinda mayor control sobre el error y posibilita obtener resultados más precisos.

Los ponderadores asociados a cada factor condicionante serán calibrados a partir del análisis de la cuenca del estero San Alfonso, localizada en la comuna de San José de Maipo, la cual fue seleccionada debido a las siguientes características:

### **1.1.1 Crecimiento Demográfico**

En los últimos años, el Cajón del Maipo ha experimentado dos cambios significativos. Por un lado, su crecimiento demográfico ha aumentado, lo que se traduce en una mayor cantidad de personas expuestas a amenazas naturales. Por otro lado, considerando el aumento en la ocurrencia de los eventos de remociones en masa y específicamente de deslizamientos producto de la actividad antrópica y el cambio climático (UNDRR, 2020), realizar estudios que delimiten las zonas de susceptibilidad permitirá prevenir estos desastres mediante la planificación territorial y planes de mitigación. Teniendo en cuenta que se espera que la población mundial aumente en aproximadamente 2.500 millones de personas en 2050, alcanzando una población total aproximada de 9.200 millones (van der Mensbrugge & Roland-Holst, 2009), hace que generar una correcta planificación territorial sea fundamental para los futuros proyectos de urbanización, cumpliendo así con el objetivo número 11 de los objetivos de desarrollo sostenible (ODS) de la ONU.

### **1.1.2 Grado de Conocimiento**

El cajón del Maipo en general y en específico la cuenca del estero San Alfonso han sido estudiados y caracterizados en detalle, por varios autores (e.g., Hauser, 1985, 1996; Sepúlveda et al., 2009; Gajardo et al., 2013; Bravo et al., 2014; Sepúlveda & Jara, 2016; Marín et al., 2017; Muñoz, 2018), por lo que se cuenta con información geológica de alta calidad, como los catastros de remociones en masa, lo que favorece a este estudio ya que permitirá validar de mejor manera los resultados.

### **1.1.3 Representatividad**

Las características de esta cuenca son semejantes a las de otras cuencas cordilleranas de Chile central (Lat 33°-35°S), por lo que se puede usar como base para una vez realizado el estudio poder extrapolar esta metodología a otras cuencas con propiedades similares.

De esta manera este trabajo propone utilizar la metodología de redes neuronales artificiales (RNA) con el fin de contribuir al estudio de susceptibilidad de remociones en masa a través de

una propuesta metodológica cuantitativa con la cual se pueda hacer una jerarquización de los factores condicionantes específicos para distintas zonas de estudio.

## 1.2 Ubicación y Accesos

El área de estudio se encuentra ubicada en Región Metropolitana de Santiago, Provincia Cordillera, Comuna San José de Maipo, en la cuenca del estero San Alfonso (**¡Error! No se encuentra el origen de la referencia.**). Esta cuenca tributa al río Maipo mediante su curso principal de drenaje, el estero San Alfonso. La cuenca en estudio tiene una dimensión de 21 km<sup>2</sup> aproximadamente, su altitud varía entre 1.100 a 3.500 m.s.n.m. aproximadamente y su descarga ocurre en el kilómetro 48 de la ruta G-25, específicamente donde se ubica su puente homónimo.

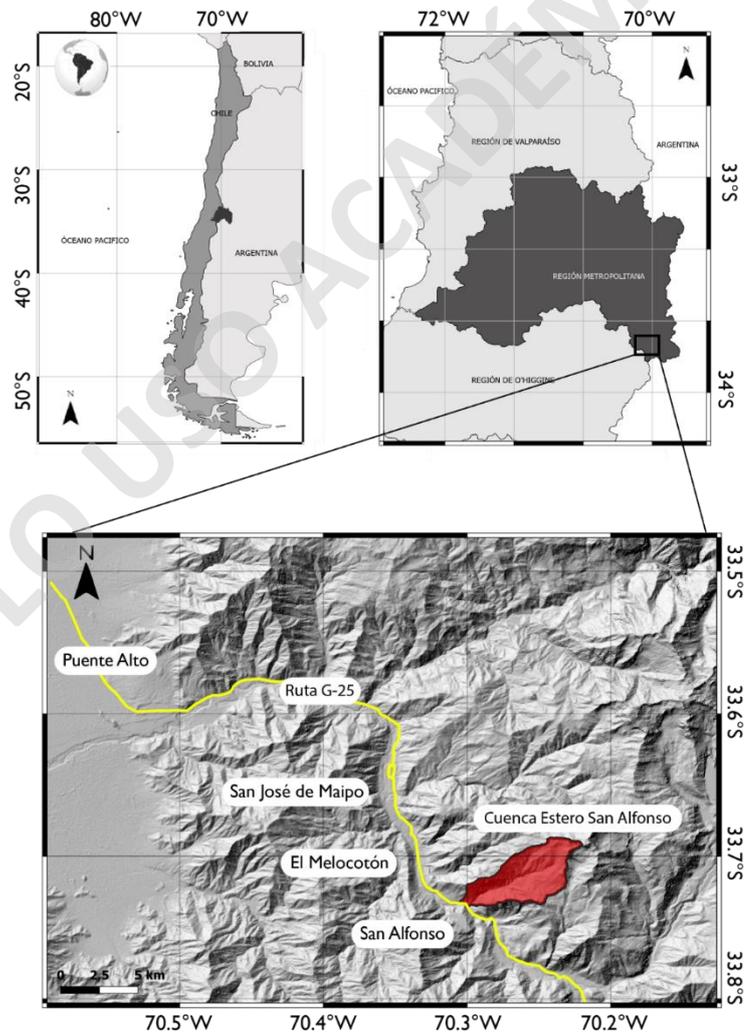


Figura 1.1. Mapa de ubicación y accesos al área de estudio, en amarillo ruta G-25 y en rojo la cuenca del estero San Alfonso.

## 1.3 Objetivos

### 1.3.1 Objetivo General

Generar un mapa de susceptibilidad aplicando la metodología de redes neuronales artificiales para deslizamientos de suelo en la cuenca del estero San Alfonso, escala 1:25.000.

### 1.3.2 Objetivos Específicos

- Seleccionar los factores condicionantes que se utilizarán para el análisis de ocurrencia de deslizamientos de suelo.
- Preprocesar y analizar el conjunto de datos representativos de las condiciones de ocurrencia de deslizamientos de suelo en la cuenca del estero San Alfonso.
- Entrenar una red neuronal artificial utilizando el conjunto de datos procesados y evaluar su capacidad predictiva.
- Generar el mapa de susceptibilidad de deslizamientos de suelo.
- Validar el mapa de susceptibilidad mediante análisis numérico y visual.
- Identificar e interpretar las áreas de mayor riesgo de deslizamientos de suelo en la cuenca del estero San Alfonso.

## 1.4 Descripción Área de Estudio

### 1.4.1 Clima y Vegetación

La clasificación climática de Köppen-Geiger, actualizada por *Sarricolea et al. (2017)*, establece seis tipos de clima para la región Metropolitana. San José de Maipo y alrededores se caracteriza por ser una zona de lluvias invernales con una estación seca que dura entre 7 y 8 meses, las temperaturas pueden oscilar entre los 0 y 30°C. Por encima de los 3.000 m hay un clima de montaña con precipitaciones en forma de lluvia y nieve. Los ecosistemas de la zona se conocen como "Bosque y matorral mediterráneo andino" y "Estepa altoandina". Ambos son característicos de la alta cordillera de los Andes en Chile central (*Benado et al., 2012*).

Las condiciones climáticas descritas anteriormente y la vegetación del área de estudio se encuentran estrechamente relacionadas. Desde los 500 m.s.n.m. hasta aproximadamente los 1500 m.s.n.m en la zona de climas templados con estación seca prolongada, dominan los bosques esclerófilos, las especies arbóreas y arbustivas que se presentan en este tipo de bosques

son el Peumo, Boldo, Litre, Quillay y Espino (*Salinas et al., 2018*). En las zonas con mayor humedad, cercano a los cauces de las quebradas, se pueden encontrar también especies como la Patagua, Lingue y Canelo (*Guillon, 2007*), mientras que sobre los 1500 a 2000 m.s.n.m. domina la vegetación característica de climas andinos. En general se asocia con especies vegetales rastreras o acojinadas, con espinas o achaparradas, adaptadas para resistir las exigentes condiciones climáticas. Las especies características en la zona central son la Hierba Blanca, el Pichi-Pichi y el Pingo-Pingo (*BCN, 2004*).

## 1.4.2 Geomorfología

### 1.4.2.1 Unidades Morfoestructurales

En Chile central al sur de los 33°S hasta los 35°S se pueden identificar cinco unidades morfoestructurales paralelas entre sí, con orientación aproximada N-S. De Oeste a Este éstas son: Cordillera de la Costa, Depresión Central, Cordillera Principal, Cordillera Frontal y Precordillera (**¡Error! No se encuentra el origen de la referencia.**). (e.g. *García, 2000; Fernández, (2001), Rauld, (2002); Farias, 2010 y Boyce, 2020*).

En particular, la zona de estudio se ubica en la en el sector precordillerano de la Cordillera Principal, la cual es el efecto más prominente de la subducción de la corteza oceánica bajo el margen Pacífico de Sudamérica, esta es reconocida desde al menos, el Jurásico (*Mpodozis y Ramos, 1989*) y con variaciones en la tasa de convergencia durante el Eoceno – Mioceno que van desde 5 a 15 cm/año (*Pardo-Casas y Molnar, 1987; Somoza, 1998*).

Esta alcanza altitudes superiores a las demás unidades morfoestructurales, de hasta aproximadamente 6570 m.s.n.m. En ella se reconocen dos segmentos: uno occidental compuesto por rocas cenozoicas que abarca toda la zona de estudio, y uno oriental que evidencia rocas mesozoicas deformadas, correspondiente en este segmento a la Faja Plegada y Corrida (FPC) del Aconcagua. (e.g. *Farias, 2010; Boyce, 2020*).

Actualmente se estima que la tasa de convergencia es de 6.8 cm/año (*Demets et al., 1994; Vigny et al., 2009*). Este régimen de esfuerzos convergentes ha condicionado distintos procesos geológicos como el magmatismo, ubicación del arco con respecto a la fosa, desarrollo de cuencas, orogenia y tectonismo (*Fock, 2005; Farias et al., 2016*).

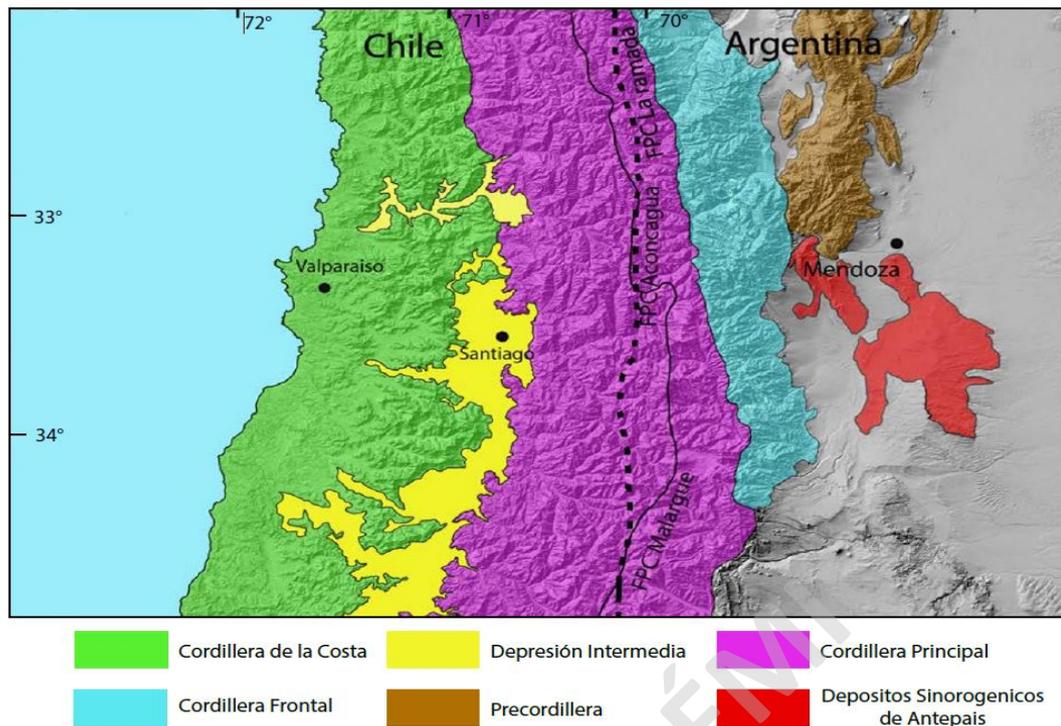


Figura 1.2. Segmentación morfoestructural del órogeno andino entre los 32°S y los 35°S. basado en Charrier & Muñoz (1994); Giambiagi et al. (2003), (2012); Tassara & Yáñez (2003) en Quiroga (2013).

#### 1.4.2.2 Geomorfología Regional

Börgel (1983) y Farias et al. (2010) presentan un mapa geomorfológico regional para la Región Metropolitana (Figura 1.3) identificando de Oeste a Este las siguientes unidades: planicie marina y/o fluvio-marina; cuencas graníticas marginales; cordillera de la costa; cuenca de Santiago, llanos de sedimentación fluvial y/o aluvial y cordillera andina.

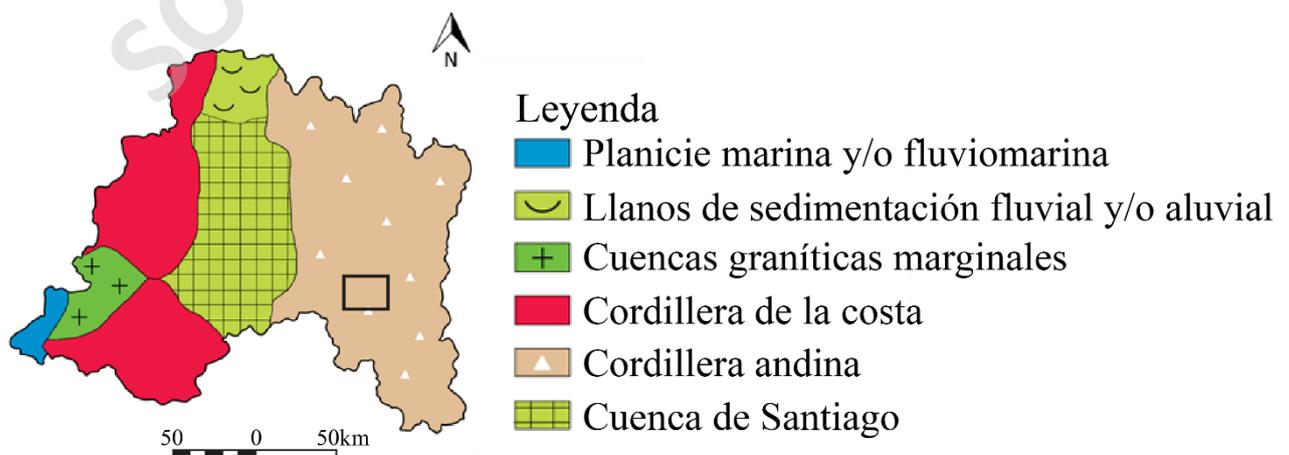
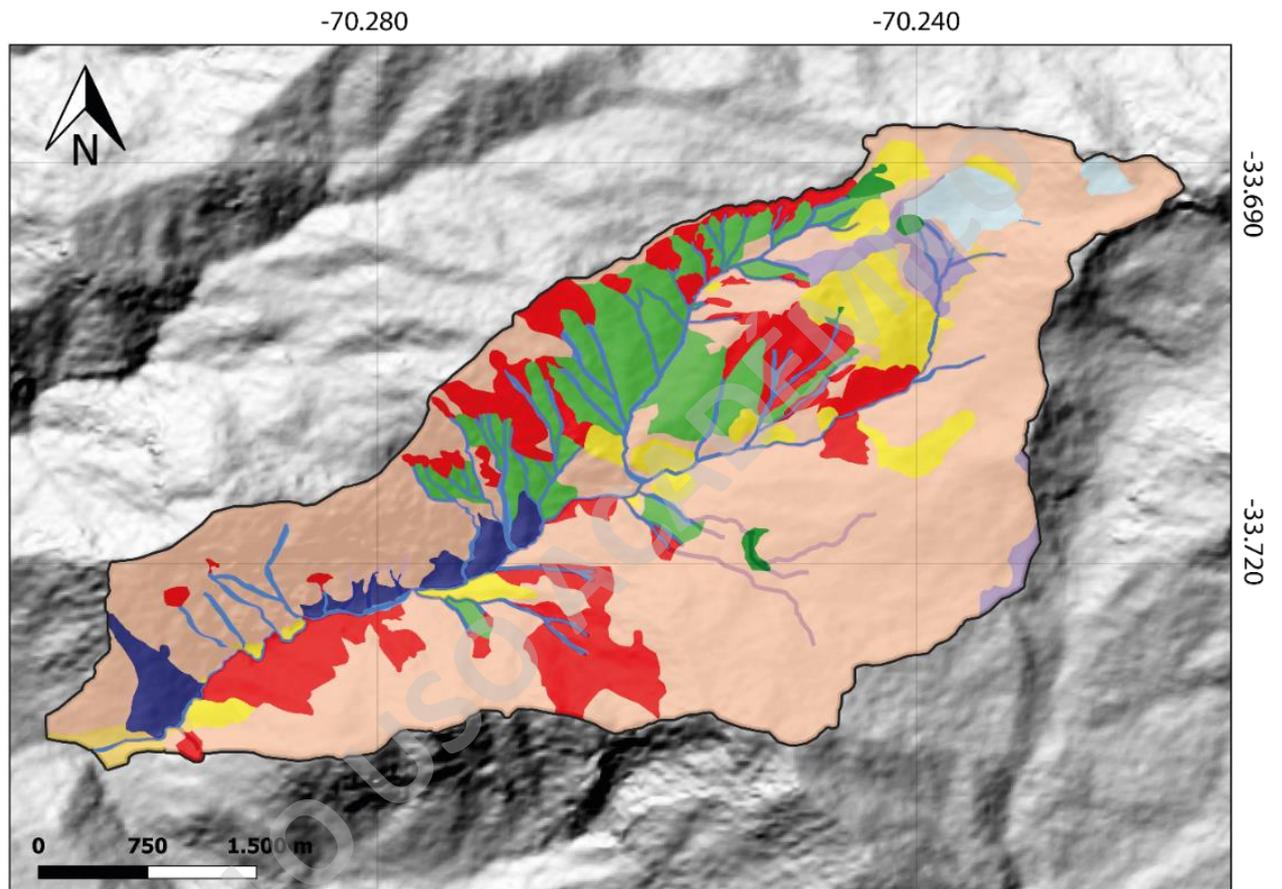


Figura 1.3. Mapa Geomorfológico Regional de la Región Metropolitana. El recuadro negro encierra el área de estudio. Börgel (1983).

### 1.4.2.3 Geomorfología Local

La geomorfología local (Figura 1.4) fue extraída del estudio realizado por *Muñoz (2018)*, a partir de trabajo en terreno y fotointerpretación de imágenes satelitales. En ella se identifican las morfologías predominantes de la cuenca del estero San Alfonso, estas corresponden a laderas de caída, deslizamientos, abanicos aluviales, zonas de interfluvio y zonas de arranque de aluviones.



#### Leyenda

	Abanico aluvial		Circo glacial		Cono de deyección		Deslizamiento
	Interfluvio		Ladera de caída		Morrenas		Pantano
	Vía aluvial		Zona de arranque				

Figura 1.4. Mapa Geomorfológico local de la cuenca del estero San Alfonso. Modificado de *Muñoz (2018)*.

## CAPÍTULO 2 : MARCO GEOLÓGICO

### 2.1 Geología Regional

El contexto geológico regional del área de estudio está definido principalmente por la hoja geológica de Santiago de *Thiele (1980)* a una escala 1:250.000 (Figura 2.1), la cual posteriormente fue digitalizada y modificada por *Fock (2005)*.

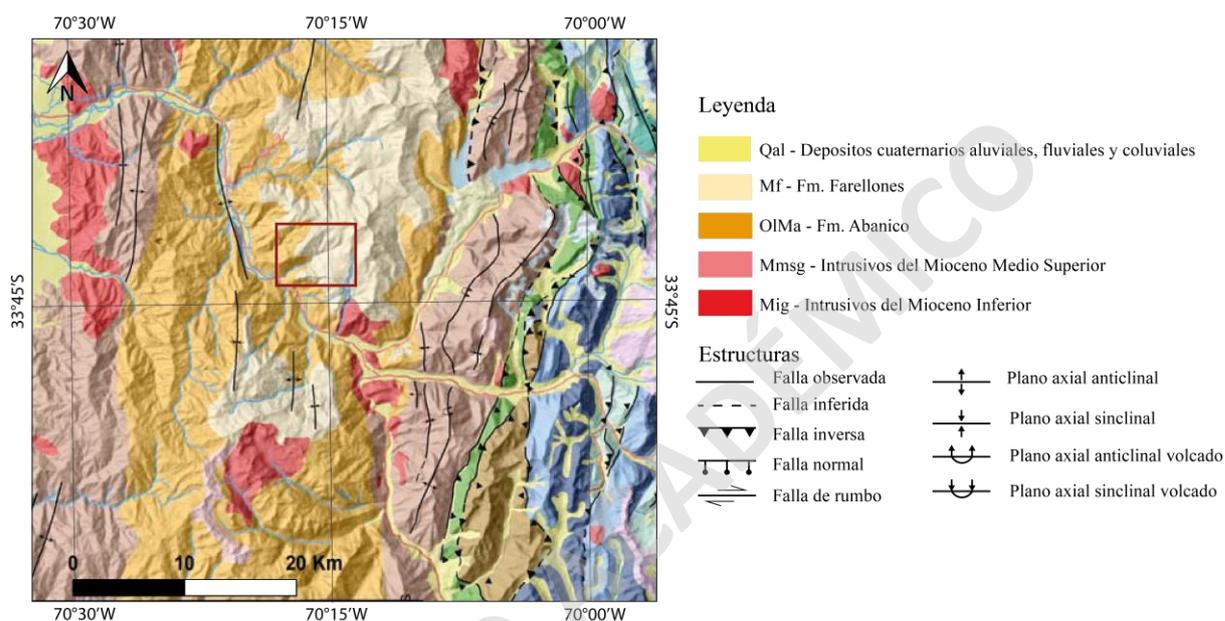


Figura 2.1. Mapa geológico regional de Fock et al. (2005) adaptado de Thiele (1980), Sellés y Gana (2001) y SERNAGEOMIN (2002).

#### 2.1.1 Rocas Estratificadas

##### 2.1.1.1 Formación Abanico (Aguirre, 1960)

Esta unidad es descrita como una sucesión de lavas básicas a intermedias, rocas piroclásticas ácidas e intercalaciones sedimentarias continentales (fluviales, aluviales y lacustres) dispuestas en forma de lentes cuyo espesor alcanza los 500 m (*Charrier et al., 2002; Nyström et al., 2003*). Los depósitos alcanzan un espesor promedio de 3500 a 4000m, aunque se considera que este aparece aumentado por las numerosas intrusiones de sills y lacolitos andesíticos (*Thiele, 1980*).

De acuerdo a diversas dataciones radiométricas y estudios de fauna fósil se le asigna una edad Eoceno Superior – Mioceno (Diversas dataciones radiométricas y estudios de fauna fósil permiten asignar una edad Eoceno Superior–Mioceno (*Wyss et al., 1994; Charrier et al., 1996, 2002; Gana et al., 1997; Sellés, 1999; Sellés et al., 2000; Fuentes et al., 2000, 2002*).

### **2.1.1.2 Formación Farellones (Khlon, 1960)**

Sucesión compuesta de lavas, tobas e ignimbritas con intercalaciones de brechas volcánicas. Existe un predominio de las lavas por sobre las tobas y brechas (*Thiele, 1980*). El espesor reportado es de 2.500 m, aumentado por numerosos mantos intrusivos y lacolitos del Mioceno Superior – Plioceno (*Thiele, 1980; Rivano et al, 1990*).

A la Formación de acuerdo con las dataciones radiométricas Ar/Ar disponibles se le asigna una edad Miocena (*Fuentes, 2004*). Esta unidad litoestratigráfica sobreyace a la Fm. Abanico entre los 32°S hasta los 35°S (*Fock, 2005*).

## **2.1.2 Rocas Intrusivas**

### **2.1.2.1 Intrusivos del Mioceno Inferior**

Corresponde a plutones cuyo rango de edad varía entre los 20 y 18 Ma. (*Sellés y Gana, 2001*). Intruyen a la Fm. Abanico y su litología principal corresponde a granodioritas (*Thiele, 1980; Kurtz et al., 1997*).

### **2.1.2.2 Intrusivos del Mioceno Medio-Superior**

Intrusivos cuyo rango de edad varía entre los 13 y 8 Ma (*Sellés & Gana, 2001*), y que se ubican más al este de la franja de Intrusivos del Mioceno Inferior. Las litologías principales de esta unidad son granodiorita, monzogranito y monzonita cuarcífera (*Thiele, 1980; Kurtz et al., 1997; Deckart et al., 2005; Deckart & Godoy, 2006*).

## **2.1.3 Depósitos No Consolidados**

### **2.1.3.1 Depósitos Coluviales**

Corresponden a depósitos holocénicos con una estratificación interna poco definida, ubicados en las laderas o al pie de ellas, estos desarrollan morfologías cónicas las cuales pueden alcanzar varias decenas de metros y fuertes pendientes de entre 20° a 25°. Su génesis se asocia principalmente a la meteorización mecánica y química y al efecto de la gravedad (*Moreno et al., 1991; Herrera, 2016*).

### **2.1.3.2 Depósitos Aluviales y Fluviales**

Corresponden a depósitos cuya variación granulométrica va desde bloques a arcillas semiconsolidados a no consolidados del Holoceno. Son el principal material de relleno del valle central y de los valles interiores. Los depósitos del río Maipo forman importantes niveles de terrazas los cuales gradan a glaciofluviales al pasar la cota de 1500 m.s.n.m (*Thiele, 1980; Ormeño, 2007; Herrera, 2016*).

### **2.1.3.3 Depósitos Glaciales**

Los depósitos glaciales corresponden a morrenas las cuales pueden dividirse por temporalidad en depósitos antiguos y depósitos recientes. Los depósitos antiguos se ubican entre las cotas 1450 y 1550 m.s.n.m, el grado de compactación y la meteorización de estos depósitos, además de la ausencia de depósitos equivalentes río abajo y la cota en que se encuentran, permiten asignarles una edad Pleistocena superior. Por su parte, los depósitos recientes se ubican entre las cotas 2000 y 4000 m.s.n.m., y corresponden a morrenas laterales, frontales y de fondo, ligados a glaciares en retroceso, ubicados en valles en dirección aproximada norte-sur (*Chiu, 1991; Herrera, 2016*).

### **2.1.4 Estructuras**

Las estructuras corresponden principalmente a pliegues asimétricos con ejes de rumbo N-NE y a fallas inversas con la misma orientación y con vergencia tanto al este como al oeste (*González, 1963; Thiele, 1980*). En la parte más oriental se puede observar una secuencia de fallas, anticlinales y sinclinales de rumbo N-NW, apretados y volcados con vergencia de preferencia al este, que constituyen la Faja Plegada y Corrida del Aconcagua, que afecta principalmente a las rocas Mesozoicas (*Thiele, 1980; Ramos et al., 1991; Rauld, 2002; Giambiagi et al., 2003*).

## **2.2 Geología Local**

El estudio de la geología local es fundamental para comprender mejor la historia geológica del área de estudio. Para la cuenca del estero San Alfonso se utilizó la descripción Geológica/Geotécnica local levantada por *Muñoz (2018)* a escala 1:20.000 (Figura 2.2), adaptada del mapa geológico de *Moreno et al. (1991)* de escala 1:50.000.

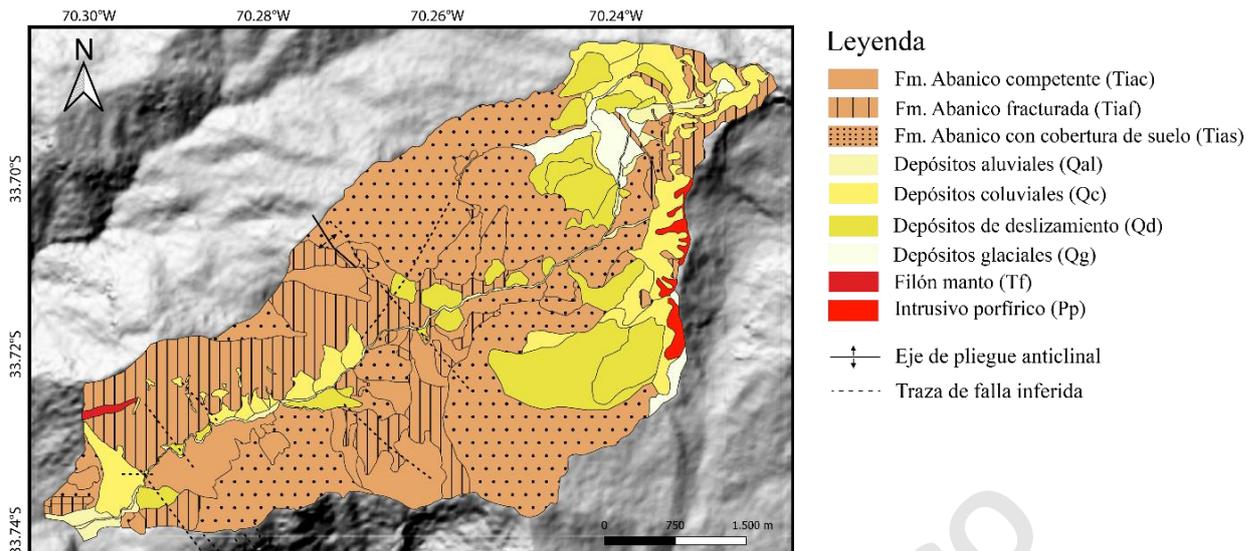


Figura 2.2. Mapa geológico/geotécnico cuenca estero San Alfonso. Modificado de Muñoz (2018).

## 2.2.1 Rocas Estratificada

### 2.2.1.1 Unidad Abanico fracturada (Tiaf)

En esta unidad la roca se presenta fracturada y meteorizada. Las rocas más incompetentes corresponden a lavas de grano fino (andesitas) e intercalaciones sedimentarias (lutitas y areniscas finas). Generalmente se encuentra en toda el área de estudio, principalmente en las zonas más próximas a estructuras tipo fallas y pliegues.

### 2.2.1.2 Unidad Abanico competente (Tiac)

En esta unidad la roca presenta un leve fracturamiento y meteorización. Las rocas de grano más grueso (lavas de grano grueso, brechas, tobas) son más competentes, presentándose fracturadas, pero formando bloques mayores entre los sets de estructuras. En general, se encuentra alejado de estructuras mayores, como fallas y pliegues.

### 2.2.1.3 Unidad Abanico con cobertura de suelo (Tias)

Esta unidad presenta un desarrollo de suelo superficial residual que genera una topografía suave y su espesor varía de decímetros a metros, principalmente en las zonas localmente más elevadas, corresponde a suelo arenoso a gravoso denso, con un porcentaje de material fino limoso variado. Suele estar cubierto por escasa vegetación.

## **2.2.2 Intrusivos**

### **2.2.2.1 Intrusivo porfídico (Pp)**

Corresponde a un intrusivo mayor en la zona de estudio que se encuentra en el borde oriental de la cuenca y afecta a la Fm. Abanico. Corresponde a un pórfido andesítico de masa fundamental de color negro con fenocristales de plagioclasa. Este intrusivo podría estar asociado con la alteración hidrotermal que se observa en la zona. Se presenta poco fracturado.

### **2.2.2.2 Filón manto (Tf)**

Corresponde a un intrusivo menor en la zona de estudio que se encuentra en el borde suroccidental de la cuenca y afecta a la Fm. Abanico. Se dispone con orientación NE-SW, con un manteo menor a 30°.

## **2.2.3 Depósitos no consolidados**

### **2.2.3.1 Depósitos aluviales (Qal)**

Se reconocen dos tipos de depósitos: activos e inactivos. Los primeros corresponden a depósitos bien gradados, clastos subangulares a subredondeados, de granulometría variable, desde arenas gruesas a gravas, con eventual presencia de bloques, sueltos a firmes en una matriz areno-limosa, cuyas litologías provienen principalmente de la Fm. Abanico y su origen se asocia a flujos esporádicos de baja energía con volúmenes variables, ocasionados principalmente en las cabeceras de las subcuencas de mayor altitud. Morfológicamente se presentan en vías y abanicos aluviales.

Los segundos corresponden a depósitos densos, mal gradados, clastos subredondeados a redondeados, de granulometría variable, desde arenas gruesas a bolones, cuyas litologías provienen principalmente de la Fm. Abanico. Su origen se asocia a flujos estacionales o perennes de alta energía, pero su proveniencia no es bien conocida Morfológicamente se presentan en terrazas. Queda abierta la hipótesis de que podrían haber sido depositados por un antiguo régimen del estero San Alfonso o más bien corresponden a depósitos fluviales.

### **2.2.3.2 Depósitos coluviales (Qc)**

Corresponden a acumulaciones de sedimentos gruesos de tamaños variables, que generalmente se muestran en forma de conos de deyección al pie de la Unidad Abanico fracturada o como mantos sobre ésta. Se encuentran en las zonas de alta pendiente que gradualmente decrecen. Sus depósitos tienen un espesor decimétrico a métrico, son pobremente gradados y el tamaño promedio de sus clastos son centimétricos a decimétricos, con tamaños hasta 8 m. Dentro de éstos, domina una compacidad baja, con escasa a nula cobertura vegetal y una litología perteneciente a la Fm. Abanico. Los clastos son de variada angulosidad y esfericidad, mientras que su pendiente de reposo varía entre 20 y 40°. Estos depósitos se encuentran por toda el área de estudio, principalmente en laderas cercanas al cauce principal del estero San Alfonso y en las zonas de mayor altitud local.

### **2.2.3.3 Depósitos de deslizamientos (Qd)**

Corresponden a acumulaciones de sedimentos de mayor envergadura (volumen) en comparación a Qc. Se presentan a los pies de zonas de alta pendiente, se distinguen principalmente por su morfología lobulada y por el escarpe localizado en sus laderas adyacentes. Sus características litológicas y granulométricas son ampliamente variadas. Corresponden a depósitos densos y los de mayor volumen se encuentran en las subcuencas de mayor altitud.

### **2.2.3.4 Depósitos glaciales (Qg)**

Corresponden a depósitos firmes con clastos angulosos inmersos en una matriz arenolimsa, con presencia de bloques; de textura masiva, mal seleccionada y caótica. Estos depósitos se reconocen principalmente en morrenas y dentro de circos glaciales. Su origen se asocia al avance y retroceso de glaciares, los cuales actualmente no se observan en la cuenca en estudio.

## **CAPÍTULO 3 : MARCO TEÓRICO**

### **3.1 Remociones en masa**

Los fenómenos de remoción en masa son procesos de transporte de material que tienen carácter descendente ya que están fundamentalmente controlados por la gravedad (*Cruden, 1991*). Estos procesos geomorfológicos pueden originarse por factores naturales y/o antrópicos, y se consideran un signo de inestabilidad de las laderas, que se define como la "propensión de una ladera a sufrir procesos de deslizamiento morfológica y estructuralmente perturbadores" (*Glade & Crozier, 2005*).

#### **3.1.1 Clasificación de remociones en masa**

##### **3.1.1.1 Tipo de movimiento y material**

La clasificación más utilizada para remociones en masa es la propuesta por *Cruden & Varnes (1996)*, considerando principalmente el tipo de material y los mecanismos del movimiento. Los tipos de materiales, a partir de los cuales se pueden generar los distintos tipos de eventos, corresponden a roca y suelo; en tanto los tipos de movimientos que se pueden generar son: caídas, deslizamientos (rotacionales y traslacionales), flujos, volcamientos y propagación lateral.

La clasificación de los tipos de remociones propuesta por *Cruden & Varnes (1996)*, ha sido enmendada por *Hungr et al. (2014)* con la intención de actualizar la categorización de remociones según la nueva información que se ha recopilado sobre los movimientos en masa, y de los materiales y mecanismos involucrados. Además, agrega un nuevo ítem en los tipos de movimientos el cual corresponde a la deformación de laderas, definiendo así un total de 32 tipos de remociones en masa (Tabla 3.1).

Tabla 3.1. Sistema de clasificación de RM de Cruden & Varnes (1996), actualizado por Hungr et al. (2014).

Tipo de Movimiento	Roca	Suelo
<b>Caída</b>	1. Caída de roca/hielo	2. Caída de detritos/limo
<b>Volcamiento</b>	3. Volcamiento en bloque 4. Volcamiento flexural	5. Volcamiento de grava/arena/limo
<b>Deslizamiento</b>	6. Deslizamiento rotacional 7. Deslizamiento planar 8. Deslizamiento en cuña 9. Deslizamiento compuesto 10. Deslizamiento irregular	11. Deslizamiento rotacional de arcilla/limo 12. Deslizamiento planar de arcilla/limo 13. Deslizamiento de grava/arena/limo 14. Deslizamiento compuesto de arcilla/limo
<b>Propagación lateral</b>	15. Propagación lateral de ladera	16. Licuefacción de arena/limo 17. Propagación lateral de arcilla sensitiva
<b>Flujo</b>	18. Avalancha de roca/hielo	19. Flujo seco de arena/limo/detritos 20. Deslizamiento por flujo de arena/limo/arcilla 21. Deslizamiento por flujo de arcilla sensitiva 22. Flujo de detritos 23. Flujo de lodo 24. Crecida de detritos 25. Avalancha de detritos 26. Flujo de tierra 27. Flujo de turba
<b>Deformación de ladera</b>	28. Deformación de ladera de montaña 29. Deformación de ladera de roca	30. Deformación de ladera de suelo 31. Reptación 32. Solifluxión

#### a) Caída

Es un tipo de movimiento en masa en el cual uno o varios bloques de suelo o roca se desprenden de una ladera, sin que a lo largo de esta superficie ocurra desplazamiento cortante apreciable. Una vez desprendido, el material se transporta por el aire efectuando golpes, rebotes y rodamiento (Varnes, 1978). Estos tipos de remociones corresponden a movimientos rápidos a extremadamente rápidos y es importante señalar que las caídas no tienen un movimiento masivo ni tipo flujo, pues si bien existe interacción mecánica entre fragmentos individuales y su trayectoria, no la hay entre los fragmentos en movimiento (Proyecto Multinacional Andino, 2007). La generación de desprendimientos, controladas por discontinuidades en la roca, está

relacionada con pendientes abruptas, principalmente de inclinaciones mayores a  $50^\circ$ , donde la roca está directamente expuesta (Soeters & Westen, 1996).



Figura 3.1. Esquema caída de roca. Extraído de Proyecto Multinacional Andino (2007).

### b) Volcamiento

Corresponde al desprendimiento de uno o varios fragmentos de rocas o suelo mediante la inclinación de éstos en torno a un punto o un eje bajo el centro de gravedad de la masa desplazada este tipo de movimiento ocurre por acción de la gravedad, empujes de las unidades adyacentes o por la presión de fluidos en grietas (Varnes, 1978). El volcamiento puede ser en bloque, flexural o de bloque de suelo. Su velocidad es variable entre extremadamente lentos a extremadamente rápidos y lo que lo distingue de una caída propiamente tal es que en la superficie de ruptura se genera cizalle, característica que lo hace ser catalogado por algunos autores como deslizamiento (Goodman, 1989).

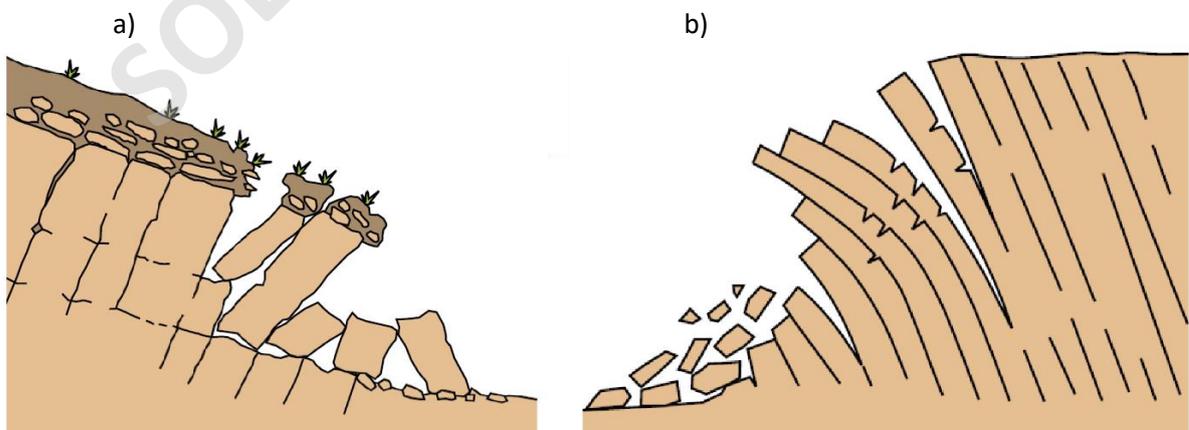


Figura 3.2. Esquema tipos de volcamientos, a) Volcamiento en bloque. b) Volcamiento flexural. Extraído de Proyecto Multinacional Andino (2007).

### c) Propagación Lateral

Se distingue como un tipo de movimiento en masa cuyo desplazamiento ocurre predominantemente por deformación interna (expansión) del material. En general presentan una subsidencia de la masa fracturada y está condicionada por laderas de baja a moderada pendiente, pueden considerarse como la etapa final en una serie de movimientos donde la deformación interna predomina decididamente sobre otros mecanismos de desplazamiento como los que imperan en el deslizamiento o el flujo (*Proyecto Multinacional Andino, 2007*).

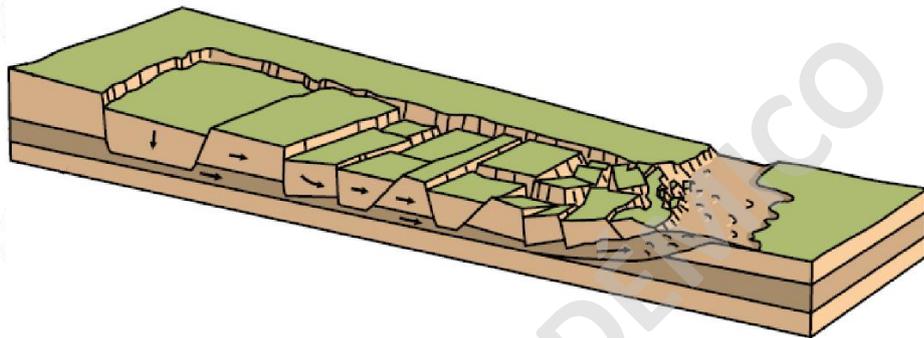


Figura 3.3. Esquema propagación lateral. Extraído de Proyecto Multinacional Andino (2007).

### d) Deformación de Ladera

*Hungr et al. (2014)* los incorpora en la clasificación actualizada de remociones en masa de *Cruden & Varnes (1996)* y los define como movimientos de ladera extremadamente lentos, producidos por efecto de la gravedad y condicionados por el tipo de roca y/o suelo asociado. La expresión física de la deformación está dada por la presencia de escarpes, terrazas, grietas, trincheras y bultos, pero carecen de una superficie de ruptura completamente definida.

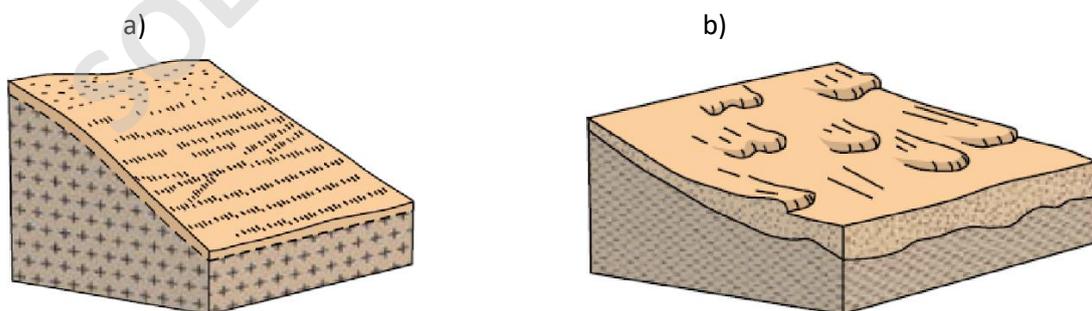


Figura 3.4. Esquema tipos de deformación de laderas, a) Reptación. b) Soliflucción. Extraído de Proyecto Multinacional Andino (2007).

### e) Flujo

Es un tipo de movimiento en masa que durante su desplazamiento exhibe un comportamiento semejante al de un fluido; puede ser rápido o lento saturado o seco. En muchos casos se originan a partir de otro tipo de movimiento, ya sea un deslizamiento o una caída (Varnes, 1978).

Hungr et al., (2001), clasifica los flujos de acuerdo con el tipo y propiedades del material involucrado, la humedad, la velocidad, confinamiento lateral y otras características que los hacen distinguibles. Los flujos se pueden clasificar según Varnes (1978), Hungr et al., (2001) y Hungr et al., (2005) en: flujos secos, flujo de detritos, crecida de detritos, flujo de lodo, flujo de tierra, deslizamiento por flujo, avalancha de detritos, y avalancha de rocas.

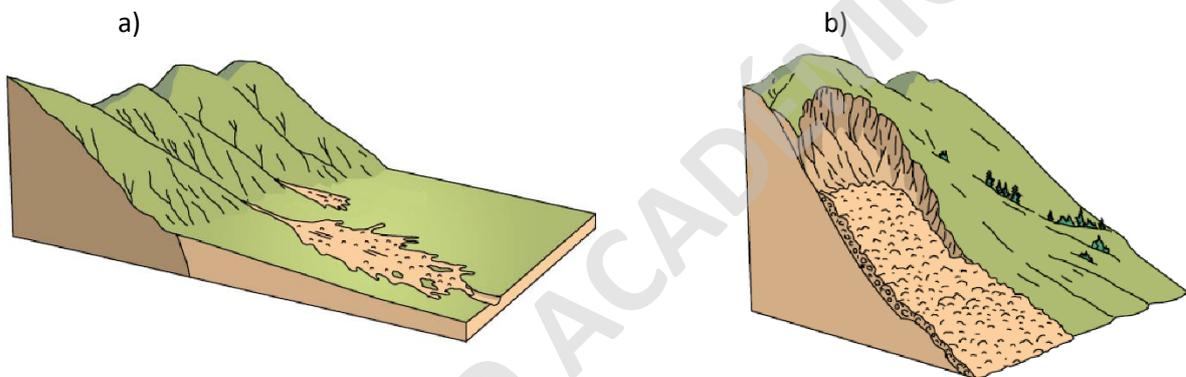


Figura 3.5. Esquema. a) Flujo no canalizado. b) Flujo canalizado. Extraído de Proyecto Multinacional Andino (2007).

### f) Deslizamiento

Es un tipo de remoción en masa caracterizado por el movimiento ladera abajo de una masa de suelo o roca cuyo desplazamiento ocurre predominantemente a lo largo de una superficie de falla, o de una delgada zona en donde ocurre una gran deformación cortante. Cuanto mayor sea la pendiente mayor es la componente de cizalle y los deslizamientos serán más frecuentes (Hauser, 1993). Estos se pueden categorizar según la forma de la superficie de corte en: rotacional, traslacional (planar o en cuña), irregular o compuesta.

Los deslizamientos pueden clasificarse según el material que es removido en deslizamientos de suelo y deslizamientos de roca, estos últimos ocurren cuando bloques de roca se separan de una ladera y se mueven hacia abajo por la fuerza de gravedad. Este tipo de movimiento en masa se produce principalmente en terrenos con pendientes pronunciadas donde las rocas están

sueltas o mal consolidadas, puede ser causado por factores como la erosión, actividad humana, acción del agua y sismos, entre otros.

Por otro lado, los deslizamiento de suelo ocurren cuando el suelo y la vegetación se deslizan sobre una capa de roca subyacente. El deslizamiento de suelo puede ser causado por factores como la sobrecarga del terreno, la saturación agua del suelo y la erosión, entre otros. A diferencia del deslizamiento de roca, el deslizamiento de suelo suele ocurrir en terrenos menos empinados y puede afectar grandes áreas de terreno (Keefers, 1984; Varnes, 1988, González de Vallejo, 2002).

El modelo conceptual de deslizamiento de suelo utilizado en este trabajo se divide en tres componentes principales: la zona de ruptura, la zona de acumulación y la zona de deformación. La zona de ruptura es la zona en la que se produce la falla o ruptura del suelo, y suele estar ubicada en la parte superior del deslizamiento. La zona de acumulación es la zona en la que se acumula el material deslizado, y suele estar ubicada en la parte inferior del deslizamiento. La zona de deformación es la zona en la que el suelo se deforma y se desliza hacia abajo, y suele estar ubicada entre las zonas de ruptura y de acumulación. (Cruden & Varnes, 1996; Ercanoglu et al., 2011).

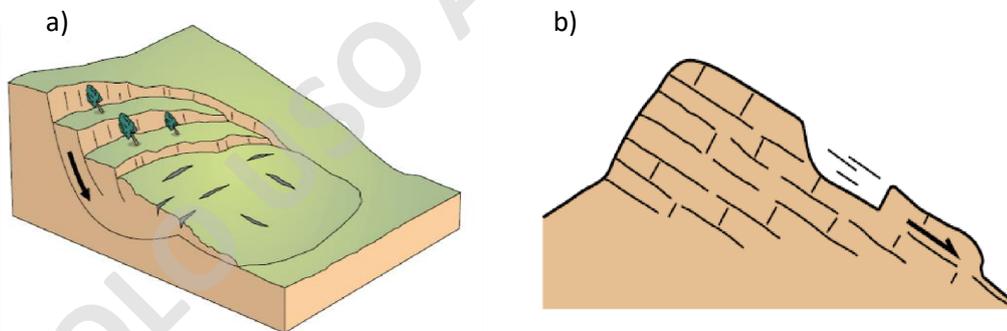


Figura 3.6. Esquema, a) Deslizamiento rotacional. b) Deslizamiento traslacional. Extraído de Proyecto Multinacional Andino (2007).

### 3.1.1.2 Velocidad

Cruden & Varnes (1996), proponen categorías para las diferentes tasas de movimientos (Tabla 3.2), los cuales van desde extremadamente rápidos a extremadamente lentos, y con base en estas velocidades estiman cuales son las consecuencias probables del fenómeno.

Tabla 3.2. Clasificación de remociones en masa según velocidad de desplazamiento de Cruden & Varnes (1996) y respuesta humana de Hungr (1981)

Clase	Descripción	Velocidad típica	Respuesta humana
1	Extremadamente lenta	16 mm/año	Nula
2	Muy lenta	16 mm/año	Mantenimiento
3	Lenta	1,6 m/año	Mantenimiento
4	Moderada	13 m/mes	Evacuación
5	Rápida	1,8 m/h	Evacuación
6	Muy rápida	3 m/min	Nula
7	Extremadamente rápida	5 m/s	Nula

### 3.1.2 Factores Condicionantes

Los factores condicionantes (Tabla 3.3) son agentes que potencialmente pueden aumentar o disminuir la estabilidad de una ladera. En otras palabras, son factores que intervienen en una situación potencialmente inestable, y que, por lo tanto, juegan un rol fundamental en la susceptibilidad a generar una remoción en masa, donde se entiende susceptibilidad como la capacidad o potencialidad de una unidad geológica o geomorfológica de ser afectada por un proceso geológico determinado (Sepúlveda, 1998).

Tabla 3.3. Factores condicionantes para análisis de susceptibilidad de remociones en masa. Basado en Lara (2007), Muñoz (2013) y Arenas et al. (2017).

Factor	Condición de influencia
<b>Geología y Geotecnia</b>	Características geológicas del área de estudio, propiedades mecánicas y calidad de la roca.
<b>Geomorfología</b>	Topografía, morfología y procesos morfogenéticos.
<b>Hidrología</b>	Red de drenaje, nivel freático, caudal, escorrentía y coeficiente de infiltración.
<b>Clima y Vegetación</b>	Erosión de laderas por factores atmosféricos, acumulación de nieve, estabilización de laderas por densidad de vegetación.
<b>Actividad Antrópica</b>	Desestabilización artificial de laderas y obstrucción del canal de drenaje.
<b>Morfometría</b>	Elevación, pendiente, curvatura, densidad de drenaje, entre otros.
<b>Antecedentes</b>	Catastro de eventos ocurridos en la cuenca.

### **a) Geología**

La geología corresponde a la caracterización de los depósitos y afloramientos presentes en el área de estudio en términos de litología, composición y estructuras internas (estratificación, gradación, foliación, plegamiento, etc.), relaciones de contacto, edad, meteorización, alteraciones y tipo de depósitos (*Hauser, 1997*).

Para que se pueda producir un proceso de remoción en masa es necesario que haya abundante material que pueda ser movilizado. En este sentido, la geología de la zona controla en gran parte la existencia de depósitos de sedimento o suelos residuales generados por meteorización in situ (*Sepúlveda, 1998*).

### **b) Geotecnia**

Para estudiar las remociones en masa no sólo es importante conocer la composición y tipo de material sensible a ser movilizado, sino que también como se espera que se comporte en términos mecánicos y resistentes. Es importante considerar el grado de alteración y meteorización de los macizos rocosos, así como caracterizar su fábrica estructural (tipo, disposición y condición de las discontinuidades), además de obtener valores de su resistencia, tanto de la roca intacta, del macizo como de sus discontinuidades, además de parámetros como la permeabilidad, humedad, densidad de los materiales que lo componen (*Muñoz, 2013*).

### **c) Geomorfología**

Por ser las remociones en masa procesos gravitacionales, se requiere tener una cierta pendiente para que se produzcan. En el caso de los deslizamientos, éstos se ven favorecidos por una morfología de laderas empinadas, lo que las hace potencialmente inestables al producir la aceleración de los materiales deslizados y favorecer el escurrimiento de agua (*Prieto, 1985; Hauser, 1993*).

Los rasgos geomorfológicos que condicionan eventos de remoción en masa son principalmente la topografía, pendientes de las laderas, cambios fuertes de pendientes de las laderas y la extensión y altura de las laderas, estas características inciden en la velocidad, energía y volumen de las remociones que puedan originarse. Así también, cualquier modificación de ellos puede transformar una ladera estable en inestable y generar remociones (*Popescu, 2002*).

En la generación de una remoción en masa es necesario material susceptible a ser movilizado. Por esto, es fundamental el reconocimiento de eventos anteriores que hayan dejado material suelto, como también, coluvios que se ubiquen en pies de laderas y quebradas, donde su condición de equilibrio límite los hace propensos a generar flujos o deslizamientos (*Villela, 2017*).

#### **d) Hidrología e Hidrogeología**

La red de drenaje, las posiciones y variaciones del nivel freático, caudales, coeficientes de escorrentía y coeficientes de infiltración, son factores hidrológicos e hidrogeológicos que condicionan la generación de remociones en masa ya que están directamente relacionados a la incorporación de agua en los suelos o macizos rocosos (*Lara, 2007*). El agua afecta negativamente la resistencia de los materiales, ya que, por un lado, genera presiones intersticiales lo que reduce la resistencia, aumenta los esfuerzos de corte por el incremento del peso del terreno y genera fuerzas desestabilizadoras en grietas y discontinuidades (*González de Vallejo et al., 2002*).

#### **e) Clima y Vegetación**

Los agentes atmosféricos tienen una gran influencia sobre la estabilidad de las laderas, considerando que estos pueden afectar negativamente a la competencia de la roca y/o suelo por procesos de meteorización y erosión. Los principales factores que condicionan la erosión de una ladera son las precipitaciones, la temperatura y sus variaciones, el viento y la radiación solar (*Sepúlveda, 1998; Lara, 2007*).

En zonas montañosas, un alza en la ubicación de la isoterma de 0°C, por sobre la cota normal en determinada época del año, produce fusión de la nieve acumulada y/o una ampliación de la cuenca receptora de aguas lluvias, lo que implica un aumento en la incorporación de agua al suelo. Este factor fue determinante para la generación de los 'aluviones' de 1993 en las quebradas Macul y San Ramón, al oriente de Santiago (*Naranjo & Varela, 1996*).

#### **f) Actividad Antrópica**

El control que ejerce el factor humano sobre la estabilidad de laderas es muchas veces primordial en la generación de eventos de remoción en masa, pueden contribuir tanto a la desestabilización de las laderas producto de la disminución artificial de la resistencia del

material, como a la contribución de material para ser movilizados por futuros eventos y cambios en la escorrentía superficial y en la topografía (*Lara, 2007*).

### **3.1.3 Agentes Desencadenantes**

Corresponden a estímulos externos que pueden detonar una remoción en masa, estos pueden generar una respuesta casi inmediata al incrementar rápidamente los esfuerzos o reduciendo la resistencia del terreno en una ladera (*Wieczorek, 1996*).

#### **a) Precipitaciones**

La lluvia opera tanto como un factor condicionante de inestabilidad de ladera como un agente desencadenante, las áreas donde se registra un mayor promedio de precipitación anual presentan mayores problemas de estabilidad debido entre otras cosas, a la existencia de caudales de flujo subterráneo y materiales más meteorizados que tienen incidencia en las propiedades geomecánicas del terreno (*Cuanalo et al., 2006*).

El desencadenamiento de remociones en masa por causas meteorológicas y climáticas está relacionado fundamentalmente con el volumen, intensidad y distribución de las precipitaciones, lo que implica considerar la respuesta del terreno ante lluvias intensas durante horas o días, su respuesta estacional y en ciclos de sequía (*González de Vallejo et al., 2002*).

Las precipitaciones cortas e intensas serían más proclives a generar eventos superficiales, mientras que remociones más profundas serían provocadas por eventos distribuidos en largo periodo de tiempo (*Aleotti, 2004*).

#### **b) Sismicidad**

Los sismos son otros grandes factores desencadenantes de remociones en masa en diversos escenarios geológicos y topográficos. Las aceleraciones sísmicas generan un cambio temporal en el régimen de esfuerzos al que está sometido la ladera, tanto normales como de corte, pudiendo producir su inestabilidad (*Lara, 2007*).

*Sepúlveda et al. (2004)* realizan un estudio sobre la amplificación topográfica, el cual es un efecto causado por la interacción entre el movimiento sísmico y determinadas configuraciones geomorfológicas, comúnmente pendientes empinadas, lo que puede resultar en la activación de fallas que se consideran estables en ausencia de un evento sísmico. Este efecto esta

caracterizado por movimientos más fuertes hacia la cresta de la ladera y más atenuados hacia su base (Geli *et al.*, 1988), lo que puede resultar en deslizamientos y caídas de roca.

### 3.1.4 Mapas de Susceptibilidad

La susceptibilidad se define como la capacidad o potencialidad de una unidad geológica o geomorfológica de ser afectada por un proceso geológico determinado (Sepúlveda, 1998). Por lo tanto, un mapa de susceptibilidad es un producto cartográfico (Figura 3.7) que representa la probabilidad de que ocurra un proceso geológico en un área determinada en función de las características intrínsecas del terreno (Chung *et al.*, 1995)

En el caso específico de la susceptibilidad a remociones en masa, los mapas de susceptibilidad indica cuán propensa es una ladera a producir estos eventos. Las aplicaciones incluyen la planificación urbana y regional, la evaluación de riesgos en la construcción de edificios y otras estructuras, la identificación de zonas propensas a desastres y la toma de decisiones en materia de seguridad pública para generar planes de mitigación y gestión del riesgo geológico.

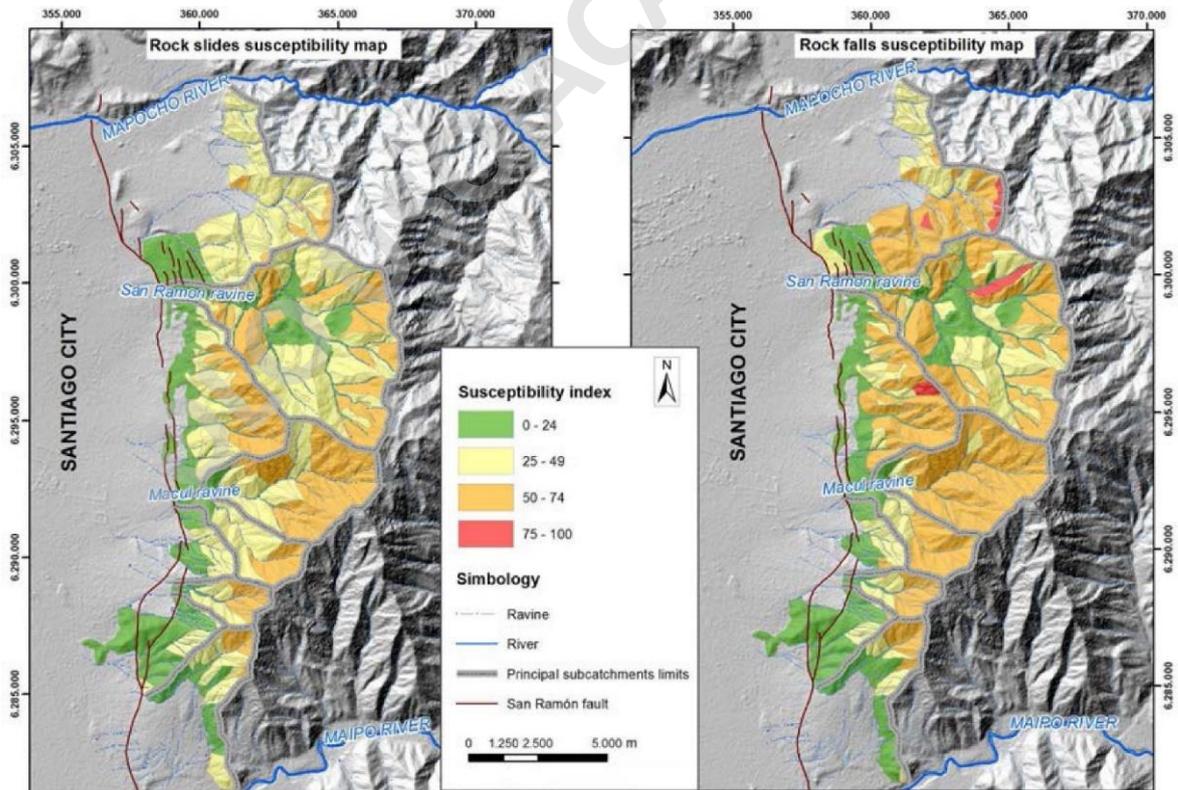


Figura 3.7. Ejemplo mapa de susceptibilidad. A) deslizamientos de roca, b) caída de roca, Lara *et al.*, 2018.

## 3.2 Inteligencia Artificial y Machine Learning

La inteligencia artificial (IA) y el aprendizaje automático (Machine Learning, ML) son dos campos relacionados pero distintos dentro del ámbito de la informática.

La inteligencia artificial hace referencia a la creación de sistemas y algoritmos que imitan la inteligencia humana y pueden realizar tareas que normalmente requieren una inteligencia humana, como el reconocimiento de patrones, la toma de decisiones y la resolución de problemas (*Rouhiainen, 2018*).

El aprendizaje automático, por otro lado, es una subcategoría de la IA que se enfoca en el desarrollo de algoritmos y sistemas que pueden aprender y mejorar a partir de datos sin ser explícitamente programados para realizar una tarea específica. En otras palabras, el aprendizaje automático se enfoca en cómo los sistemas de IA pueden aprender de datos y mejorar con el tiempo, mientras que la IA en sí abarca una amplia gama de técnicas y enfoques para crear sistemas inteligentes.

### 3.2.1 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNA) son sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas (*Palmer y Montaña, 1999*). Estas intentan emular cómo el cerebro procesa la información mediante las conexiones sinápticas. Se ha demostrado su utilidad en la resolución de problemas de regresión lineal y clasificación binaria (*Kanungo et al., 2006*).

Las RNA están formadas por capas de "neuronas" artificiales (Figura 3.8) que están interconectadas por "sinapsis" artificiales. Cada neurona recibe entradas de otras neuronas a través de estas conexiones, y realiza una operación matemática en estas entradas antes de pasarlas a las neuronas de la capa siguiente. El proceso se repite a través de múltiples capas hasta que se produce una salida final del modelo.

El proceso de entrenamiento de una RNA implica el ajuste de los "pesos" de las conexiones entre las neuronas para minimizar el error en la salida del modelo en relación con la salida deseada. Una vez que se ha entrenado una RNA, se puede utilizar para realizar una variedad de tareas, como el reconocimiento de patrones, la clasificación y la predicción.

En general los estudios de susceptibilidad de remociones en masa pueden ser comprendidos como un problema de clasificación binaria, ya que lo que se busca es que la RNA aprenda a reconocer patrones a partir de datos conocidos que le permitan distinguir entre dos categorías (1 y 0), y de esta manera adquirir la capacidad de tomar decisiones para poder clasificar a partir de datos que no conoce.

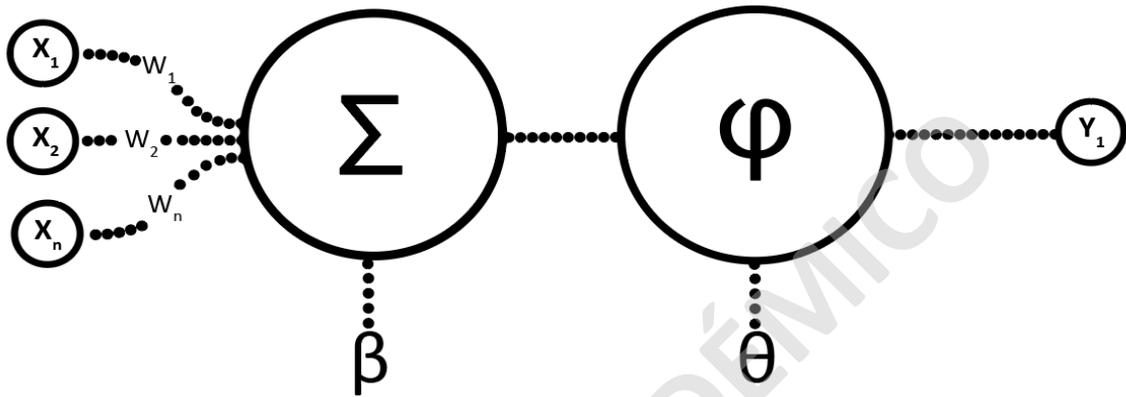


Figura 3.8. Esquema de los componentes y funcionamiento de una neurona.

**Valores de entrada (x):** son los valores de los parámetros a evaluar, corresponde a las variables explicativas de la ocurrencia de un evento, por ejemplo, en este caso los factores condicionantes de la ocurrencia de deslizamientos de suelo.

**Pesos sinápticos (w):** Es el peso que indica la relevancia de cada uno de los factores, de acuerdo a su grado de incidencia en el objetivo del análisis, este define con que intensidad cada variable afecta a la neurona.

**Función de entrada ( $\Sigma$ ):** Es una suma ponderada de los valores de entrada a los cuales se les asigna un peso sináptico.

**Bias ( $\beta$ ):** Se agrega una entrada cuyo valor es constante e igual a 1, y esta puede ser controlada manipulando el valor del parámetro de bias, también denominado sesgo, permitiendo trasladar la función de activación en el eje x, y determinando donde cortara la función en el eje y, evitando así posibles valores iguales a cero.

Hasta esta etapa los componentes de una neurona tienen el comportamiento de una regresión lineal con la siguiente configuración:

$$Y = \sum x_n w_n + \beta \quad \text{Ecuación 3.1}$$

**Umbral ( $\theta$ ):** Es un valor que define los límites que se utilizarán para evaluar los resultados de la regresión lineal, si el valor supera el umbral se define que  $Y=1$ , y si no lo supera  $Y=0$ , lo que permite determinar si es que la neurona es activada y se pasa al siguiente proceso.

**Función de Activación ( $\phi$ ):** Es un ponderador que busca distorsionar la recta formada en la regresión lineal, mediante la integración de deformaciones no lineales. Se encarga de realizar la discriminación para dejar pasar o no el flujo de información hacia la siguiente neurona y permiten a las redes neuronales adecuarse a las exigencias del análisis. Algunas de las funciones de activación más utilizadas en algoritmos de aprendizaje de retropropagación del error (Backpropagation) son:

**a) Función Sigmoidea (logística):** La familia de funciones sigmoideas son de las funciones de activación más utilizadas en las redes neuronales artificiales, debido a que estas permiten mitigar el efecto de los valores atípicos en el entrenamiento del modelo, entre estas destaca la función sigmoidea logística la cual permite convertir variables independientes de rango casi infinito en probabilidades simples entre 0 y 1. Además muchos procesos naturales tienen una progresión temporal que va desde niveles bajos al inicio, hasta alcanzar un peak transcurrido un cierto tiempo, y la función sigmoide permite describir esta evolución.

$$y = \frac{1}{1+e^{-x}} \quad \text{Ecuación 3.2}$$

**b) Función Tangente Hiperbólica:** esta función es similar a la sigmoideal logística, pero se encuentra acotada para un rango entre -1 y 1, entre sus ventajas comparativas se encuentra que esta última al estar centrada en cero trabaja mejor con el algoritmo de aprendizaje de retropropagación del error, acelerando el proceso de aprendizaje.

$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{Ecuación 3.3}$$

**c) Función ReLU:** La función ReLU (Rectified Linear Unit) es una función de activación no lineal ampliamente utilizada en redes neuronales artificiales, especialmente en las capas ocultas de las mismas y se define como:

$$f(x) = \max(0, x) \quad \text{Ecuación 3.4}$$

Es decir, toma el valor máximo entre cero y el valor de entrada  $x$ . Esto significa que, si el valor de entrada  $x$  es positivo, la salida es igual a  $x$ , y si el valor de entrada es negativo, la salida es cero.

La función ReLU es popular en las redes neuronales debido a su simplicidad y eficiencia computacional. Además, la función ReLU puede ayudar a resolver el problema de la desaparición del gradiente, que puede ocurrir en otras funciones de activación cuando se utilizan redes neuronales profundas. Al establecer la salida a cero para los valores negativos, la función ReLU ayuda a evitar que las señales se degraden en las capas posteriores de la red.

### 3.2.2 Arquitectura Perceptrón Multicapa

La arquitectura de una red neuronal consiste en la organización y disposición de las neuronas y las capas que forman (Figura 3.9). En este sentido los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas (Molina, 2012).

Un perceptrón multicapa (MLP, por sus siglas en inglés) es una red neuronal artificial con múltiples capas ocultas entre la capa de entrada y la capa de salida.

A diferencia del perceptrón simple, que solo tiene una capa de neuronas y se utiliza para clasificar datos linealmente separables, el MLP puede manejar datos no lineales. Cada capa oculta está compuesta por un conjunto de neuronas interconectadas, que realizan una operación matemática en las entradas recibidas antes de pasarlas a las neuronas de la capa siguiente (Maind y Wankar, 2014).

El proceso de entrenamiento de un MLP implica la propagación hacia adelante de los datos de entrada a través de las capas de la red neuronal, y luego la propagación hacia atrás del error de salida para ajustar los pesos de las conexiones entre las neuronas en la red (Park & Lek, 2016). Este proceso se repite a través de múltiples iteraciones hasta que se minimiza el error en la salida del modelo.

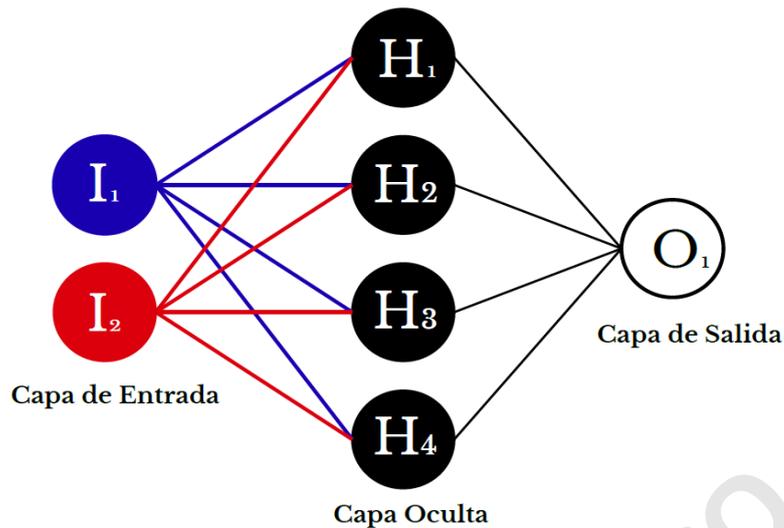


Figura 3.9. Esquema del funcionamiento y componentes de una red neuronal artificial simplificada.

**Capa de Entrada (Input):** Una capa de entrada se refiere a un conjunto de datos espaciales que se utilizan como entrada en un análisis, estas pueden ser datos geográficos de diferentes tipos, como mapas, imágenes satelitales, datos LiDAR, datos topográficos, entre otros. son un componente importante de muchos análisis de GIS, ya que proporcionan la información necesaria para realizar cálculos o generar nuevos datos (Rumelhart et al., 1986).

**Capa Oculta (Hidden):** Su función es procesar la información de entrada de la capa anterior, procesarla y generar una salida que se transmite a la siguiente capa a través de conexiones ponderadas, estas conexiones representan la fuerza de la influencia de cada nodo en los nodos de la capa siguiente. La información procesada en cada capa oculta se utiliza para ajustar las conexiones ponderadas entre las neuronas de la red, con el fin de mejorar la precisión de la red en la tarea de aprendizaje (Walczak & Cerpa, 2003).

**Capa de Salida (Output):** Es la última capa de neuronas de una red neuronal que genera la salida o el resultado de la red. Su función de activación determina el valor de salida de la red neuronal. Dependiendo del tipo de problema que se está resolviendo, la red neuronal determina la configuración de la capa de salida. Por ejemplo, en un problema de clasificación binaria, la capa de salida tendría una sola neurona, cuya función de activación produciría un valor de salida binario (1 o 0). En un problema de clasificación multiclase, la capa de salida tendría tantas neuronas como clases se están clasificando, y la función de activación de cada neurona produciría la probabilidad de pertenecer a cada clase (Domingos, 2012; Radford et al., 2016).

## **CAPÍTULO 4 : METODOLOGÍA**

En este capítulo se describe de manera detallada cómo se llevó a cabo el estudio y se justifican las decisiones tomadas en cuanto a la selección de las técnicas y herramientas utilizadas. Además, se establecen los criterios y parámetros que se han seguido para evaluar los resultados obtenidos.

### **4.1 Revisión Bibliográfica**

Una vez establecida el área de estudio, correspondiente a la cuenca del estero San Alfonso, se procede a realizar una búsqueda sistemática y análisis de literatura académica y científica (e.g. Hauser, 1993, 1996, 2000; Sepúlveda, 1998, 2014; Hungr et al., 2005, 2014; Lara, 2007; Alpaydin, 2010; Muñoz, 2013; Villela, 2017; Muñoz, 2018; Wang, 2019; Sandoval, 2021, Alfaro, 2022) además de prensa (e.g. *El Mostrador*, *La Tercera*), imágenes satelitales, mapas, tablas de descripción geotécnica, entre otros. El objetivo de esta etapa es resumir la información y evidencia existente sobre un tema en específico, en este caso la búsqueda de información se enfocó en las remociones en masa, metodologías de evaluación de peligro y susceptibilidad, inteligencia artificial y redes neuronales artificiales.

### **4.2 Catastro y Mapeo de Zonas de Ocurrencia**

En una primera instancia, se realizó el mapeo poligonal de zonas de ocurrencia de deslizamientos de suelo utilizando como referencia el mapa geomorfológico elaborado por Muñoz (2018) y la fotointerpretación de imágenes satelitales históricas en Google Earth Pro, de esta manera se delimitan las zonas que corresponden a las áreas de ocurrencia, según se definen en el modelo conceptual de deslizamientos de suelo, las cuales indicarán las zonas donde los valores de los factores condicionantes resultan en un deslizamiento. Posteriormente se realiza el mapeo de puntos con base en el inventario poligonal, este puede realizarse de distintas formas, primero utilizando los centroides de los polígonos, utilizando una malla regular de puntos (Prashka et al., 2020) o bien, como un mapeo de puntos aleatorios, este último método es el utilizado para este estudio, debido a que favorece la representatividad de los datos (Althuwaynee et al., 2014).

*Sameen et al. (2019)* recomienda que la distancia entre puntos no sea menor a 100 metros, para de esta forma evitar el sobremuestreo de zonas con valores similares que resulten en un sobreajuste de la red neuronal artificial.

### **4.3 Preselección de Factores Condicionantes**

Una parte fundamental para la evaluación de susceptibilidad es seleccionar los factores condicionantes que determinan las condiciones de estabilidad del terreno en la cuenca donde se realizará el estudio.

Para realizar la preselección de factores se llevó a cabo una revisión bibliográfica de estudios que se han realizado en sectores de características similares. Utilizando como referencia las investigaciones de *Sepúlveda (1998)*, *Rebolledo et al. (2000)*, *Lara (2007)*, *Muñoz (2013)*, *Arenas et al. (2017)*, *Muñoz (2018)* y *Espinoza (2019)*.

De acuerdo con este análisis fue posible determinar los factores condicionantes que se utilizan con mayor frecuencia en estudios de este tipo (Tabla 4.1), además de algunos factores experimentales calculados con los algoritmos del software SAGA incluido en QGIS, tales como el factor LS, índice de rugosidad topográfico y índice de humedad topográfico.

Se debe tener en cuenta que la incidencia de los factores condicionantes varía según el tipo de remoción en masa, y que para condiciones geológicas o climáticas distintas a las que fueron consideradas en la metodología de *Lara (2007)* para la Quebrada San Ramón y en la de *Muñoz (2013)* en Viña del Mar, es necesario calibrar el peso de los factores. Este último punto es lo que se busca resolver mediante la aplicación de redes neuronales artificiales, ya que estas permitirían determinar cuáles son los factores condicionantes más relevantes para el estudio de la cuenca del estero San Alfonso, o cualquier área de estudio que requiera ser analizada, y cuáles son las ponderaciones más precisas para cada parámetro en la localidad estudiada.

Tabla 4.1. Resumen de factores condicionantes para remociones en masa. Basado en Sepúlveda (1998), Lara (2007), Muñoz (2013) y Arenas et al. (2017).

Factores Condicionantes	
Geología	Elevación
Geotecnia	Aspecto
Geomorfología	Gradiente Topográfico
Uso de Suelo	Curvatura
Hidrología	Índice de Humedad Topográfico
Antecedentes	Distancia Red de Drenaje
Pendiente	Índice de Rugosidad Topográfico
Densidad de Drenaje	Factor LS

#### 4.4 Elaboración de Mapas Temáticos

Una vez que se establecen todos los factores condicionantes a utilizar, se procede a elaborar los mapas temáticos (Figura 4.1), estos son representaciones gráficas que muestran la distribución espacial de un conjunto específico de datos de las variables que influyen en la susceptibilidad de las remociones en masa, como la topografía, la geología, la pendiente, la orientación de la ladera, entre otras. Estos mapas se crean a partir de información obtenida por medio de técnicas de teledetección, sistemas de información geográfica (SIG), análisis estadísticos y modelos matemáticos.

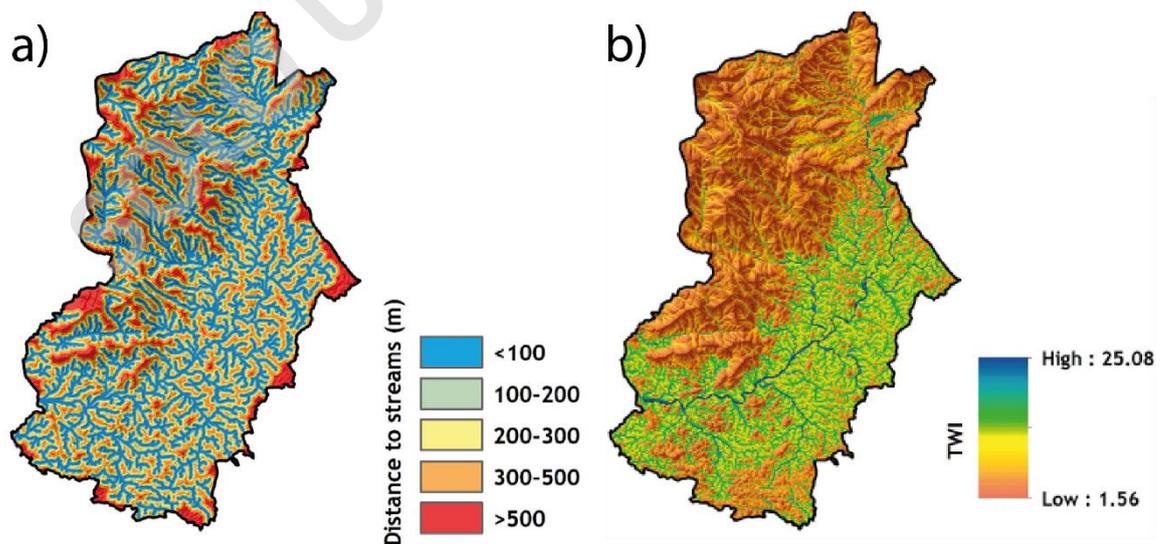


Figura 4.1. Ejemplos de mapas temáticos, a) Distancia a la red de drenaje y b) Índice de humedad topográfico. Extraído sin modificaciones de Feby et al., 2020.

## 4.5 Acondicionamiento de Variables

La base de datos generada en el paso anterior debe ser separada en dos conjuntos aleatorios, no hay una proporción fija o "mejor" para la división entre conjuntos de entrenamiento y testeo en una red neuronal artificial, ya que esto puede depender del tamaño del conjunto de datos, la complejidad del modelo y la naturaleza del problema (*Japkowicz & Stephen, 2002*). Sin embargo, una división comúnmente utilizada es 70/30, es decir, el 70% de los datos se utilizan para entrenamiento y el 30% restante para testeo. Otra proporción comúnmente utilizada es 80/20.

Es importante tener en cuenta que, en general, se necesita suficiente cantidad de datos para entrenar un modelo con precisión y evitar el sobreajuste (*overfitting*), lo que ocurre cuando el modelo se ajusta demasiado a los datos de entrenamiento y no es capaz de generalizar bien en datos nuevos. Por lo tanto, es importante contar con suficientes datos de prueba para evaluar la capacidad de generalización del modelo (*Goodfellow et al., 2016*).

Antes de ingresar los datos a la red neuronal es necesario una etapa de preparación, para esto la base de datos debe abrirse en Excel, para procesarla antes de utilizarla en la red neuronal, es necesario realizar algunas intervenciones. Primero, debemos asegurarnos de que no haya valores vacíos y de que los números sean coherentes y consistentes en su formato. Además, es necesario normalizar las variables numéricas y categóricas antes de introducirlas en la red neuronal.

La normalización es necesaria para que todos los valores se encuentren en la misma escala, lo cual facilita el procesamiento de la red neuronal. Por ejemplo, si tenemos variables como "aspecto" que varía entre 0 y 360°, y "pendiente" que varía entre 0 y 90°, es importante que todos estos factores condicionantes se muevan en un rango de 0 a 1.

Por otro lado, las variables categóricas como, por ejemplo, geología y geomorfología, pueden ser transformadas mediante diferentes métodos, el primero consiste en realizar una codificación "One-Hot", el cual consiste en transformar cada categoría del factor condicionante, en variables binarias, donde se indica con un 1 la presencia de dicha categoría sobre el punto del catastro a evaluar y con 0 su ausencia, como se ve ejemplificado en la Tabla 4.2

Otro método es la codificación ordinal, la cual consiste en asignar un número arbitrario y correlativo para convertir cada categoría en un valor numérico (Tabla 4.3), una vez

transformadas las variables, estas pueden ser trabajadas junto con las numéricas y pasar por un proceso de normalización denominado estandarización de rango (Ecuación 4.1).

Esta técnica consiste en convertir los valores de una variable numérica en un rango estándar, generalmente entre 0 y 1 (Tabla 4.4).

La estandarización de rango es útil porque hace que las variables numéricas sean comparables entre sí al eliminar la influencia de las diferentes escalas de medida (Barth et al., 2019). Es importante tener en cuenta que la estandarización de rango no es apropiada para todas las situaciones y que debe considerarse cuidadosamente junto con otras técnicas de preprocesamiento de datos. Además, es posible que deba adaptarse a diferentes rangos según el contexto de los datos y el objetivo del análisis (Borman & Herman, 2000).

Tabla 4.2. Normalización de variables categóricas, método de la división de categorías según su presencia o ausencia en el punto evaluado.

	<b>Tias</b>	<b>Tiac</b>	<b>Tiaf</b>	<b>Qal</b>	<b>Qc</b>	<b>Qd</b>	<b>Qg</b>	<b>Tf</b>	<b>Pp</b>
	1	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	1	0	0
	0	1	0	0	0	0	0	0	0
	0	0	0	0	1	0	0	0	0
<b>Geología</b>	0	0	0	0	0	1	0	0	0
	0	0	0	1	0	0	0	0	0
	0	0	1	0	0	0	0	0	0
	0	0	0	0	0	0	0	1	0
	0	0	0	0	0	0	0	0	1

$$X_{Normalizado} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad \text{Ecuación 4.1}$$

Tabla 4.3. Variable categórica geología con sus correspondientes categorías transformadas a valores numéricos.

Geología	
Tias	1
Tiac	2
Tiaf	3
Qal	4
Qc	5
Qd	6
Qg	7
Tf	8
Pp	9

Tabla 4.4. Normalización de variables categóricas, método de la división de rango.

Geología		
Tias	1	0.00
Tiac	2	0.13
Tiaf	3	0.25
Qal	4	0.38
Qc	5	0.50
Qd	6	0.63
Qg	7	0.75
Tf	8	0.88
Pp	9	1.00

#### 4.6 Análisis Exploratorio de Datos

El análisis exploratorio de datos (EDA) es una técnica estadística que se utiliza para examinar y resumir un conjunto de datos antes de realizar un análisis más detallado. El objetivo del EDA es comprender mejor los patrones y las tendencias en los datos, identificar valores atípicos o valores faltantes, y determinar la distribución de las variables (Tukey, 1977; James et al., 2016), puede ayudar a identificar patrones interesantes en los datos. Además, permite conocer a priori la relación entre las variables para así tener una base con la que comparar los

resultados obtenidos posteriormente con la RNA y de esta manera evaluar la validez de los resultados.

El EDA se basa en la visualización de los datos a través de gráficos y tablas, y en la utilización de medidas estadísticas básicas, como la media, la mediana, la desviación estándar y los percentiles. Algunas técnicas comunes de EDA son:

- Histogramas y diagramas de caja para visualizar la distribución de las variables.
- Gráficos de dispersión para explorar la relación entre dos variables.
- Tablas de frecuencia para resumir los datos categóricos.
- Gráficos de correlación para medir la fuerza y la dirección de la relación entre dos variables.

#### **4.7 Aprendizaje y Entrenamiento**

El aprendizaje y entrenamiento de una red neuronal consiste en el proceso mediante el cual se ajustan los pesos de las conexiones entre las neuronas de la red para que esta pueda aprender a realizar una tarea específica. El objetivo del entrenamiento de una red neuronal es minimizar el error entre la salida esperada y la salida real de la red (*Goodfellow et al., 2016*)

El proceso de entrenamiento de una red neuronal se realiza en varias etapas, que incluyen:

1. Inicialización de pesos: Al inicio, los pesos de las conexiones entre las neuronas se establecen en valores aleatorios.
2. Propagación: Se proporciona un conjunto de datos de entrenamiento a la red, y los valores de entrada se propagan hacia adelante a través de la red para producir una salida.
3. Cálculo del error: se compara la salida de la red con la salida esperada y se calcula el error.
4. Retropropagación del error: El error se propaga hacia atrás a través de la red para ajustar los pesos de las conexiones entre las neuronas.
5. Actualización de pesos: Se ajustan los pesos de las conexiones en función del error calculado durante la retropropagación.
6. Repetición: Los pasos 2-5 se repiten con diferentes conjuntos de datos de entrenamiento hasta que la red logra un nivel aceptable de precisión en la tarea que se le ha asignado.

Durante el proceso de entrenamiento, la red neuronal se ajusta para minimizar el error en los datos de entrenamiento. Sin embargo, es posible que la red sobreajuste los datos de entrenamiento, lo que significa que se ajusta demasiado a los datos específicos de entrenamiento y no puede generalizar bien a nuevos datos (*Gerón, 2019; Nielsen, 2019*). Por lo tanto, es importante validar la red con un conjunto de datos separado que no se utilizó durante el entrenamiento para evaluar su capacidad de generalización.

El entrenamiento de una red neuronal puede ser supervisado o no supervisado, según si se proporciona o no la salida esperada durante el proceso de entrenamiento. Además, existen diferentes algoritmos de aprendizaje que se utilizan para ajustar los pesos de las conexiones, como el descenso del gradiente, la retropropagación y el aprendizaje por refuerzo.

#### **4.7.1 Aprendizaje Supervisado**

El aprendizaje supervisado es un tipo de aprendizaje automático en el que se utilizan datos etiquetados para entrenar una red neuronal. En este proceso, se proporciona a la red neuronal un conjunto de datos de entrada junto con su respuesta o salida esperada, y la red aprende a relacionar los datos de entrada con las salidas correctas mediante la optimización de una función de pérdida (*Bishop, 2006; Brownlee, 2017*).

El objetivo del aprendizaje supervisado es encontrar una función que permita hacer predicciones precisas sobre nuevos datos no vistos previamente. Por lo tanto, después de entrenar la red neuronal con un conjunto de datos de entrenamiento, se utiliza un conjunto de datos de prueba para evaluar su capacidad de generalización.

#### **4.7.2 Aprendizaje No Supervisado**

El aprendizaje no supervisado es un tipo de aprendizaje automático en el que se utilizan datos sin etiquetar para encontrar patrones o estructuras ocultas en los datos. A diferencia del aprendizaje supervisado, en el que se proporciona una respuesta correcta a la red neuronal durante el entrenamiento, en el aprendizaje no supervisado no se proporciona una respuesta correcta. En su lugar, la red neuronal debe encontrar patrones y estructuras ocultas en los datos de forma autónoma (*Long et al., 2008; Murphy, 2012*).

El aprendizaje no supervisado se puede utilizar para realizar tareas como la reducción de dimensionalidad, la detección de anomalías, la segmentación de datos y la clasificación de datos no etiquetados.

El algoritmo de aprendizaje utilizado en este estudio corresponde a uno del tipo supervisado y fue desarrollado por Rumelhart et al. (1986) y se denomina Retropropagación del Error (*Backpropagation*) el cual busca disminuir la diferencia entre la predicción y el resultado real, una vez obtenida esta diferencia se genera un análisis que calcula el grado de responsabilidad que tiene cada neurona en el resultado obtenido de modo que se realiza una modificación iterativa de los pesos sinápticos y bias, con el objetivo de minimizar el error entre el valor de salida obtenido por la red y el valor de salida esperado (Figura 4.2). El resultado del entrenamiento es una red capaz de generalizar y entregar resultados para casos nuevos.

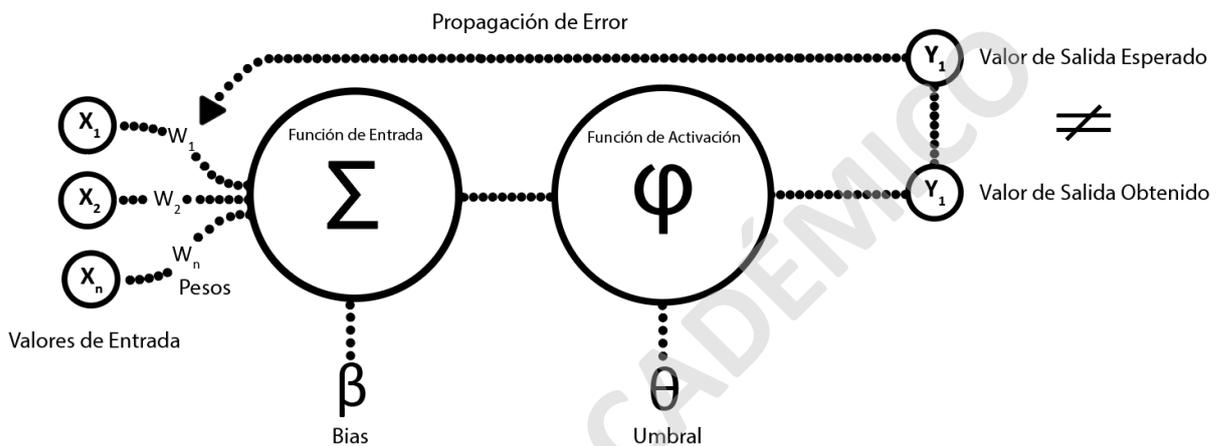


Figura 4.2. Esquema de los componentes y funcionamiento de una neurona artificial con algoritmo de aprendizaje de retropropagación del error (*Backpropagation*).

Para evaluar la desviación entre las predicciones realizadas por la red neuronal y los valores reales de las observaciones durante la etapa de aprendizaje se utiliza la función de pérdida (Loss Function). las utilizadas con mayor frecuencia son las siguientes:

- a) **Absolut Error Loss (L1):** es la diferencia absoluta entre la predicción y el valor real, realizado de manera local para cada observación en el conjunto de datos.

$$L1 = |y_{real} - y_{predicción}| \quad \text{Ecuación 4.2}$$

- b) **Squared Error Loss (L2):** es el cuadrado de la diferencia entre la predicción y el valor real, realizado de manera local para cada observación en el conjunto de datos.

$$L2 = (y_{real} - y_{predicción})^2 \quad \text{Ecuación 4.3}$$

Por su parte cada función de pérdida tiene asociada una función de coste, la diferencia es que esta última no calcula el error de manera local, sino que realiza la evaluación global, es decir, calcula el error para todo el conjunto de datos.

$$\text{Mean Absolut Error: } MAE = \frac{\sum |y_{real} - y_{predicción}|}{N^{\circ} \text{ de observaciones}} \quad \text{Ecuación 4.4}$$

$$\text{Mean Squared Error: } MSE = \frac{\sum (y_{real} - y_{predicción})^2}{N^{\circ} \text{ de observaciones}} \quad \text{Ecuación 4.5}$$

Otras funciones de costes utilizadas frecuentemente para resolver problemas de clasificación son:

**Cross Entropy:** Es una función que compara cada clase predicha con el resultado esperado 1 ó 0 y calcula un puntaje de penalización basado en que tan lejos está el resultado predicho del resultado esperado, se utiliza en la etapa de entrenamiento ya que permite minimizar el error optimizando el modelo.

$$CE = - \sum_{i=1}^N y_i * \log(p_i) \quad \text{Ecuación 4.6}$$

Donde,

N = número de clases

y = clase a predecir

p = probabilidad predicha para la clase

**Binary Cross-Entropy:** es una medida de precisión que se utiliza para problemas de clasificación cuando solo existen dos posibles resultados y se suele usar en conjunto con la función de activación sigmoideal logística ya que trabaja en un rango de 0 a 1.

$$BCE = - \sum_{i=1}^N y_i * \log(p_i) + (1 - y_i) * \log(1 - p_i) \quad \text{Ecuación 4.7}$$

La construcción y entrenamiento de las redes neuronales artificiales se realizó en el entorno de desarrollo integrado (IDE) RStudio (versión 3.5.2), utilizando el paquete de funciones "Neuralnet". El primer paso consistió en definir el directorio de trabajo, que corresponde a la ubicación o carpeta dentro del equipo donde se almacenará toda la información relativa al proyecto. Luego se instalan todos los paquetes de funciones necesarios para los diferentes procesos: neuralnet, NeuralNetTools, raster y rgdal. Para posteriormente importar los datasets (entrenamiento y testeo).

### 4.7.3 Jerarquización de Variables

La jerarquización de variables en una red neuronal se refiere a un proceso mediante el cual se establece la importancia relativa de cada variable de entrada en relación con el resultado de salida. En otras palabras, busca identificar qué factores condicionantes son las más relevantes y tienen un mayor impacto en la ocurrencia de un deslizamiento de suelo. Este proceso es importante porque permite seleccionar y enfocarse en las variables más importantes durante el entrenamiento y la optimización de la red, lo que puede mejorar la precisión y eficiencia del modelo.

Existen diferentes técnicas y algoritmos para llevar a cabo la jerarquización de variables en una red neuronal, una de ellas es el algoritmo de Garson (1991), el cual es una técnica de análisis de sensibilidad utilizada en redes neuronales para medir la contribución de cada valor de entrada según su peso en la red neuronal y así determinar su importancia.

### 4.7.4 Validación y Testeo

La fase de evaluación y testeo de una red neuronal es el proceso final de su entrenamiento, en el que se evalúa su capacidad para generalizar a nuevos datos no vistos previamente. Esta fase es crítica para determinar la precisión y eficacia de la red neuronal en la tarea que se le ha asignado (*Bishop, 2006*).

Uno de los problemas que pueden suceder en la etapa de aprendizaje es el denominado sobreajuste (*overfitting*), este ocurre cuando el número de parámetros o pesos que se utilizan son excesivos en relación al problema, lo que provoca que el modelo se ajuste demasiado a las particularidades irrelevantes presentes en los patrones de entrenamiento, en vez de generar funciones de ajustes que relacionen las entradas y salidas, perdiendo así la habilidad de generalizar su aprendizaje a casos nuevos. Para solucionar el problema del sobreajuste se recomienda utilizar un grupo de datos de validación, diferentes a los de entrenamiento, el cual permite averiguar cuál es el número de pesos óptimos y así evitar el sobreajuste (*Montaño, 2002*).

En la fase de evaluación, se utiliza un conjunto de datos de prueba independiente para evaluar el rendimiento de la red neuronal. La precisión de la red se calcula comparando las salidas predichas por la red con las salidas verdaderas de los datos de prueba (*Brownlee, 2017*).

Esta evaluación se realiza mediante diversas métricas de rendimiento, como la precisión, el error cuadrático medio, la curva ROC, entre otras.

En la fase de testeo, se utilizan nuevos datos no vistos previamente para evaluar la capacidad de la red neuronal de generalizar a nuevos escenarios. El objetivo de esta fase es determinar si la red neuronal puede proporcionar predicciones precisas en el mundo real.

#### **4.8 Generar mapa de susceptibilidad y definición de clases**

Una vez que la red neuronal ha completado el proceso de generación del mapa, se debe guardar el archivo en un formato compatible con un software GIS, en este caso fue utilizado QGIS 3.14. A continuación, el archivo del mapa de susceptibilidad generado por la red neuronal se carga en el software QGIS. A partir de ahí, se utilizan herramientas de clasificación para definir las clases de susceptibilidad. En este caso, se han definido cuatro clases de susceptibilidad, que pueden variar en función del criterio y la necesidad del usuario.

Para decidir la cantidad de clases de susceptibilidad se tuvo en cuenta como precedente la metodología de *Lara* (2007) y el artículo científico de *Lara et al.* (2018) por lo que se optó por dividir los valores de susceptibilidad en 4 clases cuyos rangos van de 0 a 24, 25 a 49, 50 a 74 y 75 a 100.

#### **4.9 Validar el Desempeño de la Red Neuronal y el Mapa de Susceptibilidad**

Para validar el desempeño de una red neuronal artificial, se pueden utilizar diferentes técnicas y herramientas, algunas de las más comunes son:

##### **4.9.1 Matriz de Confusión**

Una matriz de confusión es una herramienta utilizada para evaluar el rendimiento de un modelo de clasificación en términos de la precisión y la capacidad de distinguir entre clases, se representa como una tabla que muestra el número de predicciones correctas e incorrectas para cada clase (Fawcett, 200), y se divide en cuatro cuadrantes: verdaderos positivos (VP), falsos positivos (FP), verdaderos negativos (VN) y falsos negativos (FN). Los VP son los casos en que el modelo predijo correctamente una muestra positiva, los VN son los casos en que el modelo predijo correctamente una muestra negativa, los FP son los casos en que el modelo predijo incorrectamente una muestra positiva y los FN son los casos en que el modelo predijo

incorrectamente una muestra negativa. A partir de esta matriz se pueden calcular diferentes métricas de evaluación, como la precisión, la sensibilidad, la especificidad y la exactitud.

Predicción	Verdaderos Positivos	<i>Falsos Positivos</i>
	<i>Falsos Negativos</i>	Verdaderos Negativos
	Real	

Figura 4.3. Esquema de los valores correspondientes de una matriz de confusión.

**Exactitud:** La exactitud mide la proporción de predicciones correctas del modelo en relación al total de predicciones. Se calcula como la suma de las predicciones correctas (verdaderos positivos + verdaderos negativos) dividido por el número total de predicciones.

**Precisión:** La precisión mide la proporción de predicciones positivas correctas del modelo en relación a todas las predicciones positivas. Se calcula como la división de verdaderos positivos entre la suma de verdaderos positivos y falsos positivos.

**Sensibilidad:** La sensibilidad mide la proporción de predicciones positivas correctas del modelo en relación al total de instancias que realmente pertenecen a la clase positiva. Se calcula como la división de verdaderos positivos entre la suma de verdaderos positivos y falsos negativos.

**Especificidad:** La especificidad mide la proporción de predicciones negativas correctas del modelo en relación al total de instancias que realmente pertenecen a la clase negativa. Se calcula como la división de verdaderos negativos entre la suma de verdaderos negativos y falsos positivos.

## 4.9.2 Curva ROC/AUC

La curva de característica operativa del receptor (ROC, por sus siglas en inglés), es una representación gráfica de la tasa de verdaderos positivos (sensibilidad) frente a la tasa de falsos positivos (1-especificidad) para diferentes valores de umbral de decisión (Fawcett, 2006). proporcionan una forma visual y cuantitativa de evaluar y comparar modelos de clasificación binaria.

Se utiliza para evaluar la capacidad de un modelo de clasificación para distinguir entre dos clases y se representa trazando una línea desde el punto (0,0) hasta el punto (1,1), y se evalúa mediante el cálculo del área bajo la curva (AUC, por sus siglas en inglés), que proporciona una medida del rendimiento global del modelo.

Un modelo de clasificación perfecto tendría una curva ROC que se acercaría al rincón superior izquierdo del gráfico. lo que indicaría una sensibilidad y una especificidad altas. La diagonal del gráfico corresponde a un modelo de clasificación aleatorio. En la Figura 4.4 se representan los siguientes casos:

Si el AUC es 0, significa que el modelo no es mejor que una predicción aleatoria, por lo que el modelo es incapaz de distinguir entre las dos clases de manera efectiva. Luego, si el AUC es 0.5, significa que su rendimiento es igual al de una predicción aleatoria. Mientras que si el AUC es 0.7, el modelo es capaz de distinguir entre las dos clases, pero aún hay margen de mejora en términos de precisión, y por último cuando el AUC es 1, esto indica que el modelo es capaz de clasificar perfectamente las dos clases y no comete errores de clasificación (Wheaton et al., 1987; Raschka, 2015).

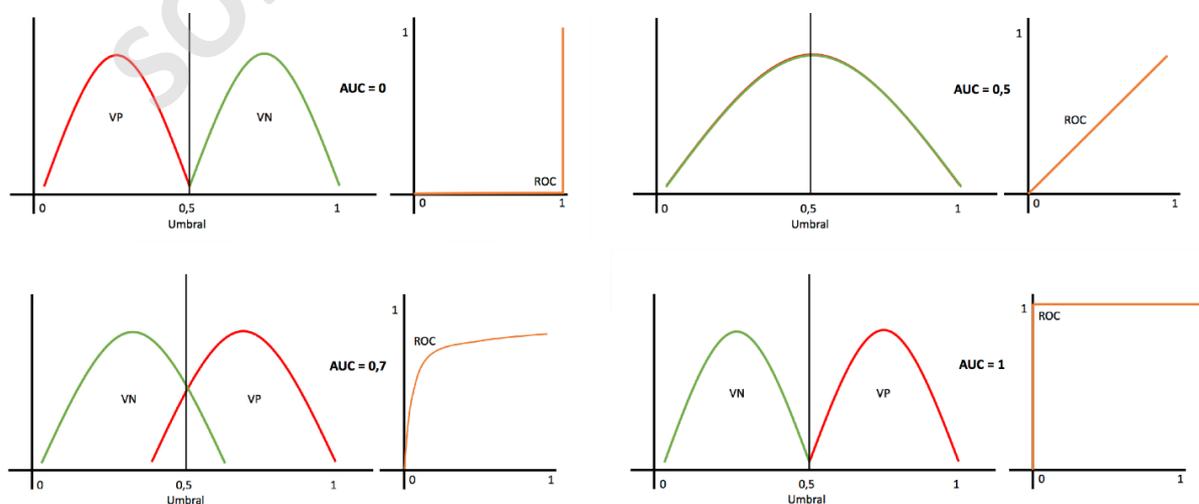


Figura 4.4. Comportamientos típicos de la curva ROC/AUC en diferentes escenarios. Elaborado por González, 2019.

### **4.9.3 Validación Visual de Mapas**

Si bien los métodos anteriores evalúan el rendimiento del algoritmo, es necesario verificar que el resultado final sea coherente, ya que numéricamente el modelo puede estar funcionando, pero el mapa obtenido debe conversar con la realidad del área de estudio. Una forma de evaluar esto es mediante la comparación visual del mapa resultante del procesamiento de la red neuronal con el catastro que se utilizó para entrenarla, también se puede llevar a cabo una comparación visual con otros mapas de susceptibilidad generados por otros expertos en el área de estudio, permitiendo identificar posibles áreas de discrepancia entre los distintos mapas

### **4.10 Análisis de zonas de susceptibilidad**

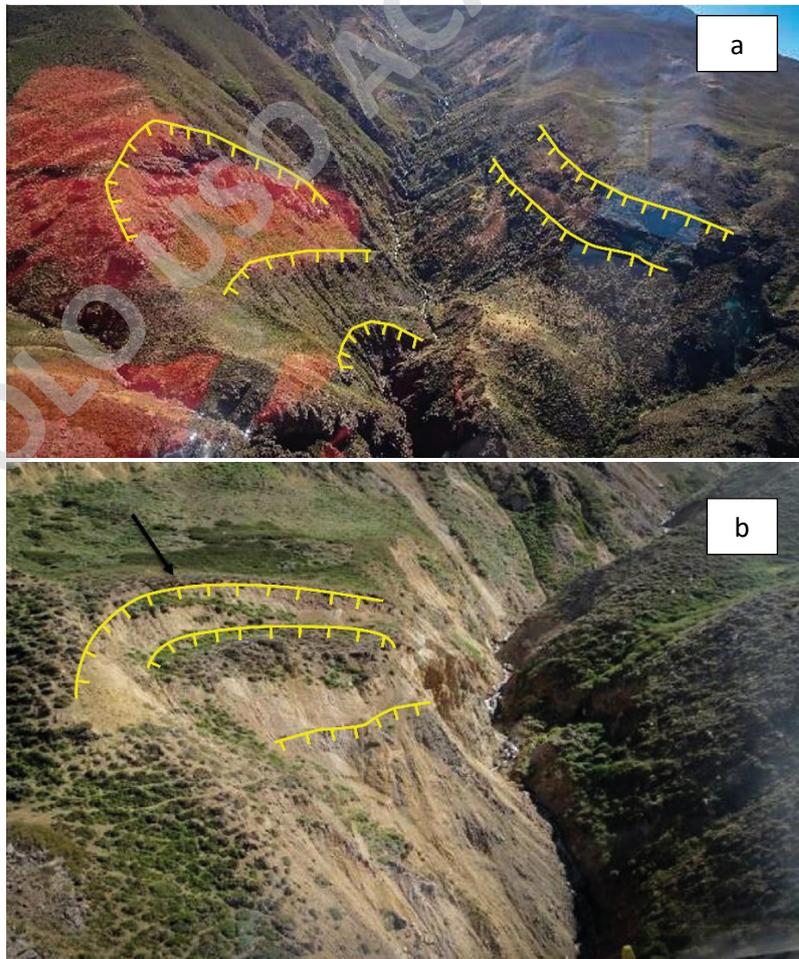
La etapa final de la metodología consiste en realizar una revisión del mapa de susceptibilidad y analizar de manera conjunta los factores condicionantes seleccionados. Se debe examinar el comportamiento de cada factor en relación a las diferentes clases de susceptibilidad definidas y discutir su validez en función de los resultados obtenidos. Además, se procede a dividir el mapa en cuadrantes con el objetivo de examinar y discutir la congruencia del resultado en cada una de estas secciones.

## CAPÍTULO 5 : RESULTADOS

### 5.1 Catastro y Mapeo de Zonas de Ocurrencia

El catastro binario (Figura 5.2), consiste en la clasificación de dos tipos de puntos: las zonas de ocurrencia de deslizamientos de suelo (ZO) con valor 1 y las no ocurrencia (No ZO) con valor 0.

Para definir las zonas de ocurrencia, se realizó el mapeo de polígonos de las áreas de influencia como, por ejemplo, zonas de escarpes y sectores con evidencias de antiguos deslizamientos (Figura 5.1), y posteriormente con esto como base se realizó el mapeo de puntos aleatorios. A pesar de que el mapeo de píxeles es más preciso y permite extraer mayores cantidades de información, este también resulta en tiempos de análisis más largos y funciona mejor para redes neuronales convolucionales las cuales realizan el aprendizaje a partir de imágenes, por lo que se optó por el mapeo de puntos ya que facilita la obtención de una base de datos para el entrenamiento de la Red Neuronal Artificial (RNA) y resulta en tiempos de análisis más cortos.



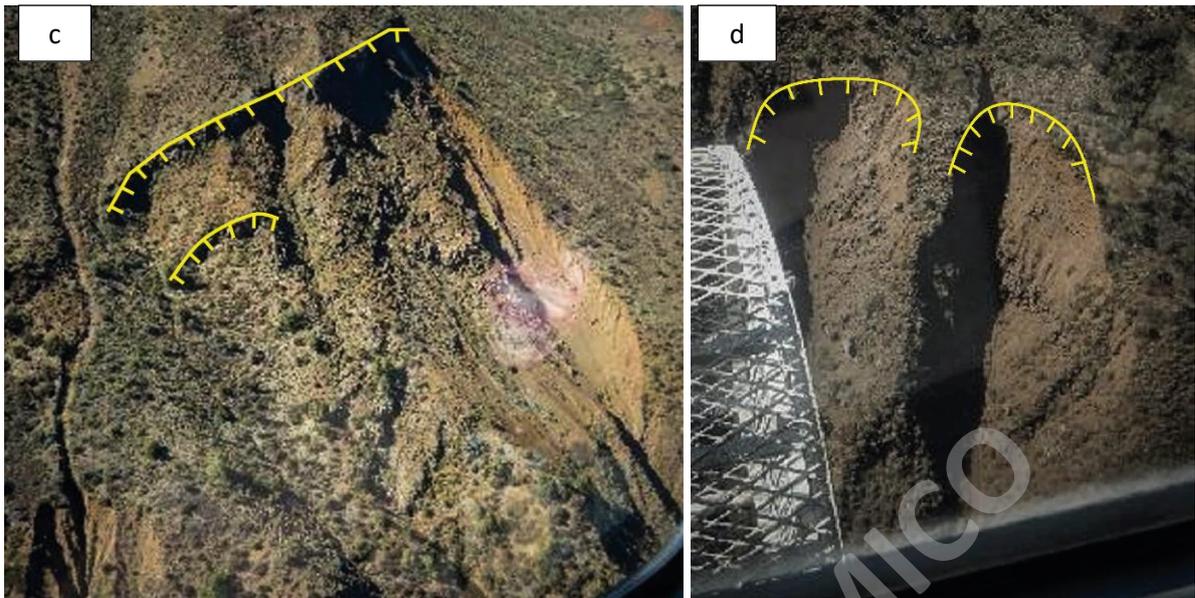


Figura 5.1. a, c y d) Escarpes de remociones en masa en quebrada San Alfonso. b) deslizamientos en primer plano y secuencia de escarpes hacia el fondo del estero San Alfonso, sobre los 3000 m.s.n.m. imágenes modificadas del informe del SERNAGEOMIN, “sobrevuelo en las cuencas altas del río Maipo y Mapocho” (Fariás & Marín, 2019).

Además, siguiendo las recomendaciones de *Althuwaynee et al.* (2014), se utilizó un muestreo aleatorio de puntos en lugar del método de muestreo de puntos a partir de los centroides de polígonos, ya que permite un mayor control sobre la posición y cantidad de puntos a evaluar, favoreciendo así la representatividad de los datos y optimizando así el tiempo de procesamiento de la RNA.

Una vez que se obtuvo el catastro de zonas de ocurrencia (1) se utiliza el modelo creado por *Althuwaynee et al.* (2014) para el software QGis 3.14, donde se ingresaron los parámetros que definirían las condiciones bajo las cuales un punto sería considerado una zona libre de deslizamientos, que puede definirse como un área en la que las condiciones geológicas, topográficas y climáticas son tales que la probabilidad de que ocurran deslizamientos es relativamente baja o nula. En general, las características que hacen que una zona sea poco propensa a deslizamientos de suelo incluyen:

- Suelos estables y resistentes, como rocas duras, suelos arcillosos compactos y gravas bien consolidadas.
- Una topografía relativamente plana o con una pendiente suave que no favorece la acumulación de agua y sedimentos en las laderas.
- Una cubierta vegetal densa y saludable que ayuda a retener la humedad del suelo y reduce la erosión.

- Un clima moderado y estable, sin precipitaciones intensas o eventos climáticos extremos que puedan desestabilizar el suelo.

El primer parámetro a ingresar es la pendiente de seguridad. En general, los terrenos con pendientes superiores a 15 grados se consideran propensos a deslizamientos de suelo, aunque esta cifra puede variar según las condiciones locales. Además, en áreas con suelos más inestables o en épocas de lluvias intensas, los deslizamientos de tierra pueden ocurrir en pendientes más suaves, por lo anterior se determinó que las pendientes donde la probabilidad de ocurrencia de un deslizamiento es casi nula correspondería a pendientes menores o iguales a 5°. Tomando como referencia los trabajos de *Hauser (1993)*, *Sauret (1987)* en *Sepúlveda (1998)*, *Lara (2007)* y *Muñoz (2013)*.

El segundo parámetro es la distancia de seguridad, es decir, la distancia mínima a la que se puede encontrar un punto de zona de ocurrencia (1) a uno libre de deslizamientos (0), para el cual se determinó una distancia de 500 metros según se recomienda en *Sameen et al. (2019)* para evitar el sobremuestreo.

Finalmente, sobre la cantidad de datos obtenidos en el muestreo, se generaron un total de 1469 puntos de los cuales 738 corresponden al inventario de zonas de ocurrencia (1) y 731 del inventario de no ocurrencia (0). No existe un consenso sobre cuantos puntos utilizar, pero se debe tener en cuenta que una cantidad muy baja de datos entregará muy poca información dificultando el aprendizaje de la RNA y una cantidad muy alta de datos puede provocar el sobreajuste (*overfitting*) al hacer que aprenda muy en detalle perdiendo así la RNA su capacidad de generalización y predicción para nuevos datos. *Dieu Tiene et al. (2015)* recomiendan utilizar una cantidad no menor a 100 datos para obtener resultados óptimos.

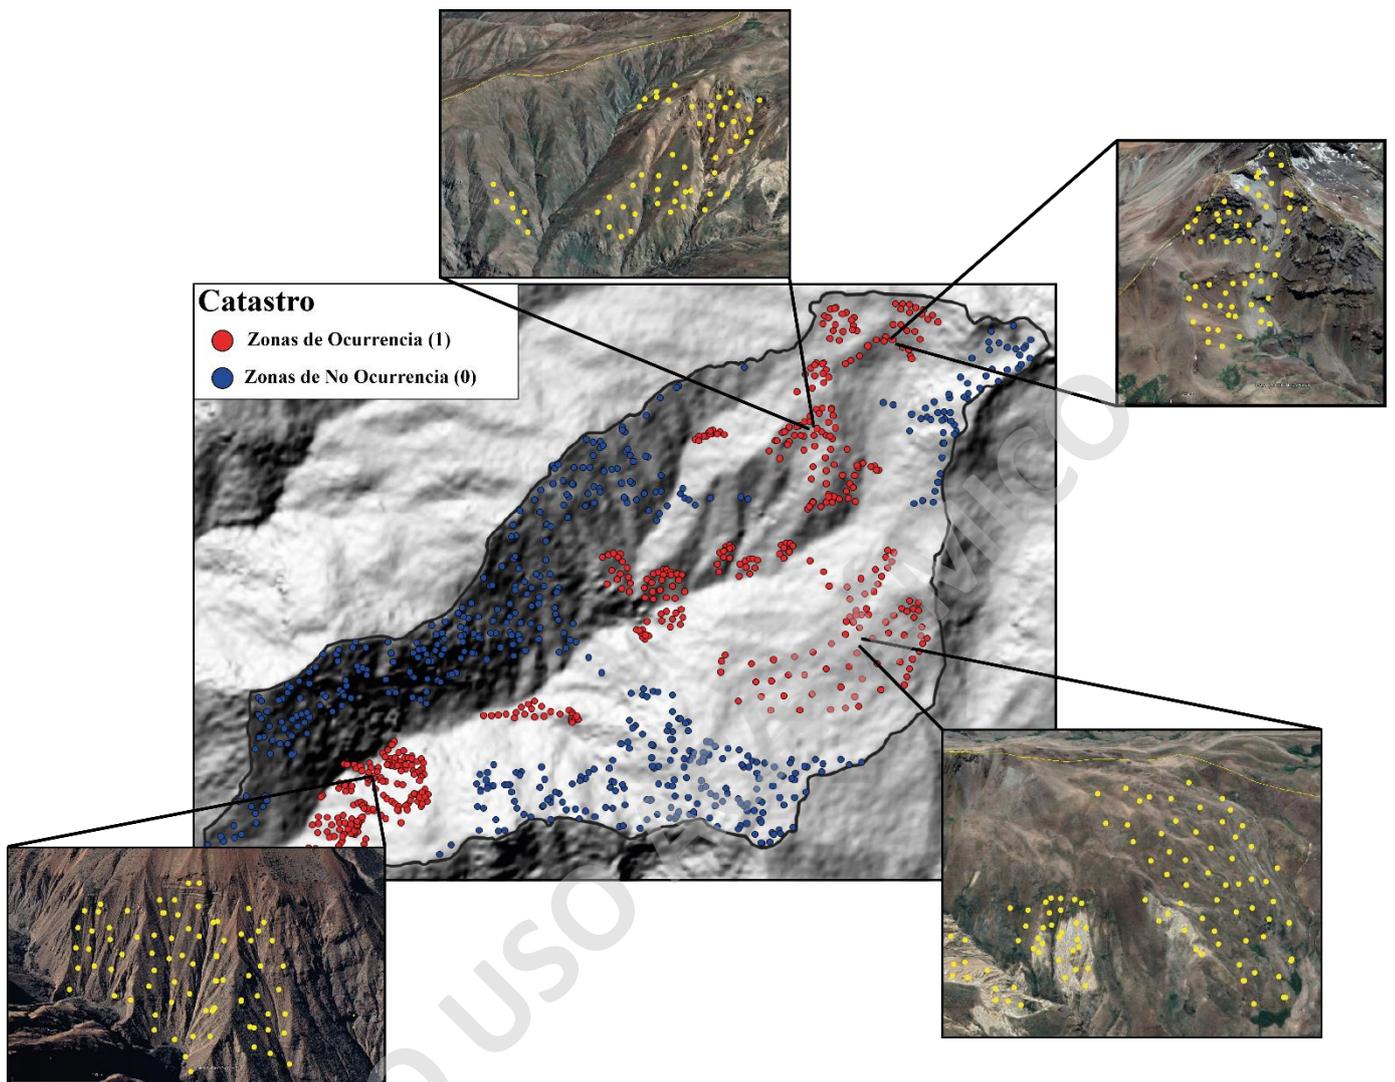


Figura 5.2. Mapa de puntos correspondiente al catastro binario, identificando zonas de ocurrencia de deslizamientos (1) y no ocurrencia (0).

## 5.2 Preselección de Factores Condicionantes

Si bien la selección final de los factores condicionantes está sujeta a los resultados que entregue la RNA, *Sandoval (2021)* menciona dos criterios que deben cumplir las variables preseleccionadas:

- a) Tener implicancia geológica en el proceso específico que será evaluado.
- b) Disponibilidad de la información geoespacial para la zona de estudio. Es decir, que el rasgo del terreno efectivamente exista y esté cuantificado o descrito para el área de estudio donde se pretende aplicar la metodología (estudios previos, datos satelitales, entre otros), y que dicha información pueda ser representada geoespacialmente

Sobre la base de lo anteriormente señalado, fue posible determinar 11 factores (Tabla 5.1) para el análisis de ocurrencia de deslizamientos de suelo.

Tabla 5.1. Factores preseleccionados para el análisis de zonas de ocurrencia de deslizamientos.

Factor	Código	Tipo de Variable
Geología	GEO	Catagórica
Geomorfología	GEOM	Catagórica
Uso de Suelo	UDS	Catagórica
Antecedentes	ANT	Catagórica
Pendiente	SLP	Continua
Aspecto	ASP	Continua
Curvatura	CV	Continua
Índice de Humedad Topográfico	TWI	Continua
Distancia Red de Drenaje	DRD	Continua
Índice de Rugosidad del Terreno	TRI	Continua
Factor LS	SLF	Continua

#### a) Geología

Se trata del mapeo y caracterización geológica (litológica y estructural) de la zona de estudio. Al igual que la pendiente, este es uno de los factores más relevantes que determinan el estado de la superficie para que se produzca en ella una remoción en masa, ya que la resistencia y la permeabilidad de las rocas y los suelos están directamente influenciadas por las características litológicas (Kavzoglu et al. 2014 en Kalantar et al. 2017).

#### b) Geomorfología

La geomorfología es una rama de la geología que se enfoca en el estudio de las formas del relieve terrestre y los procesos geológicos que las han creado y modificado a lo largo del tiempo. Es uno de los factores principales cuando se trata de eventos de remociones. Factores como topografía, pendiente, variaciones fuertes de pendiente de laderas, y extensión y altura de laderas condicionan las remociones en masa (Lara, 2007).

### **c) Uso de Suelo**

El uso del suelo se refiere a la forma en que se utiliza la superficie terrestre, es decir, la manera en que las personas ocupan y aprovechan el suelo y los recursos naturales que se encuentran en él. El uso del suelo puede incluir actividades como la agricultura, la ganadería, la silvicultura, la minería, la construcción de viviendas, edificios y carreteras, y otras actividades humanas. Se utilizó el Catastro de Uso de Suelo y Vegetación de la Región Metropolitana de CONAF (2013), en formato shape a escala 1:50.000. este factor fue considerado, ya que, en términos generales, la vegetación se reconoce como un factor estabilizante de laderas (*Lara, 2007; Soto, 2011; Muñoz, 2013*), y los cambios en el uso del suelo, como la deforestación, pueden alterar la estructura del suelo y aumentar la susceptibilidad a las remociones en masa. Además de que implícitamente entrega información sobre el efecto de la actividad antrópica en el área de estudio.

Los tipos de uso de suelo definidos para la zona de estudios son los siguientes: Bosque nativo semidenso, bosque nativo renoval denso, cajas de río, glaciares, matorral muy abierto, matorral semidenso, matorral arborescente denso, matorral arborescente semidenso, matorral arborescente muy abierto, vegas, nieves, zona urbana, terrenos sin vegetación, terreno agrícola y estepa andina central.

### **d) Antecedentes**

Para cada tipo de fenómeno analizado, se consideran la existencia de remociones en masa anteriores como un antecedente geomorfológico y de análisis retrospectivo importante. Los depósitos de remociones en masa, por lo general son sensibles a movilizarse nuevamente ya que en algunos casos son depositados con geometrías irregulares, o bien para definir alcance que pueden tener a partir de datos anteriores (*Muñoz, 2013*).

### **e) Pendiente**

Corresponde al ángulo de inclinación de la superficie, medido de 0° a 90°, con respecto al plano horizontal. Se considera una de las principales características que condicionan el terreno para la ocurrencia de remociones en masa (*Hauser, 1993; Ayalew, 2005; Lara, 2007; Kalantar et al. 2017*).

Las altas pendientes son el primer factor geomorfológico a considerar, propiciando principalmente la generación de deslizamientos, flujos y derrumbes (Lara, 2007). En general, cuanto mayor sea la pendiente, mayor será el riesgo de deslizamientos de tierra. Esto se debe a que la pendiente influye en la estabilidad del terreno y en la capacidad del suelo para retener el agua, cuando la pendiente es muy empinada, el agua que cae sobre el terreno no tiene tiempo suficiente para infiltrarse en el suelo, lo que aumenta el riesgo de erosión y deslizamientos.

#### **f) Índice de Humedad Topográfico**

El índice de humedad topográfico (TWI, por sus siglas en inglés) fue desarrollado por *Beven y Kirkby* (1979) como una medida teórica que se utiliza para estimar la humedad del suelo en diferentes puntos de una cuenca hidrográfica, a partir de la pendiente y la acumulación de agua en el terreno (*Borgeau-Chavez et al.* 2007). Se trata de un indicador útil para predecir el riesgo de remociones en masa, ya que el agua es uno de los principales factores que influyen en la estabilidad del suelo.

El TWI se basa en la relación entre la pendiente topográfica y la acumulación de agua en el terreno. La acumulación de agua en un punto determinado de la cuenca hidrográfica depende de la cantidad de agua que llega a ese punto y de la capacidad del suelo para retener el agua. La pendiente, por su parte, influye en la velocidad con la que el agua se mueve por el terreno (*Nandi & Singh, 2007; Römken et al., 1997*).

Para calcular el TWI, se utiliza la siguiente fórmula:

$$TWI = \ln (\alpha / \tan \beta) \quad \text{Ecuación 5.1}$$

Donde  $\alpha$  es la acumulación de agua en el terreno, medida en términos de área de contribución de la cuenca hidrográfica, y  $\beta$  es la pendiente topográfica, medida en grados.

Un valor alto del TWI indica que el suelo está más húmedo, lo que aumenta el riesgo de deslizamientos de tierra. Por lo tanto, el TWI puede ser una herramienta útil para identificar las áreas de la cuenca hidrográfica que tienen mayor riesgo de sufrir remociones en masa y tomar medidas preventivas y de mitigación adecuadas.

#### **g) Aspecto**

El aspecto es la orientación o dirección de la pendiente que se mide en el sentido de las agujas del reloj en grados de 0° a 360°, donde 0° está orientado al norte, 90° está orientado al

este,  $180^\circ$  está orientado al sur y  $270^\circ$  está orientado al oeste. Los parámetros asociados al aspecto, como la exposición a la luz solar, los vientos desecantes, las precipitaciones (grado de saturación) y las discontinuidades, son factores importantes en el desencadenamiento de deslizamientos de suelo (Dai et al. 2001).

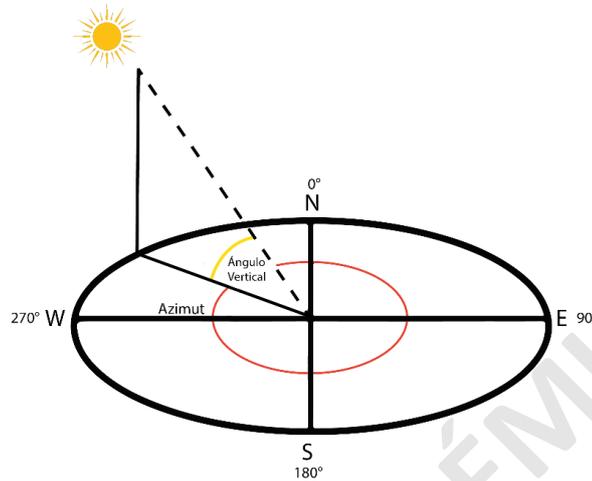


Figura 5.3. Esquema de los valores angulares de un mapa de aspecto.

## h) Curvatura Planar

La curvatura planar se calcula de manera perpendicular a la dirección de la pendiente máxima, indica el grado de concavidad/convexidad del terreno y se relaciona principalmente con la convergencia y divergencia de la corriente por una superficie. Este factor ayuda a entender los procesos de erosión y escorrentía (Kalantar et al. 2017). Las zonas convexas (valores negativos) son más susceptibles a generar deslizamientos, que las zonas planas (0) y cóncavas (valores positivos), las cuales tenderían a ser más estables.

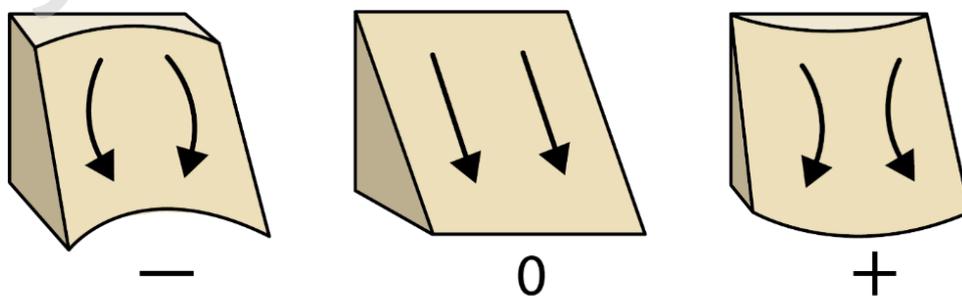


Figura 5.4. Esquema del cálculo de curvatura planar.

### **i) Distancia Red de Drenaje**

Las remociones en masa se asocian con la proximidad a redes de drenaje porque el terreno superficial puede ser modificado por la erosión que producen los ríos y cursos de agua, y también puede producir un socavamiento en los pies de las laderas (Dai y Lee, 2002). Por otra parte, las redes de drenaje pueden elevar el nivel freático de áreas circundantes, pudiendo disminuir la estabilidad de las laderas. Por lo tanto, se reconoce que existen menos remociones en masa a medida que aumenta la proximidad a redes de drenaje (Dragičević et al., 2015).

### **j) Índice de Rugosidad Topográfico**

El índice de rugosidad topográfico (TRI, por sus siglas en inglés) es una medida que se utiliza para cuantificar las variaciones en la elevación del terreno en una cuenca hidrográfica (Matthews, 1989). Se calcula a partir de la relación entre la pendiente y la altura del terreno, y se utiliza para evaluar el impacto de la rugosidad topográfica en los procesos hidrológicos y geomorfológicos (Riley et al., 1999; Różycka et al., 2017).

El índice de rugosidad topográfico se calcula utilizando la siguiente fórmula:

$$TRI = (Z_{max} - Z_{min}) / (Tan \theta) \quad \text{Ecuación 5.2}$$

Donde:

$Z_{max}$  es la elevación máxima.

$Z_{min}$  es la elevación mínima.

$Tan \theta$  es la pendiente media.

El TRI se puede interpretar como la relación entre la altura del terreno y la pendiente. Un valor alto de TRI indica que el terreno es rugoso y presenta grandes variaciones en la elevación, mientras que un valor bajo de TRI indica que el terreno es suave y presenta pocas variaciones en la elevación. Es una herramienta útil para evaluar el impacto en los procesos hidrológicos y geomorfológicos, ya que la rugosidad topográfica puede afectar la velocidad y dirección del flujo de agua, la erosión del suelo, la acumulación de sedimentos, entre otros procesos.

## k) Factor LS

El Factor LS en la Ecuación Universal de Pérdida de Suelo (USLE, por sus siglas en inglés) es una variable que describe la longitud y la pendiente de las laderas de un terreno. Esta variable se utiliza para estimar la erosión del suelo por escorrentía superficial en una cuenca hidrográfica, y se calcula a partir de la longitud y la pendiente de las laderas (*Lighthfoot & Rowan, 2000; Morgan, 2005*).

La fórmula para calcular el Factor LS es la siguiente:

$$LS = \left(\frac{m}{22.1}\right)^{1.14} * \left(\sin \frac{A}{0.0896}\right)^{1.33} \quad \text{Ecuación 5.3}$$

Donde:

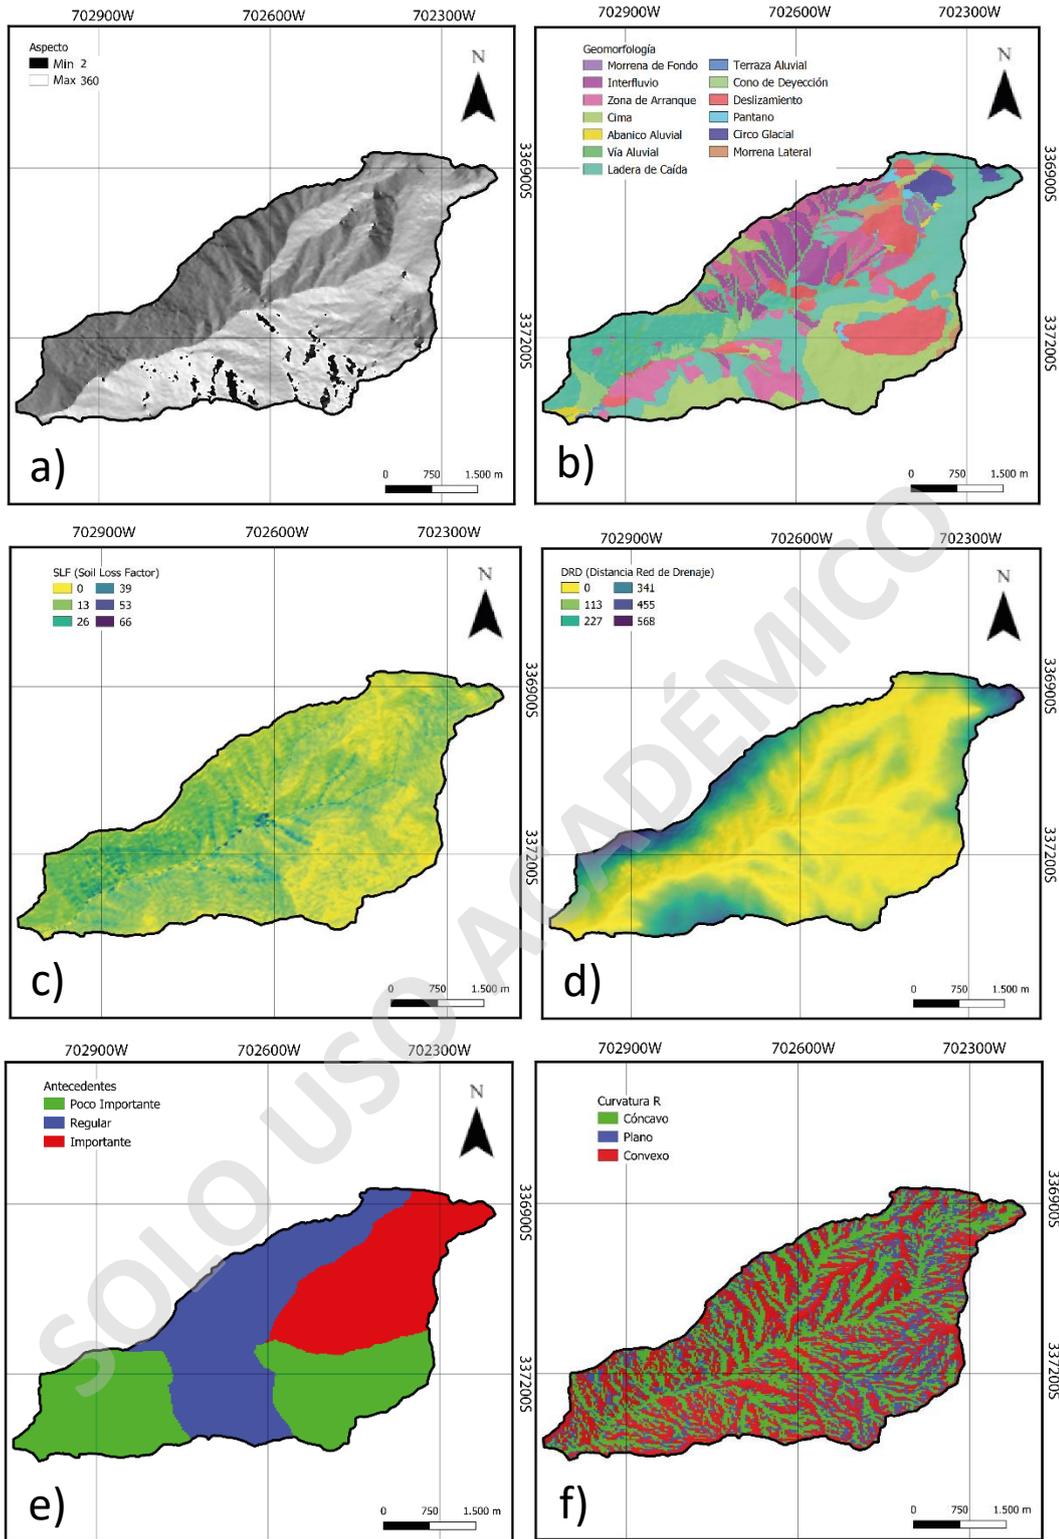
m es la longitud de la pendiente en metros.

A es el ángulo de la pendiente en grados.

El Factor LS se utiliza en la USLE para calcular la pérdida de suelo por escorrentía superficial, junto con otros factores como la capacidad erosiva de la lluvia, la cobertura vegetal, el tipo de suelo y la práctica de manejo del suelo. Cuanto mayor es el valor de LS, mayor es la erosión del suelo por escorrentía superficial.

## 5.3 Mapas Temáticos

Se generan en formato Shape utilizando el software QGIS 3.14. Los mapas se obtienen principalmente a partir de los modelos de elevación digital (DEM) del área de estudio y catastros como, por ejemplo, el de uso de suelo de la región Metropolitana elaborado por *Conaf (2013)*. Estos mapas luego deben ser reclasificados, en el caso de las variables categóricas se les debe asignar un valor numérico arbitrario y correlativo a cada uno de sus parámetros, para así poder trabajar los datos en etapas posteriores. Finalmente, los mapas deben ser rasterizados, con el fin de generar una cuadrícula de píxeles los cuales incluirán toda la información asociada al mapa. Esta información se incorpora a la tabla de atributos del catastro binario, utilizando el modelo de *Althuwaynee et al., (2017)* de modo que cada punto incluya en la tabla de atributos la información asociada a cada uno de los factores condicionantes y así generar la base de datos con que trabajara la RNA.



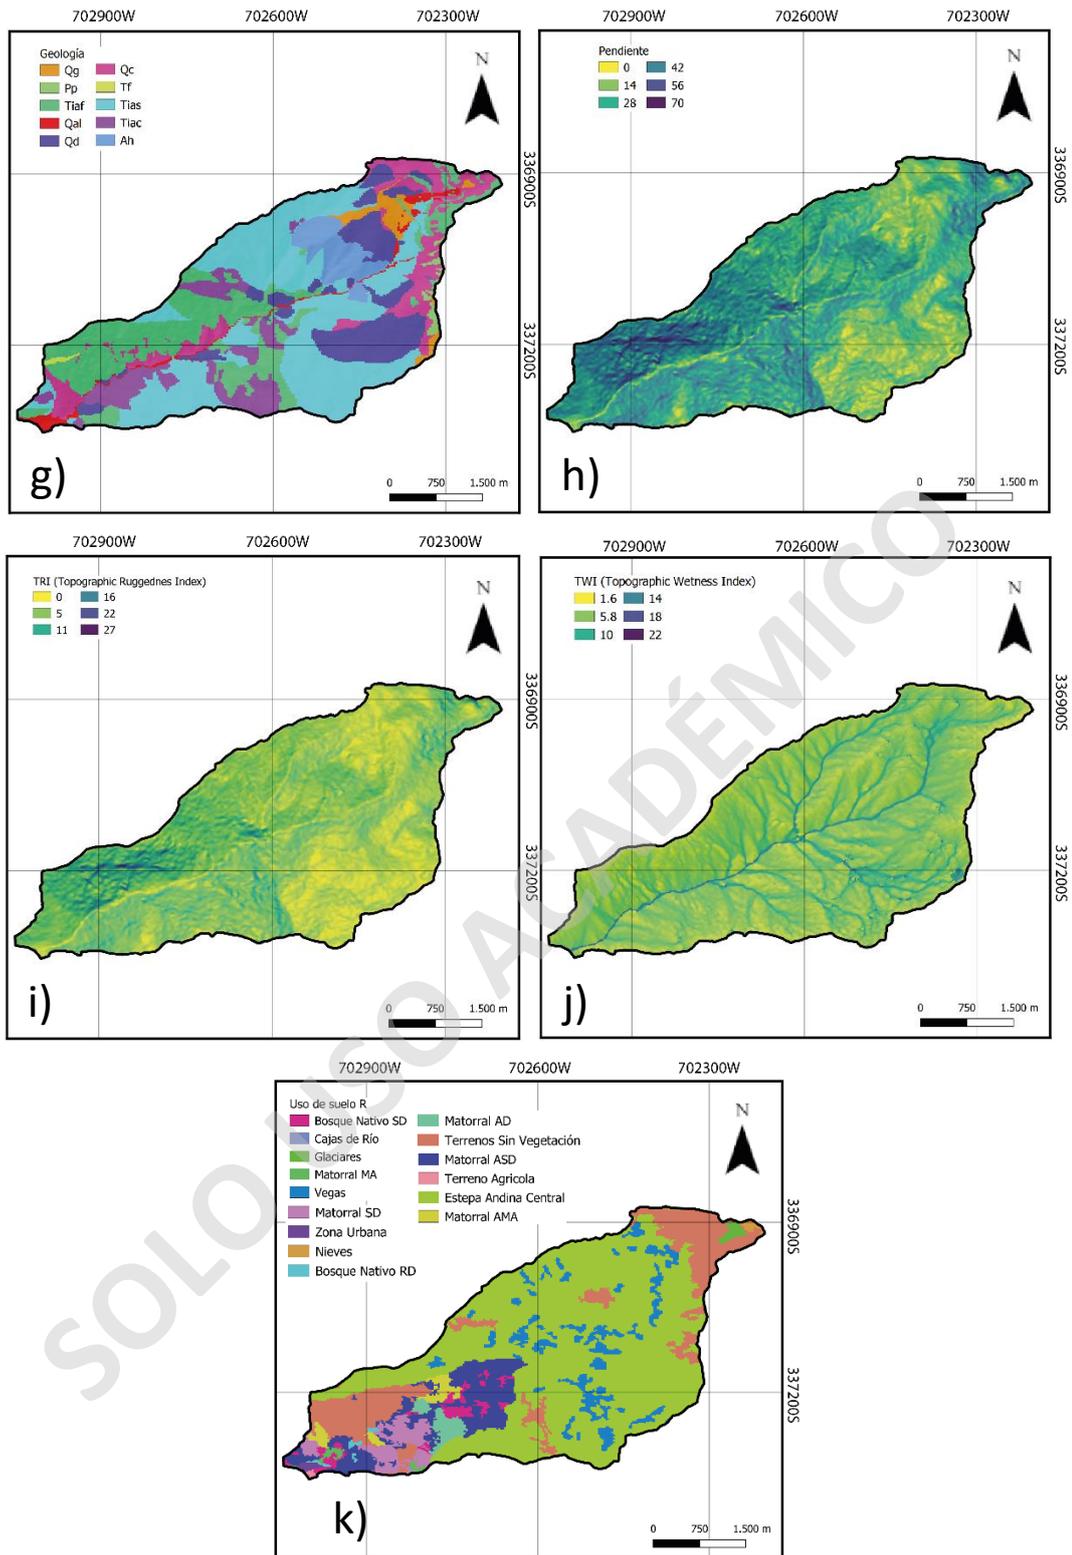


Figura 5.5. Mapas temáticos de factores condicionantes para el análisis de zonas de ocurrencia de deslizamientos de suelo. a) aspecto, b) geomorfología, c) Factor LS, d) distancia red de drenaje, e) antecedentes, f) curvatura, g) geología, h) pendiente, i) índice de rugosidad de terreno, j) índice de humedad topográfico, k) uso de suelo.

## 5.4 Análisis Exploratorio de Datos

### 5.4.1 Estadística Descriptiva

En la Tabla 5.2, se presenta el resumen de las estadísticas básicas (promedio, desviación estándar, mínimos, máximos y cuartiles) para cada uno de los factores condicionantes numéricos. Se separó entre los valores para zonas de ocurrencia de deslizamientos de suelo (ZO) y no ocurrencia (No ZO), con la finalidad de encontrar diferencias entre los valores de las variables para cada caso.

Tabla 5.2. Estadísticas básicas calculadas para factores condicionantes numéricos de zonas de ocurrencia de deslizamientos y no ocurrencia.

<b>ZO (1)</b>	<b>ASP</b>	<b>CV</b>	<b>DRD</b>	<b>SLF</b>	<b>SLP</b>	<b>TRI</b>	<b>TWI</b>
<b>Promedio</b>	230.2	-0.0015	70.7	12.4	32.5	5.8	5.8
<b>D.std</b>	78.9	0.0085	90.4	4.8	7.6	1.8	1.6
<b>Min</b>	2.6	-0.0345	0	2.1	5.1	0.9	3
<b>Q1</b>	167.9	-0.0068	5.1	9.5	27.8	4.7	4.7
<b>Mediana</b>	231.3	-0.0018	28.9	11.9	32.6	5.7	5.6
<b>Q3</b>	301.6	0.0036	109.3	14.9	37.6	6.9	6.5
<b>Max</b>	360	0.0263	423	44.2	57	13.6	15

<b>No ZO (0)</b>	<b>ASP</b>	<b>CV</b>	<b>DRD</b>	<b>SLF</b>	<b>SLP</b>	<b>TRI</b>	<b>TWI</b>
<b>Promedio</b>	239.9	0.0004	65.7	5.6	18.2	3.1	6.2
<b>D.std</b>	81.3	0.0057	123.2	4.1	10.8	2.1	2
<b>min</b>	4.8	-0.0267	0	0	1.8	0.5	2.7
<b>Q1</b>	191.3	-0.0029	2.4	2.7	10.5	1.7	4.8
<b>Mediana</b>	251.6	0.0003	15.9	4.8	16.3	2.6	5.7
<b>Q3</b>	301.7	0.0037	49.2	7.7	23.2	3.8	7.2
<b>Max</b>	360	0.0234	567.3	26.1	55.8	12.8	18

### 5.4.2 Distribución

Se elaboraron histogramas de frecuencias (Figura 5.6) con el fin de representar de manera gráfica el comportamiento de los factores condicionantes de zonas de ocurrencia (1) y no ocurrencia (0), utilizando la herramienta “Matplotlib” de Python. Las conclusiones a las que se

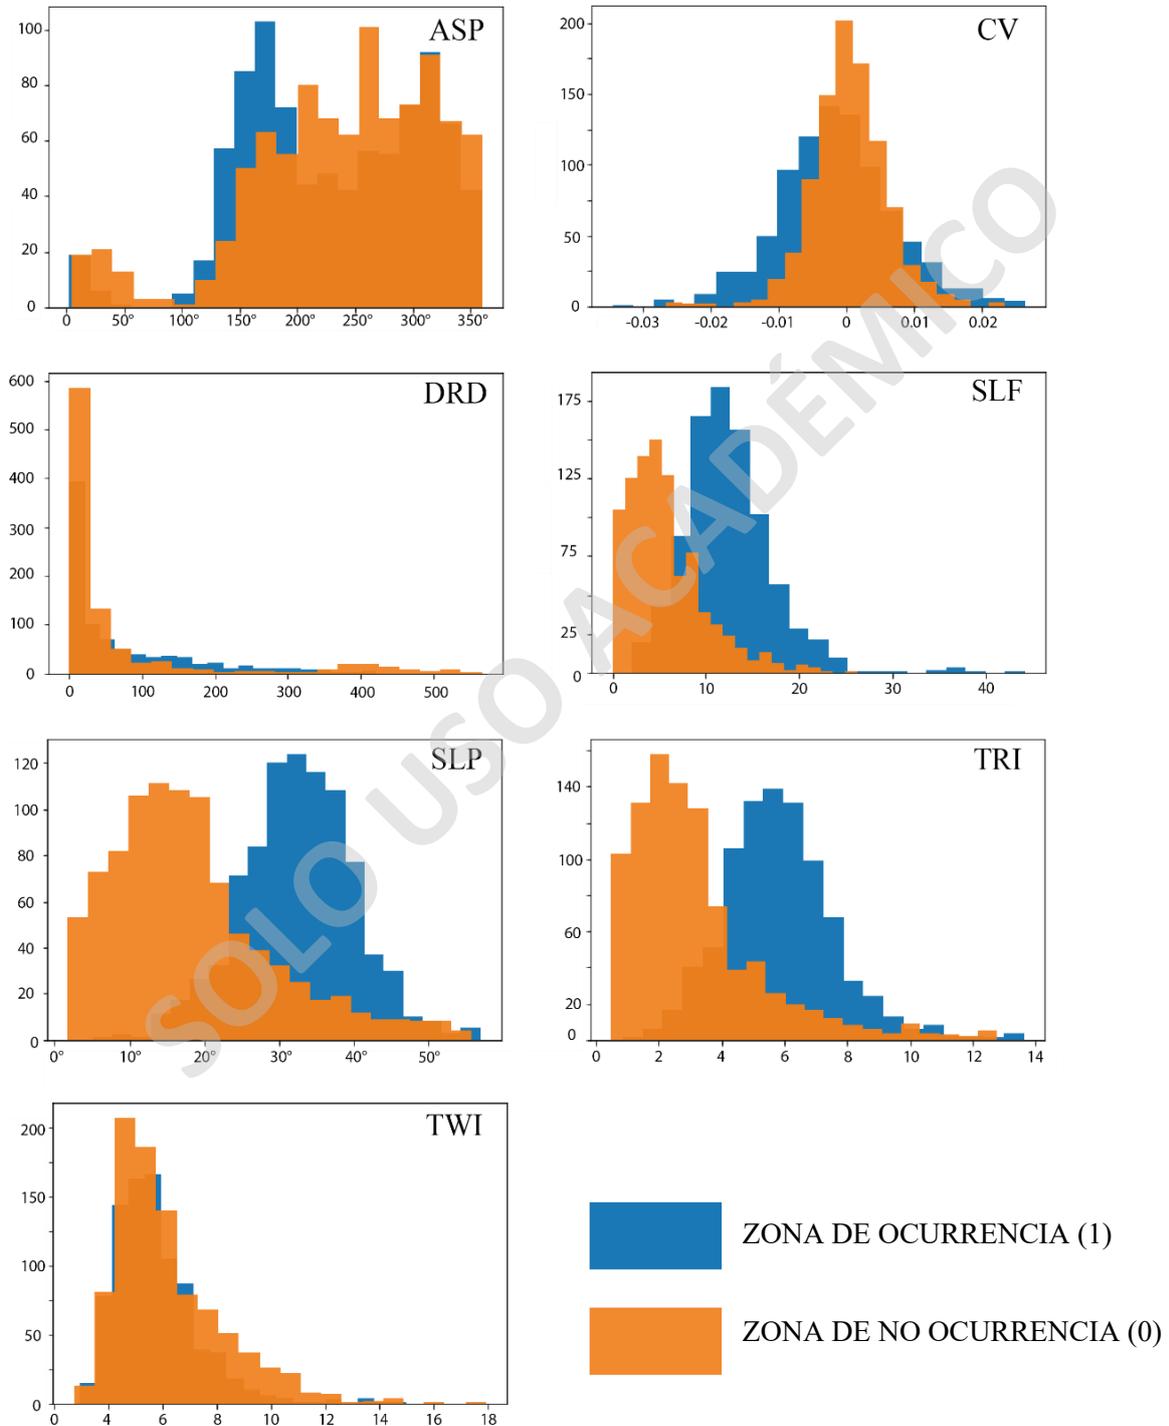


Figura 5.6. Histogramas comparativos de distribución de valores y frecuencias, de los factores condicionantes para zonas de ocurrencia y no ocurrencia.

DRD y TWI, no presentan variaciones significativas entre el dataset de zonas de ocurrencia de deslizamientos y el de no ocurrencia, por lo que se advierte que la relación de estos parámetros puede que sea sutil con respecto al objetivo del análisis, aunque para corroborar este supuesto, sería necesario también identificar como interactúan con los otros factores. También fue posible observar que sus datos se distribuyen hacia la izquierda (sesgo positivo), lo que indica que la mayoría de sus valores se encuentran bajo la media

SLP, TRI y SLF se observa una diferencia entre las distribuciones de valores para el dataset de zonas de ocurrencia y el de no ocurrencia, de los gráfico es posible deducir que las zonas de no ocurrencia tienen asociados valores bajos, mientras que el aumento en los valores de estos parámetros pareciera tener una relación directa con la producción de zonas de ocurrencia, esto se puede deber principalmente a que estos factores se encuentran ligados a la estabilidad de las laderas. En el caso de la pendiente las zonas de no ocurrencia se encuentran principalmente asociadas a ángulos de  $0^{\circ}$  a  $25^{\circ}$ , mientras que las zonas de ocurrencia presentan pendientes de entre  $25$  a  $45^{\circ}$  aproximadamente.

El índice de rugosidad topográfico al ser un medida de las diferencias de elevación con respecto a la pendiente indica que las zonas de no ocurrencia se asocian a bajos gradientes de elevación, mientras que las zonas de ocurrencia presentan una mayor diferencia de elevación, esto se asemeja a lo que ocurre con el Factor LS y las longitudes de las laderas.

En el gráfico de CV la distribución es relativamente simétrica y similar para ambos datasets, sin embargo, las zonas de no ocurrencia parecen estar relacionadas principalmente a áreas planas, mientras que las zonas de ocurrencia están relacionadas sustancialmente a las curvaturas convexas, a pesar de que también puedan ocurrir en áreas planas o curvaturas cóncavas.

En el gráfico de ASP los datos de no ocurrencia tienen una distribución más uniforme que los de zonas de ocurrencia y se puede observar que ambos datasets tienen dos peaks en común entre  $0^{\circ}$ - $50^{\circ}$  (N-NE) y  $270^{\circ}$ - $330^{\circ}$  (W-NW), por lo que la relación de estos ángulos no es concluyente con la ocurrencia del evento, pero el dataset de zonas de ocurrencia presenta un tercer peak entre los  $120^{\circ}$  y  $180^{\circ}$  (SE-S), el cual si parecía estar asociado a su ocurrencia.

### 5.4.3 Correlación

La correlación es una medida que representa el grado de correspondencia entre dos variables numéricas. Cuando dos variables están asociadas es posible identificar el comportamiento de una con respecto a la otra y se pueden determinar tendencias crecientes o decrecientes, una de las mejores formas para realizar este análisis es mediante el uso de gráficos de dispersión, en este caso se utilizó la herramienta “Pairplot” de Rstudio para conseguir los gráficos de pares (Figura 5.7) que representan gráficamente la relación existente entre cada variable. Estos gráficos pueden ayudar a identificar los factores condicionantes que tienen una relación fuerte con el resultado (valor de salida), así como a detectar patrones y relaciones no lineales entre variables. Además, pueden ser útiles para identificar variables que están altamente correlacionadas entre sí, lo que puede ayudar a reducir la dimensionalidad de los datos de entrada de la red neuronal.

De el gráfico se puede afirmar que las mayor correlación sobre el resultado del análisis se encuentra entre las variables pendiente (SLP) y Factor LS (SLF), esto se puede deber a que estas miden condiciones similares del terreno, en el caso de la pendiente esta mide el ángulo, mientras que el Factor LS se determina a partir de la longitud de la ladera (L) con respecto a la pendiente (S) y corresponde a un parámetro de la ecuación universal de perdida de suelo.

También es posible determinar a priori cuáles son las variables que tienen una mayor relevancia en el análisis y si es que tienen una relación directa o indirecta con este, es decir, determinar si es que un punto corresponde a una zona de ocurrencia de deslizamiento, en orden de importancia serian: geomorfología (GEOM), pendiente (SLP), geología (GEO), factor LS (SLF), índice de humedad topográfico (TWI), distancia a la red de drenaje (DRD), curvatura (CV) y en último lugar aspecto (ASP).

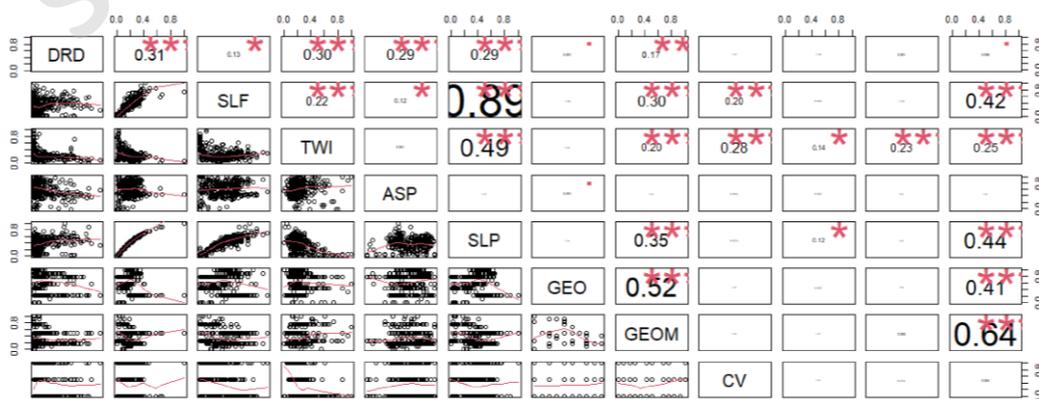


Figura 5.7. Gráfico “Pairplot”, representación gráfica de la correlación entre factores condicionantes, variables categóricas y variables numéricas.

## 5.5 Prueba y Selección de Modelos de RNA

La selección de la RNA adecuada dependerá de la naturaleza de la tarea y del conjunto de datos, y la optimización de los parámetros requerirá de experimentación y ajustes. No existe una regla fija para elegir la mejor red para una tarea específica. Sin embargo, algunos de los parámetros clave que se deben tener en cuenta al seleccionar una RNA son:

**Arquitectura de la red:** Esto incluye el número de capas, la cantidad de neuronas en cada capa y la topología de la red. La elección de la arquitectura dependerá de la complejidad de la tarea y del tamaño y complejidad del conjunto de datos.

**Función de activación:** Cada neurona en una RNA se activa a través de una función de activación. Hay varias funciones de activación comunes, como la función sigmoidea, la función ReLU y la función tanh. La elección de la función de activación dependerá de la naturaleza de la tarea y del conjunto de datos.

**Algoritmo de entrenamiento:** La selección del algoritmo de entrenamiento también es importante. Hay varios algoritmos de entrenamiento comunes, como el algoritmo de retropropagación (backpropagation) y el algoritmo de descenso del gradiente estocástico (Stochastic Gradient Descent). El algoritmo de entrenamiento adecuado dependerá del tamaño y complejidad del conjunto de datos, así como de la naturaleza de la tarea.

**Tasa de aprendizaje:** La tasa de aprendizaje determina la rapidez con la que la RNA ajusta los pesos durante el entrenamiento. Una tasa de aprendizaje demasiado alta puede hacer que la RNA no converja, mientras que una tasa de aprendizaje demasiado baja puede hacer que el entrenamiento sea demasiado lento.

**Regularización:** La regularización es un método para evitar el sobreajuste (overfitting) de la RNA. Hay varias técnicas de regularización comunes, como la L1 y L2 regularización. La elección de la técnica de regularización dependerá del tamaño y complejidad del conjunto de datos y de la naturaleza de la tarea.

Se realizó la prueba de un total de 30 modelos de RNA, en los cuales se probó utilizando distintas combinaciones de los parámetros mencionados anteriormente, ajustando paulatinamente los valores como la cantidad de capas ocultas y de neuronas contenidas en las capas y valores del umbral. También se probó el funcionamiento de los modelos con diferentes funciones de activación (sigmoidea logística, tangente hiperbólica, ReLU y softmax) y funciones

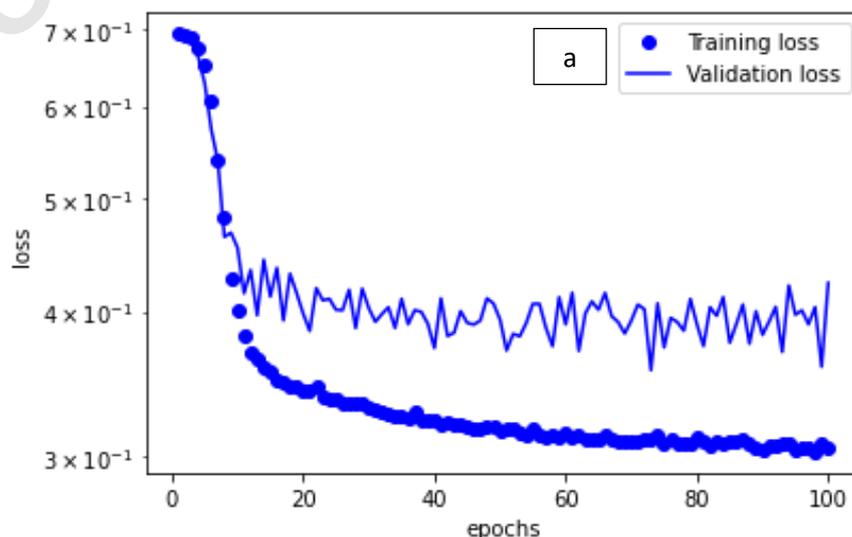
de error (entropía cruzada y suma de errores cuadrados). Además, se modificó el máximo de pasos en los modelos que no convergían cuando el máximo de pasos era muy bajo.

A partir de esta etapa de ensayos fue posible identificar principalmente tres tipos de resultados en los modelos, los cuales se presentan en los gráficos de error de entrenamiento (*training loss*) y error de validación (*validation loss*) (figuras 5.8a, 5.8b y 5.8c).

El error de entrenamiento es el error que se comete en la predicción de los datos de entrenamiento, donde la red neuronal ajusta sus pesos para minimizar el error en la predicción este se calcula en cada iteración del entrenamiento y se utiliza para actualizar los pesos de la red neuronal.

El error de validación es el error que se comete en la predicción de los datos de validación. Durante el entrenamiento, una parte de los datos se utilizan para entrenar la red y otra parte se utilizan para validar su rendimiento. El objetivo de la validación es comprobar que la red neuronal no esté sobreajustando los datos de entrenamiento, es decir, que no esté aprendiendo patrones específicos de los datos de entrenamiento que no se generalizan a otros datos. Este se utiliza para ajustar los hiperparámetros de la red neuronal, como el número de capas, el número de neuronas y la tasa de aprendizaje.

En general, se espera que el error de entrenamiento disminuya durante el entrenamiento, ya que la red neuronal aprende a ajustar sus pesos para reducir el error en la predicción. Por otro lado, el error de validación puede disminuir al principio, pero si la red neuronal empieza a sobreajustar los datos de entrenamiento, este comenzará a aumentar. El objetivo es encontrar un equilibrio entre estas dos métricas para obtener una red neuronal que generalice bien a nuevos datos.



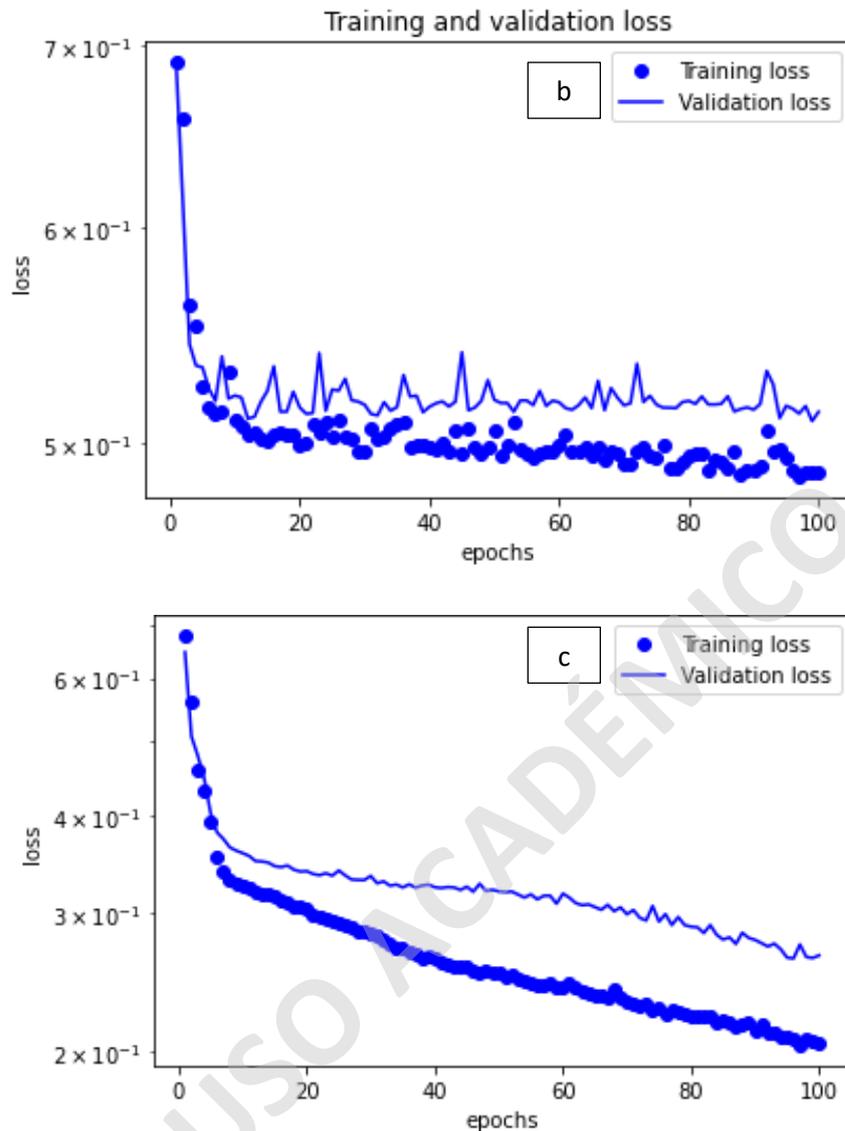


Figura 5.8. Gráficos del error de entrenamiento y validación.

Estos gráficos permiten identificar visualmente la evolución del error de entrenamiento (training loss) y del error de validación (validation loss) durante el proceso de entrenamiento.

El primer caso (Figura 5.7a) representa cuando una red neuronal comienza a sobreajustarse, lo que ocurre es que el error de entrenamiento continúa disminuyendo mientras que el error de validación comienza a aumentar, esto se debe a que la red está aprendiendo patrones específicos de los datos de entrenamiento que no se generalizan bien a nuevos datos, lo que resulta en una mala capacidad predictiva en datos de validación.

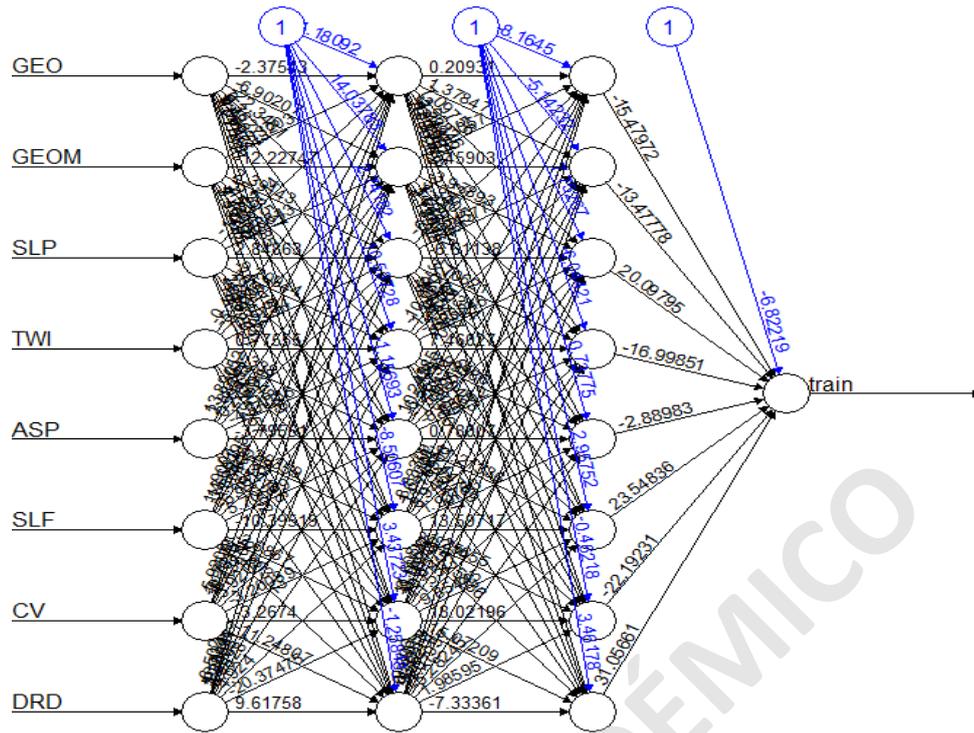
En la Figura 5.7b se muestra el segundo caso, donde las líneas de pérdida van juntas y se mantienen cerca una de la otra. Esto significa que la RNA está generalizando bien a datos

nuevos, lo que indica que la RNA no solo está memorizando los datos de entrenamiento, sino que también está aprendiendo patrones generales en los datos que le permiten hacer predicciones precisas en nuevos conjuntos de datos. Sin embargo, las fluctuaciones aleatorias o "ruido" pueden indicar una tasa de aprendizaje demasiado alta, una RNA demasiado compleja para el conjunto de datos o una cantidad insuficiente de datos de entrenamiento. Si el ruido es excesivo o persistente, puede ser una señal de que el modelo no está generalizando bien y puede necesitar ajustes o mejoras.

Por último, en la Figura 5.7c se identifica el mejor caso obtenido, donde se observa una disminución suave y constante en la pérdida tanto en el conjunto de entrenamiento como en el de validación, y, además, presenta poco ruido. Tomando estos resultados como referencia, se estimó que la RNA con el mejor rendimiento en términos de precisión de las predicciones fue la RNA.23. Su arquitectura se puede visualizar en las figuras 5.9 y 5.10, donde se pueden ver las capas que constituyen la red neuronal. Primero, hay una capa de entrada con siete neuronas que corresponden a cada uno de los valores de entrada (factores condicionantes); luego, dos capas ocultas de ocho neuronas cada una, donde se procesa la información; y, finalmente, una capa oculta con una neurona que entrega el valor de salida, que en este caso es el resultado de la clasificación binaria 1 o 0. Los otros parámetros seleccionados para este modelo se resumen en la Tabla 5.3.

*Tabla 5.3. Resumen de parámetros del modelo de RNA.23*

<b>RNA.23</b>	
Capas ocultas	2 capas de 8 nodos c/u
Set.seed	3312
Umbral	0.01
Función de activación	Sigmoidal (logística)
Función de error	Suma de los errores cuadrados (sse)
Máximo de pasos	1E+07
Tasa de aprendizaje	0.01



Error: 1.70004 Steps: 136436

Figura 5.9. Esquema de la arquitectura de la red neuronal incluyendo los pesos sinápticos entre cada nodo.

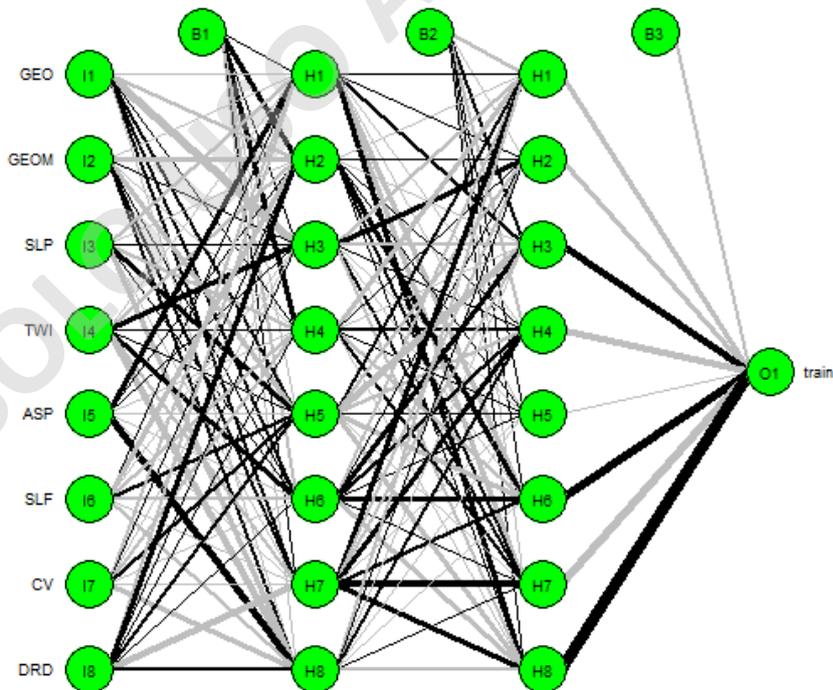


Figura 5.10. Esquema de la arquitectura de la red neuronal aplicada al análisis de susceptibilidad de zonas de ocurrencia de deslizamientos. El grosor de los conectores indica la magnitud absoluta y los colores indican valores positivos (negros) y negativos (gris).

Como se observa en la Figura 5.9 la red neuronal no entrega un valor concreto de la ponderación de cada factor. Esto se debe a que la red neuronal aprende por sí misma, mediante el ajuste de los pesos sinápticos, a partir de los datos de entrada y salida del modelo, y por lo tanto no se puede determinar con exactitud la contribución de cada factor en el resultado del análisis. Es por esto que se les denomina “cajas negras” porque su funcionamiento interno es muy complejo y difícil de entender, incluso para los expertos en el tema.

No obstante, existen herramientas para analizar la relevancia de los factores condicionantes en el resultado del análisis. Una de estas herramientas es el análisis de sensibilidad, que consiste en evaluar cómo varía el resultado de la red neuronal al modificar uno o varios factores de entrada. De esta manera, se puede determinar cuáles son los factores más importantes para el resultado del análisis.

También es posible realizar una inspección visual de los datos mediante la utilización de técnicas de visualización, como la representación gráfica de la salida de la red neuronal para diferentes combinaciones de los factores de entrada. De esta manera, se puede tener una idea general de cómo los diferentes factores afectan la salida del modelo.

a continuación, se presentan algunas herramientas que permiten analizar gráficamente la relevancia de los factores condicionantes en el resultado del análisis.

### 5.6 Jerarquización de variables

En la Figura 5.11 (gráfico de Garson) se muestran las variables ordenadas según el grado de importancia de cada una en el resultado del análisis, de este se concluye que la variable más importante es la geología/geotecnia y geomorfología, seguido de la pendiente y factor LS, y la que tiene menor influencia es la curvatura y el índice de humedad topográfico.

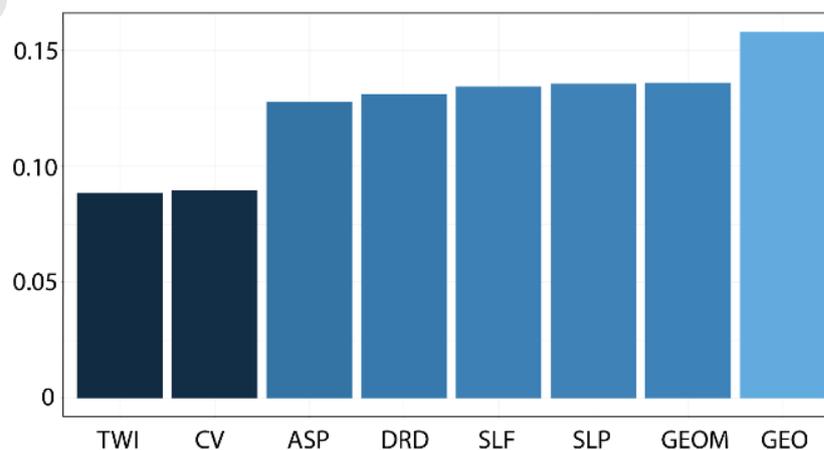


Figura 5.11. Gráfico de Garson, jerarquía de factores condicionantes en valor absoluto.

### 5.7 Análisis de Susceptibilidad de Zonas de Ocurrencia de Deslizamientos de Suelo

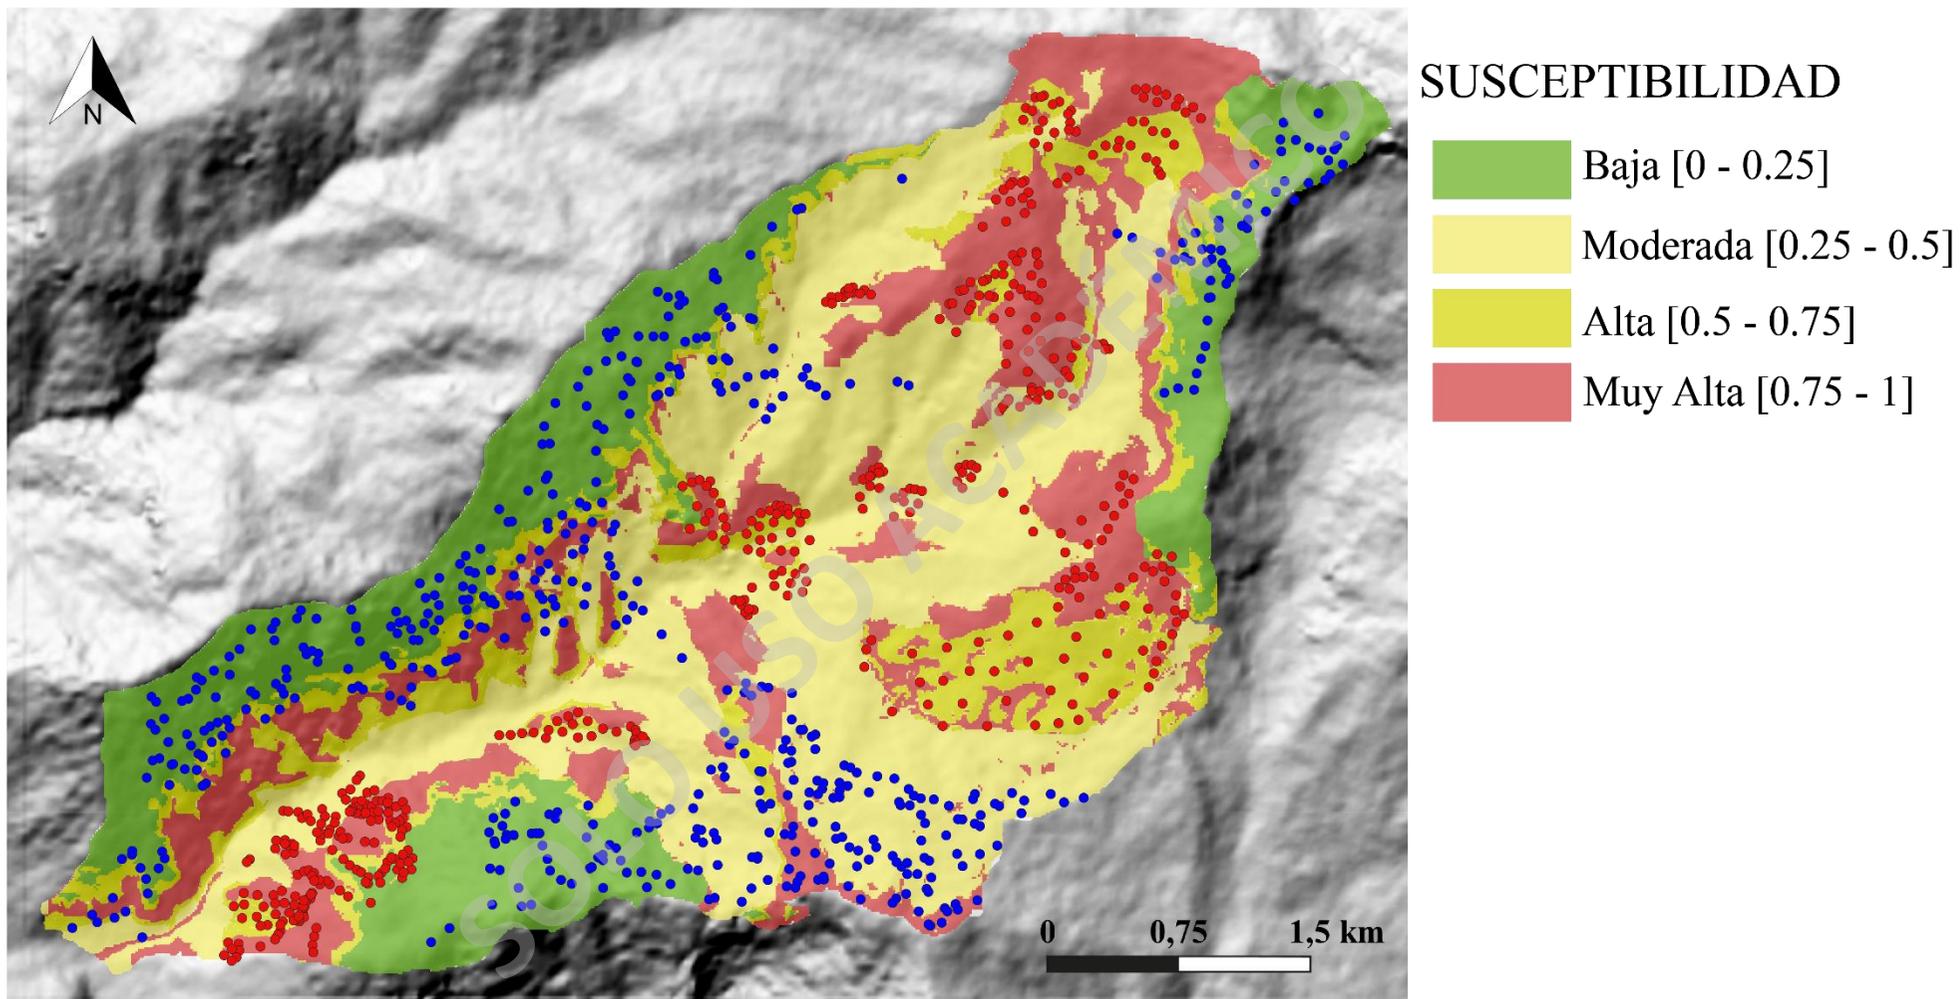


Figura 5.12. Mapa de susceptibilidad de zonas de ocurrencia de deslizamientos de suelo en la cuenca del estero San Alfonso.

## **CAPÍTULO 6 : DISCUSIONES**

El objetivo principal de este proyecto de investigación corresponde a la elaboración de un mapa de susceptibilidad de zonas de ocurrencia de deslizamientos de suelo, a partir de la generación de ponderadores para los factores condicionantes seleccionados, mediante la aplicación de una inteligencia artificial, en específico una red neuronal artificial, la cual permite encontrar los valores que mejor se ajusten al caso de estudio.

A continuación, se presentan las discusiones del proceso de prueba de la red neuronal artificial y sus resultados.

### **6.1 Red Neuronal Artificial**

El desempeño de una RNA está determinado por sus hiperparámetros, que son valores predefinidos utilizados para configurar el modelo y ajustar su complejidad y velocidad de aprendizaje. Los principales hiperparámetros son la cantidad de capas, cantidad de neuronas por capa, tasa de aprendizaje (learning rate), tipo de algoritmo, número de pasos máximo (stepmax), valor umbral (threshold), función de activación (act.fct) y función de coste (err.fct).

Cuando se hizo la revisión de la metodología se concluyó que la selección de los hiperparámetros es crítica para el desempeño de la RNA y una de las principales dificultades fue que no existe una fórmula o guía que indique como seleccionarlos, por lo que encontrar el valor adecuado y que mejor se ajuste al modelo es un proceso de ensayo y error.

#### **6.1.1 Tasa de Aprendizaje**

La tasa de aprendizaje es un hiperparámetro que determina la cantidad de ajuste que se realiza en los pesos de la RNA en cada iteración durante el entrenamiento. Al observar los resultados de los modelos, se pudo identificar que cuando la tasa de aprendizaje es demasiado alta, la RNA puede saltar mínimos locales importantes, lo que resulta en un sobreajuste o una incapacidad para converger en una solución óptima. Por otro lado, si la tasa de aprendizaje es demasiado baja, la RNA puede tardar demasiado en converger. Por lo tanto, también es necesario realizar ajustes en el número máximo de pasos (o iteraciones), ya que, si el número de pasos es demasiado bajo, la RNA tampoco converge. Sin embargo, si el número de pasos es demasiado alto, se puede aumentar el riesgo de sobreajuste y hacer que el proceso de entrenamiento sea demasiado lento.

### 6.1.2 Valor Umbral

De manera similar sucede con el valor umbral, el cual se utiliza para determinar si una neurona se activa o no. Si el umbral es demasiado alto, las neuronas pueden activarse con menos frecuencia, lo que puede limitar la capacidad de la RNA para capturar relaciones complejas en los datos. Si el umbral es demasiado bajo, puede hacer que la RNA sea demasiado sensible a pequeñas variaciones en los datos, lo que puede resultar en un sobreajuste.

### 6.1.3 Función de Activación y de Coste

En cuanto a la elección de la mejor función de activación y función de coste para una tarea de clasificación binaria, esto dependerá del conjunto de datos y la complejidad del problema. En general, la función de activación ReLU (Rectified Linear Unit) y la función de coste de entropía cruzada binaria (Binary Cross-Entropy) son opciones populares y efectivas para una clasificación binaria, pero un problema con la programación de redes neuronales con el paquete NeuralNet de R es que solo permite el uso de dos funciones de activación y de error, en el caso de las funciones de activación son sigmoidea logística (logistic) y tangente hiperbólica (tanh), y para las funciones de error permite utilizar entropía cruzada (ce) y suma de errores cuadrados (sse).

Para realizar pruebas y analizar el funcionamiento de la RNA utilizando otras funciones se utilizó la biblioteca de redes neuronales de código abierto Keras para Python, donde se pudo utilizar las funciones de activación ReLU y Softmax, las cuales son de las funciones más utilizadas en la actualidad, y las funciones de error entropía cruzada binaria y entropía cruzada categórica. Al comparar el funcionamiento de estas funciones fue posible identificar que la configuración con mejores resultados para un análisis de clasificación binaria fue utilizar la función de activación ReLU en las capas ocultas y la función de activación sigmoidea en la capa de salida, y la función de error de entropía cruzada binaria. Este ejercicio sirvió para entender que a pesar de que los resultados obtenidos en R muestran un buen desempeño, es posible mejorarlos al utilizar otras herramientas de programación como, por ejemplo, Keras, PyTorch, MatLab y TensorFlow.

### 6.1.4 Numero de Capas

Finalmente, fue posible identificar que la relación entre el número de capas y neuronas no es directa. El uso de una RNA compleja con muchas capas y neuronas puede aumentar el tiempo de entrenamiento y la probabilidad de sobreajuste. Por otro lado, una red menos compleja puede tener menos capacidad para distinguir relaciones no lineales entre las entradas y las salidas. Por lo tanto, encontrar la cantidad adecuada de capas y neuronas es un proceso de prueba y error, aunque se debe tener en cuenta que, como se muestra en la Figura 6.1, si los patrones son linealmente separables, se requiere solo una capa, mientras que, si no lo son, se necesitarán dos o más capas.

Para encontrar el modelo con mejor desempeño se realizaron pruebas variando los parámetros mencionados anteriormente. En primera instancia, se probó usar una capa oculta, esta configuración presento un correcto desempeño y un buen resultado, luego se aumentó de manera progresiva la cantidad de capas, lo que también aumentó considerablemente el tiempo de procesamiento de la RNA, pero el desempeño no vio una variación considerable, por lo que se decidió dejar las siguientes pruebas con un límite de dos capas.

Se debe tener en cuenta que las RNA pueden resolver problemas complejos con una gran cantidad de variables y millones de datos, por lo que la baja cantidad de variables y datos de este estudio hace que no sea necesario armar una configuración tan compleja para alcanzar resultados óptimos. Similar fue lo ocurrido con el número de neuronas por capa, donde se probó utilizar neuronas en múltiplos de ocho con un máximo de 64 neuronas. Se determinó que el mejor desempeño de la red se alcanzó con la configuración de 2 capas neuronales de ocho neuronas cada una como se muestra en las Figuras 5.9 y 5.10.

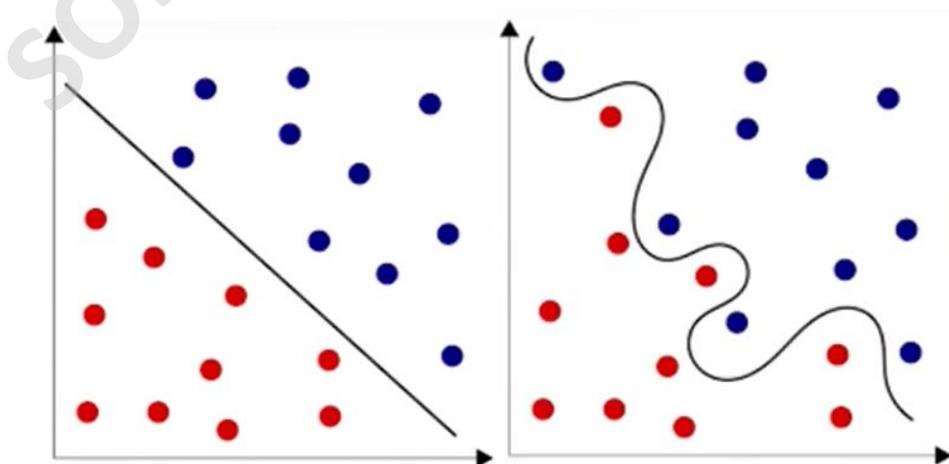


Figura 6.1. a) Esquema de un patrón de datos lineal. b) Esquema de un patrón de datos no lineal.

## 6.2 Catastro de Zonas de Ocurrencia

Durante el estudio, se encontró una dificultad al definir los puntos que no son susceptibles a producir deslizamientos de suelo debido a que se utilizaron como parámetros de seguridad la pendiente menor a 5 grados y una distancia de seguridad no menor a 500 metros de una zona de ocurrencia. Sin embargo, al no encontrarse zonas con pendientes menores a 5 grados, el programa solo utilizó la distancia como referencia para definir las zonas seguras. El cual como factor por sí solo no tiene una relación directa o causalidad con la ocurrencia de deslizamientos de suelo. Como resultado de esto, la red neuronal pudo haber identificado como zonas seguras algunos sectores donde las condiciones, sobre todo de pendiente, indican que la susceptibilidad debería ser mayor.

Por esta razón, es importante prestar atención a la calidad y precisión de los datos de entrada que se utilizan para definir tanto las zonas de ocurrencia como las zonas seguras, ya que el proceso de entrenamiento de la red neuronal depende fundamentalmente de ellos y, por ende, impactan en la eficacia y precisión del resultado final.

A pesar de las dificultades encontradas durante el entrenamiento, la red neuronal artificial logró interpolación de zonas de alta/muy alta susceptibilidad en áreas donde el catastro originalmente las había marcado como no susceptibles a deslizamientos. Esto puede ser considerado una validación del aprendizaje de la red, ya que pudo clasificar estas zonas según su propio análisis y aprendizaje, superando lo que se le había entregado en el catastro. Este resultado resalta la capacidad de las redes neuronales para identificar patrones y relaciones complejas entre los factores condicionantes, y sugiere que su uso puede mejorar significativamente la precisión en la identificación de zonas de susceptibilidad de deslizamientos de suelo en comparación con otros métodos más tradicionales.

## 6.3 Definición de Clases de Susceptibilidad

El resultado final de la red neuronal es un mapa de susceptibilidad con valores continuos entre 0 y 1, por lo cual es necesario determinar los umbrales, que corresponden a medidas arbitrarias a partir de las cuales un proceso natural se considera peligroso y objeto de análisis, estos se utilizan para discretizar el rango de valores con la finalidad de señalar con mayor precisión las zonas susceptibles a ocasionar deslizamientos de suelo.

Para decidir la cantidad de clases de susceptibilidad se tuvo en cuenta como precedente la metodología de Lara (2007) y el artículo científico de Lara *et al.* (2018) por lo que se optó por

dividir los valores de susceptibilidad en 4 clases cuyos rangos van de 0 a 24, 25 a 49, 50 a 74 y 75 a 100.

Se clasifica en estas categorías porque proporciona una forma de cuantificar y comparar la probabilidad de que ocurran deslizamientos en diferentes áreas. Las categorías se basan en una escala del 0 al 100, donde 0 representa una probabilidad muy baja de deslizamientos y 100 representa una probabilidad muy alta. Al dividir la escala en cuatro categorías, se puede proporcionar una indicación más clara de la susceptibilidad relativa y también hacer que el mapa de susceptibilidad sea más fácil de interpretar.

## **6.4 Factores Condicionantes**

La susceptibilidad a los deslizamientos de suelo es un fenómeno complejo y multifactorial. A continuación, se llevará a cabo un análisis detallado del efecto de cada uno de los factores condicionantes en la ocurrencia de un deslizamiento de suelo, con el fin de determinar su importancia relativa y la influencia en su ocurrencia.

### **6.4.1 Selección y Descarte de Factores Condicionantes**

La selección de los factores condicionantes para análisis de susceptibilidad va a depender en gran medida de las características de la zona de estudio y del tipo de remoción a analizar. No existe un criterio universalmente aceptado para la selección de los factores condicionantes que influyen en las remociones en masa, especialmente en los deslizamientos de suelo. Por lo tanto, se utiliza como base los factores condicionantes propuestos en metodologías ampliamente utilizadas (Tabla 6.1), como por ejemplo Sepúlveda (1998, 2000) y Lara (2007). Además, se tuvieron en cuenta las tesis de Villela (2017), Sandoval (2021) y Alfaro (2022), en las que se empleó la metodología de redes neuronales artificiales para análisis de susceptibilidad en el fiordo de Comau, la comuna de Chaitén y la comuna de San José de Maipo, respectivamente. De esta revisión es posible identificar que algunos factores condicionantes se presentan de manera recurrente (Tabla 6.1) independientes de la zona de estudio como, por ejemplo, pendiente, aspecto y elevación.

Tabla 6.1. Esquema comparativo de factores condicionantes de diferentes autores y este trabajo.

	Lara (2007)	Muñoz (2013)	Villela (2017)	Alfaro (2022)	CIGIDEN (2022)	Este Trabajo
<b>Pendiente</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>
<b>Geología/Geotecnia</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>
<b>Exposición Solar</b>	<b>X</b>	<b>X</b>			<b>X</b>	
<b>Aspecto</b>			<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>
<b>Antecedentes</b>	<b>X</b>	<b>X</b>				
<b>Humedad y Saturación</b>	<b>X</b>	<b>X</b>				
<b>Acumulación de Nieve</b>	<b>X</b>					
<b>Índice de Humedad Topográfico</b>				<b>X</b>		<b>X</b>
<b>Elevación</b>		<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	
<b>Curvatura</b>			<b>X</b>	<b>X</b>		<b>X</b>
<b>Vegetación</b>	<b>X</b>	<b>X</b>				
<b>Distancia a Fallas</b>		<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>	
<b>Forma (Geometría)</b>		<b>X</b>				
<b>Distancia a Red de Drenaje</b>			<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>
<b>Cobertura de Suelo</b>					<b>X</b>	
<b>Distancia a Caminos</b>					<b>X</b>	
<b>Geomorfología</b>					<b>X</b>	<b>X</b>
<b>Índice de Potencia del Cause</b>				<b>X</b>		
<b>Índice de Transporte de Sedimento</b>				<b>X</b>		
<b>Intervención Antrópica</b>	<b>X</b>	<b>X</b>				
<b>Factor LS</b>						<b>X</b>
<b>Tipo de Material</b>	<b>X</b>					

En primera instancia la selección de factores condicionantes resulto en un total de 11 factores (Tabla 5.1). A partir de los análisis de correlación, la jerarquización de variables, la prueba de modelos de RNA y el control visual de mapas se descartaron los factores condicionantes de Antecedentes, Índice de Rugosidad Topográfico y Uso de suelo.

Es importante tener en cuenta que la metodología de redes neuronales artificiales necesita, en lo posible, evitar trabajar con variables dependientes, ya que esto provoca sesgos en como esta ponderara los factores condicionantes. En el caso de los antecedentes estos son un registro de eventos históricos los cuales son totalmente dependientes de los factores condicionantes involucrados en la ocurrencia de dicho evento.

En términos similares la correlación muy alta de dos factores como por ejemplo el índice de rugosidad topográfico y la pendiente (aproximadamente 99%) provocan una sobreestimación de los pesos reales de estos factores en el resultado del análisis.

Por otro lado, también se consideró el efecto de las variables categóricas en el análisis. En las primeras pruebas de la red neuronal se observó que las variables categóricas tenían un comportamiento diferente al de las variables numéricas continuas, principalmente por el hecho de que sus distribuciones estaban definidas por las categorías. Además, a diferencia de las variables numéricas estas no tienen una jerarquización de importancia o valor, sino que son más bien contextuales. A pesar de esto, se decidió dejar las variables categóricas Geología/Geotecnia y Geomorfología debido a su relevancia en el análisis final del mapa de susceptibilidad y se descartó el Uso de Suelo.

#### **6.4.2 Geología/Geotecnia y Geomorfología**

Si bien la geología es un factor fundamental en los análisis de susceptibilidad de deslizamientos de suelo, en este caso, como se observa en la Figura 2.2, la geología es relativamente homogénea en toda la cuenca donde predomina la Fm. Abanico. Por lo tanto, se considera necesario incluir también las condiciones geotécnicas para el análisis, para de esta manera incorporar como factor el comportamiento mecánico del material e identificar los límites de suelo y roca.

En general, se ha observado que las zonas de baja/moderada susceptibilidad se encuentran ligadas a la Fm. Abanico con cobertura de suelo (Tias), mientras que las zonas de alta/muy alta susceptibilidad se asocian a escarpes, zonas de cabecera de los depósitos de deslizamiento (Qd), depósitos coluviales (Qc) y glaciales (Qg). También incluyen algunos sectores de Fm. Abanico con cobertura de suelo (Tias), Fm. Abanico competente (Tiac), específicamente las zonas donde se indica la presencia de fallas inferidas y Fm. Abanico fracturada (Tiaf), la cual se divide en zonas de baja y alta/muy alta susceptibilidad. Esto se debe a que también se considera el efecto de la distancia a la red de drenaje (DRD) y los límites suelo/roca.

En cuanto a la geomorfología, las zonas de baja/moderada susceptibilidad se vinculan con laderas de caída de roca, cimas e interfluvios. Mientras que las zonas de alta/muy alta susceptibilidad están relacionadas con morrenas laterales y de fondo, pantanos, terrazas aluviales, conos de deyección y circos glaciares.

Cabe destacar que el mapa generado presenta un ajuste muy cercano al mapa geológico/geotécnico y geomorfológico, ya que estos factores condicionantes son variables categóricas que en un principio se consideró dejar afuera del estudio debido a que su inclusión provocaba un sobreajuste de la red neuronal. Es decir, la red neuronal podría aprender solo para el caso específico de la cuenca en cuestión. Sin embargo, se decidió incluir estas variables ya que, para los fines de este estudio, forzar a la red neuronal a considerar estos factores era más importante que validar numéricamente el funcionamiento de la red neuronal debido a que estos son factores condicionantes con una relevancia de primer orden, y permiten obtener resultados con coherencia geológica.

#### **6.4.3 Pendiente y Factor LS**

La pendiente es uno de los factores más influyentes en la predicción de la susceptibilidad, ya sea de manera directa o al estar contenida en otro factor condicionante de manera indirecta, como, por ejemplo, la distancia a la red de drenaje. Mediante la observación del mapa, fue posible identificar que las zonas de alta/muy alta susceptibilidad se asocian a pendientes entre  $10^\circ$  y  $25^\circ$ , principalmente en zonas de escarpes. Mientras que los valores de baja/moderada susceptibilidad se encuentran en el rango de  $25^\circ$  a  $45^\circ$  de inclinación en la zona suroeste de la cuenca. Las pendientes sobre  $45^\circ$  no tienen una relación concluyente con la ocurrencia de deslizamientos de suelo, ya que parecieran haber otros factores que predominan, tales como la distancia a la red de drenaje y los límites roca/suelo que definen el comportamiento mecánico del material. Se debe considerar la interdependencia de los factores condicionantes, es decir, que la ocurrencia de deslizamientos de suelo no depende de un solo factor, sino de la interacción de estos.

Otra interpretación de por qué la relación entre los valores de pendiente y la ocurrencia de deslizamientos no es directa, como se esperaría, es que, si bien como regla general, las altas pendientes generan una mayor inestabilidad del terreno, también no permiten la acumulación de material que pueda ser removido.

De manera semejante, los sectores donde el factor LS presenta valores entre 0 y 6 se corresponden con las zonas de alta/muy alta susceptibilidad, esto debido a que bajos valores del factor LS, se interpretan como zonas donde hay una baja erosión del suelo por escorrentía superficial. Cuando los valores del factor LS son mayores a 6 la relación entre este factor y la susceptibilidad no es concluyente, excepto al suroeste de la cuenca donde el factor LS alcanza

valores altos (>15) y tiene asociada una alta susceptibilidad, lo que podría estar relacionado con controles estructurales, ya que en este sector hay representadas varias fallas inferidas.

#### **6.4.3 Distancia Red de Drenaje**

La distancia a la red de drenaje condiciona o está relacionada con los flujos subterráneos de agua, y por ende con el estado de saturación de los suelos y su posible rotura para la ocurrencia de remociones en masa. En general, las zonas con un valor de distancia a la red de drenaje menor a 280 metros corresponden a sectores de susceptibilidad moderada. Por otro lado, cuando los valores se encuentran entre 28 y 90 metros, se observa una tendencia hacia las zonas de alta/muy alta susceptibilidad. Finalmente, cuando los valores están por encima de los 90 metros, la susceptibilidad es baja. Esto puede deberse a que, al ser las zonas más alejadas de la red de drenaje, tienen una escasa interacción con los flujos de agua subterráneos, por lo que los suelos no se encuentran saturados y, por lo tanto, tienen una mayor estabilidad.

#### **6.4.4 Aspecto**

El aspecto u orientación de la ladera puede influir en la ocurrencia de deslizamientos de suelo debido a que afecta en la exposición de la ladera al sol y al viento, lo que a su vez influye en la distribución de la humedad en el suelo. En el sector suroeste de la cuenca las zonas de mayor susceptibilidad a formar zonas de ocurrencia de deslizamientos de suelo se encuentran en las laderas con orientación noroeste y en las laderas que miran hacia el sureste, pero estas tienen mayor relación con la presencia de conos de deyección y el límite suelo roca de la ladera. En general, en Chile central las laderas orientadas al norte tienden a tener un mayor riesgo de deslizamiento, debido a que reciben más sol y tienen una mayor evaporación, lo que puede resultar en una menor humedad en el suelo y, por lo tanto, una menor cohesión en las partículas del suelo. Mientras que las laderas que tienen una orientación este-oeste tienen una susceptibilidad moderada y las que apuntan al sur baja. (Lara, 2007).

#### **6.4.5 Índice de Humedad Topográfico y Curvatura**

Estos dos factores tuvieron los resultados menos concluyentes debido al bajo nivel de correlación que estimo la red neuronal para el análisis de la ocurrencia de deslizamientos de suelo. sin embargo, fue posible identificar que las curvaturas cóncavas favorecen la acumulación de agua, aumentando la saturación del suelo y roca por lo que se les asocia a las zonas de alta/muy alta susceptibilidad. Mientras que las zonas de baja/moderada susceptibilidad se asocian a las zonas de curvatura convexa y plana.

#### **6.5 Evaluación del Mapa de Susceptibilidad**

Según la guía del Sistema de Información Geográfica de Multiamenaza (SIGMA) del CIGIDEN, una forma de evaluar la certidumbre de los mapas de susceptibilidad es mediante la aplicación de una tabla de contingencia o matriz de confusión, y el método de la curva de éxito o gráfico ROC/AUC. Es importante destacar que la validación de una red neuronal debe realizarse utilizando diferentes técnicas y métricas para obtener una evaluación más completa y precisa del rendimiento del modelo.

##### **6.5.1 Matriz de Confusión**

De la Tabla 6.2 es posible extraer que la RNA es eficiente en la clasificación de los datos como verdaderos positivos y verdaderos negativos en la etapa de entrenamiento, lo que se ve representado como una alta precisión, exactitud, especificidad y sensibilidad esto puede ser debido a que durante la primera etapa el modelo se ajusta a los datos de entrenamiento y puede lograr una alta precisión. Sin embargo, cuando se evalúa la capacidad predictiva del modelo con datos de prueba, que no fueron utilizados en el entrenamiento, se observa una baja en el rendimiento. Es posible que esto se deba al sobreajuste de la RNA, donde el modelo puede haber aprendido patrones específicos en los datos de entrenamiento que no se generalizan bien para nuevos datos.

Otras posibles razones para la disminución de la precisión entre la etapa de entrenamiento y la de prueba incluyen problemas en la selección de los factores condicionantes, desbalanceo de clases en los datos de entrenamiento y prueba, problemas de ruido o errores en los datos de prueba, entre otros. Es importante considerar estas posibles causas y tomar medidas para abordarlas durante la construcción y evaluación del modelo.

Tabla 6.2. Matriz de confusión de entrenamiento y testeo con un valor umbral de 0.5

Matriz de Confusión Entrenamiento		Matriz de Confusión Testeo	
352	12	142	16
4	336	15	132
Métricas Entrenamiento		Métricas Testeo	
Exactitud	0.98	Exactitud	0.88
Precisión	0.96	Precisión	0.89
Sensibilidad	0.98	Sensibilidad	0.90
Especificidad	0.96	Especificidad	0.89

### 6.5.2 Gráficos ROC/AUC

El índice Área Bajo la Curva (AUC) se considera aceptable cuando su valor es mayor al 70%. Cuanto más pronunciada sea la parte inicial de la curva y mayor sea el área bajo la curva, mejor será considerado un mapa de susceptibilidad para predecir la distribución de los movimientos en masa (González et al. 2022), en vista de esto y considerando que el AUC entregado por la RNA fue de un 96% para el entrenamiento y de un 93% para las predicciones sería posible afirmar que el resultado final correspondiente al mapa de susceptibilidad presenta un buen desempeño en su función de clasificar los puntos de ocurrencia y no ocurrencia de deslizamientos de suelo. Sin embargo, es importante tener en cuenta que un valor cercano al 100% no significa necesariamente que el modelo sea perfecto o que los resultados sean confiables.

Existen varios factores que pueden afectar la precisión del modelo y generar resultados falsos positivos o falsos negativos. Por ejemplo, el desbalanceo de clases, es decir, cuando hay una gran diferencia en la cantidad de muestras entre las dos clases, puede afectar la capacidad del modelo para clasificar correctamente ambas clases. También puede haber errores en la recopilación o el preprocesamiento de los datos, o el modelo puede estar sobreajustado a los datos de entrenamiento.

En resumen, una alta puntuación en una curva ROC/AUC indica que el modelo funciona bien y tiene un buen desempeño en la tarea de clasificación, pero no garantiza que los resultados sean 100% precisos o confiables, por lo que es importante realizar una evaluación cuidadosa del modelo y tener en cuenta otros factores para determinar la precisión del modelo y su capacidad para generalizar a nuevos datos.

En vista de esto es importante recordar que la inteligencia artificial, incluyendo las redes neuronales, son una herramienta más que se suma a las ya existentes, y como tal presenta tanto beneficios como dificultades. Desde el punto de vista de la programación solo se analiza el correcto funcionamiento del algoritmo, por lo que para validar realmente que los resultados sean correctos, es necesaria una evaluación visual del mapa para ver que este sea coherente. Una manera de realizar esta revisión es utilizar otro mapa, en este caso el del CIGIDEN para la cuenca del Río Maipo, como referencia comparativa.

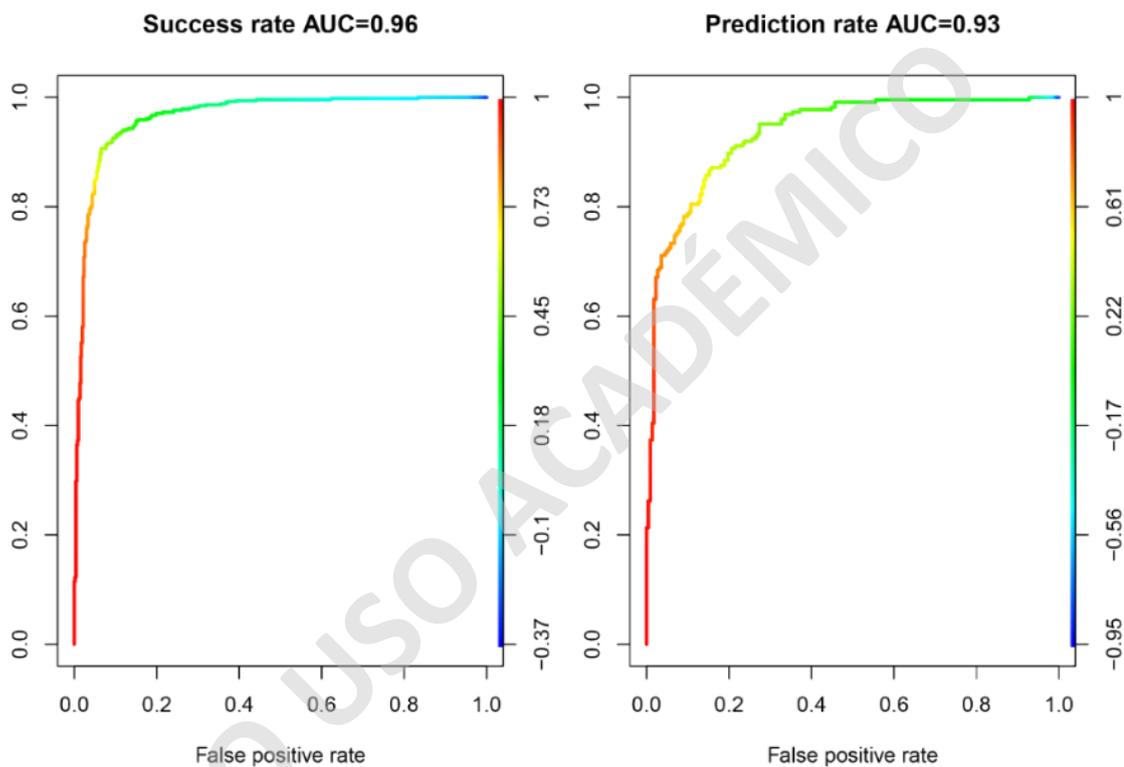


Figura 6.2. Gráficos ROC/AUC para el modelo RNA.23.

### 6.5.3 Comparación Visual de Mapas

El mapa elaborado en el proyecto SIGMA muestra la susceptibilidad relativa del terreno a ser afectado por deslizamientos de laderas. En la Tabla 6.3 se indican los factores condicionantes y sus respectivos pesos relativos, obtenidos mediante el método del proceso analítico jerárquico (AHP, por sus siglas en inglés)

Una de las principales diferencias entre los dos mapas es el tipo de análisis realizado. El mapa elaborado por el CIGIDEN considera deslizamientos de ladera indiferenciados, es decir, sin distinguir entre si son de suelo o roca, mientras que este proyecto se enfoca específicamente

en deslizamientos de suelo. También cabe destacar la diferencia en la escala de mapeo ya que en el caso de este trabajo el mapa se realizó a una escala 1:25.000 basado en un modelo de elevación digital con resolución espacial de 12,5x12,5, lo que permite capturar más detalles y características del terreno en la misma área de cobertura. Por su parte el mapa elaborado por el CIGIDEN se realizó a una escala mucho más general donde abarca toda la comuna de San José de Maipo utilizando un modelo de elevación digital remuestreado a una resolución espacial de 30x30 píxeles.

Otra diferencia relevante es la selección de los factores condicionantes: el mapa del CIGIDEN utiliza 10 factores, mientras que el mapa generado con RNA utiliza solo 8. Además, hay una diferencia en los valores de los pesos relativos asignados a cada factor (Tabla 6.3 y 6.4). En el mapa del CIGIDEN, se determinó que la pendiente es la variable de mayor relevancia, mientras que en el mapa resultado de la RNA se les dio mayor peso a las variables de geomorfología y geología/geotecnia, seguidas de la pendiente y el factor LS.

Tabla 6.3. Factores condicionantes y sus respectivos pesos ponderados para este trabajo y el mapa SIGMA de CIGIDEN.

<b>Factor Condicionante</b>	<b>Peso Ponderado</b>
Geología	16.0%
Geomorfología	14.0%
Pendiente	13.9%
Factor LS	13.7%
Distancia a drenajes	13.4%
Aspecto	12.0%
Curvatura	9.0%
Índice de humedad topográfico	8.0%
<b>Total</b>	<b>100%</b>

Tabla 6.4. Factores condicionantes y sus respectivos pesos, calculados para el mapa SIGMA del CIGIDEN.

<b>Factores Condicionantes CIGIDEN</b>	<b>Pesos %</b>
Pendiente	30%
Litología	19%
Geomorfología	15%
Distancia a fallas	12%
Elevación	8%
Distancia a drenajes	5%
Radiación solar	4%
Cobertura de suelo	3%
Orientación de capas estratigráficas y laderas	2%
Distancia a caminos	2%

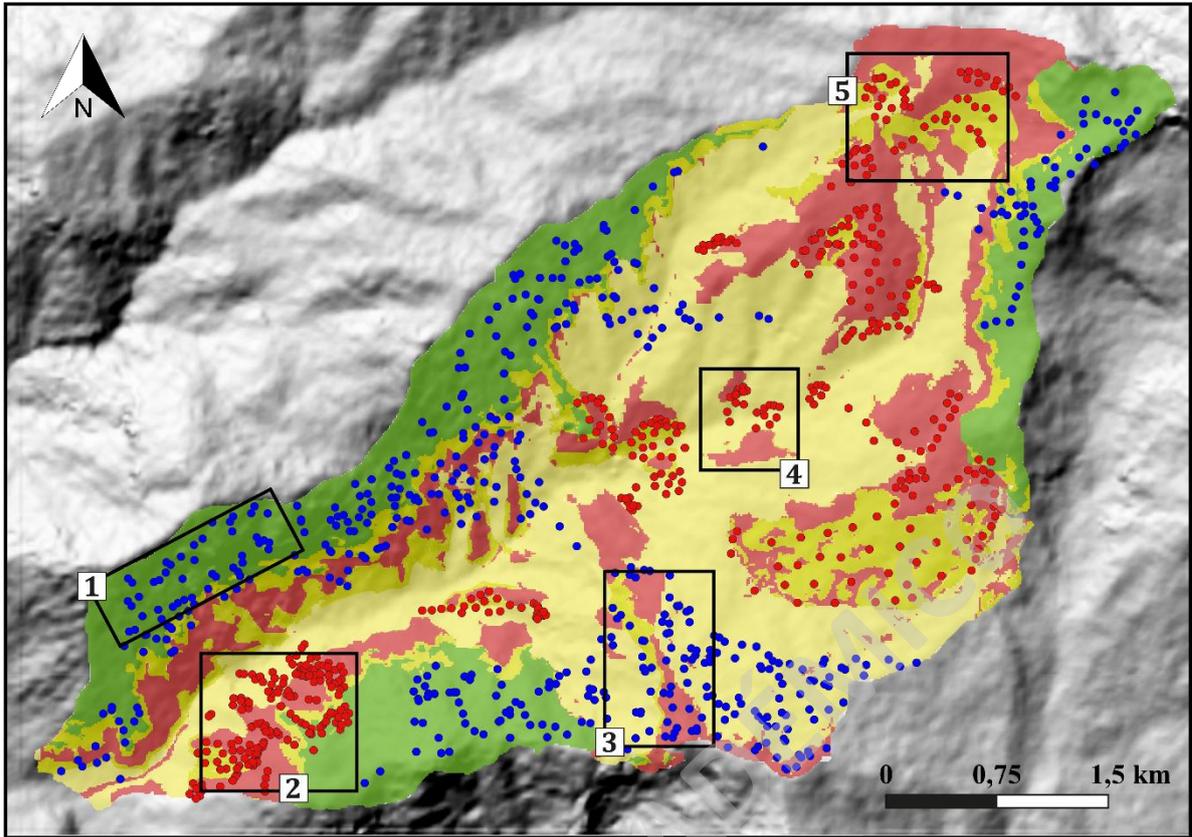


Figura 6.3. Mapa de susceptibilidad resultado de la RNA.23 dividido por zonas de análisis.

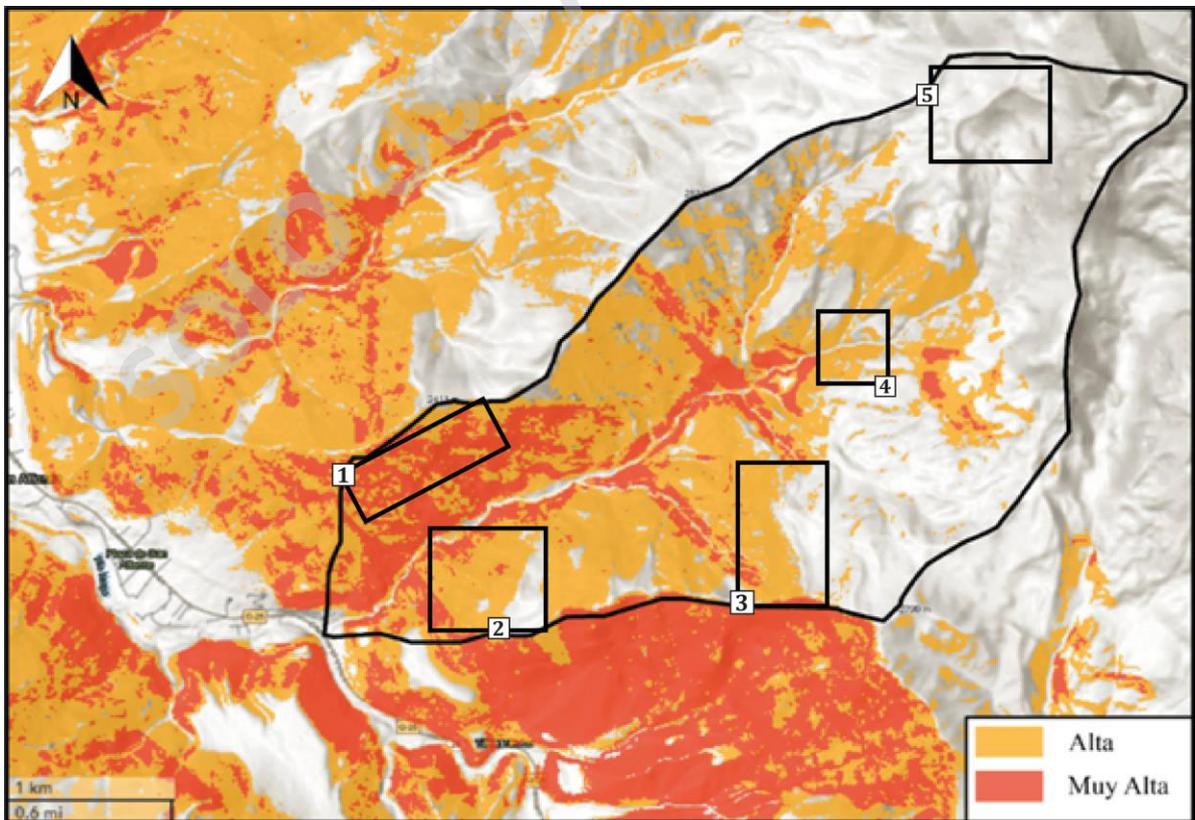


Figura 6.4. Mapa de susceptibilidad de deslizamientos de ladera, proyecto SIGMA; CIGIDEN

El mapa de susceptibilidad fue dividido en 5 cuadrantes (Figura 6.3) los cuales representan los puntos más importantes a discutir sobre la congruencia de los resultados con respecto al catastro y la comparación con el mapa del CIGIDEN. Con base en esto se realizaron las siguientes discusiones:

**Cuadrante 1:** Se observa una zona donde se encuentra el catastro de zonas de no ocurrencia de deslizamientos de suelo. Basándose en esta información, la red neuronal clasificó esta área como de baja susceptibilidad. Sin embargo, el resultado es poco coherente con lo esperado para esta zona, ya que se trata de un sector con pendientes pronunciadas y donde están presentes las unidades Fm. Abanico fracturada y Fm. Abanico con cobertura de suelo, lo que sugiere que los valores de susceptibilidad deberían ser más altos.

El primer análisis sugiere que la inexactitud en las predicciones de la red neuronal se debe a que los datos de entrenamiento utilizados para enseñar a la red a identificar zonas de no ocurrencia fueron erróneos. Estos datos consideraron únicamente la distancia de seguridad de zonas de ocurrencia (500 m), un factor que por sí solo no es relevante para determinar la ocurrencia de un deslizamiento de suelo.

Por tanto, es crucial tener en cuenta la calidad de los datos utilizados para entrenar una red neuronal y llevar a cabo una revisión exhaustiva del catastro o conjunto de datos antes de utilizarlos en el entrenamiento. La selección de datos precisos y confiables es fundamental para obtener resultados confiables y de alta calidad mediante el uso de una red neuronal.

En comparación con el mapa del CIGIDEN se observa que en este el cuadrante 1 fue caracterizado como de alta y muy alta susceptibilidad, esto puede tener relación con lo mencionado anteriormente sobre errores del catastro, pero también puede deberse a que el mapa SIGMA del CIGIDEN analiza deslizamientos de ladera indiferenciados, es decir, no separa entre deslizamientos de suelo y de roca, en cambio este trabajo es específico para deslizamientos de suelo, teniendo en cuenta el cambio abrupto que se observa entre las zonas de baja susceptibilidad y las de alta/muy alta susceptibilidad de esta ladera, se podría inferir que en esta zona existe un límite suelo/roca.

**Cuadrante 2:** En el sector suroeste de la cuenca, específicamente en la ladera norte, se pueden observar áreas de alta o muy alta susceptibilidad que no están relacionadas con los puntos marcados en el catastro de zonas de ocurrencia. Esta situación puede explicarse por la capacidad de la red neuronal para realizar interpolaciones basadas en lo aprendido de las condiciones presentes en la ladera del cuadrante 2.

Es importante tener en cuenta la ponderación asignada al factor condicionante de geomorfología. Es posible que la red neuronal, al reconocer zonas con cárcavas y conos de deyección como áreas de alta o muy alta susceptibilidad debido a que están asociadas a procesos activos, haya utilizado esta información para inferir que la ladera frontal también es propensa a sufrir deslizamientos de suelo si se cumplen condiciones geomorfológicas similares. En términos de la elaboración del mapa de susceptibilidad, estos resultados son efectivos, ya que el objetivo es identificar y prevenir áreas donde no haya eventos registrados de deslizamientos de suelo.

Es importante destacar que la red neuronal ha logrado capturar patrones relacionados con la geomorfología y utilizarlos para predecir la susceptibilidad en áreas donde no existen registros de eventos de deslizamientos. Esto demuestra la capacidad de la red para generalizar y aplicar el conocimiento aprendido en diferentes contextos dentro de la cuenca.

Con respecto al mapa del CIGIDEN, estos comparten rasgos comunes en este cuadrante donde se definen las zonas de alta y muy alta susceptibilidad a pesar de la diferencia en la selección y el peso que ponderaron los factores condicionantes que se utilizaron para realizar cada mapa. Esto puede deberse a que los deslizamientos de suelo son fenómenos complejos y multifactoriales que deben ser analizados integrando cada factor y la interacción entre ellos.

**Cuadrantes 3 y 4:** Se observan dos casos en los cuales el catastro utilizado para entrenar a la red neuronal artificial no coincide con el resultado del mapa de susceptibilidad. Por ejemplo, hay puntos del catastro de ocurrencia (rojos) que fueron interpretados como áreas de susceptibilidad moderada. Esta discrepancia puede deberse a errores en el proceso de entrenamiento de la red neuronal. Si los datos utilizados para entrenar no son representativos o no capturan adecuadamente la relación entre las características y la susceptibilidad, la red puede generar resultados contradictorios.

Además, es importante tener en cuenta posibles problemas con el catastro. Como se mencionó anteriormente, el factor de seguridad utilizado para seleccionar los puntos de no

ocurrencia puede no ser eficiente para el análisis. También es posible que las variables explicativas utilizadas para el fenómeno, es decir, los factores condicionantes seleccionados, no sean totalmente representativos. Sería conveniente explorar la inclusión de otros factores para ver cómo afectan los resultados de la red neuronal.

Por otra parte, una explicación adicional podría ser que la red neuronal haya aprendido los patrones asociados a los factores condicionantes que caracterizan una zona de ocurrencia. En consecuencia, la red neuronal pudo determinar que estas áreas presentaban dichos niveles de susceptibilidad, a pesar de que esto contradiga la información proporcionada por el catastro.

Este fenómeno demuestra la capacidad de la red neuronal para aprender y tomar decisiones, incluso si esto implica ignorar parte de la información de entrada utilizada durante el entrenamiento, ya que, en algunos casos, una red neuronal puede identificar patrones y correlaciones en los datos de entrenamiento que no eran evidentes inicialmente. Es importante tener en cuenta que esto no significa necesariamente que el resultado de la red neuronal esté equivocado, sino que ha aprendido a identificar relaciones más sutiles o complejas en los datos que pueden no haber sido capturadas en la información de entrenamiento inicial.

Finalmente, debemos tener en cuenta también que los modelos de aprendizaje automático no son perfectos y pueden tener dificultades para capturar ciertos patrones o relaciones complejas en los datos sobre todo cuando se analizan fenómenos o procesos naturales.

En general, se observa cierta semejanza entre estos cuadrantes y el mapa del CIGIDEN, las diferencias pueden deberse a que el factor más relevante en su mapa es la pendiente, mientras que en este trabajo tuvo predominancia la geomorfología, además hay diferencias en la escala de trabajo y la resolución espacial utilizada para el mapeo.

**Cuadrante 5:** Este es uno de los cuadrantes más congruentes con el catastro, pero es el que presenta mayor conflicto con respecto al mapa del CIGIDEN, ya que el mapa resultante de este trabajo define esta zona como de alta/muy alta susceptibilidad, mientras que el mapa del CIGIDEN no determina susceptibilidad en este sector.

Una posible interpretación de esta diferencia radica en el modelo conceptual utilizado para mapear las zonas de deslizamientos de suelo, y por lo tanto, el catastro utilizado para generar el mapa, así como en los factores condicionantes y el peso asignado a cada uno en el análisis. En primer lugar, al considerar las zonas de deslizamiento en su totalidad, es decir, tanto la zona de arranque como la zona de alcance, se enseñó a la red neuronal a definir la susceptibilidad en

rangos amplios. Por ejemplo, la pendiente requerida para iniciar un deslizamiento no es la misma que la necesaria para que el material se deposite en la zona de alcance. Sin embargo, la red neuronal clasificó ambos valores como de ocurrencia, lo que significa que podría haber dado el mismo peso a una pendiente de 20° que a una de 70°. Como resultado, la red neuronal no otorgó mayor relevancia a un parámetro típico en este tipo de estudios, como la pendiente, y dio mayor peso a la geomorfología y la geología. Mientras que el mapa del CIGIDEN considera como el valor más relevante la pendiente con un 30% del valor total ponderado para los factores condicionantes.

SOLO USO ACADÉMICO

## CAPÍTULO 7: CONCLUSIONES

La generación de mapas de susceptibilidad de deslizamientos de suelo es un tema de gran importancia en la gestión de riesgos naturales. En este trabajo, se utilizó la técnica de redes neuronales artificiales (RNA) para la elaboración de un mapa de susceptibilidad en la cuenca hidrográfica del estero San Alfonso. El objetivo principal de este trabajo fue generar dicho mapa, evaluar la eficacia de esta técnica y analizar el efecto de diferentes factores condicionantes en la ocurrencia de deslizamientos de suelo.

Para alcanzar este objetivo, se realizó una revisión bibliográfica sobre la metodología utilizada en la elaboración de mapas de susceptibilidad de deslizamientos de suelo y sobre la aplicación de RNA en este tipo de estudios. A partir de esta revisión, se diseñó una metodología específica que permitió la elaboración del mapa de susceptibilidad.

Los resultados obtenidos indican que la técnica de RNA es efectiva en la generación de mapas de susceptibilidad de deslizamientos de suelo, permitiendo identificar zonas críticas con alta probabilidad de ocurrencia de estos eventos. Además, se encontró que diferentes factores condicionantes tienen un efecto significativo en la ocurrencia de deslizamientos de suelo y que la inclusión de estos factores en la modelación permite mejorar la precisión de los mapas de susceptibilidad.

Entre los principales hallazgos, se destaca que, de los factores seleccionados, la geomorfología, la geología y la pendiente son los factores condicionantes más importantes para la ocurrencia de deslizamientos de suelo en la zona de estudio. Además, se encontró que la técnica de RNA puede mejorar significativamente la precisión de los modelos de susceptibilidad, en comparación con otros métodos más tradicionales o al menos permite tener un mayor control sobre el error.

Sin embargo, el estudio también reveló algunas limitaciones en el uso de las redes neuronales artificiales, por lo que se recomienda tener en cuenta las siguientes consideraciones.

En primer lugar, es de suma importancia definir claramente el modelo conceptual. Esto implica establecer la representación teórica del fenómeno a estudiar y el objetivo del análisis, incluyendo la delimitación de las zonas de influencia del evento (arranque, deformación, alcance, etc.), los procesos desencadenantes y los factores condicionantes que pueden influir en

la ocurrencia de un evento. Esta definición es fundamental, ya que guiará la recopilación de información y la generación del catastro.

En cuanto al catastro, este es el dato de mayor relevancia para esta metodología, ya que los puntos de ocurrencia y no ocurrencia son los utilizados para entrenar la red neuronal. La calidad del resultado estará directamente relacionada con la calidad de la información utilizada por lo que es esencial contar con un conjunto de datos representativo y suficiente en términos de tamaño y diversidad, para que la red neuronal pueda aprender de manera adecuada los patrones relacionados con el fenómeno a analizar. Además, se debe tener cuidado al definir los factores de seguridad que especifican las condiciones para el catastro de no ocurrencia, ya que cualquier problema en esta definición también afectará la calidad del resultado.

El tercer punto a considerar es el proceso de configuración de la red neuronal. Este proceso implica una etapa de ensayo y error, para probar diferentes modelos de redes neuronales y seleccionar aquel que tenga el mejor rendimiento para la zona y los datos del estudio. Sin embargo, si se quisiera replicar este proceso en otro lugar, sería necesario realizar todo el proceso nuevamente para encontrar la configuración de red adecuada para los nuevos datos.

Es importante tener en cuenta que la configuración óptima de la red neuronal puede variar según las características específicas de cada zona de estudio y conjunto de datos. Por lo tanto, no existe una configuración única que funcione de manera óptima en todos los casos. Es necesario adaptar y ajustar la configuración de la red según las necesidades y características particulares de cada nueva situación. Para esto se debe contar con conocimiento de los principios y técnicas involucradas en el diseño y entrenamiento de redes neuronales para poder realizar estos ajustes de manera efectiva, lo que requiere experiencia en el campo de la inteligencia artificial y la capacidad de analizar y comprender los resultados obtenidos para realizar mejoras continuas en el rendimiento de la red.

Cabe destacar la importancia de la interpretación de los resultados por parte de los geólogos y/o geólogas. El uso de redes neuronales artificiales en el análisis de susceptibilidad es una herramienta complementaria y no sustituye la experiencia y el conocimiento de los expertos.

Si bien las redes neuronales artificiales permiten optimizar recursos, mejorar resultados, y las métricas pueden indicar que el algoritmo funciona y es preciso, es importante evaluar críticamente los resultados obtenidos y considerarlos en conjunto con otros conocimientos y técnicas de análisis. La interpretación del mapa, y ver que este sea coherente con la realidad

geológica es fundamental, así como la recopilación de información en terreno de la cual dependerá el aprendizaje de la red.

Finalmente, espero que este estudio sea una contribución valiosa al campo y que inspire a otros investigadores a continuar explorando y ampliando nuestro conocimiento en el campo de la geología y la inteligencia artificial.

SOLO USO ACADÉMICO

## REFERENCIAS

- Alfaro, A. (2022). Metodología Para La Evaluación De Susceptibilidad De Remociones En Masa Basada En Redes Neuronales Convolucionales, Con Aplicación En La Comuna De San José De Maipo, Región Metropolitana, Chile. Universidad de Chile.
- Aditian, A., Kubota, T., & Shinohara, Y. (2018). Comparison of GIS-based landslide susceptibility models using frequency ratio, logistic regression, and artificial neural network in a tertiary region of Ambon, Indonesia. *Geomorphology*, 318, 101–111. <https://doi.org/10.1016/j.geomorph.2018.06.006>.
- A.Scarlett. (2014). “análisis de susceptibilidad por remoción en masa en el valle las trancas y termas de chillán. Criterios para el manejo del riesgo.”
- Acuña, V., Roldán, F., Tironi, M., & Juzam, L. (2021). The geo-social model: A transdisciplinary approach to flow-type landslide analysis and prevention. *Sustainability (Switzerland)*, 13(5), 1–37. <https://doi.org/10.3390/su13052501>.
- Alberto, C., & Ortiz, Q. (2021). Guía metodológica para zonificación de amenaza por avenidas torrenciales. In *Guía metodológica para zonificación de amenaza por avenidas torrenciales*. <https://doi.org/10.32685/9789585313156>.
- Aleotti, P., & Chowdhury, R. (1999). Landslide hazard assessment: Summary review and new perspectives. *Bulletin of Engineering Geology and the Environment*, 58(1), 21–44. <https://doi.org/10.1007/s100640050066>.
- Aleotti, P. (2004). A warning system for rainfall-induced shallow failures. *Engineering Geology*, 73(3–4), 247–265. <https://doi.org/10.1016/j.enggeo.2004.01.007>.
- Alvarez, M. (2006). Factibilidad de utilización de técnicas geofísicas en estudios de fenómenos de remoción en masa. Caso: Deslizamiento de San José de Maipo.
- Anyelo, R. (2011). Protección y estabilización de taludes para evitar deslizamientos. 122. <http://cybertesis.uach.cl/tesis/uach/2011/bmfcij.65p/doc/bmfcij.65p.pdf>.
- Arenas, M., & Opazo, E. (2017). Guía Metodológica para la Elaboración de Mapas de Susceptibilidad a las Remociones en Masa a Escala Regional. Unidad de Peligros Geológico y Ordenamiento Territorial.
- Baeza, R. C. B., & Ayala, I. A. (2004). Procesos de remoción en masa y riesgos asociados en zacapoxtla, Puebla. *Investigaciones Geograficas*, (October 1999), 7–26.
- Baştanlar, Y., & Ozuyisal, M. (2014). Introduction to Machine Learning Second Edition. In *Methods in molecular biology (Clifton, N.J.)* (Vol. 1107). [https://doi.org/10.1007/978-1-62703-748-8\\_7](https://doi.org/10.1007/978-1-62703-748-8_7).
- Betancourt, C. A., & Castro, A. (2018). Evaluación de susceptibilidad a deslizamientos mediante redes neuronales en la avenida Simón Bolívar. *Congreso de Ciencia y Tecnología ESPE*, 13(1), 13–16. <https://doi.org/10.24133/cctespe.v13i1.723>.
- Beck, M.W. 2018. NeuralNetTools: Visualization and Analysis Tools for Neural Networks. *Journal of Statistical Software*. 85(11):1-20.
- Bravo, M., Flores, R., Galindo, R., Garreaud, R., Muñoz, E., Serey, A., & Viaje, M. (2014). Determinación de posibles impactos en la gestión de los abastecimientos humanos de agua situados en la zona Metropolitana de Chile, provocados por fenómenos asociados al cambio climático. *Aquae Papers*, 5, 17–29.
- Carrara, A., Cardinali, M., Guzzetti, F., & Reichenbach, P. (1995). Gis Technology in Mapping Landslide Hazard. 135–175. [https://doi.org/10.1007/978-94-015-8404-3\\_8](https://doi.org/10.1007/978-94-015-8404-3_8).
- Ceballos, P. (2016). Evaluación de peligro de remociones en masa en Quebrada de Apoquindo, sector oriente de Santiago, Región Metropolitana.

- Charrier, R., Farias, M., & Makshev, V. (2009). Andes De Chile Norte Y Central E Implicaciones. Abril 2018.
- Charrier, R., Pinto, L., & Rodríguez, M. P. (2007). Tectonostratigraphic evolution of the Andean Orogen in Chile. Geological Society Special Publication. <https://doi.org/10.1144/goch.3>.
- Chung, C.-J. F., Fabbri, A. G., & Van Westen, C. J. (1995). Multivariate Regression Analysis for Landslide Hazard Zonation. *Advances in Natural and Technological Hazards Research*, 107–133. doi:10.1007/978-94-015-8404-3\_7
- Cuanalo C., O. A., Quezada P., P., Aguilar M., A., Oliván R., A. M., & Barona D., E. (2006). Earthquakes and rainfalls, triggers factors of landslides at the mountain range of Puebla, Mexico. *Revista Digital Científica y Tecnológica: E-GNOSIS - Universidad de Guadalajara*, 4, 1–14.
- Devkota, S., Shakya, N. M., Acharya, G., Adhikari, B. R., & Jha, K. (2018). Development of Rainfall Threshold Model for the Data Poor Region – a Case Study of Panchase Region , Central-Western Hills of Nepal. August, 1–18. <https://doi.org/10.13140/RG.2.2.19981.18405>
- DGA. (2004). Diagnóstico y clasificación de los Cursos y cuerpos de agua Según objetivos de calidad. Cuenca del Rio Maipo. Dirección General de Aguas de Chile, 1–105. <https://mma.gob.cl/wp-content/uploads/2017/12/Maipo.pdf>
- Dobrev, D. (2012). A Definition of Artificial Intelligence. 1–7. <http://arxiv.org/abs/1210.1568>
- Dolling, O. R., & Varas, E. A. (2002). Utilisation des réseaux des neurones artificielles pour la prédiction des écoulements. *Journal of Hydraulic Research*, 40(5), 547–554. <https://doi.org/10.1080/00221680209499899>.
- Du, J., Yin, K., & Lacasse, S. (2013). Displacement prediction in colluvial landslides, Three Gorges Reservoir, China. *Landslides*, 10(2), 203–218. <https://doi.org/10.1007/s10346-012-0326-8>
- Ehrenpreis, T. (1967). Classification and Terminology. *Journal of the Royal Society of Medicine*, 60(8), 799–801. <https://doi.org/10.1177/003591576706000844>.
- Fariás, M., Comte, D., Charrier, R., Martinod, J., David, C., Tassara, A., Tapia, F., & Fock, A. (2010). Crustal-scale structural architecture in central Chile based on seismicity and surface geology: Implications for Andean mountain building. *Tectonics*, 29(3). <https://doi.org/10.1029/2009TC002480>
- Feby, B., A.L, A., K, J., V.A, A., & Reghunath, R. (2020). Landslide susceptibility modelling using integrated evidential belief function based logistic regression method: A study from Southern Western Ghats, India. *Remote Sensing Applications: Society and Environment*, 100411. doi:10.1016/j.rsase.2020.100411
- Fell, R., & Eberhardt, E. (2020). The analysis of global landslide risk through the creation of a database of worldwide landslide fatalities. *Landslide Risk Management*, 377–384. <https://doi.org/10.1201/9781439833711-18>.
- Fock, A., Charrier, R., Fariás, M., & Muñoz, M. (2006). Fallas de vergencia oeste en la Cordillera Principal de Chile Central: Inversión de la cuenca de Abanico (33-34 S). *Revista de La Asociación Geológica Argentina, Publicación Especial*, 6(January), 48–55.
- Fock, A. (2005). Cronología y tectónica de la exhumación en el neógeno de los Andes de Chile central entre los 33° y los 34°s. *Memoria para optar al título de Geólogo, Universidad de Chile*. 235.
- Fratini, P., Crosta, G., & Carrara, A. (2010). Techniques for evaluating the performance of landslide susceptibility models. *Engineering Geology*, 111(1-4), 62–72. doi:10.1016/j.enggeo.2009.12.004
- Gajardo, A., Garrido, N., & Marín, M. (2013). Servicio Nacional de Geología y Minería Subdirección Nacional de Geología y Minería Departamento de Geología Aplicada Documento Externo Este trabajo fue efectuado por: POTABLE PARA LA REGIÓN METROPOLITANA. Santiago, 5 de abril de 2013.
- Garson, G.D. 1991. Interpreting neural network connection weights. *Artificial Intelligence Expert*. 6(4):46-51.

- Goh, A.T.C. 1995. Back-propagation neural networks for modeling complex systems. *Artificial Intelligence in Engineering*. 9(3):143-151.
- González, G., Jensen, E., Aron, F., Roldán, F., Sáez, E., Díaz, F., Candia, G., Gironás, J., Escauriaza, C., Saldías, J., Aranguiz, R., Gilabert, H., De la Barra F., Zúñiga, A. (2022). Guía Metodológica para la Caracterización de la Multiamenaza de la Cuenca del Río Maipo. Proyecto FONDEF 19i10021.
- Guzzetti, F., Mondini, A. C., Cardinali, M., Fiorucci, F., Santangelo, M., & Chang, K. T. (2012). Landslide inventory maps: New tools for an old problem. *Earth-Science Reviews*, 112(1–2), 42–66. <https://doi.org/10.1016/j.earscirev.2012.02.001>
- Hauser, A. (2000). Remociones en Masa en Chile, Versión actualizada. In Servicio Nacional de Geología y Minería, Boletín (Vol. 59, p. 90).
- Helm, J. M., Swiergosz, A. M., Haeberle, H. S., Karnuta, J. M., Schaffer, J. L., Krebs, V. E., Spitzer, A. I., & Ramkumar, P. N. (2020). Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions. *Current Reviews in Musculoskeletal Medicine*, 13(1), 69–76. <https://doi.org/10.1007/s12178-020-09600-8>
- Hungr, O., Leroueil, S., & Picarelli, L. (2014). The Varnes classification of landslide types, an update. *Landslides*, 11(2), 167–194. <https://doi.org/10.1007/s10346-013-0436-y>
- Jacob, R., & Murugan, S. (2016). Implementation of neural network based PID controller. *International Conference on Electrical, Electronics, and Optimization Techniques, ICEEOT 2016*, 1, 2769–2771. <https://doi.org/10.1109/ICEEOT.2016.7755199>
- Jakhar, D., & Kaur, I. (2020). Artificial intelligence, machine learning and deep learning: definitions and differences. *Clinical and Experimental Dermatology*, 45(1), 131–132. <https://doi.org/10.1111/ced.14029>
- Kanungo, D. P., Arora, M. K., Sarkar, S., & Gupta, R. P. (2006). A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling Himalayas. *Engineering Geology*, 85(3–4), 347–366. <https://doi.org/10.1016/j.enggeo.2006.03.004>
- Krogh, A. (2008). What are artificial neural networks? *Nature Biotechnology*, 26(2), 195–197. <https://doi.org/10.1038/nbt1386>
- Lancaster, J. (2015). Identification of Debris Flow ‘Mudflow’ Hazards for Assessment of Alluvial Fan Flooding. Floodplain Management Association –Annual Conference.
- Lara, M. Del P. (2007). Metodología para la Evaluación y Zonificación de Peligro de Remociones en Masa con Apliación en Quebrada San Ramón, Santiago Oriente, Región Metropolitana. Tesis, Universidad de Chile, 53(9), 1–188. [http://www.tesis.uchile.cl/tesis/uchile/2007/celis\\_c/sources/celis\\_c.pdf](http://www.tesis.uchile.cl/tesis/uchile/2007/celis_c/sources/celis_c.pdf)
- Liu, Z., Gilbert, G., Cepeda, J. M., Lysdahl, A. O. K., Piciullo, L., Hefre, H., & Lacasse, S. (2021). Modelling of shallow landslides with machine learning algorithms. *Geoscience Frontiers*, 12(1), 385–393. <https://doi.org/10.1016/j.gsf.2020.04.014>
- Marín, M. V.; Muñoz, A. A. & Naranjo, J. A. 2018. Víctimas fatales causadas por remociones en masa en Chile (1928-2017). XV Congreso Geológico Chileno “Geociencias hacia la comunidad”. PRIN-SG: Sesión General Peligros y Riesgos Naturales. 216 – 2019. Concepción, Chile.
- Margottini, C., Canuti, P., & Sassa, K. (2013). *Landslide science and practice Volume 6 risk assessment, management and mitigation* (Vol. 6).
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Historia, 55. <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>
- Montero, E. (2010). Tesis de maestría en ciencias. Cenidet.Edu.Mx. [http://www.cenidet.edu.mx/subaca/web-elec/tesis\\_mc/197MC\\_eblm.pdf](http://www.cenidet.edu.mx/subaca/web-elec/tesis_mc/197MC_eblm.pdf)

- Moreiras, S. M., & Sepúlveda, S. A. (2013). The high social and economic impact 2013 summer debris flow event in Central Chile and Argentina. *Bollettino Di Geofisica Teorica Ed Applicata*, 54(2), 181–184.
- Muñoz, A. A. (2018). Metodología Para Evaluar La Amenaza De Flujos De Detritos Utilizando Un Análisis Jerárquico De Procesos Y El Software Ramms, Con Aplicación En La Cuenca Del Estero San Alfonso, Región Metropolitana. 175. <http://repositorio.uchile.cl/handle/2250/152982>
- Muñoz, E. (2013). Susceptibilidad de remociones en masa y de respuesta sísmica asociada a fallas mayores en zonas urbanas. Estudio de caso en Viña del Mar, V región. 177. <http://repositorio.uchile.cl/handle/2250/114667>
- Nantes, E. (2019). El método Analytic Hierarchy Process para la toma de decisiones. Repaso de la Metodología y Aplicaciones. *Revista de La Escuela de Perfeccionamiento En Investigación Operativa*, 27(46), 54–73.
- Olden, J.D., Jackson, D.A. 2002. Illuminating the 'black-box': a randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling*. 154:135-150.
- Olden, J.D., Joy, M.K., Death, R.G. 2004. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. *Ecological Modelling*. 178:389-397.
- Ongsulee, P. (2018). Artificial intelligence, machine learning and deep learning. *International Conference on ICT and Knowledge Engineering*, 1–6. <https://doi.org/10.1109/ICTKE.2017.8259629>
- Ospina-Gutiérrez, J. P., & Aristizábal, E. (2021). Aplicación de inteligencia artificial y técnicas de aprendizaje automático para la evaluación de la susceptibilidad por movimientos en masa. *Revista Mexicana de Ciencias Geológicas*, 38(1), 43–54. <https://doi.org/10.22201/cgeo.20072902e.2021.1.1605>
- Padilla, C. (2006). Análisis de factores meteorológicos desencadenantes de remociones en masa en el sector oriente de Santiago. 176.
- Park, Y. S., & Lek, S. (2016). Artificial Neural Networks: Multilayer Perceptron for Ecological Modeling. In *Developments in Environmental Modelling* (Vol. 28). Elsevier. <https://doi.org/10.1016/B978-0-444-63623-2.00007-4>
- Pham, B. T., Pradhan, B., Tien Bui, D., Prakash, I., & Dholakia, M. B. (2016). A comparative study of different machine learning methods for landslide susceptibility assessment: A case study of Uttarakhand area (India). *Environmental Modelling and Software*, 84, 240–250. <https://doi.org/10.1016/j.envsoft.2016.07.005>
- Pierson, T. (2005). Distinguishing between debris flows and floods from field evidence in small watersheds. *Water*, January, 4.
- Popescu, M. E. (2002). Landslide causal factors and landslide remedial options. 3rd International Conference on Landslides, Slope Stability and Safety of Infra-Structures, 1–21.
- Pourghasemi, H. R., & Rahmati, O. (2018). Prediction of the landslide susceptibility: Which algorithm, which precision? *Catena*, 162(October), 177–192. <https://doi.org/10.1016/j.catena.2017.11.022>
- Pradhan, B. & Lee, S. 2010. Landslide susceptibility assessment and factor effect analysis: backpropagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling. Elsevier. *Environmental Modelling & Software*. Vol. 25: 747–759.
- Pradhan, B. 2012. A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS. Elsevier. *Computers & Geosciences*. Vol. 51: 350 – 365.
- Pradhan, R. N. (2017). Physical Modeling of Debris Flow by Varying Sediment Concentration. June. <https://brage.bibsys.no/xmlui/handle/11250/2458154>

- Proyecto Multinacional Andino: Geociencias Para Las Comunidades Andinas, 2007. Movimientos en Masa en la Región Andina: Una guía para la evaluación de amenazas. Servicio Nacional de Geología y Minería, Publicación Geológica Multinacional, No. 4: 432 pp
- Quiroga, R. (2013). Análisis estructural de los depósitos cenozoicos de la cordillera Principal entre el cerro Provincia y el cordón el Quempe, Región Metropolitana, Chile (33°18' y 33°25'S). [Http://repositorio.uchile.cl/handle/2250/115299](http://repositorio.uchile.cl/handle/2250/115299)
- Raschka, S. 2015. Python Machine Learning, Unlock deeper insights into machine learning with this vital guide to cutting-edge predictive analytics. Hussain A. Editor. 415pp. Birmingham, UK.
- Rauld, R. (2002). Análisis morfoestructural del frente cordillerano de Santiago oriente, entre el Río Mapocho y la Quebrada de Macul. Memoria de título de geólogo. 70.
- Reichenbach, P., Rossi, M., Malamud, B. D., Mihir, M., & Guzzetti, F. (2018). A review of statistically-based landslide susceptibility models. *Earth-Science Reviews*, 180(March), 60–91. <https://doi.org/10.1016/j.earscirev.2018.03.001>
- Rouhiainen, L. (2008). Inteligencia artificial 101 cosas que debes saber hoy sobre nuestro futuro. Alienta Editorial, 22. [https://planetadelibrosar0.cdnstatics.com/libros\\_contenido\\_extra/40/39307\\_Inteligencia\\_artificial.pdf](https://planetadelibrosar0.cdnstatics.com/libros_contenido_extra/40/39307_Inteligencia_artificial.pdf)
- Rózycka, M., Migoń, P., & Michniewicz, A. (2017). Topographic Wetness Index and Terrain Ruggedness Index in geomorphic characterisation of landslide terrains, on examples from the Sudetes, SW Poland. *Zeitschrift Fur Geomorphologie*, 61(November 2017), 61–80. [https://doi.org/10.1127/zfg\\_suppl/2016/0328](https://doi.org/10.1127/zfg_suppl/2016/0328)
- Rumelhart, D. E., & Hintont, G. E. (2019). Learning Representations by Back-Propagating Errors. *Cognitive Modeling*, 2, 3–6. <https://doi.org/10.7551/mitpress/1888.003.0013>
- Saaty, T. L. (2008). Relative measurement and its generalization in decision making why pairwise comparisons are central in mathematics for the measurement of intangible factors the analytic hierarchy/network process. *Revista de La Real Academia de Ciencias Exactas, Físicas y Naturales - Serie A: Matemáticas*, 102(2), 251–318. <https://doi.org/10.1007/BF03191825>
- Sandoval, E. (2021). Análisis de susceptibilidad de deslizamientos naturales con uso de redes neuronales artificiales, aplicado en la comuna de chaitén [Universidad de Concepción]. [http://webcache.googleusercontent.com/search?Q=cache:-rz\\_ckdlg7mj:repositorio.udec.cl/xmlui/bitstream/handle/11594/9015/TESIS%2520ANALISIS%2520DE%2520SUSCEPTIBILIDAD%2520DE%2520.Image.Marked.pdf%3Fsequence%3D1%26isallowed%3Dy+%&cd=2&hl=es&ct=clnk&gl=ec&cli](http://webcache.googleusercontent.com/search?Q=cache:-rz_ckdlg7mj:repositorio.udec.cl/xmlui/bitstream/handle/11594/9015/TESIS%2520ANALISIS%2520DE%2520SUSCEPTIBILIDAD%2520DE%2520.Image.Marked.pdf%3Fsequence%3D1%26isallowed%3Dy+%&cd=2&hl=es&ct=clnk&gl=ec&cli)
- Sassa, K., Tiwari, B., Liu, K.-F., mcsaveney, M., Strom, A., & Setiawan, H. (2018). *Landslide Dynamics: ISDR-ICL landslide interactive teaching tools : Volume 2: testing, risk management and country practices (Vol. 2)*.
- Sazli, M. 2006. A brief review of feed-forward neural networks. *Communications Faculty of Sciences University of Ankara. Series A2 – A3. Vol. 50. N° 1: 11-17*
- Sepúlveda, S. A. (1998). Metodología para evaluar el peligro por flujo de detritos en ambientes montañosos. [https://portalgeo.sernageomin.cl/Informes\\_PDF/RMET-147.pdf](https://portalgeo.sernageomin.cl/Informes_PDF/RMET-147.pdf)
- Sepúlveda, S.A., 2000. Metodología de Evaluación del Peligro de Flujos de Detritos en Ambientes Montañosos. *Revista Comunicaciones, Departamento de Geología, Universidad de Chile, N°51: 3-28.*
- Sepúlveda, S. A., Moreiras, S. M., Lara, M., & Alfaro, A. (2015). Debris flows in the Andean ranges of central Chile and Argentina triggered by 2013 summer storms: characteristics and consequences. *Landslides*, 12(1), 115–133. <https://doi.org/10.1007/s10346-014-0539-0>
- Süzen, M. L. & Doyuran, V. 2003. A comparison of the GIS based landslide susceptibility assessment methods: multivariate versus bivariate. *Springer – Verlag. Environmental Geology. Vol. 45: 665 – 679.*

- Tien Bui, D.; Anh Tuan, T.; Klempe, H.; Pradhan B. & Reyhaug I. 2015. Spatial prediction models for shallow landslide hazards: a comparative assessment of the efficacy of support vector machines, artificial neural networks, kernel logistic regression, and logistic model tree. *Landslides* Vol. 13: 361 - 378.
- UN CRED. (2020). Human cost of disasters (2000-2019). *Human Cost of Disasters*, 61, 1–2. <https://doi.org/10.1186/s12889>
- Van Westen, C. J., Rengers, N., Terlien, M. T. J., & Soeters, R. (1997). Prediction of the occurrence of slope instability phenomena through GIS-based hazard zonation. *International Journal of Earth Sciences*, 86(2), 404–414.
- Van Westen, C. J. 2002. Use of weights of evidence modeling for landslide susceptibility mapping. *International Institute for Geoinformation Science and Earth Observation (ITC)*. 21pp. Netherlands.
- Van Westen, C. J., Castellanos, E., & Kuriakose, S. L. (2008). Spatial data for landslide susceptibility, hazard, and vulnerability assessment: An overview. *Engineering Geology*, 102(3–4), 112–131. <https://doi.org/10.1016/j.enggeo.2008.03.010>
- Varnes, D. J. 1978. Slope movements types and processes. *Landslides analysis and control*. Schuster R. L. & Krizek R. J. editores. National Academy Press, Transportation Research Board Special Report N° 176: 9 – 33. Washington D. C.
- Varas, A. (1998). Fenómenos de remoción en masa mediante análisis de redes neuronales aplicada en el fiordo comau , región de los lagos , chile. 621.
- Villela. (2015). Universidad De Chile Facultad De Ciencias Físicas Y Matemáticas Departamento De Geología Desarrollo Estructural De La Cordillera Principal Al Suroeste Del Río Maipo, Sector De El Ingenio, Región Metropolitana, Chile (33°40'-33°50'S)
- Villela, B. F. (2017). Metodología para la evaluación de la susceptibilidad de fenómenos de remoción en masa mediante análisis de redes neuronales aplicada en el fiordo comau, región de los lagos, chile. Universidad de chile.
- Visvikis, D., Cheze Le Rest, C., Jaouen, V., & Hatt, M. (2019). Artificial intelligence, machine (deep) learning and radio(geno)mics: definitions and nuclear medicine imaging applications. *European Journal of Nuclear Medicine and Molecular Imaging*, 46(13), 2630–2637. <https://doi.org/10.1007/s00259-019-04373-w>
- Von Huene, R., Miller, J. J., & Dartnell, P. (2016). A possible transoceanic tsunami directed toward the U.S. west coast from the Semidi segment, Alaska convergent margin. *Geochemistry, Geophysics, Geosystems*, 17(3), 645–659. <https://doi.org/10.1002/2015GC006147>
- Wang, P. (2019). On Defining Artificial Intelligence. *Journal of Artificial General Intelligence*, 10(2), 1–37. <https://doi.org/10.2478/jagi-2019-0002>
- Wanker, M. S. (2014). Research Paper on Basic of Artificial Neural Network. *International Journal on Recent and Innovation Trends in Computing and Communication*, 2(1), 96–100.
- Wieczorek, G. F. (1996). Landslides: investigation and mitigation. Chapter 4-Landslide triggering mechanisms. *Transportation Research Board Special Report*, 247, 76–90.
- Yang, Z. R., & Yang, Z. (2014). Artificial Neural Networks. *Comprehensive Biomedical Physics*, 6, 1–17. <https://doi.org/10.1016/B978-0-444-53632-7.01101-1>
- Youd, T. L. (1985). Landslides caused by earthquakes: Discussion. *Bulletin of the Geological Society of America*, 96(8), 1091–1092. [https://doi.org/10.1130/0016-7606\(1985\)96<1091:LCBEDA>2.0.CO;2](https://doi.org/10.1130/0016-7606(1985)96<1091:LCBEDA>2.0.CO;2)
- Zhang, Z.; Beck, M. W.; Winkler, D. A.; Huang, B.; Sibanda, W. & Goyal, H. 2018. Opening the black box of neural networks: methods for interpreting neural network models in clinical applications. *Annals of Translational Medicine. Big Data Clinical Trial Column*. Vol 6. N° 11: 11 pp.