



**UNIVERSIDAD DE CONCEPCIÓN**  
**FACULTAD DE CIENCIAS QUÍMICAS**  
**DEPARTAMENTO CIENCIAS DE LA TIERRA**



**ANÁLISIS DE SUSCEPTIBILIDAD DE  
DESLIZAMIENTOS NATURALES CON USO DE REDES  
NEURONALES ARTIFICIALES, APLICADO EN LA  
COMUNA DE CHAITÉN, REGIÓN DE LOS LAGOS,  
CHILE**



*Memoria para optar al Título de Geólogo*

**Elizabeth Loreto Sandoval Fritz**

**Profesor Patrocinante:** Dr. Jorge Andrés Quezada Flory  
**Profesional Guía:** Msc. Lukas Georg Rohrbach  
**Profesores Comisión:** Msc. Abraham Elías González Martínez  
Sr. Ramiro Ulises Bonilla Parra

**Concepción, 2021**

# ÍNDICE

	Página
<b>RESUMEN</b>	
<b>1. INTRODUCCIÓN</b>	1
1.1. PLANTEAMIENTO DEL PROBLEMA	1
1.2. FINANCIAMIENTO	3
1.3. UBICACIÓN Y ACCESOS AL ÁREA DE ESTUDIO	3
1.4. OBJETIVOS	4
1.4.1. OBJETIVO GENERAL	4
1.4.2. OBJETIVOS ESPECÍFICOS	4
1.5. AGRADECIMIENTOS	4
<b>2. DESCRIPCIÓN DEL ÁREA DE ESTUDIO</b>	6
2.1. CLIMA Y VEGETACIÓN	6
2.2. GEOMORFOLOGÍA	6
2.2.1. GEOMORFOLOGÍA REGIONAL	6
2.2.2. GEOMORFOLOGÍA LOCAL	8
2.3. MARCO GEOLÓGICO	10
2.3.1. GEOLOGÍA REGIONAL	10
2.3.2. GEOLOGÍA LOCAL	11
2.3.2.1. ROCAS METAMÓRFICAS	12
2.3.2.2. ROCAS INTRUSIVAS	13
2.3.2.3. ROCAS ESTRATIFICADAS	14
2.3.2.4. DEPÓSITOS NO CONSOLIDADOS	14
2.3.3. CONTEXTO ESTRUCTURAL	14
<b>3. REVISIÓN BIBLIOGRÁFICA</b>	16
3.1. PROCESOS DE REMOCIÓN EN MASA	16
3.1.1. INTRODUCCIÓN	16
3.1.2. TIPOS DE REMOCIÓN EN MASA	16
3.1.2.1. SISTEMA DE CLASIFICACIÓN DE VARNES	16
3.1.2.2. OTROS SISTEMAS DE CLASIFICACIÓN	22
3.1.3. REMOCIONES EN MASA COMO PELIGRO GEOLÓGICO	23
3.1.3.1. TIPOS DE ZONIFICACIÓN	24
3.1.3.2. APLICACIÓN DE SIG EN LA ZONIFICACIÓN	27
3.2. ANÁLISIS DE SUSCEPTIBILIDAD	28
3.2.1. MÉTODOS CUALITATIVOS	28
3.2.1.1. MÉTODO GEOMORFOLÓGICO	28
3.2.1.2. MÉTODO DE PONDERACIONES	29
3.2.2. MÉTODOS CUANTITATIVOS	29
3.2.2.1. MÉTODOS ESTADÍSTICOS BIVARIADOS	29
3.2.2.2. MÉTODOS ESTADÍSTICOS MULTIVARIADOS	31
3.2.2.3. OTROS MÉTODOS	34
3.3. REDES NEURONALES ARTIFICIALES (RNA)	34

3.3.1. DEFINICIÓN	34
3.3.2. HISTORIA	35
3.3.3. INTELIGENCIA ARTIFICIAL (IA)	37
3.3.4. ARQUITECTURA	40
3.3.5. FUNDAMENTO MATEMÁTICO	42
3.3.6. APRENDIZAJE Y ANÁLISIS DE RNA	48
3.3.6.1. ETAPAS DE APRENDIZAJE	48
3.3.6.2. HERRAMIENTAS DE ANÁLISIS	49
3.3.7. RNA APLICADA EN EL ANÁLISIS DE SUSCEPTIBILIDAD	58
<b>4. METODOLOGÍA</b>	60
<b>4.1. ETAPA DE GABINETE 1 (PRE-TERRENO)</b>	60
4.1.1. DEFINICIÓN DEL ÁREA DE ESTUDIO	60
4.1.1.1. REVISIÓN CATASTRO NACIONAL	60
4.1.1.2. REVISIÓN CATASTRO REGIONAL	62
4.1.2. DETERMINACIÓN DEL MÉTODO PARA ANALISIS DE SUSCEPTIBILIDAD	64
4.1.3. CREACIÓN DE CATASTRO LOCAL	64
4.1.4. PRESELECCIÓN DE FACTORES CONDICIONANTES	69
<b>4.2. ETAPA DE TERRENO</b>	81
<b>4.3. ETAPA DE GABINETE 2 (POST-TERRENO)</b>	82
4.3.1. PREPARACIÓN DE DATOS	82
4.3.1.1. ACONDICIONAMIENTO DE VARIABLES CATEGÓRICAS	82
4.3.1.2. <i>DATASETS</i> DE <i>TRAINING</i> Y <i>TESTING</i>	83
4.3.1.3. GESTIÓN DE LOS <i>DATASETS</i> EN EXCEL	84
4.3.2. ANÁLISIS CON REDES NEURONALES ARTIFICIALES	86
4.3.2.1. RECURSOS COMPUTACIONALES	86
4.3.2.2. PREPARACIÓN Y GESTION DE DATOS EN RSTUDIO	86
4.3.2.3. ANÁLISIS DE ARRANQUE DE DESLIZAMIENTOS	87
4.3.2.4. ANÁLISIS DE ALCANCE DE DESLIZAMIENTOS	97
4.3.2.5. EVALUACIÓN DE OTRAS ZONAS DE CHILE	100
<b>5. RESULTADOS</b>	102
<b>5.1. RESULTADOS DE TERRENO</b>	102
<b>5.2. RESULTADOS DE ANÁLISIS CON RNA</b>	107
5.2.1. SUSCEPTIBILIDAD DE ARRANQUE DE DESLIZAMIENTOS	107
5.2.2. SUSCEPTIBILIDAD DE ALCANCE DE DESLIZAMIENTOS	110
5.2.3. MAPA INDICATIVO DE AMENAZA	113
<b>6. ANÁLISIS DE RESULTADOS</b>	116
<b>6.1. POSIBLES FACTORES CONDICIONANTES</b>	116
<b>6.2. SUSCEPTIBILIDAD CON RNA</b>	117
6.2.1. ANÁLISIS DEL MODELO DE ARRANQUE	117
6.2.2. ANÁLISIS DEL MODELO DE ALCANCE	121
<b>6.4. EVALUACIÓN DE APLICABILIDAD DE MODELOS</b>	125
6.4.1. SECTOR EL AMARILLO – LOS TURBIOS, CHAITÉN	125
6.4.2. SECTOR COÑARIPE – LAGO PELLAIFA, REGIÓN DE LOS RÍOS	128

<b>7. DISCUSIÓN</b>	129
<b>7.1. SELECCIÓN DE ÁREA DE ESTUDIO</b>	129
<b>7.2. ANÁLISIS CON REDES NEURONALES ARTIFICIALES</b>	130
<b>7.3. DISCUSIÓN DE RESULTADOS</b>	134
7.3.1. DESCARTE DE VARIABLES DE ARRANQUE	134
7.3.2. VARIABLES GEOLÓGICAS EXCLUIDAS DEL ESTUDIO	139
7.3.3. RENDIMIENTO DEL MODELO DE ARRANQUE	140
7.3.4. PROCESAMIENTO DE LAS RNA PARA ALCANCE	142
7.3.5. SELECCIÓN DE VARIABLES PARA EL ANÁLISIS DE ALCANCE	142
7.3.6. RENDIMIENTO DEL MODELO DE ALCANCE	144
7.3.7. CORRELACIÓN ARRANQUE-ALCANCE EN EL MIA	144
7.3.8. ESCALA DE VALIDEZ DEL MIA	145
7.3.9. APLICABILIDAD DE LOS MODELOS ENTRENADOS	145
<b>8. CONCLUSIONES Y RECOMENDACIONES</b>	147
<b>REFERENCIAS</b>	149
<b>ANEXO 1: SOFTWARES DE MODELACIÓN NUMÉRICA</b>	159
<b>ANEXO 2: GLOSARIO DE TÉRMINOS</b>	163
<b>ANEXO 3: VARIABLES PRESELECCIONADAS</b>	167
<b>ANEXO 4: FICHAS DE TERRENO “STORME”</b>	170
<b>ANEXO 5: FOTOGRAFÍA Y FOTOGRAMETRÍA AÉREA EN TERRENO</b>	182

## ÍNDICE DE FIGURAS

<b>Figura</b>	<b>Página</b>
1. 1. Mapa de ubicación del área de estudio	3
2. 1. Geomorfología de la Región de Los Lagos, según Börgel (1983)	7
2. 2. Geomorfología local	9
2. 3. Geología del área de estudio	12
3. 1. Esquemmatización de caída de rocas	18
3. 2. Volcamiento de rocas	18
3. 3. Esquemmatización de deslizamientos	19
3. 4. Ejemplos esquemáticos de Propagación Lateral	20
3. 5. Esquemas de remociones tipo Flujo	21
3. 6. Ejemplos esquemáticos de procesos de deformación de ladera	21
3. 7. Ejemplo Mapa Indicativo de Amenaza (MIA)	26
3. 8. Ejemplo Mapa de Intensidad (MDI)	27
3. 9. <i>Deep Learning</i> en la Inteligencia Artificial	39
3. 10. Esquemmatización de la arquitectura de una red neuronal artificial	40
3. 11. Red Neuronal Simple con retroalimentación y competición	41
3. 12. Esquemmatización del Perceptrón, la primera RNA	42

3.	13.	Representación de los pesos sinápticos en una red neuronal	43
3.	14.	Principales funciones utilizadas como función de activación en RNA	44
3.	15.	Estructura matemática interna de una RNA	45
3.	16.	Funciones de Error en una RNA	46
3.	17.	Esquema simple de la retropropagación	47
3.	18.	Reducción del Error mediante derivadas parciales con respecto al peso	47
3.	19.	Gráfica ejemplo de <i>General Weights</i>	51
3.	20.	Gráfica ejemplo del algoritmo de Garson	52
3.	21.	Comparación gráficas de Garson y Olden	53
3.	22.	Gráfica ejemplo <i>Lek Profile</i>	54
3.	23.	Gráfica ejemplo de <i>Pairwise Plot</i> .	55
3.	24.	Descripción de gráfica ROC/AUC	56
3.	25.	Interpretación de gráfica ROC/AUC	57
3.	26.	Arquitectura de una RNA aplicada a Análisis de Susceptibilidad de RM	59
3.	27.	Diagrama de flujo para la aplicación de RNA en análisis de susceptibilidad de deslizamientos	59
4.	1.	Distribución provincial de remociones tipo deslizamiento del Catastro Nacional de Remociones en Masa de SERNAGEOMIN	61
4.	2.	Catastro corregido de deslizamientos de tipo natural	63
4.	3.	Catastro poligonal de deslizamientos superficiales en el área de estudio	66
4.	4.	Catastro de deslizamientos en formato punto	67
4.	5.	Catastros binarios de arranque y alcance de deslizamientos	68
4.	6.	Espectro electromagnético	74
4.	7.	Explicación ilustrativa del NDVI	75
4.	8.	Mapa de isópacas de depósito de tefra de la erupción volcán Chaitén 2008-2009	77
4.	9.	Descripción gráfica de la variable Gradiente Topográfico (GT)	80
4.	10.	Problemas de accesibilidad del área de estudio	81
4.	11.	Ubicación de puntos de control y rutas visitadas en la campaña de terreno	82
4.	12.	Código generalizado para entrenamiento de red neuronal con <i>neuralnet package</i> .	88
4.	13.	Gráfico de jerarquización de variables	91
4.	14.	Gráfico segundo proceso de jerarquización de variables	92
4.	15.	Distribución acumulativa de resultados de una RNA aplicada al análisis de deslizamientos	96
4.	16.	Alcance de deslizamientos Canalizados y No-canalizados	97
4.	17.	Jerarquización de variables Análisis de Alcance	99
4.	18.	Ubicación de zonas de evaluación de redes neuronales	101
5.	1.	Ubicación de deslizamientos controlados en terreno	103
5.	2.	Deslizamientos visitados y descritos en terreno	104
5.	3.	Suelo y vegetación en los deslizamientos del área	105
5.	4.	Ejemplo de depósito de deslizamiento	106
5.	5.	Arquitectura Red Neuronal para análisis de Arranque	107
5.	6.	Mapa de susceptibilidad de Arranque de deslizamientos	109
5.	7.	Gráfica ROC/AUC del modelo "ANN_26"	110
5.	8.	Arquitectura de Red Neuronal para análisis de Alcance	111
5.	9.	Mapa de susceptibilidad de Alcance de deslizamientos	112
5.	10.	Gráfica ROC/AUC del modelo "ALC.F.8"	113
5.	11.	Mapa Indicativo de Amenaza para la comuna de Chaitén, escala 1:150.000	114

5.	12.	Umbral de clasificación para el Mapa Indicativo de Amenaza	115
6.	1.	Contraste temporal en imágenes satelitales del área de estudio.	116
6.	2.	<i>Pairwise Plot</i> para el modelo “ANN_26”.	118
6.	3.	Gráfica <i>General Weights</i> para “ANN_26”.	119
6.	4.	Gráfica de importancia de Olden para el modelo “ANN_26”.	119
6.	5.	Gráfica de Sensibilidad de <i>Lek</i> para el modelo “ANN_26”.	120
6.	6.	<i>Pairwise Plot</i> para el modelo “ALC.F.8”	121
6.	7.	Gráfica <i>General Weights</i> para el modelo “ALC.F.8”.	122
6.	8.	Gráfica de importancia de Olden para el modelo “ALC.F.8”.	123
6.	9.	Gráfica de Sensibilidad de <i>Lek</i> para el modelo “ALC.F.8”.	124
6.	10.	Deslizamiento Valle El Amarillo.	126
6.	11.	Evaluación de MIA en sector El Amarillo – Los Turbios, Chaitén.	127
6.	12.	Evaluación de MIA en sector Coñaripe – Lago Pellaifa.	128
7.	1.	Diagrama de flujo del proceso metodológico implementado	131
7.	2.	Comparación geoespacial entre variables categóricas y modelos descartados de RNA	135
7.	3.	<i>Lek Profile</i> Modelo ANN_1 que ilustra la sensibilidad de la variable TEPHRA	137
7.	4.	Espesor de tefra del Volcán Chaitén (2008-2009) contrastado con el catastro de Arranque de deslizamientos	138
7.	5.	Comparación de gráficas ROC/AUC entre un modelo de RNA deficiente (ANN3) y el modelo final seleccionado (ANN_26)	141
7.	6.	<i>Lek Profiles</i> de los Modelos ALC.F.5 y ALC.F.8	143

## ÍNDICE DE TABLAS

Tabla	Página	
3. 1.	Sistema de clasificación de RM de Varnes modificado por Hungr et al. (2014)	17
3. 2.	Clasificación de remociones en masa según velocidad de Cruden & Varnes (1996)	22
3. 3.	Glosario para la formación de nombres de movimientos en masa.	23
3. 4.	Cronología de contribuciones en el desarrollo de las Redes Neuronales Artificiales	36
4. 1.	Clasificación de deslizamientos para el análisis, filtrado y evaluación de calidad del Catastro Nacional de Remociones en Masa de SERNAGEOMIN (2017)	61
4. 2.	Factores condicionantes preseleccionados para el análisis de deslizamientos	70
4. 3.	Procedimiento para la obtención de ráster TWI	78
4. 4.	Variables categóricas y su conversión numérica	83
4. 5.	Transformación de variables categóricas	84
4. 6.	Estructura de <i>datasets</i> finales	85
4. 7.	Jerarquización de variables (Parte I)	90
4. 8.	Jerarquización de variables (Parte II)	90
4. 9.	Modelos de redes neuronales ejecutados para análisis de Arranque	94
4. 10.	Modelos de redes neuronales ejecutados para análisis de Alcance	99
5. 1.	Parámetros RNA del modelo “ANN_26”	108
5. 2.	Error asociado al mapa de susceptibilidad de Arranque	109

5.	3.	Parámetros RNA del modelo “ALC.F.8”	111
5.	4.	Error asociado al mapa de susceptibilidad de Alcance	112



# RESUMEN

La singular combinación de características geológicas, geomorfológicas y climáticas presentes en Chile promueven una persistente modelación del relieve, dando paso a la continua ocurrencia de procesos de remoción en masa; fenómenos considerados un peligro geológico, que requiere ser analizado y estimado. Por tal razón, este proyecto de memoria pretende contribuir al estudio de deslizamientos de origen natural en Chile, desarrollando una estrategia metodológica cuantitativa para la estimación de dicho tipo de remoción.

En base a la distribución de registros de remociones en masa (RM) a nivel nacional y regional, se toma como zona de estudio la localidad de Chaitén ubicada en la Región de los Lagos, entre los 42°50' y 43°03' lat. S, y los 72°27' y 72°50' long. W, emplazada en los Andes Norpatagónicos, donde se desarrolla un clima temperado hiper húmedo, que propicia el desarrollo de antiguos y densos bosques temperados, de tipo Patagónico norte y Valdiviano, con un relieve controlado por la tectónica asociada al Sistema de Fallas Liquiñe-Ofqui (SFLO), el modelado glacio-fluvial y por procesos volcánicos de la Zona Volcánica Sur Sur, cuyos principales representantes en el sector son los volcanes Chaitén y Michinmahuida. Geológicamente, el área de estudio se emplaza en los dominios del Batolito Norpatagónico, cuyas rocas graníticas miocenas en conjunto con el complejo acrecionario metamórfico paleozoico conforman las escarpadas montañas donde se llevan a cabo los procesos de remoción estudiados. Estos corresponden principalmente a deslizamientos traslacionales (planares) de suelo y vegetación, fluidizados, de grandes dimensiones, cuya ocurrencia reciente se registra desde el año 2013. Si bien son diversos los tipos de zonificación y metodologías que se pueden implementar para el análisis de estos procesos, el presente estudio se enfoca en la realización de mapas de susceptibilidad del terreno orientados a la elaboración de un Mapa Indicativo de Amenaza (MIA) mediante el uso de Redes Neuronales Artificiales (RNA) como método de regresión.

Las RNA son sistemas informáticos que utilizan una configuración matemática inspirada en la red neurológica animal. Se trata de una interconexión de neuronas que colaboran entre sí para producir un estímulo de salida. Dichas neuronas se basan en un conjunto de algoritmos diseñados para encontrar patrones, interpretando, etiquetando y agrupando datos. Son una técnica útil en la solución de problemas de regresión y clasificación en diversas áreas. Estas estructuran sus nodos (o neuronas) de manera ordenada y agrupadas en capas, siendo necesario que contengan al menos los tres tipos: (1) Entrada, (2) Oculta (1 o más), y (3) Salida, conformando una arquitectura llamada *Multilayer Perceptron* (MLP). El trabajo con RNA comprende 3 etapas esenciales: (1) Entrenamiento, (2) Testeo, y (3) Análisis final. Las dos primeras se encargan de configurar la RNA y evaluar su rendimiento (ROC/AUC), respectivamente; y cada una requiere un set de datos distinto proveniente del conjunto total de datos disponibles para la evaluación del problema. En ambos casos la información debe contener valores de entrada (las que explican el fenómeno) y de salida (valores esperados), con el fin de orientar el aprendizaje de la red (*Supervised Learning*). Luego, se efectúa el análisis final sobre un conjunto de datos a los que se busca la solución otorgada por la red resultante. No obstante, las RNA tradicionalmente se consideran "*black boxes*", debido a la dificultad para comprender el análisis interno de éstas; por ello, es necesario utilizar diferentes herramientas gráficas que han sido desarrolladas para develar y evaluar el procesamiento de cada RNA (*Pairwise Plot*, *General Weights*, Importancia de Garson y de Olden, y sensibilidad de Lek), y así seleccionar la que se ajuste de forma óptima a los datos.

En la aplicación de las RNA para análisis de susceptibilidad de RM, las variables de entrada corresponden a los factores condicionantes del terreno (recurso digital SIG), mientras que la variable de respuesta o de salida equivale a la ocurrencia de las RM, cuyo comportamiento es binario, es decir, puede ocurrir / no ocurrir (1/0). Para el caso de estudio, se realiza una doble evaluación de susceptibilidad, de Arranque de deslizamientos y del Alcance que puede lograr el material removido. En ambos casos se inicia con la confección de un catastro de eventos y la preselección de variables explicatorias respectivas (11 y 6 variables), información que al ser cruzada origina los correspondientes *datasets*, que son subdivididos para entrenamiento y testeo (60% y 40%). Dicha información es utilizada para el aprendizaje y calibración de las RNA respectivas, programadas con el paquete de funciones "neuralnet" en RStudio; efectuando un total de 30 iteraciones para el Arranque y 10 para Alcance. En cada caso se descartan variables de acuerdo a observaciones en terreno y el rendimiento de los modelos en base a las gráficas y mapas asociados, para finalmente seleccionar un modelo óptimo de RNA. De acuerdo a esto, el Arranque puede ser explicado por los factores Pendiente, Pendiente Senoidal, Rugosidad, NDVI y TWI, mientras que el Alcance puede ser estimado con las variables Densidad de Drenaje, Pendiente, TWI, Gradiente Topográfico y Curvatura. Los errores obtenidos para los modelos finales, son de 3.2% para Arranque (AUC=0.99) y 11.9% para Alcance (AUC=0.96). Las clases más altas de ambos mapas de susceptibilidad son conjugados en un MIA. Luego, las RNA entrenadas se evalúan en 2 zonas diferentes de Chile; una cercana al área de estudio y otra lejana. Esto determina que una red entrenada puede generar buenas estimaciones en zonas aledañas; no así en zonas con un diferente contexto geológico y geomorfológico. De esta forma, se puede considerar las RNA como una herramienta útil para la estimación de amenazas de forma remota y de bajo costo, aplicable a cualquier escala, la cual dependerá de la resolución y calidad de los recursos utilizados. Así, el MIA obtenido es un producto válido para una escala 1:150.000.



# 1. INTRODUCCIÓN

## 1.1. PLANTEAMIENTO DEL PROBLEMA

La singular combinación de características geológicas, geomorfológicas y climáticas presentes en Chile, no tan solo le otorgan una gran riqueza natural, expresada en la amplia diversidad de paisajes y ecosistemas existentes a lo largo y ancho del territorio nacional, sino que, además, dichas cualidades promueven una persistente modelación del relieve. Esto en muchos casos involucra la generación de procesos gravitacionales o de remoción en masa (RM), fenómenos que constituyen uno de los peligros geológicos más comunes en nuestro país, y que históricamente han sido causantes de grandes desastres. Tradicionalmente y en términos generales, se distinguen 6 clases de dichos procesos, de acuerdo a lo propuesto por Varnes (1958, 1978), quien diferencia por el tipo de movimiento: Caídas o desprendimientos, Deslizamientos, Flujos, Volcamientos, Extensiones Laterales y Complejos. Si bien esta clasificación y sus variantes posteriores (Cruden & Varnes, 1996; Hungr *et al.* 2014) es la más aceptada en el mundo de habla inglesa e hispana, existen otros sistemas de clasificación en función de variables tales como las características geotécnicas (Hutchinson, 1988; Hungr *et al.* 2001), el grado de deformación del bloque removido, o incluso el grado de rapidez y/o espontaneidad de la remoción; atributos igualmente importantes en la caracterización de dichos fenómenos.

Considerando la capacidad de los procesos de RM para afectar negativamente asentamientos humanos y la infraestructura asociada a ellos, nace la necesidad de comprender y analizar este tipo de peligros, con el fin de predecir o estimar espacial y temporalmente la ocurrencia, magnitud y alcance de estos, mediante la generación de mapas de zonificación de peligro y riesgo, simulaciones numéricas de los procesos, entre otros. Tales estudios representan la base para la implementación de obras de mitigación, planes de emergencia o alerta temprana, y planificación territorial.

Aproximadamente desde fines de los años 70's, numerosos estudios alrededor del mundo (por ejemplo, Carrara, 1983; Bonham-Carter & Agterberg, 1990; Van Westen, 1993, 2002; Guzzetti *et al.* 1997; Sepúlveda, 2000; Süzen & Doyuran, 2003; Lara, 2007; Pradhan & Lee, 2010) han contribuido al entendimiento, análisis y zonificación de los peligros de remoción en masa, formulando y poniendo en práctica diversas metodologías de tipo cualitativo, cuantitativo y mixtas. Muchos de estos trabajos han sido efectuados para la evaluación de RM en un sentido

general, sin embargo, para realizar un análisis de mayor detalle y con resultados aún más cercanos a la realidad, es preciso dirigir el estudio a un tipo específico de remoción, ya que el comportamiento reológico y los factores físicos (naturales o antrópicos) que condicionan su generación, son diferentes. A lo anterior, se suma la necesidad de evaluar de manera particular estos procesos y metodologías en cada nueva zona geográfica donde se requiera este tipo de análisis, debido a la configuración particular de características geológicas, morfológicas y climáticas de cada región.

Los deslizamientos, entendidos como “movimientos 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” (Varnes, 1978), corresponden a uno de los procesos de RM más recurrentes y con mayor registro de fatalidades en nuestro país, después de los flujos. De acuerdo a Marín *et al.* (2018), a nivel país se contabiliza un total de 164 víctimas fatales a causa de deslizamientos en un período de 90 años, con la región de Los Lagos liderando el ranking de fatalidades con un total de 74 personas. Si bien, muchas veces esta clase de remociones son provocadas o influenciadas por intervención humana, y dependen de una correcta aplicación de estudios geotécnicos previos que minimicen la inestabilidad, es de interés el comprender la ocurrencia y comportamiento de los deslizamientos en escenarios completamente naturales. Es decir, previo a cualquier tipo de intervención humana (por ejemplo, instalación o expansión de poblados, la construcción de obras civiles, implementación de proyectos mineros, hidroeléctricos, entre otros), se requiere caracterizar, estimar y zonificar la susceptibilidad intrínseca del terreno ante este tipo de remociones, y el grado de peligro asociado.

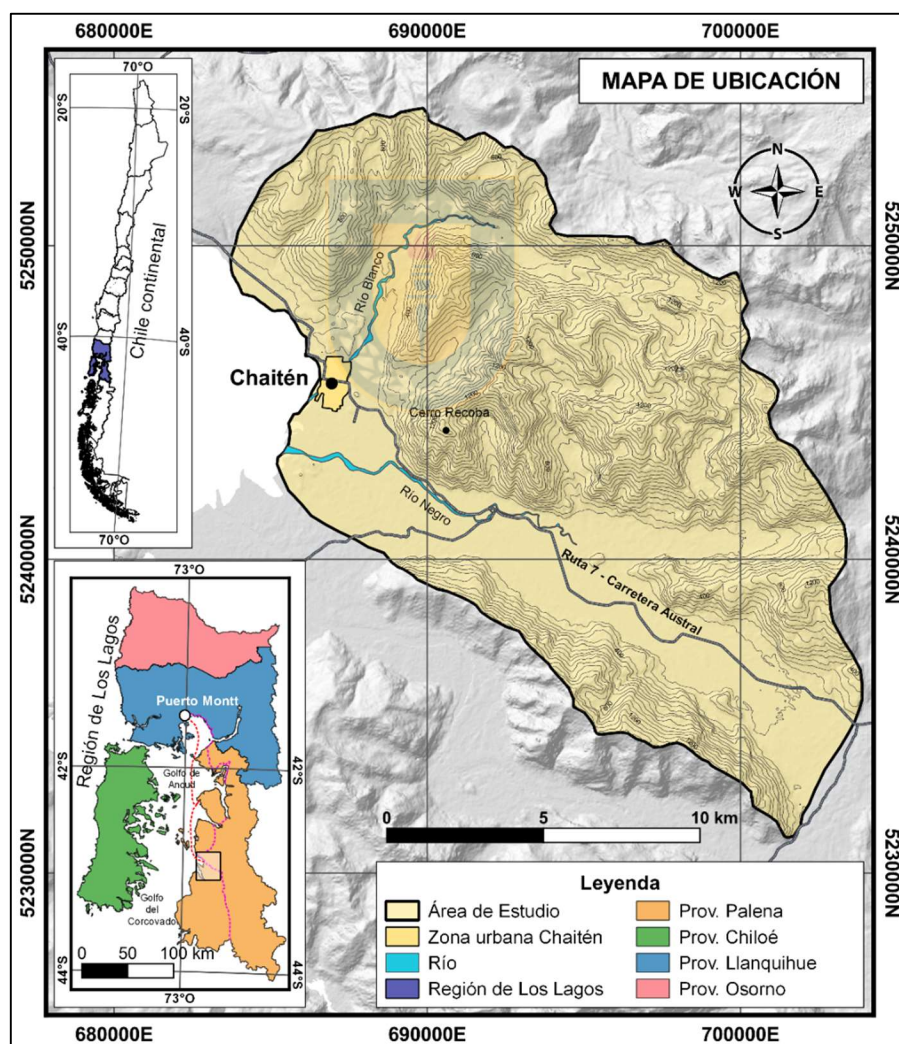
Este proyecto de memoria pretende contribuir al estudio de deslizamientos de origen natural en Chile, desarrollando una estrategia metodológica cuantitativa para el análisis de dicho tipo de remociones. Para esto se seleccionarán y adaptarán herramientas computacionales descritas en la literatura científica para estimar la susceptibilidad ante estos eventos, de la forma más objetiva posible, en una zona determinada de Chile. De esto se desprenderá la elaboración de un Mapa Indicativo de Amenaza, el cual señalará de forma diferenciada aquellas zonas con alta susceptibilidad de originar deslizamientos (Arranque) y aquellas con potencial de ser afectadas ya sea por el transporte o depósito del material removido (Alcance). Posteriormente esto será evaluado en otras zonas del territorio nacional, con el fin de definir los alcances de la metodología y modo de empleo del producto obtenido.

## 1.2. FINANCIAMIENTO

Este proyecto será financiado en su totalidad por la empresa consultora GEOTEST Chile SpA, quien genera el requerimiento de este estudio, y da la posibilidad de llevarlo a cabo como trabajo de memoria de título.

## 1.3. UBICACIÓN Y ACCESOS AL ÁREA DE ESTUDIO

El área de estudio se ubica en la Provincia de Palena, Región de Los Lagos, Chile. Específicamente se localiza en la comuna de Chaitén, abarcando una superficie aproximada de 256 Km<sup>2</sup> entre los 42°50' y 43°03' lat. S, y los 72°27' y 72°50' long. W (Figura 1.1).



**Figura 1.1: Mapa de ubicación del área de estudio.** Se muestra la topografía del área de estudio con una equidistancia altimétrica de 80 metros. Las rutas de acceso se muestran en el mapa regional, en rojo la vía marítima y en fucsia la Ruta 7 o Carretera Austral.

Para llegar al área se cuenta con 2 accesos principales desde el norte del país. En ambos casos se requiere como punto de partida en la ciudad de Puerto Montt, localidad a la que se puede llegar desde Santiago de Chile ya sea por tierra, mediante la Ruta 5 Sur, o bien, vía área directa. Desde aquí es posible dirigirse a Chaitén vía terrestre por la Ruta 7 (Carretera Austral), o bien, tomando la ruta más directa vía marítima desde el puerto Angelmó abordando una barcaza destino a Chaitén con parada en Caleta Ayacara. En el primer caso, la duración de viaje es de aproximadamente 12 horas, mientras que mediante barcaza es un viaje de 9 horas al que se puede acceder previa compra de tickets en sólo 2 horarios al día.

## **1.4. OBJETIVOS**

### **1.4.1. OBJETIVO GENERAL**

Desarrollar un procedimiento metodológico para el análisis de deslizamientos de origen natural en Chile.

### **1.4.2. OBJETIVOS ESPECÍFICOS**

- Seleccionar y llevar a cabo una metodología cuantitativa para evaluación de susceptibilidad.
- Generar un mapa de susceptibilidad de Arranque de deslizamientos.
- Generar un mapa de susceptibilidad de Alcance de deslizamientos.
- Elaborar un Mapa Indicativo de Amenaza.
- Discutir la aplicabilidad y extrapolación de la metodología en Chile.

## **1.5. AGRADECIMIENTOS**

Quiero agradecer al equipo de GEOTEST por haberme dado la confianza y la oportunidad de realizar mi memoria de título con ellos y ellas, y por el financiamiento otorgado para la realización de la etapa de terreno. Muchas gracias a Lukas Rohrbach por la buena voluntad que tuvo desde un principio en mi solicitud, y por el constante acompañamiento durante todo este proceso. De forma especial quiero agradecer a Andrea Segura, quien me acompañó, alentó y asesoró en buena parte de todo mi trabajo, volviéndose alguien en quien pude encontrar una buena amiga. Muchas gracias a Marcela Vollmer y Anne Schauss por su recibimiento cálido, alegre y muy profesional al inicio de este proyecto, gracias a ambas por su consejo y guía.

Igualmente quiero agradecer a mi profesor Jorge Quezada por su buena disposición, la confianza que ha mostrado en mi trabajo desde el primer día, y por el apoyo en esto que significó un gran desafío para mí. Así también, quiero agradecer a la señora Carolina Rojas por la excelente gestión, buena disposición y simpatía que siempre ha tenido conmigo a la hora de realizar trámites y pedirle orientación. Muchas gracias también al profesor Abraham González por la calidez y apoyo que me brindó al comienzo de mi búsqueda de un tema de memoria, por su constante consejo y cercanía.

Mis mayores agradecimientos son para mis padres, Carmen y Modesto, quienes han sido mis grandes pilares para poder llegar a esta instancia; gracias por la vida y por su amor, por su comprensión y apoyo, y por siempre haberme alentado a ser mejor y tener grandes aspiraciones en la vida. Gracias a mi abuelo, mi papito, por siempre desearme lo mejor y recibirme siempre con una sonrisa y un cálido abrazo, y por las largas charlas llenas de anécdotas que me enseñan de la vida.

A Diego, cuánto he de agradecer a este perfecto compañero, que me ha dado su amor, su cariño, comprensión desde que di mis primeros pasos en la universidad. Gracias por tantos buenos momentos en todo este viaje que recorrimos juntos para convertirnos en geólogos. Muchas gracias por siempre apoyarme en mis estudios, por confiar siempre en mis capacidades, alentarme y por prestarme tanta ayuda en cada una de las etapas de mi formación profesional. Gracias por ser mi pololo y mejor amigo.

Todo este proceso no habría sido lo mismo sin el apoyo y la compañía de mis grandes amigas y amigos. Muchas gracias a mi grupito favorito, mis geoamigos Yael, Jhonny, Danitza, Esteban, Belén y Javi; también a las “*amikas*” Pilar, Rommy, Valeria, Gabriela; y a mis amigotes, Paulo y René. Gracias a todas y todos por su amistad, por tantos buenos recuerdos que creamos juntos en estos años de universidad, y por todo el apoyo mutuo que nos dimos para salir adelante. Cada uno de ustedes tiene un espacio en mi corazón.

Finalmente quiero agradecer por el constante aliento y apoyo a mis amigas de la vida Constanza y Valeska, gracias por ser parte de mi vida. Y finalmente, gracias a Melissa, por una amistad espontánea y sincera, que se transformó en un gran apoyo para sobrellevar el trabajo de memoria en tiempos de pandemia; gracias por tantas risas, conversas y buena onda.

## 2. DESCRIPCIÓN DE ÁREA DE ESTUDIO

### 2.1. CLIMA Y VEGETACIÓN

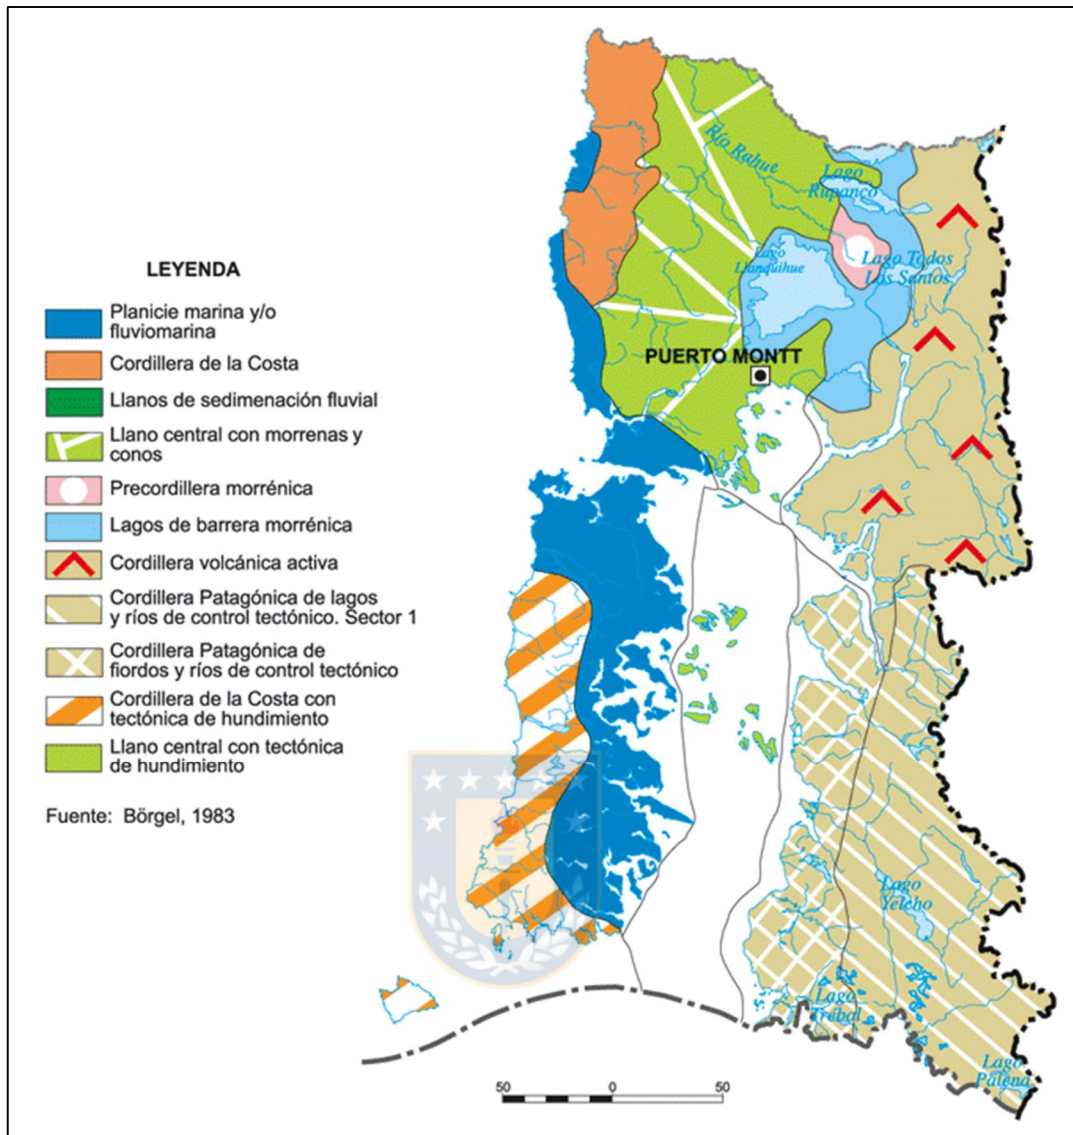
El área de estudio exhibe un clima temperado hiper húmedo, con una isoterma 0°C ubicada aproximadamente a los 1.000 m s.n.m., un ciclo estacional modesto, y un promedio de precipitación anual que varía entre 5.000 y 10.000 mm (Garreaud *et al.*, 2013). De acuerdo al estudio realizado por R&Q Ingeniería (2007), en la zona domina un clima Marino Húmedo Patagónico, el cual se caracteriza por presentar en invierno un promedio de temperaturas mínimas en el mes más frío entre -29°C y 2.9°C, y el promedio de máximas diarias en el mismo mes, entre 5°C y 10°C.

Las condiciones climáticas antes descritas propician el desarrollo de una abundante y densa vegetación, la cual es dominada por antiguos bosques temperados siempreverdes, de los tipos Patagónico norte y Valdiviano (Luebert & Pliscoff, 2006; Swanson *et al.*, 2013; Veblen *et al.*, 1983 y Veblen *et al.*, 1996 en Moreno-González *et al.*, 2019). Dichos bosques se componen principalmente por árboles de hoja perenne tales como Coihue, Tapa, Avellano, Luma, Arrayán, Canelo, Ulmo y Tenío (*Nothofagus dombeyi*, *Laureliopsis philippiana*, *Gevuina avellana*, *Amomyrtus luma*, *Luma apiculata*, *Drymis winteri*, *Eucryphia cordifolia* y *Weinmannia trichosperma*, respectivamente), cuyas copas normalmente se disponen en variadas capas y se pueden encontrar antiguos ejemplares que alcanzan hasta 40m de altura. Así mismo, el sotobosque (apegado al suelo) está densamente cubierto por helechos como *Lophosoria quadripinnata* y *Blechnum magellanicum*, plantones, arbustos y bamboo como *Chusquea spp.* Comúnmente conocido como Quila (Moreno-González *et al.*, 2019)

### 2.2. GEOMORFOLOGÍA

#### 2.2.1. GEOMORFOLOGÍA REGIONAL

A nivel regional, la zona se enmarca dentro de la “Región patagónica y polar del inlandsis antártico”, de acuerdo a Börgel (1983), la cual corresponde a un relieve controlado por tectónica de bloques con una subsecuente erosión y modelado glacial. De forma más específica, el mismo autor diferencia subregiones morfológicas, situándose el área de estudio en la subregión de la Cordillera patagónica del Pacífico con ríos y fiordos de control tectónico (Figura 2.1).



**Figura 2.1: Geomorfología de la Región de Los Lagos, según Börgel (1983).** Se presentan las diferentes regiones geomorfológicas que se distinguen en la Región de Los Lagos. Toma de Educar Chile (fuente digital).

Esta subregión morfológica se sitúa al Este de la zona insular y de los grandes canales australes, extendiéndose desde límite norte del fiordo Comau, frente al Golfo de Ancud, hasta el extremo sur de la Región de Los Lagos en Puerto Escondido.

Se trata de una continuación de la Cordillera de los Andes, que evidencia la acción de diversos procesos erosivos, principalmente de acción glacial, que han propiciado su descenso abrupto hacia el mar mediante la formación de amplios valles y fiordos, exhibiendo relieves escarpados, pero con relieves de baja y mediana altura, que no superan los 2500 m s.n.m. Este tipo de relieve incluye numerosos ventisqueros en su porción oriental; el más cercano al área de

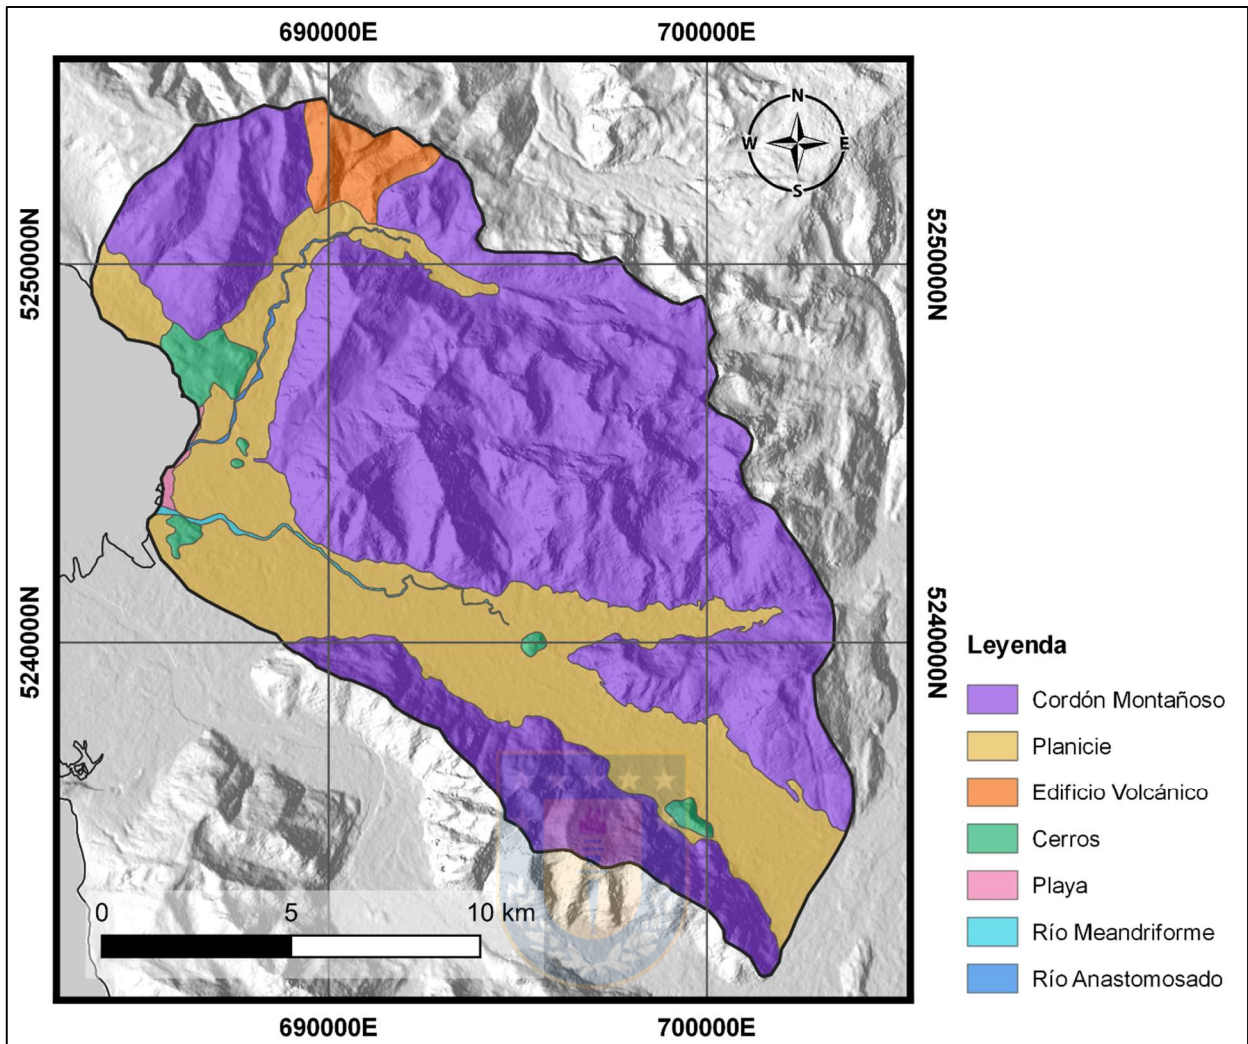
estudio corresponde al Ventisquero El Amarillo, que nace desde las laderas del Volcán Michinmahuida y da origen al Río El Amarillo ubicado en dirección NS al este del área de estudio.

Esta zona también exhibe un no despreciable modelado de origen volcánico, pudiéndose distinguir de norte a sur, importantes relieves como lo son los volcanes Huequi (1318 m s.n.m.), Michinmahuida (1835 m s.n.m.), Chaitén (962 m s.n.m.), Corcovado (2300 m s.n.m.) y Yanteles (2042 m s.n.m.), todos ellos ubicados a poca distancia de la costa. En específico, el Volcán Chaitén, el más cercano al área de estudio, corresponde al relieve que divide las cuencas de los ríos Rayas al Norte, y Chaitén (o Blanco) al Sur; se trata de un edificio volcánico tipo caldera de explosión, abierta hacia el Sur, dentro de la cual se halla un domo riolítico.

### **2.2.2. GEOMORFOLOGÍA LOCAL**

En el área de estudio es posible identificar 2 rasgos geomorfológicos mayores: planicies, y un prominente cordón montañoso (Figura 2.2). Ambos enmarcados en un contexto de fuerte control tectónico y de modelado glacial. Las primeras se conforman principalmente por depósitos fluviales, fluvio-glaciares y laháricos, pueden ser diferenciadas en 2. La principal, se sitúa en un amplio valle de dirección NW-SE cuya extensión lateral varía entre 1.7 y 3.5 Km aproximadamente, y alberga en su porción septentrional un río de característica meandriforme llamado Río Negro. La segunda planicie, que se distingue por tener una amplitud menor (800 – 1300 m), se ubica en el valle del Río Blanco, curso de agua de tipo anastomosado, elongado en dirección NNE-SSW, que actualmente disecta un nivel de terrazas conformadas por depósitos de tipo laháricos originados por el colapso de la columna eruptiva del Volcán Chaitén el año 2008, como parte de la violenta actividad que este registró entre los años 2008 y 2009.





**Figura 2.2: Geomorfología local.** Se presentan los rasgos geomorfológicos que conforman el área de estudio. Elaboración propia.

El cordón montañoso es la característica geomorfológica más distintiva de la zona, con alturas que alcanzan los 1200 a 1300 m s.n.m., laderas cuya pendiente media se sitúa entre 35° y 45° con máximas que alcanzan los 80° de inclinación en las escarpadas crestas, y un complejo entramado de quebradas y depresiones en altura. Las rocas que lo conforman son parte del Batolito Norpatagónico, el cual se encuentra fuertemente tectonizado por grandes estructuras de orientación NNE-SSW y NW-SE, las cuales controlan el escenario geomorfológico general de la zona (Muñoz, 2019).

Otro rasgo presente en el área, en proporción menor, corresponde a la apertura Sur de la caldera del Volcán Chaitén, desde la cual nace un estero tributario del Río Blanco. Del mismo modo, en menor proporción se identifican cerros y lomas ubicados en sectores aledaños a la

zona urbana de la comuna de Chaitén. Se trata de formaciones rocosas graníticas, remanentes del modelado glacial. Y en último lugar, de forma menos desarrollada es posible distinguir la presencia de playas, constituidas en gran parte por el material volcánico de origen lahárico en la desembocadura del Río Blanco.

## **2.3. MARCO GEOLÓGICO**

### **2.3.1. GEOLOGÍA REGIONAL**

La ubicación del área de estudio dentro del margen Andino, corresponde a la parte Norte de la Patagonia chilena, donde es posible distinguir 3 unidades morfológicas principales: Cordillera de la Costa, Valle Central sumergido y Cordillera Principal (Hervé *et al.*, 2007; Echaurren *et al.*, 2016).

La Cordillera de la Costa, correspondiente a la Isla Grande Chiloé en la latitud del área de estudio, se caracteriza por ser una morfoestructura de baja elevación que se extiende paralela a la fosa, exponiendo un prisma de acreción carbonífero metamorfozido entre fines del Paleozoico y fines del Triásico (Hervé *et al.*, 2007). Habría sido exhumado en primera instancia durante el Cretácico tardío, para posteriormente ser alzado por tectonismo Neógeno (Duhart & Adriasola, 2008; Nielsen & Glodny, 2009). Este rasgo se separa de la Cordillera Principal por el Valle Central; una depresión alargada que en esta zona se encuentra sumergida bajo el mar, y da origen a los Golfos de Ancud por el norte y del Corcovado en la porción sur, frente a la comuna de Chaitén.

El Valle o Depresión Central es una cuenca intermontana delimitada por la Isla de Chiloé al W y el Batolito Norpatagónico al E, y constituye una prolongación de la cuenca *onshore* Osorno-Llanquihue (McDonough *et al.*, 1997), definiendo un depocentro de aproximadamente 70 Km de ancho paralelo a la fosa, el cual contiene cerca de 4 Km de rocas marinas volcanoclásticas cenozoicas y sedimentos de origen glacial (Jordan *et al.*, 2001; Duhart & Adriasola, 2008).

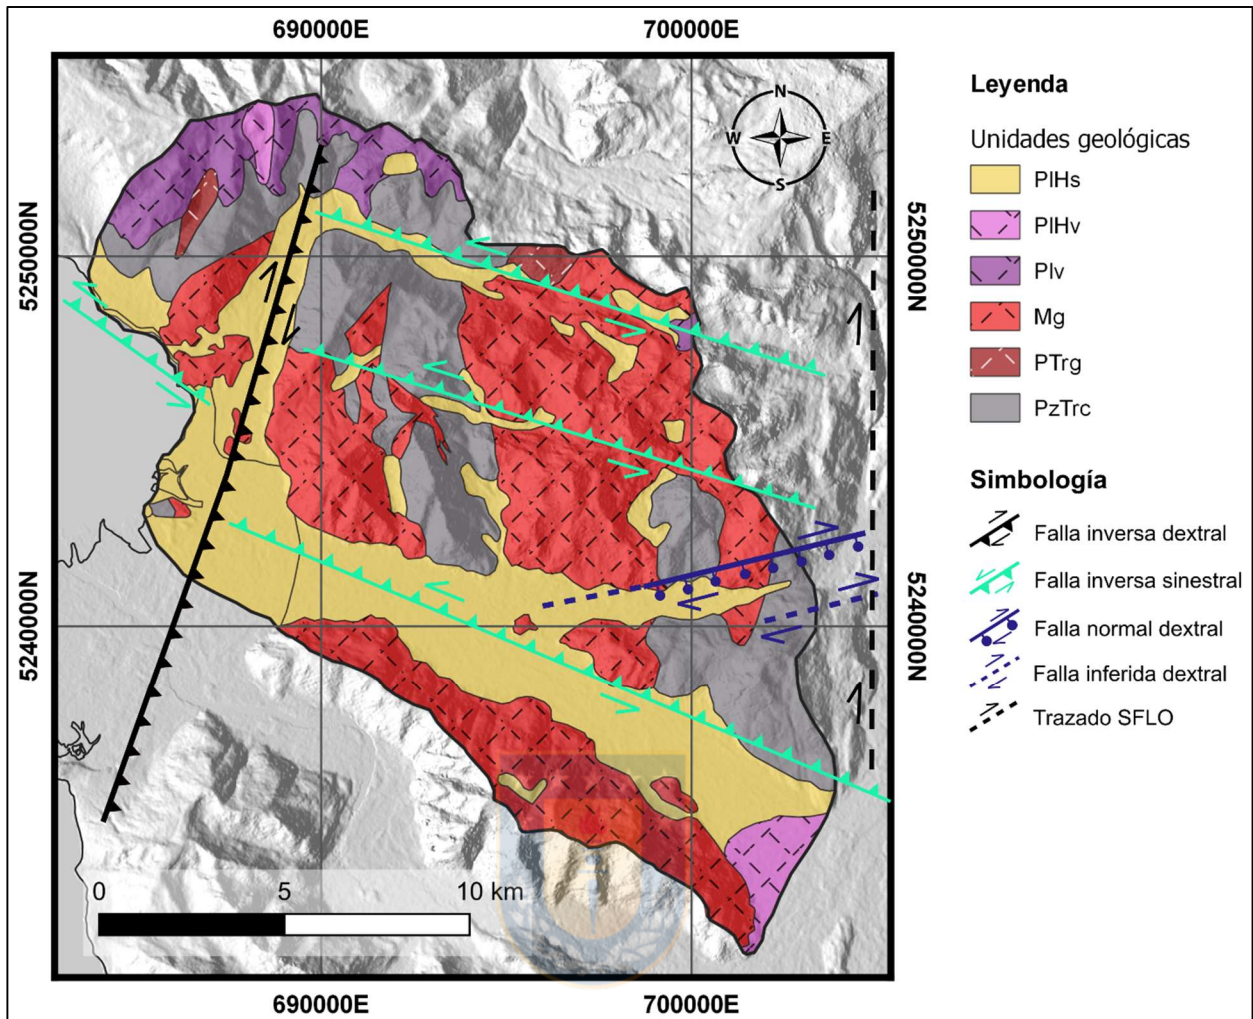
La Cordillera Principal, más conocida como los Andes Norpatagónicos en esta latitud, conforma un estrecho cinturón montañoso de extensión lateral cercana a los 100Km y altitudes máximas de 2200 m s.n.m. Se constituye principalmente por el Batolito

Norpatagónico; macizo intrusivo de señal calcoalcalina de edad Jurásico tardío - Mioceno, formado mayoritariamente por pulsos que datan entre el Cretácico temprano tardío, y el Cretácico tardío (Pankhurst *et al.* 1999). El volcanismo contemporáneo a este arco magmático está registrado en las formaciones Ibáñez y Lago de la Plata de edad jurásica media – tardía, y el Grupo Divisadero de Cretácico temprano, todas unidades que afloran principalmente en terreno argentino.

Los Andes Norpatagónicos también están constituidos por afloramientos más restringidos del complejo acrecionario metamórfico, a modo de franjas relacionadas al Sistema de Fallas Liquiñe - Ofqui (SFLO), un extenso sistema cortical transcurrente de tipo dextral que deforma el basamento ígneo-metamórfico. Dichas rocas albergan el arco volcánico actual, correspondiente a la Zona Volcánica Sur Sur (ZVSS) la cual se extiende entre los 41, 5° lat. S hasta los 46° lat. S, y a unos 270 Km al este de la fosa (Lopez-Escobar *et al.*, 1995 en Muñoz, 2019), dominada por un lineamiento de dirección NNE de más de 1000 Km de largo, estrechamente ligado y controlado por el SFLO, cuyas principales trazas se relacionan directamente con la posición de los volcanes de la zona.

### **2.3.2. GEOLOGÍA LOCAL**

En el área de estudio, se distinguen 6 unidades geológicas (Figura 2.3) de acuerdo al mapa 1:500.000 de SERNAGEOMIN para la parte sur de la Región de Los Lagos (Ordóñez & Crignola, 2003). Dichas unidades se describen a continuación, agrupadas según el tipo de formación rocosa.



### 2.3.2.1. ROCAS METAMÓRFICAS

#### Paleozoico – Triásico (PzTr)

Rocas metamórficas de grado bajo y medio compuestas principalmente por metareniscas y micaesquistos. También es posible distinguir esquistos y anfibolitas, y en rocas ultramáficas en menor proporción. En la zona afloran rocas mesozonales del Complejo Metamórfico Amarillo - Puerto Cárdenas (SERNAGEOMIN-BRGM, 1995), comprendido por micaesquistos y gneises micáceos de edad Paleozoico Superior.

De acuerdo a Hervé *et al.* (2017), las rocas paleozoicas de esta zona son parte del Complejo Metamórfico de la Cordillera Principal (*Main Range Metamorphic Complex*, MRMC), y las

diferencian como rocas metapelíticas-metapsamíticas y ortogneises. Las primeras se habrían formado por la sucesiva acreción frontal de metaturbiditas en un prisma acrecionario, de forma similar a la Serie Oriental del centro-sur de Chile, mientras que las ortogneises tendrían un protolito ígneo cristalizado durante el Devónico en un arco de islas que se habría acrecionado al margen occidental de Gondwana, para luego ser metamorfizados durante el Cretácico.

#### 2.3.2.2. ROCAS INTRUSIVAS

##### **Intrusivo Pérmico-Triásico (PTrg)**

SERNAGEOMIN-BRGM (1995) indica que esta unidad se conforma principalmente por Gabros, y en menor medida, ultrabasitas, con edades K.Ar en plagioclasa y hornblenda entre 265 y 245 Ma. De acuerdo a Ordoñez & Crignola (2003), estas rocas afloran de forma muy restringida al NE área de estudio.

##### **Intrusivo Mioceno (Mg)**

Es la unidad perteneciente al Batolito Norpatagónico, que constituye la mayor parte del área de estudio. Corresponde a granitos, granodioritas, monzonitas, tonalitas, dioritas y gabros, con edades comprendidas entre 20 y 5 Ma (Mioceno, localmente hasta Plioceno) (Ordoñez & Crignola, 2003). Es posible distinguir dos conjuntos litológicos: tonalitas foliadas con hornblenda y biotita que marcan dicha foliación, y un grupo de tonalitas de hornblenda y biotita que gradan desde dioritas cuarcíferas hasta granitos, con predominancia tonalitas. En particular, para la zona de estudio, Soto (2019) describe que las rocas del Cerro Recoba en Chaitén se conforma por dioritas, granodioritas y granitos de grano medio a grueso que intruyen unidades metamórficas del basamento (PzTr). Por su parte, Muñoz (2019) señala la presencia enclaves máficos compuestos de biotitas de grano medio en tonalitas de anfíbol y biotitas que afloran en la Costanera de Chaitén, así como también describe Tonalitas mesocráticas de anfíbol a los pies del Cerro Recoba.

De acuerdo a Duhart (2003), dada la naturaleza calcoalcalina y metaluminosa de estos intrusivos, constituyen una asociación típica de arco magmático de margen continental activo.

### 2.3.2.3. ROCAS ESTRATIFICADAS

#### **Unidades volcánicas cuaternarias (Plv – PIHv)**

De acuerdo a Ordoñez & Crignola (2003), distinguen dos unidades distinguibles principalmente por su edad. La primera (Plv), corresponde a rocas pleistocenas constituidas por lavas y depósitos piroclásticos y laháricos, principalmente dacíticos, asociados a estratovolcanes, calderas erosionadas y a las secuencias basales de los estratovolcanes activos y erosionados. Por su parte, la unidad más reciente (PIHv) de edad Pleistoceno Superior – Holoceno), se describe como lavas y depósitos piroclásticos y laháricos, principalmente basálticos a riolíticos, asociado a estratovolcanes activos.

Estas rocas afloran de forma restringida en la zona norte del área de estudio, asociadas a las faldas de los volcanes Chaitén y Michinmahuida.

### 2.3.2.4. DEPÓSITOS NO CONSOLIDADOS

#### **Sedimentos no consolidados del Pleistoceno – Holoceno (PIHs)**

Corresponden a depósitos fluviales, aluviales, deltaicos, coluviales, estuarinos, lacustres, de conos de deyección, morrénicos, de remociones en masa, de playas y eólicos (Ordoñez & Crignola, 2003). De forma particular en el área de estudio, los sedimentos predominantes corresponden a depósitos fluvio-glaciales, de remociones en masa, y depósitos laháricos en el valle del Río Blanco y la planicie que alberga la ciudad de Chaitén.

### 2.3.3. CONTEXTO ESTRUCTURAL LOCAL

El estudio estructural de más detalle para la zona de estudio hasta la fecha, es el de Muñoz (2019), definiendo el control estructural del basamento sobre el volcanismo cuaternario del Complejo Volcánico Chaitén – Michinmahuida (CVChM). En esta investigación, se determina que en la zona existe el dominio de 2 estados de esfuerzos, uno compresivo a transpresivo en dirección NE-SW y uno transcurrente orientado en la E-W, los cuales evidenciarían una partición parcial de la deformación en el intraarco donde se emplaza el CVChM, provocada por la subducción oblicua entre las placas Nazca y Sudamericana, proceso que da origen a fallas paralelas al margen convergente (SFLO), acomodando la transpresión impuesta.

De forma particular, el área de estudio se sitúa en un bloque delimitado por 2 estructuras mayores NNE-SSW y NS, y fallas oblicuas a éstas en dirección WNW. De acuerdo a esto se define la ocurrencia de 8 estructuras principales, que se vinculan los quiebres topográficos más notorios en la zona, como los son los valles del Río Blanco y Río Negro, entre otros. El trazado, ubicación y tipo específico de cinemática para cada estructura mapeada por Muñoz (2019) se puede revisar en el mapa geológico presentado en la Figura 2.3.



### 3. REVISIÓN BIBLIOGRÁFICA

A continuación, se presenta una revisión bibliográfica con respecto a los procesos de remoción en masa (RM) junto a los métodos de análisis de susceptibilidad del terreno ante dichos procesos, así como también, se expone la formulación teórica de las Redes Neuronales Artificiales (RNA) y su aplicación en análisis de susceptibilidad de deslizamientos. De forma adicional, en el Anexo 1 es posible consultar una revisión con respecto a *softwares* de modelación numérica de RM.

#### 3.1. PROCESOS DE REMOCIÓN EN MASA

##### 3.1.1. INTRODUCCIÓN

La definición más básica y ampliamente aceptada para el concepto de remoción en masa es “un movimiento ladera abajo de una masa de roca, detritos o tierra por efecto de la gravedad” propuesta por Cruden (1991) y Cruden & Varnes (1996).

Las RM son procesos geomorfológicos cuyo origen puede darse por factores naturales y/o antrópicos. 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 en Thiebes, 2012).

##### 3.1.2. TIPOS DE REMOCIÓN EN MASA

En la literatura científica es posible encontrar una gran diversidad de clasificaciones para los movimientos en masa, las cuales se basan principalmente en el tipo de material involucrado, los mecanismos de movimiento, el grado de deformación del material y el grado de saturación (Proyecto Multinacional Andino, 2007).

###### 3.1.2.1. SISTEMA DE CLASIFICACIÓN DE VARNES

El sistema de clasificación de RM más utilizado en países de habla inglesa es el propuesto por D. J. Varnes, en base a las propiedades de los materiales y mecanismo de proceso (Varnes 1954, 1978; Cruden & Varnes, 1996). Dicho sistema ha sido modificado y actualizado por Hungr *et al.* (2014) con la intención de reflejar los avances más recientes en el entendimiento de los movimientos en masa, y de los materiales y mecanismos involucrados; definiendo un total de 32




tipos de remoción en masa (Tabla 3.1) enmarcados en 6 tipos de movimiento que se describen a continuación. Cabe mencionar que, si bien es posible identificar cada uno de los procesos establecidos por los autores citados, existe una clase “Compleja” que involucra dos o más de los tipos de movimiento que actúan en conjunto en el desarrollo del proceso de ladera.

**Tabla 3.1: Sistema de clasificación de RM de Varnes modificado por Hungr et al. (2014).** Se presentan 32 tipos de procesos clasificados según el tipo de movimiento y el material involucrado. La descripción en detalle de cada tipo puede ser consultada en la publicación citada.

Tipo de Movimiento	Roca	Suelo
<b>Caída</b>	1. Caída de roca/hielo	2. Caída de boulder/detritos/limo
<b>Volcamiento</b>	3. Volcamiento en bloque de roca 4. Volcamiento flexural de roca	5. Volcamiento de grava/arena/limo
<b>Deslizamiento</b>	6. Deslizamiento rotacional de roca 7. Deslizamiento planar de roca 8. Deslizamiento de roca en cuña 9. Deslizamiento compuesto de roca 10. Deslizamiento irregular de roca	11. Deslizamiento rotacional de arcilla/limo 12. Deslizamiento planar de arcilla/limo 13. Deslizamiento de grava/arena/detritos 14. Deslizamiento compuesto de arcilla/limo
<b>Propagación lateral</b>	15. Propagación lateral de ladera de roca	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/detritos 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

### Caída (*Fall*)


Se trata de un tipo de RM en el cual uno o varios bloques de suelo o roca se desprenden de una ladera, sin apreciarse desplazamiento cortante a lo largo de la superficie. Al desprenderse, el material cae principalmente por el aire, pudiendo efectuar golpes, rebotes y rodamiento (Figura 3.1). De acuerdo a Cruden & Varnes (1996) este proceso es muy rápido a extremadamente rápido, con velocidades superiores a  $5 \times 10^1$  mm/s. 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.



**Figura 3.1: Esquematación de caída de rocas.** Tomado sin modificaciones de Proyecto Multinacional Andino (2007).

### Volcamiento (*Toppling*)

Consiste en un movimiento en masa en el cual ocurre una rotación hacia delante de uno o varios bloques de suelo o roca, a partir de un punto o pivote de giro ubicado en su parte inferior. Según Varnes (1978), este movimiento ocurre por empujes de las unidades adyacentes o por la presión de fluidos en grietas, supeditados a la acción de la gravedad. El volcamiento puede ser en bloque (Figura 3.2 a y b), flexural o flexional (Figura 3.2 c), o de bloque de suelo.




**Figura 3.2: Volcamiento de rocas.** a) y b) esquemas de volcamiento en bloque de roca; c) volcamiento flexural. Tomado sin modificaciones de Proyecto Multinacional Andino (2007).

## Deslizamiento (*Slide*)

Es un 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.


En el sistema de Varnes (1978), se clasifican según la forma de la superficie de falla por la cual se desplaza el material, en traslacionales y rotacionales (Figura 3.3). A su vez, los deslizamientos traslacionales pueden ser planares o en cuña. Sin embargo, las superficies de rotura de movimientos en masa son generalmente más complejas que las de los dos tipos anteriores, pues pueden consistir de varios segmentos planares y curvos, caso en el cual se hablará de deslizamientos compuestos (Hutchinson, 1988).



**Figura 3.3: Esquemmatización de deslizamientos.** a) Deslizamiento traslacional; b) Deslizamiento rotacional. Tomado sin modificaciones de Proyecto Multinacional Andino (2007).

## Propagación Lateral (*Lateral Spread*)

Se distingue como un tipo de movimiento en masa cuyo desplazamiento ocurre predominantemente por deformación interna (expansión) del material (Figura 3.4). La mayoría de los deslizamientos y los flujos involucran algún grado de expansión. Las propagaciones laterales 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 3.4: Ejemplos esquemáticos de Propagación Lateral.** Tomado sin modificaciones de Proyecto Multinacional Andino (2007).

### Flujo (*Flow*)

Es un tipo de RM 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) clasifican los flujos de acuerdo con el tipo y propiedades del material involucrado, la humedad, la velocidad, el confinamiento lateral y otras características que los hacen distinguibles; así mismo, aportan definiciones que enfatizan aspectos de uso práctico útiles para el estudio de amenazas. Cruden & Varnes (1996) también diferencian flujos canalizados (“*channelized flows*”) y no-canalizados; los primeros corresponden a aquellos que el material transportado sigue canales preexistentes en la topografía, mientras que los no-canalizados (“*open-slope flows*”) corresponden a las remociones fluidizadas que generan su propio trayecto al descender por la ladera de un valle hasta llegar a pendientes más suaves donde depositará el material.




Figura 3.5: Esquemas de remociones tipo Flujo. Tomado sin modificaciones de Proyecto Multinacional Andino (2007).

### Deformación de ladera (*Slope deformation*)

De acuerdo a Hungr *et al.* (2014) aquellos macizos rocosos altamente estresados que forman laderas de montañas con relieve vertical del orden de 1 km o más, pueden estar sujetos a deformación visible, evidenciada por las características topográficas de la superficie: escarpes, bancos, grietas, trincheras y bultos, entre otros (Figura 3.6). La deformación a gran escala de las laderas de montaña fue descrita por primera vez por Heim (1932), quien consideró tales fenómenos como signos precursoros de fallas inminentes en la pendiente. Tal como señala Zischinsky (1969), el llamado “*slope sagging*” (“*sackung*”) es omnipresente en la montaña. Así también se utiliza a veces el término “pendiente de arrastre” (“*slope creep*”).

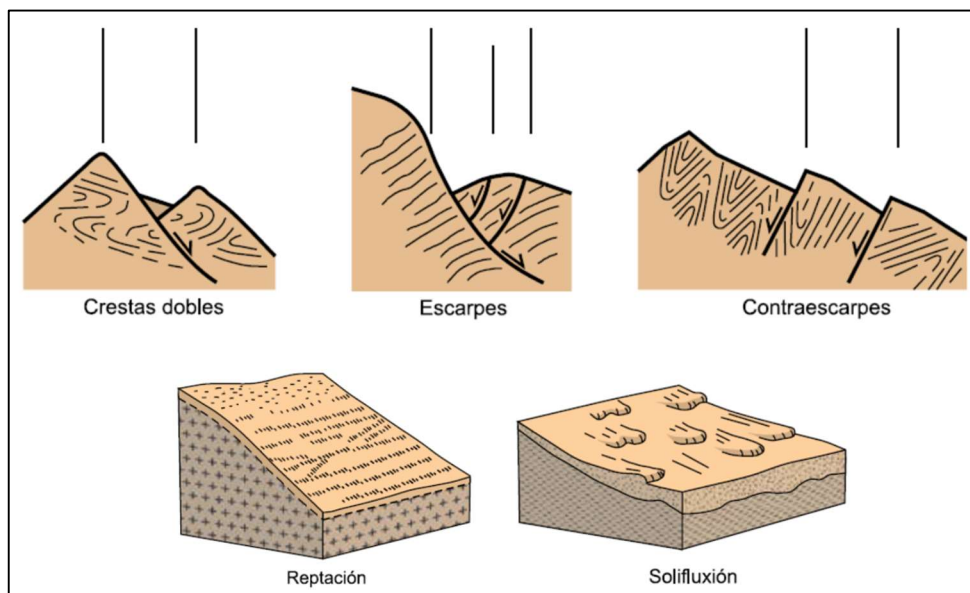


Figura 3.6: Ejemplos esquemáticos de procesos de deformación de ladera. Tomado sin modificaciones de Proyecto Multinacional Andino (2007).

### 3.1.2.2. OTROS SISTEMAS DE CLASIFICACIÓN

Una segunda clasificación ampliamente conocida para las RM es aquella basada en la velocidad del proceso (Cruden & Varnes, 1996), que caracteriza remociones que van desde las extremadamente rápidas a extremadamente lentas (Tabla 3.2).

**Tabla 3.2: Clasificación de remociones en masa según velocidad de Cruden & Varnes (1996).** Tomado de Thiebes (2012) sin modificaciones.

Clase	Descripción	Velocidad común	Daños esperados y reacción de la población
1	Extremadamente rápido	> 5 m/s	Desastre de mayor violencia; edificios destruidos por el impacto y desplazamiento de material; muchas muertes; escape improbable.
2	Muy rápido	> 3 m/min	Pérdida de algunas vidas; velocidad es mucha para permitir escapar a todas las personas.
3	Rápido	> 1.8 m/h	Escape y evacuación posibles; estructuras destruidas.
4	Moderado	> 13 m/mes	Algunas estructuras temporales e insensibles pueden mantenerse por un tiempo.
5	Lento	> 1.6 m/año	Las construcciones de reparación pueden realizarse durante el movimiento; las estructuras insensibles pueden mantenerse con trabajos de mantenimiento frecuentes si el movimiento total no es grande durante una fase de aceleración determinada.
6	Muy lento	> 15 mm/año	Algunas estructuras permanentes sin daño por el movimiento
7	Extremadamente lento	< 15 mm/año	Imperceptible sin instrumentos; construcción es posible con precauciones.

Por otra parte, se han propuesto diversos términos para caracterizar y conformar los “nombres” de los movimientos en masa. Cruden & Lan (2015) resumen un glosario con los diferentes términos acuñados en base a aspectos como los ya mencionados; tipo de movimiento, material involucrado y velocidad (o tasa de movimiento), adicionando otras características como el estado de actividad, la distribución de actividad, el estilo de actividad, y el contenido de agua (Tabla 3.3).

**Tabla 3.3: Glosario para la formación de nombres de movimientos en masa.** Extracto de terminologías presentadas en Cruden & Lan (2015) para ser utilizadas en la descripción de remociones. Se excluyen los criterios ya descritos anteriormente en el presente trabajo: Tipo de movimiento, material y velocidad.

Criterio	Términos asociados	
Estado de actividad	1. Preparatorio	4. Reactivado
	2. Marginal	5. Suspendido
	3. Activo	6. Inactivo (Durmiente, Abandonado, Reparado, Estabilizado, Relicto)
Distribución de actividad	1. Avanzando	4. Disminuyendo
	2. Retrocediendo	5. En movimiento
	3. Creciendo	-
Estilo de actividad	1. Complejo	4. Sucesivo
	2. Compuesto	5. Único
	3. Múltiple	-
Cantidad de agua	1. Seco	4. Muy mojado
	2. Húmedo	5. Congelado
	3. Mojado	6. Derretido

Para obtener mayor detalle e información con respecto a los diversos tipos de clasificación expuestos se recomienda consultar en los respectivos trabajos citados en cada caso.

### 3.1.3. REMOCIONES EN MASA COMO PELIGRO GEOLÓGICO

Las RM son un componente crucial del ciclo geológico de la Tierra, donde el movimiento de las placas tectónicas provoca que partes de la corteza se eleven continuamente para luego ser erosionadas de nuevo por la gravedad y flujos de agua que remueven material hacia los pies de laderas o fondo de valles (Davies, 2015).

Diversos fenómenos que ocurren en la naturaleza son considerados como peligros naturales, tales como sismos, tsunamis, erupciones volcánicas, huracanes, entre otros, que por sus características de intensidad y frecuencia causan daños a la estructura social de la zona donde ocurren. Dentro de esta gama de eventos que implican peligrosidad se integran los procesos de remoción en masa (Borja & Alcántara, 2004), los cuales al depender en gran medida del contexto geológico del lugar donde se originen, son considerados como un peligro geológico.

El estudio, comprensión y análisis de los movimientos en masa como un peligro geológico requiere conocer y diferenciar varios conceptos, los que pueden ser consultados en el Anexo 2

### 3.1.3.1. TIPOS DE ZONIFICACIÓN

Es necesario definir y establecer diferencias entre los diferentes tipos de zonificación que es posible realizar en el análisis de remociones en masa. Para ello, a continuación, se presentan los 3 tipos de zonificación que bien describen Arenas & Opazo (2017) la *Australian Geomechanics Society* (2007).

**Zonificación de Susceptibilidad de Remociones en Masa:** Es la división del terreno en zonas que presentan diferente grado de susceptibilidad a un tipo particular de RM. La evaluación de la susceptibilidad se puede realizar de manera cualitativa o cuantitativa, y debería indicar, si es posible, tanto las zonas de generación como las de alcance. Implica la clasificación, el volumen (o área) y la distribución espacial de los movimientos en masa existentes y potenciales en el área de estudio. La zonificación de la susceptibilidad suele conllevar la elaboración de un inventario de los eventos ocurridos en el pasado junto con una evaluación de las zonas con posibilidades de experimentar remociones en el futuro, pero sin evaluar la frecuencia (probabilidad anual) de que se produzcan.

**Zonificación del Peligro de Remociones en masa:** División del terreno en zonas que presentan diferente grado de peligro de RM de un determinado tipo y magnitud (volumen/área), con una probabilidad de ocurrencia en un intervalo de tiempo determinado. Debe indicar, necesariamente, tanto las zonas de generación como las de posible alcance de las RM. Toma los resultados de los mapas de susceptibilidad y asigna una frecuencia estimada (probabilidad anual o período de retorno) a los posibles movimientos en masa. El peligro puede expresarse como la frecuencia de un tipo particular de movimiento en masa de un determinado volumen, o de un determinado tipo, volumen y velocidad (que puede variar con la distancia de la fuente) o, en algunos casos, como la frecuencia de los movimientos con una intensidad particular que puede ser medida en términos de energía cinética. Sin embargo, las medidas de intensidad son más útiles en estudios de caídas de rocas.

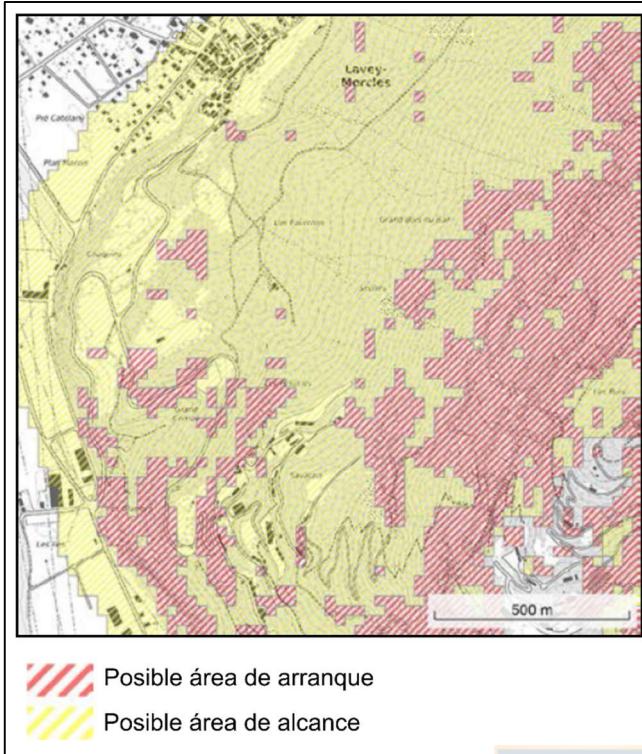
**Zonificación de Riesgo de Remociones en Masa:** Utiliza los resultados de la cartografía de la zonificación de peligros y evalúa los posibles daños a las personas (probabilidad anual de que la persona más expuesta al riesgo pierda la vida) y a los bienes (valor anual de la pérdida de bienes) para los elementos en peligro, teniendo en cuenta la probabilidad y la vulnerabilidad temporal y espacial.



La *Australian Geomechanics Society* (2007) también añade que a menudo será necesario elaborar mapas de susceptibilidad, peligro y riesgo por separado para los diferentes tipos de remociones en masa que afectan a la zona; por ejemplo, para las caídas de rocas, pequeños deslizamientos poco profundos o grandes deslizamientos profundos. Así también, puede ser necesario elaborar mapas por separado para los procesos de laderas naturales y laderas construidas; si éstos se combinan en un solo mapa, los límites pueden ser confusos.

De la misma forma, la *Federal Office for the Environment* Suiza “FOEN” (2016) reconoce 2 tipos adicionales de productos cartográficos en el análisis de remociones en masa: Mapa Indicativo de Amenaza y Mapa de intensidad.

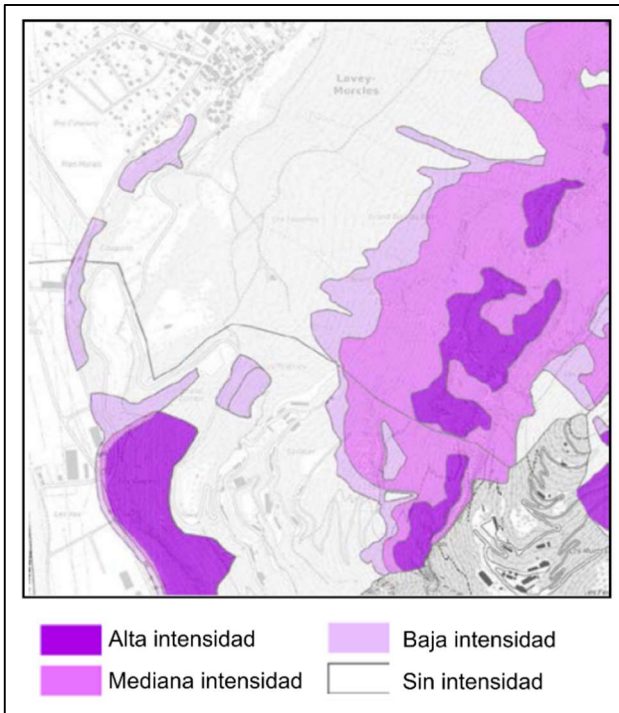
**Mapa Indicativo de Amenaza (MIA):** Ofrece un panorama general de la situación de susceptibilidad a los peligros. Abarca grandes zonas en las que existen amenazas potenciales, pero no proporciona ninguna información sobre el grado de peligro. Su función es ser la base para la planificación territorial regional, identificación de zonas de conflicto, y la evaluación de las aplicaciones de planificación fuera del perímetro de los mapas de peligros, establecimiento de prioridades en la elaboración de los mapas de peligros. Estos mapas de índices se elaboran individualmente para cada tipo de proceso de peligro (Figura 3.7). Pueden basarse en documentos geocientíficos y en cálculos de modelos y se fundamentan en el registro de peligros naturales. Pueden contener inexactitudes en relación con la demarcación espacial, y la presencia de una amenaza puede no estar indicada con precisión en todos los casos. Estos mapas sólo contienen indicaciones de la susceptibilidad a los peligros y no hechos verificados. Los mapas indicativos de amenaza sólo se utilizan en lugares para los que no se dispone de un mapa de peligrosidad vinculante (por ejemplo, fuera de las zonas de asentamiento) o para obtener panoramas específicos.



**Figura 3.7: Ejemplo Mapa Indicativo de Amenaza (MIA).** Mapa MIA del cantón de Vaud, Suiza. Proyecto CDN-VD, GEODE-DN. La representación puede variar (por ejemplo, con una distinción de acontecimientos documentados o sospechosos o, por ejemplo, con procesos de remoción en masa modelados). Tomado de FOEN (2016).

### Mapa de Intensidad (MDI)

Los mapas de intensidad indican las intensidades de los procesos de peligro que son esperables, por clase de probabilidad (alta, media, baja, muy baja) (Figura 3.8). Se definen valores límite para la diferenciación de las intensidades para cada proceso de peligro. En función del proceso, se utilizan diferentes parámetros para la estimación de la intensidad (por ejemplo, las energías para remociones tipo caída de rocas). En consecuencia, los mapas de intensidad constituyen la base para la elaboración de los mapas de peligros, aunque tienen muchas otras aplicaciones posibles. Por ejemplo, la información para el dimensionamiento de las estructuras de protección (capacidad de absorción de energía, ubicación adecuada, etc.) puede deducirse de las energías y su distribución espacial.



**Figura 3.8: Ejemplo Mapa de Intensidad (MDI).** Mapa del cantón de Vaud, Suiza. Proyecto CDN-VD, GEODE-DN. Hecho para un período de retorno de 100 años. Tomado de FOEN (2016).

### 3.1.3.2. APLICACIÓN DE SIG EN LA ZONIFICACIÓN DE RM

Un Sistema de Información Geográfica (SIG, o *Geographic Information System GIS* en inglés) se define como “un poderoso set de herramientas para coleccionar, almacenar, obtener a voluntad, transformar y visualizar datos espaciales del mundo real para un set particular de propósitos” (Burrough, 1986 en Van Westen, 1993). También tienen la capacidad de manipular y presentar espacialmente los datos con grandes capacidades de mapeo y poderosos análisis espaciales.

De acuerdo a la *Australian Geomechanics Society* (2007), se recomienda enfáticamente que la zonificación de movimientos en masa se lleve a cabo en un SIG para que la ésta pueda ser fácilmente aplicada en la planificación territorial y podrá actualizarse a medida que se disponga de más información.

Los datos utilizados en SIG pueden proceder de diversas fuentes, a menudo del propio proyecto (cartografía geológica y de ingeniería, cartografía de remociones en masa, estudios del GPS, perforación de pozos, pozos de ensayo, entre otros) y de fuentes externas, como organizaciones y autoridades gubernamentales, empresas privadas y otras organizaciones espaciales (es decir, modelos de elevación digital, catastro, contornos, fotografía aérea, uso del suelo, vegetación, y otros).

## 3.2. ANÁLISIS DE SUSCEPTIBILIDAD

La preparación de un mapa de susceptibilidad suele basarse en dos supuestos:

- 1) Que el pasado es una guía para el futuro, de modo que las zonas que han experimentado remociones en el pasado es probable que experimenten nuevamente en el futuro.
- 2) Las zonas con topografía, geología y geomorfología similares a las zonas que han sufrido un movimiento en masa en el pasado, también es probable que lo experimenten en el futuro.

Estas suposiciones son a menudo razonables, pero cabe señalar que hay excepciones, como cuando la fuente de las remociones se agotan con la ocurrencia de anteriores.

La *Australian Geomechanics Society* (2007) bien describe que los mapas de zonificación de la susceptibilidad a los deslizamientos deben incluir:

- Un mapa o una serie de mapas que muestren el inventario de los movimientos en masa históricos, indicando la ubicación y la zona de arranque de las remociones.
- Mapas a la misma escala que exhiban los factores que condicionan el terreno.
- Cuando proceda, preparar un mapa en el que se indiquen los límites de la distancia de viaje, ya sea como valor máximo o cuantificado mediante métodos empíricos o modelación numérica.
- Un mapa que muestre las áreas de clasificación de zonas de susceptibilidad interpretadas. Este mapa debe presentar también la topografía e información catastral.

El análisis que requiere la zonificación de susceptibilidad puede llevarse a cabo desde diferentes enfoques metodológicos, haciendo posible el uso de diversas herramientas de mayor o menor complejidad y/o avance tecnológico.

### 3.2.1. MÉTODOS CUALITATIVOS

#### 3.2.1.1. MÉTODO GEOMORFOLÓGICO

En este caso, el análisis es llevado a cabo por un geomorfólogo de mapeo, utilizando conocimientos específicos de terreno obtenidos a través de foto interpretación y salidas de campo. El mapa puede ser confeccionado ya sea directamente en campo o bien, mediante la

recodificación del mapa geomorfológico. Los criterios sobre los cuales él basa las diferentes clases de susceptibilidad no están formalizados con reglas generalizadas, y pueden variar de polígono a polígono. Los SIG pueden ser utilizados en este tipo de trabajos como una herramienta de dibujo, permitiendo una rápida recodificación de unidades, y corrección de unidades mal codificadas. Sin embargo, los SIG no son utilizados como una herramienta de análisis de los diferentes parámetros relacionados con la ocurrencia de las remociones en masa. Este método puede ser aplicado a escala regional, media o gran escala en un período de tiempo relativamente corto. No obstante, el detallado trabajo de campo requiere una cantidad de tiempo considerable. La precisión del mapa resultante dependerá completamente a las habilidades y experiencia del geomorfólogo, y aquellos mapas realizados en una misma área por diferentes profesionales podrán variar considerablemente.

### 3.2.1.2. MÉTODO DE PONDERACIONES

Van Westen (1993) indica que la base para este método es el conocimiento del profesional de las ciencias de la Tierra quien decide qué parámetros son importantes para la ocurrencia de los movimientos en masa. Se asignan valores ponderados cualitativos a cada clase dentro de un mapa de parámetro, y a la vez cada uno de éstos recibe un peso o ponderación. Los valores de ponderación no son derivados cuantitativamente, pero se estiman a partir el conocimiento en terreno de los factores causales o condicionantes. Dependiendo del grado de detalle del estudio, se usan diversos mapas, dentro de los cuales los más importantes son la geomorfología, los eventos de remoción en masa, el ángulo de pendiente, la geología, el uso de tierra, la distancia a fallas, caminos y redes de drenaje.

### 3.2.2. MÉTODOS CUANTITATIVOS

#### 3.2.2.1. MÉTODOS ESTADÍSTICOS BIVARIADOS

##### **Peso de la Evidencia (PDE)**

Relaciona mapas de diferentes factores condicionantes en la generación de remociones en masa (RM) con la densidad de eventos existentes en la zona. Utiliza la forma log-lineal del modelo de probabilidad Bayesiana, para estimar la importancia relativa de evidencia mediante estadística. Este modelo está basado en el cálculo de pesos positivos ( $W+$ ) y negativos ( $W-$ ), para cada factor condicionante (de forma individual), basado en la presencia o ausencia de RM

en el área y su densidad. Requiere un inventario previo de eventos de RM, mapeando su forma y extensión (polígonos). La metodología está basada en el cálculo de densidades mediante el conteo de píxeles, por lo que todas las capas de información deben estar en formato ráster. Se relacionan la cantidad de píxeles con RM y la cantidad de píxeles de cada clase que compone el mapa de factor. Así se obtiene un “Peso” para cada factor. Los mapas de factores posteriormente se combinan y se clasifican en grados de susceptibilidad, los que reflejarían una probabilidad espacial de ocurrencia de movimientos.

Ventajas de este método es que se considera una metodología sencilla para obtener una buena aproximación a la susceptibilidad, gran parte de la información utilizada proviene desde la misma fuente; un Modelo de Elevación Digital DEM, y lleva a cabo la automatización del cálculo de pesos para cada factor haciendo uso de SIG. Sin embargo, hay que tener en cuenta que este proceso es dependiente del número de píxeles indicados con remoción en masa, lo que provoca subestimaciones o sobreestimaciones si el área de una clase es muy pequeña y las RM no están distribuidas uniformemente. Además, requiere simplificar los mapas temáticos de los diferentes factores, y no entrega posibles correlaciones entre ellos.

Diversos autores han hecho uso de este método en el análisis de susceptibilidad de remociones en masa, en países como Japón, Turquía, Colombia y Chile (Molina, 2016; Náquira, 2009; Bonham-Carter & Argterberg, 1990; Van Westen, 1993; Van Westen, 2002; Süzen & Doyuran, 2003; Henríquez, 2019; Luzi *et al.* 2000; Dahal *et al.* 2007; Ozdemir & Altural, 2012).

### **Valor de la Información (VDI)**

Técnica que requiere una base de datos de parámetros recolectados para diferentes unidades de la superficie. El análisis se basa en la presencia (1) o ausencia (0) de RM en una cierta ubicación o dentro de una unidad de superficie. Puede ser usada tanto para información tanto alfa numérica como numérica. La presencia o ausencia de parámetros también se calcula. La importancia relativa de la ocurrencia de remociones para cada parámetro se calcula en términos de un valor de información, el cual es el logaritmo de la densidad de remociones por parámetro, comparada con la densidad del total de remociones.

Las ventajas y desventajas en el uso de esta técnica son básicamente las mismas señaladas para el PDE.

Estudios que han llevado a cabo este método son Van Westen (1993), Che *et al.* (2011), Sarkar *et al.* (2013), y Achour *et al.* (2017).

### **Índice de Frecuencia (IF)**

Consiste en un método probabilístico simple, que al igual que PDE y VDI, relaciona el inventario de remociones con cada uno de los factores condicionantes, con el fin de asignar un peso o ponderación a cada factor de acuerdo a la distribución espacial de los eventos registrados. Cada factor representado por un mapa, es subdividido en clases. Para otorgar un peso o valor a cada clase, se calcula la razón porcentual entre la cantidad de píxeles con presencia de remociones (1) dentro de cada clase y el total de los mismos en toda el área, así también para los píxeles sin eventos (0), obteniéndose 2 valores porcentuales A(1) y B(0), cuya razón A/B corresponde al índice de frecuencia de remociones para cada clase de factor o parámetro considerado, cuyo valor varía entre 0 y 1, límites mínimo y máximo de “peso” asignado para cada clase. Finalmente, los mapas de factores se combinan para dar origen al mapa de susceptibilidad.

Los autores que han hecho uso de este método si bien reconocen ventajas y desventajas similares a las indicadas para PDE y VDI, algunos señalan que esta técnica ha mostrado una exactitud muy similar a métodos más complejos como regresiones logísticas.

Trabajos que han aplicado esta metodología son Lee & Min (2001), Lee *et al.* (2003); Yilmaz (2008), Lee & Sambath (2006), Lee & Pradhan (2006), Pradhan & Lee (2010), y Ozdemir & Altural (2012).

### **3.2.2.2. MÉTODOS ESTADÍSTICOS MULTIVARIADOS**

#### **Proceso Analítico Jerárquico (AHP)**

Utilizado para obtener pesos de los factores causales. Este proceso permite realizar un análisis comparativo entre propiedades que no tienen una escala de medición entre sí, bajo tres principios fundamentales: 1) la construcción de jerarquías, 2) el establecimiento de prioridades, y 3) la consistencia lógica.

Se construye una matriz de comparación a pares donde se asignan valores de acuerdo a la escala propuesta por Thomas L. Saaty (Saaty, 1980 y 2000; Saaty & Vargas, 2001). El tamaño

de la matriz será el cuadrado de la cantidad de factores, y expone cada uno de ellos en la primera fila y en la primera columna. Los casilleros diagonales de la comparación a pares toman el valor 1, mientras que los casilleros de las mitades superior e inferior a la diagonal son simétricos unos con otros, por lo que sus correspondientes valores son recíprocos unos con otros. Una vez que se construye esta matriz, la ponderación cuya suma es igual a 1, se obtendrán por medio de un procesador de imágenes computarizado con capas temáticas de todos los factores causales categorizados sobre la base de ponderaciones de clase como inputs. Cuando son pocos parámetros, las ponderaciones pueden también derivar de una serie de simples procesos de sumas y divisiones. Entonces, las ponderaciones se consideran como el promedio de todas las posibles formas de comparar los factores causales. La comparación se valida según un índice de consistencia (IC), el cual no debe superar el valor de referencia determinado, que dependerá del tamaño de la matriz.

Esta metodología es capaz de comparar como se interrelacionan los diversos factores condicionantes, de una forma simple y que puede entregar buenas estimaciones. No obstante, se debe tener en consideración que da espacio a cierta subjetividad que puede derivar en variaciones de resultados para un mismo set de datos, ya que la comparación a pares, si bien tiene como referencia la escala de Saaty, está sujeta al criterio, conocimiento y experiencia del profesional a cargo.

Diversos autores han aplicado este método en el análisis de susceptibilidad de remociones en masa con buenos resultados (Muñoz, 2018; Elmes, 2006; Concha, 2017; Ayalew *et al.*, 2005; Henríquez, 2019; y Achour *et al.* 2017).

### **Regresión Logística Binaria (RLB)**

Es un modelo matemático de regresión no lineal para variables dependientes categóricas, en particular para aquellas variables dicotómicas (si o no, éxito o fracaso, entre otras). Resulta útil para los casos en los que se desea predecir la presencia o ausencia de una característica o resultado, según los valores de un conjunto de predictores. Es similar a un modelo de regresión lineal, pero está adaptado para modelos en los que la variable dependiente es dicotómica. La regresión logística se puede aplicar a un rango más amplio de situaciones de investigación que el análisis discriminante.



El modelo de regresión logística permite obtener una relación de regresión multivariable entre una variable dependiente y varias independientes. Utiliza el estimador de máxima verosimilitud en lugar del método de los mínimos cuadrados para calcular la medida de ajuste global del modelo.

Es un método más preciso y sensible que los bivariados. Además, variables independientes pueden ser continuas, discretas o categóricas y no necesariamente deben seguir una distribución normal. Sin embargo, se debe tener en cuenta que el proceso requiere más tiempo y trabajo con respecto a una metodología bivariada. De la misma forma, se debe considerar que puede presentar problemas si la cantidad de datos positivos (variable dependiente igual a 1), es muy distinta a la cantidad de datos negativos (variable dependiente igual a 0). También presenta problemas si los datos son pocos o si los eventos tienen un tamaño pequeño, no siendo recomendable su uso en tales casos. Por otra parte, cabe mencionar que la técnica requiere la conversión de datos a formato ASCII.

La RLB es un método muy popular dada la buena precisión de sus resultados, por lo que ha sido ampliamente utilizada en estudios de análisis de susceptibilidad de RM (Süzen & Doyuran, 2003; Schachter, 2008; Ayalew *et al.* 2005; Yesilnacar & Topal, 2005; Guzzetti *et al.*, 1999; Yilmaz, 2008; Lee & Sambath, 2006; Lee & Pradhan, 2006; Pradhan & Lee, 2010; Ozdemir & Altural, 2012; Rincón *et al.* 2016; y Kalantar *et al.* 2017).

### **Análisis Discriminante (AD)**

Técnica estadística de clasificación, que permite identificar aquellas variables que discriminan entre dos o más grupos definidos con anterioridad. Por lo tanto, permite establecer diferencias entre dichos grupos. Se parte de una muestra de N sujetos en los que se han medido p variables cuantitativas independientes, que son las que se utilizarán para tomar la decisión en cuanto al grupo en el que se clasifica cada sujeto. Resulta útil para construir un modelo predictivo para pronosticar el grupo de pertenencia de un caso, a partir de las características observadas de cada caso. El procedimiento genera una función discriminante o, para más de dos grupos, un conjunto de funciones discriminantes, basada en combinaciones lineales de las variables predictoras que discriminan los grupos de la mejor forma posible. Las funciones se generan a partir de una muestra de casos para los que se conoce el grupo de pertenencia. Posteriormente, las funciones pueden ser aplicadas a nuevos casos que dispongan de medidas para las variables predictoras, pero de los que se desconozca el grupo de pertenencia.

Para el caso de análisis de susceptibilidad, esto se utiliza para clasificar o seleccionar los factores condicionantes (variables independientes o predictoras) que contribuyen a la generación de remociones.

Una excelente ventaja de este método es que cuando está basado en una gran cantidad de variables mapeables geológicas y geomorfológicas, es capaz de discriminar exitosamente entre áreas estables e inestables. Por otra parte, se debe tener en cuenta que posee requisitos de normalidad de las variables independientes y de homogeneidad de la varianza y de la covarianza (difícilmente se cumplen cuando no hay una cantidad equivalente de casos positivos y negativos).

Es posible consultar en los trabajos de Carrara (1983), Carrara *et al.* (1991), Guzzetti *et al.* (1997), y Schachter (2008), sobre la aplicación de esta metodología en el análisis de susceptibilidad de RM.

### 3.2.2.3. OTROS MÉTODOS

Los grandes avances tecnológicos de las últimas décadas han dado paso a la aplicación de avanzadas técnicas computacionales en el ámbito de los peligros geológicos, en específico para el análisis de susceptibilidad de RM. Esto ha permitido la incursión en el ámbito de la inteligencia artificial (IA), haciendo uso de técnicas como Redes Neuronales Artificiales (RNA, *Artificial Neural Networks* "ANN") y Máquinas de Vectores de Soporte (MVS, *Support Vector Machines* "SVM") (Kalantar *et al.*, 2017; Tien Bui *et al.*, 2015; Pradhan, 2012). Las primeras son el método seleccionado para llevar a cabo el presente trabajo, por lo que serán revisadas con mayor detalle en la siguiente sección.

## 3.3. REDES NEURONALES ARTIFICIALES (RNA)

### 3.3.1. DEFINICIÓN

Las Redes Neuronales Artificiales (RNA, o en inglés ANN) son sistemas informáticos con potentes herramientas de modelización de datos, que utilizan una configuración matemática apropiada inspirada en la red neurológica biológica o cerebro animal (Fuentes *et al.*, 2018). Se trata de un sistema de interconexión de neuronas que colaboran entre sí para producir un estímulo de salida. Dichas neuronas se basan en un conjunto de algoritmos diseñados para

encontrar patrones, interpretando, etiquetando y agrupando datos sensoriales a través de una especie de percepción artificial. Se consideran una técnica útil en la solución de problemas de regresión y clasificación, mediante la aproximación de funciones lineales y no lineales para complejos patrones de datos (Kanungo *et al.*, 2006).

Jacob & Murugan (2016) definen las RNA como un grupo de unidades de procesamiento simples (neuronas) que se comunican entre sí enviando señales analógicas. Tales señales viajan a través de conexiones ponderadas con otras neuronas y cada una acumula la información que recibe, aprende de ella y genera una salida (*output*) de acuerdo con una función de activación interna (por ejemplo, gaussiana, sinusoidal, lineal y tangente); esta salida puede proporcionar una entrada (*input*) para otras neuronas o puede ser parte de la salida de la red. Los patrones que reconocen son numéricos y se encuentran contenidos en vectores, a los que deben ser traducidos todos los datos del mundo real, ya sean imágenes, sonidos, textos, series, entre otros.

### 3.3.2. HISTORIA

De acuerdo al trabajo recopilatorio de Acevedo *et al.* (2017), el concepto o idea de red neuronal artificial se remonta al año 1936 con el reconocido matemático e informático Alan Turing, quien evalúa la posibilidad recrear redes neuronales de forma artificial, al encontrar relaciones entre el funcionamiento cerebral y el computacional. Pero no es hasta 1943, cuando el neurofisiólogo Warren McCulloch junto al joven matemático Walter Pitts presentaron un modelo de neuronas artificiales recreadas en un circuito eléctrico, construyendo así lo que fue considerado como el primer modelo de una red neuronal implementada en las ciencias de la computación. Esto fue el puntapié inicial en el desarrollo y evolución de las redes neuronales durante el siglo XX, donde han contribuido numerosos trabajos (Tabla 3.4), de los cuales destaca el de Frank Rosenblatt en 1957, creando la primera RNA funcional que es utilizada hasta la actualidad: el “Perceptrón”, que corresponde a una unidad simple de procesamiento empleada para identificar patrones en una clasificación de tipo binaria.

**Tabla 3.4: Cronología de contribuciones en el desarrollo de las Redes Neuronales Artificiales.** Tomado y modificado de Acevedo y otros (2017). Recopilación original de Matich (2001).

Año	Contribución
1936	Alan Turing realiza estudios del cerebro y encuentra relaciones entre la forma en que esta trabaja y la computación.
1943	Warren McCulloch y Walter Pitts inician los fundamentos de la computación neuronal y escriben una teoría acerca de la forma de trabajar de las neuronas. Este puede verse en su trabajo llamado " <i>A Logical Calculus of Ideas Immanent in Nervous Activity</i> " donde modelan una red neuronal simple a través de circuitos eléctrico.
1936 -1949	Donald Hebb define una regla para explicar cómo se realiza un proceso de aprendizaje. Para las redes neuronales actuales, se sigue utilizando la regla de Hebb. Según él, el aprendizaje ocurre cuando ciertos cambios en una neurona son activados. En su trabajo " <i>The Organization of Behavior</i> " explica que, si dos neuronas que están interconectadas entre sí se activan al mismo tiempo, esto indica que existe un incremento en la fuerza sináptica. Hebb también intentó encontrar semejanzas entre el aprendizaje y la actividad nerviosa. Sus trabajos formaron las bases de la Teoría de las Redes Neuronales.
1950	Después de realizar algunos ensayos, Karl Lashley encontró que la información no era almacenada de forma centralizada en el cerebro si no que era distribuida encima de él.
1956	Se realiza el "Congreso de Dartmouth", encuentro transcurrido en el verano de 1956 en la Universidad Dartmouth College, Nuevo Hampshire. Algunos autores y escritos mencionan el evento como referencia para indicar que allí se dio el nacimiento de la inteligencia artificial.
1957	Nace el Perceptrón, un tipo de red neuronal artificial desarrollada por Frank Rosenblatt. Puede decirse que esta es la red neuronal más antigua, pero que sigue utilizándose actualmente para identificar patrones. En este modelo, después de que la neurona aprende una serie de patrones, puede reconocer otros similares, aunque no se le hubiesen presentado en el entrenamiento, a esto se le llama generalización. Sin embargo, sus capacidades eran limitadas, era incapaz de clasificar clases no separables linealmente.
1959	Se crea el Teorema de Convergencia del Perceptrón, por el mismo Frank Rosenblatt, en donde se confirma que, bajo ciertas condiciones, el aprendizaje del Perceptrón convergía hacia un estado finito.
1960	Se hace la primera red neuronal aplicada a un problema real en donde se realizan filtros adaptativos para eliminar ecos en las líneas telefónicas, basado en el modelo de Bernard Widroff y Marcian Hoff.
1969 -1975	Se realiza la discusión acerca de la posibilidad de seguir trabajando con redes neuronales o no. Esto debido que, con varios estudios y pruebas realizadas, se demostró que el Perceptrón era débil ya que las funciones no lineales son empleadas en computación y en los problemas del mundo real. Sin embargo, durante esta época surge el algoritmo de "propagación hacia atrás", que resuelve el problema que presentaba el Perceptrón, realizado por Paul Werbos en 1974. Al trabajo realizado por Werbos, algunos autores lo denominan como el resurgimiento de las redes neuronales.
1986	Aparece el nombre de conexionismo para definir el procesamiento distribuido en paralelo. David E. Rumelhart y James McClelland proporcionan una exposición de la utilización de conexionismo en los computadores para simular procesos neuronales.

Hanson (2020) señala que, si bien en la década de los 70's existió un pequeño receso en los avances de las RNA debido a la falta de robustez del Perceptrón, durante la década de los 80's se recobró el entusiasmo en el funcionamiento de las RNA cuando John Hopfield propuso realizar un sistema con conexiones bidireccionales, tal como funcionan las neuronas en la realidad. Por otra parte, en 1982, Japón declaró estar concentrado en lograr un mayor

desarrollo de las RNA, lo cual impulsó a EEUU a financiar investigaciones del mismo tipo en su propio territorio.

El mismo autor citado anteriormente, indica que a fines de los 80's y comienzo de los 90's no se lograron grandes aportes al avance de las RNA. Sin embargo, en 1997, la IBM PC *Deep Blue*, que era una computadora jugadora de ajedrez, derrotó al campeón mundial de ajedrez. Desde este punto en adelante, han sido mucho más los avances en esta área. Fue así como en la década de los 90's se comenzó a aplicar el *Machine Learning* (ML) en la minería de datos o más conocido como "*data mining*", en la programación adaptativa y aplicaciones web, aprendizaje de contenido, y aprendizaje de idiomas. Investigadores comenzaron a crear programas para computadora para examinar gran cantidad de datos y realizar inferencias, o "aprender", de los resultados. De esta forma el ML se convirtió en principal camino de innovación haciendo posible la creación de programas que una vez acabados, pueden continuar aprendiendo sin ninguna ayuda y avanzan, así como se le presenten más datos, sin requerir mediación humana.

### 3.3.3. INTELIGENCIA ARTIFICIAL (IA)

La Inteligencia Artificial (IA) puede entenderse como un sistema computarizado capaz de realizar tareas que normalmente requieren inteligencia humana, como la percepción visual, reconocimiento verbal, la toma de decisiones, o la traducción entre idiomas. Es una rama de la informática destinada a crear máquinas inteligentes, por lo que se ha convertido en un componente clave en la industria tecnológica (Hanson, 2020).

La IA ha desarrollado un gran número de herramientas para resolver los problemas más difíciles en las ciencias de la computación, tales como:

- Optimización de búsquedas
- Lógica
- Métodos probabilísticos para razonamientos u ocurrencias inciertas
- Métodos de clasificación y aprendizaje estadístico
- Idiomas

Dentro de las múltiples aplicaciones que puede tener la IA se pueden mencionar: el procesamiento de idiomas, juegos de computadora, reconocimiento verbal, sistemas de vigilancia, medicina, entre muchos otros.


Las RNA corresponden a uno de los tantos sets de algoritmos que llevan a cabo los diferentes tipos de IA. Dentro éstas, las RNA son una herramienta de la rama del *Machine Learning* (ML), que comprende aquellos algoritmos capaces de aprender o automodificarse al ser expuestos a más información, sin ser explícitamente programados.

Tal se explicará en la siguiente sección, las RNA se estructuran en base nodos (*nodes*), que se entienden como “lugares donde ocurre la computación”, los cuales se organizan en 3 tipos de capas (*layers*):

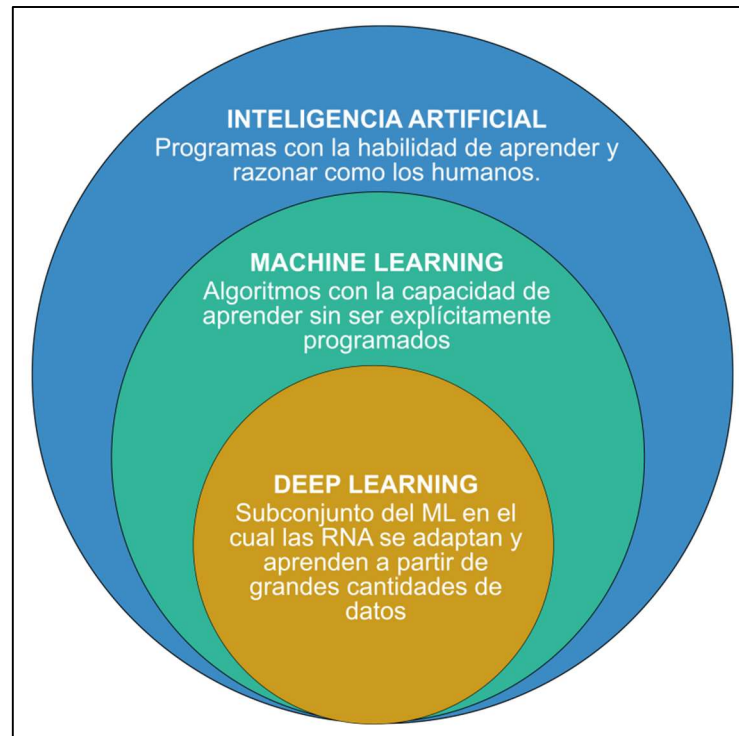
- **Input Layer:** capa de entrada, son los datos originales, o en bruto (*raw data*).
- **Hidden Layers:** capas ocultas, por donde pasa y se procesa la información de entrada
- **Output Layer:** capa de salida, es el resultado final

A mayor número de capas ocultas, es mayor el grado de procesamiento (aprendizaje) del modelo, así como la precisión de sus resultados. De acuerdo a esto, se distinguen dos niveles o modos de aprendizaje:

- **Shallow Learning:** 1 capa oculta
- **Deep Learning:** 2 o más capas ocultas. Es más complejo y logra resultados más precisos.



En la Figura 3.9 se esquematiza la relación entre los conceptos de IA, RNA y ML como subconjuntos uno dentro de otro.



**Figura 3.9: Deep Learning en la Inteligencia Artificial.** Se presenta la relación entre la inteligencia artificial, el *machine learning* y el *deep learning*, cada una es subconjunto de la anterior, respectivamente. Elaboración propia.

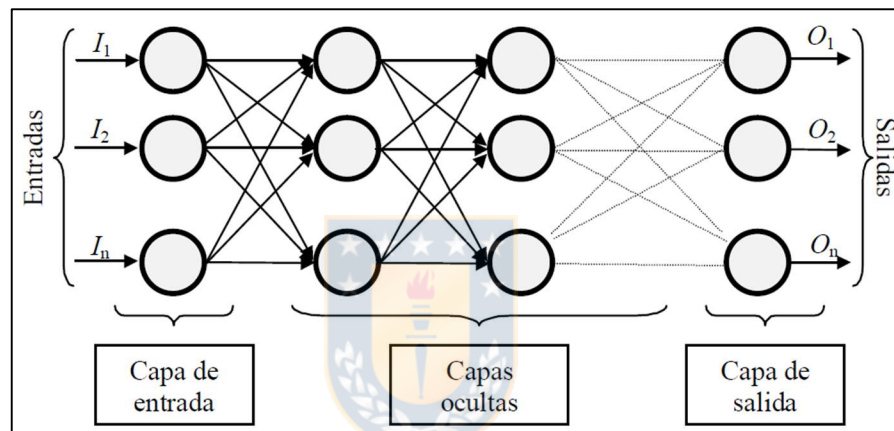
Por otra parte, de acuerdo al modo de aprendizaje se pueden diferenciar otros subconjuntos dentro del *Machine Learning*. Dos de ellos son:

- **Supervised Learning:** El modelo requiere un *dataset* de referencia previamente etiquetado o clasificado, para aprender y ajustarse mediante estimación y comparación con el tipo de resultado que se espera.
- **Unsupervised Learning:** No se cuenta con un *dataset* etiquetado de referencia. Es un sistema complejo y con un gran potencial para el desarrollo y avance de la inteligencia artificial, ya que en la realidad es muy poca la información que se puede categorizar y etiquetar previamente.

En el caso de la aplicación de RNA para llevar a cabo análisis de susceptibilidad de remociones en masa, estamos frente a un *Supervised Learning*, basado en un catastro o inventario de eventos.

### 3.3.4. ARQUITECTURA

Maind & Wankar (2014) explican que las RNA típicamente consisten en cientos de unidades de procesamiento simples que están conectadas entre sí en una red de comunicación compleja. Cada unidad o nodo es un modelo simplificado de neurona real que envía una nueva señal a los otros nodos a los que está conectado. Las RNA estructuran sus nodos (o neuronas) de manera ordenada y agrupada en capas (Figura 3.10). Aunque existen redes muy útiles conformadas sólo por una capa o incluso un elemento, la mayoría de las aplicaciones requieren que contengan al menos los tres tipos normales de capas: (1) Entrada o *Input*, (2) Oculta o *Hidden* y (3) Salida o *Output*.



**Figura 3.10: Esquemización de la arquitectura de una red neuronal artificial.** Se presenta una red neuronal con 2 capas ocultas, y cada capa, tanto la de entrada como las ocultas y la de salida se conforman por 3 neuronas cada una. Tomado de Matich (2001), sin modificaciones.

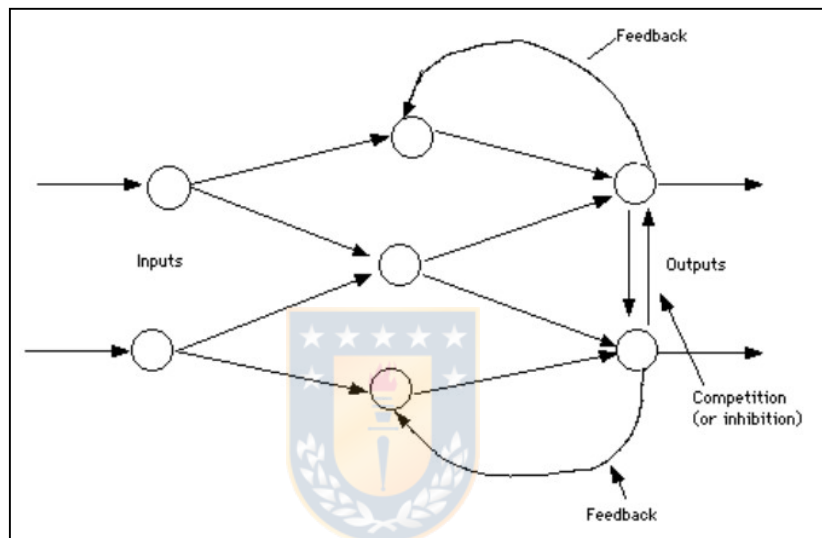
**Capa de Entrada (*Input Layer*):** Recibe los datos provenientes de los archivos iniciales (o inputs), o bien, de sensores electrónicos en aplicaciones en tiempo real.

**Capas Ocultas (*Hidden Layers*):** Pueden ser muchas. Se encuentran entre las dos anteriores. Estas contienen una gran cantidad de nodos en varias estructuras interconectadas. Las entradas y las salidas de cada una de estas neuronas ocultas simplemente van a otras neuronas.

**Capa de Salida (*Output Layer*):** Envía información directamente al mundo exterior, a un proceso informático secundario, o a otros dispositivos.



Las líneas de comunicación entre nodos son un aspecto importante de las RNA, ya que unifican el sistema. Son las conexiones que otorgan distintas fuerzas a las diferentes entradas. Existen dos tipos; una causa que el mecanismo combinatorio con la siguiente neurona suma, mientras que la otra hace que se reste. En términos más humanos, uno excita mientras que el otro inhibe. Algunas modelos de RNA, quieren que una neurona inhiba otras neuronas de la misma capa. Esto se llama inhibición lateral o competición (*competition* o *inhibition*), que usualmente ocurre en la capa de salida. Otro tipo de conexión es la retroalimentación (*feedback*), donde la salida de una capa regresa a la capa anterior (Figura 3.11).



**Figura 3.11: Red Neuronal Simple con retroalimentación y competición.** Tomado de Maind & Wankar (2014), sin modificaciones.

En este punto es necesario definir 2 términos útiles para la comprensión de la estructura de una red neuronal artificial:

**Perceptrón:** Primer modelo de RNA, creado en 1958 por el psicólogo Frank Rosenblatt. Es un simple algoritmo destinado a realizar clasificación binaria; es decir, predice si la entrada pertenece o no a una cierta categoría de interés. Fue presentado como el dispositivo “*Mark I perceptron*”, el cual básicamente funciona como una red sin capas ocultas (Figura 3.12). Se puede ver como la unidad elemental de una red neuronal actual (nodo).

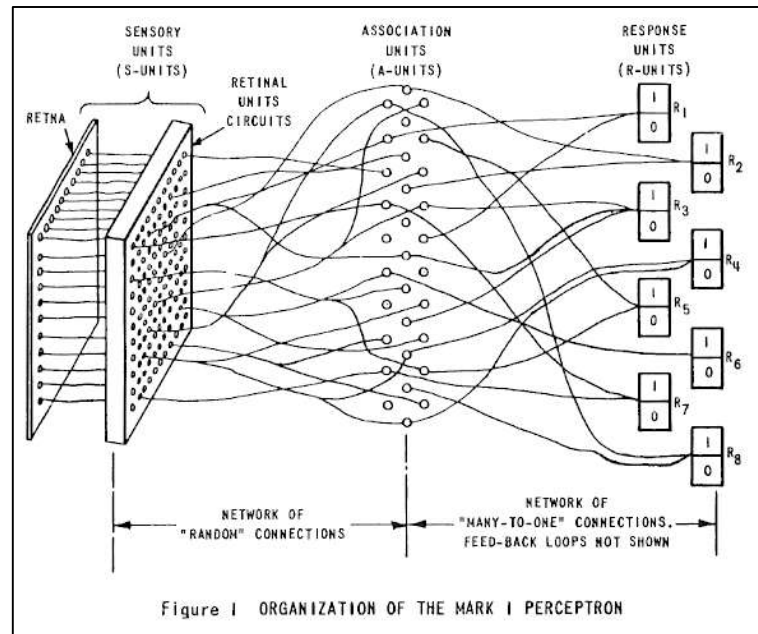


Figura 3.12: Esquemización del Perceptrón, la primera RNA. Representación gráfica de Mark I Perceptron. Tomado de Rosenblatt (1958), sin modificaciones.

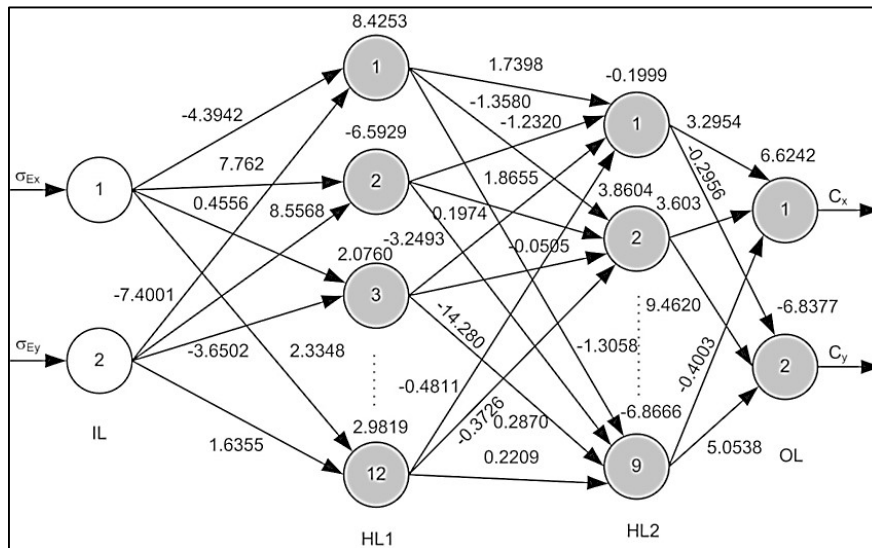
**Multi-Layer Perceptron (MLP):** RNA actual, está compuesta por más de un perceptrón, constituyéndose por una capa de entrada, una de salida y entre ambas un número arbitrario de capas ocultas que son el verdadero motor de este modelo. Es decir, se compone de al menos 3 capas de nodos o neuronas. Suelen ser utilizadas en problemas de aprendizaje supervisado.

### 3.3.5. FUNDAMENTO MATEMÁTICO

El procesamiento matemático que se lleva a cabo dentro de una red neuronal puede ser comprendido de manera más simple al revisar de forma separada el funcionamiento de cada elemento que compone internamente una red neuronal, así como también el significado de conceptos asociados a dichos elementos. Por esta razón, a continuación, se describirán conceptos y elementos clave que explican cómo una RNA procesa la información y aprende de ella.

**Peso Sináptico (*Synaptic Weight*):** En una RNA, las neuronas se conectan entre sí por medio de los *Synaptic Weights*, o sólo *Weights* (Figura 3.13). Cada neurona de la red recibe información ponderada a través de estas conexiones sinápticas desde las otras neuronas a las que se conecta, y genera un *output* por el paso de una suma ponderada de esas señales de entrada (ya sean entradas externas o entradas provenientes de otras neuronas) a través de una

función de activación. Previo al entrenamiento, a las ponderaciones iniciales de la red se le asignan valores uniformes de forma aleatoria.

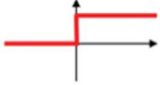
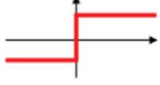






**Figura 3.13: Representación de los pesos sinápticos en una red neuronal.** Las cifras positivas y negativas expresadas sobre cada línea de conexión corresponden al peso asignado para cada entrada de nodo. Tomado de Bazil Raj *et al.* (2014), sin modificaciones.

**Función de entrada a la red (*Net input function*):** Corresponde a la función de entrada a cada neurona de la red, encargada de combinar las ponderaciones de cada *input* mediante una sumatoria simple del producto "*input x weight*".

**Función de activación (*Activation function*):** Se define como el camino desde la entrada hasta la salida de una neurona mediante una función de transformación no lineal. Su rol es determinar en cada nodo si transmitir, o no, la señal que éste ha recibido de la capa anterior y en qué medida. Es una combinación de *weights* y *biases* (sesgos) que trabajan sobre los datos de entrada de la capa anterior para determinar si esa señal sobrepasa un determinado umbral y se considera significativa. Los *weights* y *biases* se actualizan lentamente a medida que la red neuronal minimiza su error; es decir, el nivel de activación de los nodos cambia en el curso del aprendizaje.

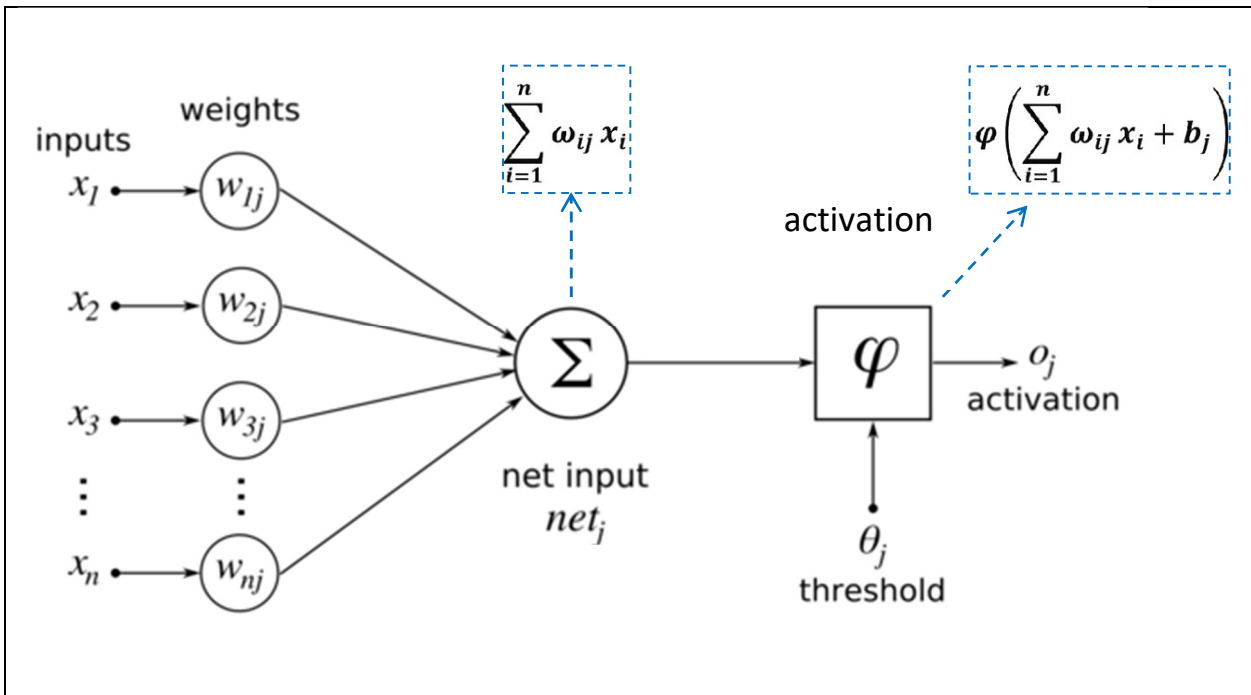
El *Deep Learning* considera funciones de activación como Sigmoidal, ReLU, Tanh y ELU, entre otras (Figura 3.14). Estas permiten a las redes neuronales tomar complejas decisiones de borde para características en varios niveles de abstracción.

Activation function	Equation	Example	1D Graph
Unit step (Heaviside)	$\phi(z) = \begin{cases} 0, & z < 0, \\ 0.5, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Sign (Signum)	$\phi(z) = \begin{cases} -1, & z < 0, \\ 0, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Linear	$\phi(z) = z$	Adaline, linear regression	
Piece-wise linear	$\phi(z) = \begin{cases} 1, & z \geq \frac{1}{2}, \\ z + \frac{1}{2}, & -\frac{1}{2} < z < \frac{1}{2}, \\ 0, & z \leq -\frac{1}{2}, \end{cases}$	Support vector machine	
Logistic (sigmoid)	$\phi(z) = \frac{1}{1 + e^{-z}}$	Logistic regression, Multi-layer NN	
Hyperbolic tangent	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	Multi-layer NN	

**Figura 3.14: Principales funciones utilizadas como función de activación en RNA.** Se exponen los nombres de las diferentes funciones, junto con sus respectivas ecuaciones, ejemplos de usos en IA y estadística, así mismo las gráficas asociadas a cada una para visualizar la variación y comportamiento posible de los valores que procesa cada función. Tomado de Raschka (2015), sin modificaciones.

**Neurona Bias (*Bias Neuron*):** Es una neurona especial añadida a cada capa de la red neuronal, que simplemente almacena el valor de 1, una constante. Esto hace posible trasladar la función de activación a izquierda o derecha en el gráfico de la función de activación. Vale decir, determina el corte de la función por el eje Y, controlando inconsistencias matemáticas al evitar posibles valores iguales a 0.

En la Figura 3.15 se ilustran los conceptos previamente definidos y se explica de forma simple la correlación entre ellos.



**Figura 3.15: Estructura matemática interna de una RNA.** Se muestra esquemáticamente lo que correspondería a un acercamiento del proceso matemático que se lleva a cabo en 1 neurona de una RNA. Cada *input* inicial de información ( $x$ ) entra a una neurona con un peso ( $w$ ) asociado, los cuales se suman mediante la función de entrada (*net input*  $\Sigma$ ) para luego ser enviadas a la función de activación (*activation function*  $\varphi$ ), la cual realizará la discriminación para dejar pasar o no el flujo de información hacia la siguiente neurona, y se aplica el valor constante de la neurona Bias ( $b$ ). Modificado de Sibi et al. (2013).

**Función Error (Error Function):** El error, en cualquier punto del entrenamiento de la red neuronal, se puede definir como la diferencia entre la aproximación realizada por nuestro modelo y el valor objetivo real que estamos tratando de alcanzar y siempre es de un solo valor, ya que su trabajo es evaluar cómo es la red en su conjunto. De forma general, el error se puede entender de acuerdo a la siguiente ecuación:

$$e_j(n) = d_j - y_j(n)$$

Donde "e" es el error,  $d_j$  es el *output* deseado para la neurona  $j$  y  $y_j(n)$  es el *output* real obtenido para la neurona  $j$  calculada mediante el uso de los actuales pesos de la red en la iteración número "n" (Sazli, 2006).

Para cada neurona se aplica una función de error, la cual puede ser la suma de errores al cuadrado (sse) o la entropía cruzada (ce) (Figura 3.16), siendo la primera la más utilizada.

Estas funciones deben cumplir con dos condiciones para ser utilizadas en el proceso de entrenamiento:

- Debe poder ser escrita como un promedio o media.
- No debe depender de ningún valor de activación de la red junto a la capa de salida.

$$E_{sse} = \frac{1}{2} \sum_{l=1}^L \sum_{h=1}^H (o_{lh} - y_{lh})^2$$


$$E_{ce} = \frac{1}{2} \sum_{l=1}^L \sum_{h=1}^H [y_{lh} \log(o_{lh}) + (1 - y_{lh}) \log(1 - o_{lh})]$$

**Figura 3.16: Funciones de Error en una RNA.** Se presentan las ecuaciones correspondientes a la suma de errores al cuadrado ( $E_{sse}$ ) y la entropía cruzada ( $E_{ce}$ ). Tomado de Zhang (2016).

**Algoritmo de retropropagación (*Backpropagation algorithm*):** Es el algoritmo más utilizado en el proceso de entrenamiento (*training*) de una *Feedforward Network*. Es un método de actualización de los pesos sinápticos de la red mediante retropropagación, que es la aplicación repetida de cálculos de derivadas parciales de los errores con respecto al peso, siguiendo una regla en cadena de acuerdo a la siguiente igualdad:

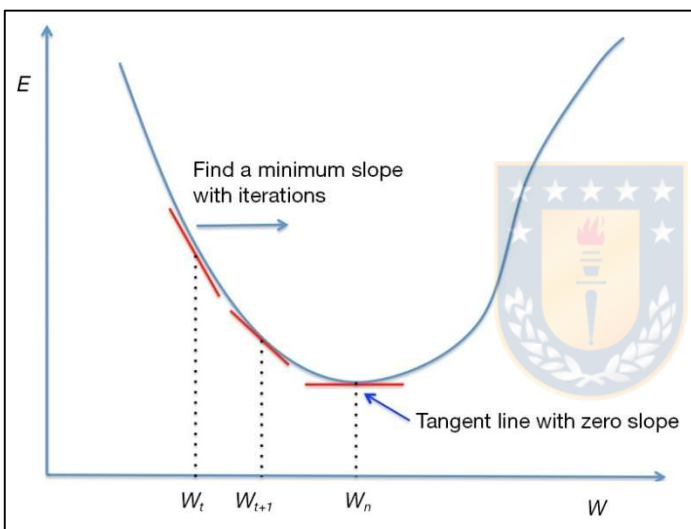
$$\frac{\partial z}{\partial x} = \frac{\partial z}{\partial y} \cdot \frac{\partial y}{\partial x} \rightarrow \frac{\partial \text{Error}}{\partial \text{Weight}} = \frac{\partial \text{Error}}{\partial \text{Activacion}} \cdot \frac{\partial \text{Activacion}}{\partial \text{Weight}}$$

Parte por calcular las derivadas de la función objetivo con respecto a las unidades de salida, luego las derivadas de la salida de la última capa oculta a la entrada de la misma; luego la entrada de la última capa oculta a los pesos entre ella y la penúltima capa oculta, y así sucesivamente. Es decir, en este proceso de actualización de los pesos sinápticos, existe un flujo de información inverso, desde la capa de salida hasta la capa de entrada (Figura 3.17).



**Figura 3.17: Esquema simple de la retropropagación.** Se muestra de manera simple el flujo de información durante el proceso de retropropagación, ejecutando las derivadas parciales de los errores con respecto al peso siguiendo una regla en cadena. Modificado de Raschka (2015).

Las derivadas parciales absolutas de la función de error con respecto al peso, corresponden a pendientes (*slopes*) que nos sirven de guía para encontrar un error mínimo (Figura 3.18). Este mecanismo de ajuste también es conocido como “Gradiente Descendiente”.



**Figura 3.18: Reducción del Error mediante derivadas parciales con respecto al peso.** Representación gráfica del significado de la derivación parcial en cadena en el algoritmo de retropropagación. El objetivo es encontrar una tangente con pendiente mínima que indicaría el error mínimo que el modelo de RNA es capaz de generar. Tomado sin modificaciones de Zhang (2016).

**Tasa de aprendizaje (*Learning rate*):** La eficacia y la convergencia de la retropropagación se basan en el valor de la constante de aprendizaje  $\eta$ . La cantidad por la cual son actualizadas las ponderaciones o pesos de la red es directamente proporcional al factor de aprendizaje  $\eta$  y por lo tanto juega un papel importante en el en la señal de error de una neurona. La tasa de aprendizaje normalmente se ajusta a un valor predeterminado y se mantiene constante durante el funcionamiento del algoritmo. La *Learning rate* se encuentra presente en cada actualización de retropropagación según la siguiente fórmula (Zhang, 2016):

$$w_k^{(t+1)} = w_k^{(t)} - \eta \frac{\partial E^{(t)}}{\partial w_k^{(t)}}$$

Donde  $w_k^{(t+1)}$  es el nuevo peso actualizado en la neurona  $k$  en la iteración  $(t+1)$ ,  $w_k^{(1)}$  es el peso anterior en la primera iteración y la constante  $\eta$  está multiplicando a la derivada del error con respecto al peso.

**Umbral (*Threshold*):** corresponde a un valor constante arbitrariamente asignado al modelo, que indica el valor mínimo de la pendiente (o derivada parcial) del mecanismo Gradiente Descendiente de la retropropagación, con el fin de indicar el límite para detener las iteraciones dentro de la red, ya que difícilmente se dará con un valor de pendiente mínima igual a 0.

### 3.3.6. APRENDIZAJE Y ANÁLISIS DE RNA

Ya entendido el concepto y funcionamiento teórico de una red neuronal, es preciso entender cómo se lleva a cabo la construcción y aprendizaje de una RNA, orientada a la solución de un problema de regresión como lo es el análisis de susceptibilidad de RM.

Llevando los conceptos e ideas desarrolladas anteriormente a una situación más tangible y realista, las RNA son sistemas que se construyen en entornos de desarrollo integrado "IDE" (*Integrated Development Environment*) aplicaciones informáticas diseñadas para facilitar la creación *softwares* empleando diferentes lenguajes de programación, como lo son Python, R, Java, C++, C#, Visual Basic, entre otros. Existen numerosos IDE, tales como VS Code, IDLE, Eclipse, RStudio, Matlab, NetBeans, Geany, CodeRun, entre muchos otros.

Independientemente del lenguaje de programación e IDE seleccionado para crear y entrenar una RNA, el procedimiento requiere seguir 3 grandes etapas que se explican a continuación.

#### 3.3.6.1. ETAPAS DE APRENDIZAJE

##### **Entrenamiento (*Training*)**

Su objetivo es entrenar la red neuronal para arrojar los resultados deseados. Para cada registro se conoce el resultado esperado (esto es *Supervised Learning*) por lo que a los nodos (neuronas) de salida se les puede asignar valores «1» para el que corresponda a la clase correcta, y «0» para los que no (esto es, para cada variable binaria de salida). De este modo es posible comparar los valores calculados en la red en los nodos de salida con estos valores "correctos", y calcular un término de error para cada uno. Estos términos de error se utilizan



para ajustar los pesos en las capas ocultas con el fin de que los valores de salida se acerquen a los deseados en las siguientes iteraciones hasta llegar a un error mínimo.

Para esta etapa se requiere un set de datos (*dataset*) de *training*, el cual abarca una porción del espectro total de datos a analizar. Incluye:

- Variables independientes, también llamados predictores o factores.
- Resultado esperado para la variable en evaluación, es decir, un registro o catastro de eventos.

### **Testeo (*Testing*)**

En esta fase, el objetivo es la calibración del modelo previamente entrenado. Se lleva a cabo el procesamiento de los datos de entrada (variables independientes) con un conjunto de datos de testeo, distinto al utilizado en la fase de entrenamiento. Se genera un resultado a partir de los pesos corregidos durante el *training*, y se evalúa el grado de precisión mediante un porcentaje de validación de acuerdo al grado de acierto con respecto a los valores de referencia contenido en el *dataset* de *testing* que corresponde a otro subconjunto de datos (más pequeño) extraído del conjunto total a evaluar. Los resultados entregados en esta fase dependerán también de la calidad y confiabilidad de los datos de entrada.

### **Análisis final**

Consiste en ejecutar la RNA ya entrenada, ingresando los datos que se desea evaluar y obtener una respuesta o solución al problema establecido.

Cabe mencionar que las 2 primeras etapas usualmente deben ser repetidas numerosas veces, cambiando y configurando tanto las variables que controlan en suceso evaluado, así como la arquitectura y parámetros que definen la red neuronal. Esto con el fin de dar con el modelo de RNA más adecuado para el problema y set de datos disponible.

#### **3.3.6.2. HERRAMIENTAS DE ANÁLISIS**

Si bien las RNA pueden ser utilizadas como potentes herramientas de estimación comparadas con otros modelos convencionales (como la regresión logística), también se les critica ser “*black boxes*”, es decir, unas cajas negras (Zhang *et al.*, 2018). Esto se debe a que, en comparación a

otros métodos, los modelos de RNA son muy difíciles de interpretar, y el identificar qué variables “predictoras” son las más importantes y cómo se relacionan para ser modeladas apropiadamente. Por este motivo, nace la necesidad de utilizar herramientas de análisis que permitan “develar” esta caja negra, y así poder entender cómo la red neuronal procesa y estima cada covariable que explica (o explicaría) el fenómeno o problema evaluado.

Las herramientas mencionadas van a depender del entorno y lenguaje de programación seleccionados para llevar a cabo el estudio. Dado que para el presente trabajo se optó por utilizar el lenguaje R y mediante el IDE RStudio, las herramientas de análisis a utilizar serán aquellas especialmente diseñadas para llevar a cabo en dicho entorno, con base en los trabajos Beck (2018), Zhang (2016), Zhang *et al.* (2018) y Fritsch & Günther (2010).

### **Pesos Generales (*General Weights*)**

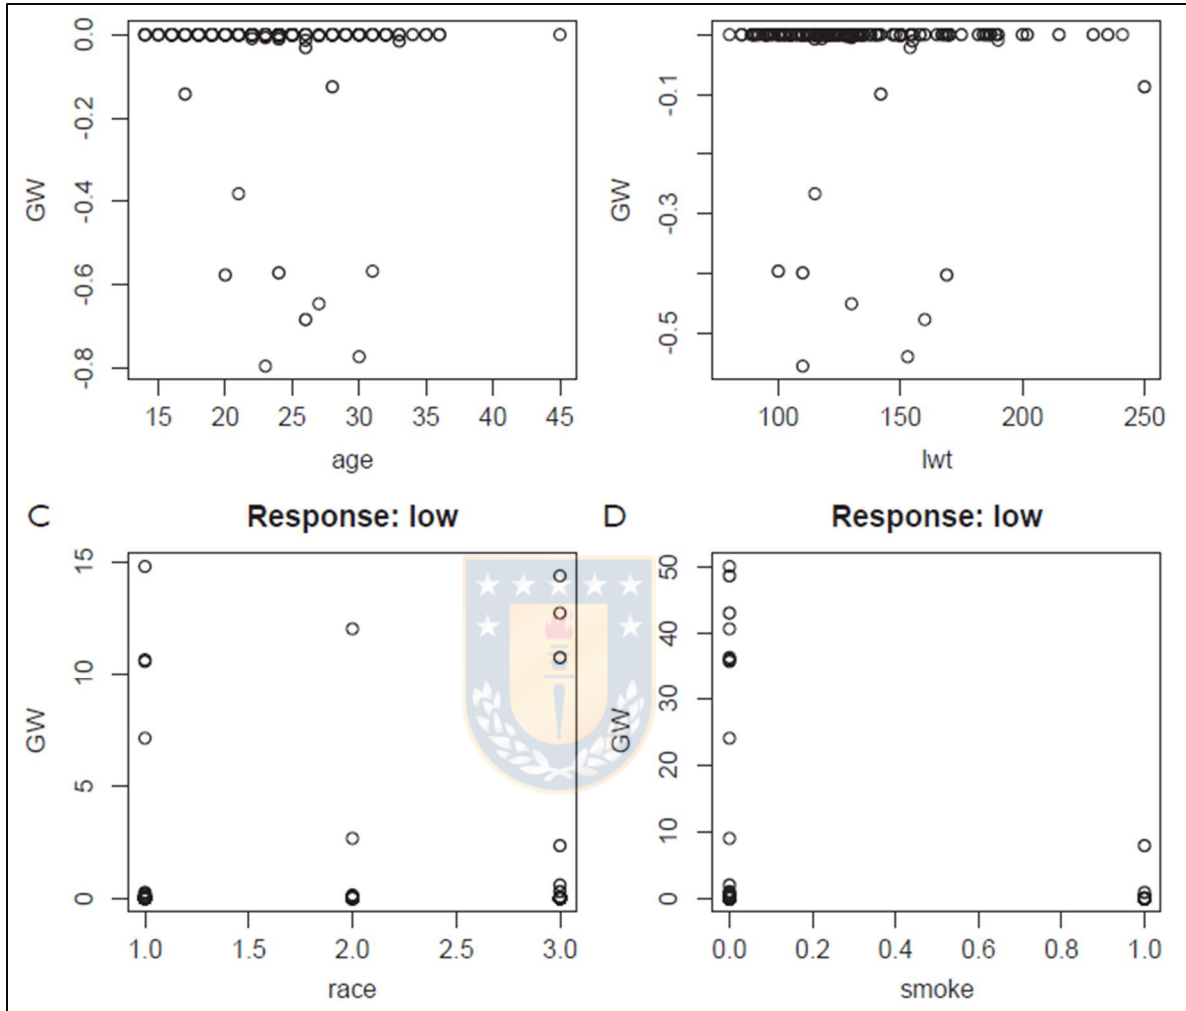
La interpretabilidad del modelo RNA requiere entender el efecto independiente de cada variable individual en la predicción del modelo. Intrator & Intrator (2001) desarrollaron el concepto de pesos generales para la interpretación de la red neuronal. Esta herramienta de análisis ha sido desarrollada para el paquete de funciones “neuralnet”, elaborado por Fritsch & Günther (2010) para creación de redes neuronales en RStudio. Los pesos generales (GW) se escriben matemáticamente como:

$$GW_i = \frac{\partial \log \left[ \frac{o(x)}{1 - o(x)} \right]}{\partial x}$$

Donde “i” es el índice para cada variable, “o(x)” es la probabilidad del resultado previsto por cada vector variable. Log-*odds* es la función de enlace para el modelo de regresión logística. La derivada parcial de la función log-*odds* con respecto a la variable de interés es el coeficiente para esa variable.

De acuerdo a Zhang (2016), lo anterior se traduce en gráficas que ayudarán a identificar las variables que no cumplen con el requisito de no-linearidad de las RNA (Figura 3.19); aquellas que no presentan variabilidad gráfica concentrando sus puntos en un valor constante (por ejemplo, cero), son covariables de comportamiento lineal, lo cual indicaría que éstas no tienen efectos sobre los resultados del modelo. En cambio, las covariables que muestran gran variabilidad gráfica (positiva y/o negativa) se interpretan como variables no-lineales, las que sí

afectarían la salida de la RNA. Dichas interpretaciones permiten discriminar variables en el proceso de construcción de la red, al señalar aquellas que no aportan en la explicación del suceso evaluado.



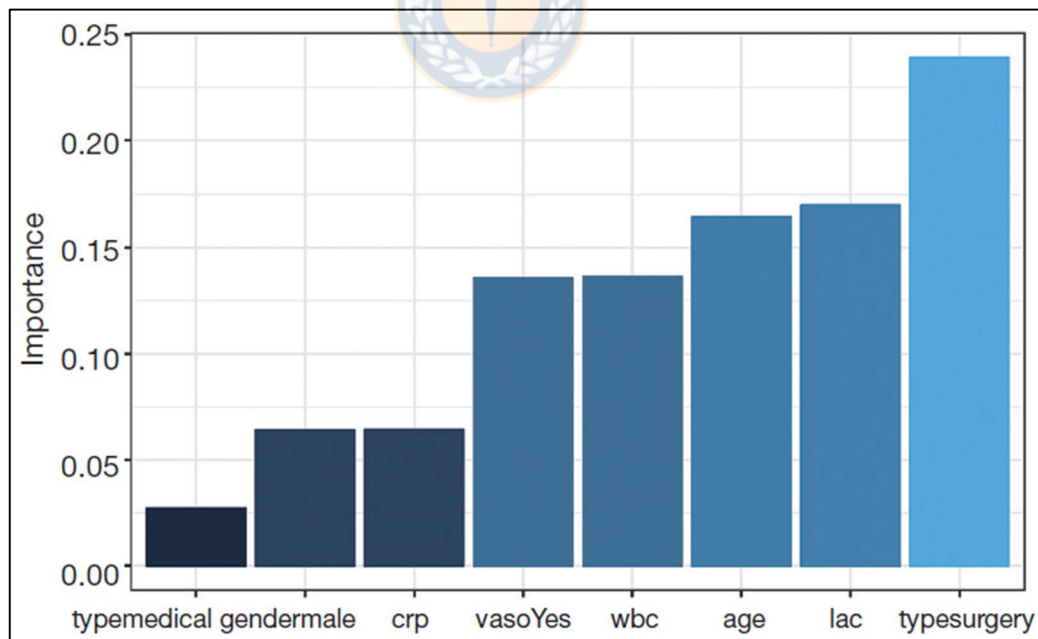
**Figura 3.19: Gráfica ejemplo de General Weights.** Ejemplo de aplicación de análisis de pesos generales en un problema médico. Se muestran los pesos asociados a cada covariable en gráficos separados. El valor de los pesos generales se grafica en el eje de las ordenadas. Se puede ver que las covariables “age” y “lwt” se mayormente concentran en un valor constante, indicando que dichas variables se comportan de manera lineal con respecto al suceso evaluado, por lo cual podrían ser desestimadas del análisis global con RNA. Tomado sin modificaciones de Zhang (2016).

### Importancia de Variables: Algoritmos de Garson y de Olden

Enmarcado en el paquete de funciones “NeuralNetTools” de RStudio, formulado por Beck (2018), ofrece un set de herramientas de análisis de RNA creadas con los principales paquetes de redes neuronales utilizados en RStudio, como lo son “caret”, “neuralnet”, “nnet”, y “RSNNS”.

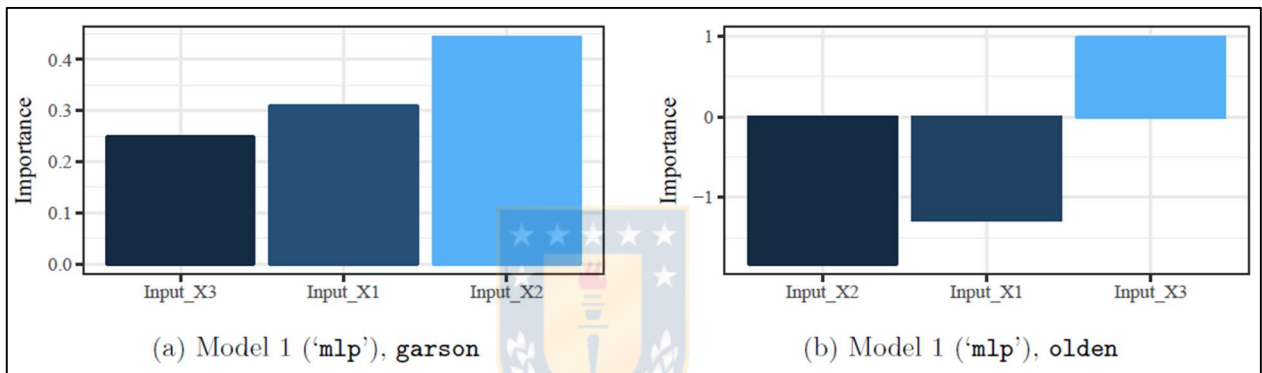
Según consigna el autor mencionado, existen métodos alternativos para describir cuantitativamente una red neuronal, los cuales deconstruyen los pesos del modelo para determinar la importancia de las variables. NeuralNetTools dispone de 2 algoritmos para evaluar la importancia de las variables en una RNA; el algoritmo de Garson de importancia relativa (Garson, 1991; Goh, 1995), y el algoritmo de Olden de los pesos de conexión (Olden *et al.*, 2004).

El algoritmo de Garson es una función que identifica la importancia relativa de cada variable como una magnitud absoluta. Para cada nodo de entrada (covariables), se identifican todos los pesos que conectan una entrada a través de la capa oculta a la variable de respuesta para devolver una lista de todos los pesos específicos de cada variable de entrada. Los productos sumados de las conexiones de cada nodo de entrada se escalan en relación con todas las demás. Un valor para cada nodo de entrada indica la importancia relativa como la magnitud absoluta de 0 a 1, lo cual se entrega en un gráfico de barras (Figura 3.20). Este método está limitado en el sentido de que no se puede determinar la dirección de la respuesta (si es negativa o positiva) y sólo pueden evaluarse las redes neuronales con una capa oculta y un nodo de salida.



**Figura 3.20: Gráfica ejemplo del algoritmo de Garson.** La función implementada en NeuralNetTools para el algoritmo de Garson entrega como salida una gráfica de barras donde se exponen comparativamente las diferentes variables ingresadas al modelo, ordenadas de menor a mayor importancia. Tomado sin modificaciones de Zhang *et al.* (2018).

Por otra parte, el algoritmo de Olden calcula la importancia como el producto sumado de los pesos de conexión *input-hidden* y *hidden-output* entre cada nodo de entrada y salida. Una ventaja es que la contribución relativa de cada conexión se mantiene tanto en magnitud como en signo (Figura 3.21). Por ejemplo, los pesos de conexión que cambian su signo (por ejemplo, de positivo a negativo) entre las capas *input-hidden* a *hidden-output* tendrían un efecto de cancelación, mientras que Garson puede proporcionar resultados diferentes basados en la magnitud absoluta. Una ventaja adicional es que la función de Olden puede evaluar RNA con múltiples capas ocultas y variables de respuesta (nodos de salida). Los valores de importancia asignados a cada variable están en unidades basadas en el producto sumado de los pesos de conexión, mientras que Garson devuelve la importancia en una escala de 0 a 1.

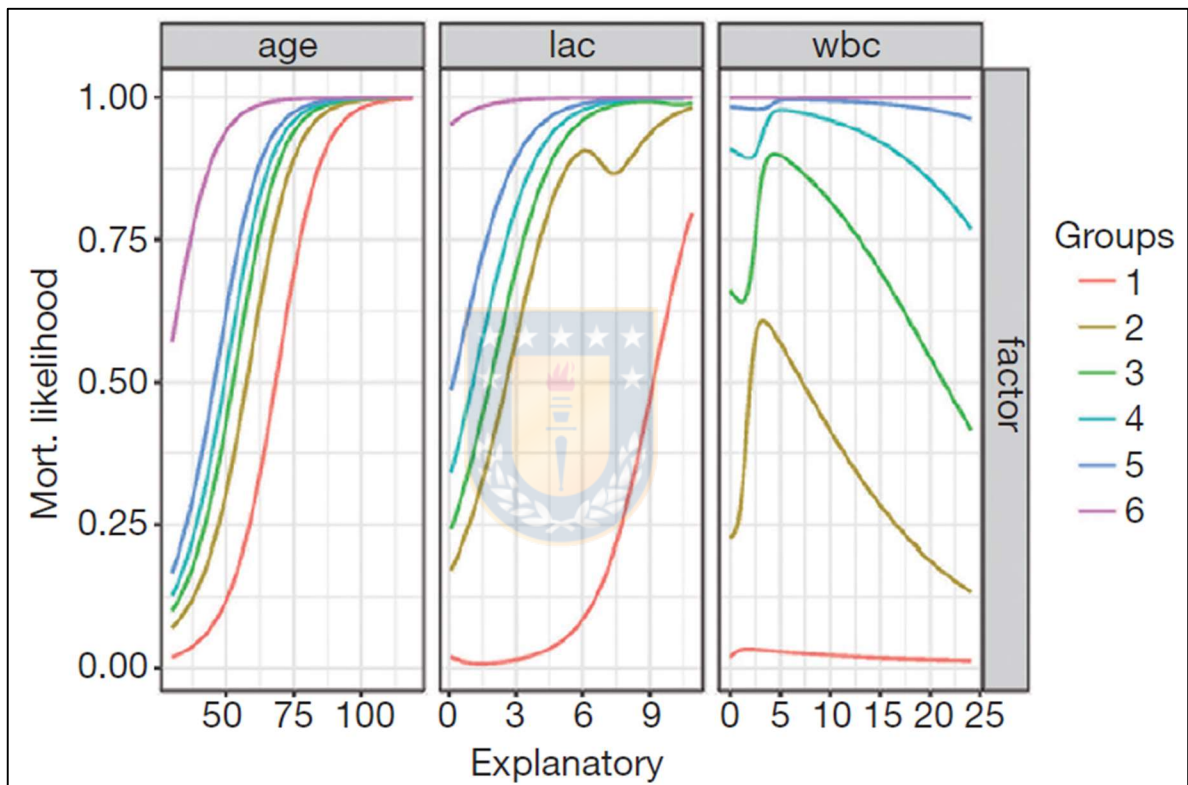


**Figura 3.21: Comparación gráficas de Garson y Olden.** Las diferencias entre ambas gráficas radican en la capacidad de Olden para mantener y representar la importancia de las variables tanto en magnitud como en signo, por dicha razón se pueden observar barras tanto en el cuadrante positivo como en el negativo. Además, los valores entregados por Olden pueden ser mayor a 1 y menor a -1 ya que provienen de una suma directa sin ponderación, a diferencia de Garson. Tomado sin modificaciones de Beck (2018).

### Análisis de sensibilidad: Perfil de Lek (*Lek profile*)

Un enfoque alternativo para evaluar las relaciones entre variables en una RNA es el método del perfil Lek, o *Lek Profile* (Lek *et al.* 1996; Gevrey *et al.*, 2003). Este método difiere fundamentalmente de los algoritmos de importancia de las variables, ya que evalúa el comportamiento de las variables de respuesta (salida o *output*) a través de diferentes valores de las covariables (variables explicatorias, o predictores). El método es genérico y puede extenderse a cualquier modelo estadístico en R con un método de predicción. Sin embargo, es uno de los pocos métodos utilizados para evaluar la sensibilidad en las RNA, en este caso contenido dentro del paquete NeuralNetTools ya mencionado anteriormente.

La función evalúa de forma independiente los efectos de cada variable de entrada al construir una gráfica (Figura 3.22) que simula predicciones del modelo entrenado (eje de las ordenadas), a través del rango de valores de cada una de esas variables (eje de las abscisas). El resto de las variables explicativas se mantienen constantes en diferentes niveles, por lo que se genera una curva para cada nivel; esto se realiza con el fin de evaluar los efectos de las variables de entrada sobre las demás. Es decir, por una parte, se evalúa el comportamiento de una variable de entrada frente al fenómeno estudiado (*output*), y por otra, se detecta qué tan sensible es dicha variable ante la presencia del resto de las variables explicativas (*inputs*).



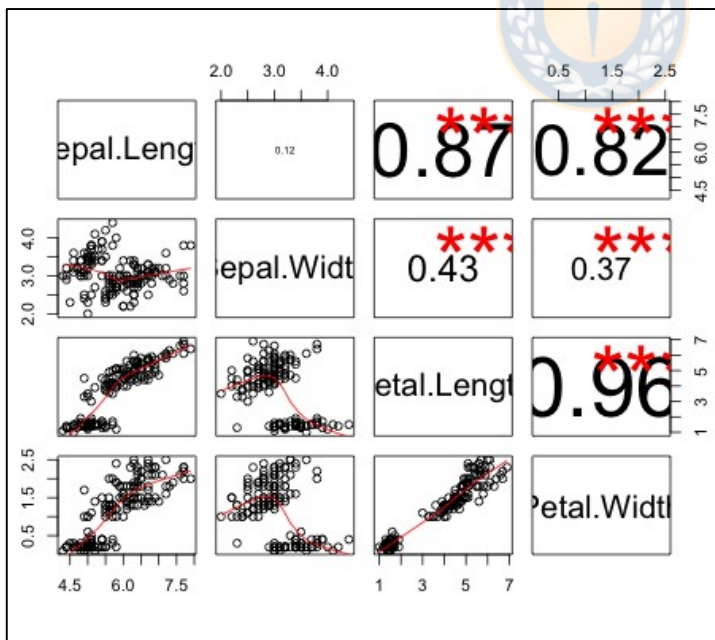
**Figura 3.22: Gráfica ejemplo Lek Profile.** Se presentan 3 gráficas correspondientes a 3 variables evaluadas ("age", "lac" y "wbc") en un estudio del área de la medicina. Cada gráfica contiene un total de 6 curvas que representan 6 grupos definidos por el grado de contribución de las demás variables, en este caso definido por cuantiles (0, 20, 40, 60, 80 y 100 por ciento). Es decir, en la variable "age", la curva color café del grupo 2 muestra una cómo varía dicho factor en relación a la probabilidad simulada (*output*), manteniendo el resto de los predictores constantes en el cuantil 20, mientras que la curva morada del grupo 6 realiza la evaluación con el 100% de las variables, es decir, constantes en su valor máximo. La misma lógica se aplica para cada gráfica. En un modo simple, la variable evaluada será más sensible mientras más cambie la tendencia de las curvas al incrementar el porcentaje de contribución de los demás predictores. En este ejemplo, la variable "wbc" presenta una mayor sensibilidad al variar abruptamente su comportamiento al aumentar el aporte de los demás factores. Tomado sin modificaciones de Zhang *et al.* 2018.

Los niveles mencionados anteriormente, corresponden a los cuantiles de la distribución de cada variable explicativa. Es decir, las diferentes curvas que muestra el perfil de Lek mantienen

constantes los demás predictores en un cierto cuantil (mínimo, 20, 40, 60, 80 y máximo), mientras que varían la variable de interés desde su mínimo a su máximo valor. Una explicación más acabada y extensa sobre esta herramienta de análisis puede ser revisada en el trabajo de Beck (2018).

### Gráfica de comparación a pares (*Pairwise plot*)

Una herramienta adicional para analizar la relación que existe entre las variables de entrada y la variable de respuesta, y a su vez analizar la relación existente entre el conjunto de variables de entrada (covariables), es una gráfica de comparación a pares, o *Pairwise Plot*. Esto corresponde a una forma de representación de los datos en una matriz de dimensión “n x n”, donde n corresponde al número de variables de entrada, o predictores que explican un fenómeno en un modelo de regresión. En dicha matriz se relacionan o comparan unas variables con otras, una a una, generando diagramas de dispersión (*scatter plots*) para cada par de variables enfrentadas (Figura 3.23). En este caso también se incluye en la matriz la variable de respuesta, o predicción hecha por el modelo, para tener una visión generalizada del modo de variación de cada predictor con la variable de respuesta.



**Figura 3.23: Gráfica ejemplo de *Pairwise Plot*.** Se observa una matriz de 4x4, ya que se comparan 4 variables explicativas. En la diagonal se encuentra el nombre correspondiente de cada variable, mientras que en la porción inferior se muestra la distribución de los datos en gráficos de dispersión que enfrentan la variable más próxima en la diagonal tanto hacia la arriba (valores en eje x) y hacia la derecha (valores en eje y). En la porción superior se muestran indicadores del grado de ajuste o grado de relación entre cada par correspondiente, marcadas con asteriscos color rojo aquellas que tienen un indicador relevante. Elaboración propia con set de datos de ejemplo disponibles en RStudio.

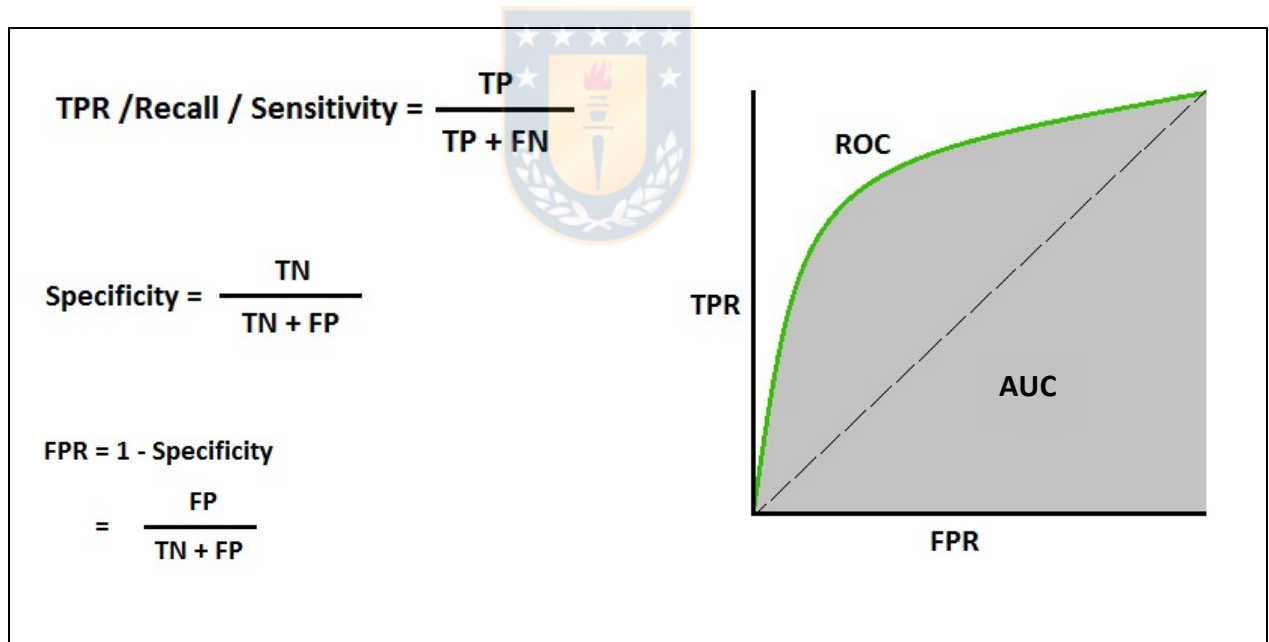
Este tipo de gráficas pueden ser aplicadas en cualquier estudio de regresión estadística, y puede ser llevado a cabo empleando diferentes lenguajes de programación. En el caso de R,

los *Pairwise plot* pueden realizarse con diferentes funciones contenidas en los paquetes “lattice” o “ggplot2”.

### Gráfica ROC/AUC

Es pertinente analizar el modelo desde un enfoque de rendimiento del mismo, es decir, es necesario evaluar qué tan asertivo es el modelo de RNA.

La Gráfica ROC/AUC (Figura 3.24) es una medida del rendimiento para el problema de clasificación en varios umbrales. ROC (*Receiver Operating Characteristic*, o Característica Operativa del Receptor) es una curva de probabilidad y AUC (*Area Under the Curve* o Área Bajo la Curva) representa el grado o medida de separabilidad. Dice cuánto es capaz el modelo de distinguir entre clases. Cuanto más alto es el AUC, mejor es el modelo para predecir “0” como “0” y “1” como “1”. Por analogía, cuanto más alto es el AUC, mejor es el modelo para distinguir entre zonas con deslizamiento y sin deslizamiento.

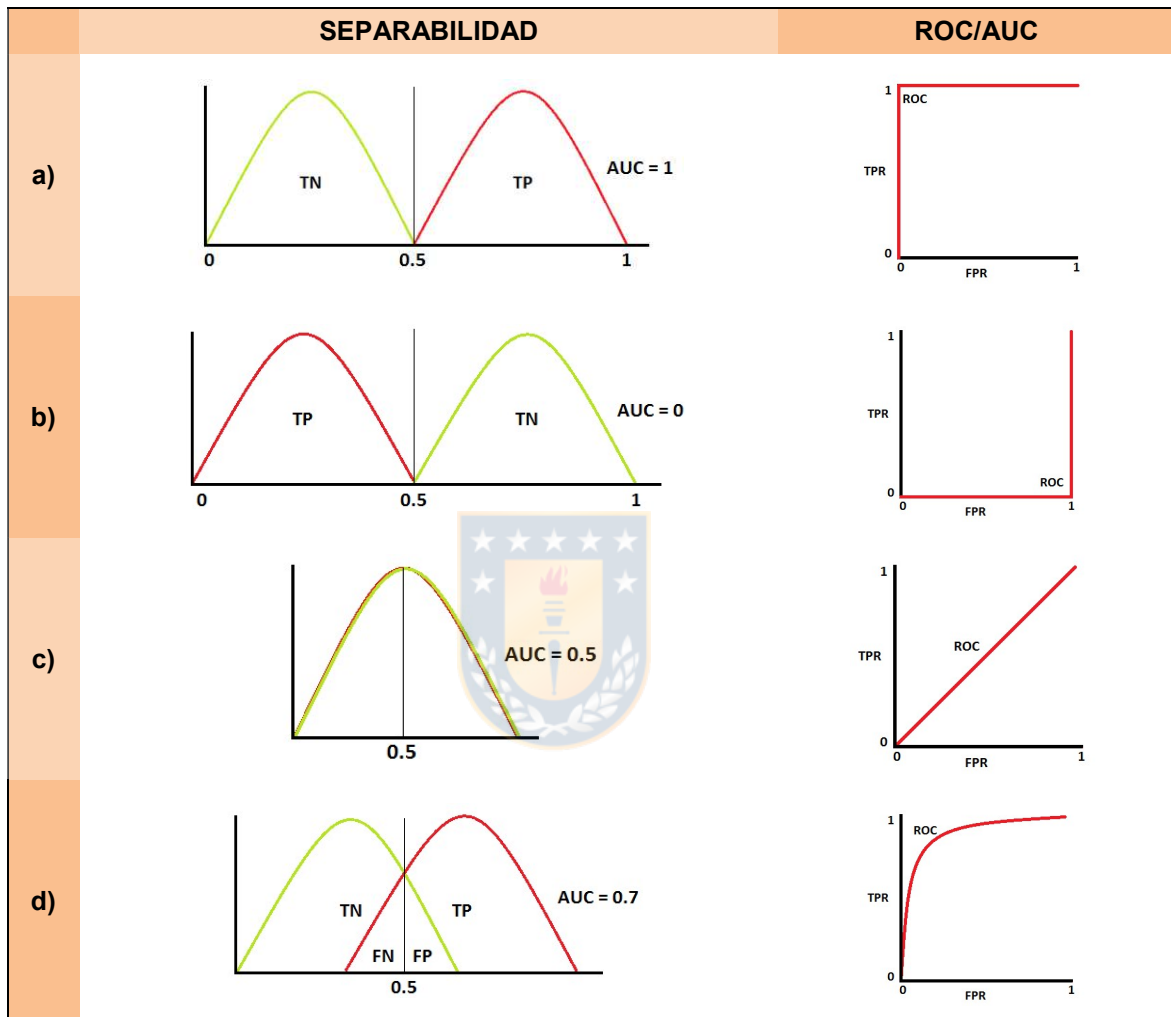


**Figura 3.24: Descripción de gráfica ROC/AUC.** Se presentan los términos que conforman la gráfica: *True Positive Rate* (TPR), la Especificidad y el *False Positive Rate* (FPR), los cuales están basados en medidas de aciertos y errores en el modelo, los cuales son: Verdaderos Positivos (TP), Falsos Negativos (FN), Verdaderos Negativos (TN) y Falsos Positivos (FP). En la gráfica se utilizan el FPR en el eje x y TPR en el eje y, las que dan origen a la curva ROC, y el área bajo dicha curva (AUC), medido de 0 a 1 permite una mejor interpretación del rendimiento del modelo. Modificado de Fawcett (2005).

Tal como se expresa de forma gráfica en la Figura 3.25, un excelente modelo tiene AUC cerca del 1, lo que significa que tiene una buena medida de separabilidad. Por otra parte, un modelo



pobre tiene un AUC cercano al 0, lo cual indica que tiene la peor medida de separabilidad; de hecho, significa que está reciprocando el resultado (predice 0 como 1 y 1 como 0). Cuando AUC es 0.5, significa que el modelo no tiene ninguna capacidad de separación de clases. Lo esperable de un buen modelo es que el AUC se encuentre entre 0.7 y 1.

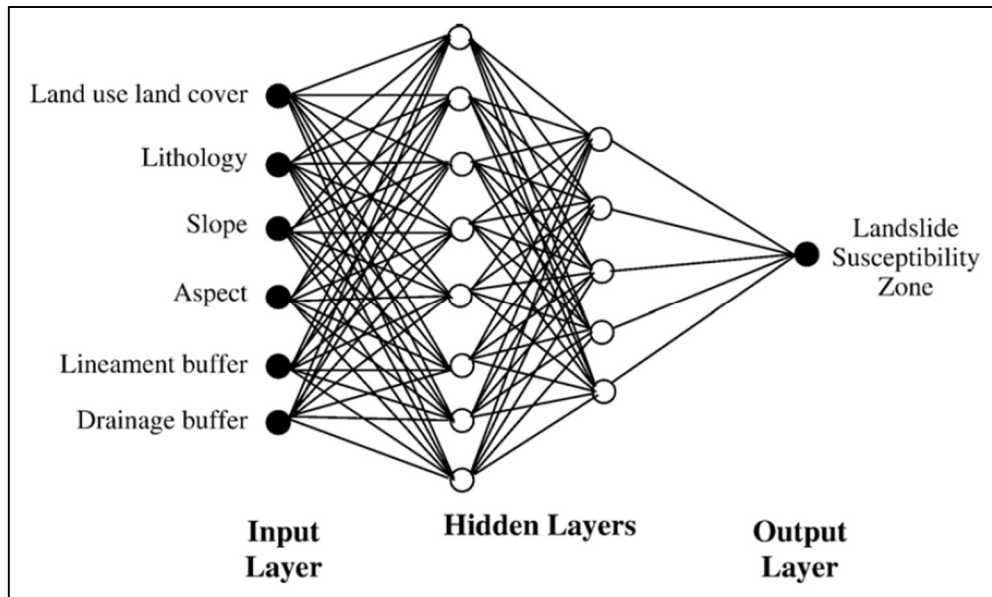


**Figura 3.25: Interpretación de gráfica ROC/AUC.** Se expone de forma gráfica la separabilidad entre clases de 4 distintos casos de modelos con AUC 1, 0, 0.5 y 0.7. En cada caso se tomó a modo de ejemplo un umbral de separación igual a 0.5, esto quiere decir, que todas las salidas del modelo de RNA que tengan un valor igual o mayor a 0.5 se considerarán igual a 1 (evento positivo), y bajo dicha cifra, se considerarán 0 (evento negativo). a) separabilidad perfecta, AUC=1, predice todos los positivos como positivos y negativos como negativos, b) separabilidad inversa, AUC=0, predice todos los positivos como negativos, y viceversa, c) sin capacidad de separabilidad, AUC=0.5, no tiene capacidad de distinción entre clases, d) separabilidad adecuada, AUC=0.7, si bien la predicción no es perfecta y existen falsos negativos y falsos positivos, está dentro de un rango aceptable. Un buen rendimiento de modelo se encuentra con AUC entre 0.7 y 1. Modificado de Fawcett (2005).

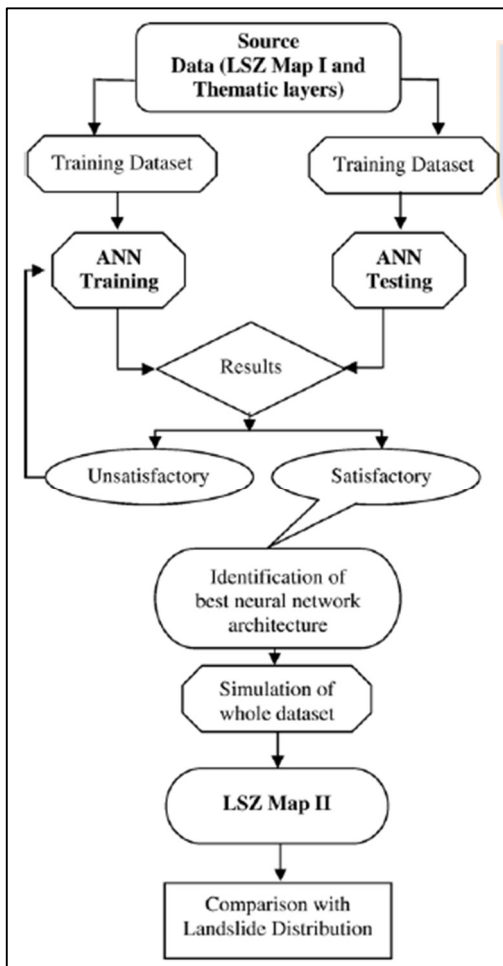
### 3.3.7. RNA APLICADA EN EL ANÁLISIS DE SUSCEPTIBILIDAD

Ya explicadas las bases teóricas en cuanto a la comprensión y construcción de redes neuronales, se hace necesario entender su aplicabilidad en el análisis de susceptibilidad (AS) de remociones en masa. Esto ha sido llevado a cabo por numerosos trabajos en diversos países, cuyos autores bien explican la analogía entre la arquitectura de una RNA y los elementos propios de un AS, así también el procedimiento metodológico generalizado para llevar a cabo un estudio de estas características con el uso de RNA.

De acuerdo a lo anterior, se tiene que de forma análoga, las variables explicativas (variables de entrada, covariables o predictores) corresponden a los factores condicionantes (o factores de estabilidad) del terreno en un análisis de susceptibilidad tomados a partir de un recurso digital SIG, como lo es un ráster DEM, mientras que la variable de respuesta, o variable de salida (output) de una RNA equivale a la ocurrencia de procesos de remoción en masa (a modo general, o un tipo específico de éstos, como deslizamientos), cuyo comportamiento es binario, es decir, puede ocurrir (positivo, 1), o no ocurrir (negativo, 0). De esta forma, se tiene que los nodos de la capa de entrada (inputs) se conforman por los diferentes factores condicionantes (cada uno es un nodo), y la capa de salida se conforma sólo por un nodo que representa la medida de probabilidad de ocurrencia de un evento de remoción en masa. La Figura 3.26 muestran un ejemplo de esta analogía de manera gráfica, mientras que en la Figura 3.27 se presenta un esquema metodológico generalizado propuesto por Kanungo *et al.* (2006) para llevar a cabo este tipo de análisis con RNA.



**Figura 3.26:** Arquitectura de una RNA aplicada a Análisis de Susceptibilidad de RM. Tomado sin modificaciones de Kanungo *et al.* (2006).



**Figura 3.27:** Diagrama de flujo para la aplicación de RNA en análisis de susceptibilidad de deslizamientos. Muestra de forma generalizada los pasos a seguir en la aplicación de este método para Análisis de Susceptibilidad (LSZ). Tomado sin modificaciones de Kanungo *et al.* (2006).

## 4. METODOLOGÍA

### 4.1. ETAPA DE GABINETE 1 (PRE-TERRENO)

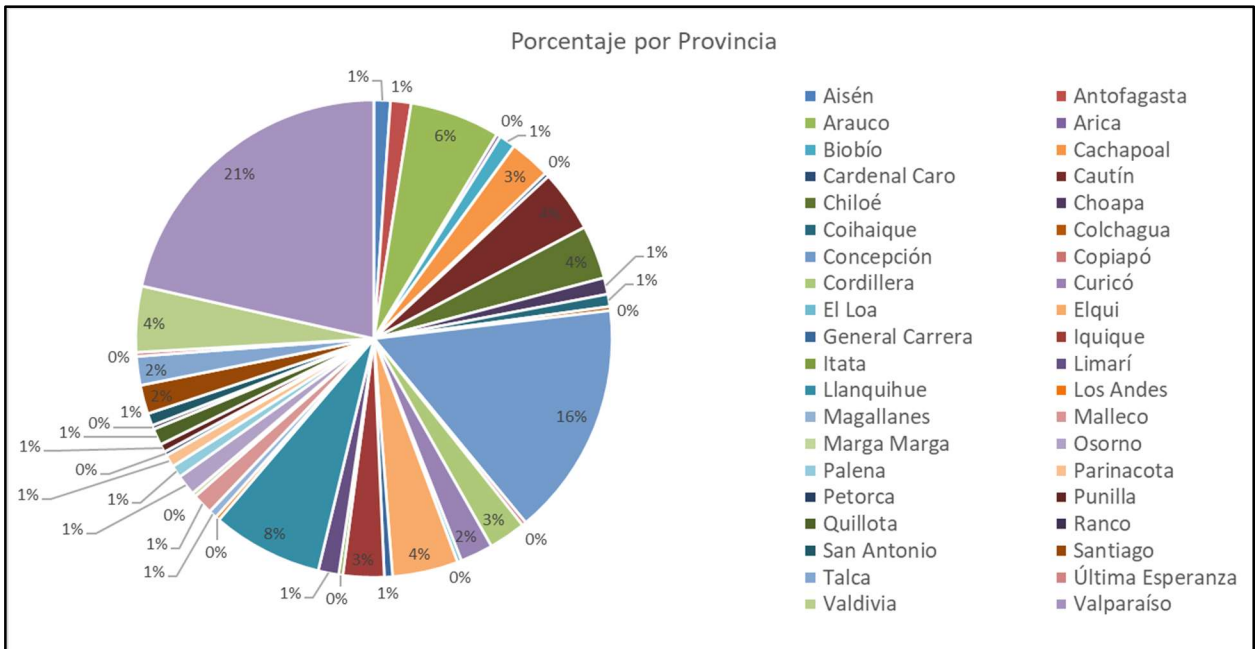
#### 4.1.1. DEFINICIÓN DEL ÁREA DE ESTUDIO

En primera instancia, fue necesario definir el área a lo largo de Chile donde se aplicará el método seleccionado para análisis de deslizamientos. El principal criterio para ello fue la existencia de numerosos eventos de remociones en masa registrados en una misma zona, los cuales conformarían la base de datos de referencia para el método de análisis a elegir. En segundo lugar, se consideró la factibilidad para efectuar una visita en terreno al área seleccionada. Así mismo, se tuvo en cuenta la cercanía a poblados y/o infraestructura que podrían verse amenazados por las remociones a estudiar.

##### 4.1.1.1. REVISIÓN CATASTRO NACIONAL

Se llevó a cabo la revisión del Catastro Nacional de Remociones en Masa de SERNAGEOMIN publicado en el trabajo de memoria de título de Candia & Herrera (2017), cuyo mapeo se encuentra disponible de forma *online* en el Catálogo Nacional de Información Geológica y Minera “Portal GEOMIN” de SERNAGEOMIN, donde posteriormente ha sido actualizado y complementado con datos más recientes.

Se analizó la distribución provincial de los datos, con el fin de identificar concentraciones de registros (Figura 4.1), donde fue posible notar que sólo las provincias de Valparaíso (21%), Concepción (16%), Llanquihue (8%) y Arauco (6%) acumulan el 51% de los deslizamientos que existen en el catastro. Sin embargo, dado que este estudio tiene como objeto de análisis sólo deslizamientos de ladera de tipo natural, fue necesario hacer una clasificación y filtrado exhaustivo de los datos disponibles, de acuerdo a la Tabla 4.1.



**Figura 4.1:** Distribución provincial de remociones tipo deslizamiento del Catastro Nacional de Remociones en Masa de SERNAGEOMIN. Elaboración propia.

**Tabla 4.1:** Clasificación de deslizamientos para el análisis, filtrado y evaluación de calidad del Catastro Nacional de Remociones en Masa de SERNAGEOMIN (2017) en ONEMI (2017). Elaboración propia.

Tipo Deslizamiento	Descripción
<b>Natural</b>	Deslizamiento condicionado y gatillado por factores primordialmente naturales (litología, lluvias, vegetación, etc.). Acción humana sobre el entorno no incide en la condición geomecánica de la remoción.
<b>Antrópico</b>	Deslizamiento originado por desestabilización de taludes en cortes de camino o terraplenes, por sobrecarga de construcciones (viviendas, aceras, postes, aceras, etc.) o plantaciones forestales, por acción minera (cortes, bancos, túneles, relaves, etc.), por desperfectos en tubería subterránea o rompimiento de matrices, entre otros efectos antrópicos.
<b>Mal Clasificado</b>	Descripción en informe no corresponde a un deslizamiento.
<b>Poca información</b>	No hay información suficiente para clasificar la remoción.
<b>Sin informe</b>	No se encuentra disponible el enlace al archivo.
<b>Ubicación inexacta</b>	La ubicación es muy inexacta, sólo referencias a región o zona del país.

De acuerdo a la clasificación realizada, sólo un 15.8% del total de registros corresponden a deslizamientos de tipo natural, que corresponden sólo a 57 eventos distribuidos en diferentes zonas del país. En vista de esta escasez de datos, que no permite discriminar de buena forma posibles áreas de estudio, fue necesario recurrir a otro catastro existente, más específico.

#### 4.1.1.2. REVISIÓN CATASTRO REGIONAL

Fue posible acceder al Catastro de Remociones en Masa de la Región de Los Lagos, confeccionado el año 2018 por personal de la Oficina Técnica de SERNAGEOMIN en Puerto Varas (Garrido N. & Gómez P., comunicación personal, 2019), recopilación que correspondería a la base de datos de remociones más detallada a nivel nacional, de acuerdo a lo informado por profesionales de la Unidad de Peligros Geológicos y Ordenamiento Territorial de SERNAGEOMIN.

Este catastro consta de 4.990 eventos georreferenciados, clasificados en 3 tipos: Caída, Deslizamiento y Flujo. Se conformó en base a 5 fuentes de información:

- Informes Técnicos
- Campañas de Terreno
- Fotointerpretación
- Memoria para optar al Título de Geólogo, de Patricio Derch, 2007
- Prensa Online y Redes Sociales

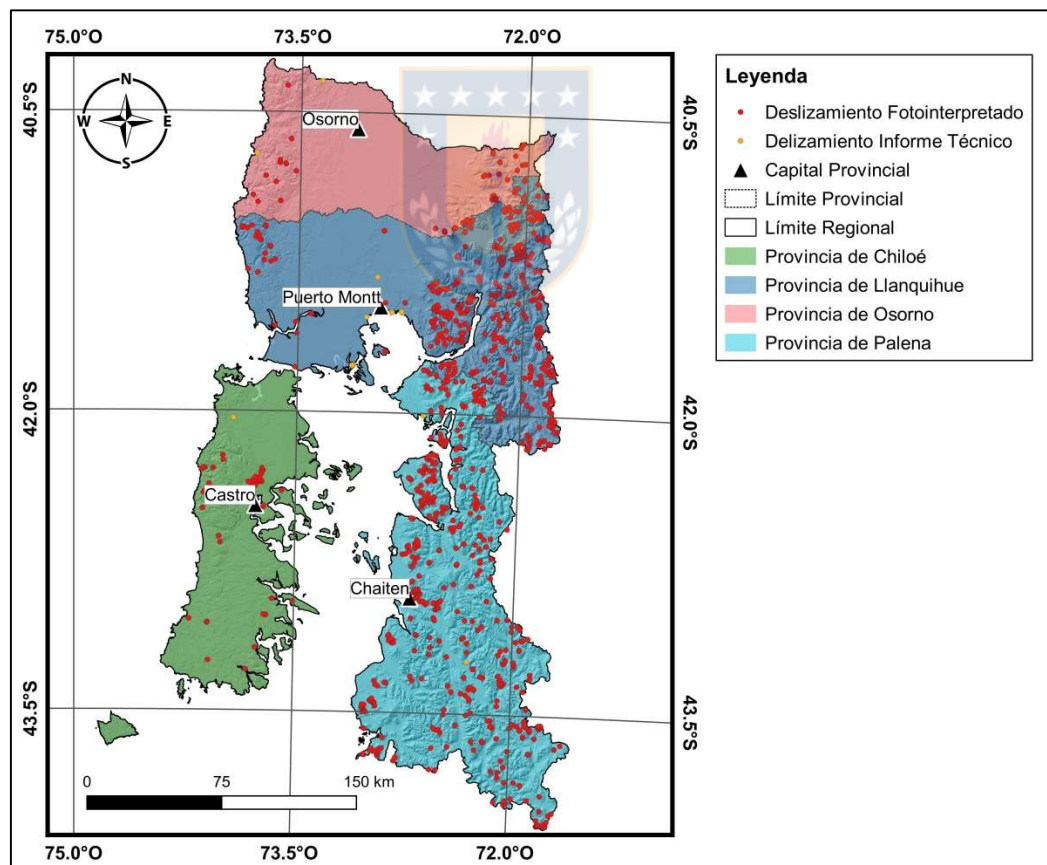
Los datos se encuentran tabulados en una planilla Excel con variadas hojas de información; una que incluye todos los puntos catastrados, y 5 pestañas más donde se agrupan los puntos según su fuente. La caracterización de los eventos se realiza con 26 campos de información, cuya completitud depende directamente de la fuente de donde fue obtenido el dato. De los campos mencionados, los más útiles para filtrar la información en este caso son:

- Proceso principal
- Factores desencadenantes natural y/o antrópico
- Consecuencias y/o descripción
- Tipo de documento o fuente
- Nombre del informe

Se procedió a analizar y filtrar los datos de este catastro, comprobando su información y validez revisando en detalle los registros provenientes de cada fuente de información declarada. Las remociones de tipo deslizamiento que se consideraron para este estudio cumplen con las siguientes características.

- No ser resultante de una inestabilidad de talud o inestabilidad geotécnica.
- Ser de tipo espontáneo, no permanente.
- No ser gatillado por grandes terremotos como el de 1960 o 2010
- No involucrar erosión costera ni efectos de derretimiento de permafrost

Es preciso señalar que, en este catastro regional, los eventos fotointerpretados conforman el grueso de la información mapeada, con un total de 4.522 remociones, de las cuales 1.840 corresponderían a deslizamientos. De éstos, 33 se describen como procesos gatillados por influencia antrópica, o erosión fluvial o costera (remociones permanentes). Y finalmente, un total de 1.807 están clasificados como deslizamientos gatillados sólo por precipitaciones intensas y prolongadas (172), o sin información (1.635). En vista de esto último, fue necesario realizar una revisión visual del mapeo, comparando con la base satelital de Google Earth Pro, y eliminando los eventos que no se adecúan a los criterios antes mencionados (Figura 4.2).



**Figura 4.2:** Catastro corregido de deslizamientos de tipo natural. Modificado de Catastro de Remociones en Masa de la Región de Los Lagos (SERNAGEOMIN, 2018).

Con la base de datos corregida se efectuó un análisis visual y geoespacial de la distribución de los puntos catastrados en busca de zonas que presenten concentraciones importantes de deslizamientos, cercanas a poblados e infraestructura, y que sea factible visitar en terreno. Esto dio como resultado la selección del área de estudio presentada, en la comuna de Chaitén, la cual cumple con los criterios propuestos para llevar a cabo esta investigación.

#### **4.1.2. DETERMINACIÓN DEL MÉTODO PARA ANÁLISIS DE SUSCEPTIBILIDAD**

Parte esencial de este trabajo es la elección de un método innovador para el análisis de susceptibilidad de deslizamientos, por lo cual se realizó una búsqueda bibliográfica orientada a la aplicación de diferentes técnicas con base estadística, utilizadas en Chile y el mundo en esta materia. Esto consideró métodos estadísticos bivariados y multivariados, además de inteligencia artificial básica. Las técnicas fueron caracterizadas y contrastadas, teniendo en cuenta sus ventajas y desventajas.

Luego de evaluar la utilidad y factibilidad de cada método, se decidió hacer uso de Redes Neuronales Artificiales (RNA) en vista de los buenos resultados que diversos estudios declaran obtener con esta técnica (Yesilnacar & Topal, 2005; Yilmaz, 2008; Pradhan & Lee, 2009; Tien Bui *et al.*, 2015), con igual o mejor desempeño predictivo frente a otros procedimientos de tipo estadístico. Así también, las RNA pueden ser una herramienta muy útil para discriminar y seleccionar factores que efectivamente condicionen la ocurrencia de un evento de interés en un lugar específico, lo cual en este estudio son los deslizamientos de suelo de origen natural en la zona de Chaitén.

La elección de las RNA como método de análisis consideró además de la escasa o nula aplicación que tiene esta tecnología en nuestro país en materia de peligros geológicos, lo cual representaría un avance e innovación para este tipo de investigaciones, acercando el mundo de la inteligencia artificial a la evaluación y pronóstico de procesos de remoción en masa en el territorio nacional.

#### **4.1.3. CREACIÓN DE CATASTRO LOCAL**

Una base de datos o inventario de deslizamientos es el componente fundamental para prever futuros eventos (Tien Bui *et al.*, 2012 en Kalantar *et al.*, 2017). Para el presente trabajo esto se confeccionó inicialmente como un mapeo de superficie de deslizamientos, en un formato de

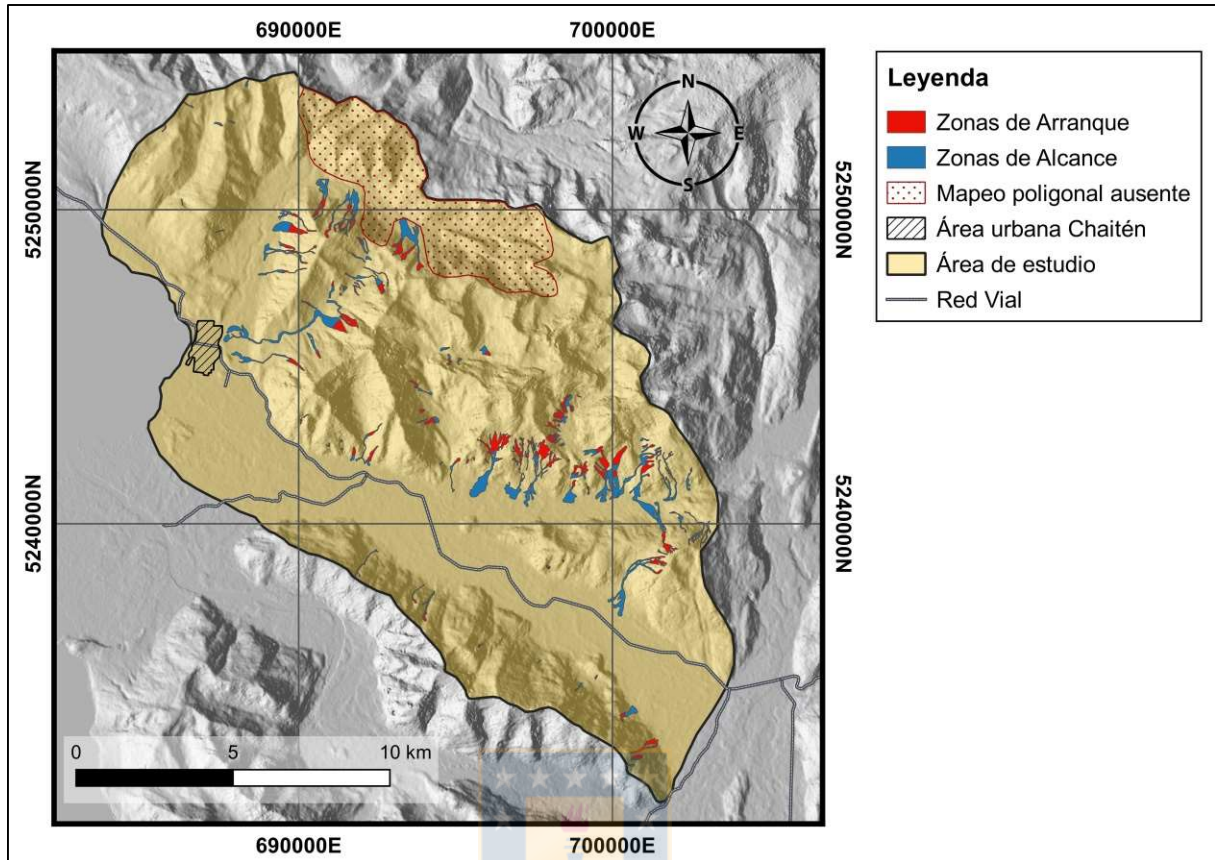


polígonos, lo cual posteriormente se modificó en un catastro de puntos para añadir más detalle y especificidad al muestreo de la superficie.

### **Mapeo Poligonal**

El primer inventario de polígonos fue construido inicialmente en Google Earth Pro, software en el que se dispone de una base satelital de gran resolución y amplio rango de imágenes históricas. Ambas características permiten, por una parte, realizar un mapeo de detalle, y por otra, detectar eventos de deslizamientos ocurridos varios años en el pasado, que actualmente pueden estar ocultos por el renuevo de vegetación y/o modificaciones naturales o antrópicas en la superficie. Este mapeo delimita toda el área que ha sido afectada por cada remoción, diferenciando la zona de arranque (origen del material) y el alcance (tránsito y depósito) de ésta (Figura 4.3). Esta separación de zonas se justifica por la intención del presente estudio en crear un Mapa Indicativo de Amenaza “MIA” (FOEN, 2016), el cual representa la susceptibilidad del terreno ante estos dos sub-procesos. De esto último se desprende entonces la necesidad de tener 2 tipos de catastro, para llevar a cabo 2 tipos de análisis que se conjugarán en 1 mapa final.





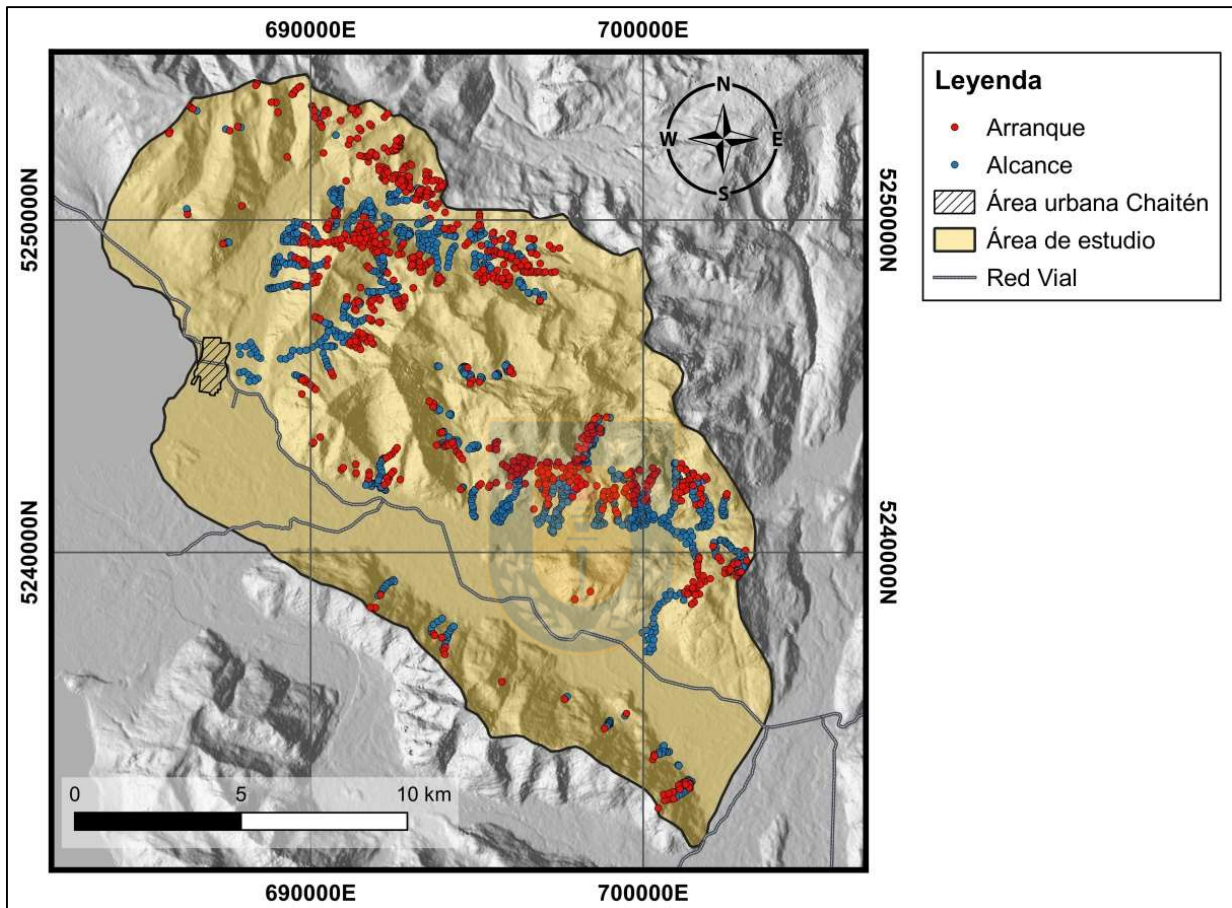
**Figura 4.3: Catastro poligonal de deslizamientos superficiales en el área de estudio.** En rojo zonas de arranque, en azul zonas de alcance. Se indica con patrón de puntos el sector que no pudo ser mapeado de forma poligonal. Elaboración propia.

Es pertinente señalar que este primer inventario poligonal no necesariamente individualiza cada evento de deslizamiento, ya que en la zona de estudio es muy recurrente la unión o superposición de remociones a lo largo del tiempo. En consecuencia, simplemente representa zonas de arranque y alcance sin poder cuantificar el número de deslizamientos que se registran en la zona. Por otra parte, existe un sector dentro del área de estudio donde se observa una gran cantidad de remociones que han afectado casi la totalidad de las laderas lo que dificulta este tipo de mapeo, ya que no es posible crear polígonos certeros en dicha zona (Figura 4.3).

Las principales utilidades que presta este tipo de inventario para este estudio en específico son, por un lado, el poder ser usado como base para un posterior catastro de puntos, y por otro, tener claras demarcaciones de las remociones para comparar con el mapa resultante del análisis con redes neuronales, facilitando una rápida evaluación visual del ajuste de los modelos con las situaciones reales de referencia.

## Mapeo de puntos

Se confeccionó un segundo catastro, esta vez en formato punto. Este fue hecho con base en el mapeo poligonal y las imágenes satelitales de Google Earth Pro. Estos puntos representan un muestreo aleatorio de la superficie abarcada por el proceso de remoción en masa, donde también se hace la distinción entre zona de arranque y alcance (ver Figura 4.4).



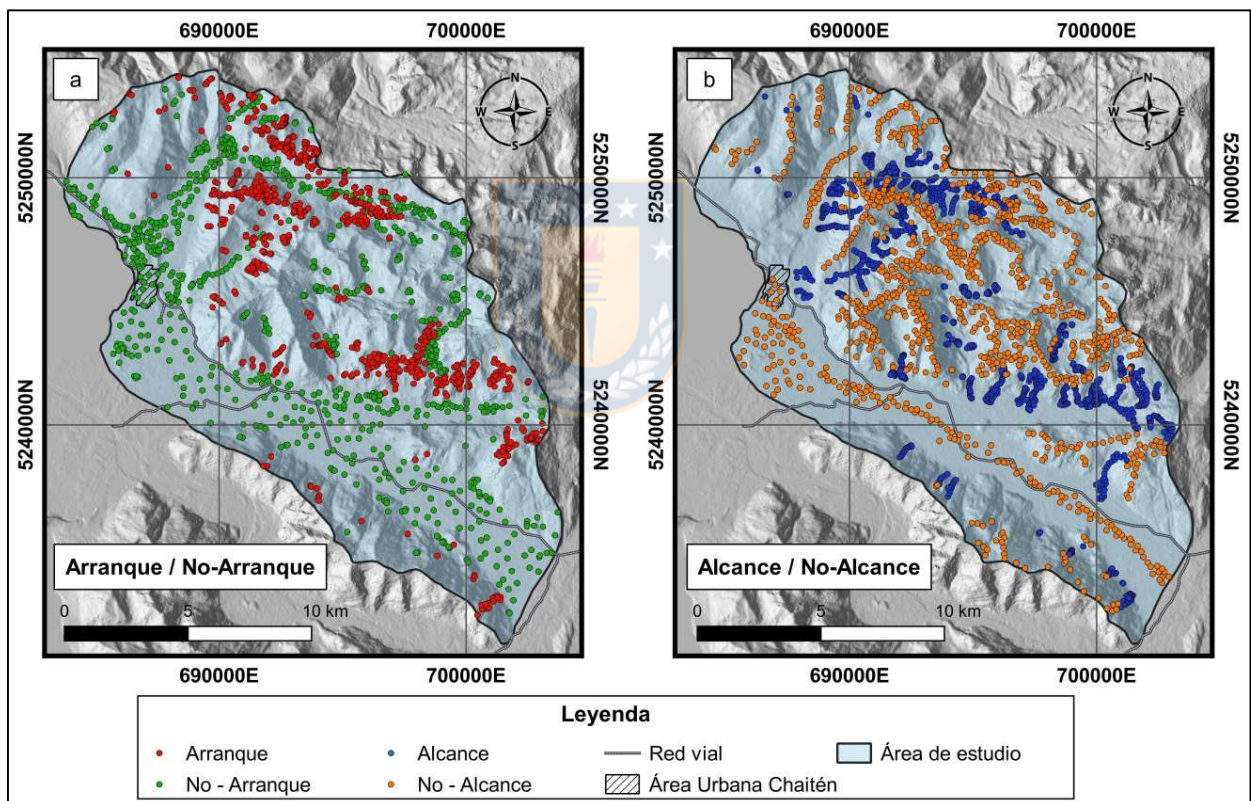
**Figura 4.4: Catastro de deslizamientos en formato punto.** En rojo los puntos que caen dentro de zonas de arranque, en azul los puntos que se ubican en zona de alcance. Elaboración propia.

Este catastro tiene como objetivo caracterizar una mayor cantidad de puntos del terreno, capturando los datos de las capas temáticas (formato ráster) pertenecientes a cada factor condicionante que sea evaluado y/o seleccionado en el estudio. De esta forma se cuenta con una mayor disponibilidad de información para entrenar la red neuronal frente a la que se tendría a partir de un mapeo poligonal, donde cada objeto entrega sólo 1 muestra del terreno (valor promedio de toda la zona que abarca cada polígono).

## Catastro Binario

El análisis de deslizamientos considera estos procesos como variables de clasificación binaria, es decir, el indicador de las remociones (inventario) debe ser separado en 2 clases: deslizamientos y no-deslizamientos (Tien Bui, 2015). De esta forma, se confeccionó un catastro con información dual, donde los puntos que indican deslizamientos son representados como casos “Verdaderos” o “1”, y los no-deslizamientos como “Falsos” o “0”.

Debido al doble análisis que se llevó a cabo, para los sub-procesos de arranque y alcance, en cada uno se realizó esta separación entre clases 0 y 1. Por tanto, se generan 2 inventarios: Arranque/No-Arranque y Alcance/No-Alcance (Figura 4.5).



La selección y mapeo de puntos de No-Arranque se efectuó en base al mapa de pendientes del área de estudio. A partir de un modelo de elevación digital DEM 12m ALOS PALSAR del año

2007, se obtuvo el mapa de pendientes mediante procesamiento en ArcMap 10.5. En dicho software se clasificó el ráster resultante de tal manera que fuesen representados sólo los píxeles con pendiente menor a  $4^\circ$ , que corresponderían a zonas del terreno donde es imposible la generación de una remoción debido a la falta de inclinación del mismo. Las zonas demarcadas fueron exportadas en formato *shape*, para luego ser llevadas a QGIS Desktop 3.10.5, donde fue posible generar puntos aleatorios dentro de los polígonos. Los puntos obtenidos fueron revisados posteriormente, eliminando objetos muy aislados y rellenando manualmente zonas que requerían mayor muestreo (Figura 4.5 a).

En cuanto al mapeo de No-Alcance, este se llevó a cabo de forma manual, mapeando directamente los puntos en ArcMap 10.5 sobre una base satelital de Google. Dichos puntos indican zonas donde geomorfológicamente sería imposible o muy difícil que transite o se deposite material de una remoción del tipo que se pretende evaluar. Atendiendo a esto, el muestreo de No-Alcance cubre tanto a las cimas o crestas de las montañas, como las porciones centrales de los amplios valles del área (Figura 4.5 b).

Finalmente, tal como se puede observar en la Figura 4.5, se obtuvieron 2 catastros de tipo binario para evaluar los 2 sub-procesos correspondientes; arranque y alcance. El primero consta de un total de 1572 puntos separados equitativamente entre arranque y no-arranque, y el segundo está conformado por un total de 2090 puntos de muestreo también separados de forma equivalente entre alcance y no-alcance.

#### **4.1.4. PRESELECCIÓN DE FACTORES CONDICIONANTES**

Otro de los pilares fundamentales de cualquier estudio de susceptibilidad, es la correcta elección de los factores que condicionan el terreno para la ocurrencia del proceso evaluado. En el presente trabajo uno de los objetivos es lograr que la red neuronal artificial (RNA) sea capaz de indicar cuáles son las variables (factores) que tienen mayor peso o relevancia en la generación de cada sub-proceso que se analizará para el Mapa Indicativo de Amenaza (MIA), y así llegar a una estimación óptima que se ajuste al catastro de referencia con el cual se llevará a cabo el entrenamiento y aprendizaje de la RNA.

Si bien la selección de factores condicionantes estará supeditada a la computación de la red neuronal, es necesario contar con un set de variables preseleccionadas para ser ingresadas y evaluadas por la red. En consecuencia, se llevó a cabo una revisión bibliográfica sobre los

factores más recurrentemente considerados en estudios de este tipo y fueron preseleccionados de acuerdo a los siguientes criterios:

- Tener implicancia geológica en el proceso específico que será evaluado. En este caso, deslizamientos traslacionales, planares, de suelo, espontáneos y de origen natural
- 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 (ser mapeada).

Atendiendo a lo mencionado anteriormente, para evaluar el proceso de arranque de deslizamientos fueron preseleccionados 11 factores condicionantes, de los cuales 4 también fueron utilizados para el análisis de Alcance de la remoción junto a 2 factores adicionales, especialmente formulados para dicho proceso. En el Anexo 3 es posible revisar los correspondientes mapas que representan cada uno de estos 13 factores en el área de estudio. A continuación, se describen el total de las variables que se consideraron en este trabajo, enlistadas en la Tabla 4.2.

**Tabla 4.2: Factores condicionantes preseleccionados para el análisis de deslizamientos.** Listado de características del terreno a considerar como variable en la evaluación del arranque y alcance de deslizamientos. Se presenta el código que representa cada factor, el tipo de variable (categórica o numérica continua). Se indica la relación que tiene cada factor con los procesos de arranque y alcance de forma separada, lo cual se refiere a la correlación con eventos positivos de cada proceso. Elaboración propia.

Factor	Código	Tipo Variable	Relación con Arranque	Relación con Alcance
Geología	GEO	Categórica	Según categoría.	-
Uso de Tierra	LUSE	Categórica	Según categoría.	-
Pendiente	SLOPE	Continua	Directa.	Inversa.
Pendiente Senoidal	SIN_SLOPE	Continua	Directa.	-
Curvatura	CURV	Continua	Directa.	Inversa.
Aspecto	ASPE	Categórica	Depende de clima y geografía.	-
Rugosidad	ROUGH	Continua	Directa.	Inversa.
Insolación	SOLAR	Continua	Directa.	-
Elevación	ELEV	Continua	Directa.	-
<i>Normalized Difference Vegetation Index</i>	NDVI	Continua	Centrada en valores positivos entre 0 y 1.	-
Depósito de tefra erupción volcán Chaitén 2008 - 2009	TEPHRA	Continua	Directa	-
<i>Topographic Wetness Index</i>	TWI	Continua	Inversa.	Directa.
Densidad de drenaje	DREN	Continua	-	Directa
Gradiente Topográfico	GT	Continua	-	Centrado en 0.5

## Geología

Se trata del mapeo y caracterización geológica (litológica) 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).

La base geológica fue obtenida del mapa geológico esquemático de la parte sur de la Región de Los Lagos, de SERNAGEOMIN, escala 1:500.000 (Ordóñez & Crignola, 2003).

## Uso de tierra

Base de datos vegetacional del área. Fue considerada ya que, en términos generales, la vegetación se reconoce como un factor estabilizante de laderas (Lara, 2017; Santacana, 2001), sin embargo, en zonas lluviosas como Chaitén, podría tener el efecto contrario.

Se trata de un catastro nacional de usos de la tierra y formaciones vegetales, especialmente aquellas relacionadas a bosque nativo, plantaciones forestales y matorrales, que constituye la línea base de la información cartográfica vegetacional de Chile. En específico para este trabajo se utilizó el Catastro de Uso de Suelo y Vegetación de la Región de Los Lagos de CONAF, año 2013, en formato *shape* a escala 1:50.000.

## Pendiente

Corresponde al ángulo de inclinación de la superficie, medido en grados de 0° a 90°, con respecto al plano horizontal o *datum* local de referencia. 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 flujos, deslizamientos y derrumbes. Las pendientes tanto de laderas como de cauces (ejes hidráulicos), mientras mayores son, otorgan una alta capacidad de transporte y energía a los flujos (Lara, 2007).

La capa temática en formato ráster de esta variable se obtiene a partir de un DEM 12.5 m ALOS PALSAR del año 2011, mediante procesamiento en ArcMap 10.5.

### **Pendiente Senoidal**

Es una configuración trigonométrica derivada de la pendiente ( $\beta$ ) del terreno. Está definida por la fórmula a continuación:

$$\text{Pendiente senoidal} = \text{sen}(\beta \cdot 2)$$

Se ha observado que a partir de los 45° de pendiente, la ladera se torna muy empinada para retener cobertura de suelo, lo que disminuye la probabilidad de generarse una ruptura superficial (Santacana, 2001; Hungr *et al.* 2014). El objetivo de esta modificación trigonométrica de la pendiente es reajustar los valores o ponderaciones máximas hacia los valores centrales de esta, vale decir, entre 0° a 45° de pendiente (normal), la pendiente senoidal aumenta, y desde 45° hasta 90° decrece.

La capa temática de este factor fue obtenida mediante álgebra de mapas a partir del mapa de pendientes, con procesamiento en ArcMap 10.5.

### **Curvatura**

Indica el grado de concavidad/convexidad del terreno. Ayuda a entender los procesos de erosión y escorrentía. Infiuye en la convergencia y divergencia del flujo. Afecta la aceleración y desaceleración del flujo y, por lo tanto, influye en la erosión y la sedimentación (Kalantar *et al.* 2017). De esto se desprende que zonas más convexas serían más susceptibles a generar deslizamientos, mientras que zonas planas y cóncavas tenderían a ser más estables o bien, como lugar de depositación de material.

Este factor fue calculado mediante procesamiento en *Spatial Analyst* de ArcMap 10.5, a partir del DEM base elegido para este trabajo.

### **Aspecto (Orientación de laderas)**

Identifica la dirección de la pendiente descendente de la tasa de cambio máxima en un valor desde cada celda hacia sus vecinas. Puede pensarse como la dirección de la pendiente. Indica de manera indirecta la situación de una ladera en cuanto a su insolación, por lo tanto, si una



ladera se encuentra húmeda o seca con mayor frecuencia. También influirá en la cantidad de lluvia recibida según la dirección de avance de los frentes nubosos.

Esta variable también se obtiene a partir del DEM ALOS PALSAR de 12.5 m, mediante procesamiento en *Spatial Analyst* de ArcMap 10.5.

### **Rugosidad**

Se define como la variación de la pendiente en un área determinada. Laderas de alta rugosidad son más propensas a presentar deslizamientos debido a que los cambios sucesivos de pendiente favorecen la infiltración e inestabilidad del terreno (Santacana, 2001), por lo que se ha considerado un instrumento eficaz para evaluar la estabilidad de laderas (Althuwaynee *et al.*, 2014). Se puede entender entonces, que una baja rugosidad del terreno se puede asociar a zonas de depósito de material.

Al provenir del modelo de elevación, la rugosidad se entiende como una variable continua, cuya capa temática fue obtenida como sub-producto del DEM base del presente estudio, a través de procesamiento en *Spatial Analyst* de ArcMap 10.5.

### **Insolación**

Cuantifica a qué tanta luz o sombra están expuestas las laderas en el tiempo. Se relaciona a la humedad del terreno de tal manera que aquellas laderas o porciones de éstas que reciban mayor insolación serían más secas y susceptibles ante frentes lluviosos abruptos (Santacana, 2001).

Esta variable fue cuantificada espacialmente a partir del ráster DEM, haciendo uso la herramienta *Solar Radiation* de *Spatial Analyst* en ArcMap 10.5, en la cual se estableció el parámetro de muestreo de luz o radiación recibida cada 2 semanas en un período total de 1 año.

### **Elevación**

Altitud con respecto al nivel del mar, en metros. Corresponde al Modelo de Elevación Digital, del cual se derivan otras características superficiales del área de estudio.


Fue considerada como factor ya que tendría relación con la pluviometría y crioclastía, entendiéndose que a mayores altitudes hay más precipitaciones y mayor desarrollo de crioclastía, lo que empeora la calidad de la roca (Muñoz, 2018; Santacana 2001).

## NDVI

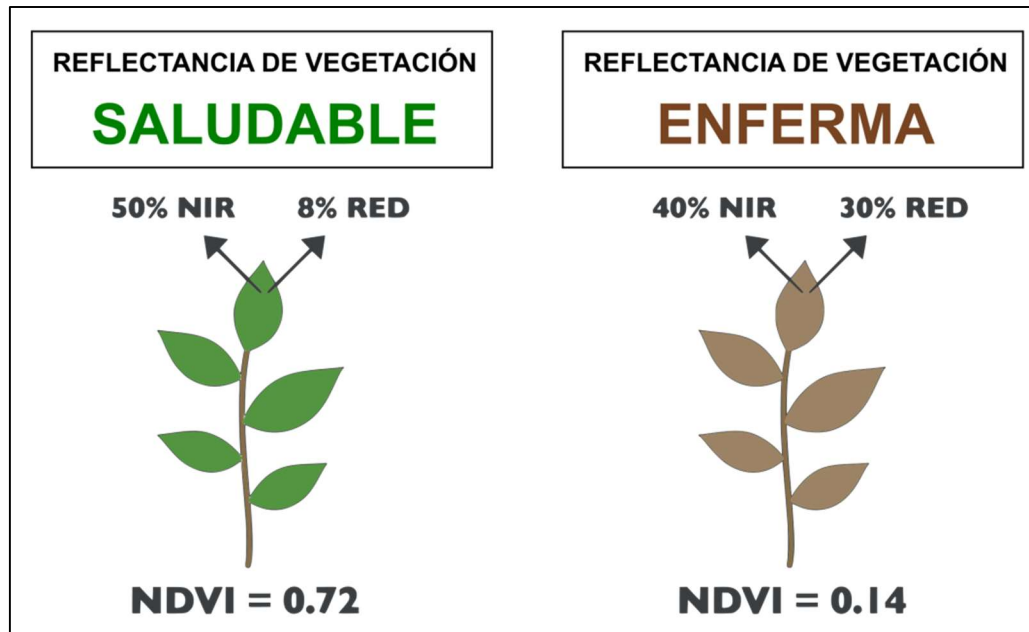
*Normalized Difference Vegetation Index*. Es un indicador simple de biomasa fotosintéticamente activa o un cálculo de la salud de la vegetación, la cual es considerada como un factor estabilizante de laderas. El NDVI indica la calidad de ésta, además de diferenciar la presencia o desarrollo de otras cubiertas de suelo, como cuerpos de agua, ciudades o roca descubierta. Se define de acuerdo a la siguiente fórmula:

$$\text{NDVI} = \frac{(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED})}$$

Donde NIR corresponde a la luz infrarroja cercana (841-876 nm) y RED es la luz roja visible (620-670 nm) del espectro electromagnético (Gaitán *et al.*, 2015) (Ver Figura 4.6). Esta comparación matemática funciona debido a que el pigmento de clorofila en una planta sana absorbe la mayor parte de la luz roja visible, mientras que la estructura celular de una planta refleja la mayor parte de la luz infrarroja cercana. Esto significa que una alta actividad fotosintética, comúnmente asociada con vegetación densa, tendrá menos reflectancia en la banda roja y mayor reflectancia en el infrarrojo cercano (Ver Figura 4.7). Al observar cómo estos valores se comparan entre sí, puede detectar y analizar de manera confiable la cubierta vegetal por separado de otros tipos de cobertura natural del suelo.



**Figura 4.6: Espectro electromagnético.** Se presenta todo el espectro electromagnético resaltando aquella porción del espectro visible por el ojo humano. Se muestran diferentes escalas de medición, donde es posible ubicar la banda RED y NIR entre los 620-670 y 841-876 nanómetros (nm), respectivamente. Tomado de Ordóñez (2012).



**Figura 4.7: Explicación ilustrativa del NDVI.** Una planta o árbol saludable tiene una alta reflectancia del espectro NIR y baja reflectancia de RED, mientras que una planta enferma o muerta, tiene mayor reflectancia RED y menor de NIR. Esto tendrá como consecuencia que vegetación saludable tenga un alto NDVI, cercano a +1, y la vegetación en mal estado, NDVI más cercano a 0. Los valores que se muestran en la ilustración son sólo a modo de ejemplo. Elaboración propia.

El rango de valores posibles de NDVI varían entre -1 y +1, donde sólo los valores positivos corresponden a zonas con vegetación, y cuanto más alto es el índice (más cercano a +1) mayor es la calidad/densidad de la vegetación (Yengoh *et al.*, 2013). De acuerdo a esto, es esperable que la ocurrencia de deslizamientos se asocie a valores bajos valores positivos de NDVI (valores intermedios en el rango total), los cuales indicarían un mal estado de la cubierta vegetal.

Los parámetros espectrales utilizados corresponden a las Bandas 4 y 5 (RED y NIR, respectivamente) de una imagen satelital Landsat 8 con resolución 30 m, del año 2013. El mapa NDVI fue resultado un álgebra de mapas realizado en ArcMap 10.5 con los insumos satelitales antes mencionados.


### **Depósito de tefra erupción Volcán Chaitén 2008 - 2009**

La erupción del volcán Chaitén en 2008-2009 involucró una variedad de procesos volcánicos e hidrológicos asociados que dañaron los bosques aledaños. La tefra gruesa ("lluvia de grava", >5 cm de profundidad) erosionó el follaje del dosel arbóreo en un área de aproximadamente 50 km<sup>2</sup> hacia el NNE de la apertura volcánica. La tefra fina (>10cm de profundidad) se acumuló en

la copa de los árboles, lo que quebró las ramas de los árboles viejos y arqueó los jóvenes en un área de aproximadamente 480 km<sup>2</sup> (Swanson *et al.*, 2013).

Observaciones de teledetección posterior al proceso eruptivo, han revelado que los deslizamientos de suelo se han concentrado en laderas densamente forestadas, mayormente entre 2 a 6 años después de haber sido cubiertos por la tefra. Korup *et al.* (2019) señalan que esta inestabilidad retardada es consistente con una pérdida gradual de la fuerza de cizalle de las raíces de los árboles en descomposición en zonas de alta carga de tefra. Los mismos autores mencionan que las zonas circundantes al área de afectación de la erupción, con características de topografía, vegetación, precipitaciones y litología comparables mantuvieron las tasas de deslizamiento de suelo aproximadamente diez veces más bajas.

Lo anteriormente expuesto, fundamentó la idea de incluir como un posible factor condicionante el grosor del depósito de tefra asociada a la erupción del volcán Chaitén 2008-2009. La información geoespacial fue obtenida desde el mapa de isópacas (Figura 4.8) del depósito de tefra calculado en el trabajo de Alfano *et al.* (2011). Dicho mapa fue georreferenciado y vectorizado en ArcMap 10.5, para posteriormente ser interpolado en una superficie TIN, la cual fue exportada a una capa ráster que cubre la totalidad del área de estudio, conformando así la capa temática del factor en cuestión.



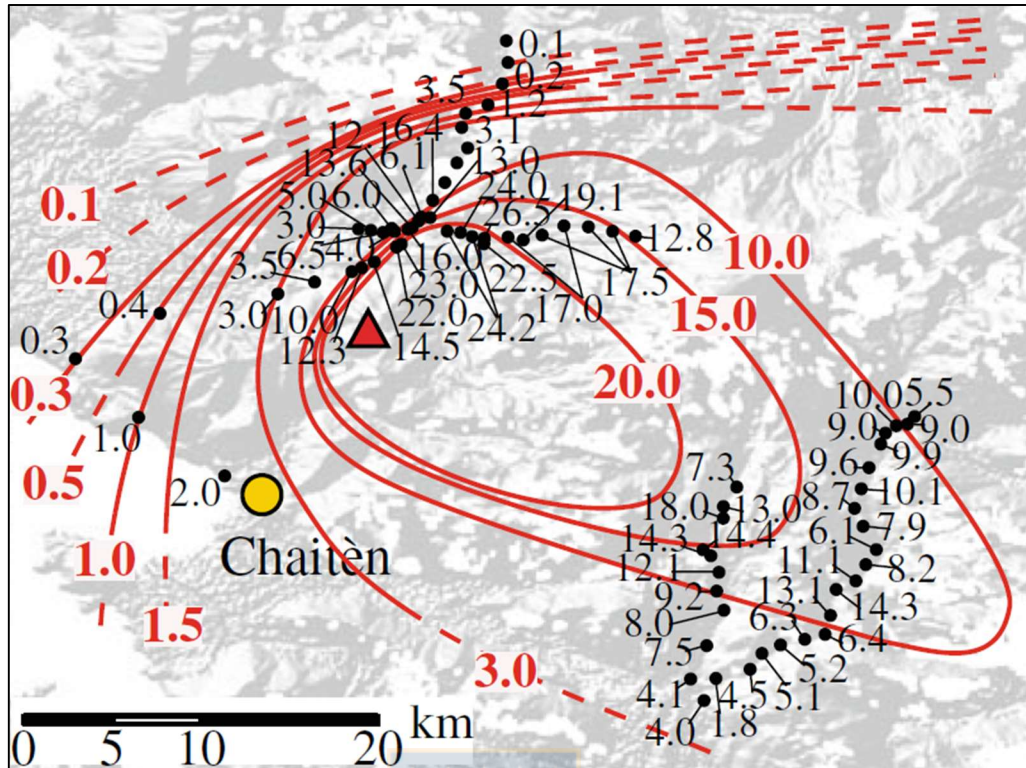


Figura 4.8: Mapa de isópacas de depósito de tefra de la erupción volcán Chaitén 2008-2009. Líneas rojas corresponden a las isópacas que indican el grosor en centímetros del depósito de tefra caída. Tomado de Alfano *et al.* (2011). Sin modificaciones.

## TWI

*Topographic Wetness Index*. Es uno de los modelos propuestos para cuantificar la humedad de los suelos a partir de un DEM (Beven & Kirkby, 1979). Se considera una aproximación a la humedad que capaz de retener la superficie (Radula *et al.*, 2018). Las zonas más constantemente húmedas serían más estables ante cambios bruscos en el suministro de aguas lluvias, por lo que el TWI tendría una relación inversa con respecto a la susceptibilidad del terreno a generar deslizamientos (Althuwaynee *et al.*, 2014). Otros autores interpretan la influencia de este factor de forma directa, es decir, consideran que a mayor humedad existe una mayor presión de poros en los suelos, desestabilizándolos (Yilmaz, 2009; Kalantar *et al.*, 2017), lo que hace pensar que este factor puede variar la forma en que contribuye al proceso dependiendo de las características geológicas y climáticas de zona donde se evalúe.

El TWI se define por la siguiente fórmula, adaptada por Kalantar *et al.* (2017) basado en Beven & Kirkby (1979):

$$TWI = \ln\left(\frac{A}{b \tan \beta}\right)$$

Donde “A” corresponde a la acumulación de flujo (*flow accumulation*) en metros cuadrados, “b” se refiere al tamaño de pixel (*cell size*) por el cual el agua fluye, en metros y “β” representa la pendiente en dicho pixel, en radianes. En línea con esta definición, el TWI fue calculado a partir del modelo de elevación digital utilizando una combinación de herramientas de *Hydrology* y algebra de mapas en *Spatial Analyst* de ArcMap 10.5, de acuerdo al procedimiento que se detalla en la Tabla 4.3 a continuación.

**Tabla 4.3: Procedimiento para la obtención de ráster TWI.** Notar el ajuste realizado para el *flow accumulation* (FA) en el paso N°6, sumando la constante 1 para evitar posibles resultados igual a 0, ya que el logaritmo natural de 0 no está determinado. Además, puesto que FA es un indicador adimensional, se escala multiplicándolo por el área de la celda del DEM “b<sup>2</sup>”, en metros cuadrados. Elaboración propia.

	Descripción	Representación	Herramienta ArcMap 10.5
1°	Ráster <i>flow direction</i> (“FD”) a partir de DEM.	FD f(DEM)	<i>Flow Direction</i> de <i>Hidrology</i>
2°	Ráster <i>flow accumulation</i> (“FA”) a partir de FD.	FA f(FD)	<i>Flow Accumulation</i> de <i>Hidrology</i>
3°	Ráster de pendientes (“β”) a partir de DEM.	β f(DEM)	<i>Raster Calculator</i> de <i>Map Algebra</i>
4°	Conversión de β a radianes	β (rad) = β*π/180	<i>Raster Calculator</i> de <i>Map Algebra</i>
5°	Cálculo condicional de tangente de la pendiente (tan β)	tan β = con(β > 0, tan β, 0.001)	<i>Raster Calculator</i> de <i>Map Algebra</i>
6°	Escalado (m <sup>2</sup> ) y ajuste del término “A” en función del tamaño de pixel “b”	A = (FA+1)*(b <sup>2</sup> )	<i>Raster Calculator</i> de <i>Map Algebra</i>
7°	Cálculo de TWI	$TWI = \ln\left(\frac{A}{b \tan \beta}\right)$	<i>Raster Calculator</i> de <i>Map Algebra</i>

### Densidad de drenaje

De acuerdo a Dobos & Daroussin (2007), la densidad de drenaje es una medida de la disección del paisaje. El grado de disección de la superficie está determinado por la escorrentía de la superficie y la permeabilidad de los suelos y de los estratos rocosos subyacentes. Cuanto menos se infiltra el agua en el suelo, mayor es la escorrentía de agua en la superficie, lo que causa la erosión y la disección de la superficie terrestre. Así, la escorrentía superficial es inversamente proporcional a la permeabilidad.

La disección es difícil de medir. Un posible enfoque para caracterizar el grado de disección del paisaje consiste en medir la longitud total de los valles o líneas de drenaje. La densidad de drenaje (D) es la longitud total de los arroyos y ríos permanentes y estacionales dividida por un tamaño unitario de área (A), como se expresa en la siguiente fórmula (Dobos *et al.*, 2000):

$$D = \frac{\sum_1^n L}{A}$$

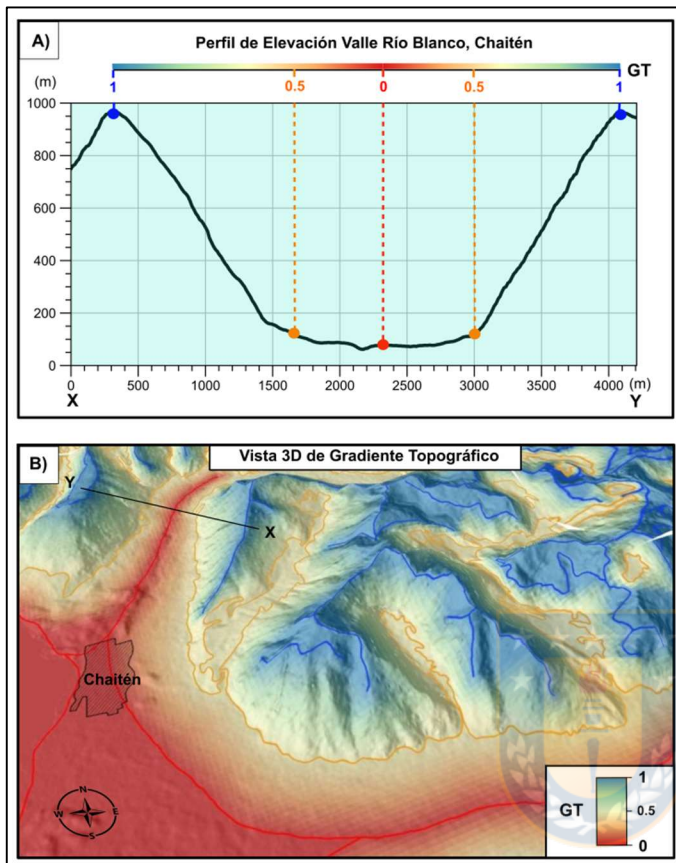
Dada la relación de este indicador con la erosión y disección de la superficie, tendría una cercana relación con el transporte de material a través de remociones fluidizadas, por lo que fue seleccionado como uno de los factores que incidirían en el alcance de las remociones evaluadas en este trabajo. De esta forma, a mayor densidad de drenaje, es esperable que el terreno sea más propenso a ser alcanzado por el material removido por los deslizamientos analizados.

La capa temática que representa geoespacialmente este parámetro, fue obtenida mediante procesamiento en ArcMap 10.5, a partir de la Red de Drenaje del área en formato *Shape* de líneas previamente obtenida a partir del DEM de la zona. La Densidad de Drenaje fue calculada con la herramienta *Line Density* de *Spatial Analyst*, la cual sigue los mismos fundamentos matemáticos expresados en la fórmula de la ya presentada de Dobos *et al.* (2000). Es preciso señalar que para el cálculo con dicha herramienta fue establecido arbitrariamente un radio de búsqueda 200m que determina el área circular por la cual se suman las longitudes de líneas de drenaje, es decir, el término "A" en este estudio corresponde a  $200^2\pi \approx 125.664 \text{ m}^2$ .

### **Gradiente Topográfico**

Este factor fue ideado de forma exclusiva para este trabajo, específicamente diseñado para establecer una componente de distancia relativa que puede alcanzar el avance de flujos con respecto a los quiebres topográficos del perfil de los valles, esto quiere decir, que el gradiente topográfico es una referencia numérica relativa a: 1) centro de los valles amplios (más de 500m de ancho), 2) pie de las laderas y 3) cimas de montañas. A cada uno de estos quiebres se les asocian los valores 0, 0.5 y 1, respectivamente (Figura 4.9), de esta forma se logra graduar el perfil de los valles para constreñir la posición que tiende a adoptar el alcance de las remociones hacia el interior de los valles. Esto va dirigido a solucionar posibles resultados que indiquen que toda la superficie de los valles pueden ser zonas de alcance de remociones, lo cual es muy

poco probable dada la gran amplitud de éstos, que en la zona de estudio pueden superar los 3km de ancho.



**Figura 4.9: Descripción gráfica de la variable Gradiente Topográfico (GT).** a) Perfil de elevación de Valle del Río Blanco, Chaitén. Se muestran de forma esquemática los puntos de quiebre que corresponden a los valores 0, 0.5 y 1: centro de valle, pie de ladera y cima de las montañas, respectivamente. b) Vista 3D de GT, se puede observar el trazado en rojo, amarillo y azul de cada uno de los índices de quiebre de GT. Sobre la superficie sombreada se representa la continuidad en degradé de este indicador de distancia. Se muestra también el trazado del perfil XY de la Figura 4.9 a).

La construcción del gradiente topográfico parte con la delimitación manual de contornos lineales que sigan los quiebres mencionados anteriormente, lo cual implica el dibujo vectorial en formato *Shape*, con asignación de los valores correspondientes de cada objeto en la tabla de atributos. Posteriormente se genera una triangulación de los elementos creados, con el fin de obtener posteriormente un *output* formato ráster (12.5m) que representará la posición relativa de cada pixel con respecto a los trazos señalados, en una escala de 0 a 1. Todo lo mencionado anteriormente fue realizado en ArcMap 10.5, haciendo uso de la herramienta *Create TIN* para generar la triangulación entre los contornos creados, lo que luego fue exportado a formato ráster con la herramienta *TIN to Raster*, ambos procesos de *3D Analyst*.




## 4.2. ETAPA DE TERRENO

La campaña a terreno tuvo lugar entre los días 08 y 11 de Febrero de 2020. Este se llevó a cabo bajo la guía de 2 geólogas, profesionales de GEOTEST Chile SpA.

Los principales propósitos de la visita a terreno fueron localizar y caracterizar los deslizamientos presentes en la zona mediante directa observación de las cicatrices y depósitos dejados por éstos, definir las posibles causantes de los mismos con ayuda de los relatos y testimonios de lugareños, y realizar vuelos de dron para contar con un registro fotográfico aéreo (Dron DJI Phantom 4) de las remociones más representativas y accesibles del área. Esto último fue pensado con el fin de generar modelos digitales de terreno (DTM) localizados que permitiesen llevar a cabo una modelación numérica de los deslizamientos y sus depósitos, y así obtener diferentes parámetros geomecánicos útiles para la caracterización de éstos.

Todo lo mencionado anteriormente fue completado de forma satisfactoria, dentro de las limitaciones que presentó esta visita a terreno, donde se logró dimensionar la dificultad de acceso a gran parte del área de estudio, debido a la abundante y densa vegetación (Figura 4.10a), y a la escarpada topografía (Figura 4.10b). Razones que hacen necesario tener un mayor conocimiento de la zona, técnica y tiempo para adentrarse en los bosques, pues de lo contrario se incurre en mayor riesgo de accidentes. Esto restringió enormemente el acercamiento a muchos de los deslizamientos previamente detectados, por lo cual los puntos visitados son muy limitados con respecto a la extensión total del área. Las rutas y puntos de control de la campaña de terreno se pueden observar en la Figura 4.11.



**Figura 4.10: Problemas de accesibilidad del área de estudio.** a) Se muestra la densa vegetación existente en la zona, lo cual dificulta y retrasa considerablemente el avance a través de las rutas planificadas. b) Es posible dimensionar el gran escarpe de las montañas del área, lo que se transforman en barreras impenetrables hacia sectores altos.

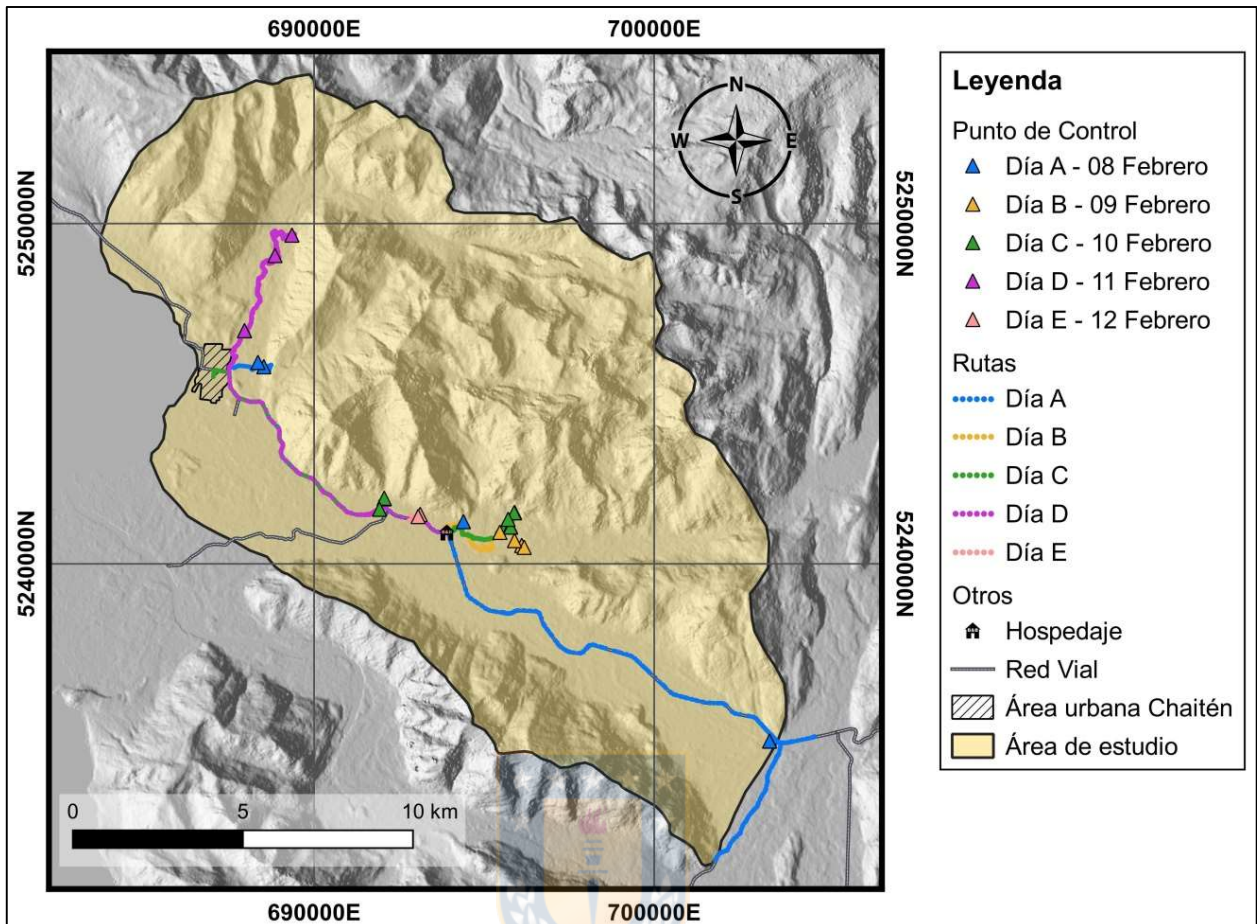


Figura 4.11: Ubicación de puntos de control y rutas visitadas en la campaña de terreno. Se presentan los 24 puntos de control que fueron visitados en los 5 días efectivos de terreno. Los colores tanto de puntos y rutas se condicen con el día correspondiente de trabajo. Se indica además el lugar de alojamiento (hospedaje) durante la visita.

### 4.3. ETAPA DE GABINETE 2 (POST-TERRENO)

#### 4.3.1. PREPARACIÓN DE DATOS

##### 4.3.1.1. ACONDICIONAMIENTO DE VARIABLES CATEGÓRICAS

La Geología y Uso de Suelo son variables de tipo categóricas, por lo cual debieron ser acondicionadas para ser evaluadas como una variable numérica (Tabla 4.4). Esto implicó asignar un valor numérico arbitrario a cada categoría, para luego convertir las respectivas cubiertas desde formato *Shape* a Ráster en ArcMap 10.5.

**Tabla 4.4: Variables categóricas y su conversión numérica.** Se describen cada una de las categorías de las variables Geología y Uso de Suelo, y la correspondiente asignación numérica arbitraria a cada una de ellas. Elaboración propia.

Variable	Categoría	Valor num.	
Geología	PIHs	Depósitos fluviales y aluviales, deltaicos, coluviales, estuarinos, lacustres, conos de deyección, morrénicos, de remociones en masa, de playas y eólicos.	1
	PIHv	Lavas y depósitos piroclásticos y laháricos, principalmente basálticos a riolíticos	2
	Piv	Lavas y depósitos piroclásticos y laháricos, principalmente dacíticos.	3
	Mg	Granitos, granodioritas, monzonitas, tonalitas, dioritas y gabros.	4
	PTrg	Gabros, y en menor proporción, ultrabasitas.	5
	PzTrc	Esquistos anfíbolíticos, y rocas máficas y ultramáficas.	6
Uso de Suelo	Áreas sobre límite de la vegetación		1
	Bosque Nativo Achaparrado		2
	Bosque Nativo Adulto – Renoval denso		3
	Bosque Nativo Adulto – Renoval semidenso		4
	Bosque Nativo Adulto		5
	Cajas de Ríos		6
	Ciudades - Pueblos – Zonas Industriales		7
	Lago – Laguna – Embalse – Tranque		8
	Marismas herbáceas		9
	Matorral arborescente		10
	Matorral pradera		11
	Matorral semidenso		12
	Playas y Dunas		13
	Praderas perennes		14
Ríos		15	

#### 4.3.1.2. DATASETS DE TRAINING Y TESTING

Las Redes Neuronales Artificiales (RNA), herramienta seleccionada para llevar a cabo el análisis de deslizamientos requiere ser entrenada en base a información previa, la cual en este caso corresponde al catastro de deslizamientos (arranque y alcance). Es decir, la red necesita aprender a partir de datos reales que serán el parámetro de referencia para que este sistema interconectado de neuronas sea capaz de estimar o prever cómo se comportará el terreno que tiene determinadas características dadas por los factores condicionantes del mismo.

Fueron construidos 2 set de datos (*datasets*), de entrenamiento y testeo (*training* y *testing*) tanto para el análisis de arranque, como el de alcance. Para el *training* se utilizó el 60% del total de los puntos de cada inventario, y el 40% restante para *testing*. Esta proporción fue elegida de forma arbitraria, ya que como se pudo constatar en bibliografía revisada, no existe un consenso

específico en cuanto a esto (Ermini *et al.* 2005; Yesilnacar & Topal, 2005; Kanungo *et al.* 2006; Pradhan & Lee, 2010; Kalantar *et al.* 2017; Braun, 2018). La separación de inventarios se realizó de forma aleatoria con herramientas vectoriales en QGIS 3.10.5.

Una vez definidos los inventarios de *training* y *testing*, a partir de ellos se efectuó una extracción de estadísticas zonales con un *buffer* de 15m, sobre cada una de las capas temáticas (ráster) pertenecientes a los factores condicionantes preseleccionados. Esta secuencia de procesos fue optimizada y llevada a cabo gracias a la elaboración de un modelo de herramientas en *Model Builder* de ArcMap 10.5. Esto entregó como *output* 4 tablas Excel correspondientes a cada uno de los inventarios Arranque/*Training*, Arranque/*Testing*, Alcance/*Training* y Alcance/*Testing*.

#### 4.3.1.3. GESTIÓN DE LOS DATASETS EN EXCEL

Se llevó a cabo un último proceso de preparación de los datos necesarios para entrenar y evaluar la red neuronal. Esto consiste en 2 tipos de tratamiento diferenciado para variables categóricas y continuas. Las primeras requieren ser transformadas a variables binarias, por lo cual, cada una de las categorías de las variables Geología y Uso de Suelo se transformaron en nuevas variables numéricas con valores posibles 0 y 1, donde 1 indica la presencia de una determinada categoría sobre el punto del catastro evaluado, y 0 indica la ausencia de la misma (Tabla 4.5). Esto se llevó a cabo haciendo uso de fórmulas condicionales de Microsoft Excel 2010.

**Tabla 4.5: Transformación de variables categóricas.** Se muestra a modo de ejemplo el desglose de la variable Geología, en 6 nuevas variables de tipo numérica binaria, que corresponden a cada una de las categorías de dicho factor. Las nuevas variables indican la presencia (1) o ausencia (0) una determinada categoría en el punto evaluado del inventario de puntos. Esto se aplica de la misma forma con el facto Uso de Suelo, o cualquier otra variable categórica. Elaboración propia.

Variable Original		Nuevas Variables					
Geología		GEO1	GEO2	GEO3	GEO4	GEO5	GEO6
PIHs	1	1	0	0	0	0	0
PIHv	2	0	1	0	0	0	0
PIv	3	0	0	1	0	0	0
Mg	4	0	0	0	1	0	0
PTrg	5	0	0	0	0	1	0
PzTrc	6	0	0	0	0	0	1

En cuanto a las variables numéricas continuas, estas deben ser normalizadas en un rango de valores 0 a 1, de acuerdo a la fórmula que se expresa a continuación:

$$X_{\text{norm}} = \frac{X_i - X_{\text{min}}}{X_{\text{máx}} - X_{\text{min}}}$$

Donde  $X_i$  corresponde al valor de un factor determinado sobre un punto del catastro,  $X_{\text{máx}}$  y  $X_{\text{min}}$  son los valores máximos y mínimos en la cobertura ráster de dicho factor, y  $X_{\text{norm}}$  es el nuevo valor normalizado, que puede adoptar valores entre 0 y 1.

Tanto este proceso de normalización, como la transformación de las variables categóricas, se realizó en cada uno de los 4 *datasets*, en los cuales siempre se debe conservar la correspondencia de valores de factores con el valor de referencia del inventario, el cual indica si el dato corresponde a la presencia (1) o ausencia (0) de cada uno de los sub-procesos evaluados (Tabla 4.6).

**Tabla 4.6: Estructura de *datasets* finales.** Se muestra un extracto de un *dataset* de *training*, el cual al igual que uno de *testing*, debe incorporar una columna que indique los valores de referencia para la red neuronal, es decir, señala a qué corresponde cada punto muestreado (filas) por el catastro; los 1 indican la presencia de un deslizamiento (arranque o alcance, donde corresponda) y los 0 indican la ausencia de dicho proceso. El resto de las columnas corresponden a los valores muestreados de cada factor condicionante sobre cada punto. En este caso solo se muestran las variables continuas, ya normalizadas. Elaboración propia.

TRAINING	SLOPE	ELEV	CURV	SIN_SLOPE	ROUGH	TWI	SOLAR	NDVI
1	0.468346	0.388628	0.585938	0.975204	0.06850	0.22113	0.64580	0.46488
1	0.670922	0.489348	0.574777	0.931504	0.12051	0.14998	0.46973	0.40961
1	0.404333	0.350721	0.587054	0.918956	0.04488	0.25488	0.68107	0.59060
1	0.470812	0.184962	0.590179	0.974795	0.08807	0.20613	0.72777	0.34084
1	0.446348	0.491385	0.591518	0.958066	0.21425	0.15975	0.82809	0.5605
0	0.048775	0.439536	0.58817	0.140100	0.05183	0.27085	0.69326	0.64335
0	0.033307	0.410526	0.590179	0.095798	0.04918	0.2215	0.74400	0.71033
0	0.021171	0.499373	0.584821	0.060977	0.02320	0.45608	0.77410	0.67633
0	0.042429	0.517126	0.594494	0.121974	0.03790	0.20588	0.78562	0.71874
0	0.037457	0.454731	0.58817	0.107760	0.01934	0.36882	0.75250	0.27844

Los *datasets* resultantes del proceso señalado anteriormente, fueron exportados en formato "CSV" (separado por comas) para poder ser importados al *software* donde será llevado a cabo el análisis con redes neuronales.

## 4.3.2. ANÁLISIS CON REDES NEURONALES ARTIFICIALES

### 4.3.2.1. RECURSOS COMPUTACIONALES

El análisis con redes neuronales artificiales fue llevado a cabo en el entorno de desarrollo integrado (IDE) RStudio (versión 1.2.5033), herramienta de programación con uso de lenguaje R. Es un *software* libre de código abierto (*open source*), por tanto es gratuito y además es multiplataforma, es decir, puede ser usado en diversos sistemas operativos (S.O.). El presente estudio fue llevado a cabo en un S.O. Windows 10 *Home Single Language*. Las características del equipo utilizado se detallan a continuación:

- Procesador: Intel ® Core™ i3-6100U CPU 2.30GHz
- Memoria RAM: 8.00 GB
- Tipo de sistema: Sistema operativo de 64bits, procesador x64

RStudio cuenta con innumerables “paquetes” (*packages*), que corresponden a colecciones de funciones y conjuntos de datos creados por los desarrolladores y colaboradores de dicho *software* para llevar a cabo todas de tareas que se pueden realizar con él. Si bien se utilizaron numerosos paquetes de funciones dentro del código implementado para este análisis, es preciso señalar que el entrenamiento de RNA's se gestó con el paquete de funciones “neuralnet”, desarrollado por Frauke Guenther y Stefan Fritsch. De la misma forma, para la evaluación e interpretación de la red neuronal fue clave el uso del paquete “NeuralNetTools”, creado por Marcus Beck para la visualización y análisis de redes neuronales. Por su parte, la creación de los mapas originados por la red neuronal requirió el uso del paquete “raster”, desarrollado por Robert Hijmans y colaboradores, para la lectura, escritura, análisis y modelación de datos espaciales.

### 4.3.2.2. PREPARACIÓN Y GESTIÓN DE DATOS EN RSTUDIO

El primer paso para el trabajo en entorno RStudio consistió en definir el directorio de trabajo (*Working Directory*), que corresponde a la ubicación o carpeta dentro del equipo donde se almacenará toda la información relativa al proyecto. En seguida de esto procedió la instalación de todos los paquetes de funciones necesarios para los diferentes procesos: neuralnet, NeuralNetTools, raster y rgdal. Luego fueron importados los 4 *datasets* de *training* y *testing* tanto del Arranque como del Alcance.

Por otra parte, se llevó a cabo la importación de los diferentes ráster correspondientes a cada uno de los factores condicionantes preseleccionados. Esto fue realizado por separado para arranque y alcance, ya que luego fueron convertidos en 2 set de datos independientes, los cuales posteriormente pasaron por un proceso de normalización, al igual que los datos de *training* y *testing*, ya que la red neuronal solo será capaz de trabajar con datos constreñidos entre 0 y 1 (0 y 1 inclusive). Cabe mencionar que los *datasets* derivados de los rásters de variables categóricas pasaron por un proceso de reestructuración y clasificación, con el fin de mantener el mismo orden y estructura que los *dataset* de *training* y *testing*. Esto último es clave para llevar a cabo el método, pues todos los sets de datos utilizados para entrenar y evaluar una red neuronal deben tener el mismo formato, por tanto, la misma cantidad de variables y los mismos encabezados.

#### 4.3.2.3. ANÁLISIS DE ARRANQUE DE DESLIZAMIENTOS

##### **Ejecución de redes neuronales y pruebas de modelos**

Tal como fue mencionado anteriormente, la ejecución de las redes neuronales (RNA) fue llevada a cabo mediante el uso del paquete de datos “neuralnet”, el cual incorpora la función del mismo nombre, que es la encargada de entrenar una red neuronal definida por una serie de argumentos o parámetros, los cuales se detallan y explican en el trabajo Fritsch & Günther (2010). En la Figura 4.12 se muestra la función arquetipo utilizada en el presente estudio, indicando aquellos argumentos que fueron mantenidos como constantes, y los que se modificaron en el proceso de ajuste de la red neuronal a través de la ejecución de diferentes modelos (diferentes RNA). Cada modelo de red neuronal está dado por la variación de 1 o más parámetros o variables dentro de dicha función.

```
#MODELO "ANN.X"

library(neuralnet)
x<-c(a,b,c...)
set.seed(7896129)

ANN.X<-neuralnet(TRAINING~VARIABLE1+VARIABLE2+VARIABLE3+VARIABLE4+VARIABLEn,
data=DATAFRAME.TRAINING, hidden=x, threshold=0.01, rep=1, algorithm="rprop+",
err.fct="ce", act.fct="logistic", linear.output=FALSE, stepmax=1e+05,
learningrate=0.01)
```

**Figura 4.12: Código generalizado para entrenamiento de red neuronal con neuralnet package.** Se presenta un extracto del código desarrollado, correspondiente al entrenamiento de una red neuronal. Primero se requiere definir la estructura de las capas ocultas (argumento "hidden"), dada por la cantidad de elementos numéricos un vector auxiliar "x", y el número seleccionado será la cantidad de neuronas cada capa respectiva. En seguida se establece el elemento "set.seed" con una cifra aleatoria, que permitirá que el modelo ejecutado sea reproducible. Luego, se configura la función "neuralnet" que entrenará y definirá una red "ANN.X". Los elementos y parámetros indicados en color son aquellos que fueron ajustados y modificados entre un modelo y otro. Mayores detalles sobre el uso de la función neuralnet se describen en Fritsch & Günther (2010). Elaboración propia.

Luego de entrenar un modelo de red neuronal, prosiguió el testeo de la misma al computar la red con los datos correspondientes para ello. Dicho proceso permite evaluar la capacidad de predicción del modelo al ejecutarlo con un nuevo set de datos, y posibilita la obtención de la curva ROC/AUC asociada a dicho modelo. De la misma forma, fueron generados los diversos gráficos que permiten develar el comportamiento interno de la red neuronal: *General Weights*, *Pairwise Plot*, *Garson Plot*, *Olden Plot* y *Lek Profile*.

En línea con lo anterior, una vez ejecutado cada modelo, se computó y exportó el mapa de susceptibilidad correspondiente al mismo, haciendo uso de los ráster importados previamente al entorno de RStudio. Esto se realizó de forma paralela a las pruebas de modelos con motivo de evaluar visualmente resultado de cada red neuronal, con criterio geológico-geomorfológico. Es decir, se supervisó el desempeño de la red neuronal con el fin de detectar posibles sinsentidos o incongruencias en el mapa, o resultados poco realistas; lo cual fue un importante parámetro de evaluación para la selección del modelo final.

Todo lo descrito anteriormente fue repetido sucesivas veces con el fin de probar diversos modelos de red neuronal que permitan, por una parte, realizar una evaluación y discriminación de variables, y por otra, lograr la configuración de factores condicionantes y parámetros neuronales más adecuados para analizar de forma correcta la susceptibilidad de las laderas ante el proceso de deslizamiento objeto de este estudio.



## Evaluación y descarte de variables

Luego de llevar a cabo una cierta cantidad de iteraciones de distintas redes neuronales, se procedió a hacer una evaluación de las variables, lo que en para este estudio en particular se abordó desde 2 enfoques diferentes:

- 1) Control visual de mapas: Se rechazaron modelos cuyos mapas no arrojaron un sentido lógico, y se descartaron variables asociadas a la incongruencia.
- 2) Jerarquización de variables: Basado diferentes gráficas vinculadas a cada modelo, se realizó una comparación y jerarquización relativa de las diferentes variables, de acuerdo a la computación interna de cada red neuronal.

El descarte por control visual de mapas fue llevado a cabo solo en una primera etapa de pruebas de modelos (10 iteraciones), donde fue evidente la poca consistencia de los mapas asociados. Esto conllevó la desestimación de las variables categóricas para las siguientes pruebas, lo que será abordado en el capítulo 6. Cabe mencionar que la eliminación de variables implica re-estructurar los sets de datos de *Training* y *testing*, restando las columnas pertenecientes a los factores descartados.

El siguiente set de modelos (11 iteraciones) fue evaluado principalmente de acuerdo al segundo enfoque discriminatorio, consistente una jerarquización simple y ordenada ideada en este estudio, que se fundamenta en 3 de las gráficas de interpretación de redes neuronales: *Pairwise Plot*, *Garson Plot* y *Olden Plot*. Sólo fueron consideradas dichas gráficas, dado que ellas entregan un orden relativo de las variables en cuanto a su importancia o peso dentro del análisis interno que efectúa la red neuronal. Esta jerarquización fue llevada a cabo en una hoja Excel, donde se confeccionó una tabla cuyas filas corresponden a las variables evaluadas, mientras que las columnas representan a las gráficas mencionadas de cada uno de los modelos efectuados (Tabla 4.7). De esta forma, cada casillero indicará el orden relativo de la variable dado en la gráfica y modelo correspondiente, de tal forma que el número 1 indica máxima importancia, e índices más altos señalan menor importancia. Luego, para cada variable se realiza una sumatoria horizontal de los valores otorgados en cada una de las 3 gráficas, para posteriormente ordenar las variables de acuerdo a la cifra total obtenida, lo que además se graficó para visualizar de mejor manera

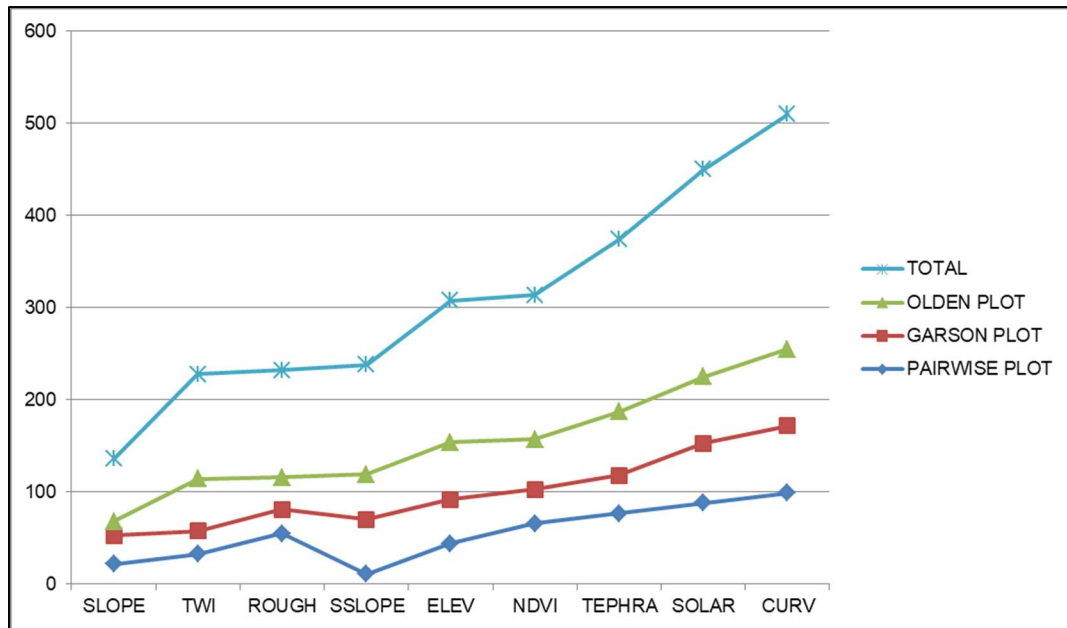
**Tabla 4.7: Jerarquización de variables (Parte I).** Ejemplo de tabla confeccionada para efectuar jerarquización de variables de acuerdo al orden relativo de éstas entregado por las gráficas de los diferentes modelos de red neuronal ejecutados. Los valores mostrados son ficticios, tabla válida sólo como muestra de la estructura de trabajo. Elaboración propia.

Gráfica	Pairwise Plot (PW)			Garson Plot (GP)			Olden Plot (OP)		
Modelo	Mod 1	Mod 2	Mod3	Mod 1	Mod 2	Mod3	Mod 1	Mod 2	Mod3
SLOPE	2	2	2	6	4	2	1	2	1
SIN_SLOPE	4	4	4	4	5	4	4	3	6
CURV	7	7	7	3	3	6	7	5	8
ROUGH	5	5	5	1	1	3	6	1	3
SOLAR	3	3	3	2	8	1	3	7	5
ELEV	8	8	8	5	6	8	8	8	7
NDVI	6	6	6	7	2	7	5	6	4
TEPHRA	2	2	2	6	4	2	1	2	1
TWI	4	3	4	4	5	4	4	3	6

Variable	PW	GP	OP	TOTAL
SLOPE	22	31	15	68
TWI	33	25	56	114
ROUGH	55	26	35	116
SIN_SLOPE	11	59	49	119
ELEV	44	48	62	154
NDVI	66	37	54	157
TEPHRA	77	41	69	187
SOLAR	88	65	72	225
CURV	99	73	83	255

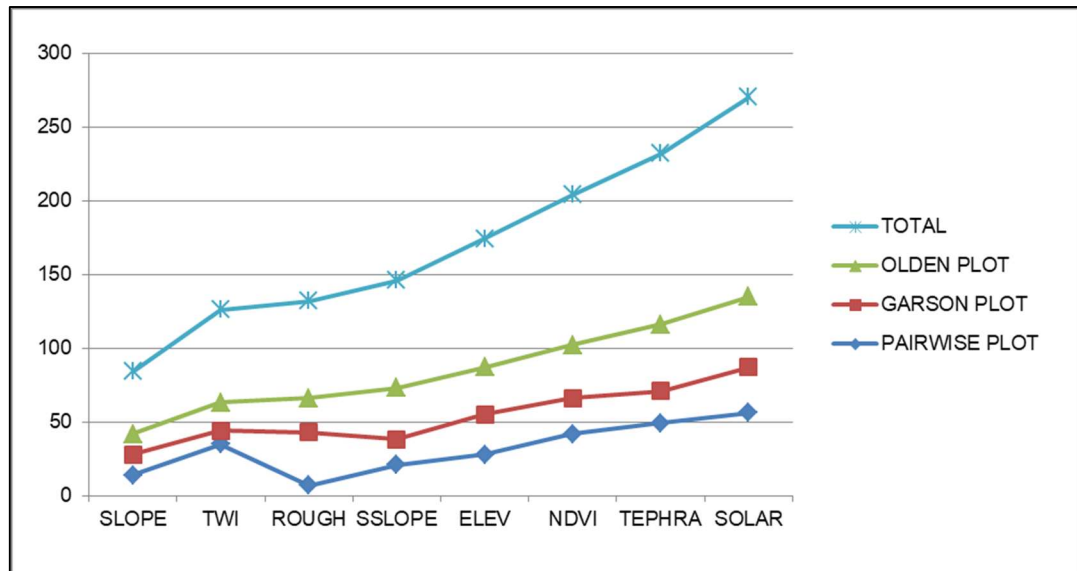
**Tabla 4.8: Jerarquización de variables (Parte II).** Sumatoria de índices ordinales de importancia de variables, realizado para el segundo set de iteraciones de red neuronal. Se observa que la mayor importancia la obtiene la variable Pendiente (SLOPE) al obtener la mayor sumatoria de índices. Valores reales obtenidos del análisis de Arranque. Elaboración propia.





**Figura 4.13: Gráfico de jerarquización de variables.** Directamente asociado a la Tabla 4.8, muestra de manera gráfica el orden de importancia relativa total obtenido para las variables evaluadas en el segundo set de iteraciones de redes neuronales para la evaluación del Arranque de deslizamientos. Se puede observar que las variables CURV tiene el mayor índice, señalando la baja jerarquía de dicho factor con respecto a los demás. Las curvas azul roja y verde, al presentarse de forma aproximadamente paralelas entre sí, evidencian que las 3 gráficas consideradas estiman de forma muy similar la importancia que las redes neuronales asignan a las variables.

Una vez realizada la evaluación por jerarquía de variables, se procedió a descartar la de menor relevancia, que en este caso fue el factor CURV. De esta forma se procedió a eliminar dicha variable de los sets de datos, para llevar a cabo nuevas pruebas de modelos (6 iteraciones), las cuales fueron sometidas una vez más al mismo proceso de evaluación ya descrito, con el fin de poder supervisar los cambios que genera en la red neuronal la ausencia del factor descartado. La jerarquización obtenida de este tercer set de iteraciones de red neuronal entrenada con 8 variables, se puede observar en la Figura 4.14.



**Figura 4.14: Gráfico segundo proceso de jerarquización de variables.** Se puede observar el mismo orden jerárquico que la primera evaluación (Figura 4.13), dejando nuevamente en las últimas posiciones a las variables TEPHRA y SOLAR.

Puesto que en el último caso las diferencias de jerarquía entre las variables son lineales, es decir, no se identificó un quiebre o diferencia sustancial de importancia entre una variable y la que se encuentra justo bajo ella, esto dificultó la toma de decisión en cuanto a la cantidad de variables que efectivamente deben desestimarse. Para solucionar esto, se recurrió al análisis de las gráficas restantes obtenidas del entrenamiento de las redes neuronales: *General Weights* (GW) y *Lek Profile*. (Lek)

Las gráficas mencionadas pueden ser utilizadas con doble propósito; por una parte indican el correcto funcionamiento del modelo, ya que estas deben ser interpretables (de acuerdo a la descripción entregada por sus autores), de lo contrario reflejan un deficiente desempeño en la configuración del modelo de red neuronal. Por otro lado, cada gráfica puede señalar qué variables no tienen relevancia dentro del análisis interno que realiza cada red neuronal, en términos de los pesos que se les asigna a las variables en el proceso de aprendizaje de la red (*General Weights*), o en términos de la sensibilidad que tienen las diferentes variables en presencia de las demás (*Lek Profile*). De acuerdo a esto, se decidió descartar las variables TEPHRA y SOLAR, ya que además de haber resultado como las variables de menor importancia o jerarquía, evidenciaron alta sensibilidad ante la presencia de otras variables, lo que modifica su comportamiento ante el proceso evaluado, y no serían factores condicionantes robustos.

Se llevaron a cabo 6 pruebas adicionales con las 6 variables restantes del último proceso discriminante. Estos modelos muestran una mayor congruencia a modo general en sus gráficas *Lek* y *GW*, es decir, son más interpretables y permiten visualizar de mejor manera el comportamiento de cada variable. Esto indica que el descarte de variables realizado tuvo efectos positivos en el rendimiento de la red neuronal. Sin embargo, es posible notar que algunos *Lek Profile* indican que la variable *ELEV* es muy sensible con respecto a las otras, es decir, la relación que tiene dicha variable con el proceso de arranque de deslizamientos es cambiante frente a la presencia de otros factores. Considerando esto, se procedió a realizar siguientes pruebas desestimando la variable *ELEV*. De esta forma, los últimos ensayos fueron llevados a cabo con las variables *SLOPE*, *SIN\_SLOPE*, *ROUGH*, *TWI* y *NDVI*.

El listado total de modelos ejecutados junto a la arquitectura y parámetros que conforman cada uno, pueden ser revisados en la Tabla 4.9.



**Tabla 4.9: Modelos de redes neuronales ejecutados para análisis de Arranque.** Se enlistan los modelos de redes neuronales entrenadas, detallando las variables, arquitectura y parámetros que definen cada uno de ellos. Elaboración propia.

MODELO	SLOPE	ELEV	TEPHRA	CURV	SSLOPE	ROUGH	TWI	SOLAR	NDVI	HIDDEN	THRESHOLD	ALGORITHM	ERR.FCT	STEP-MAX	LEARNINGRATE
ANN.1	X	X	X	X	X	X	X	X	X	x=c(9)	0.01	rprop+	ce	1.00E+05	-
ANN.2	X	X	X	X	X	X	X	X	X	x=c(9)	0.01	backprop	ce	1.00E+10	1.00E-02
ANN.3	X	X	X	X	X	X	X	X	X	x=c(9)	0.01	rprop+	sse	1.00E+05	-
ANN.4	X	X	X	X	X	X	X	X	X	x=c(9)	0.01	backprop	sse	1.00E+05	-
ANN.5	X	X	X	X	X	X	X	X	X	x=c(9)	0.01	rprop+	ce	1.00E+08	-
ANN.6	X	X	X	X	X	X	X	X	X	x=c(9,6)	0.01	rprop+	ce	1.00E+05	-
ANN.7	X	X	X	X	X	X	X	X	X	x=c(18)	0.01	rprop+	ce	1.00E+05	-
ANN.8	X	X	X	X	X	X	X	X	X	x=c(18,9)	0.01	rprop+	ce	1.00E+05	-
ANN.9	X	X	X	X	X	X	X	X	X	x=c(5)	0.01	rprop+	ce	1.00E+05	-
ANN.10	X	X	X	X	X	X	X	X	X	x=c(15)	0.01	rprop+	ce	1.00E+05	-
ANN.11	X	X	X	X	X	X	X	X	X	x=c(3)	0.01	rprop+	ce	1.00E+05	-
ANN.12	X	X	X	X	X	X	X	X	X	x=c(9)	0.01	rprop+	ce	1.00E+05	-
ANN.13	X	X	X	X	X	X	X	X	X	x=c(6)	0.01	rprop+	ce	1.00E+05	-
ANN.14	X	X	X	X	X	X	X	X	X	x=c(6)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.15	X	X	X	X	X	X	X	X	X	=c(2,3,6,3,	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.16	X	X	X	X	X	X	X	X	X	x=c(4,8,4)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.17	X	X	X	X	X	X	X	X	X	x=c(8,16)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.18	X	X	X	X	X	X	X	X	X	x=c(3)	0.01	rprop+	ce	1.00E+05	-
ANN.19	X	X	X	X	X	X	X	X	X	x=c(3)	0.01	rprop+	ce	1.00E+05	-
ANN.20	X	X	X	X	X	X	X	X	X	x=c(3)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.21	X	X	X	X	X	X	X	X	X	x=c(6)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.22	X	X	X	X	X	X	X	X	X	x=c(6)	0.01	backprop	ce	1.00E+10	1.00E-02
ANN.23	X	X	X	X	X	X	X	X	X	x=c(6,3)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.24	X	X	X	X	X	X	X	X	X	x=c(12)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.25	X	X	X	X	X	X	X	X	X	x=c(6)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.26	X	X	X	X	X	X	X	X	X	x=c(6)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.27	X	X	X	X	X	X	X	X	X	x=c(6)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.28	X	X	X	X	X	X	X	X	X	x=c(12)	0.01	backprop	sse	1.00E+10	1.00E-02
ANN.29	X	X	X	X	X	X	X	X	X	x=c(12)	0.01	backprop	ce	1.00E+10	1.00E-02
ANN.30	X	X	X	X	X	X	X	X	X	x=c(12)	0.01	rprop+	sse	1.00E+10	1.00E-02

## Selección de modelo

La selección final del modelo de red neuronal fue realizada en base a los últimos ensayos efectuados con las 5 variables mencionadas anteriormente. De éstos, fue seleccionado aquel que satisficiera las siguientes condiciones:

- Mapa con sentido geológico/geomorfológico
- Gráficas interpretables y con sentido.
- Buen índice ROC/AUC
- Bajo porcentaje de error

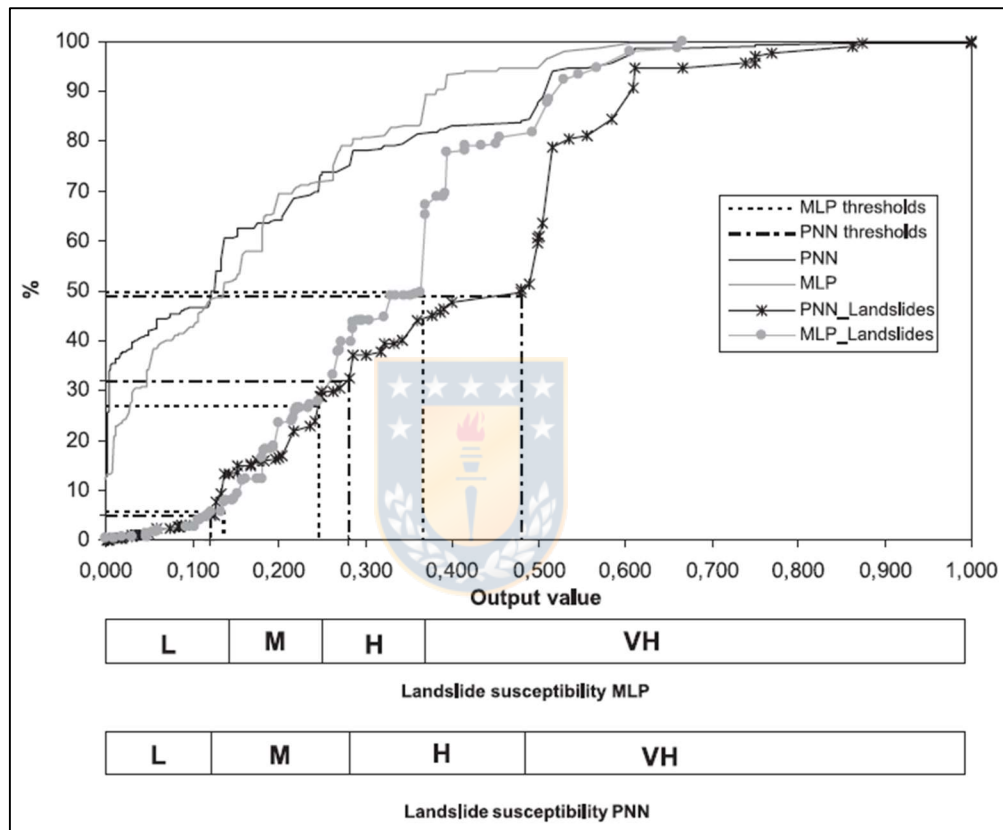
## Cálculo de error

El error asociado al modelo seleccionado fue calculado a partir del *dataset* de *testing* evaluado sobre el mapa resultante de la red neuronal elegida. Esto comprendió en primera instancia una extracción de datos zonales en ArcMap 10.5 de los puntos del catastro de *testing* sobre el mapa de susceptibilidad, con el fin de comparar y evaluar el grado de predicción de la red neuronal. Estos datos fueron llevados a una hoja Excel en la cual se ordenaron los valores de referencia del catastro frente a los valores que arrojó la red neuronal para cada punto. Luego, para hacer un cálculo porcentual del ajuste que presentaron los datos, se requirió definir un umbral arbitrario de evaluación desde el cual los valores obtenidos del mapa se considerarán 1 o 0. En este caso se seleccionó un umbral de 0.9, es decir, todos aquellos puntos en los cuales el mapa arrojó un valor igual o mayor a 0.9 se consideró como un 1, y bajo este un 0. De esta forma, fue posible determinar y cuantificar los verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, y con ello calcular el porcentaje de error (falsos totales).

## Determinación de umbral para representación de mapa final

El mapa *output* de la red neuronal corresponde a un ráster de valores continuos, por lo cual es necesario discretizar el rango de valores para así señalar con mayor precisión las zonas de gran índice de susceptibilidad de acuerdo a clases. En este caso se precisan sólo 2 clases. Para ello se confeccionó una gráfica de distribución porcentual de los eventos positivos catastrados. Esto es, un gráfico que ordena en términos de frecuencia acumulada los valores que la red neuronal calculó para los puntos que en el inventario fueron reconocidos como zonas de arranque.

El objetivo es poder visualizar de manera gráfica el porcentaje del catastro está contenido en un cierto rango o clase susceptibilidad, lo cual busca dar sustento a la clase a seleccionar como “Zona de Arranque” para el mapa final indicador de amenaza. Vale decir, se determinó el umbral que separa las dos clases, de acuerdo al mayor quiebre que mostró la curva graficada y deja gran porcentaje del catastro en el rango superior o de mayor susceptibilidad. Aplicación similar de procedimiento se puede observar en los trabajos de Ermini *et al.* (2005) (Figura 4.15) y Kalantar *et al.* (2017).




**Figura 4.15: Distribución acumulativa de resultados de una RNA aplicada al análisis de deslizamientos.** Se muestra la distribución para los dos modelos efectuados en este trabajo en su conjunto (1 y 0) y para los subconjuntos relativos a las zonas de deslizamiento (1) mapeadas. Los umbrales resaltados se han situado en correspondencia con los puntos de inflexión en las curvas del subconjunto de deslizamientos y se han utilizado para el posterior mapeo de susceptibilidad a los deslizamientos. L: susceptibilidad baja; M: susceptibilidad media; H: susceptibilidad alta; VH: susceptibilidad muy alta. Tomado sin modificaciones de Ermini *et al.* (2005)



#### 4.3.2.4. ANÁLISIS DE ALCANCE DE DESLIZAMIENTOS

En términos generales, el análisis del Alcance de deslizamientos se llevó a cabo siguiendo las mismas directrices metodológicas del análisis de Arranque, salvo modificaciones ligadas a la naturaleza de los datos de entrenamiento, que se mencionarán a continuación en cada etapa.

Es preciso señalar que en esta etapa se probó realizar un análisis dual al separar los datos del catastro con el fin de poder obtener 2 estimaciones de Alcance; una máxima y una mínima. Se diferenciaron procesos canalizados y no-canalizados (Figura 4.16), los primeros corresponden a aquellos deslizamientos cuyo material fluidizado habría confluído por quebradas sumándose al proveniente de otros centros de remoción; estos son los que logran un mayor alcance, mientras que los no-canalizados son aquellos deslizamientos ocurridos en una ladera sin transportarse por una quebrada, lo que a modo general no correspondería a eventos con alcance menor.



**Figura 4.16: Alcance de deslizamientos Canalizados y No-canalizados.** Vista 3D hacia la ladera Este del valle del Río Blanco, Chaitén. Ejemplos de diferenciación de mapeo de deslizamientos Canalizados (en celeste) y No-canalizados (en verde). Elaboración Propia.

El entrenamiento de redes neuronales se llevó a cabo con el catastro completo, sin la distinción entre ambos modos de transporte de deslizamientos pues la idea es poder utilizar la misma red

neuronal seleccionada para luego ejecutarla sólo con los datos de alcance no-canalizado y así idealmente obtener de un mapa que estime un alcance mínimo.

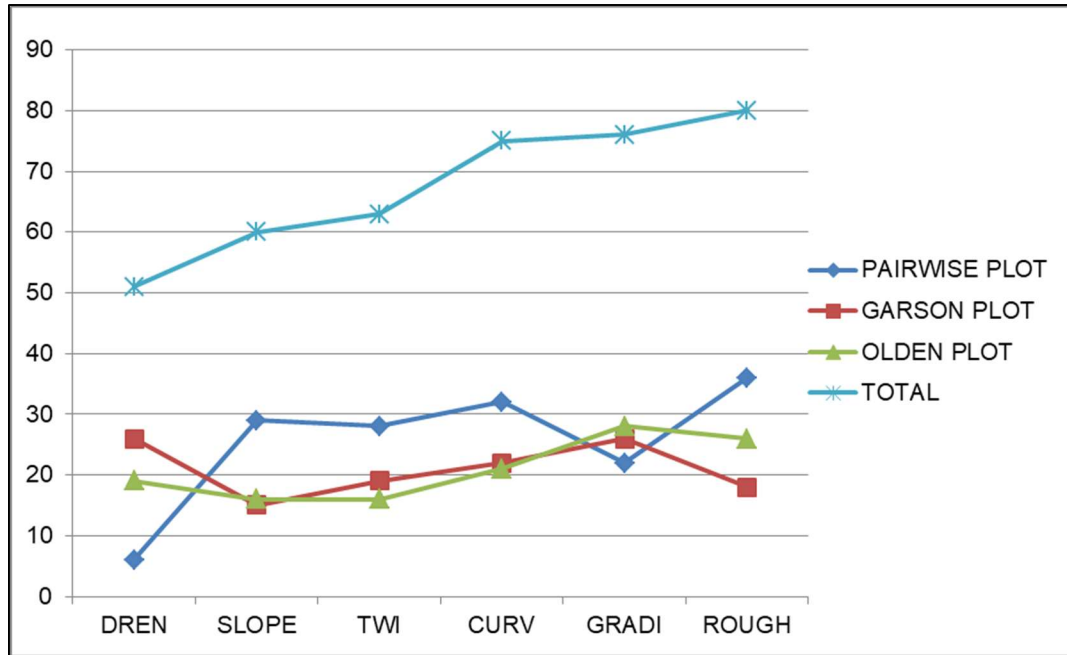
### **Ejecución de redes neuronales y pruebas de modelos**

Las diferentes redes neuronales entrenadas en esta etapa se llevaron a cabo de la misma forma y bajo los mismos criterios que el análisis de Arranque de deslizamientos. Sin embargo, en este caso la iteración de diferentes modelos fue mucho más limitada ya que el tiempo de computación de cada red neuronal fue mayor que en el análisis anterior. Esto fue causado por la naturaleza de los datos del catastro, los que se distribuyen de forma mucho más irregular con respecto a los rasgos geomorfológicos del área. Dicha característica significó a una mayor variabilidad en los datos, y por tanto, mayor dificultad a la hora de ejecutar el entrenamiento de cada red neuronal.

### **Evaluación y descarte de variables**

Una vez ejecutadas 6 iteraciones de entrenamiento de redes neuronales con 6 variables preseleccionadas (todas variables continuas), de forma paralela se realiza una evaluación visual de los mapas resultantes de cada modelo, lo que, a diferencia del análisis anterior, no fue causal de descarte de alguna variable ya que ningún mapa muestra inconsistencias graves ni directamente relacionadas a un factor en particular.

En vista de lo anterior, se procedió a evaluar las variables mediante el mismo proceso de jerarquización formulado para este trabajo, el cual indicó que la variable de menor jerarquía corresponde a ROUGH (Figura 4.17). Por tanto, los siguientes modelos fueron entrenados con 5 variables, y se realizaron 4 iteraciones. Cabe mencionar que en este proceso existieron redes neuronales con combinaciones de parámetros cuyo tiempo de computación fue extremadamente largo (más de 8 horas), por lo cual fue necesario abortar la ejecución.



**Figura 4.17: Jerarquización de variables Análisis de Alcance.** Evaluación de variables realizada para el análisis de Alcance de deslizamientos. Se puede observar que la variable DREN se estima como la de mayor jerarquía, mientras que la variable ROUGH al obtener el índice más alto es la variable con menor jerarquía.

Debido a la poca cantidad de variables, sólo se realizó un proceso de descarte de variables. El siguiente set de iteraciones sólo fue evaluado en base al comportamiento observable en las gráficas y mapas resultantes de cada entrenamiento, siguiendo los mismos criterios mencionados para el análisis de Arranque. Se efectuaron un total de 10 iteraciones, las cuales se detallan en la Tabla 4.10.

**Tabla 4.10: Modelos de redes neuronales ejecutados para análisis de Alcance.** Se enlistan los modelos de redes neuronales entrenadas, detallando las variables, arquitectura y parámetros que definen cada uno de ellos. Elaboración propia.

MODELO	SLOPE	GRADI	DREN	CURV	ROUGH	TWI	HIDDEN	THRESHOLD	ALGORITHM	ERR.FCT	STEP.MAX	LEARNINGRATE
ALC.F.1	X	X	X	X	X	X	x=c(6)	0.01	backprop	sse	1.00E+10	1.00E-02
ALC.F.2	X	X	X	X	X	X	x=c(12)	0.01	backprop	sse	1.00E+10	1.00E-02
ALC.F.3	X	X	X	X	X	X	x=c(6)	0.01	rprop+	sse	1.00E+10	1.00E-02
ALC.F.4	X	X	X	X	X	X	x=c(9)	0.01	backprop	sse	1.00E+10	1.00E-02
ALC.F.5	X	X	X	X	X	X	x=c(6)	0.01	rprop-	sse	1.00E+10	1.00E-02
ALC.F.6	X	X	X	X	X	X	x=c(14)	0.01	rprop-	sse	1.00E+10	1.00E-02
ALC.F.7	X	X	X	X	-	X	x=c(5)	0.01	rprop+	sse	1.00E+10	1.00E-02
ALC.F.8	X	X	X	X	-	X	x=c(5)	0.01	rprop-	sse	1.00E+10	1.00E-02
ALC.F.9	X	X	X	X	-	X	x=c(12)	0.01	rprop-	sse	1.00E+10	1.00E-02
ALC.F.10	X	X	X	X	-	X	x=c(5)	0.01	rprop-	ce	1.00E+10	1.00E-02

### **Selección del modelo, cálculo de error y representación del mapa final**

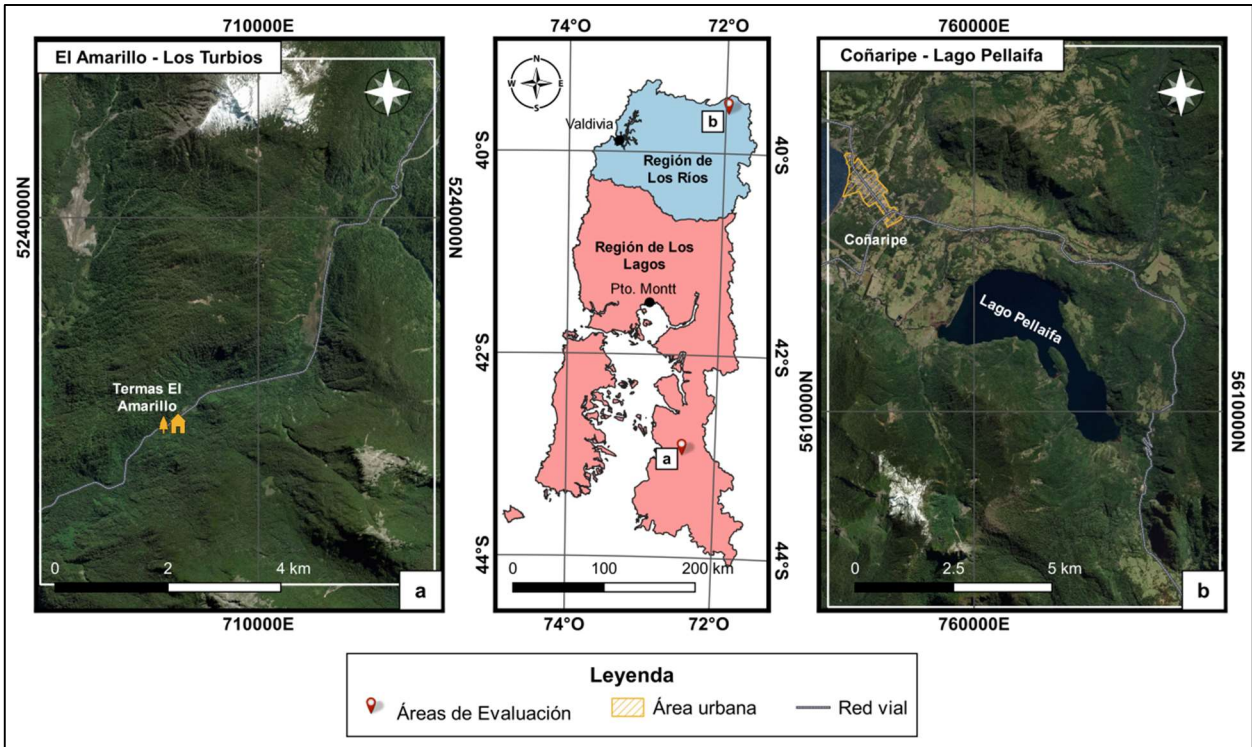
La selección del modelo de alcance, junto al cálculo del error asociado y la obtención del umbral de clasificación para la representación final del mapa, fueron llevados a cabo siguiendo el mismo procedimiento descrito para el análisis de Arranque de deslizamientos.

#### **Alcance no-canalizado**

Una vez seleccionado el modelo más adecuado, fueron preparados los *datasets* correspondientes al subconjunto “no-canalizado” del catastro de Alcance. Luego, con dicha información fue re-entrenada la red neuronal elegida, y posteriormente se exportó el mapa resultante de ésta.

#### **4.3.2.5. EVALUACIÓN EN OTRAS ZONAS DE CHILE**

Se llevaron a cabo 2 pruebas de los modelos de red neuronal seleccionados, en 2 lugares distintos a la zona de estudio; una zona cercana al área de estudio, y una lejana. Para ello se determinó aplicar esto en el sector El Amarillo – Los Turbios, a pocos kilómetros al Este del área de estudio, y en el sector Lago Pellaifa – Coñaripe, ubicado a aproximadamente 377 kilómetros al Norte de Chaitén, en la Región de Los Ríos (Figura 4.18).



**Figura 4.18: Ubicación de zonas de evaluación de redes neuronales.** En el centro se presenta un mapa de escala regional donde se muestra la ubicación de las áreas de evaluación. En ambos costados se exponen las imágenes a y b con las imágenes satelitales (ESRI) respectivas para la zona El Amarillo-Los Turbios y Coñaripe-Lago Pellaifa. Elaboración propia.

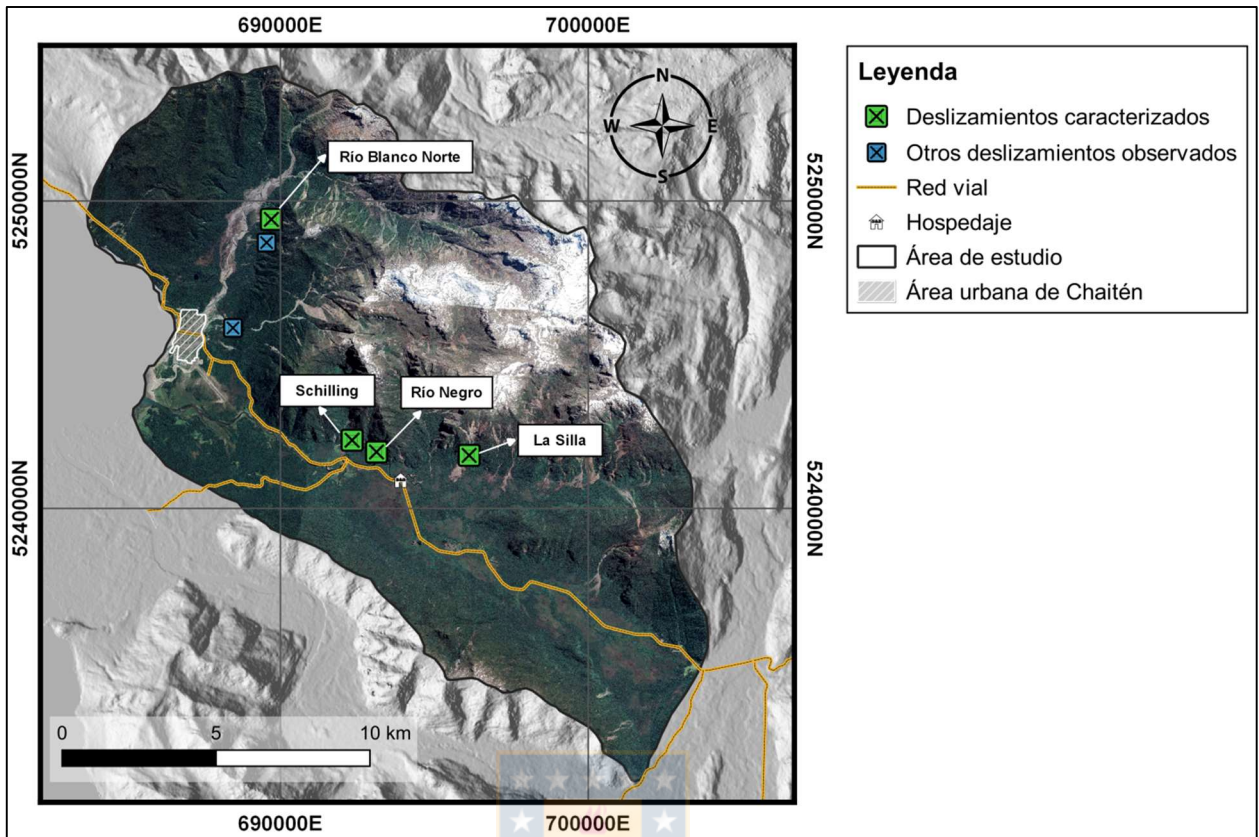
Fueron recopilados los datos geospaciales necesarios para preparar las capas temáticas ráster de cada factor involucrado en los modelos finales seleccionados, para cada una de las 2 zonas seleccionadas. Por tanto, se obtuvieron 2 set de rásters, para cada una de las zonas, tanto para evaluar en Arranque como el Alcance de deslizamientos. Posteriormente se importaron dichos datos a RStudio para computar las redes neuronales con la nueva información, y así obtener los mapas correspondientes a cada nueva zona evaluada.

## 5. RESULTADOS


Los resultados del presente trabajo se presentan por separado en Resultados de Terreno y Resultados de Análisis de Susceptibilidad; esto con el fin de ordenarlos de acuerdo a su naturaleza y alcances. Los primeros comprenden todos aquellos datos y observaciones rescatadas en el trabajo de campo en la zona de estudio, que fueron clave a la hora de caracterizar el tipo de proceso estudiado, y discernir con criterio geológico cuáles son los principales factores que condicionan la ocurrencia de los mismos, para luego conjugar esto con el análisis de redes neuronales artificiales (RNA). Por otra parte, se presentan los resultados centrales de este estudio referentes al análisis de susceptibilidad, los cuales abarcan los mapas de susceptibilidad e indicativo de amenaza, los errores asociados a ellos, así como también las diferentes gráficas que permiten develar el funcionamiento de las RNA, y el proceso de validación de este método.

### 5.1. RESULTADOS DE TERRENO

Los resultados de terreno más relevantes radican en la caracterización morfológica y temporal de las remociones en masa presentes en la zona. De acuerdo a esto, se tiene que la mayor parte de ellos pueden ser descritos como deslizamientos naturales de suelo y vegetación, traslacionales, planares y fluidizados. Todos aquellos deslizamientos a los que fue posible acceder fueron descritos de manera individual en una ficha tipo llamada “StorMe” del Ministerio de Medio Ambiente de Suiza, la cual es utilizada por los profesionales de GEOTEST en las visitas a terreno (Anexo 4). Si bien fue posible avistar numerosas cicatrices de deslizamientos en las laderas de la zona visitada, sólo 4 remociones de grandes dimensiones pudieron ser observadas y caracterizadas de forma cercana. Dichos deslizamientos fueron llamados “La Silla”, “Schilling”, “Río Blanco Norte” y “Río Negro” (Figuras 5.1 y 5.2).




**Figura 5.1: Ubicación de deslizamientos controlados en terreno.** Se muestran los 4 deslizamientos que pudieron ser observados y descritos con mayor detalle en terreno (marcados en verde) y se indican otros deslizamientos que pudieron ser observados a mayor distancia (marcados en azul).



**Figura 5.2: Deslizamientos visitados y descritos en terreno.** Fotografías en terreno de los 4 deslizamientos mejor observados y documentados de la visita a la zona de estudio. a) “La Silla”: Corresponde a un deslizamiento de enormes dimensiones, de tipo múltiple y canalizado, además involucra más de un tipo de remoción. Sólo es posible observar la parte inferior de la ladera afectada y el depósito. b) “Río Negro”: Deslizamiento traslacional de suelo y vegetación. Se observa desde una distancia moderada, no se logra acceder al depósito por barrera fluvial y vegetacional. c) “Schilling”: Deslizamiento traslacional de suelo y vegetación. Es posible acceder a los pies del mismo, a un costado del depósito. d) “Río Blanco Norte”: Deslizamiento traslacional de suelo y vegetación. Se logra acceder cerca de los pies de la ladera, observando sólo la mitad inferior de la remoción, ya que tiene su origen cerca de la cota 800m. Una verdadera muralla de vegetación asentada sobre los bordes del depósito impide al paso hasta el mismo. Observaciones a distancia moderada.

En la mayoría de los deslizamientos fue posible observar que el material desprendido (zona de arranque) corresponde casi exclusivamente a una delgada cubierta de suelo (1-1.5 metros de espesor) y la vegetación que la sobreyace, que corresponde a densos bosques nativos cuyas especies arbóreas (Coihue, Alerce, Tenío, Tepú, Tapa, Ciruelillo, Arrayán, entre otros) alcanzan los 30 a 40 metros de altura (Figura 5.3). Junto con esto, no es posible notar alguna correlación entre la ocurrencia de estos eventos con el tipo de roca subyacente y/o estructuras asociadas.





**Figura 5.3: Suelo y vegetación en los deslizamientos del área.** Se presentan dos ejemplos de deslizamientos donde se puede apreciar la cicatriz dejada en la ladera correspondiente al macizo rocoso expuesto, delimitado inmediatamente por densos bosques en los cuales se distingue una delgada capa de cobertura de suelo, la cual se intenta delimitar con líneas naranja. En ambos casos no se incluye escala ya que son fotografías tomadas en perspectiva y con uso de zoom. a) Deslizamiento “Río Negro”. Se puede observar la corona de desprendimiento, donde se expone de forma clara suelo y raíces. b) Deslizamiento Schilling. No es posible ver la corona de desprendimiento, sin embargo, se puede notar la delgada capa de suelo a la cual se anclan las grandes especies arbóreas.

Los deslizamientos habrían tenido un movimiento mayormente traslacional, dejando el macizo rocoso descubierto y “lavado”, y el material movilizado en todos los casos habría sido fluidizado, dada las características de los depósitos, los cuales en todos los casos tienen forma de “lenguas” al pie de las laderas, donde la mezcla de suelo, rocas y troncos se observan con clara imbricación y forman “levees” en los bordes del depósito (Figura 5.4). Las fichas de cada uno de los deslizamientos mencionados pueden ser revisadas en el Anexo 4, y los resultados de la fotogrametría aérea realizada sobre éstos, de puede ver en el Anexo 5.



**Figura 5.4: Ejemplo de depósito de deslizamiento.** Fotografía aérea del deslizamiento “Schilling”, en la cual se encuadra la zona de depósito principal que exhibe una morfología de “lengua” y es posible apreciar los diques formados por los troncos de árboles removidos, transportados y depositados de forma fluidizada, posicionándose a modo de “levees” en los bordes del depósito. Esto se presenta en todos los deslizamientos de la zona.

Cabe señalar que, de acuerdo a los testimonios de lugareños, todos los deslizamientos observados habrían ocurrido de manera extremadamente rápida en medio de importantes frentes de lluvia en otoño-invierno. Así también, ellos declaran que previo a la erupción del Volcán Chaitén no existía conocimiento de fenómenos de remociones en masa del tipo, frecuencia y magnitud como los que han ocurrido en los últimos 6 años.

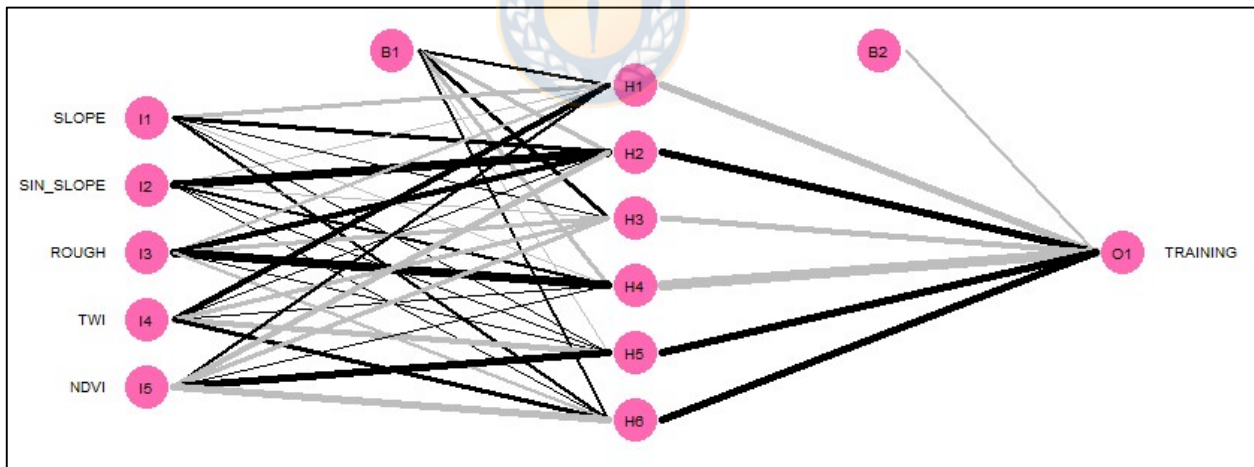
De igual forma es preciso mencionar que la gran mayoría de los eventos catastrados en el área, pese a las grandes dimensiones que exhiben, no infligieron daños a personas, animales ni infraestructura, salvo 1 evento ocurrido el año 2015, cuyo material movilizado afectó al Cuartel Militar de Chaitén, ubicado a aproximadamente 3 Km de distancia desde la zona de arranque.

## 5.2. RESULTADOS DE ANÁLISIS CON RNA

A continuación, se presentan los resultados centrales de este trabajo comenzando por los 2 procesos de análisis de susceptibilidad llevados a cabo de forma separada para el arranque y alcance de deslizamientos. En ambos casos, se exponen los modelos seleccionados, indicando los parámetros, arquitectura y variables utilizadas, y los mapas obtenidos directamente desde la red neuronal. Posteriormente se presenta el mapa final indicativo de amenaza que conjuga ambos análisis previos, y para finalizar se entregan los resultados de la evaluación de los modelos en otras zonas.

### 5.2.1. SUSCEPTIBILIDAD DE ARRANQUE DE DESLIZAMIENTOS

El modelo de red neuronal seleccionado es el modelo "ANN\_26", cuya arquitectura se presenta en la Figura 5.5, donde se puede ver que las 5 covariables seleccionadas mediante el proceso descrito en el capítulo de Metodología, las cuales corresponden a la Pendiente, Pendiente Senoidal, Rugosidad, TWI y NDVI. Los parámetros matemáticos utilizados para la construcción de la red se listan en la Tabla 5.1.



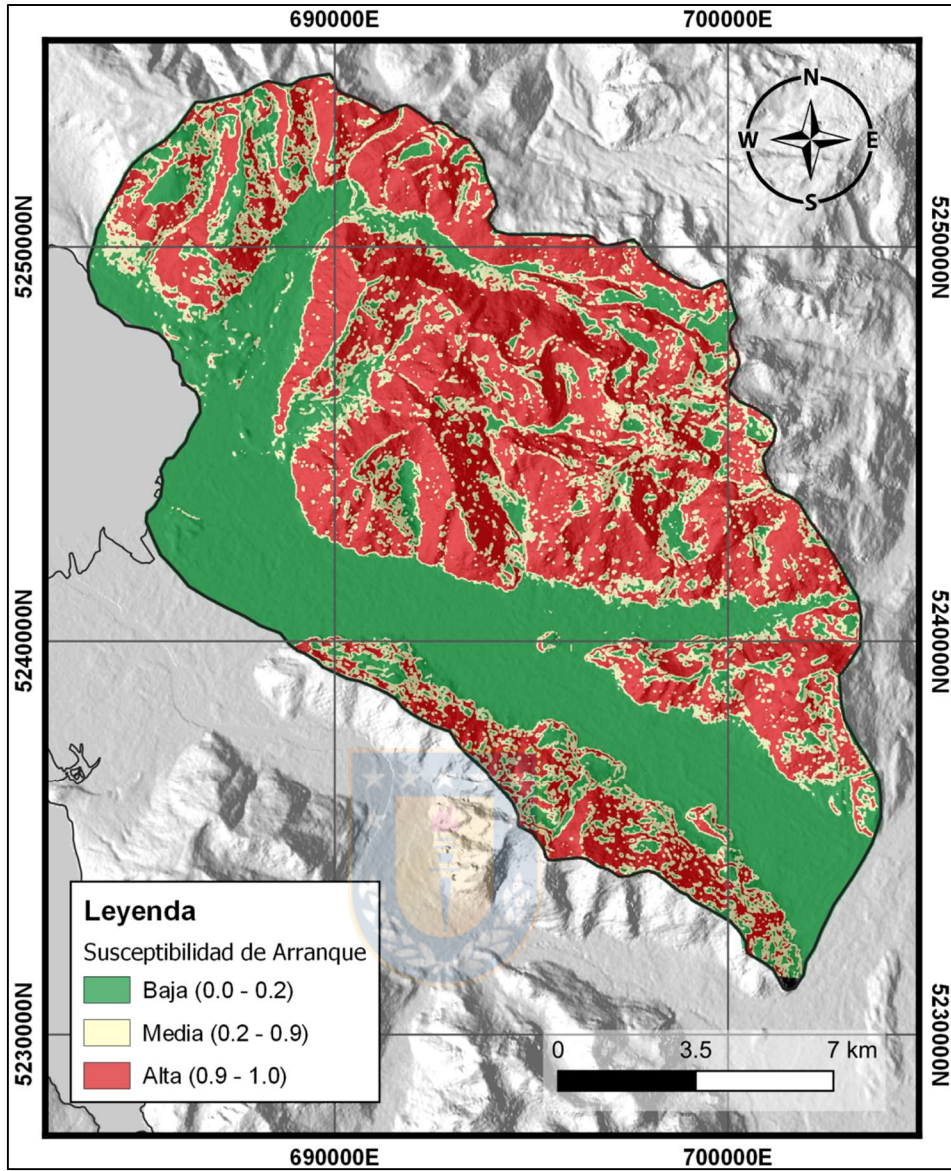
**Figura 5.5: Arquitectura Red Neuronal para análisis de Arranque.** Red conformada por una capa de entrada constituida por 5 nodos correspondiente a las 5 variables explicatorias (factores condicionantes) seleccionadas, una capa oculta con 6 nodos y la capa de salida corresponde una única neurona que representa la variable binaria evaluada con la referencia del *Training*. Los pesos sinápticos entre las distintas capas se representan cualitativamente con líneas negras para pesos positivos y grises para pesos negativos, mientras que el grosor de dichas líneas es proporcional a la magnitud absoluta de éstos.

**Tabla 5.1: Parámetros RNA del modelo “ANN\_26”.** Lista de los parámetros ingresados a la función “neuralnet”, y que conforman la red neuronal seleccionada para el análisis de Arranque de deslizamientos.

Parámetro	ANN_26
Capas ocultas	1 capa, 6 nodos
Umbral	0.01
Repeticiones	1
Algoritmo	<i>Backpropagation</i>
Función del error	Suma de errores al cuadrado (sse)
Función de activación	Logística
Máximo de pasos	10 <sup>10</sup>
Tasa de aprendizaje	0.01

El mapa resultante de la computación de esta red neuronal se muestra en la Figura 5.6. Este ilustra un índice de susceptibilidad en una escala de 0 a 1, el cual señala la predisposición del terreno para la ocurrencia de deslizamientos (arranque) en base a las características del mismo, que corresponden a las variables ingresadas en el modelo. Así, zonas cercanas a 0 no podrían originar deslizamientos, mientras que las cercanas a 1 serían muy propensas a generar dichos procesos. El error asociado al mapa, con respecto al catastro de referencia, es de un 3.2%, tal como se detalla en la Tabla 5.2.



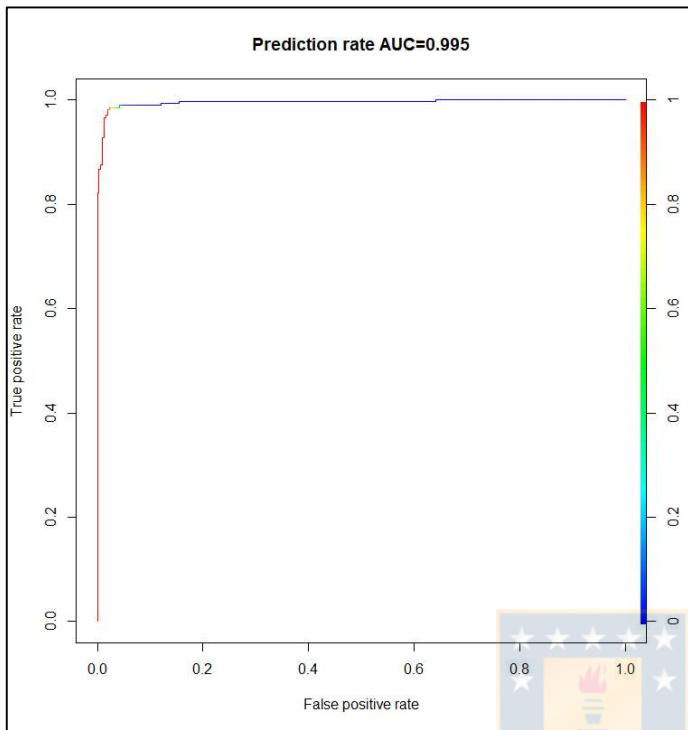


**Figura 5.6: Mapa de susceptibilidad de Arranque de deslizamientos.** Mapa resultante del modelo de red neuronal "ANN\_26". Se indican 3 niveles de susceptibilidad, baja, media y alta. Los valores de índice de susceptibilidad se indican en la leyenda.

**Tabla 5.2: Error asociado al mapa de susceptibilidad de Arranque.** Se mide el grado de acierto del modelo con un umbral de 0.9, el cual separa los resultados en 2 clases (>0.9=1; <0.9=0) comparables con los eventos de deslizamiento y no-deslizamiento registradas en el catastro de referencia. Dicha comparación arroja grupos de Verdaderos (aciertos) y Falsos (errores). En base a eso se calcula el total de eventos para cada grupo y se calculan los respectivos porcentajes con respecto total global (630 eventos), lo cual entrega un error de 3.2%.

Eventos		Catastro de referencia		Total	Porcentaje
		Deslizamiento	No-deslizamiento		
Modelo RNA Umbral IS = 0.9	Verdaderos	298	312	610	96.8%
	Falsos	17	3	20	3.2%

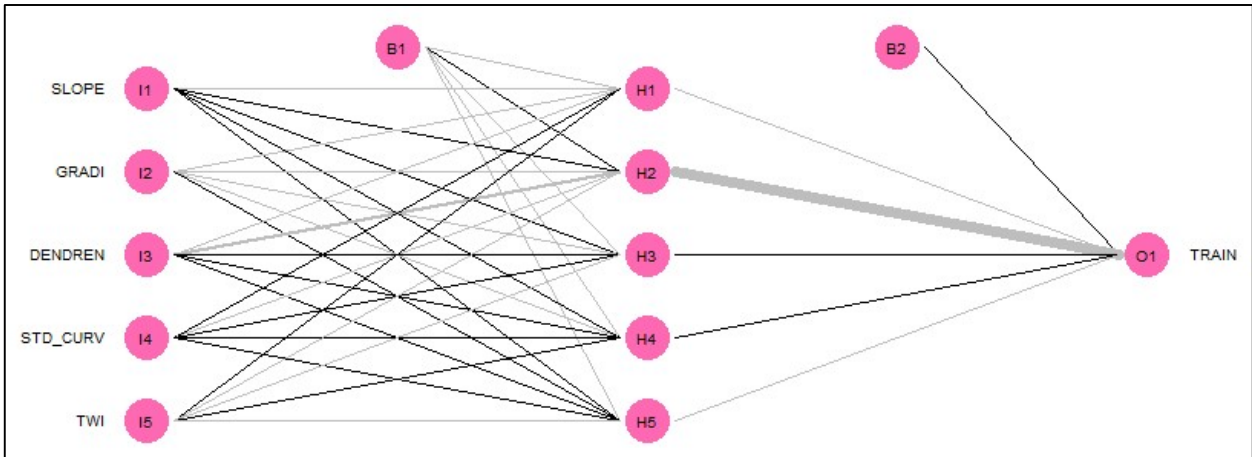
Otra medida del rendimiento del modelo seleccionado corresponde a la gráfica ROC/AUC que se muestra a continuación en la Figura 5.7.



**Figura 5.7: Gráfica ROC/AUC del modelo "ANN\_26".** Se obtiene una "tasa de predicción" igual a 0.995, muy cercana a 1, lo cual indica una capacidad de separabilidad entre clases casi perfecta para este modelo.

### 5.2.2. SUSCEPTIBILIDAD DE ALCANCE DE DESLIZAMIENTOS

Para el análisis de susceptibilidad de zonas de alcance, fue seleccionado el modelo "ALC.F.8", correspondiente a una red de arquitectura 5 x 5 x 1, como puede observarse en la Figura 5.8. Las variables que la conforman son Pendiente, Gradiente Topográfico, Densidad de Drenaje, Curvatura y TWI, resultantes del proceso de selección mediante sucesivas pruebas de modelos de RNA. Los parámetros matemáticos utilizados para la construcción de la red se listan en la Tabla 5.3.

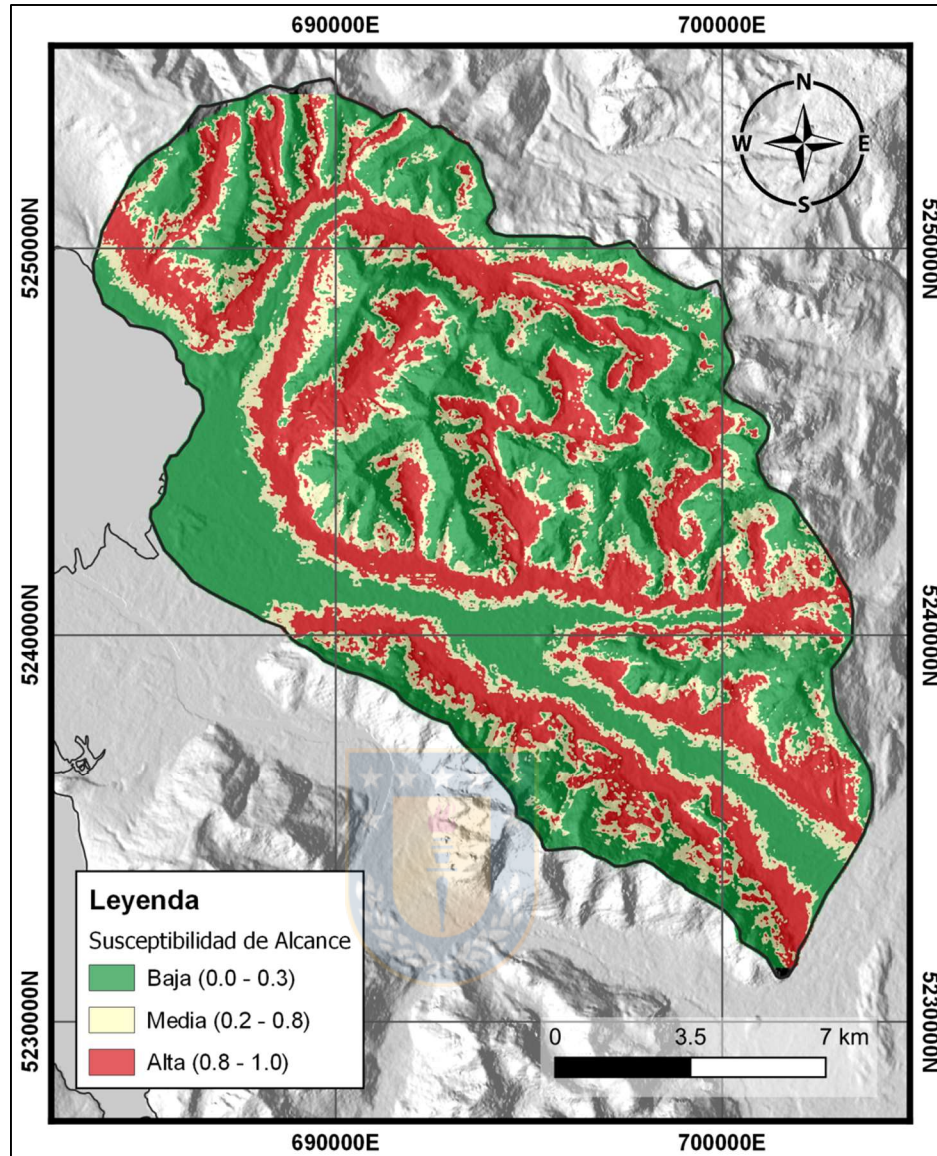


**Figura 5.8: Arquitectura de Red Neuronal para análisis de Alcance.** Se constituye por una capa de entrada de 5 nodos correspondientes a las 5 variables explicatorias seleccionadas, una capa oculta de 5 nodos y la capa de salida conformada por sólo una neurona de la variable de respuesta binaria evaluada con los datos provenientes del *dataset* de *Training*. Los pesos sinápticos entre las distintas capas se representan cualitativamente con líneas negras para pesos positivos y grises para pesos negativos, mientras que el grosor de dichas líneas es proporcional a la magnitud absoluta de éstos.

**Tabla 5.3: Parámetros RNA del modelo “ALC.F.8”.** Lista de los parámetros ingresados a la función “neuralnet”, y que conforman la red neuronal seleccionada para el análisis de Alcance de deslizamientos.

Parámetro	ALC.F.8
Capas ocultas	1 capa, 5 nodos
Umbral	0.01
Repeticiones	1
Algoritmo	<i>Resilient Backpropagation (-)</i>
Función del error	Suma de errores al cuadrado (sse)
Función de activación	Logística
Máximo de pasos	$10^{10}$
Tasa de aprendizaje	0.01

Al igual que el mapa de susceptibilidad obtenido para el Arranque de deslizamientos, se presenta un mapa (Figura 5.9) que expone un índice de susceptibilidad en una escala de 0 a 1, categorizado en 3 clases: baja, media y alta. Estas clases señalan el grado de predisposición del terreno para ser alcanzado por el material removido por los deslizamientos previamente analizados. De esta forma, las zonas con índices cercanos a 0 no podrían ser alcanzados por las remociones, mientras que las cercanas a 1 serían muy propensas a ser alcanzadas ya sea por el tránsito o deposición final del material deslizado. El error asociado a este mapa, con respecto al catastro de referencia, es de un 11.9%, tal como se detalla en la Tabla 5.4.




**Figura 5.9: Mapa de susceptibilidad de Alcance de deslizamientos.** Mapa resultante del modelo de red neuronal “ALC.F.8”. Se indican 3 niveles de susceptibilidad, baja, media y alta. Los valores de índice de susceptibilidad se indican en la leyenda.

**Tabla 5.4: Error asociado al mapa de susceptibilidad de Alcance.** Se mide el grado de acierto del modelo con un umbral de 0.8, el cual separa los resultados en 2 clases ( $>0.8=1$ ;  $<0.8=0$ ) comparables con los eventos de alcance y no-alcance registradas en el catastro de referencia. Dicha comparación arroja grupos de Verdaderos (aciertos) y Falsos (errores). En base a eso se calcula el total de eventos para cada grupo y se calculan los respectivos porcentajes con respecto total global (832 eventos), lo cual entrega un error de 11.9%.

Eventos		Catastro de referencia		Total	Porcentaje
		Deslizamiento	No-deslizamiento		
Modelo RNA Umbral IS = 0.8	Verdaderos	332	401	733	88.1%
	Falsos	84	15	99	11.9%



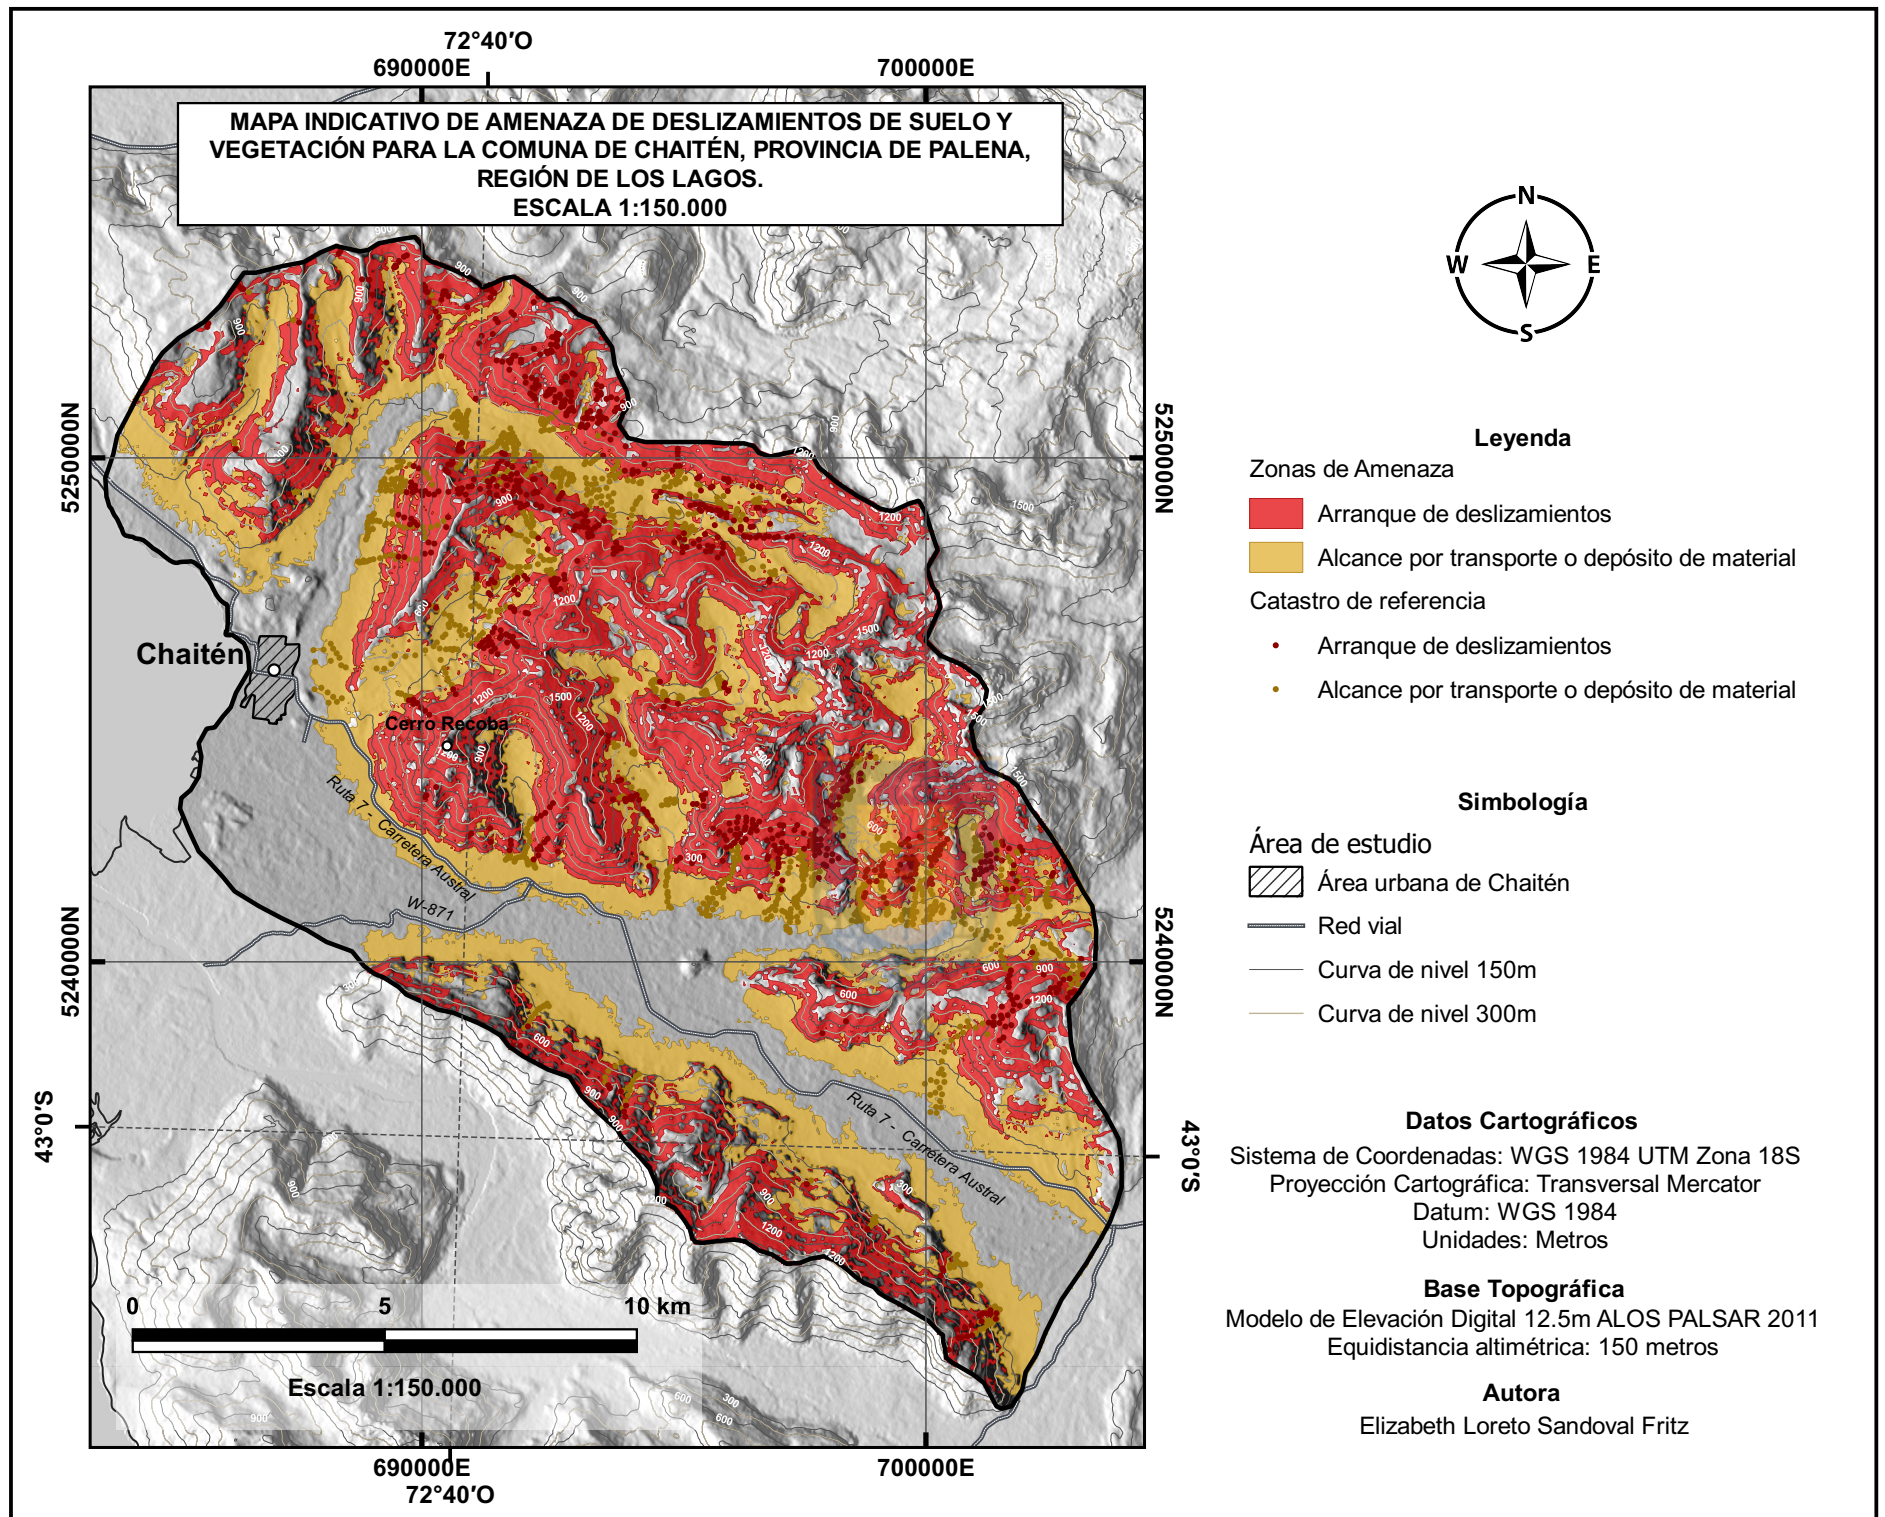
Otra medida del rendimiento del modelo seleccionado corresponde a la gráfica ROC/AUC que se muestra a continuación en la Figura 5.10.



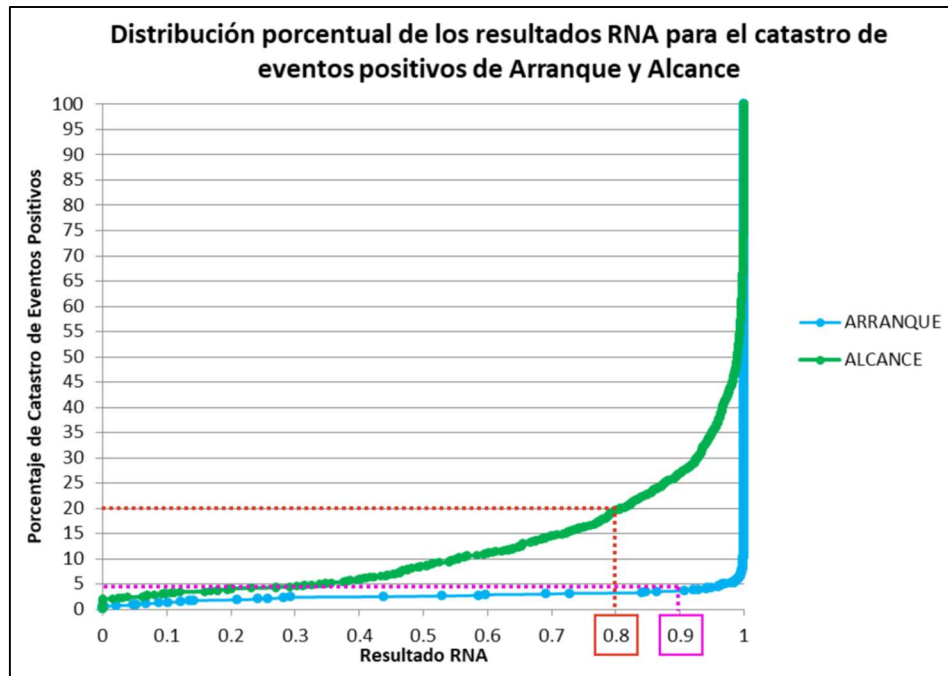
**Figura 5.10: Gráfica ROC/AUC del modelo "ALC.F.8".** Se obtiene una "tasa de predicción" igual a 0.963, muy cercana a 1, lo cual indica una muy buena capacidad de separabilidad entre clases para este modelo.

### 5.2.3. MAPA INDICATIVO DE AMENAZA

Una vez realizados los análisis de susceptibilidad correspondientes, los datos de salida de ambos modelos (mapas de susceptibilidad) se conjugan en un solo mapa que será indicativo de la amenaza (Figura 5.11) asociada a las características del terreno, la cual expresa los índices de susceptibilidad más altos obtenidos para cada sub-proceso Arranque y Alcance de deslizamientos. Los umbrales de corte para delimitar la clase más alta de susceptibilidad en cada caso, se seleccionan de acuerdo a la técnica planteada en la sección 4.3.2, que entrega las distribuciones de datos presentadas en la Figura 5.12, desde donde se toman los quiebres en 0.9 para Arranque, y 0.8 para Alcance. Esto señala que sobre dichos umbrales el modelo contiene el 95% y el 80% de los eventos positivos catastrados para cada proceso, respectivamente



**Figura 5.11: Mapa Indicativo de Amenaza para la comuna de Chaitén, escala 1:150.000.** Se presenta el resultado final del análisis llevado a cabo con Redes Neuronales Artificiales. Las áreas en rojo indican la porción del terreno que representa importante amenaza para generar zonas de arranque de deslizamientos de suelo y vegetación. Mientras que las áreas en amarillo indican aquellas zonas propensas a alcance del material de dichos deslizamientos, ya sea por transporte o por depósito de la remoción. Los puntos en rojo y amarillo corresponden al catastro de eventos positivos de Arranque y Alcance, respectivamente. Las zonas de Arranque se delimitan a partir un índice de susceptibilidad igual o mayor a 0.9, mientras que las de Alcance desde un índice igual o mayor a 0.8. Las primeras abarcan un 95% del total de eventos positivos del catastro para arranque con el cual fue entrenada la red neuronal para dicho proceso, mientras que las zonas de Alcance cubren un 80% del total de los puntos de su respectivo catastro.




**Figura 5.12: Umbrales de clasificación para el Mapa Indicativo de Amenaza.** En base a la distribución porcentual de los resultados de la red neuronal versus los datos de catastro, se pueden definir umbrales para separar clases en la salida de cada modelo (mapas de susceptibilidad). Dichos umbrales se estiman visual y arbitrariamente de acuerdo a los cambios de tendencia de la distribución y al grado de porcentaje que abarcan los rangos que limitan dichos umbrales. En este caso se hace una separación de dos clases que requiere solo 1 valor umbral para cada mapa, por lo que se determinan los índices 0.9 para Arranque y 0.8 para alcance, los cuales engloban el 95% y 80% del total de los eventos positivos catastrados para cada sub-proceso.

## 6. ANÁLISIS DE RESULTADOS

### 6.1. POSIBLES FACTORES CONDICIONANTES

En base a la caracterización y observaciones realizadas en terreno, así como también a los testimonios de lugareños, y complementado con la revisión de imágenes satelitales temporales y bibliografía, es posible inferir que la ocurrencia de los deslizamientos en la zona está estrechamente ligada a la calidad de la vegetación supeditada a la ocurrencia del período eruptivo del Volcán Chaitén en los años 2008 y 2009.

Al revisar el registro histórico de imágenes satelitales para la zona en Google Earth Pro, es posible notar una gran diferencia entre el panorama visual del año 2007 (pre-erupción) versus el año 2016 (Figura 6.1), donde se activaron la mayor parte de los deslizamientos catastrados en el área. Por otra parte, otros autores ya han relacionado la ocurrencia de importantes erupciones en Chile (Volcán Chaitén y otros), con la pérdida de calidad de la vegetación y la posterior activación de remociones en masa en la zona afectada por caída de ceniza (Korup *et al.*, 2019; Moreno-González *et al.*, 2019; Swanson *et al.*, 2013).



**Figura 6.1: Contraste temporal en imágenes satelitales del área de estudio.** Se exhiben los notorios cambios superficiales en el área entre el escenario pre-eruptivo el año 2007 y el que existe 7 años después de dicho evento. En la imagen derecha es posible observar numerosas cicatrices dejadas por deslizamientos de gran magnitud, de los cuales no existía registro reciente alguno antes de la erupción del Volcán Chaitén.

En base a estas evidencias, se puede entender que la erupción del Volcán Chaitén 2008-2009 expulsó enormes cantidades de ceniza o tefra, la cual al depositarse por suspensión sobre los

extensos bosques de la zona paulatinamente habría incidido en la salud de la cubierta vegetal, perdiendo capacidad de retención de agua y fuerza radical, lo que años más tarde se traduciría en numerosos focos de desestabilización con una gran susceptibilidad ante factores gatillantes como lo son los extensos y fuertes períodos de lluvias que se registran año a año en la zona.

De acuerdo a lo anterior, posibles factores condicionantes de mayor relevancia en la zona son: la vegetación (uso de suelo o NDVI), tefra caída en la erupción del Volcán Chaitén (isópacas de tefra), características hidrológicas (densidad de drenaje, TWI) y morfología superficial (pendiente, rugosidad, curvatura, entre otros).

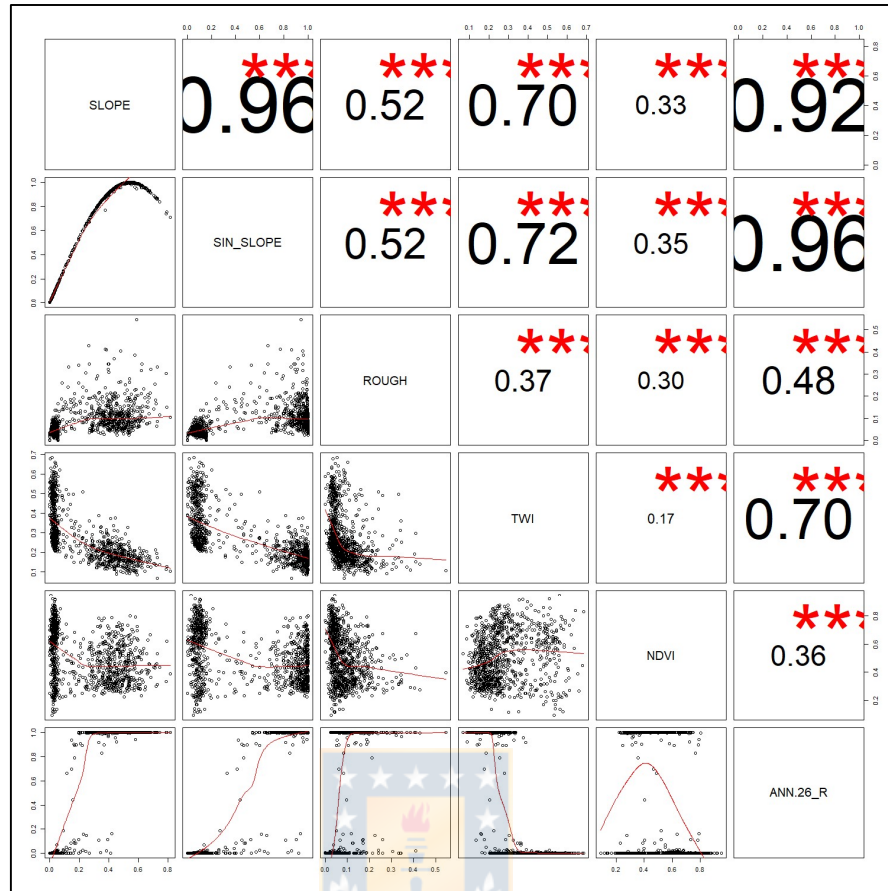
Cabe señalar que esta estimación de factores condicionantes es aplicable sólo al análisis de susceptibilidad para la zona de arranque de deslizamientos.

## 6.2. SUSCEPTIBILIDAD CON RNA

### 6.2.1. ANÁLISIS DEL MODELO DE ARRANQUE

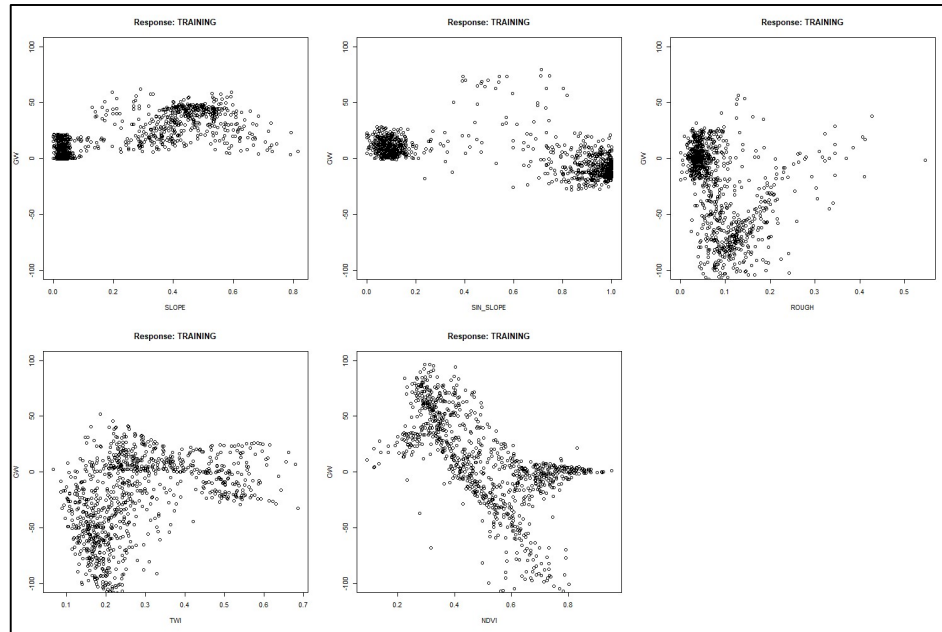
Las gráficas de análisis de RNA obtenidas para el modelo seleccionado se presentan a continuación en las Figuras 6.2, 6.3, 6.4 y 6.5, cada una con su correspondiente interpretación antecediéndola.

La gráfica *Pairwise Plot* (Figura 6.2) muestra una relación simple entre todas las variables ingresadas al modelo, y con la variable de respuesta entregada por la red neuronal. Las principales observaciones deben efectuarse, por una parte, sobre la columna del extremo derecho, donde se muestran indicadores numéricos del grado de ajuste que cada covariable tiene con la variable de respuesta (arranque de deslizamientos), de lo cual se extrae que las covariables con mayor correlación son la pendiente senoidal (SIN\_SLOPE) y la pendiente (SLOPE), y en tercer lugar el TWI; sin embargo, las 5 covariables tienen grados de correlación relevantes que explican la variable de respuesta. Por otro lado, en la fila del extremo inferior se puede ver la relación y variación entre las covariables y el fenómeno evaluado, de forma gráfica; aquí es posible notar el modo de correlación, donde se tiene que las variables SIN\_SLOPE, SLOPE y ROUGH evolucionan de forma directa con la ocurrencia de deslizamientos, mientras que el TWI lo hace de forma inversa y el NDVI tiene un comportamiento dual, mostrando una correlación concentrada hacia valores medios de dicha variable.



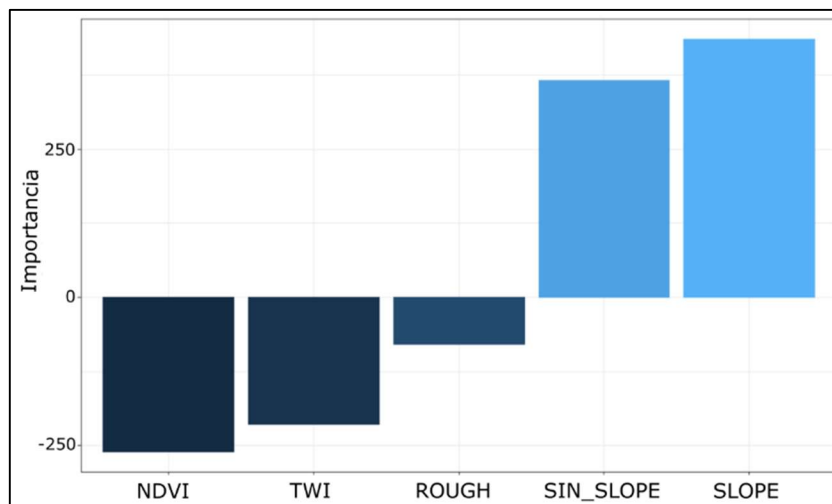
**Figura 6.2:** *Pairwise Plot* para el modelo “ANN\_26”. Comparación pareada entre todas las variables de entrada del modelo, y la predicción realizada por la red neuronal.

Los pesos generales para el Arranque (Figura 6.3) indican que cada una de las covariables cumplen con el requisito de no-linealidad de la red neuronal, ya que ninguna concentra sus pesos en un valor constante. Esto ocurre ya que en modelos previos fue posible detectar aquellas variables que se comportan de manera lineal sin contribuir de forma significativa a la respuesta de la red, y fueron descartadas. De forma adicional es posible notar que los factores que tienen una relación directa con la ocurrencia de deslizamientos, sus pesos generales son positivos, mientras que aquellos con relación inversa sus pesos se incrementan de forma negativa, lo que indica una contribución a la “no-ocurrencia” del fenómeno en el rango de valores donde sucede esto (valores bajos de la variable). Con respecto a esto último, se puede ver claramente el comportamiento dual del NDVI, que tiene contribución positiva en valores por bajo la media, y contribución negativa sobre ella.



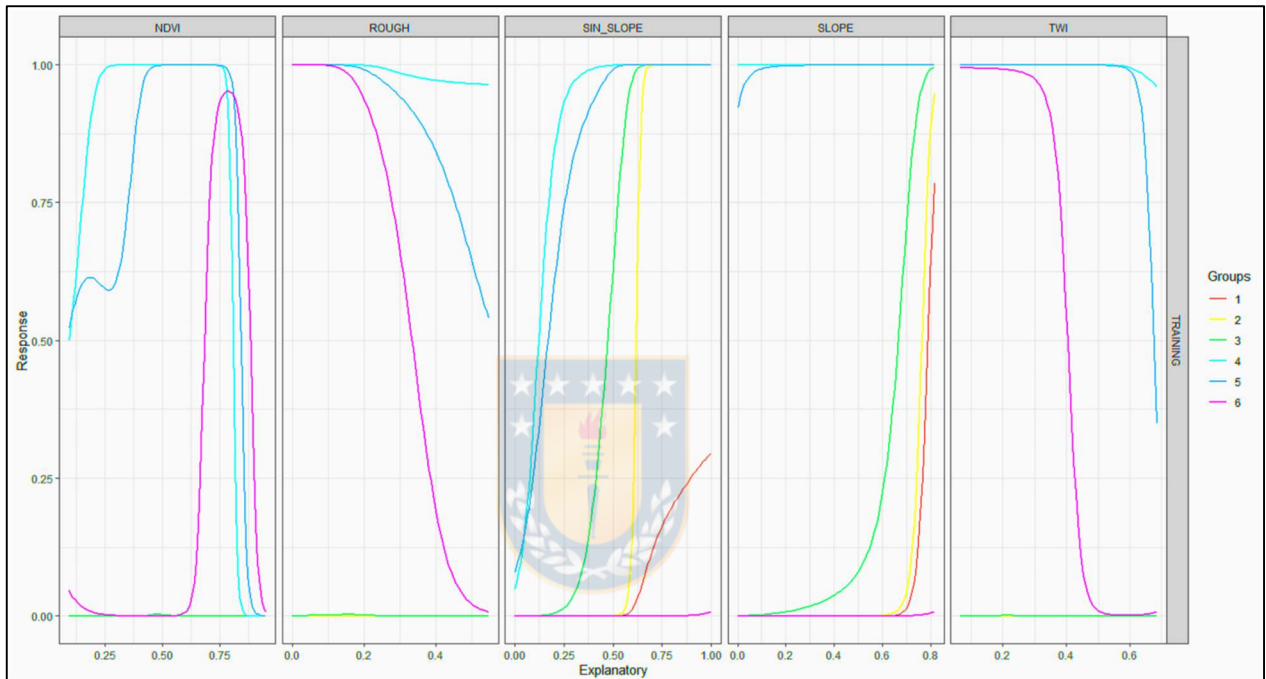
**Figura 6.3: Gráfica General Weights para “ANN\_26”.** Se muestran los pesos calculados por la red neuronal para cada una de las variables de entrada.

De acuerdo a la gráfica de Olden (Figura 6.4), la importancia de las variables aumenta en el siguiente orden: ROUGH, TWI, NDVI, SIN\_SLOPE\_SLOPE. El algoritmo de Olden conserva el signo de la sumatoria de pesos sinápticos, con lo cual se logra tener una referencia de cómo contribuye cada covariable de forma general a la variable de respuesta; aquellas cuya importancia es negativa, indican una relación principalmente inversa con la ocurrencia de deslizamientos, mientras que la importancia positiva indica una relación directa.



**Figura 6.4: Gráfica de importancia de Olden para el modelo “ANN\_26”.** La importancia absoluta de las covariables está dada por el largo de las barras graficadas

Finalmente, la gráfica de sensibilidad (Figura 6.5) señala que las variables SLOPE y SIN SLOPE son las variables con menor sensibilidad y por ende más robustas del modelo, al conservar una tendencia muy similar en sus curvas, independiente del grado de aporte de los demás factores. No obstante, las covariables restantes también tienen aceptables niveles de sensibilidad (baja), lo que respalda su inclusión en el modelo. Además, es posible notar las mismas relaciones que exhiben indicadores anteriores con respecto a la variación de cada factor con el fenómeno estudiado.



**Figura 6.5:** Gráfica de Sensibilidad de *Lek* para el modelo "ANN\_26". Muestra el comportamiento de cada covariable con respecto a la variable de respuesta en función del porcentaje de distribución de las demás covariables. Las curvas de colores representan grupos conformados por 6 niveles de contribución de las covariables restantes a cada gráfica. Dichos niveles son los cuantiles mínimo, 20%, 40%, 60%, 80% y máximo.

Las gráficas presentadas dan cuenta que todas las variables incorporadas al modelo tienen importancia y robustez como factores que explican la ocurrencia de zonas de arranque de deslizamientos. Así también, cada herramienta de análisis señala el comportamiento de cada covariable con la variable de respuesta, resultados congruentes con la variación esperada para cada uno de acuerdo a lo detallado en la sección 4.1.4, excepto el factor Rugosidad (ROUGH), lo cual será analizado al igual que el descarte de otras variables en el Capítulo 7.



## 6.2.2. ANÁLISIS DEL MODELO DE ALCANCE

En la gráfica *Pairwise Plot* para el modelo seleccionado de Alcance (Figura 6.6), la principales observaciones deben efectuarse, por una parte, sobre la columna del extremo derecho, donde se muestran indicadores numéricos del grado de ajuste que cada covariable tiene con la variable de respuesta (alcance de deslizamientos), de lo cual se extrae que el factor con mayor correlación es la densidad de drenaje (DENDREN); sin embargo, las 5 covariables tienen grados de correlación relevantes que explican la variable de respuesta. Por otro lado, en la fila del extremo inferior se puede ver la relación y variación entre las covariables y el fenómeno evaluado, de forma gráfica; aquí es posible notar el modo de correlación, donde se tiene que las variables DENDREN y TWI evolucionan de forma directa con la ocurrencia de zonas de alcance, mientras que SLOPE lo hace de forma inversa y los factores GRADI y STD\_CURV tienen un comportamiento dual, correlacionándose con valores medios de dichas variables.

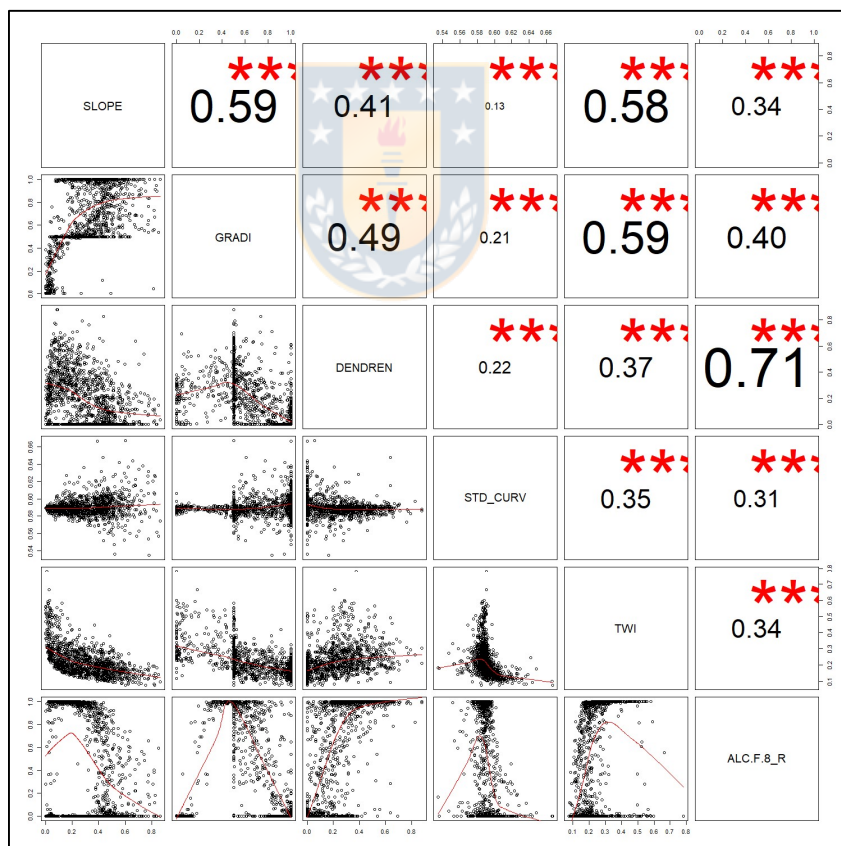
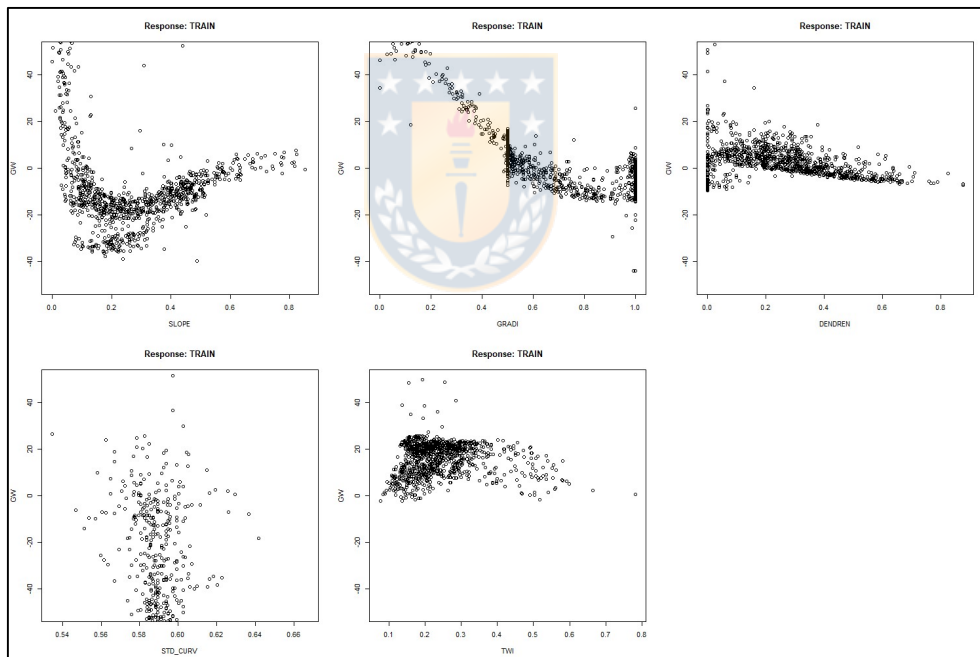


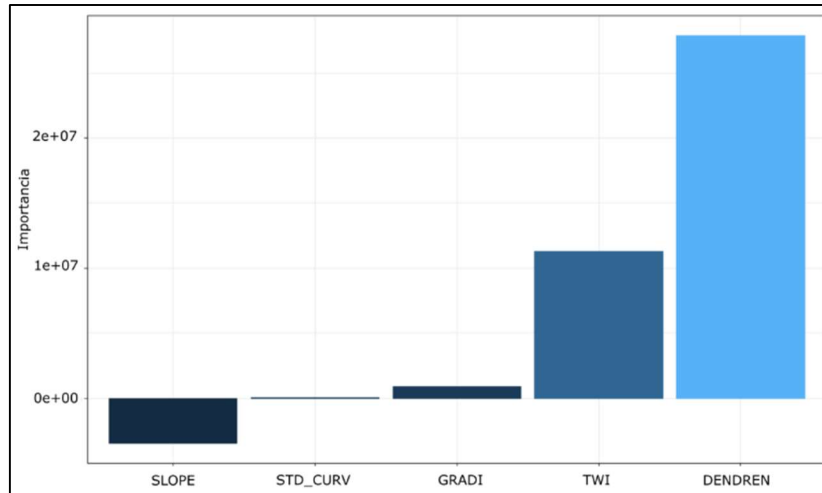
Figura 6.6: *Pairwise Plot* para el modelo “ALC.F.8”. Muestra una relación simple entre todas las variables ingresadas al modelo, y con la variable de respuesta entregada por la red neuronal.

Los pesos generales de este modelo (Figura 6.7) indican que cada una de las covariables cumplen con el requisito de no-linearidad de la red neuronal, ya que ninguna concentra sus pesos en un valor constante. Esto ocurre ya que en modelos previos fue posible detectar aquellas variables que se comportan de manera lineal sin contribuir de forma significativa a la respuesta de la red, y fueron descartadas. De forma adicional es posible notar que los factores que tienen una relación directa con la ocurrencia de deslizamientos (DENDREN, TWI), sus pesos generales son positivos, mientras que aquellos con relación inversa sus pesos se incrementan de forma negativa (SLOPE), lo que indica una contribución a la “no-ocurrencia” del fenómeno en el rango de valores donde sucede esto (valores bajos de la variable). Con respecto a esto último, se puede ver claramente el comportamiento dual del GRADI, que tiene contribución positiva en valores por bajo la media, y contribución negativa sobre ella. STD\_CURV también presenta una cierta dualidad en su peso, ya que sus valores centrales varían entre negativos y positivos.




**Figura 6.7:** Gráfica *General Weights* para el modelo “ALC.F.8”. Se muestran los pesos calculados por la red neuronal para cada una de las variables de entrada.

De acuerdo a la gráfica de Olden (Figura 6.8), la importancia de las variables aumenta en el siguiente orden: DENDREN, TWI, SLOPE, GRADI, y STD\_CURV.



**Figura 6.8: Gráfica de importancia de Olden para el modelo "ALC.F.8".**  
La importancia absoluta de las covariables está dada por el largo de las barras graficadas.

En cuanto al análisis de sensibilidad de Lek para el Alcance (Figura 6.9), se puede observar que DENDREN y SLOPE son las variables con menor sensibilidad y más robustas del modelo, al conservar una tendencia muy similar en sus curvas, independiente del grado de aporte de los demás factores. Sin embargo, las covariables restantes exhiben una sensibilidad (baja) tolerable, lo que respalda su inclusión en el modelo. Además, es posible notar las mismas relaciones vistas en indicadores anteriores con respecto a la variación de cada factor con el fenómeno estudiado.



**Figura 6.9: Gráfica de Sensibilidad de *Lek* para el modelo "ALC.F.8".** Muestra el comportamiento de cada covariable con respecto a la variable de respuesta en función del porcentaje de distribución de las demás covariables. Las curvas de colores representan grupos conformados por 6 niveles de contribución de las covariables restantes a cada gráfica. Dichos niveles son los cuantiles mínimo, 20%, 40%, 60%, 80% y máximo.

Al igual que para el análisis de susceptibilidad de Arranque, las gráficas antes presentadas evidencian que cada una de las variables consideradas en este modelo explican la ocurrencia de zonas de Alcance con relevancia y robustez aceptables. De igual forma, cada herramienta entrega una estimación de la relación que tienen las covariables con el factor evaluado, siendo todas congruentes con la relación esperada de acuerdo al conocimiento geológico/geomorfológico, lo cual se detalla en la sección 4.1.4. Mayores implicancias de estos resultados serán abordadas en el Capítulo 7.


## **6.4. EVALUACIÓN DE APLICABILIDAD DE MODELOS**

Con el objetivo de evaluar los alcances de la utilización de la metodología y resultados obtenidos, se aplican los modelos entrenados de red neuronal en 2 zonas adicionales de Chile, presentadas anteriormente en la sección 4.3.2.5. Los mapas indicativos de amenaza obtenidos en cada zona se presentan a continuación, y las implicancias de cada uno de ellos se discuten en el Capítulo 7.

### **6.4.1. SECTOR EL AMARILLO – LOS TURBIOS, CHAITÉN**

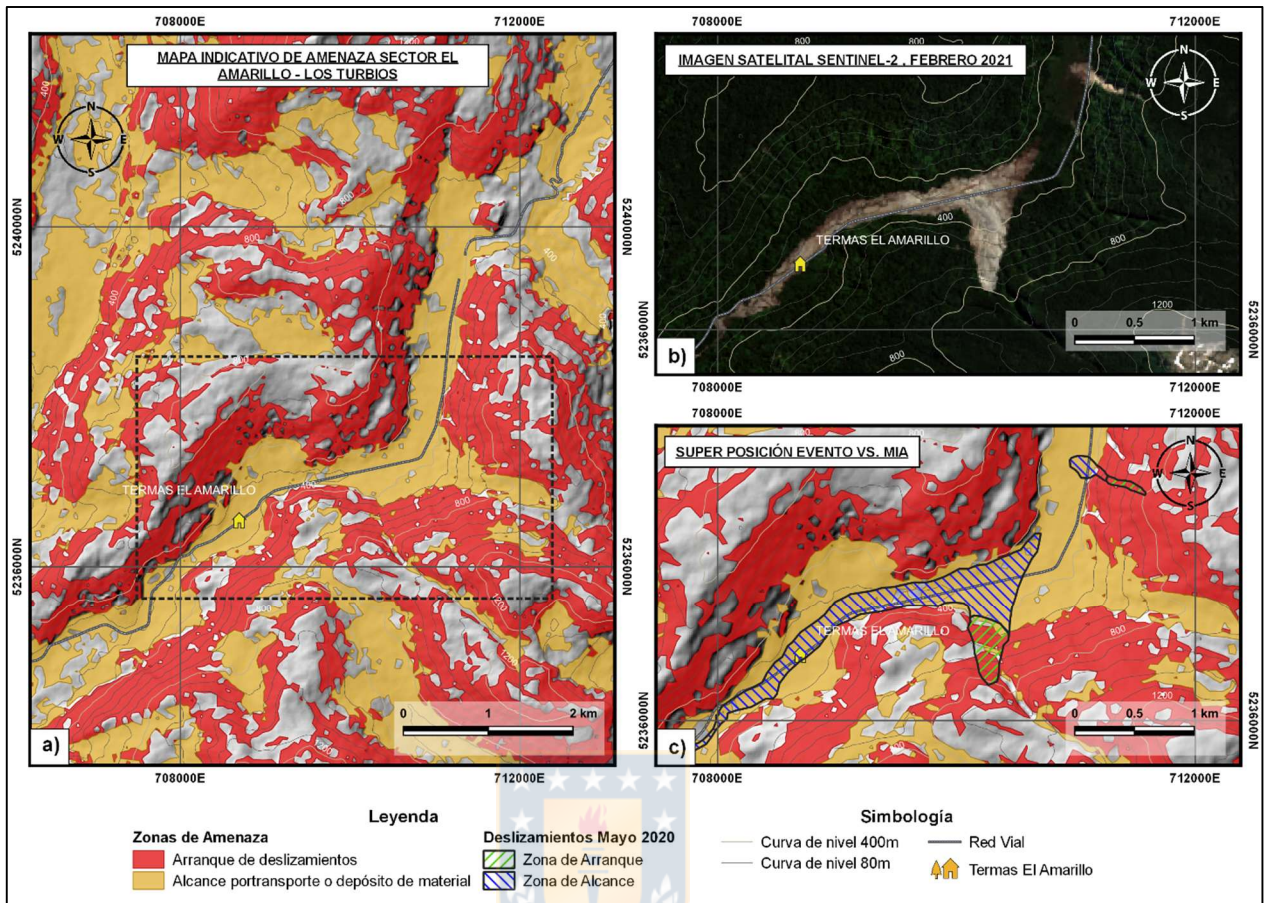
La aplicación de las RNA en esta zona da como resultado un MIA visualmente similar al obtenido en valles menores del área de estudio principal. Este resultado es posible contrastarlo con un gran evento de deslizamiento ocurrido el 15 de Mayo de 2020 en el valle del sector El Amarillo (Figura 6.10), el cual provocó un flujo de barro y detritos que se movilizó por aproximadamente 4Km valle abajo, afectando casi la totalidad de la estrecha planicie, ocasionando la muerte de 1 persona, la destrucción total de las instalaciones de Termas El Amarillo, y el aislamiento de varias familias por la afectación de la conexión vial.





**Figura 6.10: Deslizamiento Valle El Amarillo.** a) Se muestra la zona de arranque con la corona del deslizamiento, la cual se ubica cerca de la cota 800m. b) Se observa el impacto del flujo generado por el deslizamiento en todo el fondo de valle (cota 400m aproximadamente), recorriendo cerca de 4Km en dirección SW; de puede ver además como el camino que se emplaza en el lugar queda totalmente sepultado por la remoción. c) y d) son dibujos esquemáticos que muestran el mapeo interpretativo de las diferentes zonas en evento; en rojo se indica la zona más clara de Arranque, que coincide con el límite estimado por el modelo; en rojo pálido se señala el resto de la zona de Arranque, y en amarillo se delimita toda la zona afectada por el Alcance. Imágenes áreas de sobrevuelo de la Fuerza Aérea de Chile, tomadas de prensa digital.

En la Figura 6.11 se muestra el MIA obtenido para esta zona, en el cual se superpone el mapeo del evento mencionado anteriormente. Este mapa se acompaña de una muestra satelital de la situación más reciente del valle (Febrero 2021), donde es posible apreciar la distribución y dimensiones de este masivo proceso.

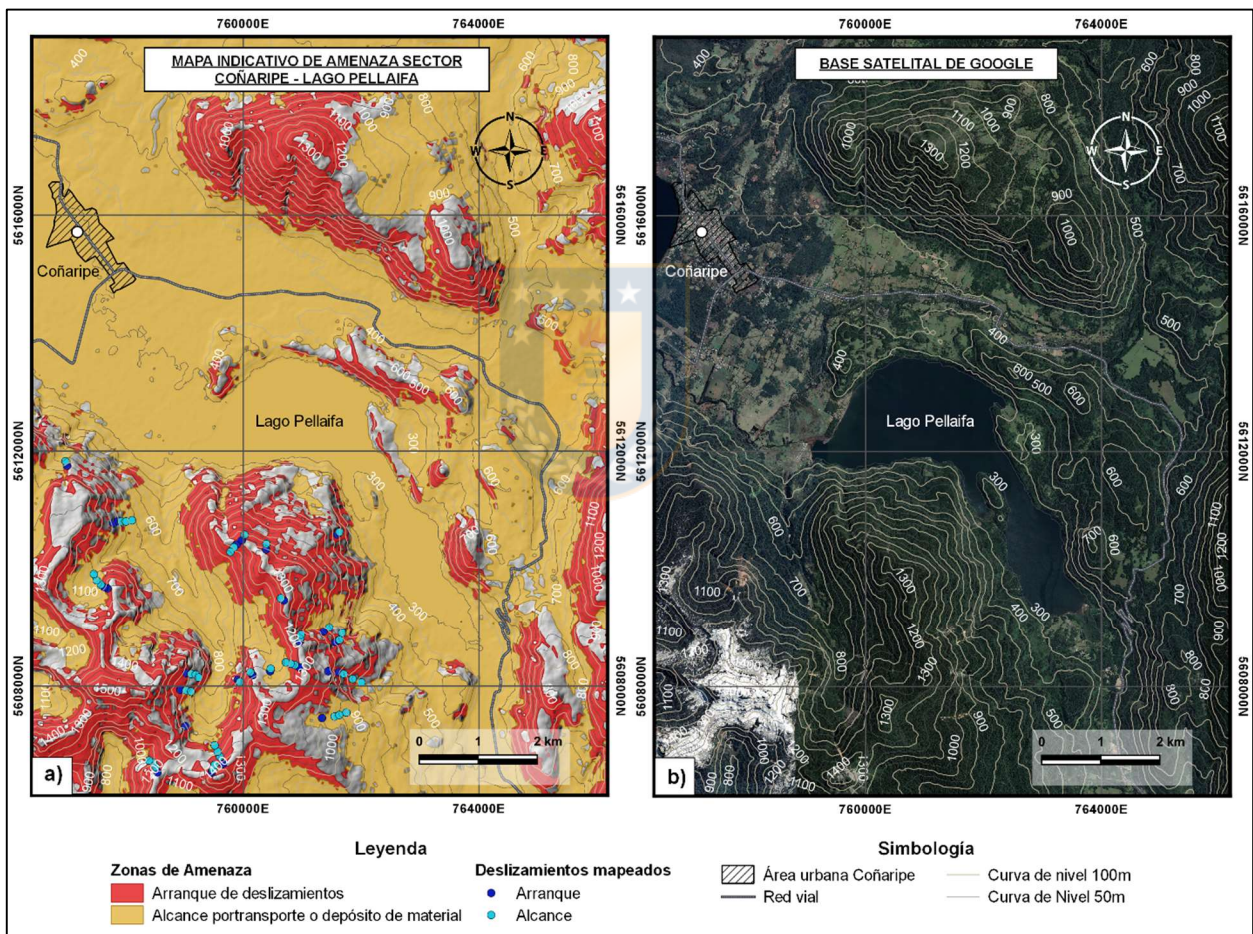


**Figura 6.11: Evaluación de MIA en sector El Amarillo – Los Turbios, Chaitén.** a) Mapa Indicativo de Amenaza obtenido tras la aplicación de los modelos de RNA ya entrenados, en un sector cercano al área de estudio original. En este valle se tiene un registro reciente de un gran deslizamiento ocurrido en Mayo de 2020. El mapa es generado con capas temáticas cuyas fuentes satelitales (DEM e imagen satelital Landsat) datan de los años 2011 y 2013. b) Acercamiento de la remoción principal observada en una imagen Sentinel-2 (Febrero de 2021), desde la cual fueron mapeados 2 eventos de remoción en masa (uno mucho menor al NE). c) Comparación del MIA con los deslizamientos representados con tramas de líneas, donde se indican las correspondientes zonas de Arranque y Alcance, que fueron diferenciadas por observación de imágenes aéreas de la Figura 6.10, utilizando como guía las formas internas y externas de la cicatriz dejada por el deslizamiento (quebradas, caídas de agua, superficie de la remoción).

Lo expuesto anteriormente en la Figura 5.24 respalda el análisis efectuado por las RNA, ya que se puede apreciar un buen ajuste entre la “predicción” del modelo y las remociones registradas, tanto en las zonas de Arranque como las de Alcance. Esto además indica que esta zona tiene un gran potencial para generar deslizamientos de magnitudes importantes, propiciando flujos de gran alcance.

## 6.4.2. SECTOR COÑARIPE – LAGO PELLAIFA, REGIÓN DE LOS RÍOS

La Figura 6.12 muestra el MIA obtenido para esta zona, al cual se superpone un mapeo de puntos de los deslizamientos detectados en la zona. En dicha figura se incluye una vista satelital del área donde es posible distinguir los elementos mapeados. Es posible notar que las zonas de arranque coinciden con todas las zonas con pendiente moderada a abrupta, y no tienen una buena correlación con los eventos mapeado en el área. Por otra parte, las zonas de posible alcance tienen una extensión desmedida que cubre todas las planicies sin perjuicio de su cercanía con las laderas.



**Figura 6.12: Evaluación de MIA en sector Coñaripe – Lago Pellaifa.** a) Mapa Indicativo de Amenaza obtenido tras la aplicación de los modelos de RNA ya entrenados, en un sector lejano al área de estudio original. Se señalan los deslizamientos detectados en la zona, mediante simbología de puntos que representan zonas de Arranque y Alcance, en colores azul y cian, respectivamente. b) Base satelital de Google para la zona de interés.



## 7. DISCUSIÓN

En este capítulo se exponen las principales consideraciones e implicancias que conlleva tanto la utilización del método seleccionado para efectuar el análisis de susceptibilidad, como los resultados del mismo. Así también se estipulan los usos, alcances, limitaciones y posibles mejoras del proceso metodológico aplicado en la presente investigación.

### 7.1. SELECCIÓN DE ÁREA DE ESTUDIO

En el presente estudio, el cual tiene un carácter investigativo para sentar las bases en futuras aplicaciones del método seleccionada,

El carácter investigativo de este estudio hace que la elección de un área de estudio se considere una etapa crucial, ya que debe satisfacer ciertos requisitos como los mencionados en la sección 4.1.1.2, sentando las bases en futuras aplicaciones del método seleccionado

A lo largo de la ejecución del trabajo tanto de gabinete como de terreno, es posible notar ciertas desventajas que conlleva la elección de un área de estudio con las características de la Provincia de Palena. De éstas, se pueden mencionar:


- Poca disponibilidad de información geoespacial previa (información detallada de suelos, vegetación, mapeo geológico, entre otros).
- Muy difícil acceso en terreno por las características geomorfológicas y de vegetación en la zona.
- Dificultad en la toma de datos fotogramétricos aéreos con *drone*, debido a la densa vegetación y a los altos y escarpados relieves.

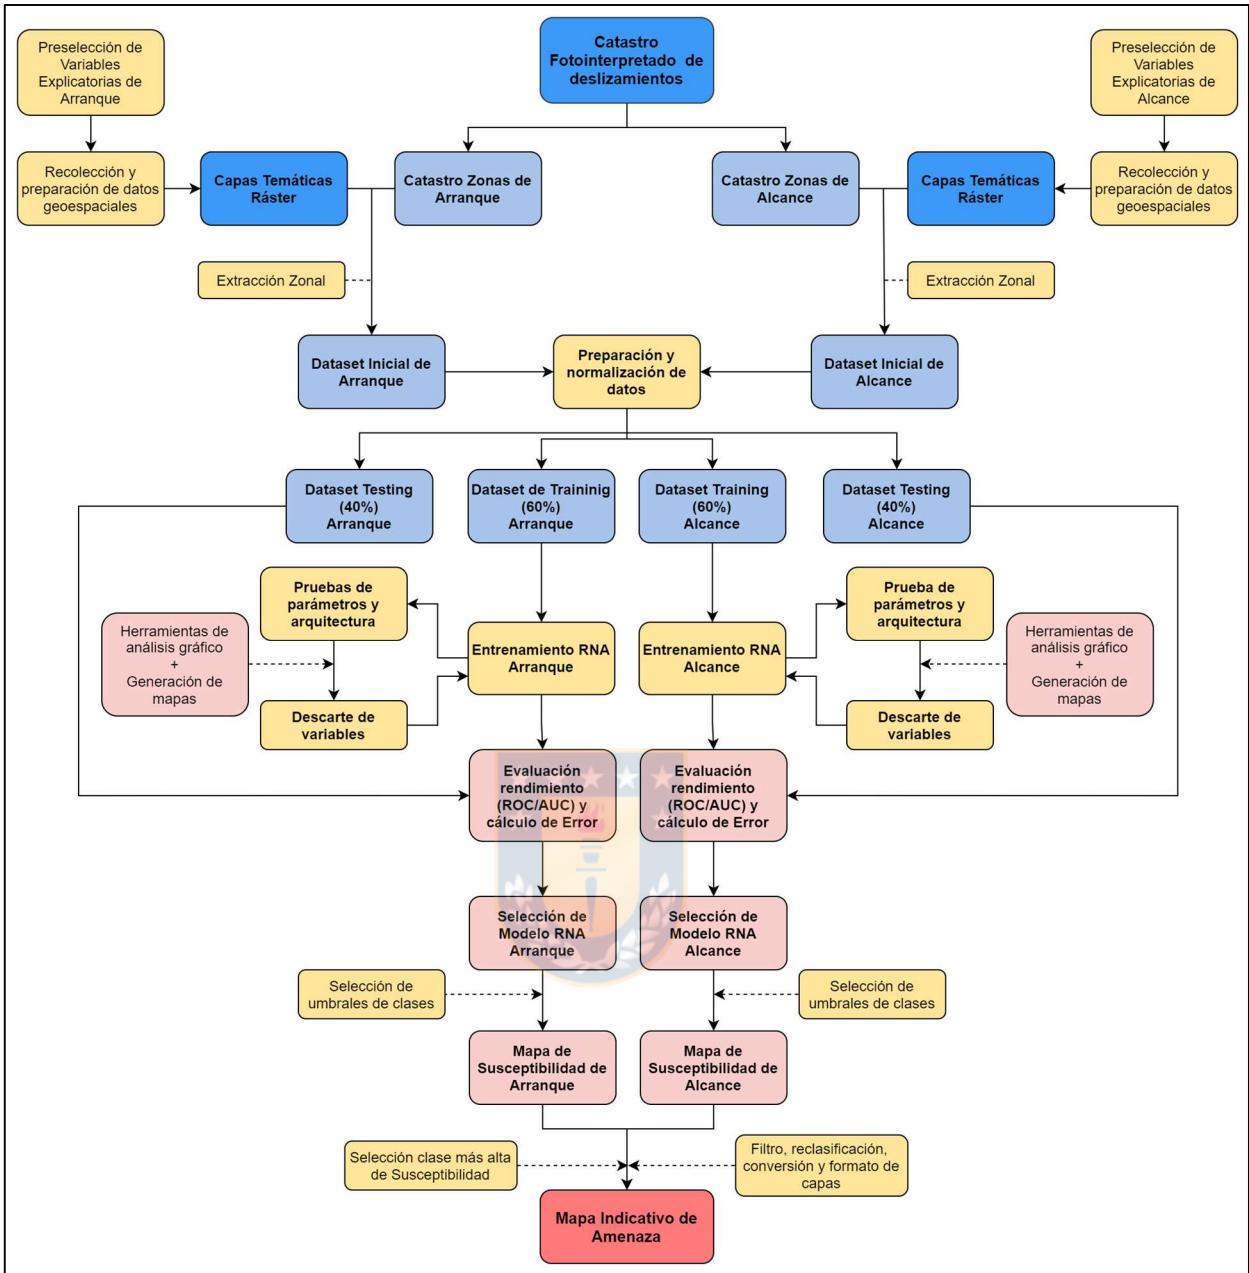
Es necesario tener en cuenta los puntos mencionados anteriormente, ya que para futuros trabajos que requieran mayor detalle se hará necesario contar con preparación técnica de alto nivel para llevar a cabo visitas a terreno que logren una cobertura de los puntos de interés. Así también, se debe considerar que para la obtención de datos fotogramétricos de calidad se ha de contar con herramientas de medición más avanzadas, como sensores LIDAR, los cuales son capaces de detectar y limpiar de vegetación los modelos de elevación digital y así, obtener modelos de terreno digital (DTM), recurso idóneo para el análisis de la superficie terrestre en este y otros tipos de estudio.

Pese a las desventajas mencionadas, el área de estudio seleccionada se impone como un lugar idóneo para el análisis remoto de procesos de ladera con origen natural, ya que existe un amplio registro de eventos que permite confeccionar un inventario robusto para la obtención de información a partir de la superficie. Sumado esto, dicho registro concentra un gran número de eventos de enormes dimensiones, como en ningún otro sector del territorio chileno, lo cual permite una excelente detección y caracterización mediante sensores satelitales; información libre, pública y gratuita, que permite disminuir los costos y tiempo necesarios para efectuar el estudio. Por otra parte, es preciso recalcar que la zona de Chaitén provee muy buenos objetos de estudio al presentar remociones en masa de origen totalmente natural, tanto en sus factores condicionantes como los gatillantes, lo que la convierte en un laboratorio natural para la comprensión y análisis de procesos de ladera, sin intervención humana que infrinja inestabilidades geotécnicas en ellos.

## **7.2. ANÁLISIS CON REDES NEURONALES ARTIFICIALES**

Antes de exponer las diferentes observaciones en cuanto al procedimiento metodológico llevado a cabo para la obtención de un Mapa Indicativo de Amenaza (MIA) con Redes Neuronales Artificiales (RNA), en la Figura 7.1 se presenta una recapitulación esquemática de éste, mediante un diagrama de flujo.





**Figura 7.1: Diagrama de flujo del proceso metodológico implementado.** Resumen esquemático simple del proceso metodológico llevado a cabo para la confección de un Mapa indicativo de Amenaza (MIA) mediante análisis con Redes Neuronales Artificiales. En tonos azules se señalan los datos sobre los cuales se cimienta el estudio, resaltando en azul más fuerte aquellos datos que componen la base inicial de éstos (*raw data*). En rojo se indican elementos considerados como resultados del análisis, resaltando el resultado central correspondiente al MIA. Y en amarillo se señalan las acciones y procesos que se aplican sobre los datos y resultados.

En primera instancia, es clave el mecanismo de muestreo del terreno para la confección del catastro o inventario necesario para el entrenamiento de RNA. Existen diversos criterios, tales como:

- **Basado en polígonos:** mapeo directo de las zonas afectadas, o subdivisión del terreno en unidades con características similares, como podrían ser microcuencas o porciones de laderas con características en común (pendiente, orientación, rugosidad, entre otros) (Prakash *et al.*, 2020)
- **Basado en puntos:** centroides de polígonos de mapeo de remociones, o mapeo con una malla regular de puntos sobre el área de estudio (Prashka *et al.* 2020), o bien, un mapeo aleatorio de puntos sobre las zonas afectadas (Althuwaynee *et al.*, 2014)
- **Basado en píxeles:** basado en el mapeo poligonal, realiza cálculos de concentración o densidad de remociones en un área de acuerdo a la cantidad de píxeles contenido en las zonas mapeadas (Van Westen, 1993).

Dadas las diversas posibilidades de muestreo, se debe considerar que cada una tiene ciertas ventajas y desventajas. El muestreo por polígonos, si bien resulta un cómodo interpretador visual, reduce significativamente la cantidad de datos a ingresar al inventario, pues cada polígono representa solo 1 dato de entrada. Por otra parte, el mapeo por puntos permite extraer una gran cantidad de información con detalle del terreno, sin embargo, no es capaz de extraer relaciones geométricas o de contexto en cada evento. Y finalmente, el método basado en píxeles si bien resulta más preciso y también permite extraer gran número de información, implica mayor procesamiento previo, aumentando los tiempos del análisis.

Del mismo modo, se debe tener en cuenta el tipo de análisis que se desea llevar a cabo, y la escala del mismo, puesto que cada criterio de muestreo puede entregar mayor o menor utilidad de acuerdo a las condiciones y objetivos del estudio. Para este caso particular, se optó por un muestreo de tipo punto aleatorio sobre las zonas afectadas por deslizamientos, ya que proporciona una cantidad importante de datos para el entrenamiento de redes neuronales, y a la vez es una técnica que no demanda excesivo tiempo de procesamiento previo.

En cuanto a la relación del mapeo o muestreo de remociones y la escala de trabajo, pese a que el mapa final se presenta en escala 1:80.000, el inventario se confecciona a múltiples escalas, ya que el objetivo principal del catastro es proveer de la mayor información posible a las RNA, las cuales al efectuar el análisis final pixel a pixel, no tienen incorporada una referencia de la escala de mapeo.

Otra observación con respecto al catastro base de este estudio, es referente al número de observaciones que lo conforman. La literatura se recomienda una base de datos de *training* que

contenga más de  $30 \cdot N \cdot (N+1)$  elementos (Kavzoglu, 2001; Yesilnacar & Topal, 2005; Yilmaz, 2008), donde N es el número de neuronas de entrada, vale decir, el número de factores condicionantes considerados en cada modelo. En el presente estudio se utilizan 2 bases de datos para evaluar Arranque y Alcance, con 1.572 y 2.090 elementos, respectivamente. De cada una se utiliza el 60% para *training* (revisar sección 4.3.1.2), lo que significa un total de 943 y 1254 observaciones disponibles para Arranque y Alcance. Considerando que los modelos finales seleccionados en cada caso se conforman por 5 neuronas de entrada cada uno, el valor mínimo de registros para el *training* debe ser igual a 900; por tanto, ambos análisis se sustentan con una base de datos robusta y suficiente.

Con respecto a la cantidad de variables explicatorias a considerar para cada análisis con RNA, si bien, de acuerdo al tamaño de las bases de datos disponible, el número de *inputs* debe ser igual a 5. Sin embargo, las RNA son utilizadas también como una herramienta discriminadora, por lo cual es recomendable comenzar las iteraciones o pruebas de modelos con una cantidad de variables en exceso, y así la red neuronal puede señalar aquellas variables que no tengan suficiente correlación o importancia con la variable de respuesta, y de esta forma descartar variables hasta llegar al número ideal con los factores condicionantes más significativos.

En la etapa de preparación de los *datasets* previo a su ingreso a las RNA, es pertinente dejar en claro la forma en que se normalizan (o se escalan) los datos. Tal como se indica en la sección 4.3.1.3, los datos se escalan de acuerdo a una normalización “Min-Max”. Esta fórmula es dependiente de los valores máximos y mínimos de cada variable. Sin embargo, la definición de estos límites no es trivial; existen dos opciones. Por una parte, los límites mínimo y máximo pueden estar definidos por la distribución de datos del *dataset* inicial para cada caso (Arranque y Alcance), o bien, pueden ser los límites del rango de las capas ráster desde donde se extrae la información para cada *dataset*. Para el presente estudio se opta por la segunda opción, dado que el catastro no abarca los valores máximos y mínimos de las capas temáticas, y al computar la red neuronal con dicha información ráster que cubre toda el área, se generará una distorsión en los valores; por ejemplo, al entrenar una RNA con normalización basada en los *datasets*, el valor máximo de la variable SLOPE probablemente alcance un valor máximo  $70^\circ$ , lo cual será equivalente a 1, pero luego, al evaluar la red neuronal con el ráster normalizado, el valor 1 equivaldrá a  $SLOPE = 85^\circ$ , ya que la capa ráster cubre un mayor rango de valores. Por tanto, con el fin de mantener valores homogéneos, la normalización tanto de los *datasets*, como de las capas ráster se hace en función de los máximos y mínimos de éstas últimas.

Otro punto que amerita discusión, se centra en el entrenamiento de las RNA. Esta etapa sin duda es la que demanda mayor tiempo de trabajo, puesto que es una evaluación repetitiva; es decir, consta de numerosas iteraciones, las cuales pueden extenderse indefinidamente. Por tal razón es necesario tener establecido un tiempo límite máximo para llevar a cabo esta etapa, y el número de iteraciones luego dependerá de la complejidad y extensión de la información procesada por las RNA; es decir, cada *dataset* tiene un tiempo de computación diferente. Por otra parte, aquí se refleja la característica de “aprendizaje supervisado”, es decir, si bien las RNA tienen la capacidad de lograr aprender y configurarse por sí solas, los resultados de cada iteración deben ser supervisados por el profesional a cargo, con el fin de evaluar y calibrar la configuración de las RNA, y definir el descarte y/o selección de variables de entrada. Esto último está ligado y depende del buen uso e interpretación de las herramientas de análisis disponibles para el paquete específico de RNA. En el mismo sentido, el profesional además debe controlar el correcto ingreso de las variables a la RNA, procurando mantener siempre el mismo orden con el cual se entrena cada modelo, ya que al sufrir modificaciones el ingreso de los datos, puede generar resultados no reproducibles y/o incongruentes con la realidad.

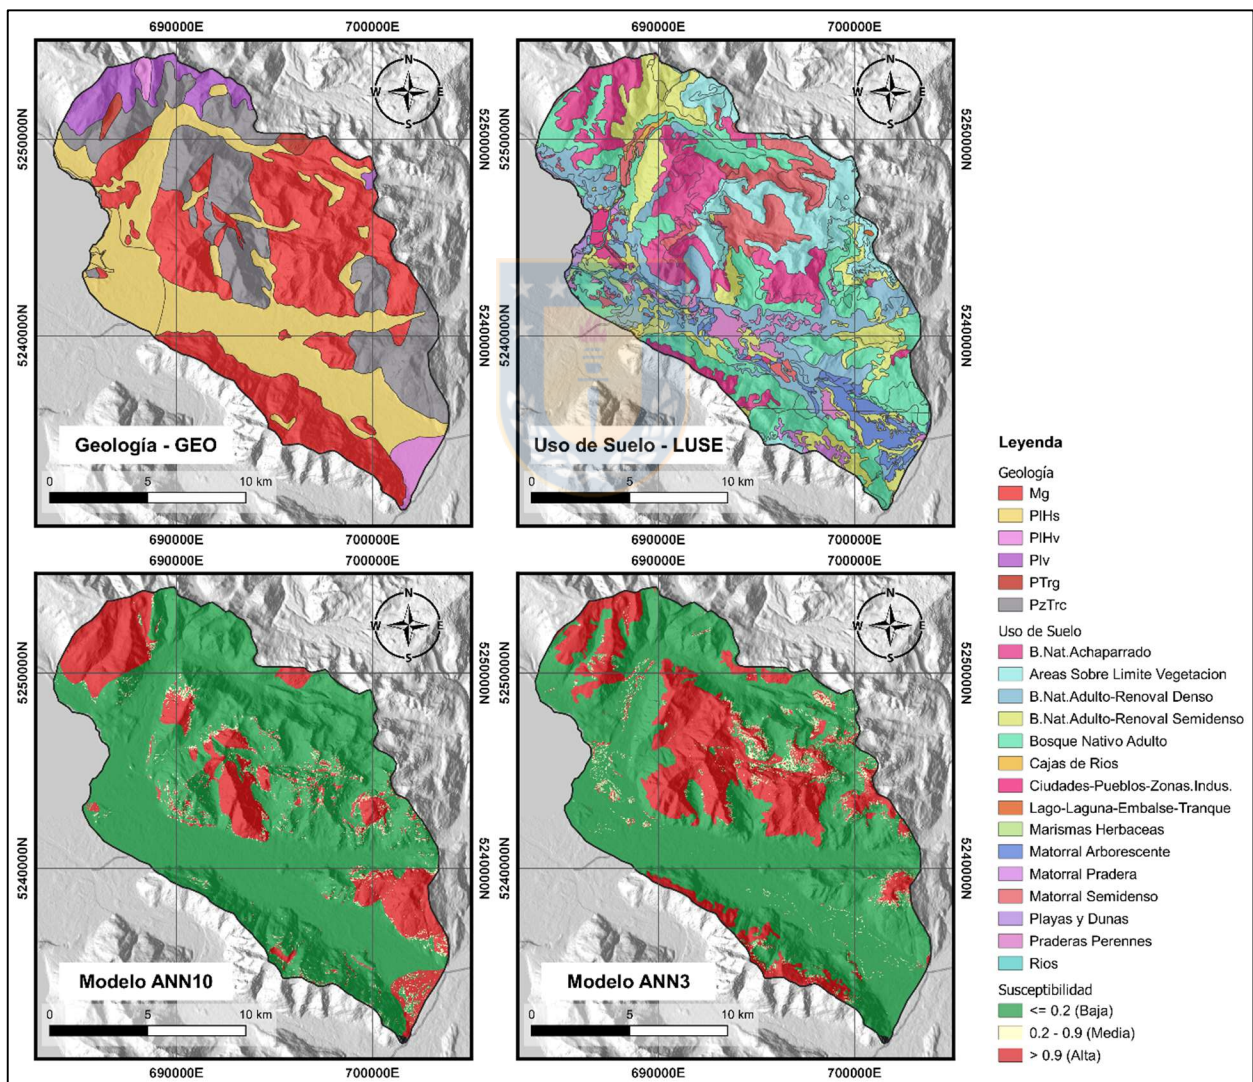
En línea con lo anterior, el presente estudio, al significar una incursión de nivel principiante en el ámbito de las redes neuronales, la inversión de tiempo en la etapa de entrenamiento es mucho mayor; el ensayo y error obligan a extender los diferentes procesos. Sin embargo, la experiencia y la constancia pueden disminuir este problema al mínimo en futuros estudios.

## 7.3. DISCUSIÓN DE RESULTADOS

### 7.3.1. DESCARTE DE VARIABLES DE ARRANQUE

De las 11 variables consideradas en primera instancia, las de tipo categórica, Geología y Uso de Suelo fueron las primeras desestimadas en el análisis de redes neuronales. Por una parte, se debe considerar que la inclusión de variables categóricas incrementa considerablemente el número de variables de entrada que son ingresadas a las RNA; esto debido a que cada categoría dentro de la variable debe ser tratada como una nueva variable de comportamiento binario (0 o 1), por lo cual, la cantidad de neuronas de entrada se distancia demasiado del número ideal de *inputs* ideales de acuerdo a la cantidad de datos disponibles en los *datasets* de *training*. Por otro lado, está la naturaleza del mapeo de cada una de estas variables. La geología, o litología, disponible para esta zona es un mapeo a escala 1:250.000, es decir, cuenta con poco detalle y pocas unidades, además se debe considerar que un mapeo de esa

escala en una zona de tan difícil acceso y escasos afloramientos, sólo es un mapeo referencial que puede presentar bastantes imprecisiones. Todo esto se refleja en grandes polígonos sobre el área de estudio que, al ser incluidos en la RNA, el mapa resultante evidencia un claro sesgo sobre unidades completas, lo cual es poco realista (Figura 7.2). Esto también ocurre con las categorías que abarcan mayor área en la variable Uso de Suelo, capa temática que, si bien aparenta tener un mayor grado de detalle en el mapeo realizado, la asertividad de éste no es la mejor, dado que al realizar algunos chequeos visuales de los polígonos trazados comparados con las imágenes satelitales disponibles, es posible detectar incongruencias en el mapeo, lo que finalmente provoca una pérdida de significancia del material disponible.

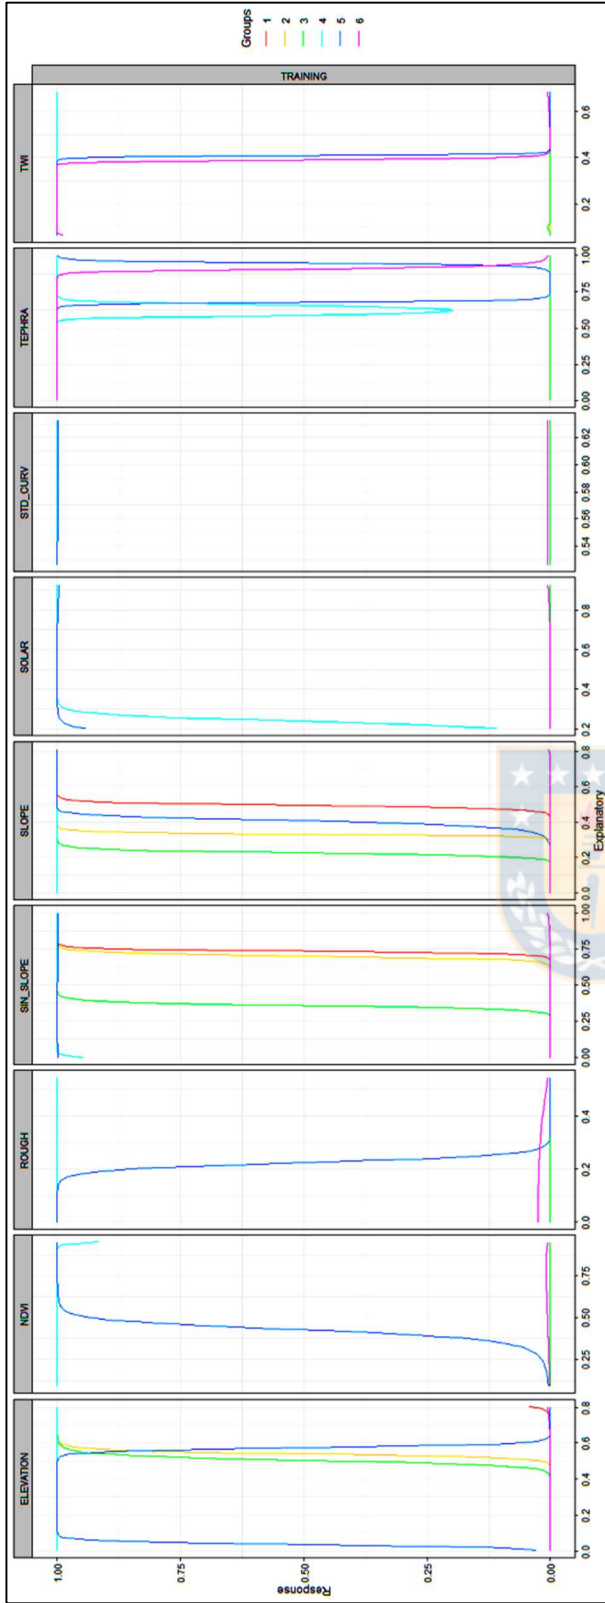


**Figura 7.2: Comparación geoespacial entre variables categóricas y modelos descartados de RNA.** Los mapas superiores muestran el mapeo de la Geología y el Uso de Suelo, y respectivamente bajo cada uno de ellos se muestra la sobre estimación de susceptibilidad provocada por algunas categorías. Se puede notar que la predicción de los modelos puede llegar ser delimitada con gran exactitud por los polígonos de dichas categorías, lo que genera resultados carentes de sentido.

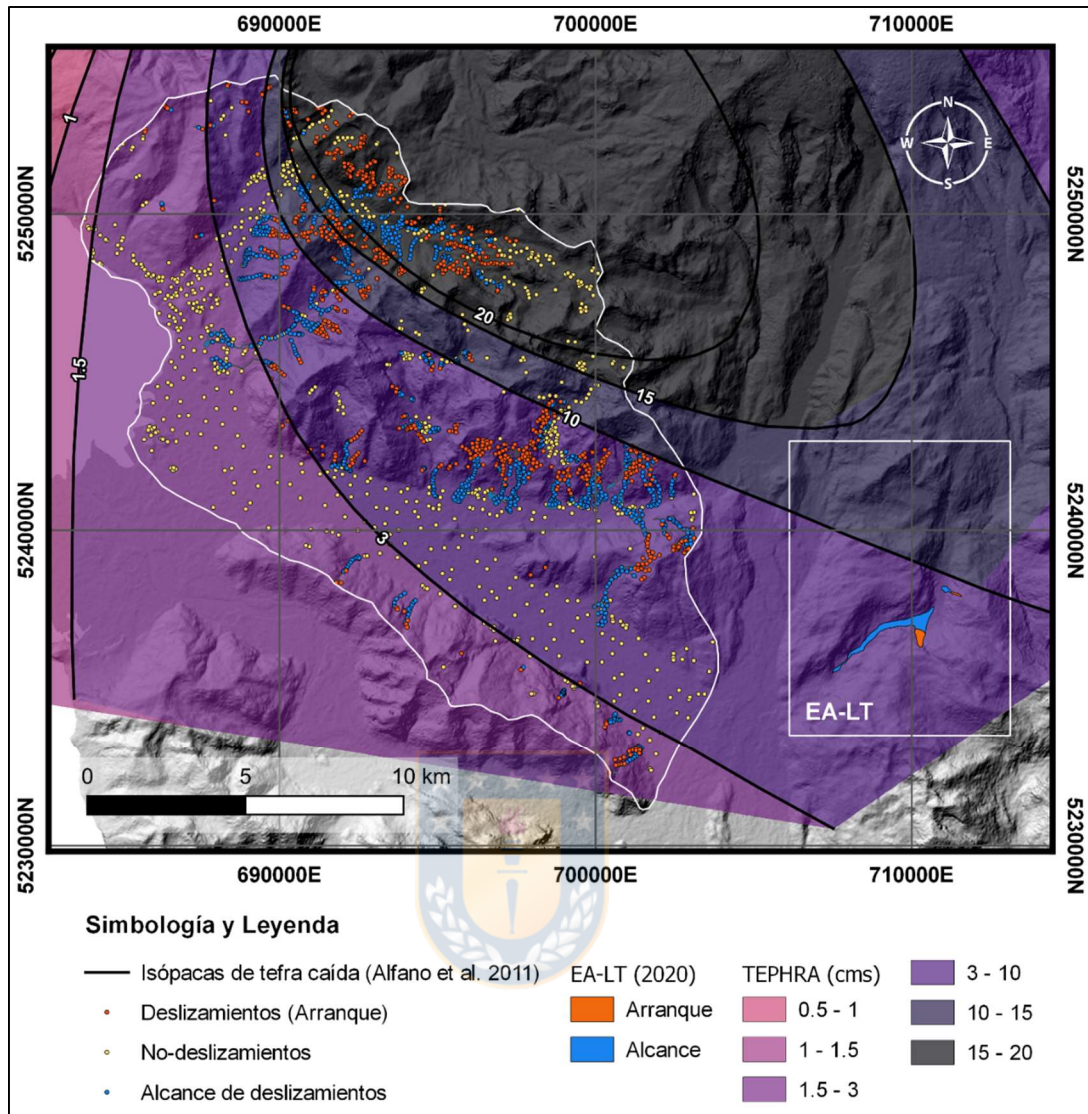
Otro factor condicionante cuya desestimación puede generar discusión, es el Aspecto u Orientación de Laderas. La representación geoespacial de esta característica, en su origen, es un ráster cuyos valores de pixel tienen una distribución continua, sin embargo, pueden ser categorizados por rangos o tramos de orientación (azimut). Si bien, en principio, para este trabajo se considera el efectuar dicha categorización, en vista de la gran cantidad inicial de variables a ingresar al modelo, luego se opta por incluirla como una variable continua, puesto que un exceso de variables de entrada puede conllevar a un pobre desempeño predictivo de la RNA considerando la insuficiente cantidad de datos de entrenamiento. Por lo demás, de existir algún patrón regular relacionado a la ocurrencia o no-ocurrencia de deslizamientos, la RNA ha de ser capaz de detectarlo con la variable en su forma no categorizada. Establecido esto, la variable es ingresada a la red, sin embargo, las diferentes configuraciones en los modelos iniciales de RNA indican que ésta característica no tiene una relación significativa con la ocurrencia de los deslizamientos del tipo analizado en esta zona geográfica específica. Esto además fue chequeado visualmente comparando la distribución de los puntos de catastro con el mapa de la variable. Por esta razón, el atributo de Aspecto (ASPE) de laderas se desestima como factor condicionante para el proceso de Arranque de deslizamientos.

En cuanto a la participación de la variable TEPHRA, que corresponde al depósito de tefra de la erupción del volcán Chaitén 2008 – 2009, en un inicio se cree que puede existir una fuerte relación entre ésta característica y la ocurrencia de zonas inestables que generan deslizamientos, por lo explicado en la sección 5.1.2. No obstante, una vez ingresada al modelo de RNA, los algoritmos implementados no evidencian una marcada relación entre ambos fenómenos, siendo muy sensible a la presencia de otras covariables (Figura 7.3). Si bien la relación espacial presentada en la Figura 7.4 entre la distribución de tefra y la ocurrencia de deslizamientos, es notoria; también es posible apreciar una gran cantidad de puntos de No-deslizamiento dentro del mismo rango de espesor de tefra que coincide con eventos positivos. Por tanto, es posible pensar que la forma en que esta variable afecta el proceso estudiado es más compleja. A esto se añade el hecho de que sobre los 15cm de tefra ocurren otros procesos superficiales ligados a la actividad volcánica propiamente tal (sepultación y quema de vegetación, entre otros), por lo que parte de la devastación identificada en dichas zonas no se incluye en el catastro.





**Figura 7.3: Lek Profile Modelo ANN\_1 que ilustra la sensibilidad de la variable TEPHRA.** Se puede observar que las curvas de la variable TEPHRA son cambiantes y poco interpretables, lo que significa que es sensible ante la presencia de otras variables, es decir que puede estar ligada o ser dependiente de alguna de ellas



**Figura 7.4: Espesor de tefra del Volcán Chaitén (2008-2009) contrastado con el catastro de Arranque de deslizamientos.** Se muestran las isópacas de tefra caída según Alfano et al. (2011), junto con el ráster resultante de la interpolación de dichas curvas. El área de estudio y zonas aledañas como el sector El Amarillo – Los Turbios (EA-LT), se ven afectadas por espesores de tefra entre 1.5 y 20 cms. Superpone el catastro binario de Arranque de deslizamientos en el área de estudio, a lo que se añade el mapeo de los dos eventos registrados para la zona EA-LT. Las zonas de arranque se ubican en un rango tefra entre 3 y 10 cms de espesor, incluyendo el evento más grande registrado en la zona, en el sector EA-LT. También se superponen los puntos de No-deslizamientos para indicar que la relación de esta variable con la ocurrencia de deslizamientos es más compleja, dependiendo de otras condiciones, como la geomorfología y la vegetación.

Lo anterior hace referencia a que la variable TEPHRA pese a tener una relación justificada geológica y ecológicamente con la generación de deslizamientos, la forma en que condiciona el terreno no es ni directa ni inversamente proporcional a la distribución del espesor de ceniza. Esto puede ser explicado por la dependencia de este factor con otras características como lo son la pendiente, el tipo de vegetación y cobertura de suelo. Es decir, si bien existe una

incidencia clave del espesor de tefra, esta reside en la forma en que ésta afecta a la vegetación, la cual puede presentar diferentes grados de resistencia ya sea por las especies o la distribución de éstas. Además, tal como se puede apreciar en la Figura 7.4, la zona real de afectación está constreñida a las altas pendientes y no sigue de manera directa la distribución de tefra estimada por Alfano *et al.* (2011). Por tanto, se determina que la influencia de caída de tefra es posible representarla con el factor NDVI, el cual no solo entrega una referencia útil del tipo de cobertura de suelo, sino que además refleja de forma más precisa y cuantitativa el grado de afectación de la vegetación ante la presencia de ceniza de la erupción del Volcán Chaitén, lo cual finalmente sería uno de los factores críticos que propician la inestabilidad de las laderas, observada desde el año 2013 hasta la fecha.

Por último, es necesario comentar el resultado obtenido con respecto al modo de influencia de la Rugosidad del terreno (ROUGH), variable que, según lo estipulado en la sección 4.1.4 es esperable una relación directa con la ocurrencia de deslizamientos, es decir, es esperable que, a mayor rugosidad, el terreno se más susceptible a generar este tipo de remociones. Sin embargo, las herramientas de análisis de RNA señalan una relación más bien inversa de esta variable con el proceso estudiado. Esto podría explicarse por el tipo específico de deslizamiento estudiado, el cual corresponde a deslizamientos traslacionales planares, de suelo y vegetación. Esta condición incide en que las zonas de más altas rugosidades no tienen desarrollo de suelo, predominando el afloramiento del macizo rocoso. Y se puede entender que mucha de la bibliografía utilizada y que hace referencia a la variable de rugosidad, estudian remociones en masa en un sentido un poco más amplio (en literatura de habla inglesa el término *landslide* por lo general hace referencia a “movimientos en masa”, sin especificación), abarcando otros tipos de deslizamiento, como lo son aquellos de tipo más profundo que se producen en el macizo rocoso.

### **7.3.2. VARIABLES GEOLÓGICAS EXCLUIDAS DEL ESTUDIO**

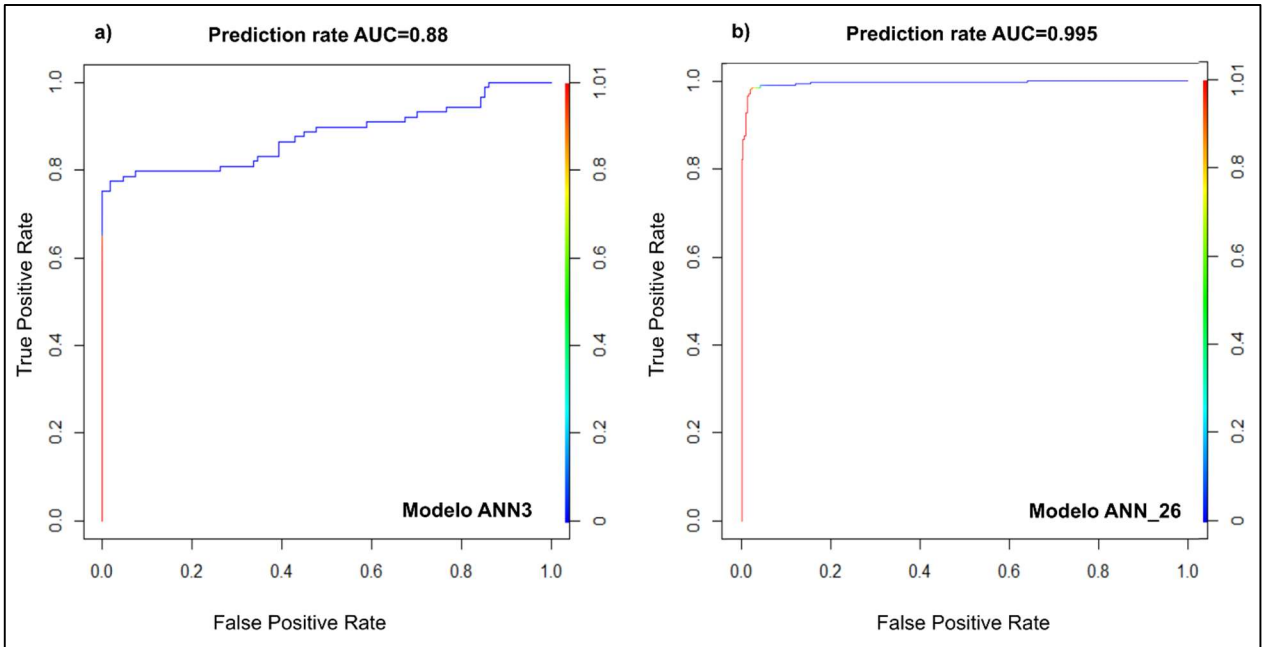
Tal como se menciona en la sección anterior, la preselección de factores condicionantes fue realizada en función del tipo específico de remoción estudiada y la disponibilidad de información para la zona de estudio. No obstante, dada las características geológicas del área de estudio, situada en un contexto estructural especial, dominado por la presencia del Sistema de Fallas Liquiñe-Ofqui (SFLO), es necesario hacer mención de la exclusión del componente geológico-estructural en este estudio.

Si bien, diversos estudios incluyen el factor estructural como una medida de “distancia a la falla”, realizando *buffers* sobre el trazado del mapeo estructural, para el área de estudio no se cuenta con un mapeo estructural de detalle que haga significativa su inclusión en el análisis; el trabajo disponible con enfoque estructural para la zona, es el de Molina (2019), sin embargo, las estructuras trazadas para el área de estudio son de gran escala, marcadas en los principales valles, donde no hay ocurrencia de deslizamientos. Por otra parte, dado el tipo de deslizamientos estudiado, se cree que la exclusión de esta característica no repercute de forma significativa en la estimación de susceptibilidad, ya que los procesos estudiados tienen un control principalmente superficial; geomorfológico y ambiental.

De la misma forma, el descarte de la variable litológica se justifica no sólo por el bajo desempeño de la RNA, sino también por constituir una variable relativamente constante en esta zona específica, dado que las condiciones de resistencia y meteorización del macizo rocoso es bastante uniforme en toda la zona visitada en terreno. Por tanto, se considera aceptable la exclusión de este factor ya que no aporta variabilidad al modelo.

### 7.3.3. RENDIMIENTO DEL MODELO DE ARRANQUE

Es necesario dejar en claro que la medida del rendimiento de modelo ROC/AUC es una herramienta que debe ser utilizada con estricta supervisión y discreción. Esto es porque en la práctica, se observa que incluso modelos que exhiben muy malos resultados, como el modelo ANN3 (Figura 7.5a), tienen valores aceptables de AUC en la curva ROC. Esto puede ser efecto de un problema común en el entrenamiento de RNA, el “*overfitting*” o “*overlearning*” (sobre-ajuste o sobre-aprendizaje); situación en la cual, de acuerdo a lo explicado por Ermini *et al.* (2005), “si una red se ajusta bien a la base de datos utilizada para su entrenamiento, no significa que sea capaz de modelar correctamente el proceso investigado porque su función no es ajustarse a los datos observados sino modelar un proceso generalizando la experiencia aprendida a otros casos no representados en la base de datos de entrenamiento”. Por lo tanto, la validez de este parámetro se hace efectiva una vez que se tiene la certeza que el modelo interpreta de forma correcta las variables de entrada, mediante el control de la red con las demás herramientas de análisis disponible explicadas con detalle en la sección 3.3.6.2.



**Figura 7.5: Comparación de gráficas ROC/AUC entre un modelo de RNA deficiente (ANN3) y el modelo final seleccionado (ANN\_26).**

Por otra parte, resulta llamativo el tan alto rendimiento obtenido con el modelo ANN\_26, ya que la gráfica ROC/AUC (Figura 7.5b) muestra una medida de separabilidad casi perfecta. Si bien esto podría ser un indicador que genere desconfianza en el modelo, al considerar que incluso modelos deficientes evaluados en este estudio han presentado valores de AUC aceptables, es esperable que modelos con mejores resultados como el seleccionado tengan valores aún más altos. Por lo demás, se piensa que estos altos valores se pueden deber a la distribución de los puntos del catastro de entrenamiento, los cuales se posicionan en zonas bastante opuestas y delimitadas (0 en valles y 1 en zonas altas de laderas), lo que significa una base de datos más fácilmente interpretable por la RNA. Esto también se refleja en corto tiempo de computación de cada modelo, el cual en promedio tarda un par de minutos solamente; a diferencia de lo que ocurre con la modelación en el análisis de Alcance.

En cuanto al error calculado a partir del desempeño en el mapa resultante de la RNA seleccionada, el cual es muy bajo (3.2%), calculado

El bajo error calculado (3.2%) para el mapa de Arranque (sección 5.2) significa una capacidad de predicción o de acierto iguala 96.8%, cifra que puede parecer poco creíble para un modelo de regresión, sin embargo, existen otros trabajos que han documentado predicciones igualmente altas, de 94% (Pradhan & Lee, 2009) o 95% (Tien Bui *et al.*, 2015) utilizando RNA

para análisis de susceptibilidad de remociones en masa. Por lo demás, se debe tener en cuenta que el procesamiento y resultados con programas de *machine learning* siempre dependerá de las características de las bases de datos ingresadas a los modelos, y en el caso de aplicación en problemas ligados a la geología, también dependerán del proceso específico evaluado y las características geológicas consideradas.

#### **7.3.4. PROCESAMIENTO DE LAS RNA PARA ALCANCE**

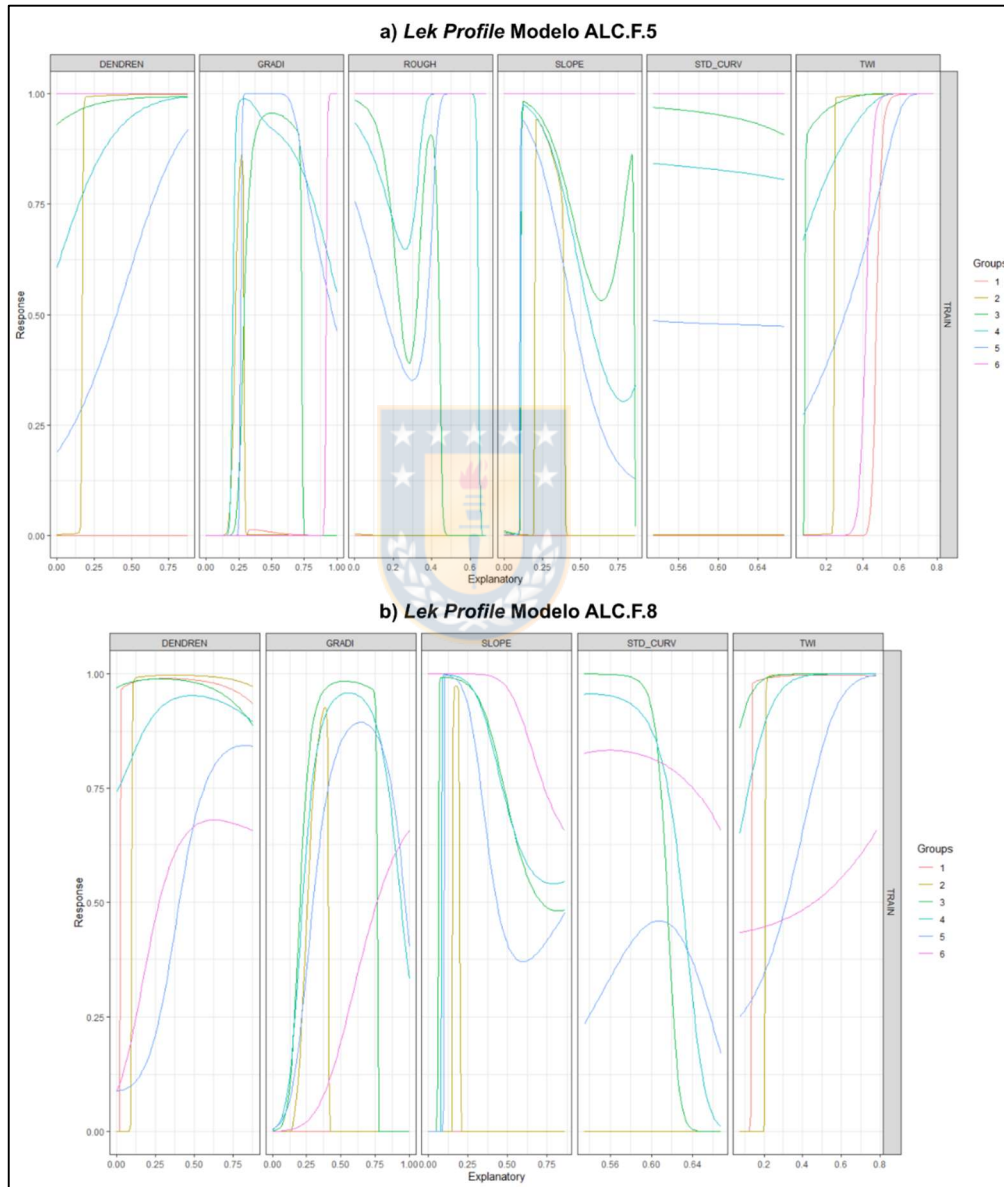
Tal como ha sido mencionado anteriormente, el modo y tiempo de procesamiento de los datos ingresados a programas de *machine learning*, está sujeto en su totalidad a la naturaleza de dichos datos. Prueba de ello, es lo experimentado en este estudio, ya que al llevar a cabo dos tipos análisis, es posible notar y contrastar cómo varía la ejecución de cada uno de ellos. En el caso del análisis de Alcance de deslizamientos se observa un gran requerimiento de tiempo computacional a la hora de ejecutar la función de entrenamiento de red neuronal. Esto se debe tanto a la cantidad de datos, moderadamente mayor que los utilizados en el análisis de Arranque, pero principalmente se debe a la distribución de los datos de catastro, los cuales conforman una base de datos numéricamente mucho más heterogénea y variada, lo que finalmente se traduce mayores tiempos de aprendizaje de las RNA, ya que al ingresar un set de datos más complejo, el traspaso y ajuste interno de la red para reducir el error, es también más complejo, traduciéndose en mayores tiempos de computación.

#### **7.3.5. SELECCIÓN DE VARIABLES PARA EL ANÁLISIS DE ALCANCE**

Es preciso dejar en claro que, al tratarse de un análisis cuyo objeto de estudio no tiene referencia bibliográfica previa en cuanto al uso del método de RNA, la selección de las variables para el análisis de susceptibilidad de Alcance, se realiza netamente en base al criterio y conocimiento geológico de la autora. En base a esto, se decide dar especial participación a factores de tipo geomorfológico e hidrológico, dado que el proceso estudiado tiene características de flujo, estrechamente ligadas a la escorrentía superficial y fuerza gravitacional supeditadas a la forma del relieve.

Luego, en cuanto al descarte de variables a lo largo del proceso de entrenamiento y ajuste de las RNA, sólo se descarta la variable Rugosidad, puesto que, las herramientas de análisis, a modo general señalan que no es un factor de gran relevancia y, además, tiene un comportamiento poco definido, siendo sensible ante otras variables, tal como se puede observar

en la Figura 7.6a. Su desestimación se justifica aún más, al notar que una vez que se retira de los datos de entrenamiento, los nuevos modelos procesan e interpretan de mejor manera todas las otras variables (Figura 6.6b). Por tanto, los factores restantes son suficientes para entregar una estimación del Alcance adecuada a los sets de datos de *training* y de *testing*, y con un resultado visualmente congruente, a modo general, con las características del terreno y los eventos registrados.



**Figura 7.6: Lek Profiles de los Modelos ALC.F.5 y ALC.F.8.** a) notar que las curvas de la variable ROUGH no tienen un aspecto uniforme y son difícilmente interpretables en cuanto a la relación de la covariable con la variable de respuesta. b) notar que al eliminar la variable ROUGH las curvas de todas las variables se organizan de mejor manera, su interpretación es simple y evidencian un mejor procesamiento de las variables.

### **7.3.6. RENDIMIENTO DEL MODELO DE ALCANCE**

De la misma forma que el modelo seleccionado de Arranque, la RNA del modelo ALC.F.8 para Alcance presenta un muy buen indicador AUC, siendo igual a 0.963; lo que, en conjunto con los demás indicadores en orden, es una buena señal de validez del modelo. Por su parte, el error calculado a partir del mapa resultante, es igual a 11.9%, es decir, un grado de predicción de 88.1%, lo que se puede considerar un ajuste muy bueno teniendo en cuenta la innovación que significa estimar este tipo de proceso con la técnica seleccionada, y además, la exclusión de factores de tipo físico/reológico en el análisis.

### **7.3.7. CORRELACIÓN ARRANQUE-ALCANCE EN EL MIA**

Si bien, en la realidad, la ocurrencia de una zona de Alcance está supeditada a la existencia previa de una zona de Arranque, el MIA no es capaz de representar esto de forma fiel, debido a que los análisis llevados a cabo se realizan de forma totalmente independiente y para efectos de este estudio no fue posible dar con un factor o variable que represente dicha dependencia. El mapa resultante señala probables zonas de Alcance de acuerdo a las características del terreno, similares a las de aquellas de los puntos donde se registran áreas de tránsito o depósito de material de ocurrencias previas. Por tanto, la superficie señalada como zona de amenaza de Alcance de deslizamiento, indica que ésta es susceptible a ser alcanzada sí y sólo sí la ladera o quebrada más próxima, pendiente arriba, está señalada como una posible zona de Arranque. Por otra parte, debe considerarse la estimación de la zona de Alcance se realiza sobre el límite máximo, es decir, la red neuronal que da origen al mapa considera todos los eventos registrados en la zona, los pequeños y los de mayor alcance; de esta forma, la zona demarcada representa el peor escenario posible, dando lugar a sobre estimaciones locales.

En cuanto a lo anterior, no obstante, existe la posibilidad de realizar una estimación de Alcance en un escenario más favorable, considerando como dato de entrenamiento de la RNA sólo puntos de catastro correspondiente a zonas de Alcance de deslizamientos no-canalizados (los que registran un menor transporte desde el origen). Se descarta llevar a cabo esto, puesto que implica la ejecución de un tercer proceso de análisis para encontrar una RNA que modele de forma adecuada ese nuevo set de datos; lo que excede el tiempo destinado para realización del presente estudio.



### 7.3.8. ESCALA DE VALIDEZ DEL MIA

Considerando, en primera instancia, la resolución de 12.5 m del DEM utilizado como base para la obtención de la mayor parte de las variables incluidas en este estudio, una escala de 1:62.500 sería adecuada para la representación cartográfica del mapa obtenido, acuerdo a lo sugerido por Al-Safri & Al-Ghamdi (2017), quienes proponen que la escala de un mapa con respecto a la resolución de un DEM puede ser estimada como “Escala Mapa = 5.000 \* (tamaño celda)”. No obstante, en este trabajo debe considerarse la inclusión del factor NDVI, el cual al ser derivado de una imagen satelital Landsat 8 tiene una resolución de 30m, lo que disminuye el detalle en la representación gráfica. Por tanto, la escala apropiada para la utilización del MIA es 1:150.000. Esto además se sustenta en el desfase máximo detectado entre datos de catastro y el MIA, de aproximadamente 150m; medida que se traduce a un error de 1mm en el mapa.

### 7.3.9. APLICABILIDAD DE LOS MODELOS ENTRENADOS

La evaluación realizada en el sector El Amarillo – Los Turbios, se considera un resultado favorable al mostrar un buen ajuste al evento ocurrido el año 2020 en dicha zona. Por tanto, esta prueba señala que el entrenamiento de RNA para este tipo de procesos puede ser utilizado como una herramienta de análisis en para zonas circundantes de características similares al área original de donde se toman los datos de referencia para el *Training* y *Testing* de los modelos. Vale decir, el modelo es extrapolable al entorno que comparte características geológico-climáticas similares a la zona original de estudio.

Por otro lado, en la evaluación llevada a cabo en el sector Coñaripe – Lago Pellaifa, es posible notar que la “predicción” hecha por las RNA para Arranque y Alcance no tienen un buen ajuste con los eventos identificados en el área, y el problema identificado más significativo es la exageración de las zonas de Alcance, las cuales abarcan la totalidad de los valles, lagos y planicies. Todos estos errores e incongruencias se deben a que las redes neuronales fueron entrenadas con un inventario de referencia que describe procesos de deslizamientos de dimensiones mucho mayores, cuyo material removido puede llegar a transportar se por centenas de metros. Esto provoca que el muestreo de las diferentes variables del terreno sea distinto y, por tanto, el aprendizaje de las redes neuronales se enfoca en un contexto geológico-geomorfológico específico, con procesos de deslizamiento emplazados en determinados lugares del perfil de los valles.

En la zona de Coñaripe - Lago Pellaifa, los deslizamientos tienen alcances mucho más reducidos, en algunos casos, el material aparentemente se deposita *in situ*, muy cerca de la zona de arranque. A esto se le añade el hecho de que este sector tiene una geología distinta, con mayor variabilidad litológica (granitoides, basaltos, andesitas, conglomerados, brechas, depósitos morrénicos y coluviales, de acuerdo a Lara & Moreno, 2004), lo que a su vez condiciona la geomorfología del lugar, la cual tiene importante presencia de niveles aterrazados, rasgo que no es común en la zona de estudio en la localidad de Chaitén.

Por otra parte, cabe señalar que el algoritmo de las RNA no procesó de forma correcta la variable GRADI para esta zona, variable que controla la posición del Alcance de las remociones con respecto a los quiebres del perfil topográfico. Debido a esto, la zona de Alcance calculada por la RNA tiene cobertura total de las bajas pendientes. Este error fue verificado en diferentes pruebas del modelo para descartar posibles errores en la manipulación del código, sin embargo, no se encontró tal error. Por esta razón, este problema se atribuye al funcionamiento interno del algoritmo de la red neuronal seleccionada, o bien, a fallas dentro de alguno de los paquetes de funciones implementados; en ambos casos, el problema excede los límites y alcances de este estudio.

Finalmente, se entiende que no es factible la aplicación de un modelo ya entrenado en un determinado contexto geológico, para determinado tipo de procesos, en uno diferente, ya que la RNA necesita nueva información de entrada y de salida para hacer una correcta “predicción” en la nueva zona.

## 8. CONCLUSIONES Y RECOMENDACIONES

De acuerdo al proceso metodológico llevado a cabo, los resultados obtenidos y a la consecuente discusión de los mismos, las conclusiones del presente estudio son las que se enlistan a continuación.

- Las Redes Neuronales Artificiales (RNA) son una herramienta con gran potencial para su empleo en diversas áreas de la geología; en específico, pueden llegar a ser un excelente método para el análisis de remociones en masa de forma cuantitativa, dada su gran capacidad de llevar a cabo tareas de clasificación y regresión en base a datos numéricos, los cuales pueden ser obtenidos desde diversas fuentes de información y proceso geoespacial.
- Se genera un mapa de susceptibilidad para el Arranque de deslizamientos con RNA, metodología que además sirve de guía para la selección de las variables que explican el fenómeno estudiados. De acuerdo a esto, se obtiene que la ocurrencia de deslizamientos en el área de estudio está condicionada por las variables de tipo superficial: Pendiente, Pendiente Senoidal, TWI, Rugosidad y NDVI.
- Se elabora un mapa de susceptibilidad de Alcance del material removido por deslizamientos, lo que se obtuvo tras evaluar los factores condicionantes Pendiente, Densidad de Drenaje, Curvatura del terreno, TWI y el Gradiente Topográfico. Esto resulta ser una buena estimación aproximada de las zonas que reúnen las condiciones geomorfológicas e hidrológicas necesarias para ser afectadas por el tránsito o depósito de material fluidizado.
- En base a los análisis de susceptibilidad de Arranque y Alcance de deslizamientos, se confecciona un Mapa indicativo de Amenaza que reúne aquellas áreas con mayor índice de susceptibilidad entregado por las redes neuronales correspondientes. Este es un insumo cartográfico a escala 1:150.000, útil para estudios comunales o provinciales.
- Se evalúa la aplicabilidad de la metodología en otras zonas de Chile, de lo que se obtiene que una RNA entrenada en una zona determinada puede ser utilizada como una herramienta de estimación con buenas aproximaciones en sectores aledaños a dicha zona; no así en áreas distantes enmarcadas en un contexto geológico y geomorfológico diferente. En este último caso, se hace necesario realizar todo el proceso desde cero, aplicable en cualquier zona que cuente con antecedentes de remociones en masa para confeccionar un catastro de eventos para el entrenamiento de una nueva RNA.

A continuación, se presenta una lista de recomendaciones para tener en cuenta en futuros estudios de este tipo con RNA:

- Es deseable que el profesional a cargo cuente no sólo con una buena formación geológica, sino también con sólidos conocimientos en áreas de programación e informática, ya que esto permite la optimización de los tiempos y procesos computacionales que requiere el *Machine Learning*, y abre las puertas a la utilización de más y mejores herramientas para el entrenamiento y evaluación de las RNA.
- La aplicación de las RNA para estudios de análisis de susceptibilidad se sustenta en los factores condicionantes (o variables explicatorias) que definen la predisposición del terreno ante el proceso estudiado, así como también en el catastro de eventos del mismo, y en el modo en que éste se confecciona para dar origen a la base de datos que nutre la RNA. Por esto, es clave dejar en claro cada uno de estos aspectos en cada estudio particular; igualmente el modo de normalización o escalado de los datos, ya que los resultados pueden variar significativamente de acuerdo a esto.
- Los resultados obtenidos podrían verse mejorados con el uso de recursos espaciales de mayor calidad, como lo sería un modelo de elevación digital libre de vegetación y otros elementos, un DTM. No obstante, para usos de escala provincial o comunal, la utilización de DEM libres, entregan resultados con buenas aproximaciones.
- Es importante tener en cuenta la cantidad de registros disponibles en el catastro de entrenamiento o *training*, ya que esto provee una referencia del número adecuado de variables que es capaz de modelar la RNA.
- Los tiempos de entrenamiento y modelación de una RNA están sujetos no sólo a la capacidad computacional del equipo utilizado, sino que también depende fuertemente de la naturaleza y distribución de los datos ingresados a ella.
- En futuros estudios se puede considerar el realizar más de una técnica de muestreo con el fin de contrastar y comparar los resultados que cada una arroja y seleccionar aquellos que muestren ser más realistas y consistentes.

## 9. REFERENCIAS

- ACEVEDO, E.; SERNA, A. & SERNA, E. 2017: Principios y características de las redes neuronales artificiales. Desarrollo e innovación en ingeniería. Editorial Instituto Antioqueño de Investigación: 720 pp. Medellín, Antioquía, Colombia.
- ALFANO, F.; BONADONNA, C.; VOLENTIK, A.C.M.; CONNOR, C.B.; WATT, S.F.L.; PYLE, D.M. & CONNOR, L.J. 2011. Tephra stratigraphy and eruptive volume of the May, 2008, Chaitén eruption, Chile. *Springer. Bull Volcanol.* Vol. **73**: 613 – 630.
- AL-SAFRI, N & AL-GHAMDI, A. 2017. A Review of Relationship Between Spatial Resolution and Map Scale and Proposed Solutions. *The Arabian Journal of Geographic Information Systems.* Saudi Geographical Society, Riyadh, Saudi Arabia.
- ALTHUWAYNEE, O. F.; PRADHAN, B.; PARK, H. & LEE, J. H. 2014. A novel ensemble bivariate statistical evidential belief function with knowledge-based analytical hierarchy process and multivariate statistical logistic regression for landslide susceptibility mapping. *Elsevier. Catena* Vol. **114**: 21 – 36.
- ARCHOUR, Y.; BOUMEZBEUR, A.; HADJI, R.; CHOUABBI, A.; CAVALEIRO, V. & BENDAOU E. A. 2017. Landslide susceptibility mapping using analytic hierarchy process and information value methods along a highway road section in Constantine, Algeria. *Springer. Arabian Journal of Geosciences.* Vol. 10. N°194: 16pp.
- ARENAS, M. & OPAZO, E. 2017. Guía Metodológica para la Elaboración de Mapas de Susceptibilidad a las Remociones en Masa a Escala Regional. Servicio Nacional de Geología y Minería. 65pp.
- AUSTRALIAN GEOMECHANICS SOCIETY. 2007. Guideline for Landslide Susceptibility, Hazard and Risk Zoning for Land Use Planning. *Journal and News of the Australian Geomechanics Society.* Vol. **42** N° 1: 13 – 36.
- AYALEW, L.; YAMAGISHI, H.; MARUI, H. & KANNO T. 2005. Landslides in Sado Island of Japan: Part II. GIS-based susceptibility mapping with comparisons of results from two methods and verifications. *Elsevier. Engineering Geology.* Vol. **81**: 432 – 445.
- BAZIL RAJ, A. A.; VIJAYA SELVI, A. J.; DURAI, K. D. & SINGARAVELU, R. S. 2014. Intensity feedback-based beam wandering mitigation in free-space optical communication using neural control technique. *Springer. EURASIP Journal on Wireless Communications and Networking.* Vol. 1. N° 160: 18pp.
- BECK, M. W. 2018. NeuralNetTools: Visualization and Analysis Tools for Neural Networks. *Journal of Statistical Software.* Vol. 85. N°11: 20pp.
- BEVEN K. & KIRKBY M. 1979. A physically based, variable contributing area model of basin hydrology / Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Bulletin,* Vol. **24**, N°1: 43-69.

- BONHAM-CARTER, G. F. & AGTERBERG, F. P. 1990. Application of a Microcomputer-based Geographic Information System to Mineral-Potential Mapping. Geological Survey of Canada. Contribution N° 47488: 49 – 74.
- BORJA, R. C. & ALCÁNTARA I., 2004. Procesos de remoción en masa y riesgos asociados en Zacapoaxtla, Puebla. Investigaciones Geográficas, Boletín del Instituto de Geografía, UNAM. Boletín N° 53: 7 – 26.
- CANDIA, J. & HERRERA A. 2017. Catastro remociones en masa a nivel nacional. Memoria para optar al título profesional de Cartógrafo y al grado de Licenciado en Ciencias Cartográficas. Universidad Tecnológica Metropolitana, Facultad de Humanidades y Tecnologías de la Comunicación Social, Escuela de Cartografía: 129pp., Santiago de Chile.
- CARRARA, A. 1983. Multivariate Models for Landslide Hazard Evaluation. Plenum Publishing Corporation. *Mathematical Geology*. Vol. **15**. N° 3: 403 – 426.
- CARRARA, A.; CARDINALI, M.; DETTI, R.; GUZZETTI, F.; PASQUI, V. & REICHENBACH, P. 1991. GIS techniques and statistical models in evaluating landslide hazard. *Earth Surface Processes and Landforms*. John Wiley & Sons, Ltd. Vol. **16**: 427 – 445.
- CHE, V. B.; KERVYN, M.; SUH, C. E.; FONTIJN, K.; ERNST G. G. J.; DEL MARMOL, M. A.; TREFOIS, P. & JACOBS, P. 2011. Landslide susceptibility assessment in Limbe (SW Cameroon): A field calibrated seed cell and information value method. *Elsevier. Catena*. Vol. **92**: 83 – 98.
- CONCHA, D. 2017. Análisis de la susceptibilidad a remociones en masa en el sector de Lota Alto, comuna de Lota. Memoria para optar al Título de Geólogo. Universidad de Concepción. Facultad de Ciencias Químicas. Departamento Ciencias de la Tierra. 96 pp. Concepción, Chile.
- CRUDEN, D. M. 1991. A simple definition of a landslide. *Bulletin of the International Association of Engineering Geology - Bulletin de l'Association Internationale de Géologie de l'Ingénieur*. Vol. **43**, N° 1: 27-29.
- CRUDEN, D. M. & VARNES, D. J. 1996. Landslide types and processes. *Landslides: investigation and mitigation (Special Report)*. Turner, A. K. & Schuster R. L.: 36 – 75 pp. Washington, DC, EE. UU.
- CRUDEN D. M. & LAN H. 2015. Using the Working Classification of Landslides to Assess the Danger from a Natural Slope. *Springer. Engineering Geology for Society and Territory* Vol. **2**: 3 – 12.
- DAHAL, R. K.; HASEGAWA, S.; NONOMURA, A.; YAMANAKA, M.; MASUDA, T. & NISHINO, K. 2007. GIS-based weights-of-evidence modelling of rainfall-induced landslides in small catchments for landslide susceptibility mapping. *Springer-Verlag. Environmental Geology*. Vol. **54**: 311 – 324.
- DAVIES, T., 2015. Landslide Hazards, Risks, and Disasters: Introduction. *Landslide Hazards, Risks, and Disasters*. Shroder, J. F., Davies, T. editores. Elsevier. 1 – 16.

- DOBOS, E.; MICHELI, E.; BAUMGARDNER, M.F.; BIEHL, L. & HELT, T. 2000. Use of combined digital elevation model and satellite radiometric data for regional soil mapping. *Elsevier. Geoderma*. Vol. **97**: 367 – 391.
- DOBOS, E. & DAROUSSIN, J. 2007. Calculation of Potential Drainage Density Index (PDD). *Digital Terrain Modelling*. Peckham, R.J. & Jordan G. Springer, Berlin, Heidelberg: 283 – 295.
- DUHART, P. 2003. Geología del área Los Lagos-Malalhue: región de Los Lagos. Servicio Nacional de Geología y Minería. Chile.
- DUHART, P. & ADRIASOLA, A. C. 2008. Nuevas restricciones temporales sobre proveniencia, metamorfismo y exhumación del Complejo Metamórfico Bahía Mansa en la Isla Grande de Chiloé, centro-sur de Chile. *Revista geológica de Chile*, Vol. 35. N°1: 79-104.
- ECHAURREN, A.; FOLGUERA, A.; GIANNI, G.; ORTS, D.; TASSARA, A.; ENCINAS, A.; GIMÉNEZ, M. & VALENCIA, V. 2016. Tectonic evolution of the North Patagonian Andes (41°–44° S) through recognition of syntectonic strata. *Elsevier. Tectonophysics*. N° 667 – 668: 99 – 114.
- ELMES, M. 2006. Análisis y evaluación de riesgos por movimientos en masa, inundación y sismicidad en el piedmont de la comuna de Puente Alto. Memoria para optar al título de Geógrafo. Universidad de Chile. Facultad de Arquitectura y Urbanismo. Escuela de Geografía. 273pp. Santiago de Chile.
- ERMINI, L.; CATANI, F. & CASAGLI, N. 2005. Artificial Neural Networks applied to landslide susceptibility assessment. *Elsevier. Geomorphology*. Vol. **66**: 327 – 343.
- FAWCETT, T. 2005. An introduction to ROC analysis. *Elsevier. Pattern Recognition Letters*. Vol. 27: 861–874
- FEDERAL OFFICE FOR THE ENVIRONMENT. 2016. Protection against Mass Movement Hazards. Guideline for the integrated hazard management of landslides, rockfall and hillslope debris flows. *The environment in practice* N° 1608: 97pp., Berna.
- FUENTES, M.; CAMPOS, C. & GARCÍA-LOYOLA, S. 2018. Application of artificial neural networks to frost detection in central Chile using the next day minimum air temperature forecast. *Chilean Journal of Agricultural Research*. Vol. **78**, N° 3: 327 – 338.
- FRITSCH, S. & GÜNTHER, F. 2010. Neuralnet: Training of Neural Networks. *The R Journal*. Vol **2**, N°2: 30 – 38.
- GAITÁN, J.J.; DONALDO BRAN, D.E. & AZCONA, C. 2015. Tendencia del NDVI en el período 2000-2014 como indicador de la degradación de tierras en Argentina: ventajas y limitaciones. *Agriscientia*. Vol. **32**, N°2: 83-93.
- GARREAUD, R.; LÓPEZ, P.; MINVIELLE, M. & ROJAS, M. 2013. Large-Scale Control on the Patagonian Climate. *Journal of Climate*. Vol. **26**: 215 - 230.

- GARSON, G. D. 1991. Interpreting Neural Network Connection Weights. *Artificial Intelligence Expert.* Vol **6**. N° 4: 46–51.
- GEVREY, M.; DIMOPOULOS, I. & LEK, S. (2003). Review and Comparison of Methods to Study the Contribution of Variables in Artificial Neural Network Models. *Ecological Modelling.* Vol. **160**. N° 3: 249–264.
- GOH, A. T. C. 1995. Back-Propagation Neural Networks for Modeling Complex Systems. *Artificial Intelligence in Engineering.* Vol. **9**. N°3: 143–151.
- GUZZETTI, F.; CARRARA, A.; CARDINALI, M. & REICHENBACH, P. 1999. Landslide hazard evaluation: a review of current techniques and their application in a multi-scale study, Central Italy. Elsevier. *Geomorphology.* Vol. **31**: 181 – 216.
- HANSON, B. 2020. Machine Learning, The Mastery Bible, The Definitive Guide to Machine Learning, Data Science, Artificial Intelligence, Neural Networks, and Data Analytics. Bill Hanson. 2° Edición.
- HAUSER A. 1993. Remociones en masa en Chile. Nacional de Geología y Minería. Boletín N° 45: 7-29, Santiago de Chile.
- HEIM, A. 1932. Bergsturz und menschenleben. zürich, fretz und wasmuth. *Vierteljahrsschrift der Naturforschenden Gesellschaft:* 77 pp. Zürich
- HENRÍQUEZ, E. 2019. Análisis de susceptibilidad a Remociones en Masa en la Comuna de Collar, al Norte de los 39°54'S, Región de Los Ríos, Chile. Memoria para Optar al Título de Geólogo. Universidad de Concepción. Facultad de Cs. Químicas, Depto. Ciencias de la Tierra. 88pp. Concepción, Chile.
- HERVÉ, F.; PANKHURST, R. J.; FANNING, C. M.; CALDERÓN, M. & YAXLEY, G. M. 2007. The South Patagonian batholith: 150 my of granite magmatism on a plate margin. *Lithos,* Vol. 97. N°3-4: 373-394.
- HERVÉ, F.; FUENTES, F.; CALDERÓN, M.; FANNING, M.; QUEZADA, P.; PANKHURST, R. & RAPELA, C. 2017. Ultramafic rocks in the North Patagonian Andes: is their emplacement associated with the Neogene tectonics of the Liquiñe-Ofqui Fault Zone?. *Andean Geology.* Vol. 44. N°1: 1-16. Santiago de Chile.
- HUNGR, O.; EVANS, S. G.; BOVIS, M. & HUTCHINSON, J. N., 2001. A review of the classification of landslides of the flow type: *Environmental and Engineering Geoscience,* Vol **7**, N°3: 221–238.
- HUNGR, O.; LEROUEIL, S. & PICARELLI, L. 2014. The Vernes classification of landslide types, an update. *Springer. Landslides* N°11: 167 – 194.
- HUTCHINSON, J. N. 1988. Morphological and geotechnical parameters of landslides in relation to geology and hydrogeology. Memorias, 5th International Conference on Landslides: 3 – 35. Lausanne.
- JACOB, R., & MURUGAN, R. 2016. Implementation of neural network based for PID controller. International Conference on Electrical, Electronics, and Optimization Techniques, 2769-2771. Chennai, India.



- JORDAN, T. E.; BURNS W. M.; VEIGA R.; PÁNGARO, F.; COPELAND, P.; KELLEY, S. & MPODOZIS, C. 2001. Extension and basin formation in the southern Andes caused by increased convergence rate: A mid-Cenozoic trigger for the Andes. *Tectonics*. Vol. 20. N° 3: 308–324.
- KALANTAR, B.; PRADHAN B.; NAGHIBI S. A.; MOTEVALLI, A. & MANSOR S. 2017. Assessment of the effects of training data selection on the landslide susceptibility mapping: a comparison between support vector machine (SVM), logistic regression (LR) and artificial neural networks (ANN). *Geomatics, Natural Hazards and Risk*, Vol. 9, N°1, 49 - 69.
- 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. *Elsevier. Engineering Geology*. Vol. 85: 347 – 366.
- KAVZOGLU, T. 2001. An investigation of the design and use of feed-forward artificial neural networks in the classification of remotely sensed images. Thesis submitted to the University of Nottingham for the degree of Doctor of Philosophy. 306 pp. Nottingham.
- KORUP, O.; SEIDEMANN, J. & MOHR, C.H. 2019. Increased landslide activity on forested hillslopes following two recent volcanic eruptions in Chile. *Nature Geoscience*.
- LARA, M. 2007. Metodología para la evaluación y zonificación de peligro de remociones en masa con aplicación en Quebrada San Ramón, Santiago Oriente, Región Metropolitana. Tesis para optar al grado de Magíster en Ciencias mención Geología. Memoria para optar al Título de Geólogo. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Geología: 212 pp., Santiago de Chile.
- LEE, S. & MIN, K. 2001. Statistical analysis of landslide susceptibility at Yongin, Korea. *Springer-Verlag. Environmental Geology*. Vol. 40: 1094 – 1113.
- LEE, S.; RYU, J.; WON, J. & PARK, H. 2003. Determination and application of the weights for landslide susceptibility mapping using an artificial neural network. *Elsevier. Engineering Geology*. Vol. 71: 289 – 302.
- LEE, S. & PRADHAN, B. 2006. Landslide hazard mapping at Sengalor, Malaysia using frequency ratio and logistic regression models. *Springer-Verlag. Landslides*. Vol. 4: 33 – 41.
- LEE, S. & SAMBATH, T. 2006. Landslide susceptibility mapping in the Damrei Romel area, Cambodia using frequency ratio and logistic regression models. *Springer-Verlag. Environmental Geology*. Vol. 50: 847 – 855.
- LEK, S.; DELACOSTE, M.; BARAN, P.; DIMOPOULOS, I.; LAUGA, J. & AULAGNIER, S. 1996. Application of Neural Networks to Modelling Nonlinear Relationships in Ecology. *Ecological Modelling*. Vol. 90. N°1: 39–52.
- LUEBERT, F. & PLISCOFF, P. 2006. Sinopsis bioclimática y vegetacional de Chile. Editorial Universitaria. 310 pp.

- LUZI, L.; PERGALANI, F. & TERLIEN, M. T. J. 2000. Slope vulnerability to earthquakes at subregional scale, using probabilistic techniques and geographic information systems. *Elsevier. Engineering Geology*. Vol. **58**: 312 – 336.
- MAIND, S. B. & WANKAR, P. 2014. Research Paper on Basic of Artificial Neural Network. *International Journal on Recent and Innovation Trends in Computing and Communication*. Vol. **2**. N°1: 96 – 100.
- MATICH, D. M. 2001. *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Cátedra de Informática Aplicada a la Ingeniería de Procesos. Universidad Tecnológica Nacional. Rosario, Argentina.
- 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.
- MCDONOUGH, M.; DUHART, P. & CRIGNOLA, P. 1997. Naturaleza del alzamiento del basamento costero y la apertura de la cuenca Osorno-Llanquihue, X región: Nuevos antecedentes sísmicos y observaciones de terreno. VII Congreso Geológico Chileno, G. D. Chong, editor. Soc. Geol. de Chile. 164–168, Santiago.
- MOLINA, C. 2016. Análisis de susceptibilidad de Remociones en Masa en las costas del Fiordo Comau, X Región, Chile. Memoria para optar al título de Geóloga. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Geología: 119pp., Santiago de Chile.
- MORENO-GONZÁLEZ, R.; DÍAZ, I. A.; CHRISTIE, D. A.; COOPMAN, R. E. & LARA, A. 2019. Early vegetation recovery after the 2008-2009 explosive eruption of the Chaitén Volcano. BIORXIV, 746859.
- MUÑOZ, 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. Memoria para optar al Título de Geólogo, Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Geología: 105pp., Santiago de Chile.
- MUÑOZ, R. 2019. Control estructural del basamento sobre el volcanismo Cuaternario del Complejo Volcánico Chaitén-Michinmahuida. Memoria para optar al Título de Geólogo. Universidad de Concepción. Facultad de Ciencias Químicas. Departamento Ciencias de la Tierra. 105 pp. Concepción, Chile.
- NÁQUIRA, M. V. 2009. Susceptibilidad de Remociones en Masa en las costas de los fiordos cercanos a Hornopirén, X Región. Memoria para optar al Título de Geólogo, Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Geología: 201pp., Santiago de Chile.
- NIELSEN, S. N. & GLODNY, J. 2009. Early Miocene subtropical water temperatures in the southeast Pacific. *Palaeogeography, Palaeoclimatology, Palaeoecology*, Vol. 280 N°3-4: 480-488.

- 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*, Vol. 178. N°3–4: 389–397.
- ONEMI. 2017. Plan específico de emergencia por variable de riesgo Remoción en Masa Nacional. Oficina Nacional de Emergencia del Ministerio del Interior y Seguridad Pública.
- ORDOÑEZ, A. & CRIGNOLA, P. 2003. Depósitos metalíferos, anomalías geoquímicas, rocas y minerales industriales y recursos energéticos del sector sur de la Región de Los Lagos. Servicio Nacional de Geología y Minería, Carta Geológica de Chile, Serie Recursos Minerales y Energéticos, N° 21: 32pp.
- OZDEMIR, A. & ALTURAL, T. 2012. A comparative study of frequency ratio, weights of evidence and logistic regression methods for landslide susceptibility mapping: Sultan Mountains, SW Turkey. *Elsevier. Journal of Asian Earth Sciences*. Vol. 64: 180 – 197.
- PANKHURST, R.J.; WEAVER, S.D.; HERVÉ, F. & LARRONDO, P. 1999. Mesozoic–Cenozoic evolution of the North Patagonian batholith in Aysén, southern Chile. *Journal Geological Society*. Vol. 156: 673–694.
- 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.
- PRAKASH, N.; MANCONI, A. & LOEW, S. 2020. Mapping Landslides on EO Data: Performance of Deep Learning Models vs. Traditional Machine Learning Models. MDPI. Remote Sensing. Vol. 12: 12pp
- 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
- RADULA, M.; SZYMURA T. & SZYMURA M. 2018. Topographic wetness index explains soil moisture better than bioindication with Ellenberg's indicator values. *Elsevier. Ecological Indications* Vol. 85: 172 – 179.
- 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.
- RINCÓN, F.; CASTRILLÓN, L.; RIVERA, M.; PEREIRA, Y. & ARISTIZÁBAL, E. 2016. Método estadístico multivariado-regresión logística para estudio de susceptibilidad ante

deslizamientos de la cuenca La Loma en el municipio de Santa Bárbara, Antioquia. XII Semana Técnica de Geología e Ingeniería Geológica. Medellín.

- ROSENBLATT, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*. Vol. **65**, N° 6: 386–408.
- R&Q INGENIERÍA S. A. 2007. Estudio de Impacto Ambiental Construcción Conexión Vial Futaleufú - Termas del Amarillo, X Región. Línea base del medio físico. 42 – 73.
- SAATY, T. 1980. *The Analytic Hierarchy Process*. McGraw Hill International. New York.
- SAATY, T. L. 2000. Fundamentals of decision making and priority theory with the analytic hierarchy process. *RWS publications*. Vol. **6**.
- SAATY, T. L. & VARGAS, L. G. 2001. *How to Make a Decision. Models, Methods, Concepts & Applications of the Analytic Hierarchy Process*. Springer Science + Business Media. 1–25. New York.
- SARKAR, S.; ROY, A. K. & MARTHA, T. R. 2013. Landslide Susceptibility Assessment using Information Value Method in Parts of the Darjeeling Himalayas. *Journal Geological Society of India*. Vol. **82**: 351 – 362.
- SANTACANA, N. 2001. Análisis de la susceptibilidad del terreno a la formación de deslizamientos superficiales y grandes deslizamientos mediante el uso de sistemas de información geográfica. Aplicación a la cuenca alta del río Llobregat. Tesis doctoral, *Universitat Politècnica de Catalunya. Departament d'Enginyeria del Terreny, Cartogràfica i Geofísica*. Barcelona.
- 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
- SCHACHTER, P. 2008. Evaluación de la susceptibilidad de remociones en masa en el sector nororiente de la Cuenca de Santiago mediante métodos estadísticos multivariados. Memoria para optar al Título de Geólogo. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Geología: 112pp., Santiago de Chile.
- 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.
- SERNAGEOMIN-BRGM. 1995. Carta Metalogénica Xa Región Sur, Chile. Servicio Nacional de Geología y Minería – Bureau de Recherches Géologiques et Minières, Informe Registrado IR-95-05, 4 Tomos, 8 Vols., 95 mapas diferentes escalas. Santiago, Chile.
- SIBI, P.; ALLWYN JONES, S. & SIDDARTH, P. 2013. Analysis of different activation functions using back propagation neural networks. *Journal of Theoretical and Applied Information Technology*. Vol. **47**. N°3: 1264 – 1268.
- SOTO, A. 2019. La granodiorita orbicular del Cerro Recoba, Batolito Patagónico Norte, Chaitén. Memoria para optar al Título de Geólogo. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, Departamento de Geología: 58pp., Santiago de Chile.

- 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.
- SWANSON, F.J.; JONES, J.J.; CRISAFULLI, C.M. & LARA, A. 2013. Effects of Volcanic and Hydrologic Processes on Forest Vegetation: Chaitén Volcano, Chile. *Andean Geology*. Vol. **40**. N°2.
- THIEBES, B. 2012. Landslide Analysis and Early Warning Systems: Local and Regional Case Study in the Swabian Alb, Germany. Doctoral Thesis. University of Vienna. Department of Geography and Regional Research. Vienna, Austria.
- 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. *Springer. Landslides* Vol. **13**: 361 - 378.
- VAN WESTEN, C. J. 1993. Application of Geographic Information Systems to Landslide Hazard Zonation. International Institute for Aerospace Survey and Earth Sciences (ITC). N°15: 265pp. Netherlands.
- 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.
- VARNES, D. J. 1958. Landslides types and processes. Landslides and engineering practice, Special Report, N°28. Eckel, E.B., editor. Highway Research Board, National Academy of Sciences: 20 – 47. Washington, DC.
- 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.
- YENGOH, G.T.; DENT, D.; OLSSON, L.; TENGBERG A.E. & TUCKER III, C.J. 2015. Use of the Normalized Difference Vegetation Index (NDVI) to assess land degradation at multiple scales: Current status, future trends, and practical considerations. Springer: 110 pp.
- YESILNACAR E. & TOPAL T. 2005. Landslide susceptibility mapping: A comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey). *Elsevier. Engineering Geology* Vol. **79**: 251 - 266.
- YILMAZ, I. 2008. Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: A case study from Kat landslides (Tokat - Turkey). *Elsevier. Computers & Geosciences* Vol. **35**: 1125 - 1138.
- ZHANG, Z. 2016. Neural networks: further insights into error function, generalized weights and others. *Annals of Translational Medicine. Big Data Clinical Trial Column*. Vol 4. N° 16: 6 pp.

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.

ZISCHINSKY, U. 1969. Über Sackungen. *Springer*. Rock Mechanics. Vol 1:30–52.



## ANEXO 1 – SOFTWARES DE MODELACIÓN NUMÉRICA

A continuación, se presentan los apuntes de 3 fuentes bibliográficas relativas al uso y comparación de diferentes *softwares* para modelación numérica de remociones en masa, tipo de técnica descartada para su aplicación en el presente estudio por la falta de los insumos fotogramétricos necesarios.

**Tabla 3.1: Modelación numérica con DAN3D y RASH3D.**

SOFTWARE/CÓDIGO	DAN3D y RASH3D
SEGÚN	Sauthier <i>et al.</i> 2015 "Numerical modelling of gravel unconstrained flow experiments with the DAN3D and RASH3D codes."
<ul style="list-style-type: none"> <li>▪ Ambos códigos tienen un enfoque mecánico continuo y se basan en una solución monofásica integrada de las ecuaciones de St. Venant usando el supuesto de flujo de agua poco profunda.</li> <li>▪ La masa heterogénea real es reemplazada por un fluido incompresible equivalente.</li> <li>▪ La reología del material está modelada por un solo término que describe el esfuerzo de cizallamiento basal que se desarrolla en la interfaz entre la masa móvil y la superficie de deslizamiento. La reología utilizada en este paper corresponde a una ley friccional basal sin cohesión tipo Coulomb.</li> <li>▪ Esta reología asume que la fuerza de resistencia al roce <math>T=(T_x, T_y)</math> en la base de la masa que fluye, depende del stress normal efectivo <math>T_z</math>, pero no de la velocidad:</li> <li>▪ DAN3D usa un método de partícula Langrangiano, Basado en conceptos de una Hidrodinámica de Partícula Suavizada (SPH), la cual es una técnica numérica carente de malla (meshless).</li> <li>▪ Implica la selección de valores apropiados para algunos parámetros numéricos, que son: el número de partículas <math>N</math>, el coeficiente de suavidad <math>B</math>, el coeficiente de suavidad de velocidad <math>C</math> y el coeficiente de rigidez <math>D</math>. McDougall (2006) recomienda los siguientes valores: <math>N = 2000</math> (para pequeños volúmenes), <math>B = 4</math>, <math>C = 0,01</math> y <math>D = 200</math>.</li> <li>▪ RASH3D se origina de un modelo preexistente llamado SHWCIN (Audusse <i>et al.</i> 2000; Bristeau <i>et al.</i> 2001). Resuelve las ecuaciones de profundidad media de St. Venant en un marco Euleriano discretizado en una malla triangular de elementos finitos utilizando un esquema cinético basado en un enfoque de volumen finito.</li> <li>▪ Los marcos Langranianos y Eulerianos presentan ventajas y desventajas: Si el enfoque Langraniano permite seguir una evolución transiente de la posición y velocidad de la masa deslizante, con respecto al enfoque Euleriano muestra el problema de bifurcación cuando el flujo impacta contra obstáculos. Sin embargo, una implementación numérica utilizando el esquema Langraniano permite llevar un registro de la deformación interna de la masa deslizante, lo cual constituye una ventaja considerable al calcular el estado de tensión utilizando el coeficiente de presión de tierra <math>K</math>.</li> <li>▪ DAN3D asume un estado de stress anisotrópico (<math>\sigma_{xx} \neq \sigma_{yy} \neq \sigma_{zz}</math>). RASH3D puede asumir un estado de stress normal tanto isotrópico (<math>\sigma_{xx} = \sigma_{yy} = \sigma_{zz}</math>) como pseudo-anisótropo (simetría axial, i.e. <math>\sigma_{xx} = \sigma_{yy} \neq \sigma_{zz}</math>)</li> <li>▪ Una conclusión de este estudio es que RASH3D es más preciso en cuanto a la posición trasera del depósito, mientras que el DAN3D es más preciso en cuanto a la posición del centro de masa del depósito.</li> </ul>	

Tabla 3.2: Modelación numérica con RASH3D y HYBRID

SOFTWARE/CÓDIGO	RASH3D y HYBRID
SEGÚN	Pirulli et al. 2018 "Comparison of depth-averaged and full-3D model for the benchmarking exercise on landslide runout"
<ul style="list-style-type: none"> <li>▪ RASH3D resuelve un conjunto de versiones de profundidad promediada de las ecuaciones de Navier-Stokes</li> <li>▪ HYBIRD (Leonardi et al., 2016), se basa en el método de Lattice-Boltzmann (LBM) y, en lugar de resolver la ecuación de Navier-Stokes directamente, realiza una solución de la ecuación de Boltzmann.</li> <li>▪ RASH3D sigue una técnica estándar de promediación de profundidad, en la que la topografía se implementa utilizando puntos (x,y,z), pero sólo se almacena un único valor para las cantidades de promediación de profundidad (altura, velocidad, tasa de roce, stress basal) para cada punto (x,y) de la grilla. Esto aumenta enormemente el rendimiento del código. En este sentido, el ápice "3D" sólo se refiere a la capacidad del código para leer y resolver topografías en 3D.</li> <li>▪ En HYBIRD no hay dirección preferencial y el código se resuelve en una cuadrícula 3D de igual espaciado. Los valores locales de velocidad, presión y tasa de roce se obtienen para cada punto de fluido en (x,y,z). Esto requiere una mayor asignación de recursos y tiempos de cálculo mucho más largos. Sin embargo, el modelo no requiere ninguna suposición sobre la forma del perfil de velocidad, y permite implementar directamente las leyes reológicas, devolviendo un archivo de velocidad 3D completo.</li> <li>▪ En RASH3D la reología del material es modelada por un solo término, el cual describe el estrés de roce basal que se desarrolla en la interface entre la masa que se mueve y la superficie de deslizamiento. Una Función SIG integrada hace posible el cambio del tipo de reología y/o valores de parámetros reológicos a lo largo del trayecto de run-out para permitir cambios en las características del flujo durante la propagación de éste. Las siguientes relaciones se implementan en RASH3D: <ul style="list-style-type: none"> <li>a) Reología Friccional. Las fuerzas de resistencia al roce en la base de la masa que fluye, se asume dependiente del stress normal, pero no de la velocidad.</li> <li>b) Reología Turbulenta, la que se caracteriza por una intensa mezcla, a tasas de stress inercial a viscoso relativamente altos. La turbulenta resistencia al roce basal es proporcional al cuadrado de la velocidad de flujo promediada en profundidad, y puede calculada usando la ecuación de Manning.</li> <li>c) Reología de Voellmy, donde la desventaja de la reología turbulenta puede ser superada por la adición de un término friccional en la formulación reológica que describe la detención del flujo en una superficie inclinada.</li> <li>d) Reología de Bingham, la cual combina comportamientos plástico y viscoso. Un comportamiento también llamado fluido de Bingham, como un material rígido por debajo de un umbral dado de "yield strength", pero también como un material viscoso, por sobre dicho umbral.</li> <li>e) Reología cuadrática.</li> </ul> </li> <li>▪ La fórmula de la tasa de erosión utilizada en RASH3D es la propuesta por McDougall &amp; Hungr (2005), por su simpleza y precisión <math>E_t = E_s h v</math>, donde <math>E_s = \ln(V_f / V_0) / l</math></li> <li>▪ HYBIRD es un código originalmente diseñado como una combinación del Método de Elemento Discreto (DEM) y LBM. El desarrollo de éste eventualmente apunta a una descripción multifase de la masa, con los granos más grandes resueltos con DEM y la masa restante mediante LBM. Este trabajo ve la primera aplicación del código a una escala topográfica completa. Por tanto, para limitar el número de "unknowns", solo se testea la parte LBM del código.</li> <li>▪ HYBIRD utiliza conceptos de teoría cinética, y discretiza una función de probabilidad Euleriana (pdf), y la evolución de ésta es controlada por una ecuación de Boltzmann.</li> <li>▪ En cuanto a los modelos reológicos de HYBIRD, ya no existe un procedimiento de integración en profundidad, los stresses son aplicados en todos los lugares del dominio, y son controlados por el modelo reológico, que puede ser elegido desde los siguientes: <ul style="list-style-type: none"> <li>a) Reología de Bingham. Comportamiento lineal de adelgazamiento de roce, análogo al implementado en RASH3D</li> <li>b) Reología Tubulenta. Una viscosidad turbulenta es calculada de acuerdo al modelo de Smagorinsky-Lily (Leonardi et al. 2011) con una constante de turbulencia subgrid <math>C_s = 0.16</math></li> <li>c) Reología Friccional</li> <li>d) Reología de Voellmy. Combina propiedades friccionales y disipación turbulenta.</li> </ul> </li> <li>▪ Una de las mayores dificultades de trabajar fuera de un marco de promediación de la profundidad, es la calibración de los parámetros reológicos.</li> </ul>	



Tabla 3.3: Modelación numérica con RASH3D y GeoFlow\_SPH

SOFTWARE/CÓDIGO	RASH3D y GeoFlow_SPH
SEGÚN	Vagnon <i>et al.</i> 2018 "Comparison of two depth averaged numerical models for debris flow runout estimation"
	<ul style="list-style-type: none"> <li>▪ RASH3D y GeoFlow_SPH (Pastor et al. 2009) son modelos numericos dinamicos de tipo continuo, y ambos estan basados en las mismas ecuaciones gobernantes (depth-averaged), pero difieren en la solucion numerica.</li> <li>▪ La aplicación de una mecánica de continuidad a una modelación de remociones de tipo flujo, implica que tanto el espesor como el largo de la masa que fluye se asume exceden varias veces el tamaño de las partículas individuales en movimiento. Con dicha hipótesis, la mezcla real en movimiento, compuesta de fases sólida y líquida, puede ser reemplazada por un fluido equivalente cuyas propiedades se aproximan el comportamiento general de la mezcla real.</li> <li>▪ En una dinámica de continuidad, las ecuaciones de movimiento pueden ser formuladas en uno de dos contextos de referencia: Euleriano o Lagrangiano. Un contexto de referencia Euleriano está fijado en el espacio, mientras que el Lagrangiano se mueve con el flujo. Además, para realizar el cálculo de balance de masa, debe ser hecha una discretización de las ecuaciones usando una malla (<i>mesh</i>), estructurada o no estructurada, o un enfoque sin malla (<i>meshless</i>). En un esquema <i>meshless</i>, en lugar de una malla, el balance es determinado por la distribución espacial de un número de masas en movimiento de referencia, conocidas como partículas.</li> <li>▪ RASH3D y GeoFlow_SPH adoptan enfoques de discretización <i>mesh</i> y <i>meshless</i>, respectivamente. RASH3D discretiza el terreno en una malla general triangular con una estructura de datos de elementos finitos y calcula el movimiento del flujo en las diferentes direcciones usando un volumen de control particular; mientras que en GeoFlow_SPH, la masa deslizante es esquematizada como una serie de nodos con términos ficticios de masa y presión.</li> <li>▪ RASH3D utiliza un método Euleriano y un sistema de referencia modificado para la evaluación de las características del movimiento del flujo (para cada nodo de la red, se calculan la velocidad y grosor, y la evolución de estos en el tiempo).</li> <li>▪ GeoFlow_SPH usa un método Lagrangiano <i>meshless</i>, conocido como Hidrodinámica de Partícula Suavizada (SPH) y el sistema de referencia es integral con la posición de la partícula.</li> <li>▪ Ambos códigos necesitan como data de entrada: 1) El modelo de elevación digital (DEM) del terreno previo al evento, 2) La posición y la magnitud del área de arranque, 3) La ley reológica.</li> <li>▪ GeoFlow_SPH está basado en marco teórico de Hutchinson (1986) y Pastor et al. (2002), y esquematiza la masa propagada como una mezcla de una fase de partículas sólidas y agua. Las ecuaciones gobernantes son resueltas utilizando el modelo SPH (Lucy, 1977; Gingold &amp; Monaghan 1977).</li> <li>▪ En el modelo SPH, una función dada y sus derivadas espaciales pueden ser aproximadas mediante aproximaciones integrales definidas en términos de kernel y ellas pueden ser aproximadas después por su reemplazo con sumatorias sobre todos los valores correspondientes a las partículas circundantes en un dominio local.</li> <li>▪ Los outputs del código GeoFlow_SPH son: los valores de velocidad y altura del depósito, evaluados en cada momento del tiempo.</li> <li>▪ El evento de referencia analizado en este estudio (flujo de detritos de Rio Nora, en Octubre de 2000), fue previamente modelado en RASH3D por Pirulli &amp; Marco en 2010. La simulación numérica con mejor ajuste fue obtenida utilizando un DEM de 5m, y considerando una reología de Voellmy con <math>\lambda g=0,1</math> y <math>\lambda i=200</math> m/s<sup>2</sup>.</li> <li>▪ GeoFlow_SPH, al ser un código de partículas <i>meshless</i>, no requiere una grilla modificada, y todos los cálculos se realizan directamente en una posición centrada en la partícula. A pesar de esto, junto a la malla topográfica de 5m (que provee la superficie del problema), GeoFlow_SPH requiere que una malla secundaria sea empleada para definir el área de la fuente del flujo de detritos. En el caso de Rio Nora, los autores asumieron una malla secundaria de 1m de espaciamiento, y consecuentemente fue obtenida un área de arranque constituida por 212 puntos.</li> </ul>

## REFERENCIAS

- AUDUSSE, E.; BRISTEAU, M.O. & PERTHAME, B. 2000. Kinetic schemes for Saint-Venant equations with source terms on unstructured grids. Institut National de Recherche en Informatique et Automatique, LeChesnay, France. Rapport de Recherche, N°. 3989: 1-44.
- BRISTEAU, M.O.; COUSSIN, B. & PERTHAME, B. 2001. Boundary conditions for the shallow water equations solved by kinetic schemes. INRIA Report 4282, National Institute for Research and Computational Sciences and Control, Le Chesnay, France.
- GINGOLD, R. A. & MONAGHAN, J. J. 1977. Smoothed particle hydrodynamics: theory and application to non-spherical stars. *Monthly Notices of the Royal Astronomical Society*. Vol. 181. N°3: 375–389.
- HUTCHINSON, J. N. 1986. A sliding–consolidation model for flow slides. *Canadian Geotechnical Journal*. Vol. 23. N°2: 115–126.
- LEONARDI, A.; WITTEL, F. K.; MENDOZA, M.; VETTER, R.; & HERRMANN, H. J. 2016. Particle-Fluid-Structure Interaction for Debris Flow Impact on Flexible Barriers. *Computer-Aided Civil and Infrastructure Engineering*. Vol. 31. N° 5: 323–333.
- LUCY, L. B. 1977. A numerical approach to the testing of the fission hypothesis. *The Astronomical Journal*. Vol. 82: 1013.
- MCDUGALL, S. & HUNGR, O. 2005. Dynamic modelling of entrainment in rapid landslides. *Canadian Geotechnical Journal*. Vol. 42. N° 5: 1437–1448.
- MCDUGALL, S., 2006. A new continuum dynamic model for the analysis of extremely rapid landslide motion across complex 3D terrain. Ph.D. Dissertation. University of British Columbia. Vancouver, Canada, 253pp.
- PASTOR, M.; QUECEDO, M.; MERODO, J. A. F.; HERRORES, M. I.; GONZÁLEZ, E. & MIRA, P. 2002. Modelling tailings dams and mine waste dumps failures. *Géotechnique*. Vol. 52. N°8: 579– 591.
- PIRULLI, M. & MARCO, F. 2010. Description and numerical modelling of the October 2000 Nora debris flow, Northwestern Italian Alps. *Canadian Geotechnical Journal*. Vol. 47. N° 2: 135– 146.

## ANEXO 2 - GLOSARIO DE TÉRMINOS

A continuación, se definen diversos términos y conceptos útiles para el presente estudio y para la evaluación de riesgo por movimientos en masa de forma general. Esto con el fin de hacer más comprensible el vocabulario utilizado en el desarrollo de este trabajo, y a la vez desambiguar conceptos para comprender de forma adecuada los objetivos, límites y alcances de este estudio.

Las definiciones fueron extraídas sin modificaciones a partir de 3 fuentes bibliográficas: Libro Movimientos en Masa en la Región Andina: Una Guía para la Evaluación de Amenazas (Proyecto Multinacional Andino, 2007), Guía Metodológica para Estudios de Amenaza, Vulnerabilidad y Riesgo por Movimientos en Masa (Servicio Geológico Colombiano, 2015), la Guía Metodológica para la Elaboración de Mapas de Susceptibilidad a las Remociones en Masa a Escala Regional (Arenas & Opazo, 2017) y la Política Nacional para la Gestión de Riesgos de Desastres (ONEMI, 2014).

**Amenaza:** Peligro latente de que un evento físico de origen natural, o causado, o inducido por la acción humana de modo accidental, se presente con una severidad suficiente para causar pérdida de vidas, lesiones u otros impactos en la salud, así como también daños y pérdidas en los bienes, la infraestructura, los medios de sustento, la prestación de servicios y los recursos ambientales. La caracterización de la amenaza debe incluir su ubicación, clasificación, magnitud o intensidad, y se evalúa en función de probabilidad de ocurrencia espacial y temporal. La magnitud o intensidad de la amenaza se pueden expresar en términos de volumen, área, velocidad, intensidad o energía.

**Condicionante:** Sinónimo de contribuyente. Se refiere a todos aquellos factores naturales o antrópicos que condicionan o contribuyen a la inestabilidad de una ladera o talud, pero que no constituyen el evento detonante del movimiento.

**Detonante:** Sinónimo de disparador, desencadenante, gatillante. Acción, o evento natural o antrópico, que es la causa directa e inmediata de un movimiento en masa. Entre ellos pueden estar, por ejemplo, los terremotos, la lluvia, la excavación del pie de una ladera y la sobrecarga de una ladera.

**Elementos expuestos:** Se refiere a las personas, medios de subsistencia, servicios ambientales y recursos económicos y sociales, bienes culturales e infraestructura que por su localización pueden ser afectados por la manifestación de una amenaza.

**Fragilidad:** Nivel de daño que un elemento dado puede sufrir luego de estar sometido a la acción de un movimiento en masa. Para bienes materiales, este nivel de daño está relacionado con el valor de las pérdidas relativo al valor de la propiedad; para personas, el nivel de daño se relaciona con la pérdida de vidas humanas y las lesiones físicas sufridas producto de un evento.

**Intervención correctiva:** Proceso cuyo objetivo es reducir el nivel de riesgo existente en la sociedad a través de acciones de mitigación.

**Intervención prospectiva:** Proceso cuyo objetivo es garantizar que no surjan nuevas situaciones de riesgo por medio de acciones de prevención, impidiendo que los elementos expuestos sean vulnerables o que lleguen a estar expuestos ante posibles eventos peligrosos. Su objetivo último es evitar un nuevo riesgo y la necesidad de intervenciones correctivas en el futuro.

**Inventario de movimientos en masa:** Conjunto de datos que identifican, caracterizan y clasifican sistemáticamente los movimientos en masa ocurridos en una región dada. Los mapas de inventario muestran la localización, área y características generales de los movimientos.

**Mapa de amenaza:** Mapa que muestra mediante una simbología apropiada la distribución espacial de las clases de amenaza o de la zonificación de la amenaza.

**Mapa inventario:** Mapa en donde se localizan geográficamente los movimientos en masa que han ocurrido en una región y se identifican sus características mediante una simbología apropiada.

**Material desplazado:** Material desplazado de su posición original en una ladera o talud debido al movimiento en masa. Está conformado por la masa desplazada y la acumulación.

**Mitigación del riesgo:** Aplicación selectiva de medidas apropiadas y principios de manejo para reducir la posibilidad de la ocurrencia de un evento o de sus consecuencias desfavorables. Dichas medidas de intervención prospectiva o correctiva están dirigidas a reducir o disminuir los daños y pérdidas que se puedan presentar a través de reglamentos de seguridad y proyectos

de inversión pública o privada, cuyo objetivo es reducir las condiciones de amenaza cuando sea posible y la vulnerabilidad existente.

**Peligro:** Sinónimo de amenaza.

**Período de retorno:** Tiempo promedio entre dos eventos de iguales características que han ocurrido en el pasado.

**Riesgo:** Probabilidad de consecuencias perjudiciales o pérdidas esperadas (muertes, lesiones, propiedad, medios de subsistencia, interrupción de actividad económica o deterioro ambiental) resultado de interacciones entre amenazas de origen natural o antropogénicas y condiciones de vulnerabilidad.

**Riesgo de Desastres:** Posibles pérdidas que ocasionaría un desastre en términos de vidas, las condiciones de salud, los medios de sustento, los bienes y los servicios, y que podrían ocurrir en una comunidad o sociedad particular en un período específico de tiempo en el futuro.

**Riesgo específico:** Cálculo de pérdidas de cualquier tipo que se expresan como proporción del riesgo total. Este cálculo está definido en un periodo de referencia, una región y para una amenaza particular. El riesgo específico también se usa para definir las pérdidas financieras a la propiedad, en cuyo caso se refiere generalmente al coeficiente del costo de reparación o reinstauración de la propiedad, según el costo de remplazo total.

**Susceptibilidad de remociones en masa:** Propensión de un área determinada a ser afectada por la ocurrencia de un cierto tipo de remociones en masa, ya sea en el lugar que se generan o las áreas que éstas se propagan (zonas de alcance). Corresponde a una característica espacial del territorio y no guarda relación con la frecuencia ni la probabilidad temporal de ocurrencia de un movimiento en masa.

**Trayectoria:** Se refiere al curso de un movimiento en masa, el cual se divide en zona de arranque o iniciación, zona de transporte o propagación y zona de acumulación o depositación. El término *runout* en inglés, se emplea en diferentes contextos, ya sea para referirse a la zona de acumulación (*runout zone*) o a la distancia de viaje o transporte (*runout distance*).

**Vulnerabilidad:** Susceptibilidad o fragilidad física, económica, social, ambiental o institucional que tiene una comunidad de ser afectada o de sufrir efectos adversos en caso de que un

evento físico peligroso se presente. Corresponde a la predisposición a sufrir pérdidas o daños de los seres humanos y sus medios de subsistencia, así como de sus sistemas físicos, sociales, económicos y de apoyo que pueden ser afectados por eventos físicos peligrosos.

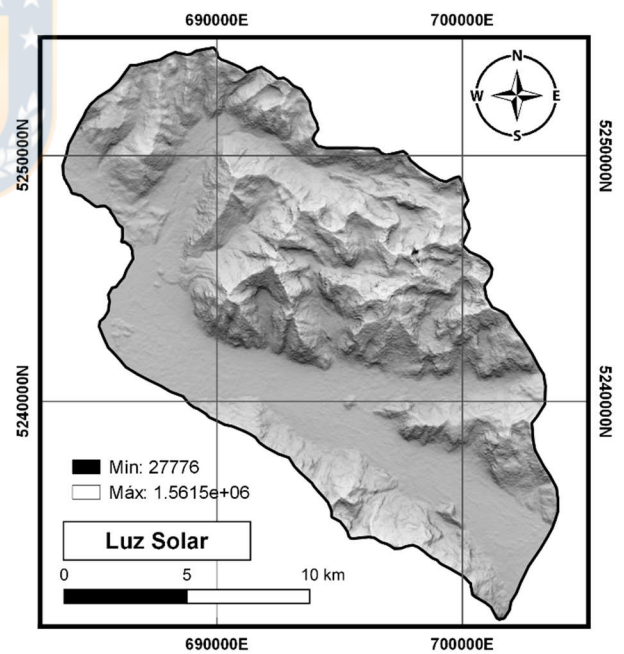
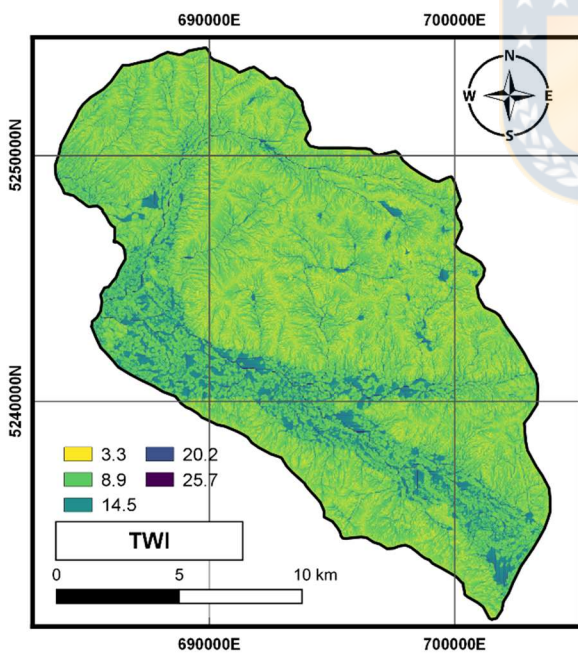

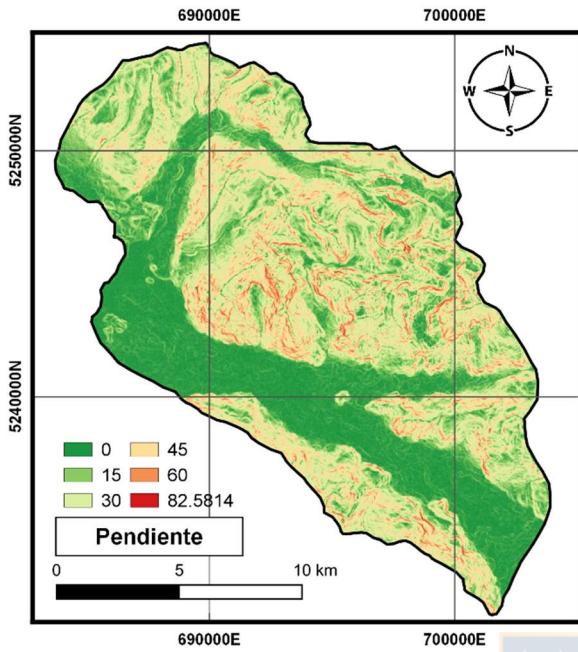
**Zona de arranque:** Sinónimo de zona de despegue, zona de desprendimiento. Área dentro de la cual el material desplazado se encuentra por debajo de la superficie original del terreno.

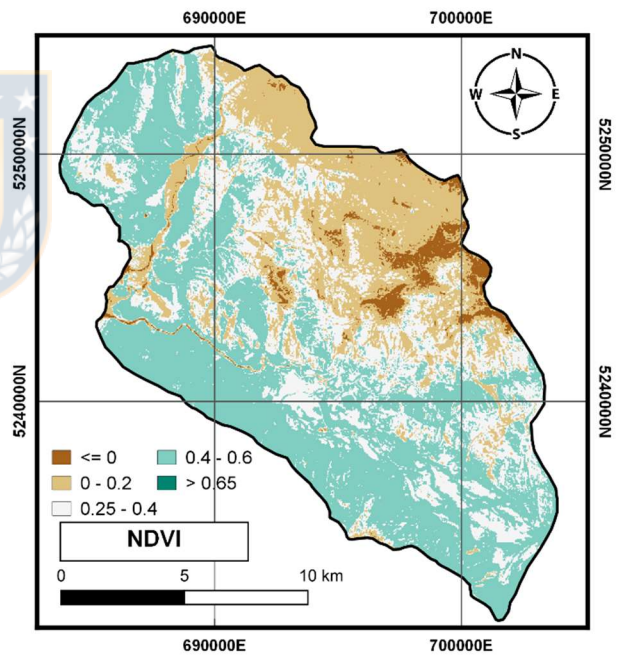
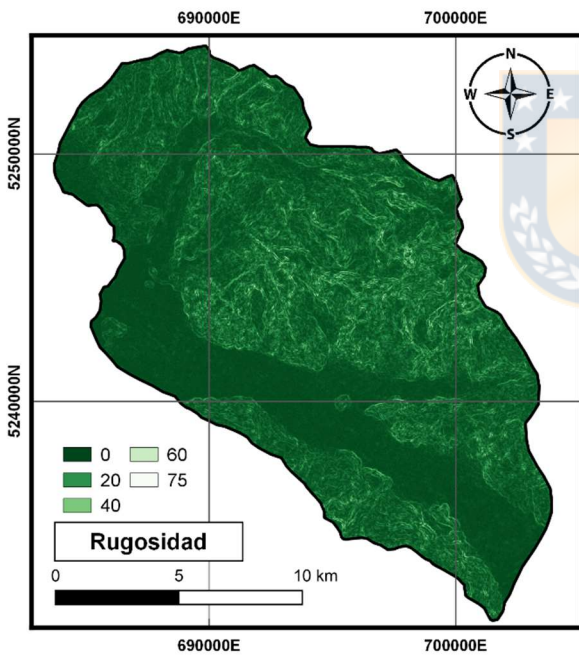

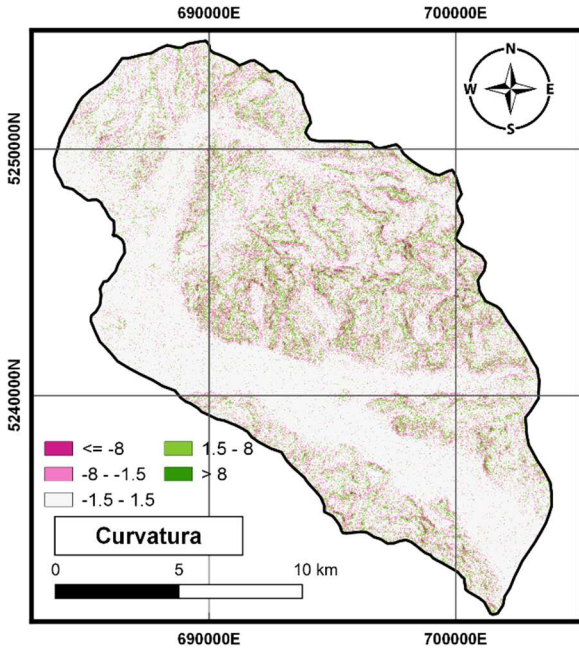
**Zona de acumulación:** Área de un movimiento en masa en la cual el material desplazado queda sobre la superficie original del terreno.

## REFERENCIAS

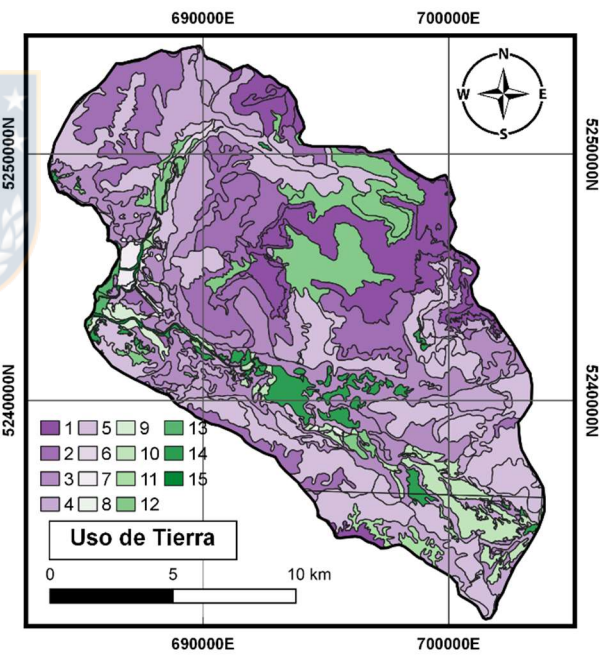
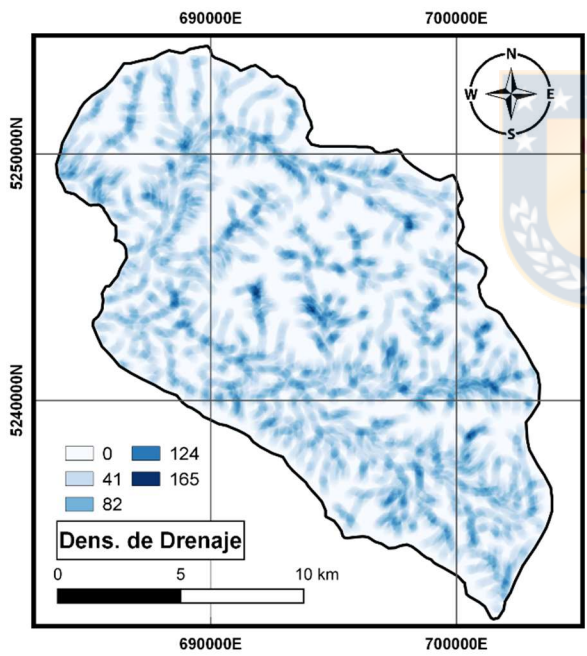


- ARENAS, M. & OPAZO, E. 2017. Guía Metodológica para la Elaboración de Mapas de Susceptibilidad a las Remociones en Masa a Escala Regional. Servicio Nacional de Geología y Minería. 65pp.
- ONEMI. 2014. Política Nacional para la Gestión de Riesgo de Desastres. Comunicaciones ONEMI. Chile.
- SERVICIO GEOLÓGICO COLOMBIANO. 2015. Guía metodológica para la zonificación de amenaza por movimientos en masa escala 1: 25.000. Dirección de Geoamenazas. Grupo de Evaluación de Amenaza por Movimientos en Masa. Bogotá, D. C., Colombia.
- 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

## ANEXO 3 – VARIABLES PRESELECCIONADAS









# ANEXO 4 – FICHAS DE TERRENO “STORME”

<b>Catastro de Eventos Peligros Naturales</b>	<b>Datos básicos</b>	Página 1/3
---	----------------------	------------

celda a llenar                      M = Conocimiento preciso                      A = Estimación                      O = no determinable

<b>Tipo de Proceso</b>	<input type="checkbox"/> Avalancha	<input type="checkbox"/> Caída de Roca	<input checked="" type="checkbox"/> Deslizamiento	<input type="checkbox"/> Inundación/Aluvión
------------------------	------------------------------------	--	---	---

### Información Básica

Comuna: CHAITÉN                      Lugares específicos: SALTO "LA SILLA"  
 Cauce: ARROYO S/N

Fecha: <input type="text" value="A"/> - <input type="text" value="JUN"/> . 2014	Hora: <input type="text" value="A"/> : <input type="text" value="4"/> : <input type="text" value="0"/> Duración: <input type="text" value="0"/> d - <input type="text" value=""/> h - <input type="text" value=""/> min
---	---

Coordenadas límites arriba:	X / Y =	<input type="text" value="696 271"/>	/	<input type="text" value="5 242 965"/>	Z =	<input type="text" value="1000"/>
Coordenadas límites abajo:	X / Y =	<input type="text" value="695 526"/>	/	<input type="text" value="5 240 835"/>	Z =	<input type="text" value="22"/>
Coordenadas Centro:	X / Y =	<input type="text" value="696 206"/>	/	<input type="text" value="5 241 924"/>		
Fecha Levantamiento:	<input type="text" value="10"/> . <input type="text" value="FEB"/> . 2020					
Levantado por (Nombre, Dirección, Tel, Correo electrónico)	ELIZABETH SANDOVAL FRITZ					

### Daños

<b>Personas/ Animales</b>			# Muertos		# Heridos		# Evacuados
	Personas	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Animales	<input type="text" value="A"/>	<input type="text" value="0"/>	<input type="text" value="A"/>	<input type="text" value="0"/>	<input type="text" value="A"/>	<input type="text" value="0"/>
<b>Bienes</b>			# destruido		# dañado		Daño [\$]
	Residencias	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Industria, Comercios, Hoteles	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Edificio con fines agrícolas	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Edificios públicos e infraestructuras	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Obras de protección	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Otros (Descripción en Memo)	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
<b>Infraestructura</b>			derramado [m]		Interrupción [h]		Daño [\$]
	Autopista Nacional	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Carretera Principal	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Otras Calles	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Línea Ferrocarril	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Instalación transportadora, Torres eléctricas	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Cañería	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
Otros (Descripción en Memo)	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
<b>Bosque / Agricultura</b>			Area afectada[a]		Madera dañada [m <sup>3</sup> ]		Daño [\$]
	Bosque	<input type="text" value="A"/>	<input type="text" value="494000"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Superficie Agrícola	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>
	Otros (Descripción en Memo)	<input type="text" value=""/>	<input type="text" value=""/>	<input type="text" value=""/>	<input type="text" value=""/>	<input type="text" value=""/>	<input type="text" value=""/>

<b>Storme</b>	Número Interno: <input style="width: 100%;" type="text"/>	Número catastro de eventos: <input style="width: 100%;" type="text"/>
---------------	---	---

**Daños** (Continuación)

**Memo (Descripción del daño)**

Se ve destruida abundante vegetación nativa la cual fue tanto removida como parte del deslizamiento, y también arrasada por el mismo. Entre las especies afectadas se puede mencionar la pérdida de: Tenío, Tapa, Ciruelillo, Coihue, Tiaca, Ulmo, Tepú, Mañío y Arrayán. Así también Coihue y Alerce, los cuales tienen a ubicarse en la parte superiores de las laderas.

**Obras de protección**

Existente en zona de arranque?	<input type="checkbox"/> No	Número catastro de obras de protección:	<input type="text" value="0"/>
Existente en zona de tránsito?	<input type="checkbox"/> No	Número catastro de obras de protección:	<input type="text" value="0"/>
Existente en zona de depósito?	<input type="checkbox"/> No	Número catastro de obras de protección:	<input type="text" value="0"/>

**Memo (Descripción aptitud de protección y medidas)**

Tipo de obras de protección, condición, aptitud de protección, peligros remanentes y nuevos, obras de complemento, costos, otros  
 No existen medidas de protección en la zona, ya que se trata de un área alejada de infraestructura y asentamientos humanos.

**Documentación**

Nombre, Dirección de la fuente, Número del estudio, imágenes etc.

- Nota, estudio, informe, cálculos
- Diarios, Literatura, referencias históricas
- Documentación de fotos
- Orthofotos, imagen aérea
- Video, película
- Datos meteorológicos

**Mapeo**

Zona de proceso cartografiado?

**Metodología**

**Zona de arranque:**

**Zona de deposición:**

- |  |   |
|--|---|
| <input type="checkbox"/> en terreno  | <input checked="" type="checkbox"/> en terreno  |
| <input checked="" type="checkbox"/> Imágenes aéreas, Fotos                 | <input checked="" type="checkbox"/> Imágenes aéreas, Fotos                            |
| <input type="checkbox"/> Observación a distancia (de la pendiente opuesta) | <input checked="" type="checkbox"/> Observación a distancia (de la pendiente opuesta) |
| <input type="checkbox"/> Otro levantamiento retrospectivo                  | <input type="checkbox"/> Otro levantamiento retrospectivo                             |

**StorMe**      Número Interno:       Número catastro de eventos:

**Catastro de Evento Peligros Nat** **Deslizamiento** **Página 3/3**

Celda a llenar      **M = Conocimiento preciso**      **A = Estimación**      **O = no determinable**

**Tipo de Proceso**       Deslizamiento       Deslizamiento fluidizado       Subsistencia

**Otros procesos acompañantes**

Inundación       Aluvión       Erosión de taludes       Otro (descripción en memo)  
 Sedimentación       Deslizamiento       Caída de roca/derrumbe

**Causa Meteo**

**Tormenta**

Duración [h]        
 Precipitación [mm]     

**Lluvia continua**

Duración [h]        
 Precipitación [mm]     

Deshielo       No determinable

**Causa desencadenante**

Calificación causa desencadenante:

Natural       Artificial, provocado por hombre  
 Por erosión en cauce       Otro (descripción en memo)

**Zona de Arranque del proceso**

Profundidad del área de arranque        1 [m]

Profundidad de subsidencia       [m<sup>2</sup>]

Ancho del área de arranque       - [m]

Área de arranque       [m<sup>2</sup>]

Masa en movimiento        Roca  
  Escombros

Superficie de deslizamiento        Roca  
  Escombros

**Zona de depósito / de tránsito**

Profundidad de depósitos        1.5 [m]  
 Volumen deslizado       - [m<sup>3</sup>]

Profundidad del área de tránsito       0 - 2 m (superficial)  
 2 - 10 m (mediano)  
 > 10 m (profundo)

Transición de deslizamiento a deslizamiento fluidizado?       Sí       No

Deposición en cauce?        Sí       No       lento (2 - 10 cm/a)  
 Obstrucción del cauce?        No       subestable, muy lento (< 2 cm/a)

**Memo (Descripción del evento en texto):**

Salidas del agua, todos los procesos ocurridos y si fueron artificiales o naturales. Desencadenante: descripción del proceso gatillado, comportamiento hidrológico, situación previa al evento, comparación con eventos anteriores, etc.

Previo al evento existía un salto de agua de caudal similar al actual, el cual después se traslada lateralmente al Este, a la posición actual del salto. El evento ocurrió en invierno del año 2014 aprox., luego de unos 5 días de lluvia continua. El área de arranque ubicada en las partes altas de la montaña corresponde a numerosos orígenes de remoción de material (suelo) que convergen y al transportarse ladera abajo provocan el arranque de una gran bloque de roca granítica que al descender se disgregó en bloques de diversos tamaños, que con el avance del deslizamiento ladera abajo adoptaron un comportamiento fluidizado, evidenciado por la disposición y características del depósito observado.

Se pueden apreciar enormes bloques (máx 35x10 m aprox) en la parte proximal del depósito, en una matriz también compuesta por bloques menores (~7m), lo cual al descender va variando progresivamente, observándose un mayor porcentaje de matriz (~90%), con bloques más pequeños (~1m). En los bordes del depósito se observa un abultamiento y concentración de material removido (Troncos + Bloques), lo que correspondería a "Levees". En el borde Oeste los bloques son más grandes con respecto a los del Este (~2x2x2m). En forma generalizada, el borde del depósito tiene una altura cercana a los 2m. Gran parte del depósito, que se observa como una planicie, corresponde a una matriz de arena gruesa (~90%) con gravas, bloques y restos de troncos "incrustados".

celda a llenar M = Conocimiento preciso A = Estimación O = no determinable

**Tipo de Proceso**  Avalancha  Caída de Roca  Deslizamiento  Inundación/Aluvión

**Información Básica**

Comuna: Chaitén Lugares específicos Río Blanco - Lahar  
 Cauce: Río Blanco

Fecha: A  .  .  Hora: O  .  Duración: O  d  h  min

Coordenadas límites arriba: X / Y =  /  Z =   
 Coordenadas límites abajo: X / Y =  /  Z =   
 Coordenadas Centro: X / Y =  /   
 Fecha Levantamiento:  .  .   
 Levantado por (Nombre, Dirección, Tel, Correo electrónico) ELIZABETH SANDOVAL FRITZ

**Daños**

<b>Personas/ Animales</b>	Personas	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Animales	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
<b>Bienes</b>			# destruido		# dañado		Daño [\$]
	Residencias	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Industria, Comercios, Hoteles	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Edificio con fines agrícolas	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Edificios públicos e infraestructuras	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Obras de protección	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
Otros (Descripción en Memo)	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	
<b>Infraestructura</b>			derramado [m]		Interrupción [h]		Daño [\$]
	Autopista Nacional	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Carretera Principal	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Otras Calles	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Línea Ferrocarril	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
	Instalación transportadora, Torres eléctricas	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O
Cañería	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	
Otros (Descripción en Memo)	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	<input type="checkbox"/> M	<input type="checkbox"/> O	
<b>Bosque / Agricultura</b>			Area afectada[a]		Madera dañada [m³]		Daño [\$]
	Bosque	<input type="checkbox"/> M	<input type="text" value="232000"/>	<input type="checkbox"/> O	<input type="text" value=""/>	<input type="checkbox"/> M	<input type="text" value="0"/>
	Superficie Agrícola	<input type="checkbox"/> M	<input type="text" value="0"/>	<input type="checkbox"/> O	<input type="text" value=""/>	<input type="checkbox"/> M	<input type="text" value=""/>
Otros (Descripción en Memo)	<input type="checkbox"/> M	<input type="text" value=""/>	<input type="checkbox"/> O	<input type="text" value=""/>	<input type="checkbox"/> M	<input type="text" value=""/>	

**StorMe** Número Interno:  Número catastro de eventos:

## Daños

(Continuación)

**Memo (Descripción del daño)**

El principal y casi único daño observado es la pérdida de denso bosque nativo y probablemente fauna nativa.

**Obras de protección**

Existente en zona de arranque?

 No

Número catastro de obras de protección:

-

Existente en zona de tránsito?

 No

Número catastro de obras de protección:

-

Existente en zona de depósito?

 No

Número catastro de obras de protección:

-

**Memo (Descripción aptitud de protección y medidas)**

Tipo de obras de protección, condición, aptitud de protección, peligros remanentes y nuevos, obras de complemento, costos, otros  
No existen medidas de protección

**Documentación**

Nombre, Dirección de la fuente, Número del estudio, imágenes etc.

 Nota, estudio, informe, cálculos Diarios, Literatura, referencias históricas Documentación de fotos

Fotografías de este terreno

 Orthofotos, imagen aérea

Google Maps

 Vídeo, película Datos meteorológicos**Mapeo**

Zona de proceso cartografiado?

**Metodología**

Zona de arranque:

Zona de deposición:

 en terreno en terreno Imágenes aéreas, Fotos Imágenes aéreas, Fotos Observación a distancia (de la pendiente opuesta) Observación a distancia (de la pendiente opuesta) Otro levantamiento retrospectivo Otro levantamiento retrospectivo**StorMe**

Número Interno:

Número catastro de eventos:



Catastro de Eventos Peligros Naturales **Datos básicos** Página 1/3

celda a llenar M = Conocimiento preciso A = Estimación O = no determinable

**Tipo de Proceso**  Avalancha  Caída de Roca  Deslizamiento  Inundación/Aluvión

**Información Básica**

Comuna: Chaitén  Lugares específicos Río Negro, Áridos Schilling  
 Cauce: Río Negro

Fecha:   .  .  Hora:   .  Duración:   d  h  min

Coordenadas límites arriba: X / Y =  /  Z =   
 Coordenadas límites abajo: X / Y =  /  Z =   
 Coordenadas Centro: X / Y =  /   
 Fecha Levantamiento:  .  .   
 Levantado por (Nombre, Dirección, Tel, Correo electrónico) ELIZABETH SANDOVAL FRITZ

**Daños**

<i>Personas/ Animales</i>		# Muertos		# Heridos		# Evacuados	
Personas	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Animales	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	

<i>Bienes</i>		# destruido		# dañado		Daño [\$]	
Residencias	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Industria, Comercios, Hoteles	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Edificio con fines agrícolas	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Edificios públicos e infraestructuras	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Obras de protección	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Otros (Descripción en Memo)	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	

<i>Infraestructura</i>		derramado [m]		Interrupción [h]		Daño [\$]	
Autopista Nacional	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Carretera Principal	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Otras Calles	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Línea Ferrocarril	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Instalación transportadora, Torres eléctricas	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Cañería	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Otros (Descripción en Memo)	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	

<i>Bosque / Agricultura</i>		Area afectada[a]		Madera dañada [m³]		Daño [\$]	
Bosque	<input type="text" value="M"/>	<input type="text" value="53700"/>	<input type="text" value="O"/>	<input type="text" value="-"/>	<input type="text" value="M"/>	<input type="text" value="0"/>	
Superficie Agrícola	<input type="text" value="M"/>	<input type="text" value="0"/>	<input type="text" value="O"/>	<input type="text" value=""/>	<input type="text" value="M"/>	<input type="text" value=""/>	
Otros (Descripción en Memo)	<input type="text" value="M"/>	<input type="text" value=""/>	<input type="text" value="O"/>	<input type="text" value=""/>	<input type="text" value="M"/>	<input type="text" value=""/>	

**StorMe** Número Interno:  Número catastro de eventos:



## Daños

(Continuación)

**Memo (Descripción del daño)**

No existe daño de bienes ni infraestructura. Sólo hay pérdida de bosque y vegetación nativa.

**Obras de protección**

Existente en zona de arranque?

 No

Número catastro de obras de protección:

-

Existente en zona de tránsito?

 No

Número catastro de obras de protección:

-

Existente en zona de depósito?

 No

Número catastro de obras de protección:

-

**Memo (Descripción aptitud de protección y medidas)**

Tipo de obras de protección, condición, aptitud de protección, peligros remanentes y nuevos, obras de complemento, costos, otros  
No existen medidas de protección en el lugar.

**Documentación**

Nombre, Dirección de la fuente, Número del estudio, imágenes etc.

 Nota, estudio, informe, cálculos Diarios, Literatura, referencias históricas

Testimonios de Patricio Echeverría y Teresita Montecino

 Documentación de fotos

Fotografías de este terreno

 Orthofotos, imagen aérea

Google Maps, Drone en terreno.

 Vídeo, película Datos meteorológicos**Mapeo**

Zona de proceso cartografiado?

**Metodología**

Zona de arranque:

Zona de deposición:

 en terreno en terreno Imágenes aéreas, Fotos Imágenes aéreas, Fotos Observación a distancia (de la pendiente opuesta) Observación a distancia (de la pendiente opuesta) Otro levantamiento retrospectivo Otro levantamiento retrospectivo

StorMe

Número Interno:

Número catastro de eventos:



**Catastro de Eventos Peligros Naturales** **Datos básicos** **Página 1/3**

celda a llenar      M = Conocimiento preciso      A = Estimación      O = no determinable

**Tipo de Proceso**       Avalancha       Caída de Roca       Deslizamiento       Inundación/Aluvión

**Información Básica**

Comuna: Chaitén      Lugares específicos: Río Negro Km 210, Casa abandonad  
 Cauce: Río Negro

Fecha: M - . 12 . 2019      Hora: A 12 . 0      Duración: O - d - h - min

Coordenadas límites arriba: X / Y = - / -      Z = -  
 Coordenadas límites abajo: X / Y = 693 120 / 5 241 452      Z = 46  
 Coordenadas Centro: X / Y = - / -  
 Fecha Levantamiento: 12 . FEB . 2020

Levantado por (Nombre, Dirección, Tel, Correo electrónico) ELIZABETH SANDOVAL - ANDREA SEGURA

**Daños**

<i>Personas/ Animales</i>		# Muertos		# Heridos		# Evacuados	
Personas	M	0	M	0	M	0	
Animales	M	0	M	0	M	0	

<i>Bienes</i>		# destruido		# dañado		Daño [\$]	
Residencias	M	0	M	0	M	0	
Industria, Comercios, Hoteles	M	0	M	0	M	0	
Edificio con fines agrícolas	M	0	M	0	M	0	
Edificios públicos e infraestructuras	M	0	M	0	M	0	
Obras de protección	M	0	M	0	M	0	
Otros (Descripción en Memo)	M	0	M	0	M	0	

<i>Infraestructura</i>		derramado [m]		Interrupción [h]		Daño [\$]	
Autopista Nacional	M	0	M	0	M	0	
Carretera Principal	M	0	M	0	M	0	
Otras Calles	M	0	M	0	M	0	
Línea Ferrocarril	M	0	M	0	M	0	
Instalación transportadora, Torres eléctricas	M	0	M	0	M	0	
Cañería	M	0	M	0	M	0	
Otros (Descripción en Memo)	M	0	M	0	M	0	

<i>Bosque / Agricultura</i>		Area afectada[a]		Madera dañada [m³]		Daño [\$]	
Bosque	A	35000	O	-	M	0	
Superficie Agrícola	M	0					
Otros (Descripción en Memo)							

**StorMe**      Número Interno:       Número catastro de eventos:

## Daños

(Continuación)

**Memo (Descripción del daño)**

No hay daños a bienes ni infraestructura. Sólo pérdida de bosque nativo.

**Obras de protección**

Existente en zona de arranque?

 No

Número catastro de obras de protección:

-

Existente en zona de tránsito?

 No

Número catastro de obras de protección:

-

Existente en zona de depósito?

 No

Número catastro de obras de protección:

-

**Memo (Descripción aptitud de protección y medidas)**

Tipo de obras de protección, condición, aptitud de protección, peligros remanentes y nuevos, obras de complemento, costos, otros  
No existen obras de protección.

**Documentación**

Nombre, Dirección de la fuente, Número del estudio, imágenes etc.

 Nota, estudio, informe, cálculos Diarios, Literatura, referencias históricas

Patricio Echeverría

 Documentación de fotos

Fotografías de este terreno

 Orthofotos, imagen aérea Vídeo, película Datos meteorológicos**Mapeo**

Zona de proceso cartografiado?

**Metodología**

Zona de arranque:

Zona de deposición:

 en terreno en terreno Imágenes aéreas, Fotos Imágenes aéreas, Fotos Observación a distancia (de la pendiente opuesta) Observación a distancia (de la pendiente opuesta) Otro levantamiento retrospectivo Otro levantamiento retrospectivo

StorMe

Número Interno:

Número catastro de eventos:

**Catastro de Evento Peligros Nat** **Deslizamiento** **Página 3/3**

Celda a llenar      **M = Conocimiento preciso**      **A = Estimación**      **O = no determinable**

**Tipo de Proceso**       Deslizamiento       Deslizamiento fluidizado       Subsistencia

**Otros procesos acompañantes**

Inundación       Aluvión       Erosión de taludes       Otro (descripción en memo)  
 Sedimentación       Deslizamiento       Caída de roca/derrumbe

**Causa Meteo**

Deshielo       No determinable

**Tormenta**

Duración [h]  
 Precipitación [mm]

**Lluvia continua**

96 Duración [h]  
 - Precipitación [mm]

**Causa desencadenante**

Calificación causa desencadenante:

Natural       Artificial, provocado por hombre  
 Por erosión en cauce       Otro (descripción en memo)

**Zona de Arranque del proceso**

Profundidad del área de arranque  1 [m]

Profundidad de subsidencia  [m<sup>2</sup>]

Masa en movimiento  Roca  
 Escombros

Ancho del área de arranque  [m]

Área de arranque  [m<sup>2</sup>]

Superficie de deslizamiento  Roca  
 Escombros

**Zona de depósito / de tránsito**

Profundidad de depósitos  - [m]  
 Volumen deslizado  - [m<sup>3</sup>]

Profundidad del área de tránsito  0 - 2 m (superficial)  
 2 - 10 m (mediano)  
 > 10 m (profundo)

Transición de deslizamiento a deslizamiento fluidizado?  Sí

Velocidad  rápido (> 10 cm/a)  
 lento (2 - 10 cm/a)  
 subestable, muy lento (< 2 cm/a)

Depositación en cauce?  Sí

Obstrucción del cauce?  Sí

**Memo (Descripción del evento en texto):**

Salidas del agua, todos los procesos ocurridos y si fueron artificiales o naturales. Desencadenante: descripción del proceso gatillado, comportamiento hidrológico, situación previa al evento, comparación con eventos anteriores, etc.

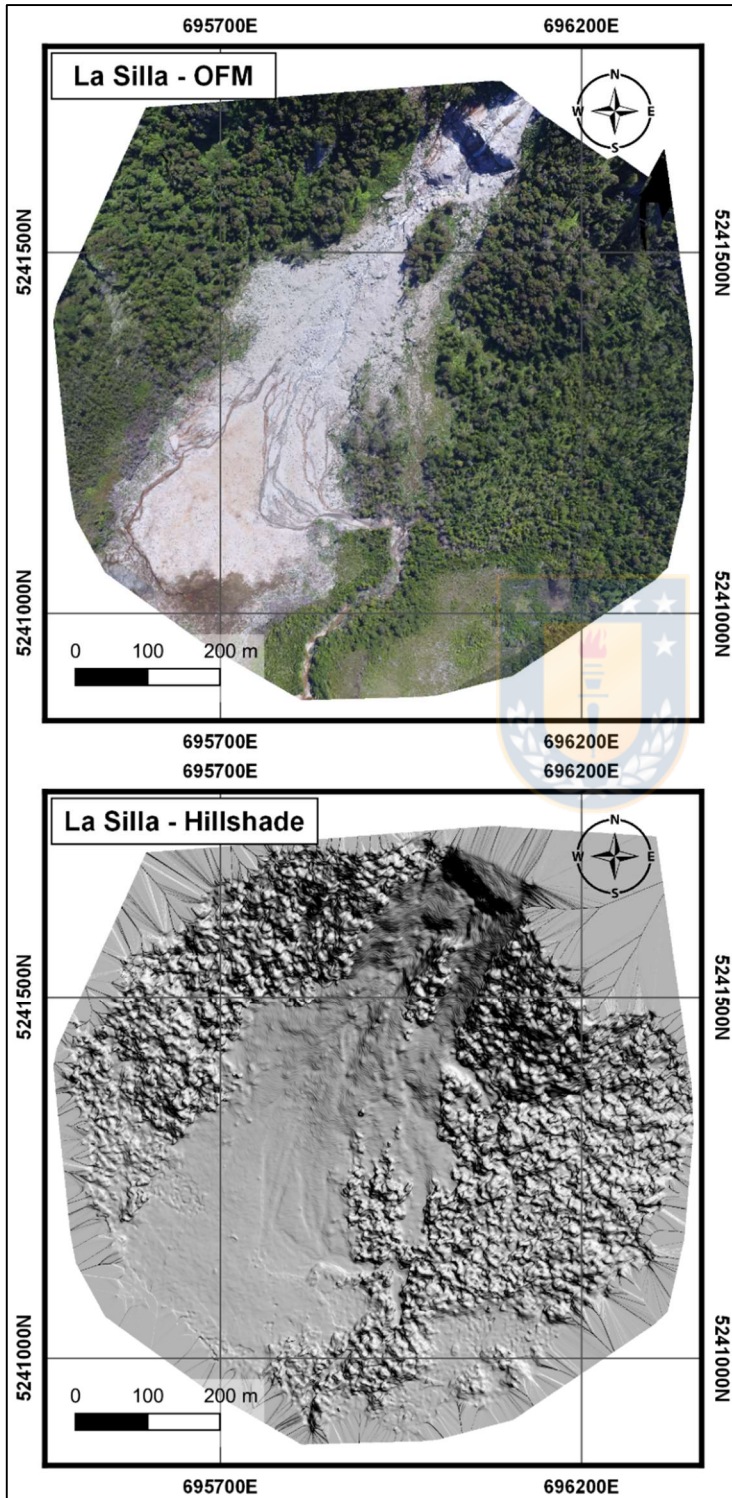
Deslizamiento de suelo, material removido corresponde a suelo (~1m de espesor) y árboles. Superficie de deslizamiento corresponde a roca. No logramos ver el depósito. Condiciones del terreno + clima nos impiden acercarnos. Hay fotografías en ambas cámaras. Características muy similares a deslizamiento Schilling. Datos de ocurrencia se consultarán con Don Patricio. Simensiones menores a deslizamiento Schilling, aproximadamente 1/3 menso de altura. No es posible hacer vuelo con dron. El evento es muy reciente, por lo que no se puede ver en Google Maps

La depositación del material removido produjo un "tranque" en el cauca del río momentáneamente, lo que provocó un desplazamiento de éste, inundando parte del terreno donde se ubica una pequeña casa ya abandonada actualmente. Luego, el río recuperó el mismo curso que seguía antes del evento. Esto ocurrió en Diciembre de 2019, aproximadamente a las 12pm (mediodía).

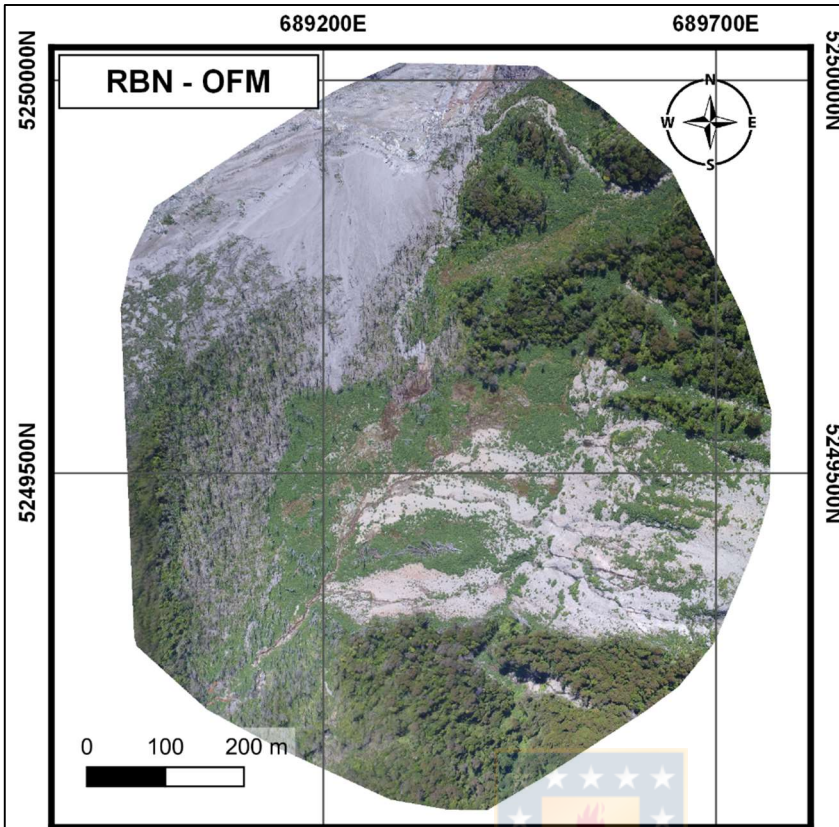
NOTA: Don Patricio y otros lugaremos dicen que los depósitos de las corridas que ocurren en ésta ladera se "entierran" o son "tragados" por el mallín, ya que el gran volumen removido del cerro no se nota o no se encuentra en los pies del cerro en la zona del depósito. Es decir, el depósito no logra reflejar el volumen deslizado.

**StorMe 2.0**      Número interno:       Número catastro de eventos:

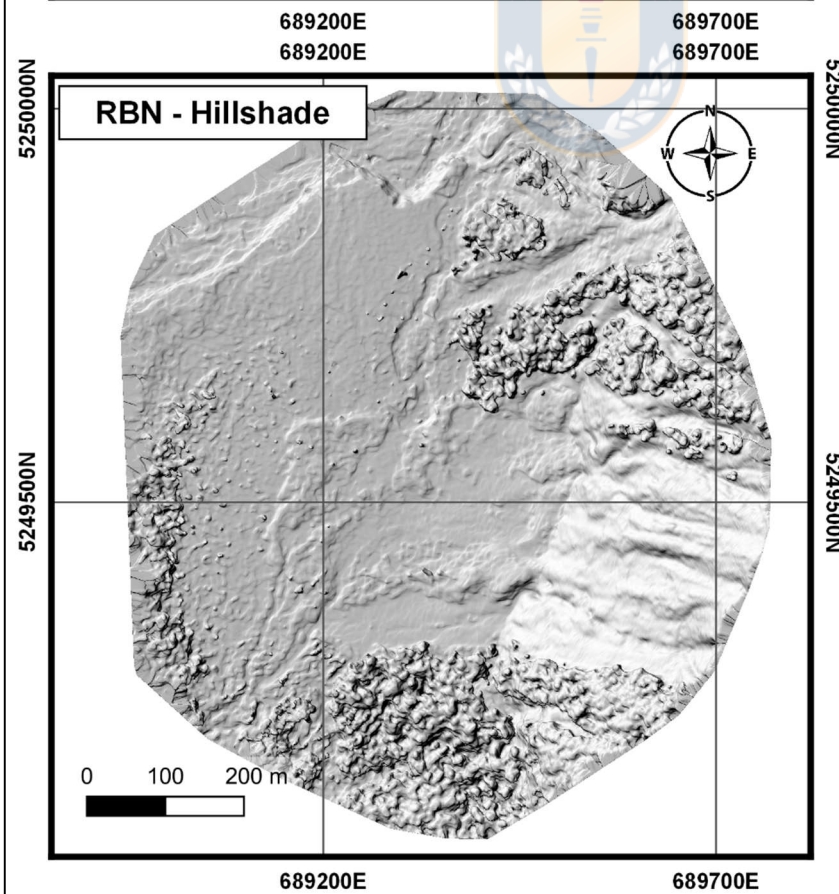
# ANEXO 5 – FOTOGRAFÍA Y FOTOGRAMETRÍA AÉREA EN TERRENO

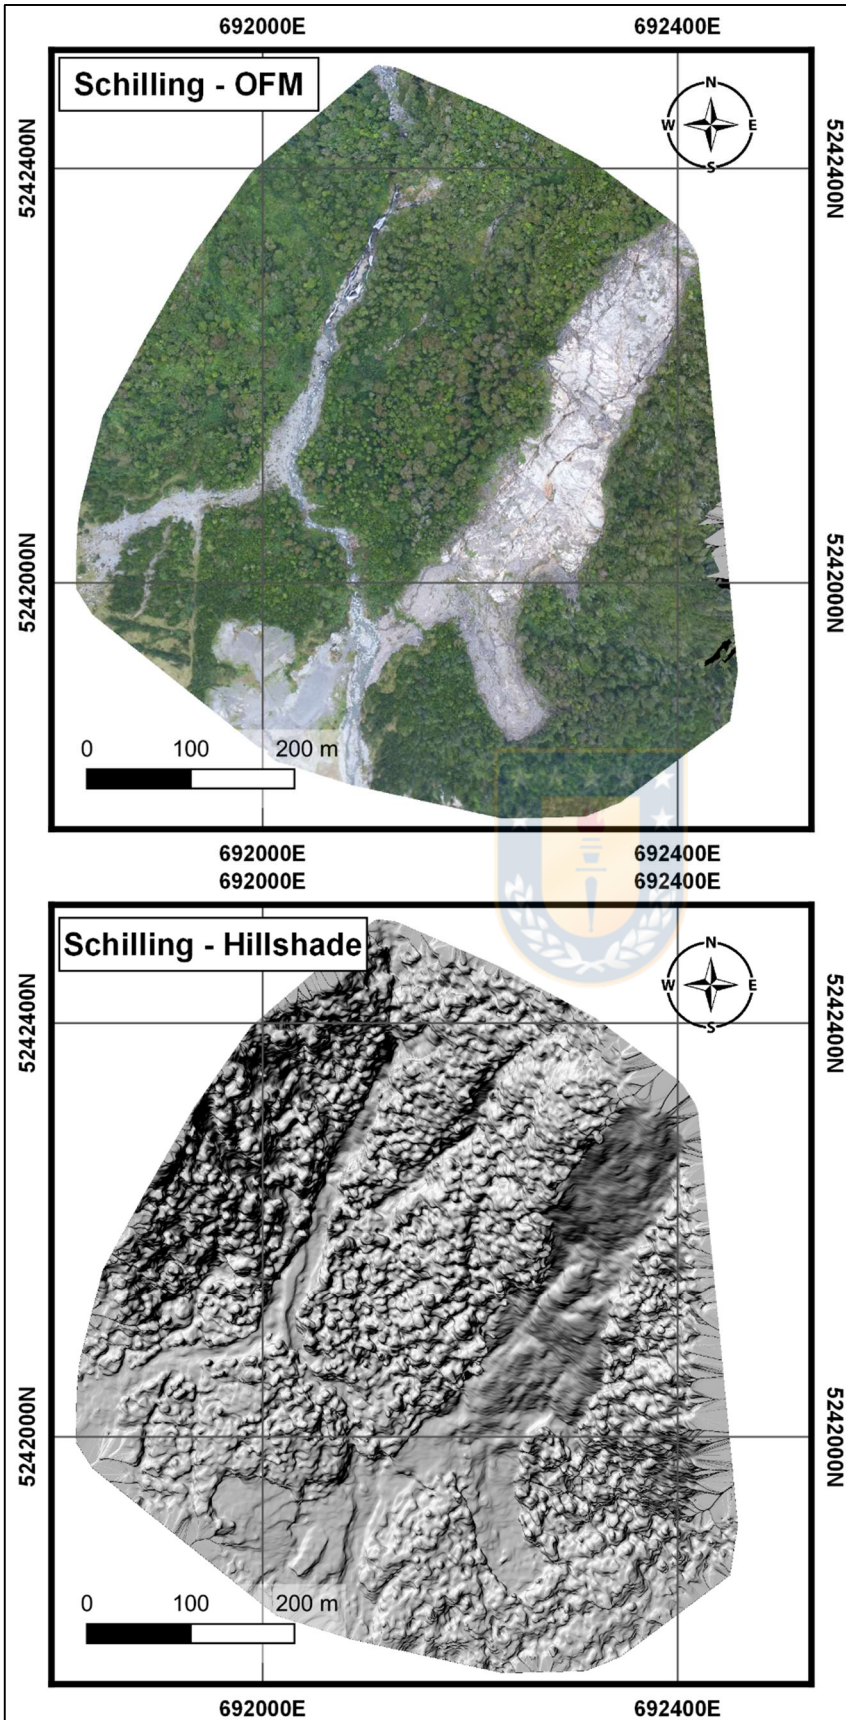


**Deslizamiento La Silla:**  
Ortofotomosaico y Mapa de  
sombras del DTM obtenido.



**Deslizamiento Río Blanco Norte:**  
Ortofotomosaico y Mapa de  
sombras del DTM obtenido.





**Deslizamiento Schilling:**  
Ortofotomosaico y Mapa de sombras del DTM obtenido.