

Universidad Internacional de La Rioja (UNIR)

ESIT

Máster Universitario en Inteligencia Artificial

Predicción de deslizamientos desencadenados por lluvias con métodos de inteligencia artificial

Trabajo Fin de Máster

Presentado por: Chahua Janampa, Jhon Elvis

Director/a: Gallego Gómez, Jenaro

Ciudad: Lima, Perú
Fecha: 23.02.2022

Resumen

Debido a la fisiografía del territorio peruano, este se encuentra expuesto a diversos eventos naturales, tales como inundaciones, flujos, deslizamientos, etc. Este último es activado principalmente por las lluvias, por lo cual surge la necesidad de contar con instrumentos metodológicos para la generación de escenarios de susceptibilidad a deslizamientos. En ese sentido se ha desarrollado un modelo basado con métodos de inteligencia artificial para la generación de escenarios a escala regional. Se emplearon métodos de aprendizaje automático para relacionar los factores condicionantes del terreno; los pronósticos de lluvia, de la entidad oficial, como factor desencadenante; y el inventario nacional de deslizamientos del departamento de Ancash para el entrenamiento y validación del modelo. Finalmente, se obtuvo que el modelo de red neuronal con 2 capas ocultas presentó un mejor comportamiento con un AUC de 90.5%, en comparación con otras estructuras de red neuronal que presentaban valores de AUC inferiores al 89.7%.

Palabras Clave: Escenarios, inteligencia artificial, pronóstico de lluvia, red neuronal, susceptibilidad a deslizamientos.

Abstract

Due to the physiography of the Peruvian territory, it is exposed to various natural events, such as floods, flows, landslides, etc. The latter is activated mainly by rains, which is why there is a need to have methodological instruments for the generation of landslide susceptibility scenarios. In this sense, a model based on artificial intelligence methods has been developed to generate scenarios on a regional scale. Machine learning methods were used to relate the conditioning factors of the terrain; the rain forecasts, from the official entity, as a triggering factor; and the national landslide inventory of the department of Ancash for model training and validation. Finally, it was obtained that the neural network model with 2 hidden layers presented a better performance with an AUC of 90.5%, compared to other neural network structures that presented AUC values lower than 89.7%.

Keywords: Artificial intelligence, landslide susceptibility, neural network, rain forecast, scenarios.

Índice de contenidos

1. Introducción.....	1
1.1 Motivación	1
1.2 Planteamiento del trabajo	2
1.3 Estructura de la memoria	2
2. Contexto y estado del arte.....	4
3. Objetivos y metodología de trabajo	6
3.1. Objetivo general.....	6
3.2. Objetivos específicos	6
3.3. Metodología del trabajo	6
4. Identificación de requisitos	8
4.1 Factores condicionantes	8
4.2 Inventario de deslizamientos.....	8
4.3 Pronósticos de lluvia	8
4.4 Métodos de aprendizaje automático.....	9
5. Descripción de la metodología	10
5.1 Preprocesamiento	11
5.1.1 Factores condicionantes a deslizamientos	11
5.1.2 Inventario de deslizamientos.....	11
5.1.3 Pronósticos de lluvia	12
5.2 Procesamiento	12
5.2.1 Susceptibilidad a deslizamiento	12
5.2.2 Predicción de deslizamiento.....	13
6. Evaluación.....	14
7. Conclusiones y trabajo futuro	49
7.1. Conclusiones	49
7.2. Líneas de trabajo futuro	50

Bibliografía	51
Anexos	53
Anexo I. Mapa de ubicación I.....	54
Anexo II. Registro de base de datos	55
Anexo III. Mapa de susceptibilidad	56
Anexo IV. Pronóstico de lluvia	57
Anexo V. Mapa de peligro por deslizamiento	58
Anexo. Artículo de investigación	59

Índice de figuras

Figura 1 Flujograma del procedimiento metodológico..... 10

Figura 2 Mapa de ubicación del área de estudio..... 14

Figura 3 base de datos y factores condicionantes a deslizamientos. 15

Figura 4 Lista de valores de la base de datos para el entrenamiento y validación del modelo.
..... 18

Figura 5 Arquitectura de la red neuronal 1..... 18

Figura 6 Arquitectura de la red neuronal 2..... 19

Figura 7 Arquitectura de la red neuronal 3..... 20

Figura 8 Arquitectura de la red neuronal 4..... 20

Figura 9 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 1. ...
..... 21

Figura 10 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 1. 21

Figura 11 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 2.
..... 22

Figura 12 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 2. ... 22

Figura 13 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 3.
..... 23

Figura 14 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 3. 23

Figura 15 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 4.
..... 24

Figura 16 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 4. 24

Figura 17 Curva ROC y valores de AUC de los modelos de redes neuronales entrenados.
..... 25

Figura 18 Valores del pixel presente en cada capa de factor condicionante. 26

Figura 19 Mapa de susceptibilidad a deslizamientos generado con redes neuronales. 27

Figura 20 Base de datos de deslizamientos sobre niveles de susceptibilidad del territorio.
..... 28

Figura 21 Vista ampliada 1 de los niveles de susceptibilidad del territorio a deslizamientos.29

Figura 22 Vista ampliada 2 de los niveles de susceptibilidad del territorio a deslizamientos.29

Figura 23 Vista ampliada 3 de los niveles de susceptibilidad del territorio a deslizamientos.30

Figura 24 Vista ampliada 4 de los niveles de susceptibilidad del territorio a deslizamientos.30

Figura 25 Vista ampliada 5 de los niveles de susceptibilidad del territorio a deslizamientos.31

Figura 26 Vista ampliada 6 de los niveles de susceptibilidad del territorio a deslizamientos.31

Figura 27 Vista ampliada 7 de los niveles de susceptibilidad del territorio a deslizamientos.32

Figura 28 Vista ampliada 8 de los niveles de susceptibilidad del territorio a deslizamientos.32

Figura 29 Vista ampliada 9 de los niveles de susceptibilidad del territorio a deslizamientos.33

Figura 30 Pronósticos de lluvia del Senamhi.....34

Figura 31 Niveles de peligro de los pronósticos de lluvia de Senamhi.35

Figura 32 Vista ampliada del pronóstico de lluvia en la zona de estudio.35

Figura 33 Mapa de nivel de peligro por pronóstico de lluvia y susceptibilidad del territorio a deslizamientos.36

Figura 34 Esquema de cálculo de nivel de probabilidad a deslizamiento en base a pronósticos de lluvia.....37

Figura 35 Niveles de predicción a deslizamiento por pronóstico de lluvia.38

Figura 36 Vista ampliada 1 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.39

Figura 37 Vista ampliada tridimensional 1 del nivel de peligro por deslizamiento.....39

Figura 38 Vista ampliada 2 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.40

Figura 39	Vista ampliada tridimensional 2 del nivel de peligro por deslizamiento.....	40
Figura 40	Vista ampliada 3 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.	41
Figura 41	Vista ampliada tridimensional 3 del nivel de peligro por deslizamiento.....	41
Figura 42	Vista ampliada 4 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.	42
Figura 43	Vista ampliada tridimensional 4 del nivel de peligro por deslizamiento.....	42
Figura 44	Vista ampliada 5 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.	43
Figura 45	Vista ampliada tridimensional 5 del nivel de peligro por deslizamiento.....	43
Figura 46	Vista ampliada 6 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.	44
Figura 47	Vista ampliada tridimensional 6 del nivel de peligro por deslizamiento.....	44
Figura 48	Vista ampliada 7 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.	45
Figura 49	Vista ampliada tridimensional 7 del nivel de peligro por deslizamiento.....	45
Figura 50	Vista ampliada 8 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.	46
Figura 51	Vista ampliada tridimensional 8 del nivel de peligro por deslizamiento.....	46
Figura 52	Vista ampliada 9 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.	47
Figura 53	Vista ampliada tridimensional 9 del nivel de peligro por deslizamiento.....	47
Figura 54	Esquema final del procedimiento para el cálculo de los niveles de peligro por deslizamiento.	48

1. Introducción

El Perú es considerado como uno de los países de muy alto riesgo a peligros naturales, debido principalmente a sus características geográficas y climáticas, tales como su ubicación en el Cinturón de Fuego del Pacífico, la presencia de placas tectónicas; factores que modifican el clima propio de la zona tropical, como la Cordillera de los Andes, Anticiclón del Pacífico Sur, Corriente Peruana, entre otros. La mayoría de eventos registrados en Perú están relacionados a los factores hidrometeorológicos, geológicos y en menor medida se encuentran los eventos relacionados a los movimientos sísmicos. Considerando lo descrito podemos señalar que la presencia de las lluvias entre los meses de septiembre a mayo, mostrando la mayor cantidad de lluvias en los meses de verano (diciembre a marzo), incrementan la ocurrencia de inundaciones, flujos de detritos, deslizamientos, etc. En vista de ello, surge la necesidad de generar metodologías para la identificación de zonas susceptibles en donde puedan ocurrir estos eventos. Para esto, se ha desarrollado una metodología aplicando métodos de inteligencia artificial para localizar las zonas susceptibles a deslizamientos y por ende la generación de escenarios con pronósticos de lluvia en las que se puede identificar oportunamente las zonas de mayor susceptibilidad a deslizarse a causa de estas.

1.1 Motivación

En Perú, la metodología oficial para la generación de escenarios de riesgo por diversos peligros está desarrollada en base a métodos semicuantitativos utilizando un proceso de análisis jerárquico con la matriz de comparación de pares (Saaty, 1977); así como, el mapa oficial de susceptibilidad a movimientos en masa, el cual está desarrollado con un modelo heurístico multivariado (Villacorta Chambi et al., 2012). Estos métodos al ser semicuantitativos se basan en relaciones subjetivas de los pesos de las variables empleadas para la generación de los mapas de susceptibilidad y escenarios de riesgo, los cuales pueden inducir a sesgos en los resultados de estos productos. La aplicación de métodos cuantitativos basados en inteligencia artificial permitirá que los resultados se muestren de manera objetiva conociendo el porcentaje de error del modelo, lo que conllevaría a identificar con mayor precisión las zonas de mayor susceptibilidad a deslizamientos bajo escenarios de pronósticos de lluvia, los cuales permitirán a los tomadores de decisiones actuar de manera oportuna para salvaguardar la vida de los pobladores y de sus medios de vida.

1.2 Planteamiento del trabajo

Para obtener mapas de escenarios de susceptibilidad a deslizamientos originado por lluvias, que cuenten con mejor precisión en la identificación de zonas de mayor probabilidad a deslizarse a causa de un evento de lluvia, se propone utilizar métodos cuantitativos basado en inteligencia artificial para maximizar el uso de los datos disponibles sobre los factores condicionantes del territorio que hacen que un suelo sea más susceptible a deslizarse a causa de un evento de lluvia. Para ello se implementarán métodos de aprendizaje automático en los cuales se podrá determinar con mayor precisión la zonificación de territorio que es más susceptible a deslizarse y estos podrán ser entrenados y validados con el inventario nacional de deslizamientos para la zona de estudio. Estos resultados serán clasificados en 4 niveles de susceptibilidad a deslizamientos. Posteriormente, podrán ser analizados con los mapas de pronósticos de lluvia, en los que se logrará identificar oportunamente las zonas probables a deslizarse bajo dicho escenario de precipitación pluvial.

1.3 Estructura de la memoria

Este trabajo de fin de máster en Inteligencia Artificial se ha estructurado en siete capítulos para una adecuada comprensión de la problemática que se ha abordado, de los aportes existentes sobre la materia, de los objetivos y tareas planteadas, de la identificación de los requisitos de la metodología planteada, de la evaluación de los modelos y de las conclusiones y trabajos futuros que surgieron en el desarrollo de este trabajo, los cuales se describen en los siguientes párrafos.

En el primer capítulo, se muestra la introducción de este trabajo, indicando la motivación del mismo, así como el planteamiento del trabajo y estructura del documento.

En el segundo capítulo, se muestra el contexto del tema abordado y el estado del arte en la que se hace una recopilación de las investigaciones relacionadas al tema con un análisis final de estas.

El tercer capítulo, contiene los objetivos y tareas planteadas para el desarrollo de esta investigación, al igual que la metodología del trabajo y su diagrama de flujo de procesos

El cuarto capítulo, contiene la identificación de los requisitos de la metodología planteada y de los insumos necesarios para la aplicación de esta metodología.

En el quinto capítulo, se detalla la metodología propuesta con los procedimientos que se deben seguir, el tratamiento de los datos que se utilizarán en la metodología y las tecnologías necesarias para aplicarla

En el sexto capítulo, se muestra la evaluación de la metodología con los procesos de validación y la interpretación de los resultados de dicha evaluación

El séptimo capítulo, se realiza las conclusiones del trabajo de fin de máster y del mismo modo se plantea las siguientes líneas de trabajo futuro

Finalmente, se añade una relación de la bibliografía utilizada en este trabajo, así como los anexos del mismo, incluyendo un artículo científico.

2. Contexto y estado del arte

A nivel nacional (Perú), los estudios realizados referente a metodologías sobre el cálculo de susceptibilidad a deslizamientos a escala regional se pueden mencionar en primera instancia a la entidad oficial responsable en materia de los peligros geológicos, el cuál es el Instituto Geológico Minero y Metalúrgico – Ingemmet, que cuenta con un mapa oficial a nivel nacional (Ingemmet, 2010) de los niveles de susceptibilidad a movimientos en masa. La metodología implementada para el cálculo de estos niveles de susceptibilidad fue utilizando un modelo heurístico multivariado el cual consiste en la superposición de capas de variables empleadas (Villacorta Chambi et al., 2012).

Asimismo, El Ministerio del Ambiente – Minam presenta una memoria descriptiva del mapa de vulnerabilidad física del Perú, en el cual presenta dentro de su procedimiento metodológico la elaboración de mapas de susceptibilidad física del territorio empleando un análisis univariable en el cual determina cualitativamente la valoración de cada variable en un rango numérico, y del mismo modo, emplea un análisis multivariable para relacionar dichas variables (Minam, 2011).

El Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres – Cenepred, como organismo público y encargado en materia de los procesos de estimación, prevención y reducción del riesgo de desastre, y reconstrucción, emplea una metodología semicuantitativa para la generación de escenarios del riesgo para diferentes peligros naturales basándose en un proceso de análisis jerárquico (Cenepred, 2012), el cual también es empleado para la elaboración de mapas de susceptibilidad a escalas locales utilizando el mismo método multicriterio (Cenepred, 2014).

Existe un Sistema de Monitoreo de Movimientos en Masa Potenciales generados por Lluvias Intensas – Silvia, el cual fue desarrollado por el Servicio Nacional de Meteorología e Hidrología del Perú – Senamhi, que utiliza datos de precipitación del producto Pisco, el cual un conjunto de datos espaciales con información de precipitación obtenida por satélite y correlacionada con datos de estaciones meteorológicas (Senamhi, 2017), el cual es empleado para determinar el nivel de susceptibilidad a ocurrencia de movimientos en masa (Senamhi, s.f.); sin embargo, este método tiene como insumo el mapa de susceptibilidad a movimientos en masa desarrollado por Ingemmet, el cual fue elaborado empleando un método semicuantitativo.

A nivel internacional, existe una serie de artículos recientes respecto al empleo de métodos cuantitativos basado en inteligencia artificial para la zonificación de la susceptibilidad a

deslizamientos. Por ejemplo, el uso de redes neuronales para la evaluación de la susceptibilidad a deslizamientos (Betancourt & Castro, 2018).

Adicionalmente, se tiene un análisis de «técnicas para la predicción espacial de zonas susceptibles a deslizamientos» en el cual se hace una recopilación de distintos métodos cuantitativos que son empleados para el cálculo de la susceptibilidad a deslizamientos (García & Castillo, 2019).

De la misma manera, se realiza una comparación de los métodos de regresión logística y pesos de evidencia para determinar qué métodos presenta mejor desempeño en la predicción de zonas susceptibles a movimientos en masa (Aristizábal et al., 2019).

El empleo de métodos de inteligencia artificial para el cálculo de la susceptibilidad a deslizamiento se ha incrementado considerablemente, generando un conjunto de artículos científicos que implementan métodos de aprendizaje automático para la zonificación de la susceptibilidad (Arabameri et al., 2019; Chen et al., 2019; Hong et al., 2019; Lei et al., 2020; Nguyen et al., 2019; Nhu et al., 2020; Ahmed et al., 2020).

Finalmente, se observa que a nivel internacional los métodos de inteligencia artificial para el cálculo de las zonas susceptibles a deslizamientos están en un auge de desarrollo, mientras que a nivel nacional (Perú) no se desarrollado aún métodos basados en inteligencia artificial para el cálculo de la susceptibilidad a deslizamientos; sin embargo, los métodos a nivel internacionales presentan como producto final el mapa de susceptibilidad, sin considerar los pronósticos de lluvia para la generación de escenarios, los cuales a nivel nacional sí son implementados bajo un enfoque semicuantitativo.

3. Objetivos y metodología de trabajo

En este capítulo se muestra los objetivos y tareas planteadas para el desarrollo del trabajo de fin de máster, así como el procedimiento metodológico que se seguirá para cumplir la meta propuesta.

3.1. Objetivo general

Proponer una metodología para la generación de escenarios de susceptibilidad a deslizamientos originado por lluvias en el departamento de Ancash, Perú, utilizando métodos basados en inteligencia artificial que permita obtener mapas con mayor precisión y exactitud de manera oportuna para la toma de decisiones.

3.2. Objetivos específicos

- Determinar las variables que condicionan la mayor predisposición a la ocurrencia de deslizamientos.
- Identificar un método de inteligencia artificial que presente mejor desempeño en la predicción de zonas susceptibles a deslizamientos.
- Localizar las zonas susceptibles a deslizarse, bajo un escenario de pronósticos de lluvia.
- Proporcionar los criterios técnicos para la elaboración de escenarios de susceptibilidad a deslizamientos originado por lluvias.
- Establecer un flujograma de trabajo del procedimiento metodológico para la generación de escenarios.

3.3. Metodología del trabajo

Para el desarrollo de este trabajo, se empezará con la determinación de las variables que serán utilizadas para la generación de un mapa de susceptibilidad a deslizamientos, los cuales son denominados como factores condicionantes del territorio. Para ello, se realizará una búsqueda de toda la información geoespacial disponible en el área de estudio que puedan ser utilizadas como factor condicionante.

Se obtendrá un inventario de deslizamientos del área de estudio los cuales podrán ser utilizados para el entrenamiento, validación y prueba del modelo basado en inteligencia artificial que será empleado para el análisis de la susceptibilidad.

Se identificará qué método de inteligencia artificial utilizado es el más exacto para la zonificación de la susceptibilidad a deslizamientos.

El resultado de la zonificación de susceptibilidad a deslizamientos será procesado con el pronóstico de lluvias generado por la entidad oficial, el cual permitirá obtener un escenario de susceptibilidad a deslizamientos, los cuales podrán ser clasificado en 4 niveles de mayor a menor probabilidad de ocurrencia de deslizamiento.

Finalmente, se dará a conocer los criterios técnicos que se deben tener en cuenta para la generación de estos escenarios, así como establecer un flujograma de trabajo para la generación de escenarios de susceptibilidad a deslizamientos originado por lluvias.

4. Identificación de requisitos

Para la identificación de los materiales requeridos en esta metodología se identificó principalmente como insumos los factores condicionantes del territorio que hacen que el suelo se más o menos susceptible a los deslizamientos; asimismo, para poder validar y entrenar el modelo se requiere un inventario de deslizamientos con los cuales se puede identificar el lugar preciso en donde ocurrió el deslizamiento y las características que presenta el terreno (factores condicionante). Finalmente, se utiliza los pronósticos de lluvias que realiza el ente oficial en meteorología del Perú (Senamhi) para conocer el grado de peligro que puede generar estas lluvias sobre el terreno en estudio.

Para el procesamiento de los insumos, se emplea métodos de inteligencia artificial, específicamente los métodos de aprendizaje automático, el cual permitirá conocer la probabilidad de ocurrencia de un deslizamiento (susceptibilidad del territorio a deslizamientos) en base a sus características y el nivel de peligro de las zonas a deslizarse a causa de una lluvia.

4.1 Factores condicionantes

Los factores condicionantes son parámetros del ámbito geográfico de estudio, el cual contribuye de manera favorable o no al desarrollo del fenómeno de origen natural (magnitud e intensidad), así como su distribución espacial (Cenepred, 2014). De esta manera, podemos identificar en nuestro territorio todo aquel factor que contribuya a la ocurrencia de deslizamientos (geología, geomorfología, hidrogeología, etc.).

4.2 Inventario de deslizamientos

Este es un registro histórico de los procesos exógenos (origen externo) de deslizamientos ocurridos en el área de estudio. Estos deben contener información que ayude a identificar las características del evento y su ubicación geográfica.

4.3 Pronósticos de lluvia

El pronóstico de lluvia es el proceso de estimación que se realiza ante situaciones de incertidumbre, se refiere a la estimación de series temporales o datos obtenidos de forma instantánea. Se considera el pronóstico como un proceso crítico y continuo cuyos resultados

son obtenidos mediante un proceso de planificación estadístico (Camargo Rueda & Paez Canabal, 2019).

4.4 Métodos de aprendizaje automático

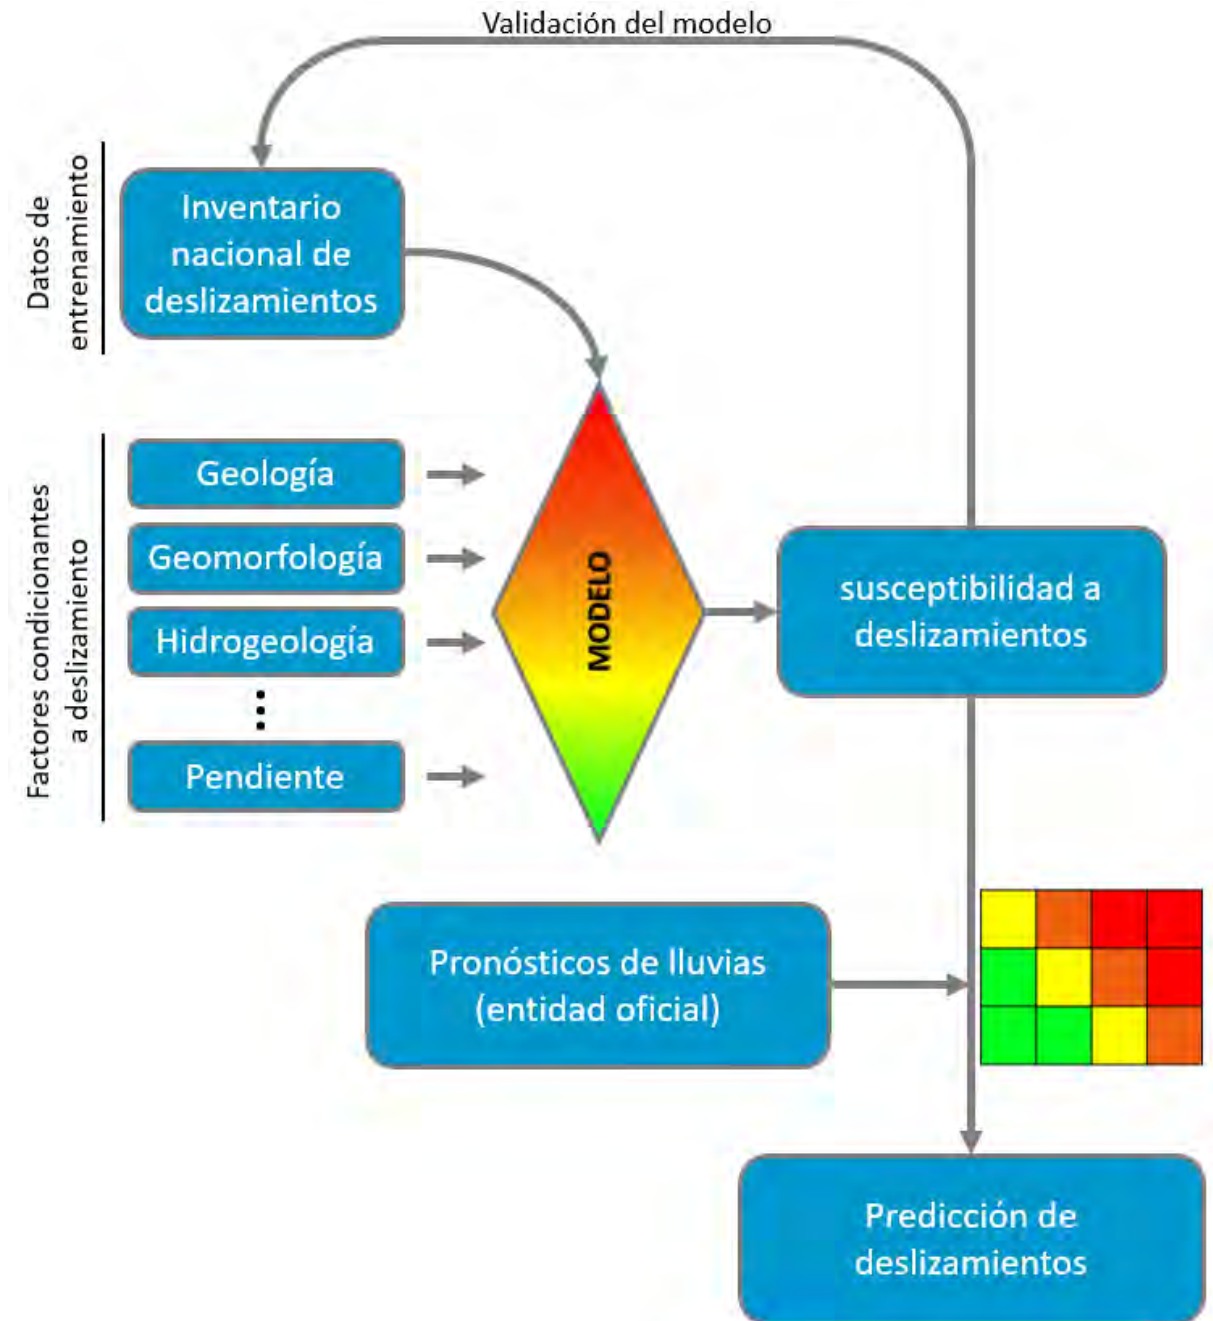
El método de aprendizaje automático, es el campo emergente de la informática que estudia los algoritmos capaces de aprender a partir de los datos disponibles en un proceso iterativo y de refinamiento gradual. Ello permite encontrar asociaciones que los métodos estadísticos no detectan fácilmente para realizar tareas de procesamiento, como clasificación, predicción o agrupación (García & Castillo, 2019). En el campo de la predicción de procesos de remoción en masa se han implementado varias técnicas, de las cuales se pueden mencionar algunas:

- Redes neuronales artificiales
- Máquinas de soporte vectorial
- Lógica difusa
- Naïve Bayes
- Modelo logístico de árbol
- Bosques aleatorios
- Clasificación y regresión de árboles
- Regresión multivariada adaptativa de splines
- Árbol de regresión ponderado
- Modelos híbridos o ensamblados

5. Descripción de la metodología

La metodología propuesta presenta el siguiente flujograma (Figura 1):

Figura 1 Flujograma del procedimiento metodológico.



En la Figura 1, se observa los procedimientos que se debe seguir para aplicar la metodología y obtener las predicciones de deslizamientos bajo un escenario de lluvia aplicando métodos de aprendizaje automático.

A continuación, se muestra los pasos detallados que se deben seguir para obtener las predicciones de deslizamiento aplicando inteligencia artificial.

5.1 Preprocesamiento

En este apartado se detalla las especificaciones y formas de cómo se debe preparar los datos de entrada al modelo a partir de los insumos requeridos.

Primeramente, se debe definir y delimitar el área de estudio en donde se desea predecir los deslizamientos desencadenados por lluvias. Esta área deberá estar representada por un archivo vectorial o raster; asimismo, este deberá estar proyectada en un sistema de proyección geográfica definido.

A partir de la delimitación del área de estudio en la que se definió la proyección de coordenadas geográficas y extensión, se empezará a generar los insumos considerando las mismas propiedades definidas por el área de estudio (factores condicionantes, inventario de deslizamientos y pronóstico de lluvias).

5.1.1 Factores condicionantes a deslizamientos

Estos factores se pueden encontrar en 2 tipos de archivos, en formato vectoriales y raster. Para el caso de archivos vectoriales, estos deberán presentar el mismo límite del área de estudio. Para el caso del formato raster, este debe poseer las mismas propiedades de extensión y cantidad de píxeles que tendrá el área de estudio al ser rasterizada. Este proceso debe pasar cada insumo considerado como factor condicionante, debido a que los cálculos que se realizarán entre las variables utilizadas serán por cada píxel de raster generado.

Todos los insumos identificados como factores condicionantes, serán rasterizados. Cada raster deberá tener la misma proyección geográfica, extensión y resolución. Además, todos los raster deben presentar los mismos 2 puntos de extensión.

5.1.2 Inventario de deslizamientos

Los puntos del inventario de deslizamientos deberán estar contenidos dentro del polígono o raster del área de estudio, los cuales deberán contener en uno de sus atributos el valor de 1 el cual significa presencia de deslizamiento.

Se añadirán puntos adicionales al inventario de deslizamientos, con el valor de 0 en su atributo, el cual indica ausencia de deslizamientos. Estos puntos deberán ser añadidos en los

lugares en los que nunca ocurrirán deslizamientos o presenten muy baja probabilidad de generación de deslizamiento debido a sus características geográficas.

Es recomendable que los puntos de registro de deslizamientos y de ausencia de deslizamientos deban estar correctamente distribuidos de manera homogénea en toda el área de estudio para garantizar resultados confiables en el procesamiento de aprendizaje automático.

5.1.3 Pronósticos de lluvia

Los pronósticos de lluvia podrán estar clasificados de manera categórica en niveles de peligro, según sea la intensidad de la lluvia. Esta información, de la misma manera que los factores condicionantes deberán estar en formato raster manteniendo las mismas propiedades de estos factores, como proyección geográfica, resolución y puntos de extensión del archivo.

5.2 Procesamiento

Para obtener la predicción de los deslizamientos a partir de los pronósticos de lluvia, se debe contar con un mapa de susceptibilidad a deslizamientos, el cuál es producto de la relación de los factores condicionantes, validados con el inventario de deslizamientos.

5.2.1 Susceptibilidad a deslizamiento

Para obtener este producto se deberán relacionar todos los factores condicionantes entre sí, para obtener qué áreas son más susceptibles a deslizarse que otras.

Cada factor condicionante contiene un conjunto de clases en el cual se caracteriza dicho factor; sin embargo, cada clase de los factores son variables categóricas. Para llevar las clases de cada factor condicionante a variables numéricas, se deberá emplear métodos de análisis estadísticos bivariados o probabilísticos, estos permiten analizar cada factor con sus respectivas clases para obtener un valor numérico en referencia al número de deslizamientos ocurridos en cada clase de un factor.

Una vez definidos los valores numéricos que presentan cada clase de cada factor condicionante, se deberán relacionar estos factores entre sí, para así tener un solo valor por cada pixel del área de estudio.

Para poder hallar esta relación entre los factores condicionantes se emplea un método de aprendizaje automático que se pueda entrenar utilizando como insumos los factores condicionantes con el inventario de deslizamientos.

Para poder entrenar el modelo previamente, se debe generar la base de datos de deslizamientos, el cual estará comprendido con puntos geográficos en el cual algunos puntos están clasificados por presencia de deslizamientos y otros con ausencia de deslizamientos en el área de estudio. En cada punto geográfico existirá además un dato de cada factor condicionante con sus clases respectivas, y cada clase poseerá un valor numérico calculado en el paso anterior. Esta base de datos estará conformada por una columna en el que se indica la categoría del punto (0= ausencia de deslizamiento, 1= presencia de deslizamiento) y las demás columnas corresponderán a la cantidad de factores condicionantes utilizados en el modelo, los cuales estarán representado por valores numéricos.

De esta base de datos se seleccionará un porcentaje para el entrenamiento del modelo y el otro para la validación y prueba del mismo. Asimismo, una vez entrenado y probado el modelo, se utilizará para la predicción de las etiquetas de los pixeles de toda el área de estudio.

Finalmente, se establecerá 4 rangos en partes iguales de los valores predichos para cada pixel, estos rangos se les categorizará como: «bajo», «medio», «alto» y «muy alto» según el caso.

5.2.2 Predicción de deslizamiento

El producto de predicción de deslizamiento, proviene de la relación entre el mapa de susceptibilidad y el de pronóstico de lluvia. Este último es obtenido de los avisos meteorológicos del Servicio Nacional de Meteorología e Hidrología del Perú (Senamhi).

Los Avisos Meteorológicos son pronósticos de carácter preventivo ante eventos severos, indicando las áreas que podrían verse afectadas y el nivel de peligrosidad (Senamhi, 2003). Esta información está disponible en formato vectorial y está categorizado en 4 niveles, de los cuales el nivel 1, no es considerado debido a que se interpreta como no ocurrencia de evento meteorológico. Los niveles del 2, 3 y 4 corresponden según al grado de peligrosidad, respectivamente.

Debido a que el mapa de susceptibilidad y de pronóstico de lluvias están representado por valores categóricos, se emplea un cuadro de doble entrada para determinar la categoría de ocurrencia de deslizamiento en 4 niveles, según el grado de probabilidad de ocurrencia.

6. Evaluación

En este apartado se aplicará la metodología empleando los pasos descritos en el capítulo anterior, para ello se utilizó como caso de estudio el departamento de Ancash que se ubica al norte de Lima, Perú (Figura 2).

Figura 2 Mapa de ubicación del área de estudio.



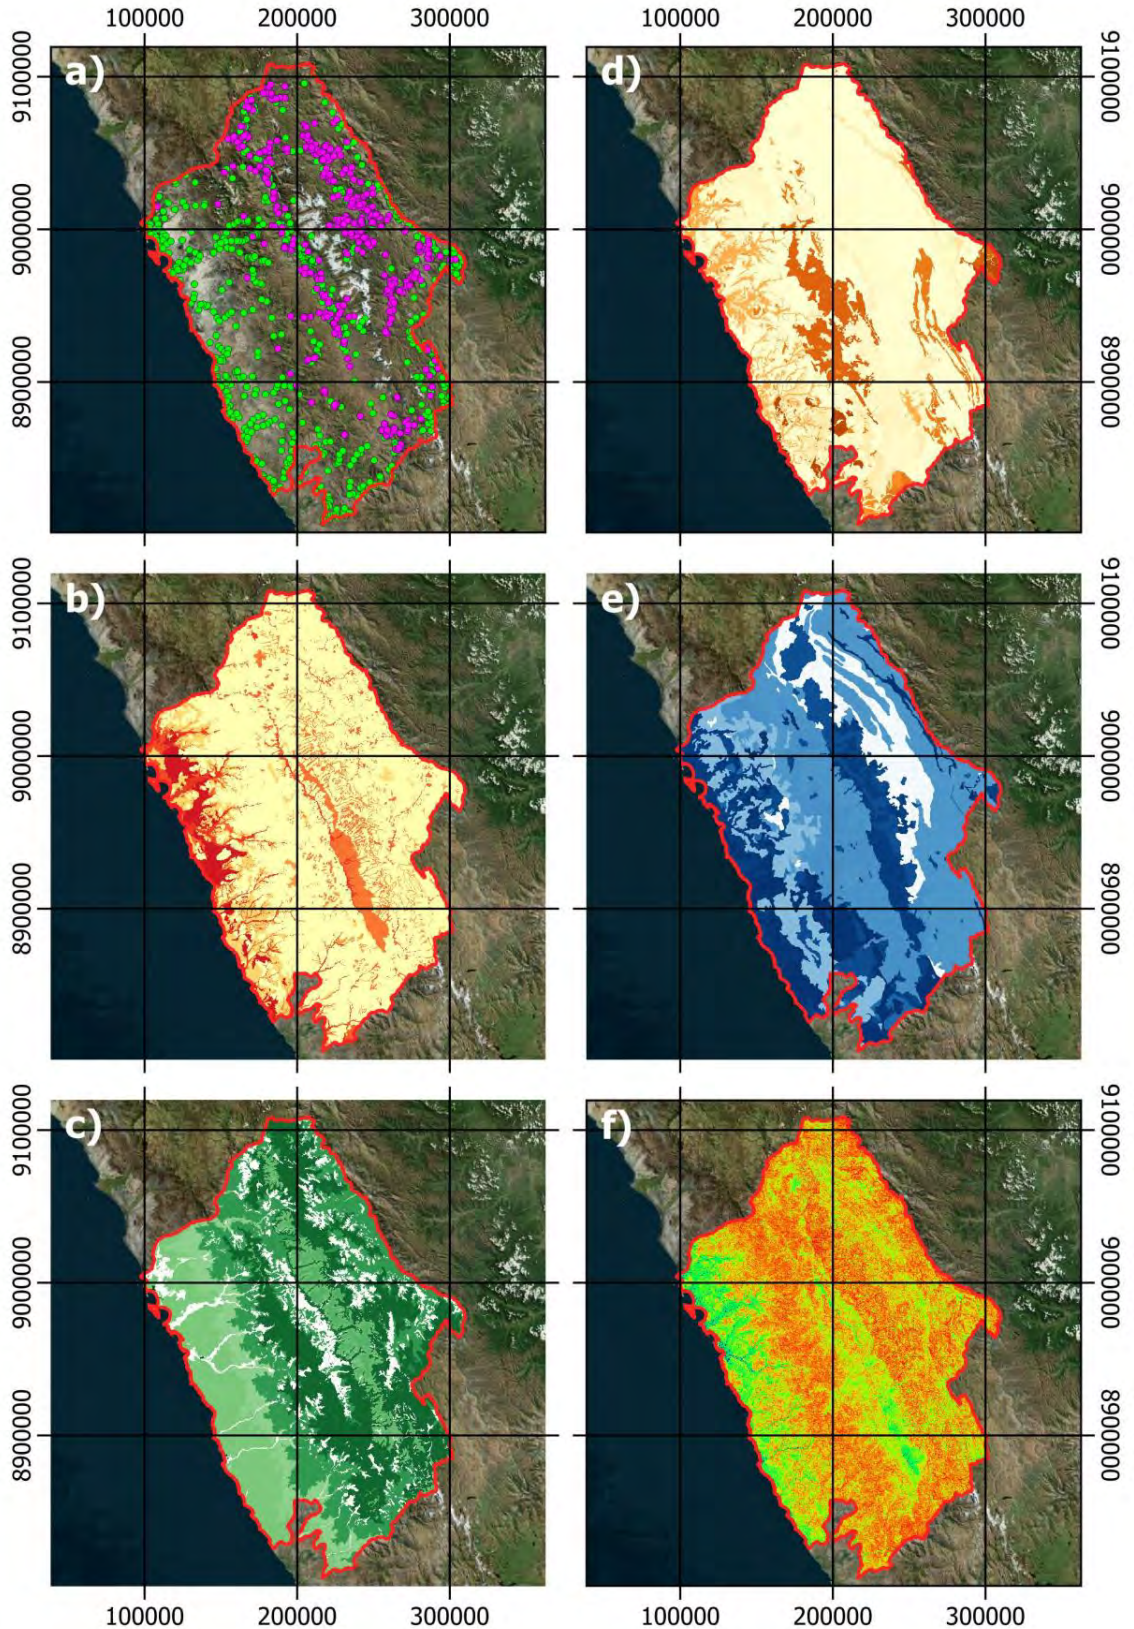
En la Figura 2, se muestra la ubicación general del área de estudio. Esta área de trabajo utiliza una proyección WGS64 UTM zona 18S.

Para este caso de estudio se utilizaron principalmente 5 factores condicionantes, los cuales son los mismos factores que el Instituto Geológico, Minero y Metalúrgico (Ingemmet) utilizó para la generación del mapa de susceptibilidad por movimientos en masa (deslizamientos, caída de rocas flujos, reptación, etc.). Además, estos factores condicionantes fueron generados por el Ingemmet, el cual es la información oficial a nivel de Perú como ente técnico científico.

Asimismo, la información del inventario de deslizamientos, fue extraído del inventario nacional de movimientos en masa del Ingemmet, los cuales de estos se extrajo solo los peligros por deslizamientos. A este inventario se le añadieron puntos en zonas en donde no ocurren deslizamientos, para estos se ha considerado las zonas en donde existe depósitos fluviales o

cuerpos de agua, así como también zonas de baja pendiente, en terrazas fluviales, llanuras de inundación y todas zonas en las que la probabilidad de ocurrencia de deslizamientos es mínima, tal como se muestra en la Figura 3.a.

Figura 3 base de datos y factores condicionantes a deslizamientos.



En la Figura 3.a, se muestra la base de datos que será utilizada para el entrenamiento y validación del modelo, donde los puntos morados representan los deslizamientos ocurridos y los puntos verdes representan zonas en donde la ocurrencia de un deslizamiento es ínfima. Se tiene un total de 512 registros de deslizamientos y 657 puntos de ausencia de deslizamientos, el cual hace un total de 1169 puntos de control.

En la Figura 3.b, se muestra el factor condicionante de geomorfología, el cual representa las diferentes geoformas presentes en el área de estudio, para este caso se ha identificado 41 diferentes tipos de unidades geomorfológicas.

En la Figura 3.c, se muestra el factor la cobertura existente, para este caso se ha identificado 19 diferentes tipos de cobertura.

En la Figura 3.f, se muestra el factor condicionante de geología (unidades geológicas superficiales) el cual representa los diferentes tipos de depósitos superficiales que se encuentran sobre el área de estudio, para este caso se ha identificado 119 diferentes tipos de unidades geológicas superficiales.

En la Figura 3.e, se muestra el factor condicionante de hidrogeología el cual representa los diferentes tipos de unidades hidrogeológicas presentes en el área de estudio, para este caso se ha identificado 29 diferentes tipos de unidades geológicas superficiales.

En la Figura 3.f, se muestra el factor condicionante de pendiente el cual representa está representada en 6 rangos distintos de inclinación del terreno.

Para poder llevar las variables categóricas de cada factor condicionante se empleó el método de Pesos de Evidencias (WoE), el cuál es un método estadístico bivariado basado en la teoría de la probabilidad bayesiana (Sujatha et al., 2014).

Con este método se podrá asignar valores pesos a cada pixel de cada factor condicionante, los cuales se obtienen con las siguientes ecuaciones

$$W_i^+ = \ln \frac{\frac{Npix_1}{Npix_1+Npix_2}}{\frac{Npix_3}{Npix_3+Npix_4}} \quad \dots (1)$$

$$W_i^- = \ln \frac{\frac{Npix_2}{Npix_1+Npix_2}}{\frac{Npix_4}{Npix_3+Npix_4}} \quad \dots (2)$$

$$W_F = W_i^+ - W_i^- \quad \dots (3)$$

Donde:

N_{pix_1} = Número de píxeles con presencia de una clase del factor condicionante y de deslizamientos.

N_{pix_2} = Número de píxeles con ausencia de una clase del factor condicionante y presencia de deslizamientos.

N_{pix_3} = Número de píxeles con presencia de una clase del factor condicionante y ausencia de deslizamientos.

N_{pix_4} = Número de píxeles con ausencia de una clase del factor condicionante y de deslizamientos.

El resultado de $W_i^+ > 0$, indica que la presencia de la clase del factor condicionante contribuye a la presencia del deslizamiento; cuando $W_i^+ = 0$, indica que la clase de dicho factor no es relevante; y cuando $W_i^+ < 0$, indica que la presencia de la clase del factor contribuye a la ausencia del deslizamiento.

El resultado de $W_i^- > 0$, indica que la ausencia de la clase del factor condicionante contribuye a la presencia del deslizamiento; cuando $W_i^- = 0$, indica que la clase de dicho factor no es relevante; y cuando $W_i^- < 0$, indica que la ausencia de la clase del factor contribuye a la ausencia del deslizamiento.

Luego de obtener los pesos de evidencias para cada clase de cada factor condicionante, se extrajo los valores de los píxeles en donde se ubicaban los puntos de la base de datos. Estos puntos estaban etiquetados con el valor de 1 (ocurrencia de deslizamiento) y 0 (ausencia de deslizamiento), asimismo cada punto tendría un valor numérico (W_F) por cada factor condicionante (Figura 4).

En la Figura 4, se observa se observa la lista de valores que contiene la base de datos que será utilizada para el modelo de inteligencia artificial. En este caso se obtuvo matriz de 1169×6 , en el cual 1169 representa la cantidad de puntos de control y 6 la cantidad de información por cada punto, en este caso la primera columna «landslide», representa la ocurrencia o no de un deslizamiento; las columnas restantes corresponden a los pesos de evidencia (W_F) de cada factor condicionante para el pixel mostrado.

La base de datos es ingresada al modelo, para ello, se separó el 80% de los datos para el entrenamiento y el 20% para la prueba del modelo.

Figura 4 Lista de valores de la base de datos para el entrenamiento y validación del modelo.

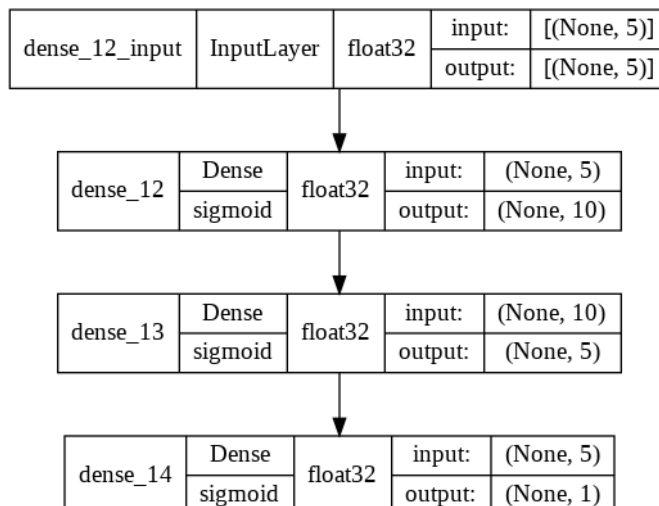
	landslide	1-glg_wf	2-gmg_wf	3-hgl_wf	4-cvg_wf	5-slp_wf
0	0	-2.93732	0.12985	-1.49672	0.85974	-1.25208
1	0	-5.79107	-4.67507	-1.49672	-4.13373	-1.25208
2	0	-2.93732	-4.67507	-1.49672	0.90345	-1.25208
3	0	-2.93732	-4.67507	-1.49672	0.90345	-0.02703
4	0	-3.06143	-4.67507	-1.46646	0.90345	-1.25208
...
1164	1	-0.62265	-5.14827	-0.45071	-1.32859	0.00623
1165	1	1.04365	3.81807	-1.46646	0.85974	-0.02703
1166	1	1.13365	0.32625	0.91335	0.25324	-0.21023
1167	1	0.80563	0.23207	-0.11162	0.25324	0.00623
1168	1	1.54253	3.81807	1.57595	0.25324	0.13470

1169 rows × 6 columns

Se utilizó un modelo de red neuronal con diferentes configuraciones (capas y funciones de activación) para obtener el modelo que mejor resultados presente. Para esto, se generó 4 modelos de redes neuronales, los cuales presentan las siguientes configuraciones:

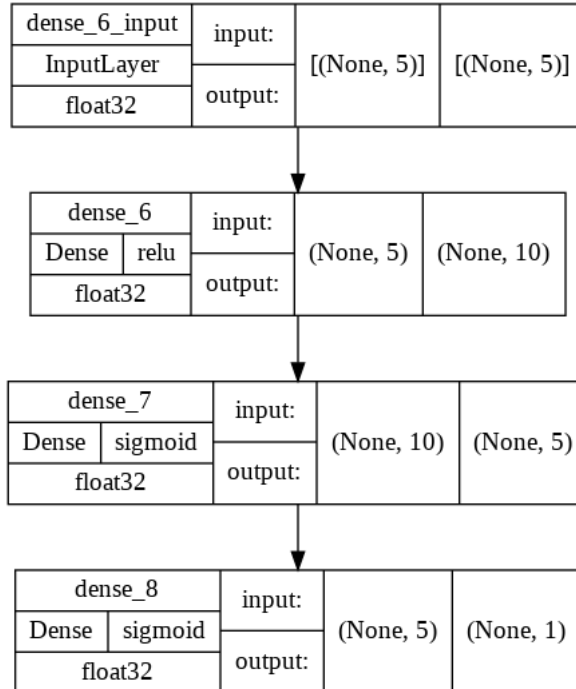
En la Figura 5, se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 2 capas ocultas de 10 y 5 neuronas, con función de activación sigmoide.

Figura 5 Arquitectura de la red neuronal 1.



En la Figura 6, se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 2 capas ocultas de 10 y 5 neuronas, con función de activación relu, sigmoide, sigmoide y sigmoide, respectivamente.

Figura 6 Arquitectura de la red neuronal 2.



En la Figura 7, se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 4 capas ocultas de 10, 20, 10 y 5 neuronas, con función de activación relu, sigmoide, sigmoide, sigmoide y sigmoide, respectivamente.

En la Figura 8, se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 4 capas ocultas de 10, 20, 10 y 5 neuronas, con función de activación relu, relu, relu, relu y sigmoide, respectivamente.

Los cuatro modelos de estructura de red neuronal fueron entrenados, con la base de datos generada (80%), además, para que el entrenamiento de los modelos sea mucho más rápido, se utilizó el optimizador «Adaptive moment estimation» (Adam), el cual combina los algoritmos de «AdaGrad» y «RMSProp», con la función de pérdida de error cuadrático medio (MSE) y una técnica de validación en el entrenamiento con la función «Split validation», utilizando 20% de los datos de entrenamiento. Finalmente, el entrenamiento de todas las redes neuronales tuvo una iteración de 6000 épocas.

Figura 7 Arquitectura de la red neuronal 3.

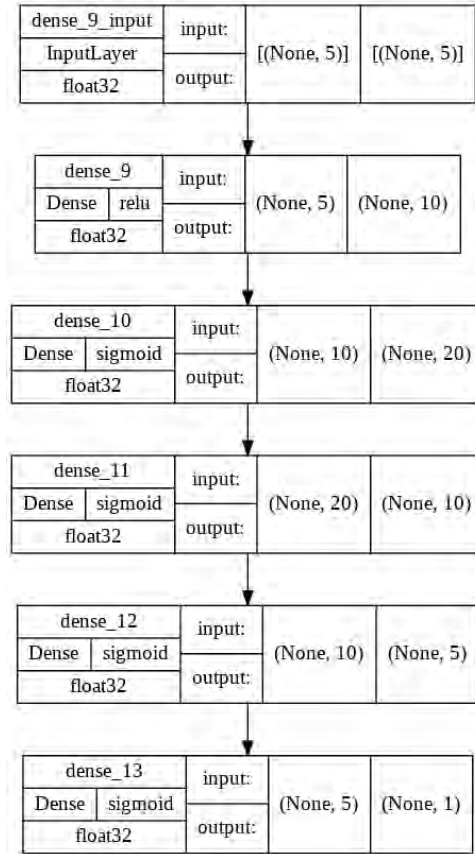
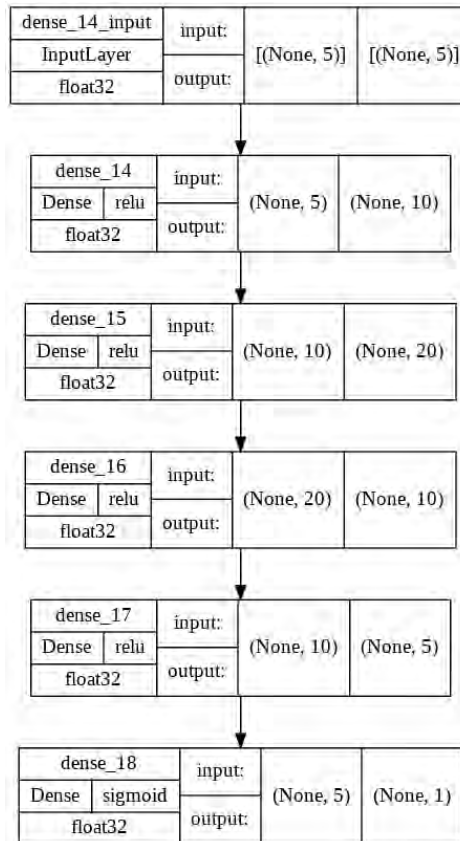



Figura 8 Arquitectura de la red neuronal 4.




Con la configuración de los modelos de red neuronal, se obtuvo que para el primer modelo de red neuronal llegó a una exactitud en el entrenamiento de 88.24% y de validación de 85.56% (Figura 9).

Figura 9 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 1.




Asimismo, se llegó a una tasa de pérdida de entrenamiento de 8.34% y una tasa de pérdida en la validación de 12.19% (Figura 10).

Figura 10 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 1.




Con la configuración de los modelos de red neuronal, se obtuvo que para el segundo modelo de red neuronal llegó a una exactitud en el entrenamiento de 92.25% y de validación de 83.42% (Figura 11Figura 9).

Figura 11 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 2.




Asimismo, se llegó a una tasa de pérdida de entrenamiento de 6.21% y una tasa de pérdida en la validación de 12.03% (Figura 12).

Figura 12 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 2.




Con la configuración de los modelos de red neuronal, se obtuvo que para el tercer modelo de red neuronal llegó a una exactitud en el entrenamiento de 93.72% y de validación de 83.96% (Figura 13Figura 9).

Figura 13 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 3.




Asimismo, se llegó a una tasa de pérdida de entrenamiento de 5.23% y una tasa de pérdida en la validación de 14.73% (Figura 14).

Figura 14 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 3.




Con la configuración de los modelos de red neuronal, se obtuvo que para el cuarto modelo de red neuronal llegó a una exactitud en el entrenamiento de 95.72% y de validación de 81.82% (Figura 15Figura 9).

Figura 15 Gráfica de la tasa de exactitud contra la tasa de validación de la red neuronal 4.



Asimismo, se llegó a una tasa de pérdida de entrenamiento de 3.09% y una tasa de pérdida en la validación de 16.63% (Figura 16).

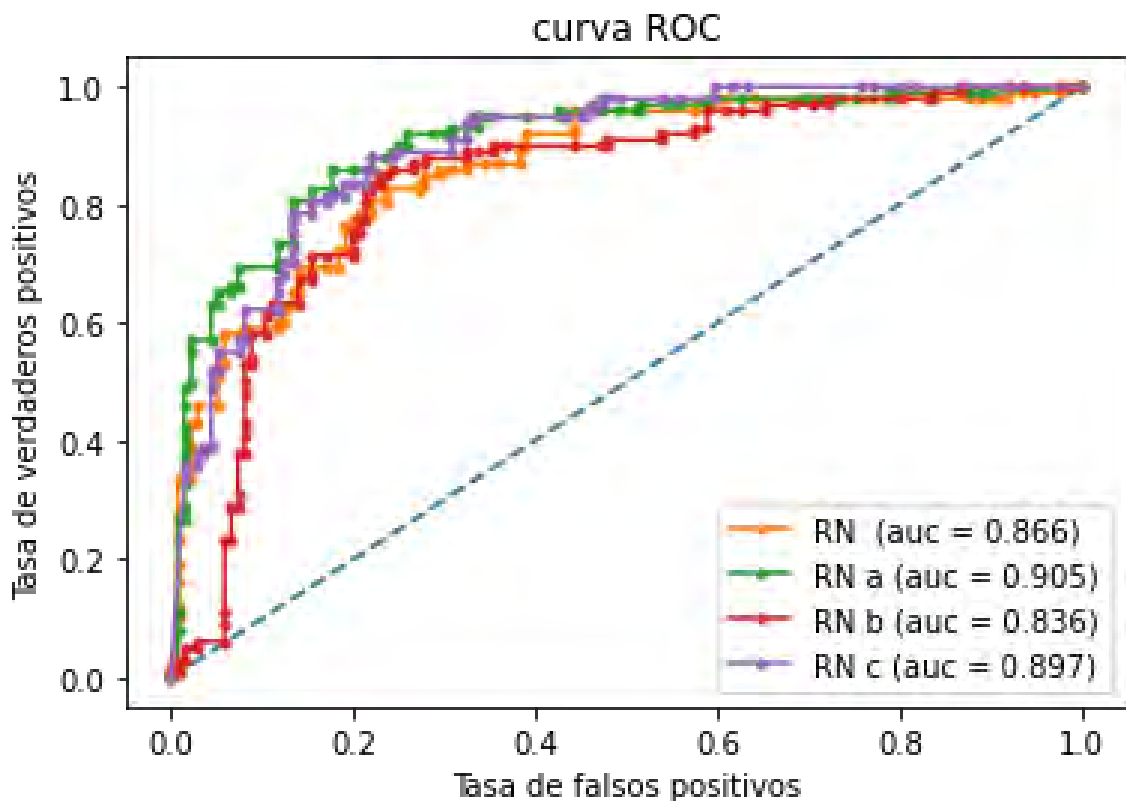
Figura 16 Tasa de pérdida contra tasa de pérdida de validación de la red neuronal 4.



Luego de obtener los modelos de redes neuronales entrenados, se utilizó las métricas de la curva ROC (Receiver Operator Characteristic, característica de operador receptor) y el valor de AUC (Area Under Curve, área bajo la curva) para determinar qué modelo obtuvo mejores resultados en el ensayo de prueba con la base de datos restante (20%).

En la Figura 17, se observa que el modelo que mejor resultados obtuvo en la prueba fue el segundo modelo de red neuronal, obteniendo un AUC del 90.5%, mientras que el tercer modelo de red neuronal obtuvo el menor valor de AUC con 83.6%.

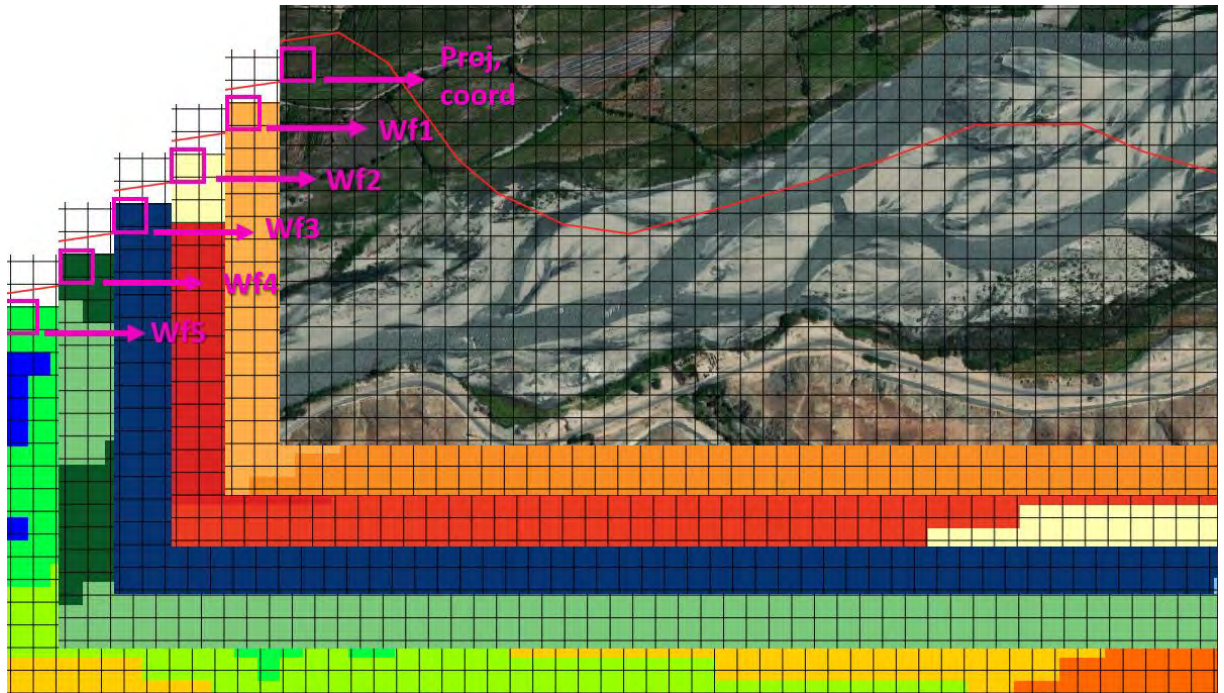
Figura 17 Curva ROC y valores de AUC de los modelos de redes neuronales entrenados.



En base a los resultados, se utilizó el segundo modelo de red neuronal para la clasificación de susceptibilidad del territorio. El modelo utilizado está configurado por 1 capa de entrada con 5 neuronas, 2 capas ocultas de 10 y 5 neuronas con función de activación relu y sigmoide, respectivamente, y una capa de salida de 1 neurona con función de activación sigmoide.

Cada pixel que abarca el área de estudio presenta información de cada capa de los factores condicionantes utilizados, para esto se generó una lista de valores el cual está comprendida por la coordenada de cada pixel, su proyección y los pesos de evidencia de cada factor condicionante tal como se observa en la Figura 18.

Figura 18 Valores del pixel presente en cada capa de factor condicionante.

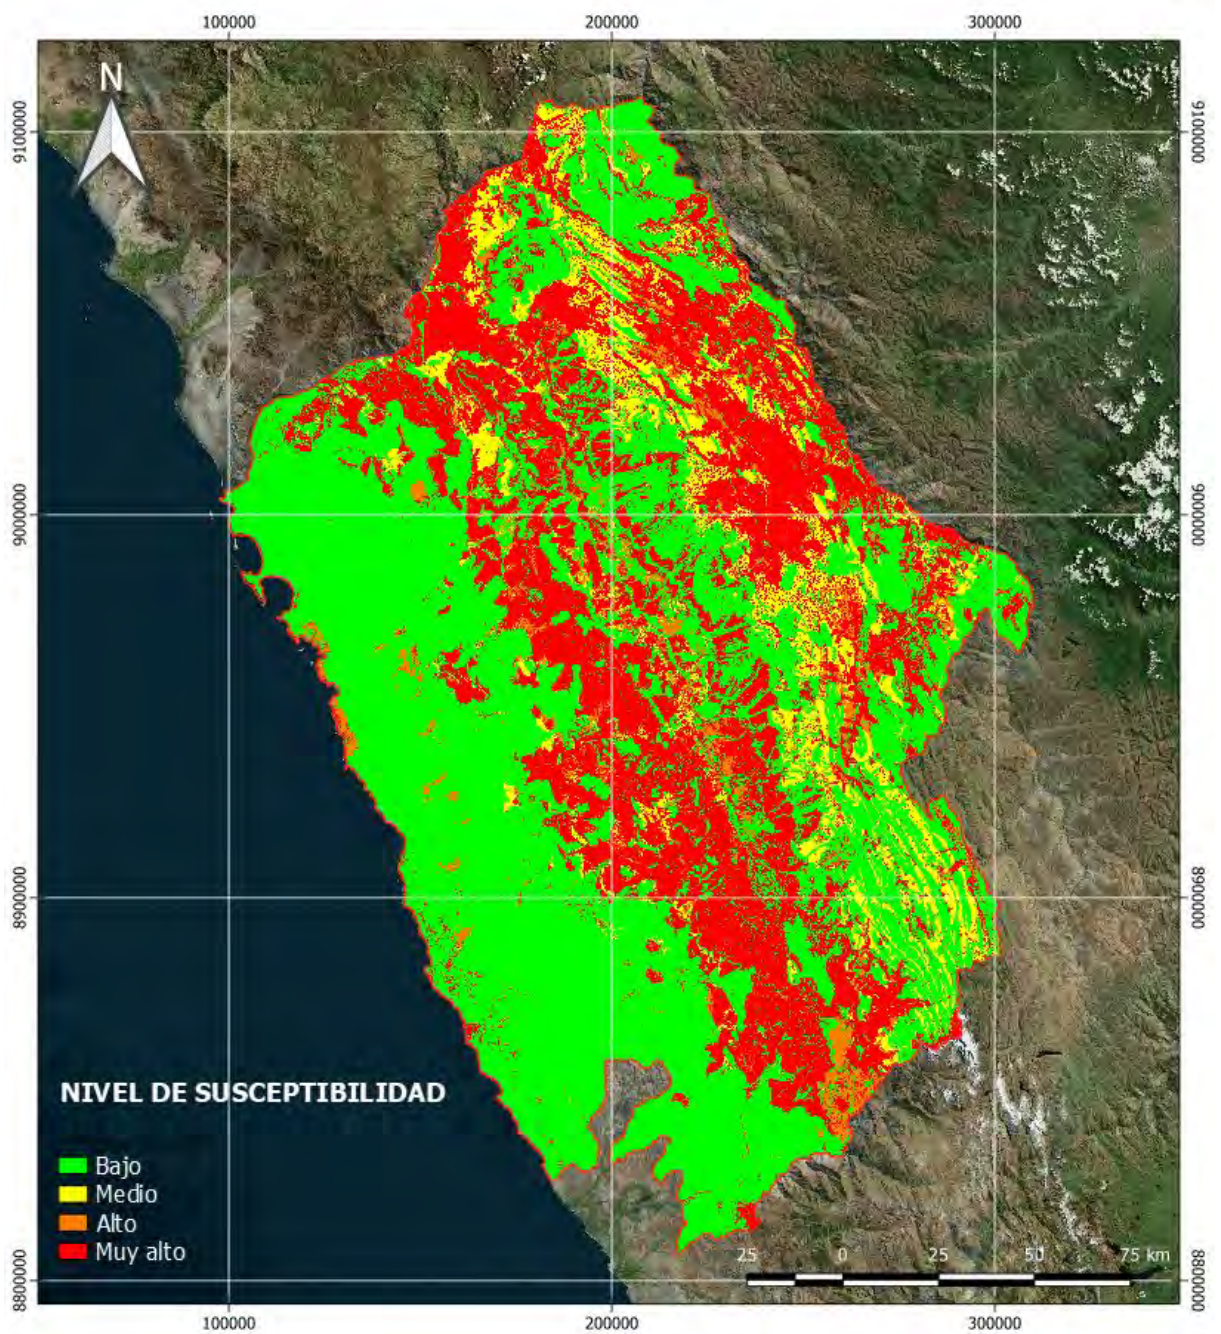


Los valores presentes en cada pixel que pertenecen a los pesos de evidencia, son ingresados al modelo entrenado para predecir el valor de susceptibilidad presente en cada pixel del área de estudio, para ello se realizó la predicción de 38'182,257 de pixeles. En el cual el modelo asignó valores entre 0 a 1, en el cual 1 significa muy alta probabilidad de ocurrencia de un deslizamiento y el 0 se interpreta como muy baja probabilidad de ocurrencia de un deslizamiento.

Luego de la predicción con el modelo, se tiene una lista de valores entre 0 y 1 para cada pixel ingresado, debido a que en esta lista cada pixel contiene la proyección geográfica y las coordenadas, se generó un archivo raster de valores entre 0 y 1, este archivo generado se le clasificó en 4 niveles, según el grado de probabilidad de ocurrencia de deslizamiento, los cuales representan los niveles de susceptibilidad del territorio a deslizamiento.

Estos niveles están clasificados como nivel bajo a los valores que se encuentran en el rango de 0 a 0.25; nivel medio, los valores que están entre 0.25 a 0.5; nivel alto, los valores que están entre 0.5 a 0.75; y nivel muy alto, los valores que se encuentran entre 0.75 a 1, tal como se observa en la Figura 19.

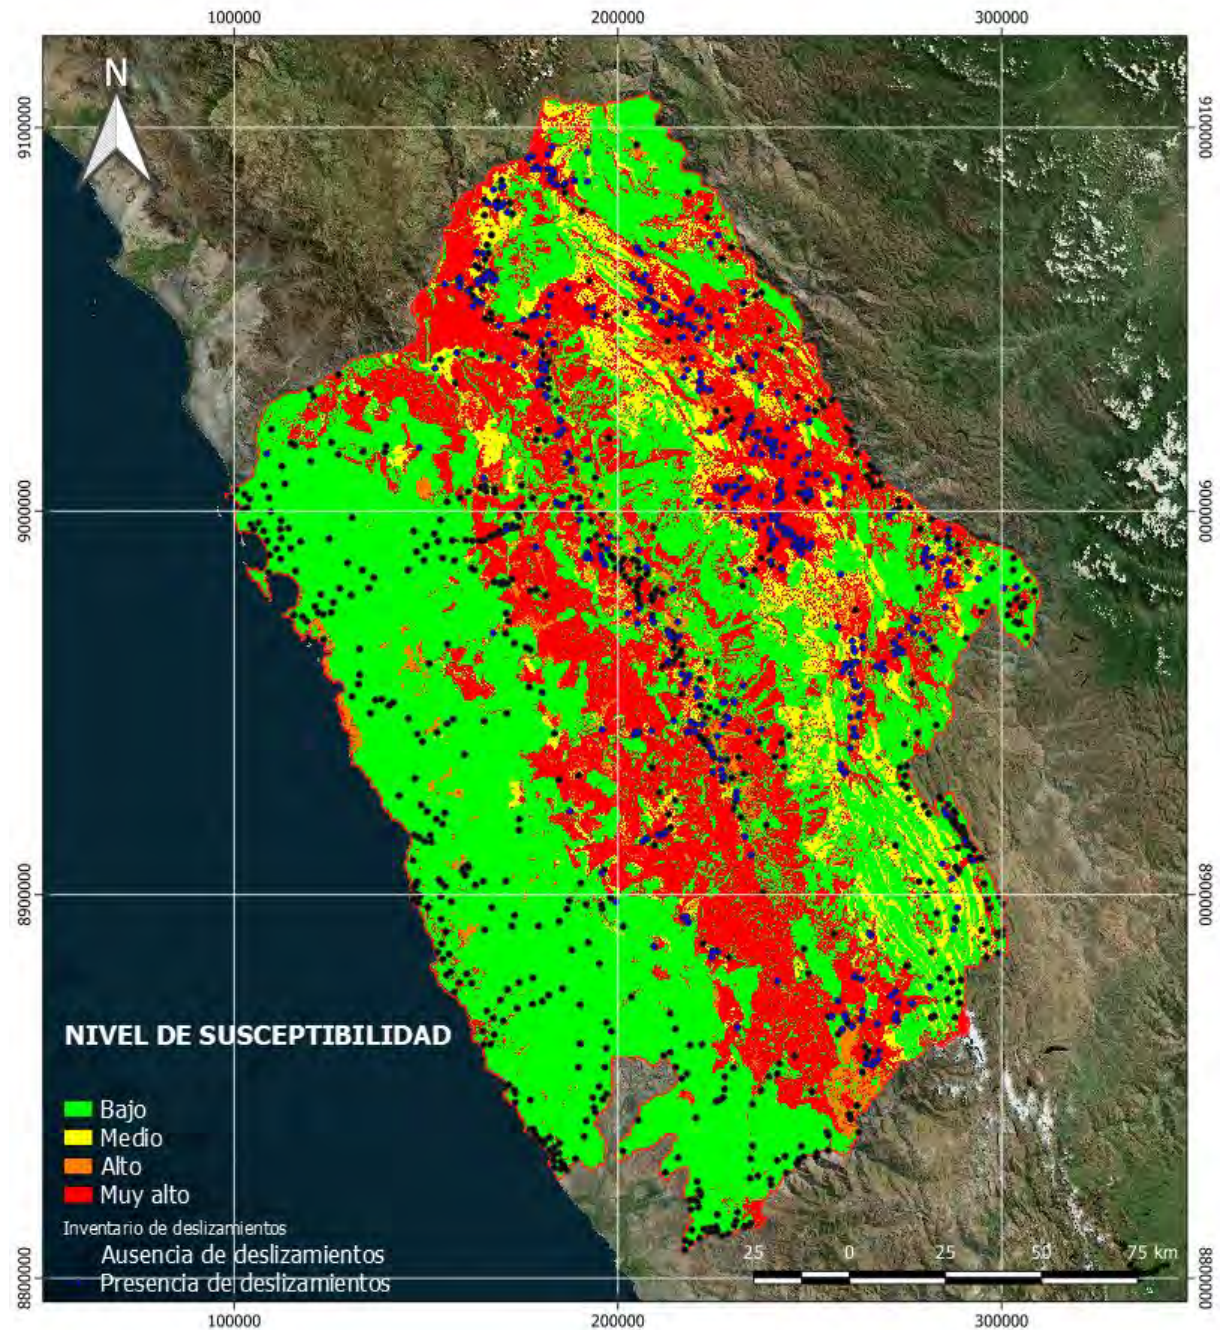
Figura 19 Mapa de susceptibilidad a deslizamientos generado con redes neuronales.



En la Figura 19, se observa la distribución geográfica de los niveles de susceptibilidad del territorio a deslizamiento para cada pixel predicho con el modelo de red neuronal, en el que se aprecia que la zona de litoral predomina el nivel bajo a deslizamiento de acuerdo al modelo utilizado, esto se debe a que estas zonas predominan relieves llanos en el cual la probabilidad de ocurrencia de un deslizamiento es muy baja, asimismo, los puntos de control en los cuales no ocurre deslizamiento coinciden con los valores predichos.

A continuación, en la Figura 20, se observa la base de datos de deslizamiento utilizado para el entrenamiento del modelo de red neuronal sobre el mapa de susceptibilidad del territorio a deslizamientos.


Figura 20 Base de datos de deslizamientos sobre niveles de susceptibilidad del territorio.



En la Figura 21, se observa la vista ampliada de los niveles de susceptibilidad, en el cual predomina el nivel bajo, estas zonas son cercanas al litoral marino por lo que estas áreas predominan en relieve plano, asimismo, se observa que los puntos negros (ausencia de


deslizamiento) se presentan en mayor cantidad que los puntos azules (presencia de deslizamientos).

Figura 21 Vista ampliada 1 de los niveles de susceptibilidad del territorio a deslizamientos.



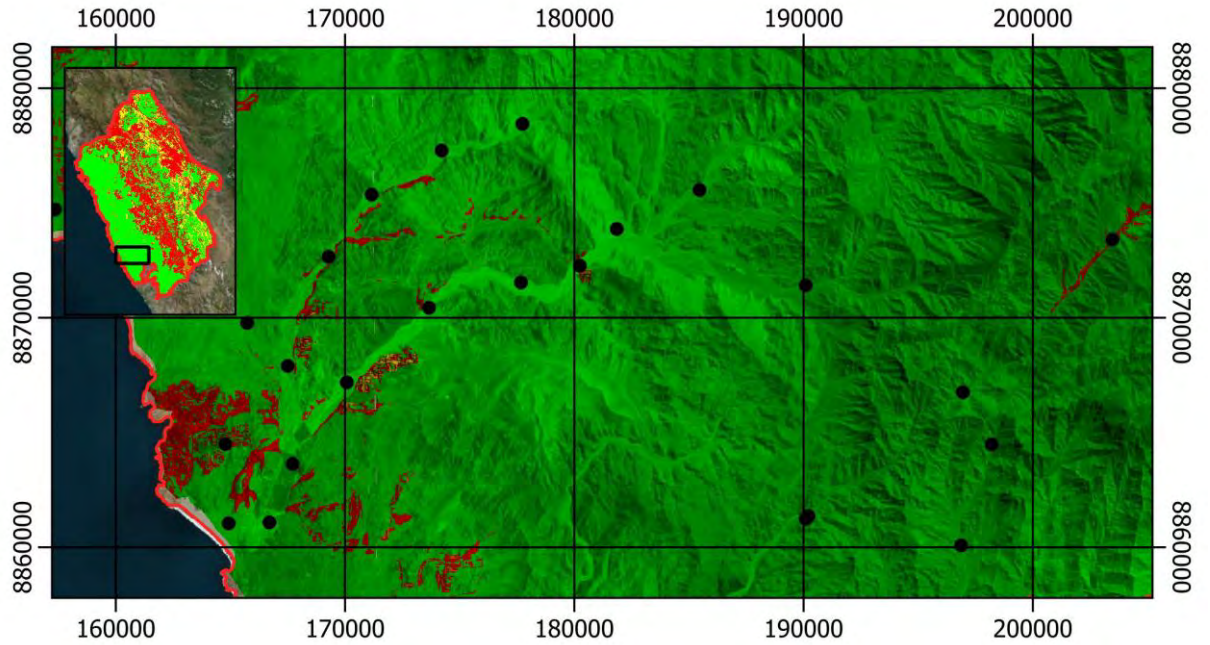
En la Figura 22, se observa de la misma manera que los puntos negros predominan; sin embargo, cerca al litoral se presentan valores de susceptibilidad alto, esto es debido a que existe la presencia de elevaciones en el lado oeste de la vista ampliada.

Figura 22 Vista ampliada 2 de los niveles de susceptibilidad del territorio a deslizamientos.




La vista ampliada al suroeste del área de estudio (Figura 23), predomina el nivel bajo; sin embargo, existe la presencia de pequeñas áreas con nivel muy alto, los cuales en su mayoría pertenecen a laderas de colinas.

Figura 23 Vista ampliada 3 de los niveles de susceptibilidad del territorio a deslizamientos.




La zona sur de la parte central del área de estudio, representado por la Figura 24, muestra zonas con nivel de susceptibilidad muy alto, los cuales pertenecen a zonas de montaña, asimismo se observa que existe evidencia de deslizamientos en dichas áreas.

Figura 24 Vista ampliada 4 de los niveles de susceptibilidad del territorio a deslizamientos.



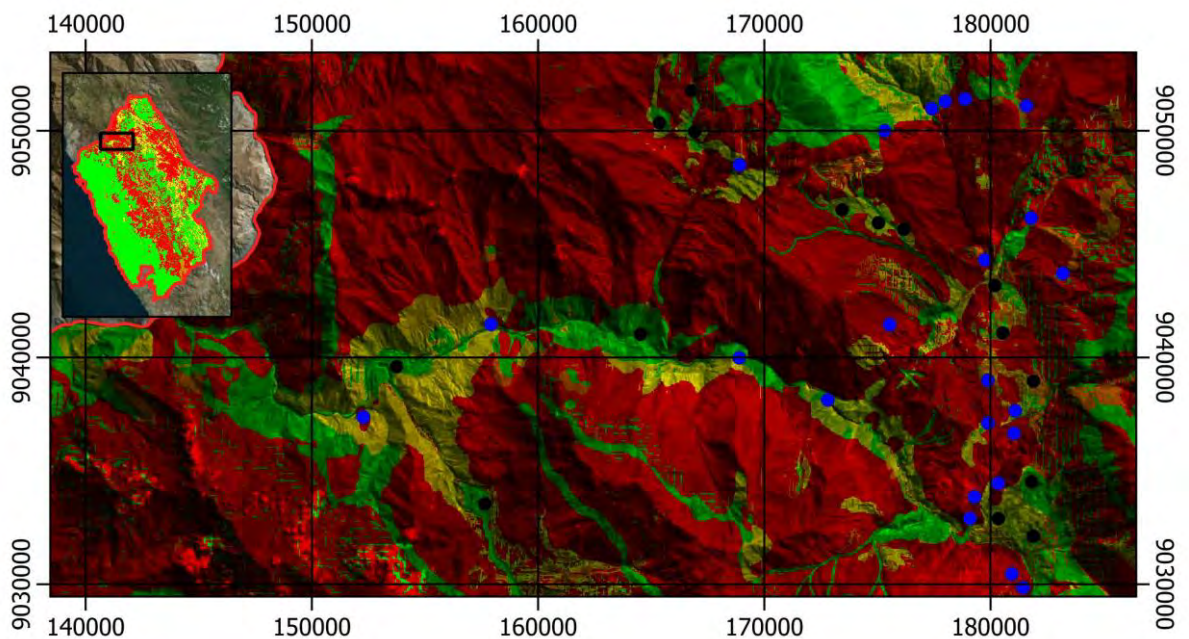
En la Figura 25, se muestra la vista ampliada de la zona central del área de estudio en donde predomina el nivel muy alto de susceptibilidad a deslizamiento; asimismo, se muestra que algunos puntos negros (ausencia de deslizamiento) pertenecen a zonas de niveles altos de susceptibilidad.

Figura 25 Vista ampliada 5 de los niveles de susceptibilidad del territorio a deslizamientos.




La zona norte central del área de estudio (Figura 26) predomina el nivel muy alto de susceptibilidad, en los cuales están comprendidos los puntos azules, así como los puntos negros están comprendido en el nivel bajo de susceptibilidad a deslizamiento.

Figura 26 Vista ampliada 6 de los niveles de susceptibilidad del territorio a deslizamientos.




En la Figura 27, se muestra la zona noreste del área de estudio, en el cual hay una concentración de puntos azules comprendidos en el nivel muy alto de susceptibilidad.

Figura 27 Vista ampliada 7 de los niveles de susceptibilidad del territorio a deslizamientos.



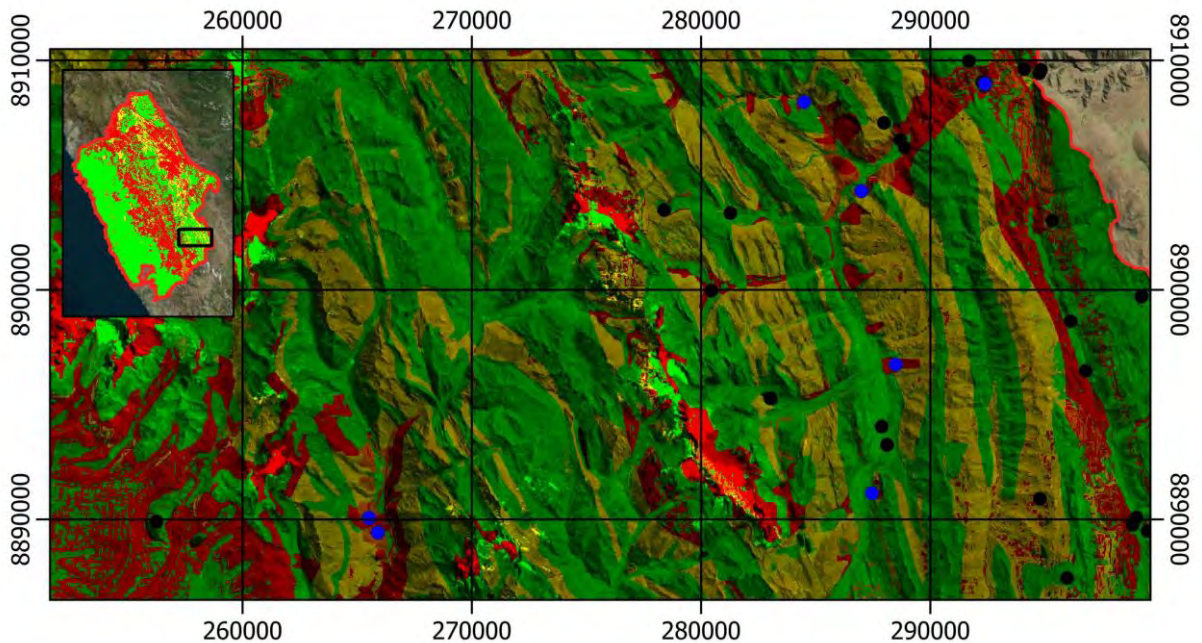
La zona este de la vista ampliada (Figura 28) se observa la distribución de los puntos azules los cuales están comprendidos en el nivel muy alto de susceptibilidad a deslizamientos; sin embargo, se presenta algunos puntos negros en el mismo nivel de susceptibilidad.

Figura 28 Vista ampliada 8 de los niveles de susceptibilidad del territorio a deslizamientos.



La Figura 29, muestra la vista ampliada de la zona sureste del área de estudio, en esta vista, no se observa gran cantidad de puntos de muestreo; sin embargo, las zonas de ladera de montaña están comprendidas como niveles medio y alto a deslizamiento, y las zonas de depresión, presentan niveles bajo a deslizamientos.

Figura 29 Vista ampliada 9 de los niveles de susceptibilidad del territorio a deslizamientos.

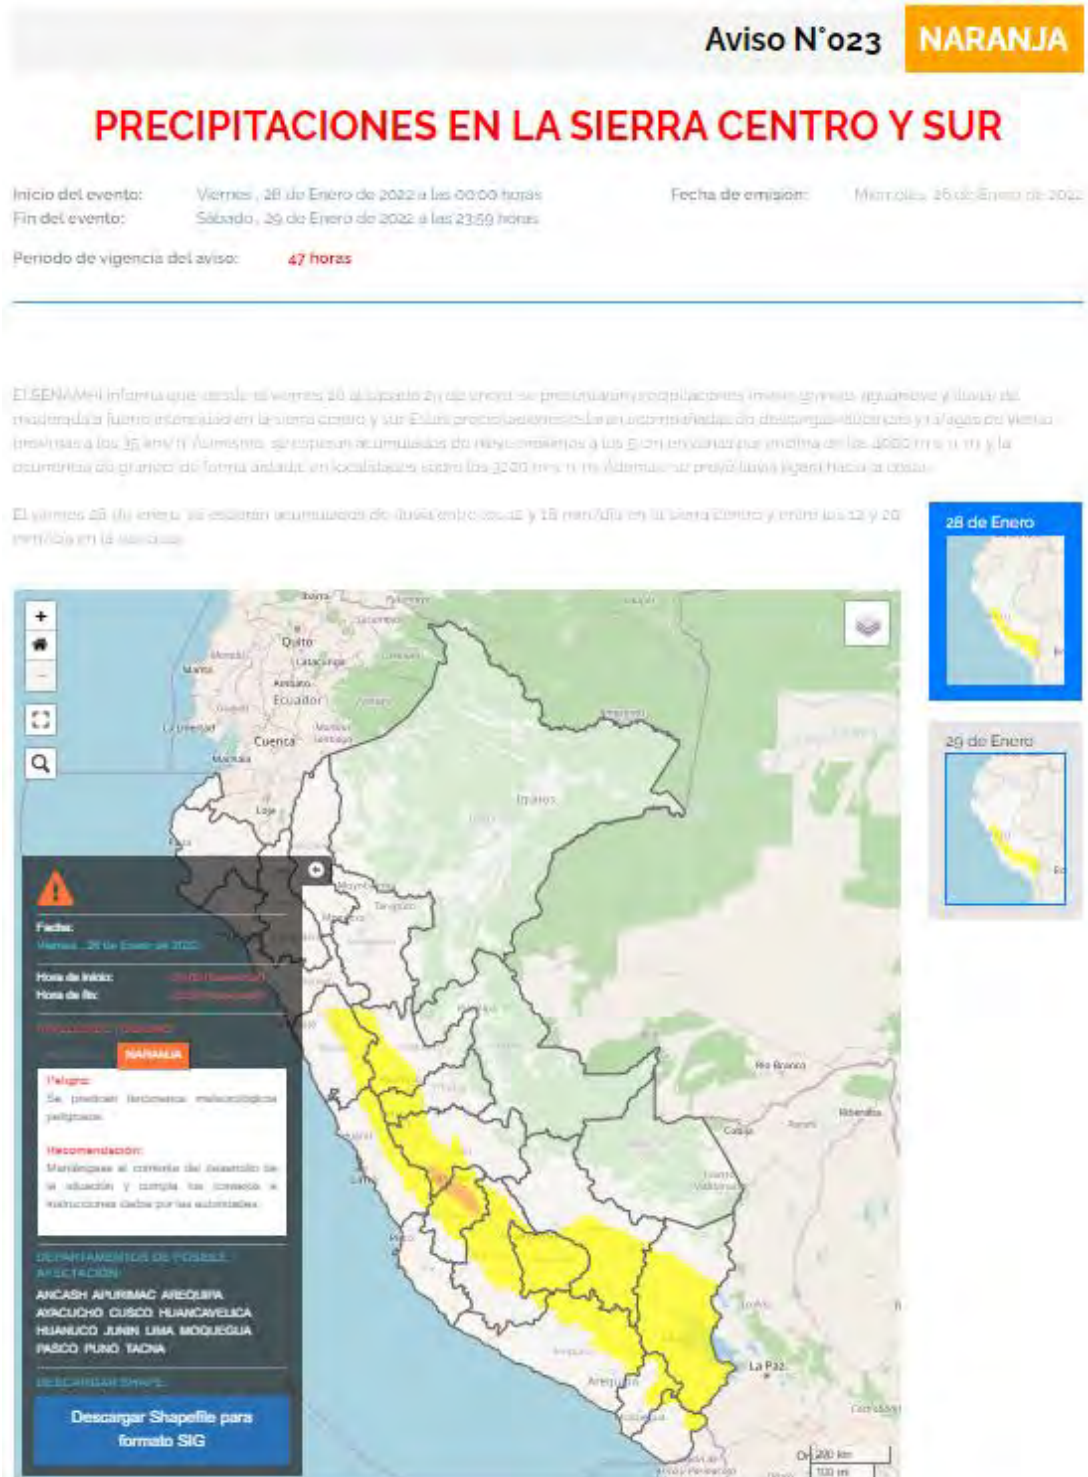


El modelo de red neuronal pudo clasificar espacialmente las zonas de mayor susceptibilidad a deslizamientos, en los cuales están ubicados los puntos azules; sin embargo, con las vistas ampliadas de las figuras 21-29, se puede observar que existen zonas en los cuales por sus características geográficas y a la vista satelital no presentarían deslizamientos, pero el modelo los clasifica con niveles alto de susceptibilidad, el mismo caso ocurre cuando existe zonas en los cuales por sus características, sí deben ser clasificado como zonas de mayor susceptibilidad pero el modelo lo clasifica como nivel bajo a deslizamiento.

Este mapa de susceptibilidad del territorio a deslizamientos, representa cuáles son las zonas más probables a deslizarse por las características propias que presenta el terreno, tales como el tipo de depósito presente (unidad geológica superficial), el tipo de geoforma (unidad geomorfológica), el tipo de unidad hidrogeológica, el tipo de cobertura vegetal y el grado de pendiente. Asimismo, al presentarse una precipitación pluvial, las zonas de mayor susceptibilidad a deslizamiento tendrían mayor probabilidad a una ocurrencia de deslizamientos que en las zonas de baja.

Para poder predecir con cierto grado de probabilidad la ocurrencia de estos deslizamientos es importante conocer con anticipación la ocurrencia de esta precipitación pluvial, así como el grado de peligro que generaría sobre ese terreno, es decir, qué tan intensa es la lluvia presente en un espacio geográfico. Para esto se utilizó los pronósticos de avisos meteorológicos (Figura 30) del Servicio Nacional de Hidrología y Meteorología del Perú (Senamhi).

Figura 30 Pronósticos de lluvia del Senamhi.



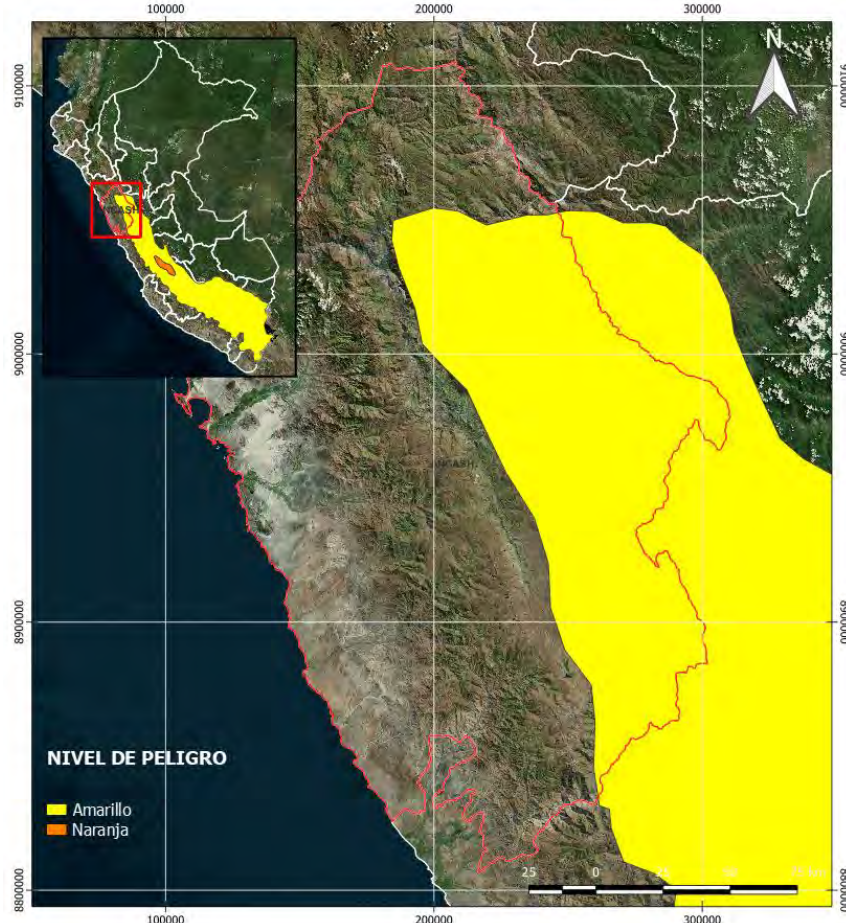
En la Figura 30, se observa el pronóstico de lluvia del Senamhi publicado el 26 de enero del 2022, en el cual presenta aviso de lluvia a partir del 28.01.22 0:00 hasta el 29.01.22 23.59. Este aviso meteorológico, está representado por polígonos con un color característico por cada nivel de peligro de lluvia, en cual cada nivel presenta una característica específica y su recomendación correspondiente. Los cuales se aprecian en la Figura 31.

Figura 31 Niveles de peligro de los pronósticos de lluvia de Senamhi.

AMARILLO	NARANJA	ROJO
<p>Peligro: Pueden ocurrir fenómenos meteorológicos peligrosos que, sin embargo, son normales en esta región.</p> <p>Recomendación: Manténgase al corriente del desarrollo de la situación meteorológica. Sea prudente si realiza actividades al aire libre que puedan acarrear riesgos en caso de mal tiempo.</p>	<p>Peligro: Se predicen fenómenos meteorológicos peligrosos.</p> <p>Recomendación: Manténgase al corriente del desarrollo de la situación y cumpla los consejos e instrucciones dados por las autoridades.</p>	<p>Peligro: Se predicen fenómenos meteorológicos de gran magnitud.</p> <p>Recomendación: Sea extremadamente precavido. Esté al corriente en todo momento del desarrollo de la situación y cumpla los consejos e instrucciones dados por las autoridades.</p>

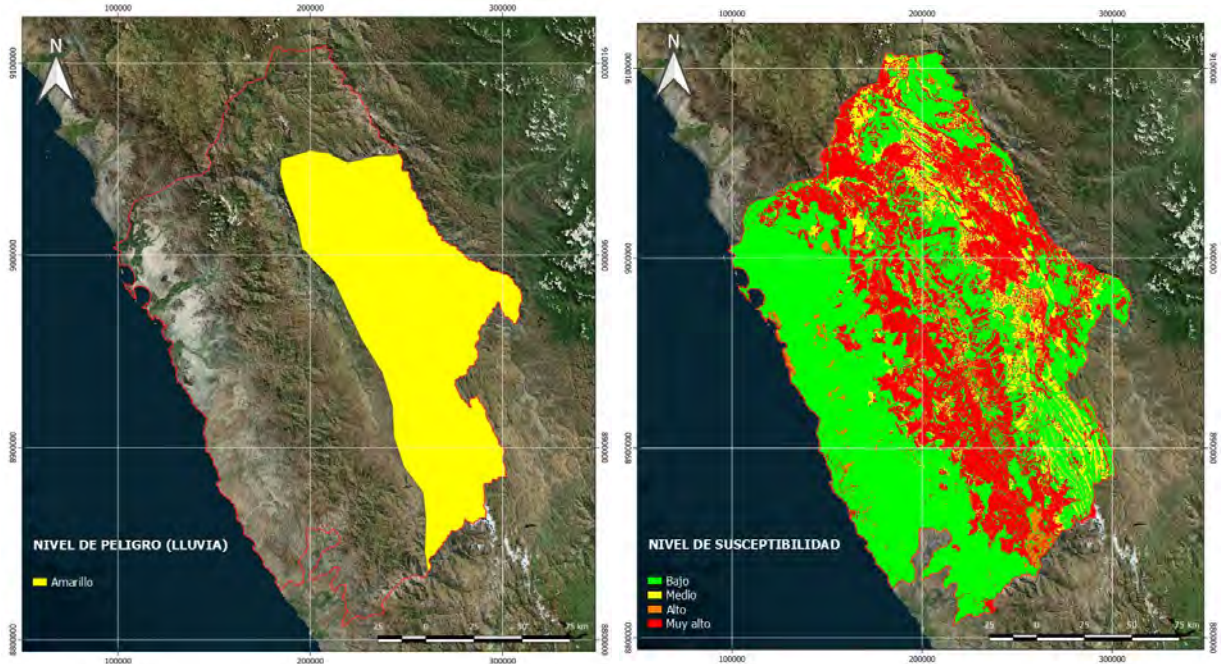
Esta información de niveles está disponible para cualquier usuario en formato shapefile (*.shp), el cual es una representación geográfica vectorial de las zonas que presentan peligro por lluvia (Figura 32).

Figura 32 Vista ampliada del pronóstico de lluvia en la zona de estudio.



Luego de haber identificado la zona del área de estudio que estará expuesta a un determinado nivel de peligro de lluvia, se integra ambas informaciones (susceptibilidad y magnitud de lluvia), para obtener las zonas de mayor probabilidad de ocurrencia de deslizamiento en base a las características propias del terreno y del pronóstico de lluvia determinado por su magnitud (Figura 33).

Figura 33 Mapa de nivel de peligro por pronóstico de lluvia y susceptibilidad del territorio a deslizamientos.



En la Figura 33, se observa la información que se va a integrar para predecir las zonas con mayor probabilidad a deslizarse ante la ocurrencia de una lluvia. Para esto, se categoriza numéricamente a cada nivel de peligro por lluvia y susceptibilidad a deslizamiento para calcular la probabilidad de deslizamiento por lluvia.

Esta categorización consiste en asignar el valor de 0 al nivel Amarillo del peligro por lluvia, el valor de 1 al nivel Naranja del peligro por lluvia, y 2 al nivel rojo del peligro por lluvia; mientras que a los niveles bajo, medio, alto y muy alto de susceptibilidad se les asignan valores del 1 al 4, respectivamente.

Para obtener el nivel de probabilidad a deslizamiento, se suman los niveles por cada pixel del área que estará expuesta a la precipitación, obteniéndose así los niveles de probabilidad a deslizamiento, el rango de [1,2], es asignado como nivel bajo; el rango <2,3], es asignado como nivel medio; el rango <3,4], es asignado como nivel alto; y el rango <4,6] es asignado como nivel muy alto a deslizamiento.

Esta asignación de numeración por niveles y la integración de estos valores para el cálculo del nivel de deslizamiento se puede observar en la Figura 34.

Figura 34 Esquema de cálculo de nivel de probabilidad a deslizamiento en base a pronósticos de lluvia.

Nivel de peligro por lluvia	Rojo	2	3 Medio	4 Alto	5 Muy alto	6 Muy alto
	Naranja	1	1 Bajo	3 Medio	4 Alto	5 Muy alto
	Amarillo	0	1 Bajo	2 Bajo	3 Medio	4 Alto
			1	2	3	4
			Bajo	Medio	Alto	Muy alto
Nivel de susceptibilidad a deslizamiento						

De acuerdo a la Figura 34, se utilizó este diagrama para la asignación de los niveles de probabilidad a deslizamiento, estos niveles obtenidos se les denominará niveles de peligro por deslizamiento.

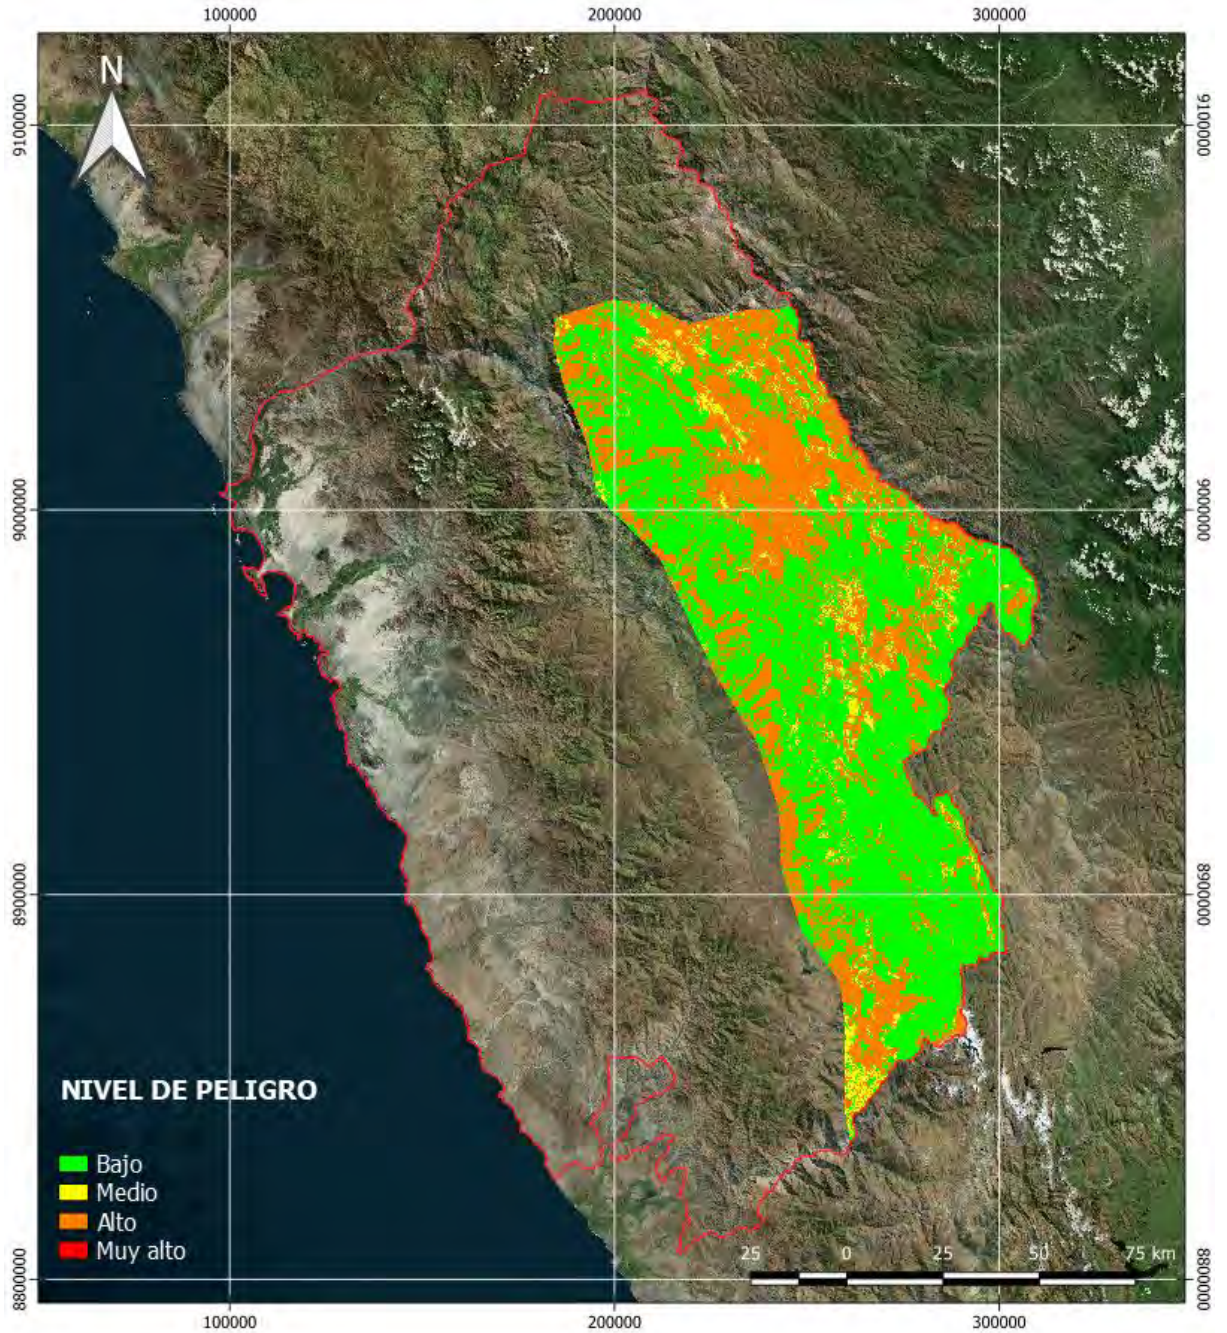
En la Figura 35, se puede observar el resultado final que se obtiene al integrar los niveles de susceptibilidad por deslizamiento con los niveles de peligro por lluvia, los cuales dan como resultado el nivel de peligro por deslizamiento en la zona de estudio.

Para este caso específico, se determinó que existe un nivel de peligro alto de ocurrencia de deslizamiento a causa de las lluvias en la zona. Estas zonas identificadas como nivel de peligro alto pertenecen en su mayoría a zonas de pendiente alta, los cuales se vuelven inestables a causa de las precipitaciones pluviales.

No existe un nivel de peligro muy alto de ocurrencia de deslizamiento; sin embargo, el nivel alto nos sugiere que hay que tener precauciones en zonas las en las que se presenta este nivel.

Esta predicción de deslizamiento realizada, utilizando el pronóstico de lluvia de la entidad oficial, nos brinda un determinado nivel de peligro con 24 horas de anticipación. Esto permitiría a las autoridades tener las precauciones en las zonas de nivel de peligro alto y muy alto, así como a la población y medios de transporte que transitan por dichas áreas con probabilidades altas a deslizamiento.

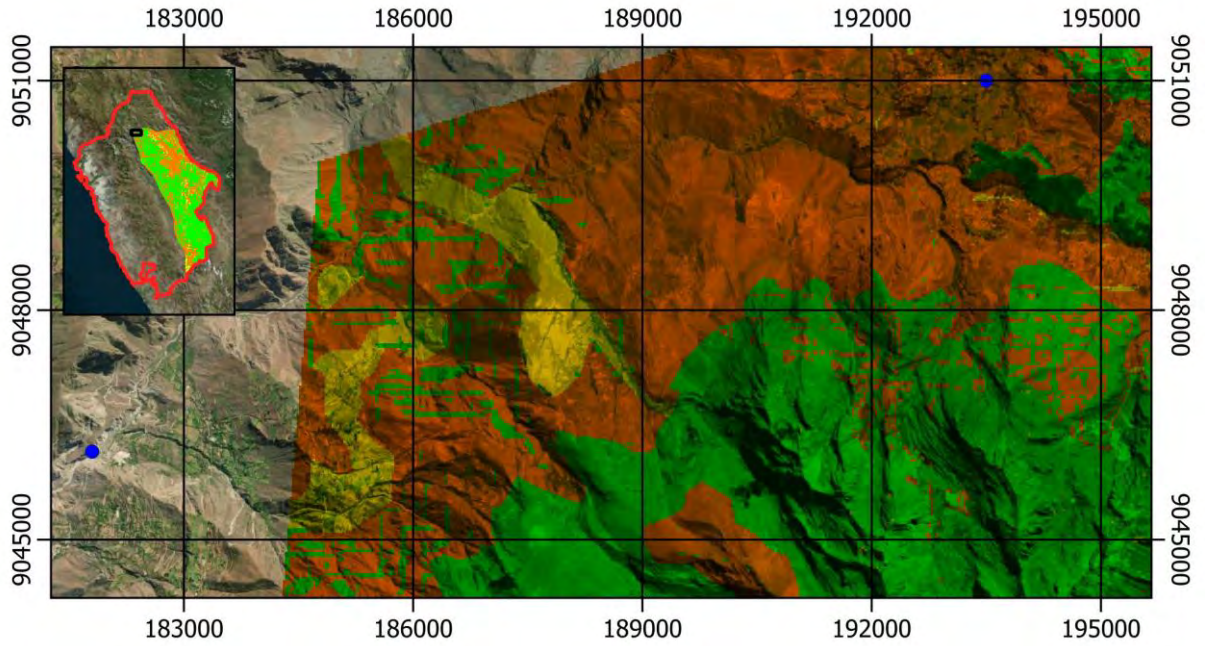
Figura 35 Niveles de predicción a deslizamiento por pronóstico de lluvia.



Para obtener una mejor visualización de los niveles de peligro por deslizamiento originados por lluvias en base a pronósticos, se muestra las vistas ampliadas de los resultados.


En la Figura 36, se muestra la vista la vista ampliada de la zona noreste del resultado del mapa de peligro por deslizamiento originado por el pronóstico de lluvias. Se observa, además, que en la zona de peligro alto se visualiza un punto del inventario de deslizamiento.

Figura 36 Vista ampliada 1 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.




En la Figura 37, se observa la vista ampliada tridimensional de los niveles de peligro por deslizamiento, en la cual se observa que la parte peligro alto, está cubierto en las zonas de ladera de montaña en las que se registró un deslizamiento. Asimismo, existe zonas de montaña que figuran como peligro bajo, el cual se puede interpretar que debido a las propiedades de suelo este tiene poca probabilidad a deslizarse o que debido al tipo de material y relieve no se ha registrado algún deslizamiento con dichas características.

Figura 37 Vista ampliada tridimensional 1 del nivel de peligro por deslizamiento.




La zona oeste (Figura 38) del mapa de peligro por deslizamiento nos muestra zonas de peligro alto, medio y bajo en su mayor proporción, así como la ubicación de 2 puntos de inventario de deslizamiento y 1 de ausencia de deslizamiento.

Figura 38 Vista ampliada 2 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.

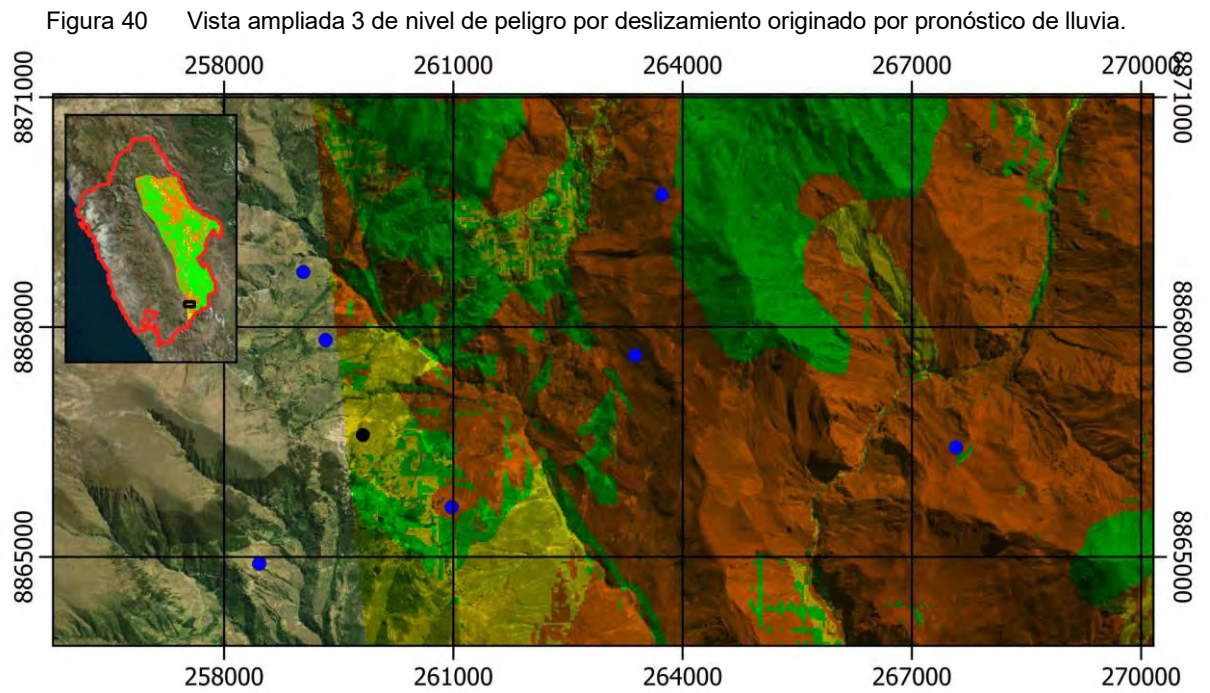


En la Figura 39, se observa de manera tridimensional que las zonas de depresión figuran como nivel de peligro bajo y las zonas de ladera adenañas a los ríos como nivel de peligro alto.


Figura 39 Vista ampliada tridimensional 2 del nivel de peligro por deslizamiento.



La zona sureste (Figura 40) del mapa de peligro por deslizamiento nos muestra zonas de peligro alto en las cuales están comprendido los puntos azules, los cuales representan deslizamientos registrados en dichas zonas.




En la Figura 41, se observa de manera tridimensional que las zonas de alta pendiente y laderas de montaña son las que en su mayoría se encuentran en peligro alto y en las cuales también se han registrado deslizamientos.




La zona sur del mapa de peligro por deslizamiento (Figura 42) nos muestra que las zonas de carretera y de curso del río están representados por el nivel de peligro bajo, mientras que las zonas de montaña en nivel de peligro alto, debido al pronóstico de lluvia determinado.

Figura 42 Vista ampliada 4 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.




En la vista tridimensional de la Figura 43, se observa que las zonas de depresión (cursos de río) se encuentran en peligro bajo, asimismo, algunas zonas que presentan pendientes relativamente bajas se encuentran en peligro medio.

Figura 43 Vista ampliada tridimensional 4 del nivel de peligro por deslizamiento.




La zona centro (Figura 44) del mapa de peligro por deslizamiento nos muestra zonas de peligro alto en las que están contenidos los registros de deslizamientos; sin embargo, se visualiza una zona de registro en la que figura como nivel bajo.

Figura 44 Vista ampliada 5 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.




En la Figura 45, se observa de manera tridimensional las zonas que presentan peligro alto, así como la zona de registro de deslizamiento en la que se presenta con peligro bajo, el cual es considerado como parte del error de incertidumbre del modelo de susceptibilidad.

Figura 45 Vista ampliada tridimensional 5 del nivel de peligro por deslizamiento.




La zona norte del mapa de peligro por deslizamiento (Figura 46) nos muestra zonas de peligro alto en gran parte del área de la vista ampliada, así como 2 puntos negros que representan ausencia de deslizamiento como nivel de peligro bajo.

Figura 46 Vista ampliada 6 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.




Otra vista tridimensional (Figura 47), nos muestra desde dicha perspectiva que los puntos de ausencia de deslizamiento, vienen a ser zonas cercanas a los ríos, en el cual las pendientes son mucho menos a las zonas de ladera de montaña que presentan nivel de peligro alto.

Figura 47 Vista ampliada tridimensional 6 del nivel de peligro por deslizamiento.




La zona noreste (Figura 48) del mapa de peligro por deslizamiento nos muestra zonas de peligro alto en las zonas de ladera de montaña. Cabe indicar que en esta vista ampliada no se ubican puntos de registro de deslizamiento, el cual es un indicio del aporte del modelo de susceptibilidad generado con las redes neuronales.

Figura 48 Vista ampliada 7 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.




En la Figura 49, se observa de manera tridimensional las zonas de ladera que están representado por un nivel de peligro alto y las zonas de quebrada y del curso de los ríos como nivel de peligro bajo.

Figura 49 Vista ampliada tridimensional 7 del nivel de peligro por deslizamiento.




La zona centro este (Figura 50) del mapa de peligro por deslizamiento nos muestra zonas de peligro alto en zonas de ladera y peligro medio en zonas de baja pendiente; sin embargo, existen zonas de alta pendiente que también figuran como peligro bajo, esto puede deberse a los otros tipos de factores condicionantes que presentan estas zonas.

Figura 50 Vista ampliada 8 de nivel de peligro por deslizamiento originado por pronóstico de lluvia.

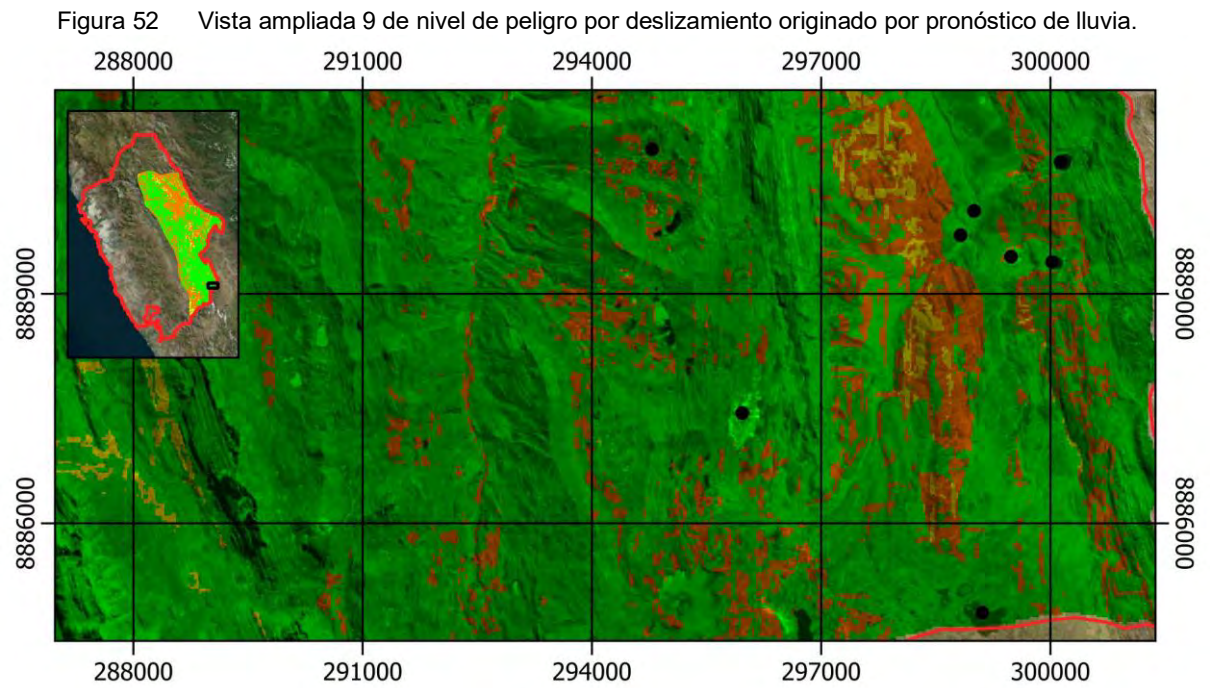


En esta vista tridimensional (Figura 51) se puede apreciar de mejor forma las zonas de registro de deslizamiento en las cuales están sobre las regiones que representan el nivel de peligro alto.

Figura 51 Vista ampliada tridimensional 8 del nivel de peligro por deslizamiento.




La zona sureste (Figura 52) del mapa de peligro por deslizamiento nos muestra gran parte del área que presenta niveles de peligro bajo, asimismo, se ubican 7 puntos negros (ausencia de deslizamiento) que se ubican en las zonas del mismo nivel de peligro.



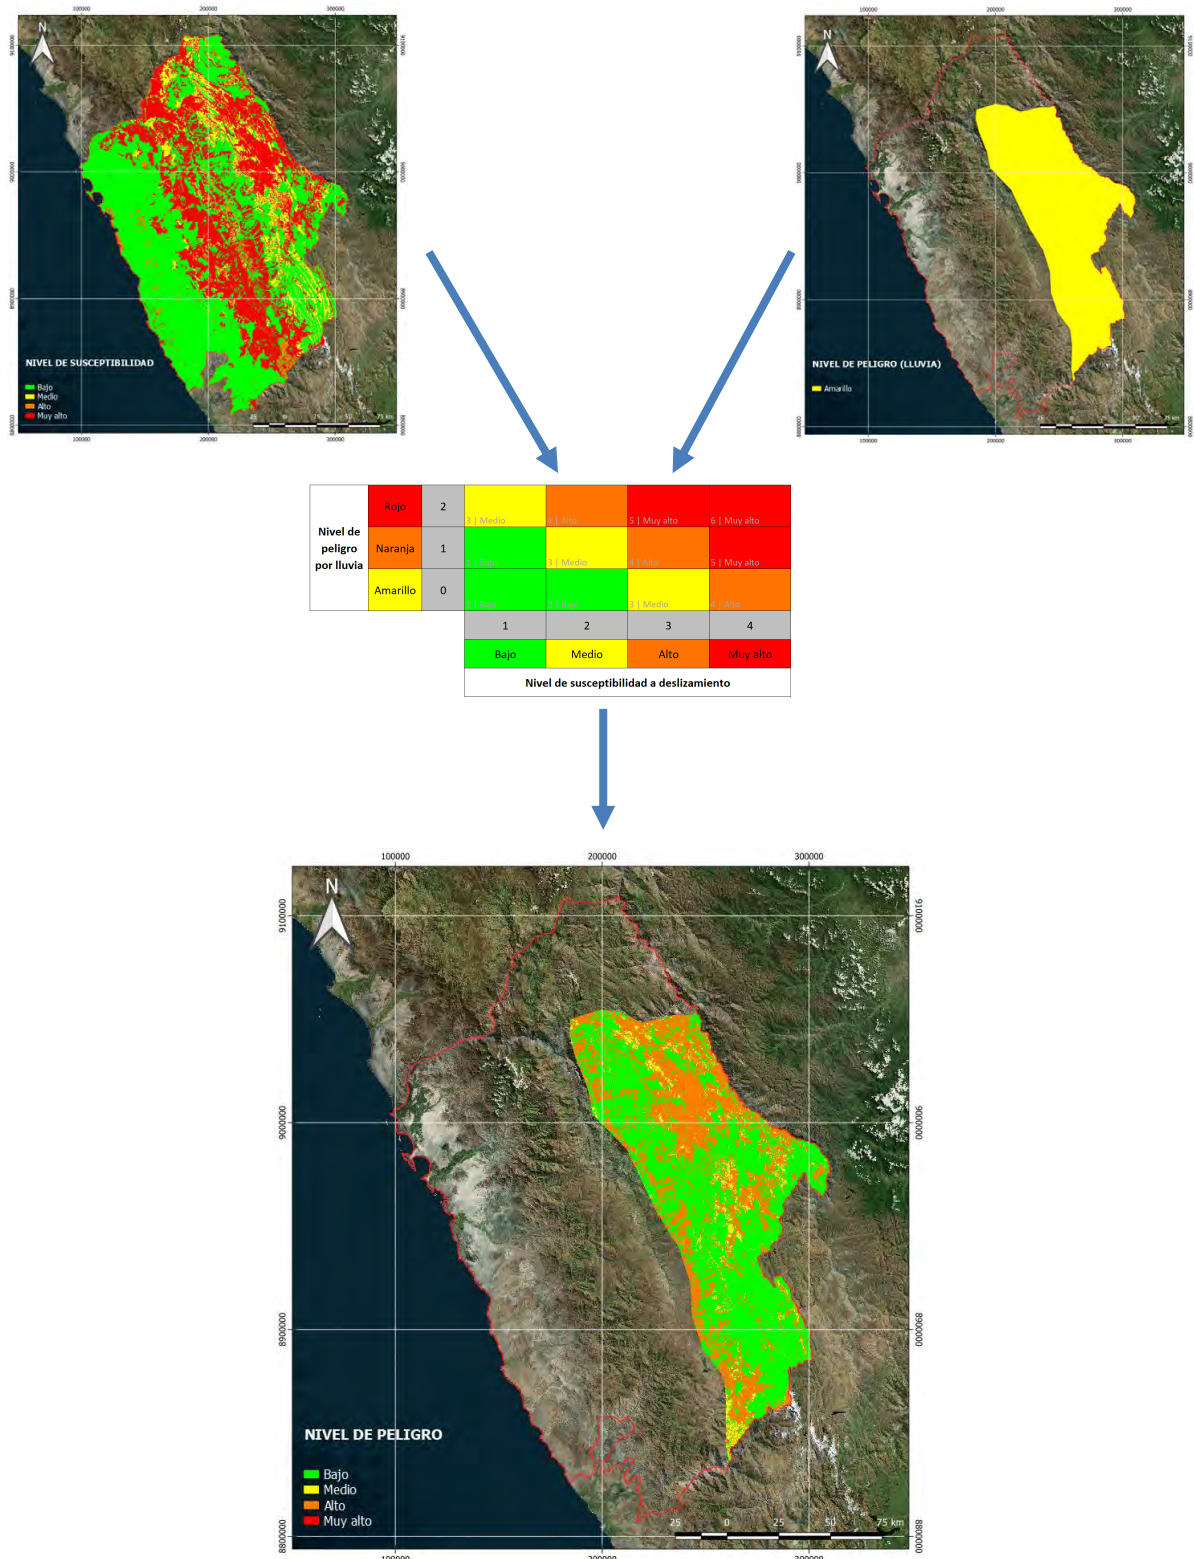
En la Figura 53, se observa de manera tridimensional que las zonas en donde se ubican los puntos negros son zonas de centros poblados o de pendientes bajas.

Figura 53 Vista ampliada tridimensional 9 del nivel de peligro por deslizamiento.



Finalmente, se muestra el esquema de este último procedimiento que se tiene que realizar para cada pronóstico de lluvia (aviso meteorológico), quedando el mapa de susceptibilidad constante, mientras que los pronósticos de lluvia van a variar de acuerdo a las condiciones meteorológicas del tiempo en la zona de estudio (Figura 54).

Figura 54 Esquema final del procedimiento para el cálculo de los niveles de peligro por deslizamiento.



7. Conclusiones y trabajo futuro

En este apartado se muestra las conclusiones obtenidas a partir de los resultados de la aplicación de la metodología propuesta y las futuras líneas de trabajo que podrían implementarse en la aplicación de esta metodología.

7.1. Conclusiones

Los métodos oficiales que actualmente se aplican en Perú para la determinación del mapa de susceptibilidad a deslizamientos están basados en métodos heurísticos semicuantitativos, los cuales dependen de la experiencia del especialista en la aplicación y asignación de pesos ponderados para poder hallar los rangos de susceptibilidad al deslizamiento; asimismo, las evaluaciones del riesgo a escala regional aplicados en Perú, utilizan como dato de entrada, estos rangos de susceptibilidad para establecer un escenario de posibles ocurrencia de peligros a movimientos en masa. Al aplicar la metodología propuesta, se muestra que los cálculos para establecer los rangos de susceptibilidad se realizan aplicando un método cuantitativo el cual no requiere de la asignación arbitraria del especialista en el proceso de asignación de pesos ponderados, sino que se basa en probabilidades de ocurrencia según el inventario nacional de deslizamientos. Esto permitió obtener mapas de susceptibilidad con mayor objetividad en la asignación de rangos, así como, conocer la exactitud que presenta el modelo entrenado en base a este inventario, lo cual no se puede conocer actualmente debido a los métodos utilizados en el Perú.

El mapa de susceptibilidad generado con la metodología propuesta representa una mejora en la introducción de métodos cuantitativos para la generación de estos mapas; asimismo, este mapa es un insumo para la generación de un mapa de predicción de deslizamientos en base a los pronósticos de lluvias que emite la entidad oficial. Estos también podrán ser utilizados en la generación de evaluaciones del riesgo a escala regional en el cual uno de los insumos utilizados son estos mapas de susceptibilidad generados con métodos de aprendizaje automático.

Finalmente, debido a la dinámica y características presentadas en el territorio, estos deslizamientos analizados en la metodología son deslizamientos súbitos desencadenados por lluvias. Como parte de la mejora de este análisis se puede incluir las lluvias precedentes a las del pronóstico con la intención de considerar las condiciones iniciales del suelo antes de la ocurrencia del deslizamiento, debido a la humedad que presentaría al infiltrarse el agua de las lluvias precedentes.

Asimismo, los resultados de los mapas de susceptibilidad generados por las redes neuronales están directamente vinculados con la cantidad de deslizamientos registrados en las zonas, es decir, si se tiene una gran cantidad de registro de deslizamientos, los resultados del modelo de redes neuronales podrán asignar las zonas de susceptibilidad a deslizamientos con mayor precisión.

7.2. Líneas de trabajo futuro

Las líneas de trabajo futuro relacionados a esta temática serían implementar una plataforma espacial en la que se puedan mostrar de manera automatizada los resultados de las zonas de predicción de deslizamientos por cada pronóstico de lluvia emitido por la entidad oficial de meteorología; Así como también, el cálculo de un mapa de peligro, vulnerabilidad y riesgo, en el que se pueda mostrar los posibles impactos que generarían estos deslizamientos sobre el territorio, sea a nivel monetario, número de vidas expuestas y los diferentes tipos de elementos expuestas en la zona (viviendas, colegios, hospitales, parcelas agrícolas, etc.).

Esta metodología también ayudaría en enfocar las zonas de mayor susceptibilidad a deslizamientos para la realización de estudios a escala de detalle (mayor o igual a 1:5,000) con la finalidad de reducir el riesgo de desastres, implementando obras de reducción para el control y estabilización de las laderas susceptibles a deslizamientos.

Asimismo, se puede trabajar en los modelos de pronóstico implementando métodos de inteligencia artificial para obtener mejores pronósticos que puedan integrarse al modelo de susceptibilidad para generar mapas de peligro con mayor precisión para la predicción de deslizamientos.

Por otro lado, estos modelos de susceptibilidad y de predicción pueden integrarse con la red nacional de carreteras para que mediante los resultados, poder identificar los tramos de carreteras que puedan estar expuestos a deslizamientos con el propósito que las empresas encargadas en el mantenimiento y rehabilitación de carreteras puedan tener una acción oportuna en aquellos tramos que puedan estar afectados a un deslizamiento, así como integrar una aplicación en el que los conductores mediante su ubicación GPS puedan tener precauciones al transitar por tramos que indiquen un nivel muy alto a ocurrencia de deslizamientos.

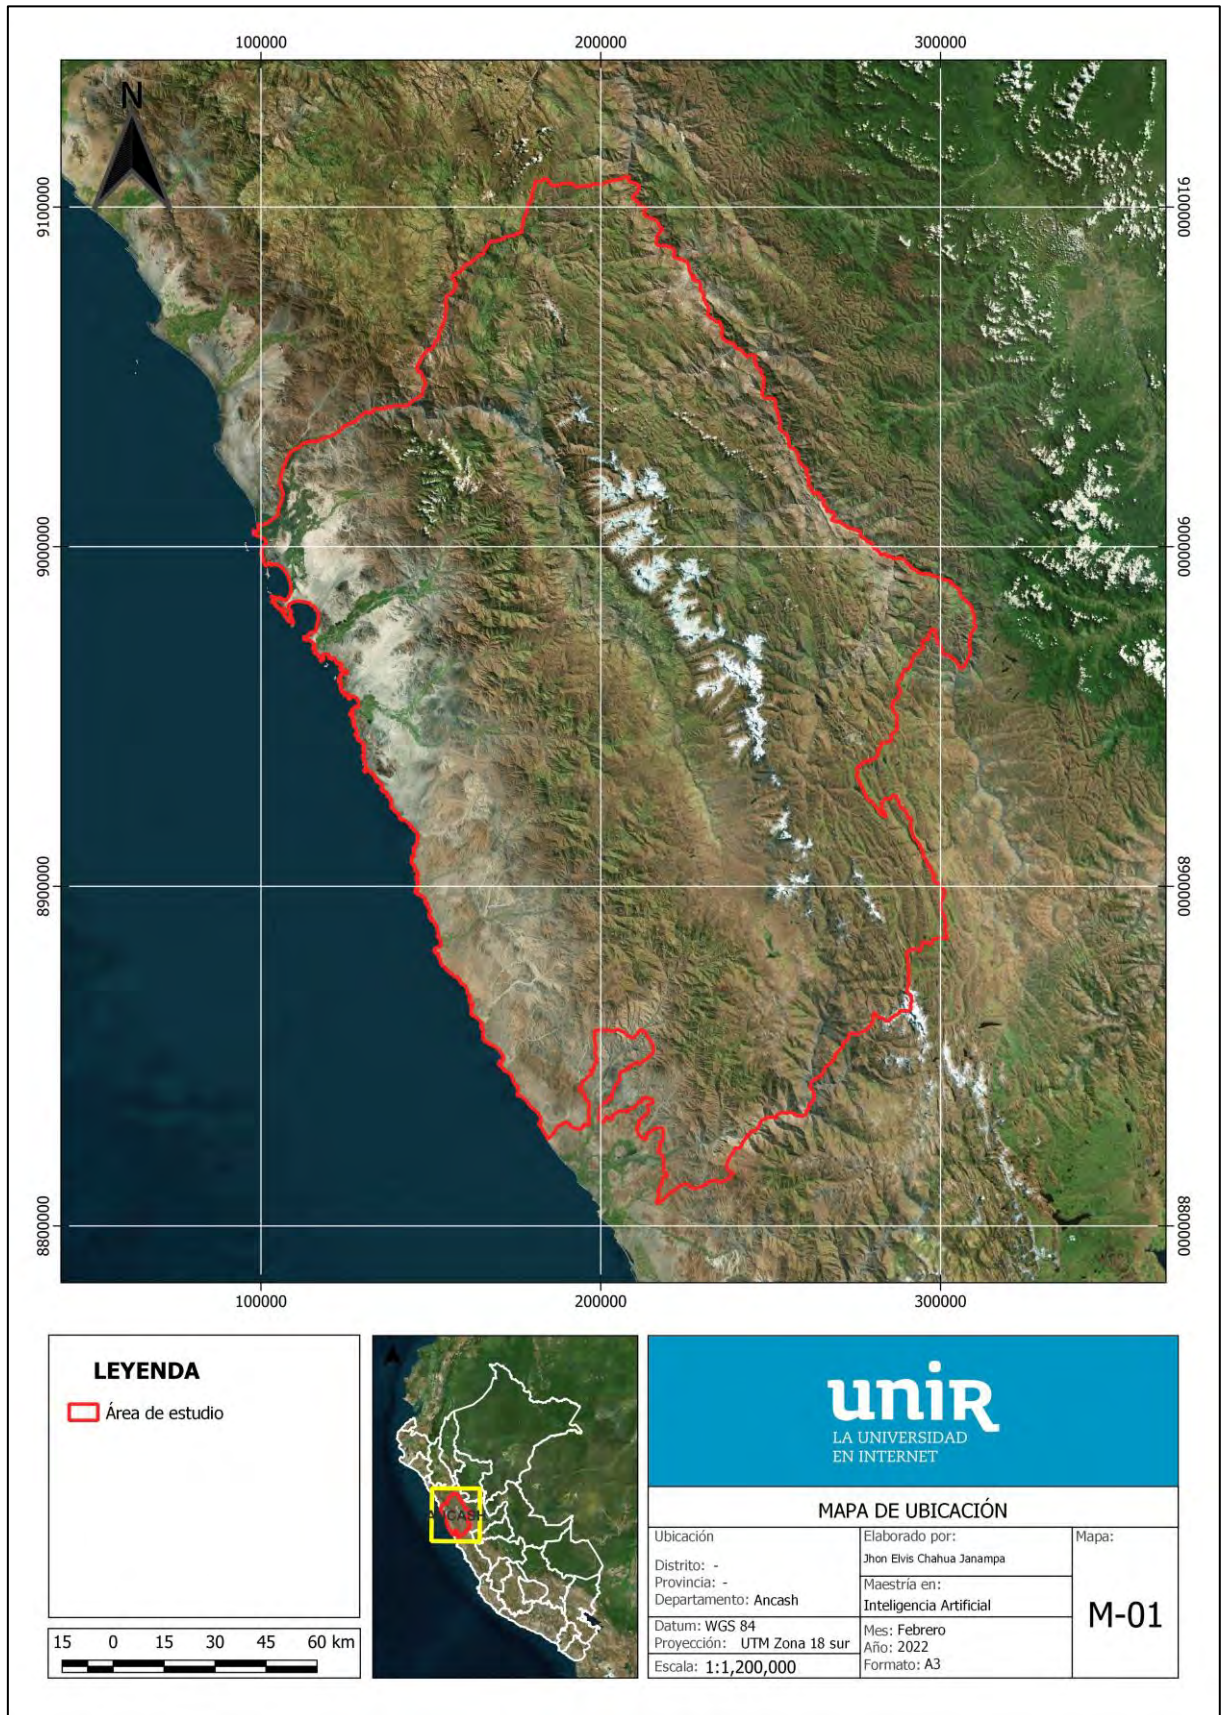
Bibliografía

- Ahmed, N., Firoze, A., & Rahman, R. M. (2020). Machine learning for predicting landslide risk of Rohingya refugee camp infrastructure. *Journal of Information and Telecommunication*, 4(2), 175-198. <https://doi.org/10.1080/24751839.2019.1704114>
- Arabameri, A., Pradhan, B., Rezaei, K., & Lee, C.-W. (2019). Assessment of Landslide Susceptibility Using Statistical- and Artificial Intelligence-Based FR–RF Integrated Model and Multiresolution DEMs. *Remote Sensing*, 11(9), 999. <https://doi.org/10.3390/rs11090999>
- Aristizábal, E., Vásquez, M., & Ruíz, D. (2019). Métodos estadísticos para la evaluación de la susceptibilidad por movimientos en masa. *TecnoLógicas*, 22(46), 39-60. <https://www.redalyc.org/journal/3442/344261485006/html/>
- Betancourt, C. A., & Castro, A. (2018). Evaluación de susceptibilidad a deslizamientos mediante redes neuronales en la avenida Simón Bolívar. *Congreso de Ciencia y Tecnología ESPE*, 13(1), Article 1. <https://doi.org/10.24133/cctespe.v13i1.723>
- Camargo Rueda, L. S., & Paez Canabal, A. (2019). *Evaluación de metodologías para el pronóstico de series de precipitación en la cuenca del río Sogamoso en el departamento de Santander Colombia*.
- Cenepred. (2012). *Escenario de Riesgo*. Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres. <https://cenepred.gob.pe/web/escenario-riesgos/>
- Cenepred. (2014). *Manual para la evaluación de riesgos originados por fenómenos naturales*. http://www.cenepred.gob.pe/web/wp-content/uploads/Guia_Manuales/Manual-Evaluacion-de-Riesgos_v2.pdf
- Chen, W., Shahabi, H., Shirzadi, A., Hong, H., Akgun, A., Tian, Y., Liu, J., Zhu, A.-X., & Li, S. (2019). Novel hybrid artificial intelligence approach of bivariate statistical-methods-based kernel logistic regression classifier for landslide susceptibility modeling. *Bulletin of Engineering Geology and the Environment*, 78(6), 4397-4419. <https://doi.org/10.1007/s10064-018-1401-8>
- García, A. C. F., & Castillo, J. N. P. (2019). Técnicas para la predicción espacial de zonas susceptibles a deslizamientos. *Avances Investigación en Ingeniería*, 16(1), 20-48. <https://doi.org/10.18041/1794-4953/avances.1.5188>
- Hong, H., Liu, J., & Zhu, A.-X. (2019). Landslide susceptibility evaluating using artificial intelligence method in the Youfang district (China). *Environmental Earth Sciences*, 78(15), 488. <https://doi.org/10.1007/s12665-019-8415-9>

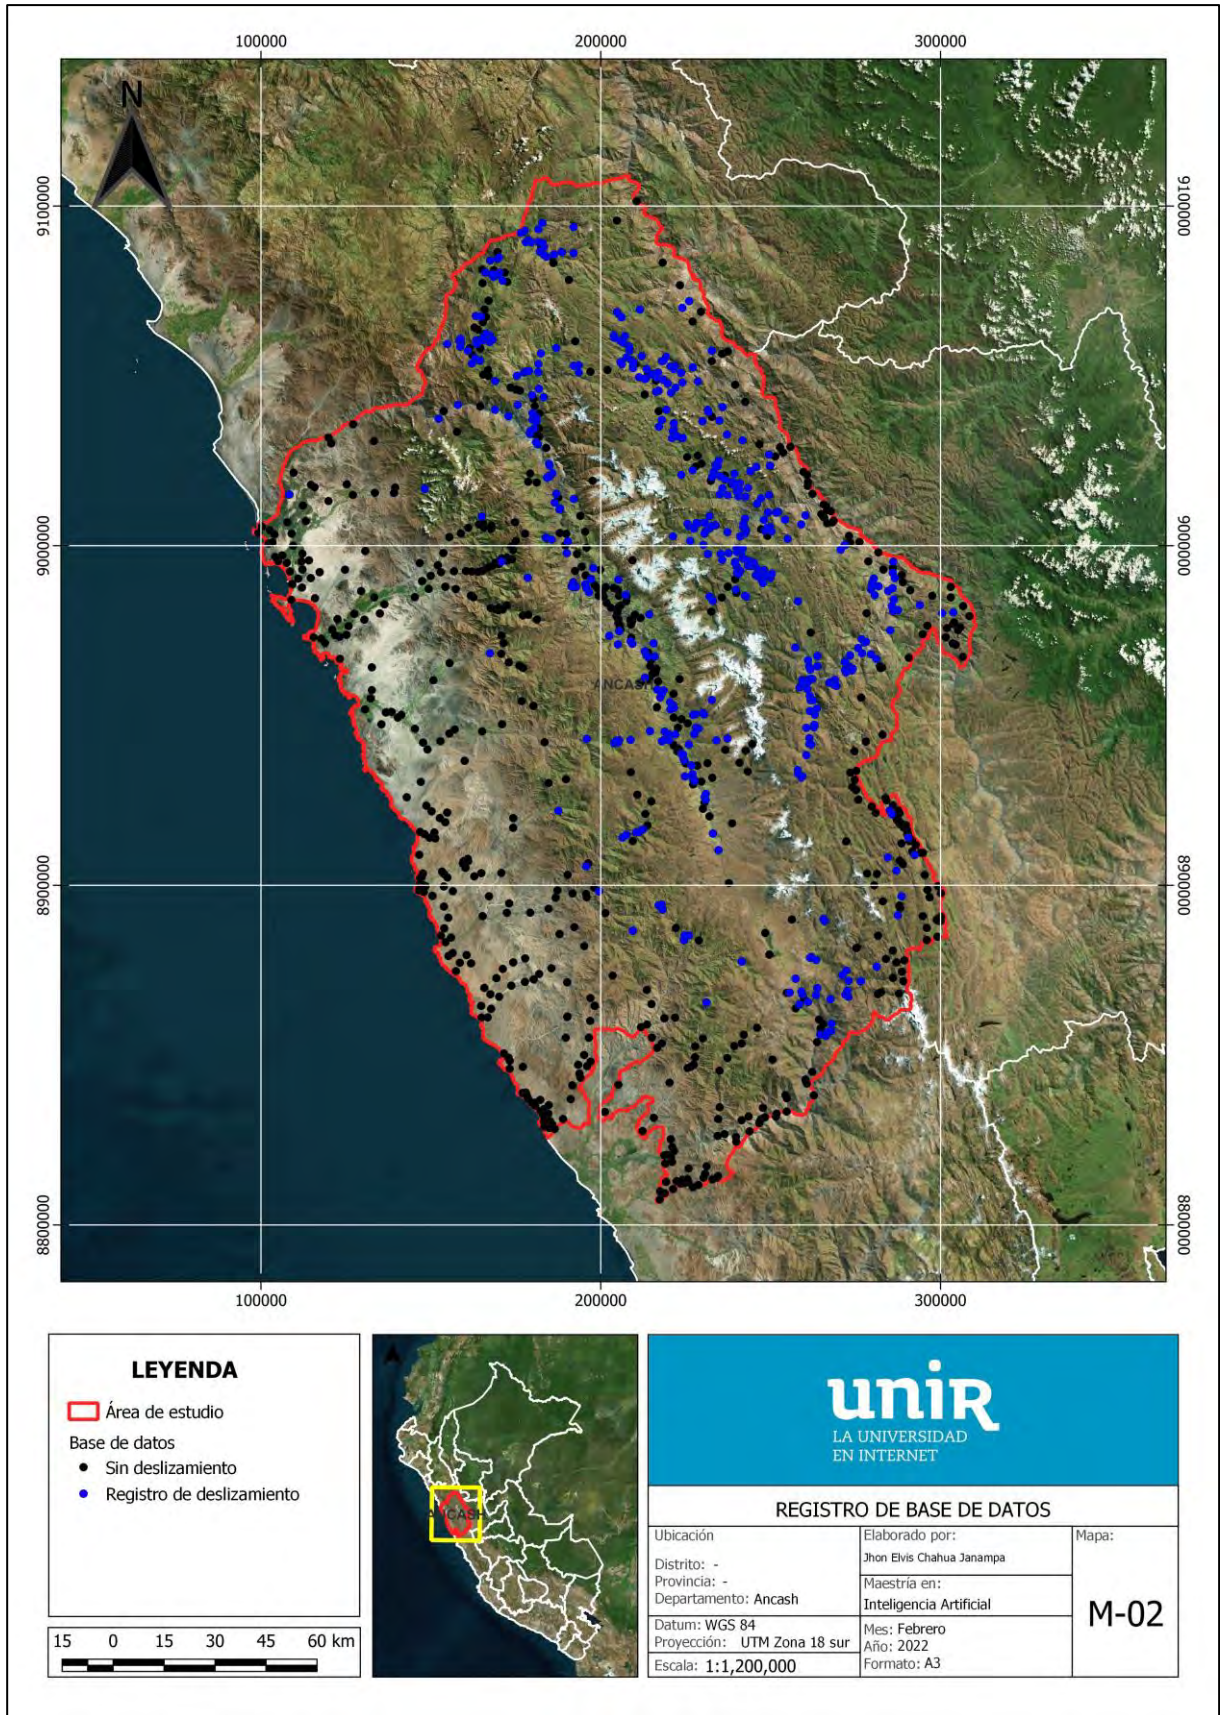
- Ingemmet. (2010). *Mapa de susceptibilidad por movimientos en masa del Perú* [Map]. https://portal.ingemmet.gob.pe/documents/73138/174996/Mapa_Movimientos_Masa.pdf
- Lei, X., Chen, W., & Pham, B. T. (2020). Performance Evaluation of GIS-Based Artificial Intelligence Approaches for Landslide Susceptibility Modeling and Spatial Patterns Analysis. *ISPRS International Journal of Geo-Information*, 9(7), 443. <https://doi.org/10.3390/ijgi9070443>
- Minam. (2011). *Memoria descriptiva del Mapa de Vulnerabilidad Física del Perú*. <http://bvpad.indeci.gob.pe/doc/pdf/esp/doc1851/doc1851-contenido.pdf>
- Nguyen, V. V., Pham, B. T., Vu, B. T., Prakash, I., Jha, S., Shahabi, H., Shirzadi, A., Ba, D. N., Kumar, R., Chatterjee, J. M., & Tien Bui, D. (2019). Hybrid Machine Learning Approaches for Landslide Susceptibility Modeling. *Forests*, 10(2), 157. <https://doi.org/10.3390/f10020157>
- Nhu, V.-H., Mohammadi, A., Shahabi, H., Ahmad, B. B., Al-Ansari, N., Shirzadi, A., Clague, J. J., Jaafari, A., Chen, W., & Nguyen, H. (2020). Landslide Susceptibility Mapping Using Machine Learning Algorithms and Remote Sensing Data in a Tropical Environment. *International Journal of Environmental Research and Public Health*, 17(14), 4933. <https://doi.org/10.3390/ijerph17144933>
- Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234-281. [https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/10.1016/0022-2496(77)90033-5)
- Senamhi. (2003). *Avisos meteorológicos*. <https://web2.senamhi.gob.pe/?p=avisos>
- Senamhi. (2017). *Uso del producto grillado Pisco de precipitación en estudios, investigaciones y sistemas operacionales de monitoreo y pronóstico hidrometeorológico*. <https://www.senamhi.gob.pe/load/file/01402SENA-8.pdf>
- Senamhi. (s.f.). *SILVIA*. Sistema de Monitoreo de Movimientos en Masa Potenciales generados por Lluvias Intensas. https://www.senamhi.gob.pe/public/images/esquema_SILVIA_2.jpg
- Sujatha, E. R., Kumaravel, P., & Rajamanickam, G. V. (2014). Assessing landslide susceptibility using Bayesian probability-based weight of evidence model. *Bulletin of Engineering Geology and the Environment*, 73(1), 147-161. <https://doi.org/10.1007/s10064-013-0537-9>
- Villacorta Chambi, S. P., Fídel Smoll, L., & Zavala Carrión, B. L. (2012). Mapa de susceptibilidad por movimientos en masa del Perú. *Repositorio Institucional INGEMMET*. <https://repositorio.ingemmet.gob.pe/handle/20.500.12544/694>

Anexos

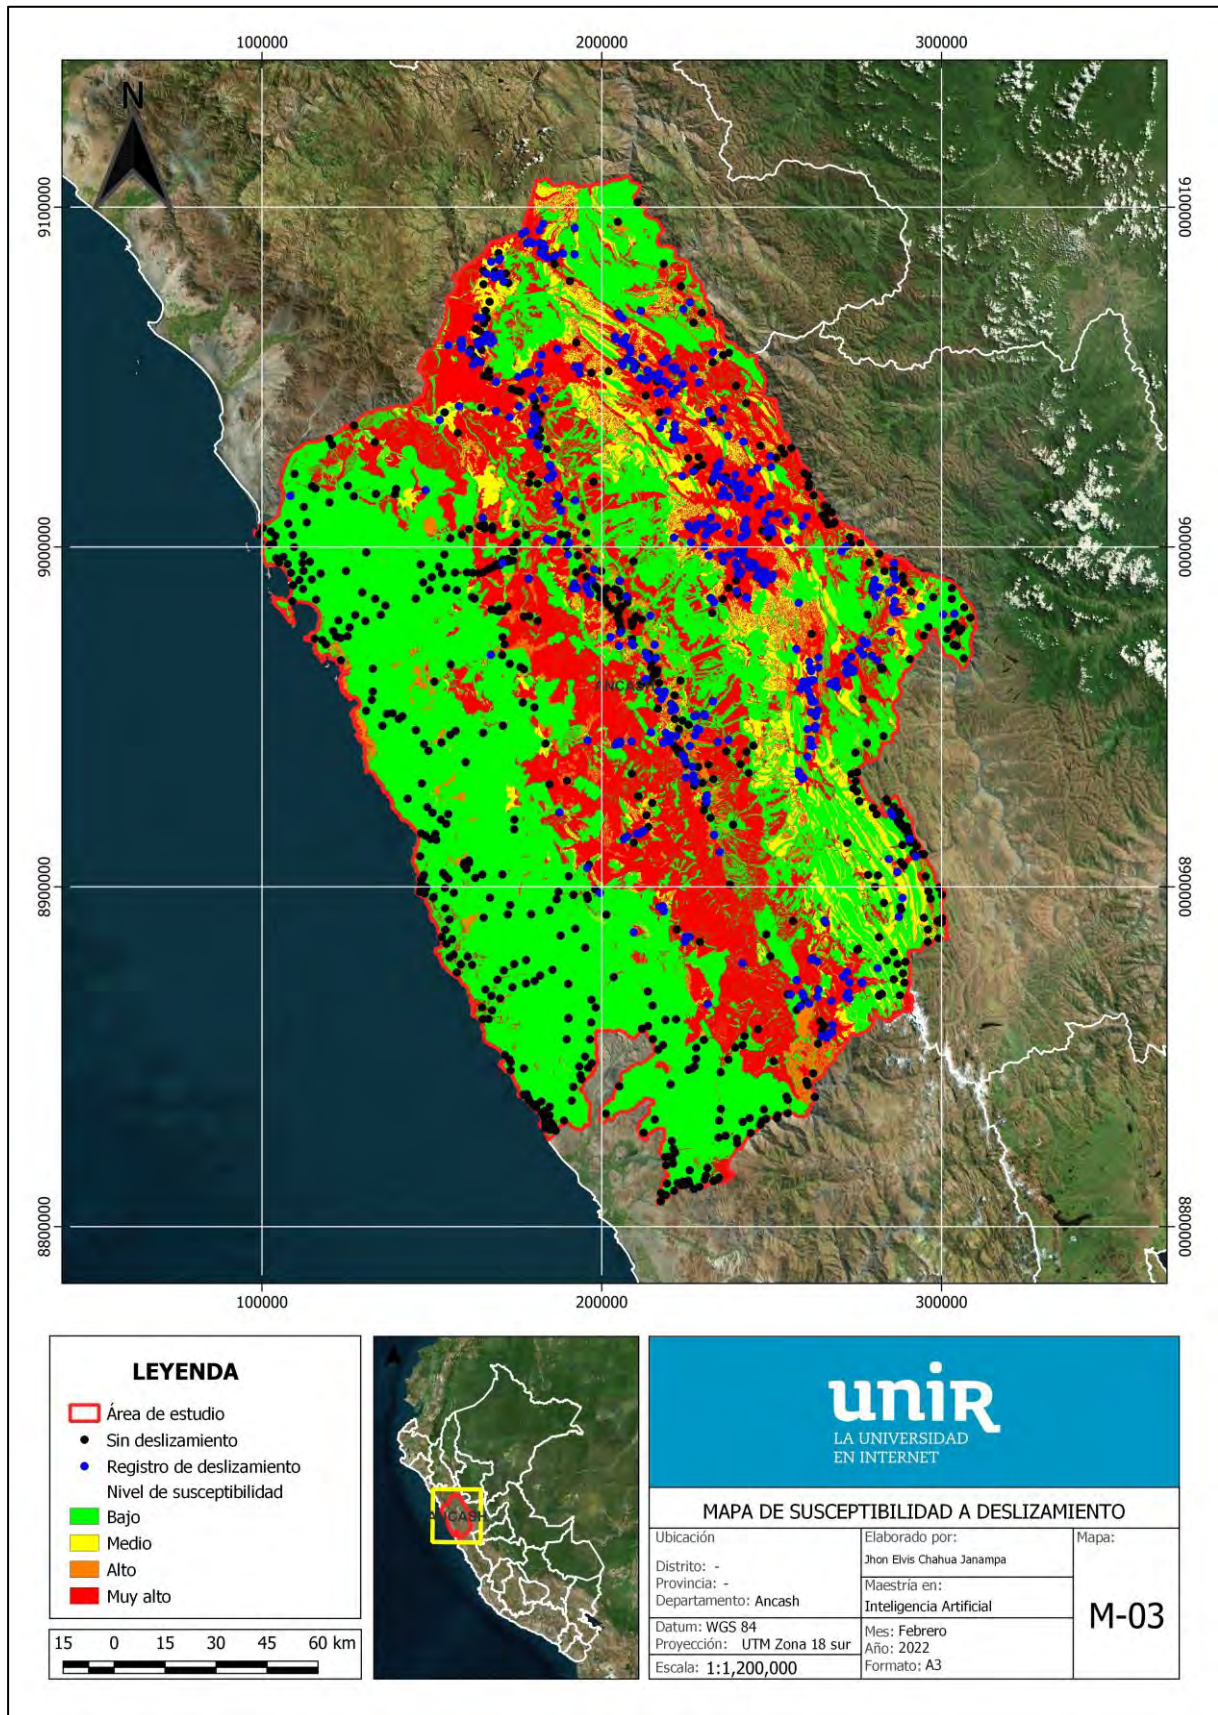
Anexo I. Mapa de ubicación I



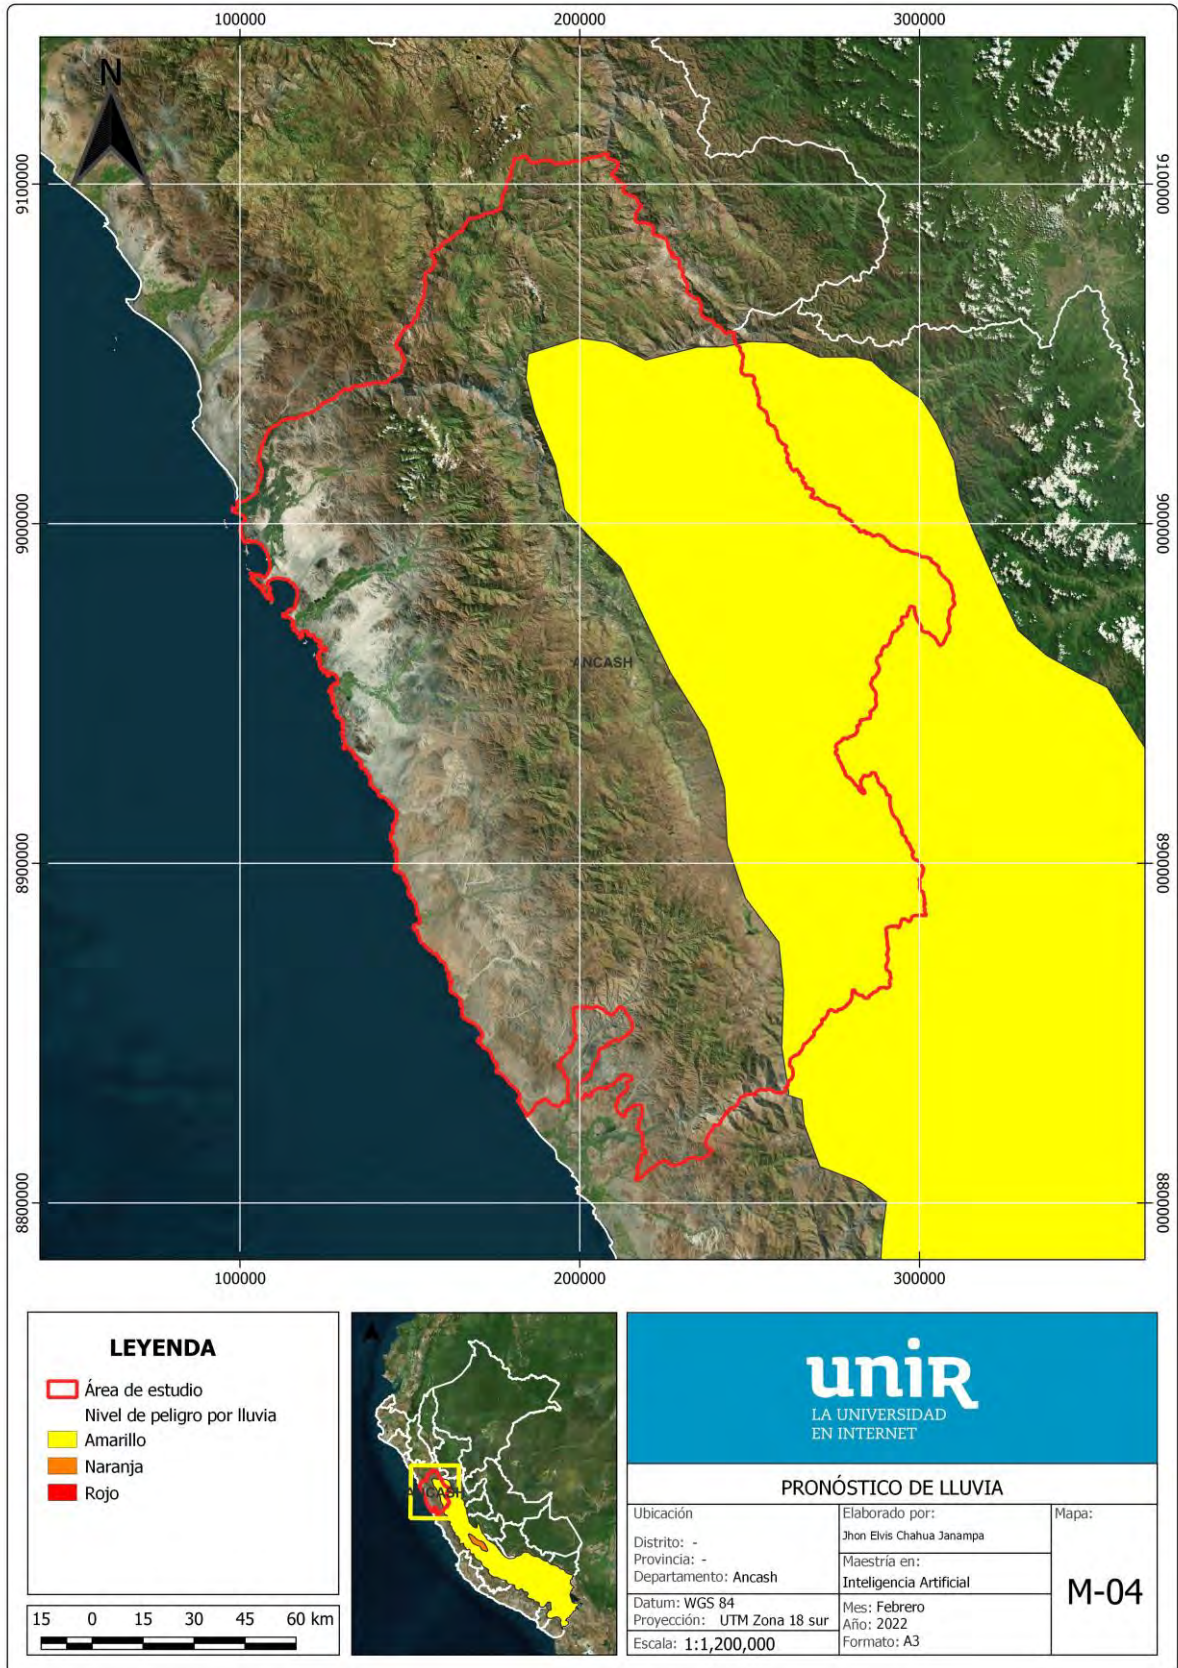
Anexo II. Registro de base de datos



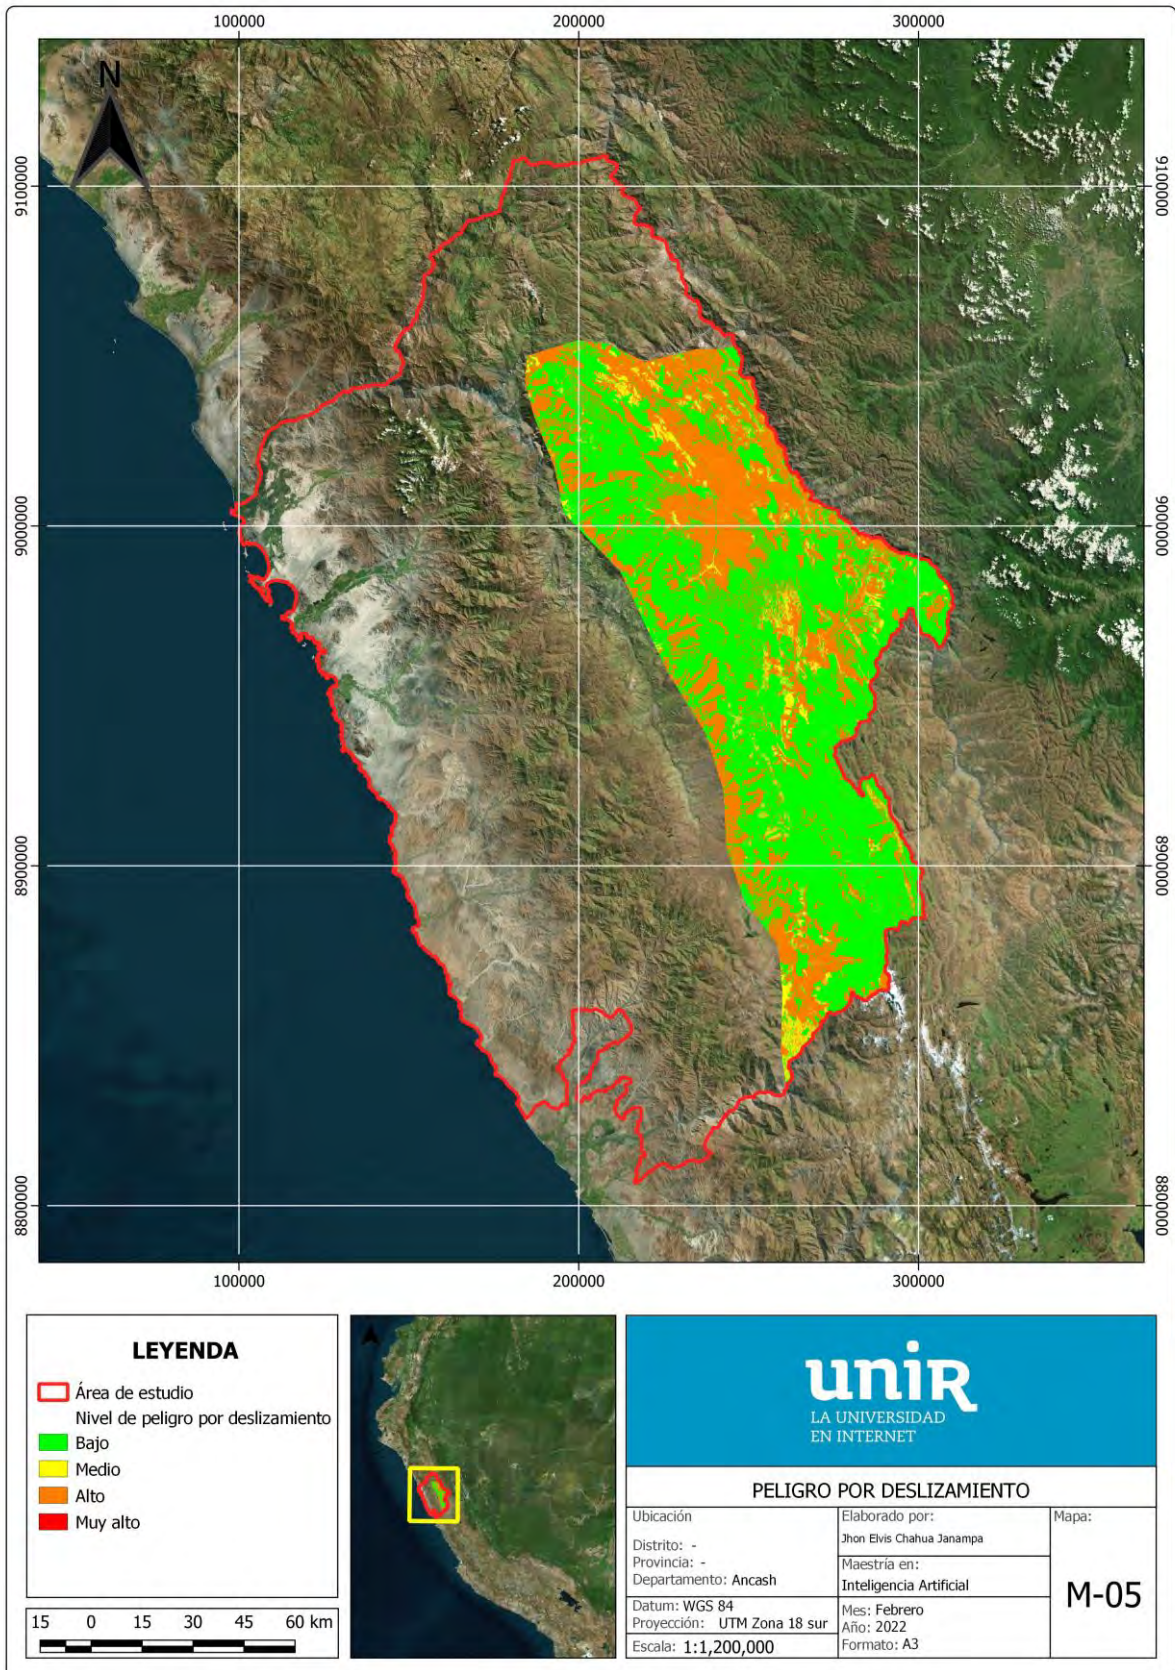
Anexo III. Mapa de susceptibilidad



Anexo IV. Pronóstico de lluvia



Anexo V. Mapa de peligro por deslizamiento



Anexo. Artículo de investigación

Predicción de deslizamientos desencadenados por lluvias con métodos de inteligencia artificial

Jhon Elvis Chahua Janampa

Universidad Internacional de la Rioja, Logroño (España)



23 de febrero del 2022

RESUMEN

Debido a la fisiografía del territorio peruano, este se encuentra expuesto a diversos eventos naturales, tales como inundaciones, flujos, deslizamientos, etc. Este último es activado principalmente por las lluvias, por lo cual surge la necesidad de contar con instrumentos metodológicos para la generación de escenarios de susceptibilidad a deslizamientos. En ese sentido se ha desarrollado un modelo basado con métodos de inteligencia artificial para la generación de escenarios a escala regional. Se emplearon métodos de aprendizaje automático para relacionar los factores condicionantes del terreno; los pronósticos de lluvia, de la entidad oficial, como factor desencadenante; y el inventario nacional de deslizamientos del departamento de Ancash para el entrenamiento y validación del modelo. Finalmente, se obtuvo que el modelo de red neuronal con 2 capas ocultas presentó un mejor comportamiento con un auc de 90.5%, en comparación con otras estructuras de red neuronal que presentaban valores de auc inferiores al 89.7%.

PALABRAS CLAVE

Escenarios, inteligencia artificial, pronóstico de lluvia, red neuronal, susceptibilidad a deslizamientos.

I. INTRODUCCIÓN

PERÚ es considerado como uno de los países de muy alto riesgo a peligros naturales, debido principalmente a sus características geográficas y climáticas, tales como su ubicación en el Cinturón de Fuego del Pacífico, la presencia de placas tectónicas; factores que modifican el clima propio de la zona tropical, como la Cordillera de los Andes, Anticiclón del Pacífico Sur, Corriente Peruana, entre otros. La mayoría de eventos registrados en Perú están relacionados a los factores hidrometeorológicos, geológicos y en menor medida se encuentran los eventos relacionados a los movimientos sísmicos. Considerando lo descrito podemos señalar que la presencia de las lluvias entre los meses de setiembre a mayo, mostrando la mayor cantidad de lluvias en los meses de verano (diciembre a marzo), incrementan la ocurrencia de inundaciones, flujos de detritos, deslizamientos, etc. En vista a ello, surge la necesidad de generar metodologías para la identificación de zonas susceptibles en donde puedan ocurrir estos eventos. Para esto, se ha desarrollado una metodología aplicando métodos de inteligencia artificial para localizar las zonas susceptibles a deslizamientos y por ende la generación de escenarios con pronósticos de lluvia en las que se puede identificar oportunamente las zonas de mayor susceptibilidad a deslizarse a causa de estas.

II. ESTADO DEL ARTE

A nivel nacional (Perú), los estudios realizados referente a metodologías sobre el cálculo de susceptibilidad a deslizamientos a escala regional se pueden mencionar en primera instancia a la entidad oficial responsable en materia de los peligros geológicos, en cuál es el Instituto Geológico Minero y Metalúrgico – Ingemmet, el cual cuenta con un mapa oficial a nivel nacional [1] de los niveles de susceptibilidad a movimientos en masa. La metodología implementada para el cálculo de estos niveles de

susceptibilidad fue utilizando un modelo heurístico multivariado el cual consiste en la superposición de capas de variables empleadas [2].

Asimismo, El Ministerio del Ambiente – Minam presenta una memoria descriptiva del mapa de vulnerabilidad física del Perú, en el cual presenta dentro de su procedimiento metodológico la elaboración de mapas de susceptibilidad física de territorio empleando un análisis univariable en el cual determina cualitativamente la valoración de cada variable en un rango numérico, y del mismo modo, emplea un análisis multivariable para relacionar dichas variables [3].

El Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres – Cenepred, como organismo público y encargado en materia de los procesos de estimación, prevención y reducción del riesgo de desastre, y reconstrucción, emplea una metodología semicuantitativa para la generación de escenarios del riesgo para diferentes peligros naturales basándose en un proceso de análisis jerárquico [4], el cual también es empleado para la elaboración de mapas de susceptibilidad a escalas locales utilizando el mismo método multicriterio [5].

Existe un Sistema de Monitoreo de Movimientos en Masa Potenciales generados por Lluvias Intensas – Silvia, el cual fue desarrollado por el Servicio Nacional de Meteorología e Hidrología del Perú – Senamhi, que utiliza datos de precipitación del producto Pisco, el cual un conjunto de datos espaciales con información de precipitación obtenida por satélite y correlacionada con datos de estaciones meteorológicas [6], el cual es empleado para determinar el nivel de susceptibilidad a ocurrencia de movimientos en masa [7]; sin embargo, este método tiene como insumo el mapa de susceptibilidad a movimientos en masa desarrollado por Ingemmet, el cual fue elaborado empleando un método semicuantitativo.

A nivel internacional, existe una serie de artículos recientes respecto al empleo de métodos cuantitativos basado en inteligencia artificial para la zonificación de la susceptibilidad a

deslizamientos. Por ejemplo, el uso de redes neuronales para la evaluación de la susceptibilidad a deslizamientos [8].

Adicionalmente, se tiene un análisis de «técnicas para la predicción espacial de zonas susceptibles a deslizamientos» en el cual se hace una recopilación de distintos métodos cuantitativos que son empleados para el cálculo de la susceptibilidad a deslizamientos [9].

De la misma manera, se realiza una comparación de los métodos de regresión logística y pesos de evidencia para determinar que métodos presenta mejor desempeño en la predicción de zonas susceptibles a movimientos en masa [10].

El empleo de métodos de inteligencia artificial para el cálculo de la susceptibilidad a deslizamiento se ha incrementado considerablemente, generando un conjunto de artículos científicos que implementan métodos de aprendizaje automático para la zonificación de la susceptibilidad [11], [12], [13], [14], [15], [16], [17].

Finalmente, se observa que a nivel internacional los métodos de inteligencia artificial para el cálculo de las zonas susceptibles a deslizamientos están en un auge de desarrollo, mientras que a nivel nacional (Perú) no se desarrollado aún métodos basados en inteligencia artificial para el cálculo de la susceptibilidad a deslizamientos; sin embargo, los métodos a nivel internacionales presentan como producto final el mapa de susceptibilidad, sin considerar los pronósticos de lluvia para la generación de escenarios, los cuales a nivel nacional sí son implementados bajo un enfoque semicuantitativo.

III. OBJETIVOS Y METODOLOGÍA

El objetivo de este estudio es proponer una metodología para la generación de escenarios de susceptibilidad a deslizamientos originado por lluvias en el departamento de Ancash, Perú, utilizando métodos basados en inteligencia artificial que permita obtener mapas con mayor precisión y exactitud de manera oportuna para la toma de decisiones.

Para este desarrollo, se empezará con la determinación de las variables que serán utilizadas para la generación de un mapa de susceptibilidad a deslizamientos, los cuales son denominados como factores condicionantes del territorio. Para ello, se realizará una búsqueda de toda la información geoespacial disponible en el área de estudio que puedan ser utilizadas como factor condicionante.

Se obtendrá un inventario de deslizamientos del área de estudio los cuales podrán ser utilizados para el entrenamiento, validación y prueba del modelo basado en inteligencia artificial que será empleado para el análisis de la susceptibilidad.

Se identificará que método de inteligencia artificial utilizado es el más exacto para la zonificación de la susceptibilidad a deslizamientos.

El resultado de la zonificación de susceptibilidad a deslizamientos será procesado con el pronóstico de lluvias generado por la entidad oficial, el cual permitirá obtener un escenario de susceptibilidad a deslizamientos, los cuales podrán ser clasificados en 4 niveles de mayor a menor probabilidad de ocurrencia de deslizamiento.

Finalmente, se dará a conocer los criterios técnicos que se deben tener en cuenta para la generación de estos escenarios, así como establecer un flujograma de trabajo para la generación de escenarios de susceptibilidad a deslizamientos originado por lluvias.

En la Figura 1, se muestra de manera esquemática los procedimientos requeridos para el desarrollo de esta metodología propuesta.

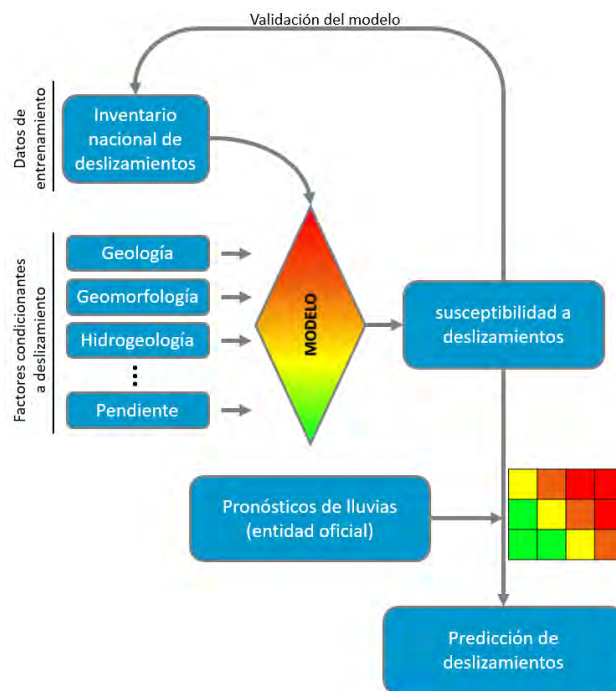


Fig. 1. Flujograma del procedimiento metodológico.

IV. CONTRIBUCIÓN

En Perú, la metodología oficial para la generación de escenarios de riesgo por diversos peligros está desarrollados en base a métodos semicuantitativos utilizando un proceso de análisis jerárquico con la matriz de comparación de pares [18]; Así como, el mapa oficial de susceptibilidad a movimientos en masa, el cual está desarrollado con un modelo heurístico multivariado [2]. Estos métodos al ser semicuantitativos se basan en relaciones subjetivas de los pesos de las variables empleadas para la generación de los mapas de susceptibilidad y escenarios de riesgo, el cual puede inducir a sesgos en los resultados de estos productos. La aplicación de métodos cuantitativos basados en inteligencia artificial permitirá que los resultados se muestren de manera objetiva conociendo el porcentaje de error del modelo, lo que conllevaría a identificar con mayor precisión las zonas de mayor susceptibilidad a deslizamientos bajo escenarios de pronósticos de lluvia, los cuales permitirán a los tomadores de decisiones actuar de manera oportuna para salvaguardar la vida de los pobladores y de sus medios de vida.

V. EVALUACIÓN Y RESULTADOS

Para la evaluación de la metodología se utilizó como caso de estudio el departamento de Ancash que se ubica al norte de Lima, Perú. Esta área de trabajo utiliza una proyección WGS64 UTM zona 18S (Fig. 2). Se utilizó principalmente 5 factores condicionantes, los cuales fueron generados por el Ingemmet, el cual es la información oficial a nivel de Perú como ente técnico científico.

Asimismo, la información del inventario de deslizamientos, fue extraído del inventario nacional de movimientos en masa del Ingemmet, los cuales de estos se extrajo solo los peligros por deslizamientos. A este inventario se le añadió puntos en zonas en donde no ocurren deslizamientos, para estos se ha considerado las

zonas en donde existe depósitos fluviales o cuerpos de agua, así como también zonas de baja pendiente, en terrazas fluviales, llanuras de inundación y todas zonas en la que la probabilidad de ocurrencia de deslizamientos es mínima, tal como se muestra en la Figura 2.a.

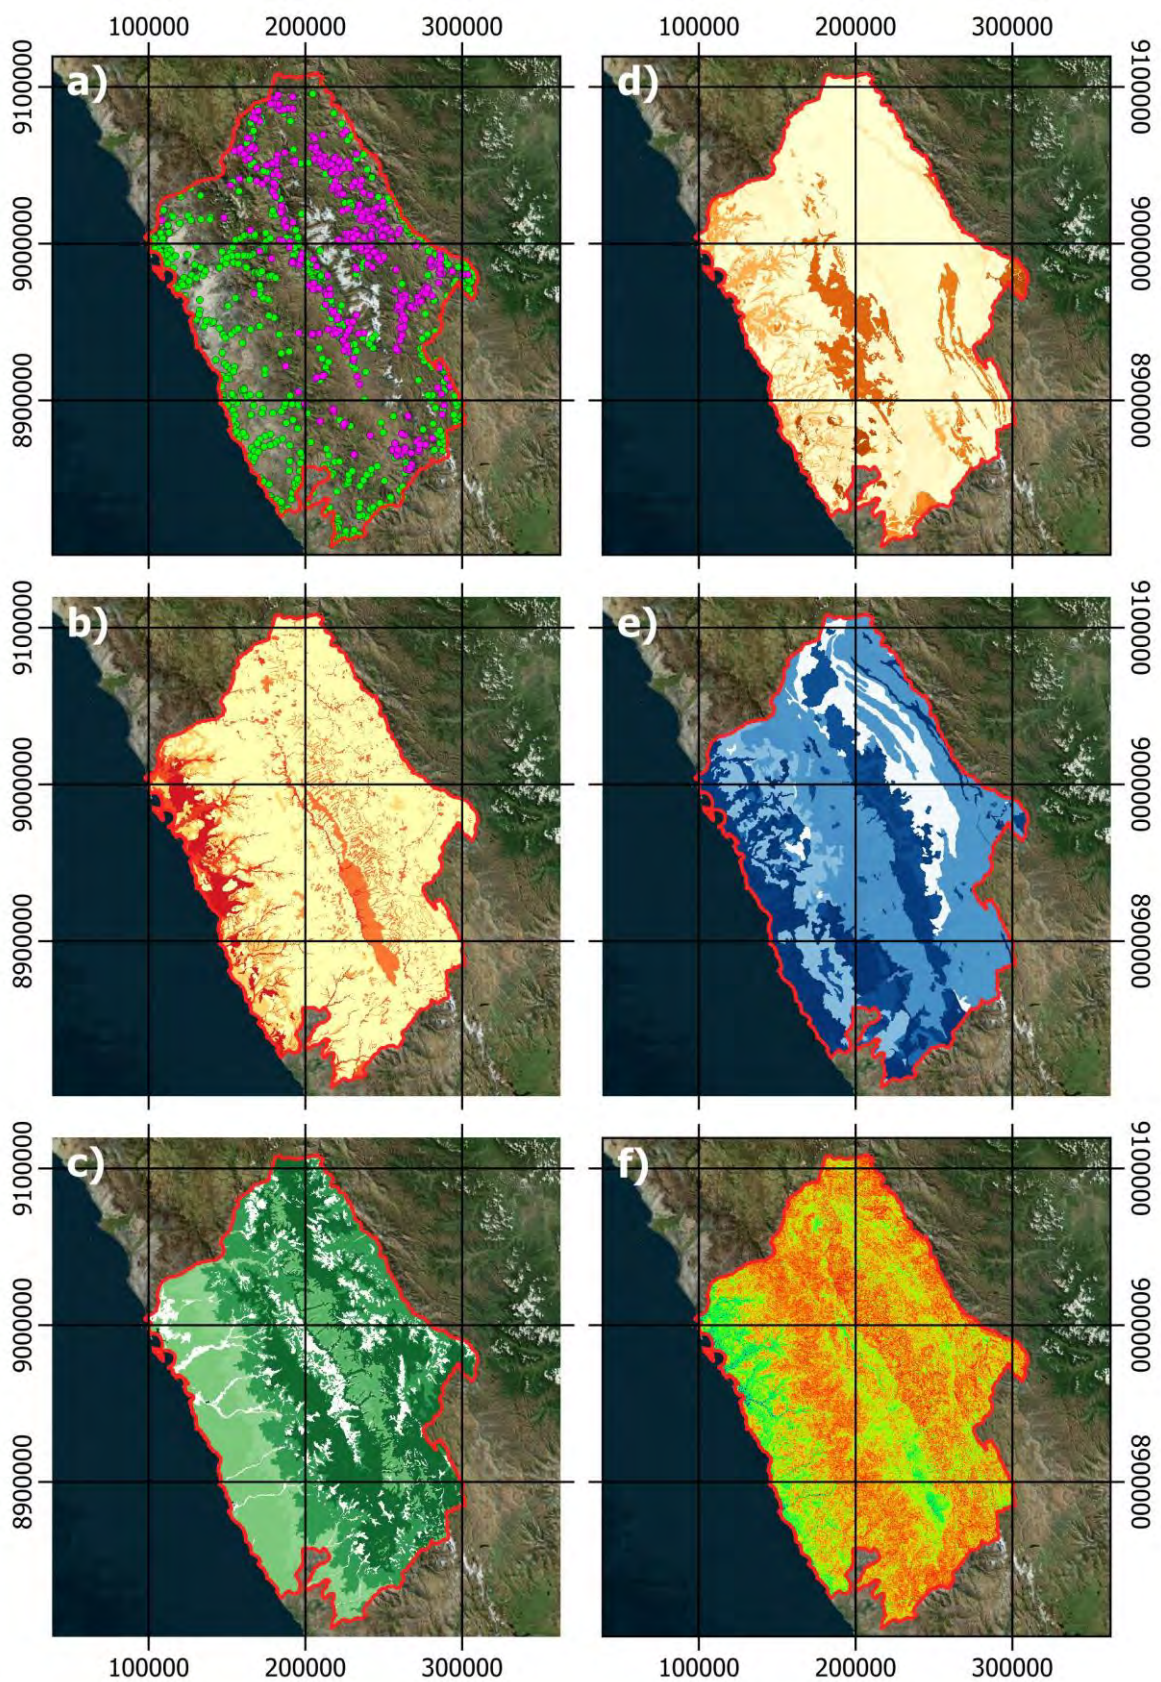


Fig. 2. Base de datos y factores condicionantes a deslizamientos.

En la Figura 2.a, se muestra la base de datos que será utilizada para el entrenamiento y validación del modelo, donde los puntos morados representan los deslizamientos ocurridos y los puntos verdes representan zonas en donde la ocurrencia de un deslizamiento es ínfima. Se tiene un total de 512 registros de deslizamientos y 657 puntos de ausencia de deslizamientos, el cual hace un total de 1169 puntos de control.

En la Figura 2.b, se muestra el factor condicionante de geomorfología, el cual representa las diferentes geofomas presentes en el área de estudio, para este caso se ha identificado 41 diferentes tipos de unidades geomorfológicas.

En la Figura 2.c, se muestra el factor la cobertura existente, para este caso se ha identificado 19 diferentes tipos de cobertura.

En la Figura 2.f, se muestra el factor condicionante de geología (unidades geológicas superficiales) el cual representa los diferentes tipos de depósitos superficiales que se encuentran sobre el área de estudio, para este caso se ha identificado 119 diferentes tipos de unidades geológicas superficiales.

En la Figura 2.e, se muestra el factor condicionante de hidrogeología el cual representa los diferentes tipos de unidades hidrogeológicas presentes en el área de estudio, para este caso se ha identificado 29 diferentes tipos de unidades geológicas superficiales.

En la Figura 2.f, se muestra el factor condicionante de pendiente el cual representa está representada en 6 rangos distintos de inclinación del terreno.

Para poder llevar las variables categóricas de cada factor condicionante se empleó el método de Pesos de Evidencias (WoE), el cuál es un método estadístico bivariado basado en la teoría de la probabilidad bayesiana [19]. Con este método se podrá asignar valores pesos a cada pixel de cada factor condicionante, los cuales se obtienen con las siguientes ecuaciones.

$$W_i^+ = \ln \frac{\frac{Npix_1}{Npix_1+Npix_2}}{\frac{Npix_3}{Npix_3+Npix_4}} \quad \dots (1)$$

$$W_i^- = \ln \frac{\frac{Npix_2}{Npix_1+Npix_2}}{\frac{Npix_4}{Npix_3+Npix_4}} \quad \dots (2)$$

$$W_F = W_i^+ - W_i^- \quad \dots (3)$$

Donde:

Npix1 = Número de pixeles con presencia de una clase del factor condicionante y de deslizamientos.

Npix2 = Número de pixeles con ausencia de una clase del factor condicionante y presencia de deslizamientos.

Npix3 = Número de pixeles con presencia de una clase del factor condicionante y ausencia de deslizamientos.

Npix4 = Número de pixeles con ausencia de una clase del factor condicionante y de deslizamientos.

El resultado de $W_i^+ > 0$, indica que la presencia de la clase del factor condicionante contribuye a la presencia del deslizamiento; cuando $W_i^+ = 0$, indica que la clase de dicho factor no es

relevante; y cuando $W_i^+ < 0$, indica que la presencia de la clase del factor contribuye a la ausencia del deslizamiento.

El resultado de $W_i^- > 0$, indica que la ausencia de la clase del factor condicionante contribuye a la presencia del deslizamiento; cuando $W_i^- = 0$, indica que la clase de dicho factor no es relevante; y cuando $W_i^- < 0$, indica que la ausencia de la clase del factor contribuye a la ausencia del deslizamiento.

Luego de obtener los pesos de evidencias para cada clase de cada factor condicionante, se extrajo los valores de los píxeles en donde se ubicaban los puntos de la base de datos. Estos puntos estaban etiquetados con el valor de 1 (ocurrencia de deslizamiento) y 0 (ausencia de deslizamiento), asimismo cada punto tendría un valor numérico (WF) por cada factor condicionante. Estos píxeles serán utilizados para el modelo de inteligencia artificial. En este caso se obtuvo matriz de 1169x6, en el cual 1169 representa la cantidad de puntos de control y 6 la cantidad de información por cada punto, en este caso la primera columna, representa la ocurrencia o no de un deslizamiento; las columnas restantes corresponden a los pesos de evidencia (WF) de cada factor condicionante. La base de datos es ingresada al modelo, para ello, se separó el 80% de los datos para el entrenamiento y el 20% para la prueba del modelo.

Se utilizó un modelo de red neuronal con diferentes configuraciones (capas y funciones de activación) para obtener el modelo que mejor resultados presente. Para esto, se generó 4 modelos de redes neuronales. Los cuatro modelos de estructura de red neuronal fueron entrenados, con la base de datos generada (80%), además, para que el entrenamiento de los modelos sea mucho más rápido, se utilizó el optimizador «Adaptive moment estimation» (Adam), el cual combina los algoritmos de «AdaGrad» y «RMSProp», con la función de pérdida de error cuadrático medio (MSE) y una técnica de validación en el entrenamiento con la función «Split validation», utilizando 20% de los datos de entrenamiento. Finalmente, el entrenamiento de todas las redes neuronales tuvo una iteración de 6000 épocas.

Evaluación 1

Se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 2 capas ocultas de 10 y 5 neuronas, con función de activación sigmoide.

Se obtuvo que para el primer modelo de red neuronal llegó a una exactitud de en el entrenamiento de 88.24% y de validación de 85.56% (Fig. 3). Asimismo, se llegó a una tasa de pérdida de entrenamiento de 8.34% y una tasa de pérdida en la validación de 12.19%.




Fig. 3. Tasa de exactitud contra la tasa de validación de la red neuronal 1.

Evaluación 2

Se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 2 capas ocultas de 10 y 5 neuronas, con función de activación relu, sigmoide, sigmoide y sigmoide, respectivamente.

Se obtuvo que para el segundo modelo de red neuronal llegó a una exactitud de en el entrenamiento de 92.25% y de validación de 83.42% (Fig. 4). Asimismo, se llegó a una tasa de pérdida de entrenamiento de 6.21% y una tasa de pérdida en la validación de 12.03%.




Fig. 5. Tasa de exactitud contra la tasa de validación de la red neuronal 2.

Evaluación 3

Se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 4 capas ocultas de 10, 20, 10 y 5 neuronas, con función de activación relu, sigmoide, sigmoide, sigmoide y sigmoide, respectivamente.

Se obtuvo que para el tercer modelo de red neuronal llegó a una exactitud de en el entrenamiento de 93.72% y de validación de 83.96% (Fig. 5). Asimismo, se llegó a una tasa de pérdida de entrenamiento de 5.23% y una tasa de pérdida en la validación de 14.73%.




Fig. 6. Tasa de exactitud contra la tasa de validación de la red neuronal 3.

Evaluación 4

Se presenta una red neuronal con 1 capa de entrada de 5 neuronas, una capa de salida de 1 neurona y 4 capas ocultas de 10, 20, 10 y 5 neuronas, con función de activación relu, relu, relu y sigmoide, respectivamente.

Se obtuvo que para el cuarto modelo de red neuronal llegó a una exactitud de en el entrenamiento de 95.72% y de validación de 81.82% (Fig. 6). Asimismo, se llegó a una tasa de pérdida de entrenamiento de 3.09% y una tasa de pérdida en la validación de

16.63%.




Fig. 4. Tasa de exactitud contra la tasa de validación de la red neuronal 4.

Luego de obtener los modelos de redes neuronales entrenados, se utilizó las métricas de la curva ROC (Receiver Operator Characteristic, característica de operador receptor) y el valor de AUC (Area Under Curve, área bajo la curva) para determinar qué modelo obtuvo mejores resultados en el ensayo de prueba con la base de datos restante (20%).

En la Fig. 7, se observa que el modelo que mejor resultados obtuvo en la prueba fue el segundo modelo de red neuronal, obteniendo un AUC del 90.5%, mientras que el tercer modelo de red neuronal obtuvo el menor valor de AUC con 83.6%.




Fig. 7. Curva ROC y valores de AUC de los modelos de redes neuronales.

Los valores presentes en cada pixel del área de estudio pertenecen a los pesos de evidencia, y son ingresados al modelo entrenado para predecir el valor de susceptibilidad presente en cada pixel del área de estudio, para ello se realizó la predicción de 38'182,257 de pixeles. En el cual el modelo asignó valores entre 0 a 1, en el cual 1 significa muy alta probabilidad de ocurrencia de un deslizamiento y el 0 se interpreta como muy baja probabilidad de ocurrencia de un deslizamiento.

Cada pixel se clasificó en 4 niveles, según el grado de probabilidad de ocurrencia de deslizamiento. Estos niveles están clasificados como nivel bajo a los valores que se encuentran en el rango de 0 a 0.25; nivel medio, los valores que están entre 0.25 a 0.5; nivel alto, los valores que están entre 0.5 a 0.75; y nivel muy alto, los valores que se encuentran entre 0.75 a 1, tal como se observa en la Fig. 8.

Para poder predecir con cierto grado de probabilidad la ocurrencia de estos deslizamientos es importante conocer con anticipación la ocurrencia de esta precipitación pluvial, así como

el grado de peligro que generaría sobre ese terreno, es decir, que tan intensa es la lluvia presente en un espacio geográfico. Para esto se utilizó los pronósticos de avisos meteorológicos del Servicio Nacional de Hidrología y Meteorología del Perú

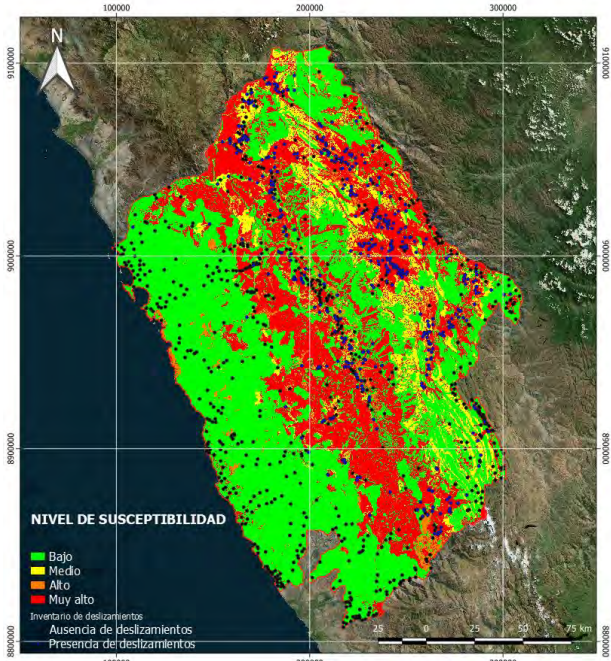


Fig. 8. Mapa de susceptibilidad a deslizamiento generado con redes neuronales (Senamhi).

Se utilizó como ejercicio el pronóstico de lluvia del Senamhi publicado el 26 de enero del 2022, en el cual presenta aviso de lluvia a partir del 28.01.22 0:00 hasta el 29.01.22 23.59. Este aviso meteorológico, está representado por polígonos con un color característico por cada nivel de peligro de lluvia, en cual cada nivel presenta una característica específica. Esta información de niveles está disponible para cualquier usuario en formato shapefile (*.shp), el cual es una representación geográfica vectorial de las zonas que presentan peligro por lluvia (Fig. 9).

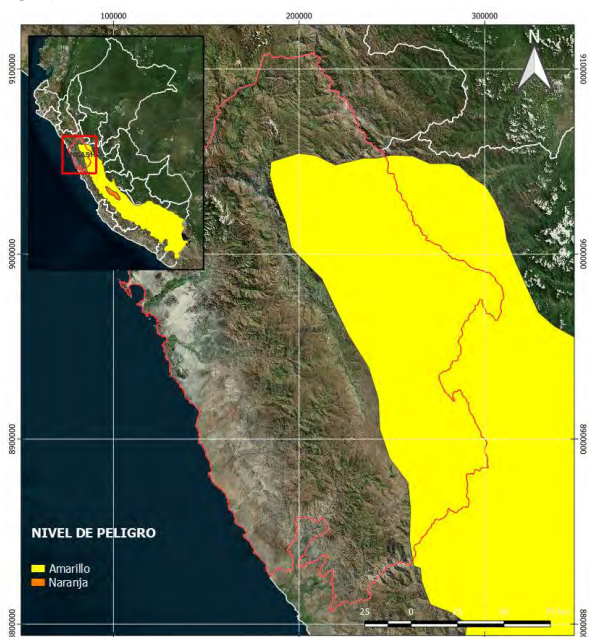


Fig. 9. Pronóstico de lluvia en la zona de estudio.

Se categoriza numéricamente cada nivel de peligro por lluvia y susceptibilidad a deslizamiento para calcular la probabilidad de deslizamiento por lluvia.

Esta categorización consiste en asignar el valor de 0 al nivel Amarillo del peligro por lluvia, el valor de 1 al nivel Naranja del peligro por lluvia, y 2 al nivel rojo del peligro por lluvia; mientras que a los niveles bajo, medio, alto y muy alto de susceptibilidad se les asignan valores del 1 al 4, respectivamente.

Para obtener el nivel de probabilidad a deslizamiento, se suman los niveles por cada pixel del área que estará expuesta a la precipitación, obteniéndose así los niveles de probabilidad a deslizamiento, el rango de [1,2], es asignado como nivel bajo; el rango <2,3], es asignado como nivel medio; el rango <3,4], es asignado como nivel alto; y el rango <4,6] es asignado como nivel muy alto a deslizamiento. Esta asignación de numeración por niveles y la integración de estos valores para el cálculo del nivel de deslizamiento se puede observar en la Fig. 10.

Nivel de peligro por lluvia	Rojo	2	3 Medio	4 Alto	5 Muy alto	6 Muy alto
	Naranja	1	1 Bajo	3 Medio	4 Alto	5 Muy alto
	Amarillo	0	1 Bajo	2 Bajo	3 Medio	4 Alto
			1	2	3	4
			Bajo	Medio	Alto	Muy alto
			Nivel de susceptibilidad a deslizamiento			

Fig. 10. Esquema de cálculo de nivel de probabilidad a deslizamiento en base a pronósticos de lluvia.

En la Fig. 11, se puede observar el resultado final que se obtiene al integrar los niveles de susceptibilidad con los niveles de peligro por lluvia, los cuales dan como resultado el nivel de peligro por deslizamiento en la zona de estudio.

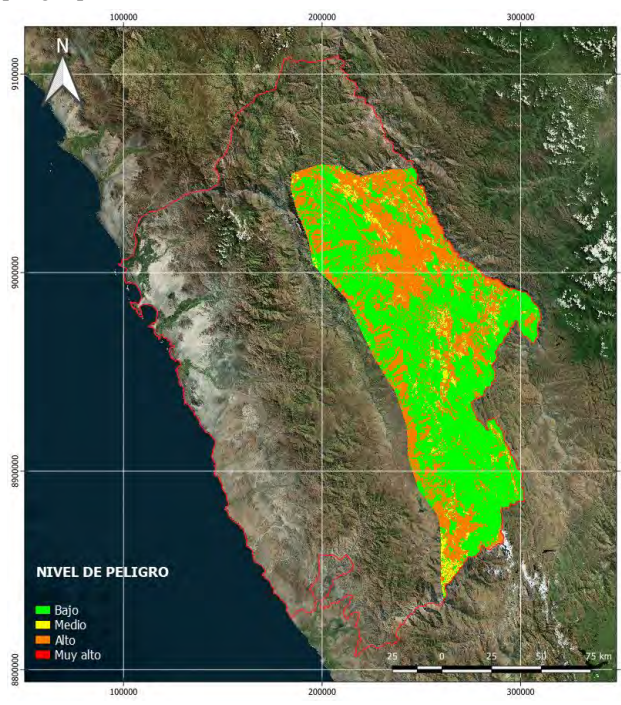


Fig. 11. Niveles de predicción a deslizamiento por pronóstico de lluvia.

VI. DISCUSIÓN

El modelo de red neuronal pudo clasificar con cierto grado de exactitud los píxeles que son más susceptibles a deslizamiento en base a las características propias del terreno, tales como el tipo de depósito presente (unidades geológicas superficiales), las geoformas, el tipo de unidad hidrogeológica, la cobertura vegetal y el grado de pendiente. En el que se aprecia que la zona de litoral predomina el nivel bajo a deslizamiento, debido a que estas zonas predominan relieves llanos en el cual la probabilidad de ocurrencia de un deslizamiento es muy baja, asimismo, los puntos de control en los cuales no ocurren deslizamiento coinciden con los valores predichos. Asimismo, las zonas en donde se presentan mayor nivel de susceptibilidad predominan en la parte central del área de estudio, debido a la cadena de montañas presentes en dicho sector y a la presencia de deslizamientos registrados en dichas zonas.

Del mismo modo, existen zonas de ausencia de deslizamientos en los cuales el modelo predijo como zonas de muy alta susceptibilidad y otras zonas en las que existe registro de deslizamiento y el modelo predijo que pertenecen a zonas de baja susceptibilidad, estos casos particulares son en menor proporción y está ligado a la tasa de exactitud presente en el modelo, así como a AUC comprobado en el modelo.

Por otro lado, la presentación de los pronósticos de lluvia representado por niveles puede facilitar la interpretación de la magnitud del evento meteorológico que al interceptarse con el mapa de niveles de susceptibilidad se obtiene los niveles de probabilidad a ocurrencia de deslizamiento o niveles de peligro; sin embargo, si estos pronósticos pudieran obtenerse expresado por probabilidad de ocurrencia o magnitud de lluvia puede realizarse un análisis más detallado de la interacción de la lluvia con la susceptibilidad del territorio.

VII. CONCLUSIONES

Los métodos oficiales que actualmente se aplican en Perú para la determinación del mapa de susceptibilidad a deslizamientos están basados en métodos heurísticos semicuantitativos, los cuales dependen de la experiencia del especialista en la aplicación y asignación de pesos ponderados para poder hallar los rangos de susceptibilidad al deslizamiento; asimismo, los las evaluaciones del riesgo a escala regional aplicados en Perú, utilizan como dato de entrada este estos rangos de susceptibilidad para establecer un escenario de posibles ocurrencia de peligros a movimientos en masa. Al aplicar la metodología propuesta, se muestra que los cálculos para establecer los rangos de susceptibilidad se realizan aplicando un método cuantitativo el cual no requiere de la asignación arbitraria del especialista en el proceso de asignación de pesos ponderados, sino que se basa en probabilidades de ocurrencia según el inventario nacional de deslizamientos. Esto permitió obtener mapas de susceptibilidad con mayor objetividad en la asignación de rangos, así como, conocer la exactitud que presenta el modelo entrenado en base a este inventario, lo cual no se puede conocer actualmente debido a los métodos utilizados en el Perú.

El mapa de susceptibilidad generado con la metodología propuesta representa una mejora en la introducción de métodos cuantitativos para la generación de estos mapas; asimismo, este mapa es un insumo para la generación de un mapa de predicción de deslizamientos en base a los pronósticos de lluvias que emite la entidad oficial. Estos también podrán ser utilizados en la generación de evaluaciones del riesgo a escala regional en el cual uno de los insumos utilizados son estos mapas de susceptibilidad generados con métodos de aprendizaje automático.

Por otro lado, debido a la dinámica y características presentadas en el territorio estos deslizamientos analizados en la metodología, son deslizamientos súbitos desencadenados por lluvias, como parte de la mejora de este análisis se puede incluir las lluvias precedentes a las del pronóstico con la intención de considerar las condiciones iniciales del suelo antes de la ocurrencia del deslizamiento, debido a la humedad que presentaría al infiltrarse el agua de las lluvias precedentes.

Asimismo, los resultados de los mapas de susceptibilidad generados por las redes neuronales están directamente vinculados con la cantidad de deslizamientos registrados en las zonas, es decir, si se tiene una gran cantidad de registro de deslizamientos, los resultados del modelo de redes neuronales podrán asignar las zonas de susceptibilidad a deslizamientos con mayor precisión.

Las líneas de trabajo futuro relacionados a esta temática serían implementar una plataforma espacial en el que se puedan mostrar de manera automatizada los resultados de las zonas de predicción de deslizamientos por cada pronóstico de lluvia emitido por la entidad oficial de meteorología; Así como también, el cálculo de un mapa de peligro, vulnerabilidad y riesgo, en el que se pueda mostrar los posibles impactos que generarían estos deslizamientos sobre el territorio, sea a nivel monetario, número de vidas expuestas y los diferentes tipos de elementos expuestas en la zona (viviendas, colegios, hospitales, parcelas agrícolas, etc.).

Esta metodología también ayudaría en enfocar las zonas de mayor susceptibilidad a deslizamientos para la realización de estudios a escala de detalle (mayor o igual a 1:5,000) con la finalidad de reducir el riesgo de desastres, implementando obras de reducción para el control y estabilización de las laderas susceptibles a deslizamientos.

Del mismo modo, Se puede trabajar en los modelos de pronóstico implementando métodos de inteligencia artificial para obtener mejores pronósticos que puedan integrarse al modelo de susceptibilidad para generar mapas de peligro con mayor precisión para la predicción de deslizamientos.

Finalmente, estos modelos de susceptibilidad y de predicción pueden integrarse con la red nacional de carreteras para que mediante los resultados, poder identificar los tramos de carreteras que puedan estar expuestos a deslizamientos con el propósito que las empresas encargadas en el mantenimiento y rehabilitación de carreteras puedan tener una acción oportuna en aquellos tramos que puedan estar afectados a un deslizamiento, así como integrar una aplicación en el que los conductores mediante su ubicación GPS puedan tener precauciones al transitar por tramos que indiquen un nivel muy alto a ocurrencia de deslizamientos.

REFERENCIAS

- [1] Ingemmet. (2010). Mapa de susceptibilidad por movimientos en masa del Perú [Map]. https://portal.ingemmet.gob.pe/documents/73138/174996/Mapa_Movimientos_Masa.pdf.
- [2] Villacorta Chambi, S. P., Fidel Smoll, L., & Zavala Carrión, B. L. (2012). Mapa de susceptibilidad por movimientos en masa del Perú. Repositorio Institucional INGEMMET. <https://repositorio.ingemmet.gob.pe/handle/20.500.12544/694>.
- [3] Minam. (2011). *Memoria descriptiva del Mapa de Vulnerabilidad Física del Perú*. <http://bvpad.indeci.gob.pe/doc/pdf/esp/doc1851/doc1851-contenido.pdf>.
- [4] Cenepred. (2012). Escenario de Riesgo. Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres. <https://cenepred.gob.pe/web/escenario-riesgos/>.
- [5] Cenepred. (2014). *Manual para la evaluación de riesgos originados por fenómenos naturales*. <http://www.cenepred.gob.pe/web/wp->

[content/uploads/Guia_Manuales/Manual-Evaluacion-de-Riesgos_v2.pdf](#).

- [6] Senamhi. (2017). *Uso del producto grillado Pisco de precipitación en estudios, investigaciones y sistemas operacionales de monitoreo y pronóstico hidrometeorológico*. <https://www.senamhi.gob.pe/load/file/014402SENA-8.pdf>.
- [7] Senamhi. (s.f.). *SILVIA*. Sistema de Monitoreo de Movimientos en Masa Potenciales generados por Lluvias Intensas. https://www.senamhi.gob.pe/public/images/esquema_SILVIA_2.jpg.
- [8] Betancourt, C. A., & Castro, A. (2018). Evaluación de susceptibilidad a deslizamientos mediante redes neuronales en la avenida Simón Bolívar. Congreso de Ciencia y Tecnología ESPE, 13(1), Article 1. <https://doi.org/10.24133/cctespe.v13i1.723>.
- [9] García, A. C. F., & Castillo, J. N. P. (2019). Técnicas para la predicción espacial de zonas susceptibles a deslizamientos. *Avances Investigación en Ingeniería*, 16(1), 20-48. <https://doi.org/10.18041/1794-4953/avances.1.5188>.
- [10] Aristizábal, E., Vásquez, M., & Ruíz, D. (2019). Métodos estadísticos para la evaluación de la susceptibilidad por movimientos en masa. *Tecnológicas*, 22(46), 39-60. <https://www.redalyc.org/journal/3442/344261485006/html/>.
- [11] Arabameri, A., Pradhan, B., Rezaei, K., & Lee, C.-W. (2019). Assessment of Landslide Susceptibility Using Statistical- and Artificial Intelligence-Based FR-RF Integrated Model and Multiresolution DEMs. *Remote Sensing*, 11(9), 999. <https://doi.org/10.3390/rs11090999>.
- [12] Chen, W., Shahabi, H., Shirzadi, A., Hong, H., Akgun, A., Tian, Y., Liu, J., Zhu, A.-X., & Li, S. (2019). Novel hybrid artificial intelligence approach of bivariate statistical-methods-based kernel logistic regression classifier for landslide susceptibility modeling. *Bulletin of Engineering Geology and the Environment*, 78(6), 4397-4419. <https://doi.org/10.1007/s10064-018-1401-8>.
- [13] Hong, H., Liu, J., & Zhu, A.-X. (2019). Landslide susceptibility evaluating using artificial intelligence method in the Youfang district (China). *Environmental Earth Sciences*, 78(15), 488. <https://doi.org/10.1007/s12665-019-8415-9>.
- [14] Lei, X., Chen, W., & Pham, B. T. (2020). Performance Evaluation of GIS-Based Artificial Intelligence Approaches for Landslide Susceptibility Modeling and Spatial Patterns Analysis. *ISPRS International Journal of Geo-Information*, 9(7), 443. <https://doi.org/10.3390/ijgi9070443>.
- [15] Nguyen, V. V., Pham, B. T., Vu, B. T., Prakash, I., Jha, S., Shahabi, H., Shirzadi, A., Ba, D. N., Kumar, R., Chatterjee, J. M., & Tien Bui, D. (2019). Hybrid Machine Learning Approaches for Landslide Susceptibility Modeling. *Forests*, 10(2), 157. <https://doi.org/10.3390/f10020157>.
- [16] Nhu, V.-H., Mohammadi, A., Shahabi, H., Ahmad, B. B., Al-Ansari, N., Shirzadi, A., Clague, J. J., Jaafari, A., Chen, W., & Nguyen, H. (2020). Landslide Susceptibility Mapping Using Machine Learning Algorithms and Remote Sensing Data in a Tropical Environment. *International Journal of Environmental Research and Public Health*, 17(14), 4933. <https://doi.org/10.3390/ijerph17144933>.
- [17] Ahmed, N., Firoze, A., & Rahman, R. M. (2020). Machine learning for predicting landslide risk of Rohingya refugee camp infrastructure. *Journal of Information and Telecommunication*, 4(2), 175-198. <https://doi.org/10.1080/24751839.2019.1704114>.
- [18] Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234-281. [https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/10.1016/0022-2496(77)90033-5).
- [19] Sujatha, E. R., Kumaravel, P., & Rajamanickam, G. V. (2014). Assessing landslide susceptibility using Bayesian probability-based weight of evidence model. *Bulletin of Engineering Geology and the Environment*, 73(1), 147-161. <https://doi.org/10.1007/s10064-013-0537-9>.

Landslides prediction triggered by rains with artificial intelligence methods

Jhon Elvis Chahua Janampa

Universidad Internacional de la Rioja, Logroño (España)

2022.02.23



ABSTRACT

Due to the physiography of the Peruvian territory, it is exposed to various natural events, such as floods, flows, landslides, etc. The latter is activated mainly by rains, which is why there is a need to have methodological instruments for the generation of landslide susceptibility scenarios. In this sense, a model based on artificial intelligence methods has been developed to generate scenarios on a regional scale. Machine learning methods were used to relate the conditioning factors of the terrain; the rain forecasts, from the official entity, as a triggering factor; and the national landslide inventory of the department of Ancash for model training and validation. Finally, it was obtained that the neural network model with 2 hidden layers presented a better performance with an auc of 90.5%, compared to other neural network structures that presented auc values lower than 89.7%.

KEYWORDS

Artificial intelligence,
Neural network,
Landslide susceptibility,
Rain forecast,
Scenarios,

I. INTRODUCTION

PERU is considered one of the countries with a very high risk of natural hazards, mainly due to its geographical and climatic characteristics, such as its location in the Pacific Ring of Fire, the presence of tectonic plates; factors that modify the climate of the tropical zone, such as the Andes Mountains, the South Pacific Anticyclone, the Peruvian Current, among others. Most of the events recorded in Peru are related to hydrometeorological and geological factors and, to a lesser extent, events related to seismic movements are found. Considering what has been described, we can point out that the presence of rains between the months of September to May, showing the greatest amount of rains in the summer months (December to March), increase the occurrence of floods, debris flows, landslides, etc. In view of this, the need arises to generate methodologies for the identification of susceptible areas where these events may occur. For this, a methodology has been developed applying artificial intelligence methods to locate the areas susceptible to landslides and therefore the generation of scenarios with rain forecasts in which the areas of greatest susceptibility to landslides can be identified in a timely manner.

II. STATE OF THE ART

At the national level (Peru), the studies carried out regarding methodologies on the calculation of susceptibility to landslides at a regional scale can be mentioned in the first instance to the official entity responsible for geological hazards, which is the Geological, Mining and Metallurgical Institute. – Ingemmet, which has an official map at the national level [1] of the levels of susceptibility to mass movements. The methodology implemented to calculate these susceptibility levels was using a multivariate heuristic model which consists of the superposition of layers of variables used [2].

Likewise, the Ministry of the Environment - Minam presents a descriptive memory of the physical vulnerability map of Peru, in which it presents within its methodological procedure the preparation of physical susceptibility maps of the territory using a univariate analysis in which it qualitatively determines the valuation of each variable in a numerical range, and in the same way, uses a multivariate analysis to relate said variables [3].

The National Center for Disaster Risk Estimation, Prevention and Reduction - Cenepred, as a public body in charge of disaster risk estimation, prevention and reduction, and reconstruction processes, uses a semi-quantitative methodology to generate disaster risk scenarios. risk for different natural hazards based on a hierarchical analysis process [4], which is also used for the elaboration of susceptibility maps at local scales using the same multi-criteria method [5].

There is a Monitoring System for Potential Mass Movements generated by Intense Rains - Silvia, which was developed by the National Service of Meteorology and Hydrology of Peru - Senamhi, which uses precipitation data from the Pisco product, which a set of spatial data with precipitation information obtained by satellite and correlated with data from meteorological stations [6], which is used to determine the level of susceptibility to the occurrence of mass movements [7]; however, this method has as input the map of susceptibility to mass movements developed by Ingemmet, which was elaborated using a semi-quantitative method.

At the international level, there is a series of recent articles regarding the use of quantitative methods based on artificial intelligence for landslide susceptibility zoning. For example, the use of neural networks for landslide susceptibility assessment [8].

Additionally, there is an analysis of "techniques for the spatial prediction of landslide-susceptible areas" in which a compilation of different quantitative methods that are used to calculate landslide susceptibility is made [9].

In the same way, a comparison of logistic regression methods

and weights of evidence is made to determine which methods have better performance in predicting areas susceptible to mass movements [10].

The use of artificial intelligence methods for calculating landslide susceptibility has increased considerably, generating a set of scientific articles that implement machine learning methods for susceptibility zoning [11], [12], [13], [14], [15], [16], [17].

Finally, it is observed that, at the international level, artificial intelligence methods for calculating areas susceptible to landslides are in a development boom, while at the national level (Peru) methods based on artificial intelligence for calculating landslides have not yet been developed. landslide susceptibility; however, the methods at the international level present the susceptibility map as the final product, without considering the rainfall forecasts for the generation of scenarios, which at the national level are implemented under a semi-quantitative approach.

III. OBJECTIVES AND METHODOLOGY

The objective of this study is to propose a methodology for the generation of susceptibility scenarios to landslides caused by rains in the department of Ancash, Peru, using methods based on artificial intelligence that allows obtaining maps with greater precision and accuracy in a timely manner for taking of decisions.

For this development, it will begin with the determination of the variables that will be used to generate a landslide susceptibility map, which are called conditioning factors of the territory. To do this, a search will be made of all the geospatial information available in the study area that can be used as a conditioning factor.

An inventory of landslides will be obtained from the study area, which can be used for training, validation and testing of the model based on artificial intelligence that will be used for the susceptibility analysis.

It will be identified which artificial intelligence method used is the most accurate for landslide susceptibility zoning.

The result of the landslide susceptibility zoning will be processed with the rainfall forecast generated by the official entity, which will allow obtaining a landslide susceptibility scenario, which can be classified into 4 levels from higher to lower probability of landslide occurrence. .

Finally, the technical criteria that must be taken into account for the generation of these scenarios will be announced, as well as a work flowchart for the generation of scenarios of susceptibility to landslides caused by rain.

Fig. 1 shows schematically the procedures required for the development of this proposed methodology.

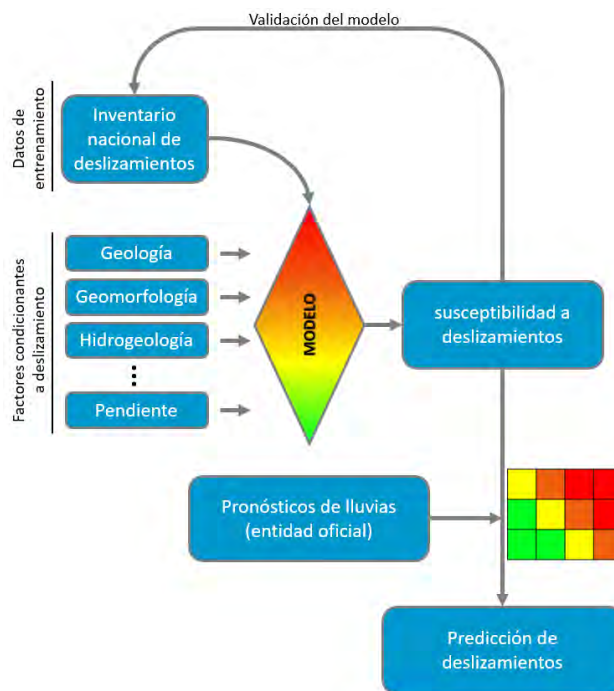


Fig. 12. Flowchart of the methodological procedure.

IV. CONTRIBUTION

In Peru, the official methodology for the generation of risk scenarios for various hazards is developed based on semi-quantitative methods using a hierarchical analysis process with the pair comparison matrix [18]; As well as the official map of susceptibility to mass movements, which is developed with a multivariate heuristic model [2]. These methods, being semi-quantitative, are based on subjective relationships of the weights of the variables used to generate susceptibility maps and risk scenarios, which can induce bias in the results of these products. The application of quantitative methods based on artificial intelligence will allow the results to be shown objectively knowing the percentage of error of the model, which would lead to more accurately identify the areas of greatest susceptibility to landslides under rain forecast scenarios, which They will allow decision makers to act in a timely manner to safeguard the lives of the inhabitants and their livelihoods.

V. EVALUATION AND RESULTS

For the evaluation of the methodology, the department of Ancash, located north of Lima, Peru, was used as a case study. This work area uses a WGS64 UTM Zone 18S projection (Fig. 2). Mainly 5 conditioning factors were used, which were generated by the Ingemmet, which is the official information at the level of Peru as a scientific technical entity.

Likewise, the information of the landslide inventory was extracted from the national inventory of mass movements of the Ingemmet, from which only the dangers due to landslides were extracted. Points were added to this inventory in areas where landslides do not occur, for these the areas where there are fluvial deposits or bodies of water have been considered, as well as low slope areas, in fluvial terraces, flood plains and all areas in which the probability of occurrence of landslides is minimal, as shown in Figure 2.a.

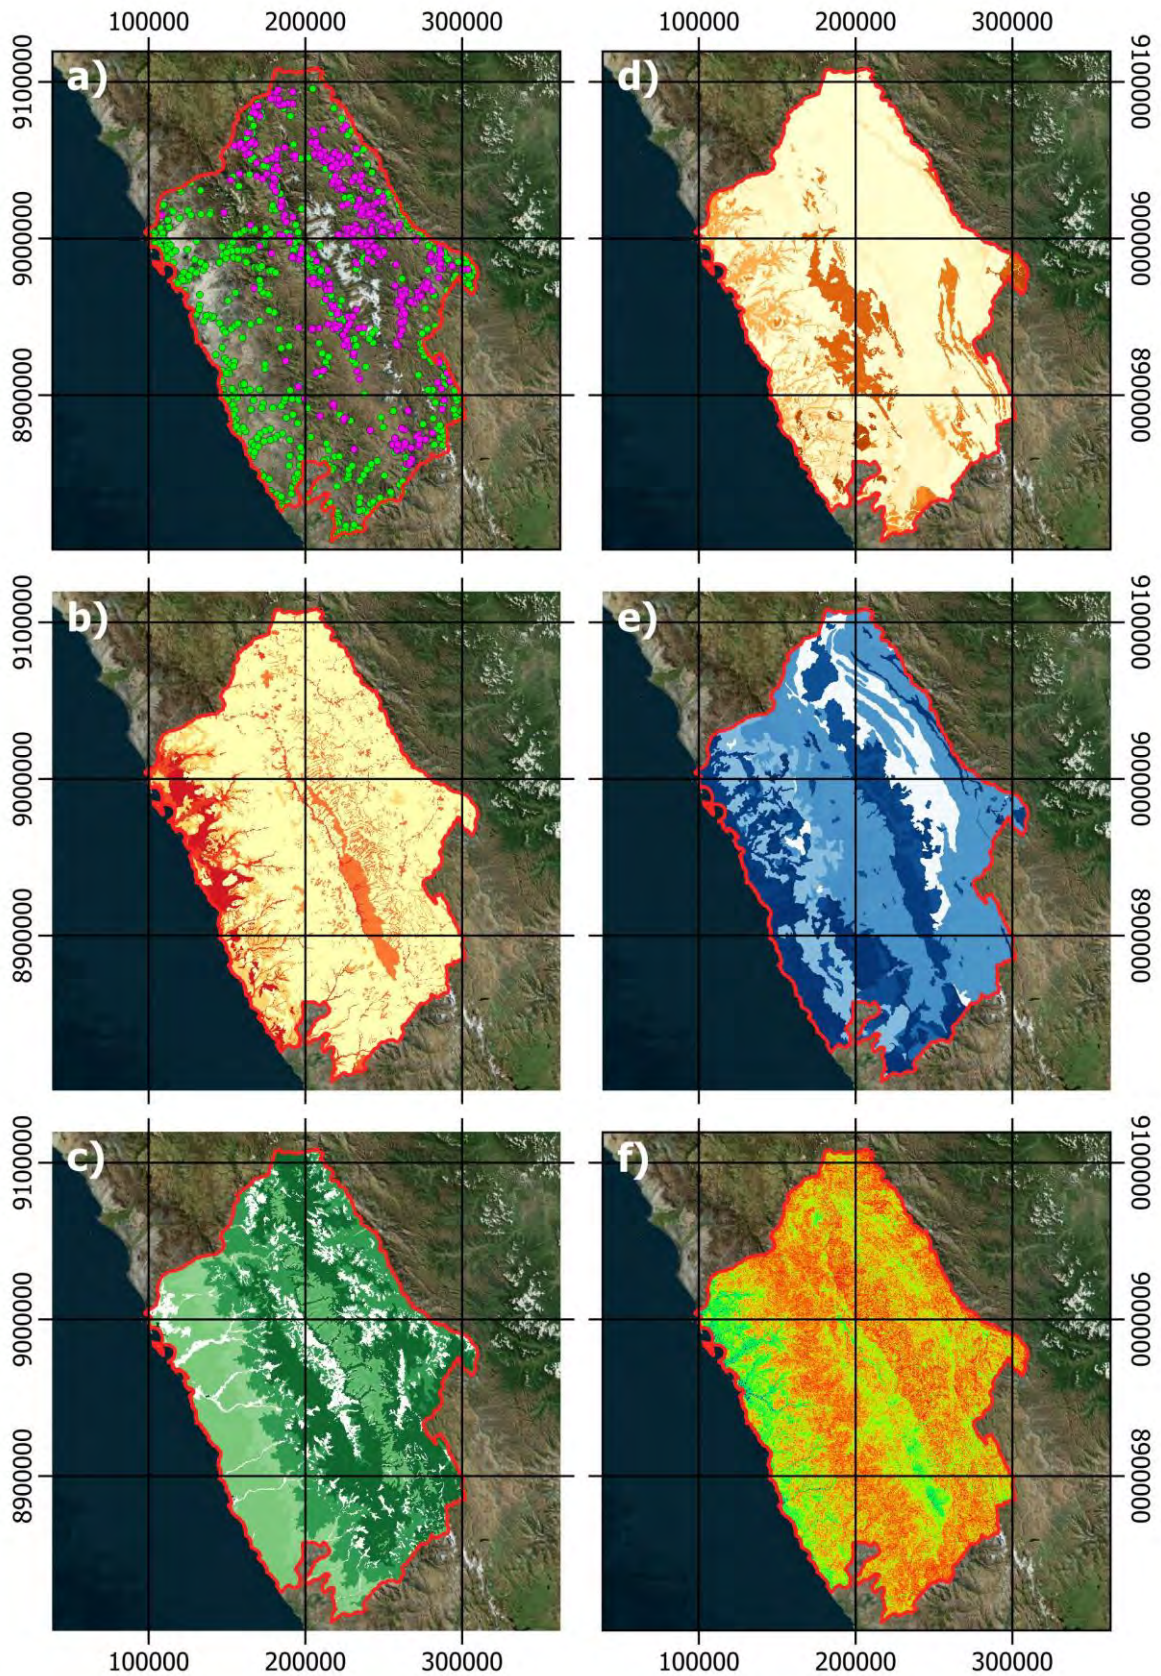


Fig. 13. Database and conditioning factors to landslides.

Figure 2.a shows the database that will be used for model training and validation, where the purple points represent the landslides that have occurred and the green points represent areas

where the occurrence of a landslide is negligible. There is a total of 512 landslide records and 657 landslide absence points, which makes a total of 1169 control points.

Figure 2.b shows the conditioning factor of geomorphology,

which represents the different geomorphs present in the study area. For this case, 41 different types of geomorphological units have been identified.

In Figure 2.c, the existing coverage factor is shown, for this case 19 different types of coverage have been identified.

In Figure 2.f, the conditioning factor of geology (superficial geological units) is shown, which represents the different types of superficial deposits that are found on the study area, for this case 119 different types of superficial geological units have been identified. .

Figure 2.e shows the conditioning factor of hydrogeology, which represents the different types of hydrogeological units present in the study area. In this case, 29 different types of surface geological units have been identified.

In Figure 2.f, the slope conditioning factor is shown, which represents is represented in 6 different ranges of terrain inclination.

In order to take the categorical variables of each conditioning factor, the Weights of Evidence (WoE) method was used, which is a bivariate statistical method based on Bayesian probability theory [19]. With this method, weight values can be assigned to each pixel of each conditioning factor, which are obtained with the following equations.

$$W_i^+ = \ln \frac{\frac{Npix_1}{Npix_1+Npix_2}}{\frac{Npix_3}{Npix_3+Npix_4}} \quad \dots (1)$$

$$W_i^- = \ln \frac{\frac{Npix_2}{Npix_1+Npix_2}}{\frac{Npix_4}{Npix_3+Npix_4}} \quad \dots (2)$$

$$W_F = W_i^+ - W_i^- \quad \dots (3)$$

Where:

Npix1 = Number of pixels with the presence of a class of the conditioning factor and slippage.

Npix2 = Number of pixels with absence of a conditioning factor class and presence of landslides.

Npix3 = Number of pixels with the presence of a class of the conditioning factor and absence of landslides.

Npix4 = Number of pixels with absence of a class of the conditioning factor and slippage.

The result of $W_i^+ > 0$, indicates that the presence of the conditioning factor class contributes to the presence of slippage; when $W_i^+ = 0$, it indicates that the class of said factor is not relevant; and when $W_i^+ < 0$, it indicates that the presence of the factor class contributes to the absence of slippage.

The result of $W_i^- > 0$, indicates that the absence of the conditioning factor class contributes to the presence of slippage; when $W_i^- = 0$, it indicates that the class of said factor is not relevant; and when $W_i^- < 0$, it indicates that the absence of the factor class contributes to the absence of slippage.

After obtaining the weights of evidence for each class of each conditioning factor, the values of the pixels where the points of the database were located were extracted. These points were

labeled with the value of 1 (occurrence of slippage) and 0 (absence of slippage), likewise each point would have a numerical value (WF) for each conditioning factor. These pixels will be used for the artificial intelligence model. In this case, a 1169x6 matrix was obtained, in which 1169 represents the number of control points and 6 the amount of information for each point, in this case the first column represents the occurrence or not of a landslide; the remaining columns correspond to the weights of evidence (WF) of each conditioning factor. The database is entered into the model, for this, 80% of the data was separated for training and 20% for model testing.

A neural network model with different configurations (layers and activation functions) was used to obtain the model that presented the best results. For this, 4 neural network models were generated. The four neural network structure models were trained, with the generated database (80%), in addition, for the training of the models to be much faster, the ‘‘Adaptive moment estimation’’ (Adam) optimizer was used, the which combines the ‘‘AdaGrad’’ and ‘‘RMSProp’’ algorithms, with the mean square error (MSE) loss function and a training validation technique with the ‘‘Split validation’’ function, using 20% of the training data. Finally, the training of all the neural networks had an iteration of 6000 epochs

Evaluaci3n 1

A neural network with 1 input layer of 5 neurons, an output layer of 1 neuron and 2 hidden layers of 10 and 5 neurons, with sigmoid activation function, is presented.

It was obtained that for the first neural network model it reached an accuracy of 88.24% in training and 85.56% in validation (Fig. 3). Likewise, a training loss rate of 8.34% and a validation loss rate of 12.19% were reached.




Fig. 14. Accuracy rate against the validation rate of the neural network 1.

Evaluaci3n 2

A neural network with 1 input layer of 5 neurons, an output layer of 1 neuron and 2 hidden layers of 10 and 5 neurons, with activation function relu, sigmoid, sigmoid and sigmoid, respectively, is presented.

It was obtained that for the second neural network model it reached a training accuracy of 92.25% and a validation accuracy of 83.42% (Fig. 4). Likewise, a training loss rate of 6.21% and a validation loss rate of 12.03% were reached.




Fig. 15. Accuracy rate against the validation rate of the neural network 2.

Evaluación 3

A neural network with 1 input layer of 5 neurons, an output layer of 1 neuron and 4 hidden layers of 10, 20, 10 and 5 neurons, with activation function relu, sigmoid, sigmoid, sigmoid and sigmoid, respectively, is presented.

It was obtained that for the third neural network model it reached a training accuracy of 93.72% and a validation accuracy of 83.96% (Fig. 5). Likewise, a training loss rate of 5.23% and a validation loss rate of 14.73% were reached.




Fig. 16. Accuracy rate against the validation rate of the neural network 3.

Evaluación 4

A neural network with 1 input layer of 5 neurons, an output layer of 1 neuron and 4 hidden layers of 10, 20, 10 and 5 neurons, with activation function relu, relu, relu, relu and sigmoid, respectively, is presented.

It was obtained that for the fourth neural network model it reached a training accuracy of 95.72% and a validation accuracy of 81.82% (Fig. 6). Likewise, a training loss rate of 3.09% and a validation loss rate of 16.63% were reached.




Fig. 17. Accuracy rate against the validation rate of the neural network 4.

After obtaining the trained neural network models, the ROC (Receiver Operator Characteristic) curve metrics and the AUC (Area Under Curve) value were used to determine which model obtained the best results. In the test trial with the remaining database (20%).

In Fig. 7, it is observed that the model that obtained the best results in the test was the second neural network model, obtaining an AUC of 90.5%, while the third neural network model obtained the lowest AUC value with 83.6%.

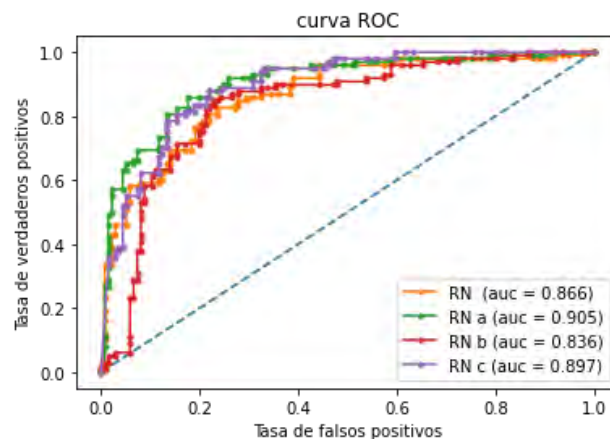


Fig. 18. ROC curve and AUC values of the neural network models.

The values present in each pixel of the study area belong to the weights of evidence, and are entered into the trained model to predict the value of susceptibility present in each pixel of the study area, for which the prediction of 38,182,257 pixels was made. In which the model assigned values between 0 and 1, in which 1 means very high probability of occurrence of a landslide and 0 is interpreted as very low probability of occurrence of a landslide.

Each pixel was classified into 4 levels, according to the degree of probability of slip occurrence. These levels are classified as low level to the values that are in the range of 0 to 0.25; medium level, the values that are between 0.25 to 0.5; high level, the values that are between 0.5 to 0.75; and very high level, the values that are between 0.75 to 1, as observed in Fig. 8.

In order to be able to predict with a certain degree of probability the occurrence of these landslides, it is important to know in advance the occurrence of this rainfall, as well as the degree of danger that it would generate on that terrain, that is, how intense is the rain present in a given space. geographical. For this, the forecasts of meteorological warnings of the National Service

of Hydrology and Meteorology of Peru (Senamhi) were used.

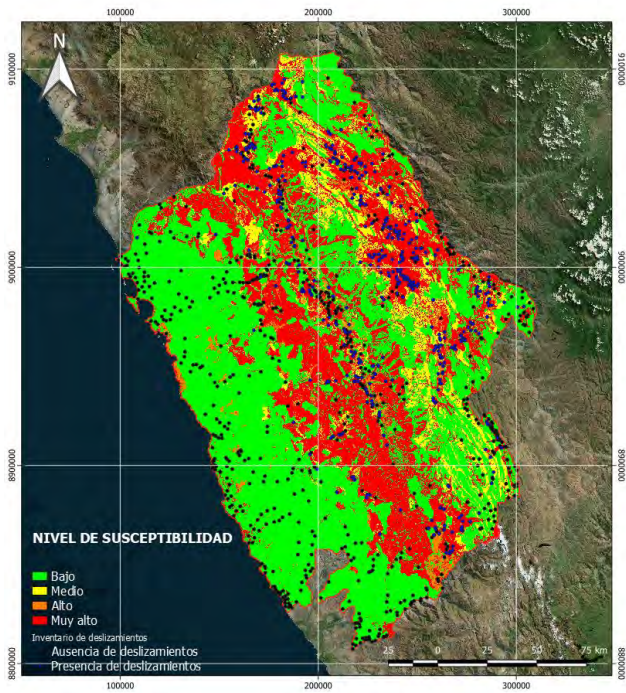


Fig. 19. Landslide susceptibility map generated with neural networks.

The Senamhi rain forecast published on January 26, 2022 was used as an exercise, in which it presents a rain warning from 01.28.22 0:00 to 01.29.22 23:59. This meteorological warning is represented by polygons with a characteristic color for each level of rain danger, in which each level presents a specific characteristic. This level information is available to any user in shapefile format (*.shp), which is a vector geographic representation of the areas that present danger due to rain (Fig. 9).

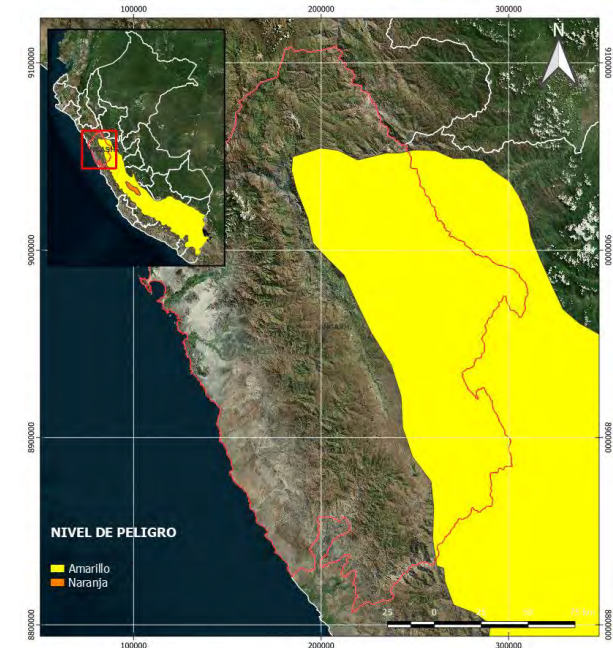


Fig. 20. Rain forecast in the study area.

Each level of rain hazard and landslide susceptibility is numerically categorized to calculate the probability of rain landslide.

This categorization consists of assigning the value of 0 to the Yellow level of the danger due to rain, the value of 1 to the Orange level of the danger due to rain, and 2 to the red level of the danger due to rain; while the low, medium, high and very high levels of susceptibility are assigned values from 1 to 4, respectively.

To obtain the level of probability of landslide, the levels are added for each pixel of the area that will be exposed to precipitation, thus obtaining the levels of probability of landslide, the range $[1,2]$ is assigned as low level; the range $<2.3]$ is assigned as a medium level; the range $<3.4]$ is assigned as a high level; and the range $<4.6]$ is assigned as very high level to slip. This assignment of numbering by levels and the integration of these values for the calculation of the slip level can be seen in Fig. 10.

Nivel de peligro por lluvia	Rojo	2	3 Medio	4 Alto	5 Muy alto	6 Muy alto
	Naranja	1	1 Bajo	3 Medio	4 Alto	5 Muy alto
	Amarillo	0	1 Bajo	2 Bajo	3 Medio	4 Alto
			1	2	3	4
			Bajo	Medio	Alto	Muy alto
Nivel de susceptibilidad a deslizamiento						

Fig. 21. Scheme for calculating the level of probability of landslide based on rain forecasts.

In Fig. 11, you can see the final result obtained by integrating the susceptibility levels with the rain hazard levels, which result in the level of landslide hazard in the study area.

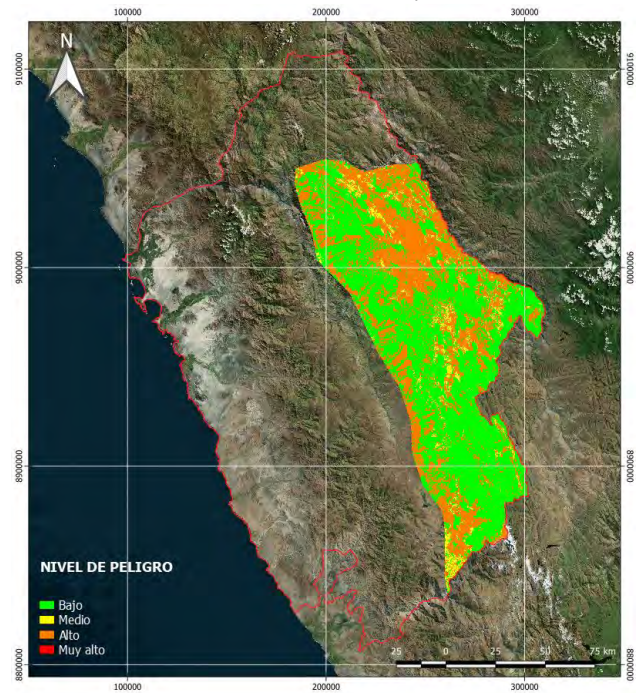


Fig. 22. Landslide prediction levels by rain forecast.

VI. DISCUSSION

The neural network model was able to classify with a certain degree of accuracy the pixels that are most susceptible to landslides based on the characteristics of the terrain, such as the type of deposit present (superficial geological units), the geofoms, the type of hydrogeological unit, vegetation cover and slope grade. In which it is appreciated that the coastal area predominates the low level of landslide, because these areas predominate flat reliefs in which the probability of occurrence of a landslide is very low, likewise, the control points in which they do not occur slip match the predicted values. Likewise, the areas with the highest level of susceptibility predominate in the central part of the study area, due to the chain of mountains present in said sector and the presence of landslides registered in said areas.

In the same way, there are zones of absence of landslides in which the model predicted as zones of very high susceptibility and other zones in which there is a landslide record and the model predicted that they belong to zones of low susceptibility, these particular cases are to a lesser extent ratio and is linked to the accuracy rate present in the model, as well as the AUC found in the model.

On the other hand, the presentation of the rain forecasts represented by levels can facilitate the interpretation of the magnitude of the meteorological event that, when intercepted with the map of susceptibility levels, levels of probability of landslide occurrence or levels of danger are obtained; however, if these forecasts could be obtained expressed by probability of occurrence or magnitude of rainfall, a more detailed analysis of the interaction of rainfall with the susceptibility of the territory can be carried out.

VII. CONCLUSION

The official methods currently applied in Peru for the determination of the landslide susceptibility map are based on semi-quantitative heuristic methods, which depend on the experience of the specialist in the application and assignment of weighted weights in order to find the landslide susceptibility ranges. ; Likewise, risk assessments at a regional scale applied in Peru use these susceptibility ranges as input data to establish a scenario of possible occurrence of dangers to mass movements. When applying the proposed methodology, it is shown that the calculations to establish the ranges of susceptibility are made by applying a quantitative method which does not require the arbitrary assignment of the specialist in the process of assigning weighted weights, but is based on probabilities of occurrence. according to the national inventory of landslides. This allowed obtaining susceptibility maps with greater objectivity in the assignment of ranges, as well as knowing the accuracy of the trained model based on this inventory, which cannot currently be known due to the methods used in Peru.

The susceptibility map generated with the proposed methodology represents an improvement in the introduction of quantitative methods for the generation of these maps; Likewise, this map is an input for the generation of a landslide prediction map based on the rainfall forecasts issued by the official entity. These may also be used in the generation of risk assessments at a regional scale in which one of the inputs used are these susceptibility maps generated with machine learning methods.

On the other hand, due to the dynamics and characteristics presented in the territory, these landslides analyzed in the methodology are sudden landslides triggered by rains, as part of the improvement of this analysis, the rains preceding those of the forecast can be included with the intention of consider the initial conditions of the soil before the occurrence of the landslide, due

to the humidity that it would present when the water from the preceding rains infiltrated.

Likewise, the results of the susceptibility maps generated by the neural networks are directly linked to the number of landslides recorded in the areas, that is, if there is a large number of landslide records, the results of the neural network model will be able to assign landslide susceptibility zones with greater precision.

The lines of future work related to this topic would be to implement a space platform in which the results of the landslide prediction zones can be automatically displayed for each rain forecast issued by the official meteorology entity; As well as the calculation of a map of danger, vulnerability and risk, in which the possible impacts that these landslides would generate on the territory can be shown, be it at the monetary level, number of lives exposed and the different types of elements exposed in the area (homes, schools, hospitals, agricultural plots, etc.).

This methodology would also help to focus on the areas with the greatest susceptibility to landslides to carry out studies at a detailed scale (greater than or equal to 1:5,000) in order to reduce the risk of disasters, implementing reduction works for control and stabilization. of slopes susceptible to landslides.

Similarly, forecast models can be worked on by implementing artificial intelligence methods to obtain better forecasts that can be integrated into the susceptibility model to generate more accurate hazard maps for landslide prediction.

Finally, these susceptibility and prediction models can be integrated with the national road network so that, through the results, it is possible to identify the road sections that may be exposed to landslides so that the companies in charge of road maintenance and rehabilitation can take timely action in those sections that may be affected by a landslide, as well as integrate an application in which drivers, through their GPS location, can take precautions when traveling through sections that indicate a very high level of landslide occurrence.

REFERENCES

- [1] Ingemmet. (2010). Mapa de susceptibilidad por movimientos en masa del Perú [Map]. https://portal.ingemmet.gob.pe/documents/73138/174996/Mapa_Movimientos_Masa.pdf.
- [2] Villacorta Chambi, S. P., Fidel Smoll, L., & Zavala Carrión, B. L. (2012). Mapa de susceptibilidad por movimientos en masa del Perú. Repositorio Institucional INGEMMET. <https://repositorio.ingemmet.gob.pe/handle/20.500.12544/694>.
- [3] Minam. (2011). *Memoria descriptiva del Mapa de Vulnerabilidad Física del Perú*. <http://bypad.indeci.gob.pe/doc/pdf/esp/doc1851/doc1851-contenido.pdf>.
- [4] Cenepred. (2012). Escenario de Riesgo. Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres. <https://cenepred.gob.pe/web/escenario-riesgos/>.
- [5] Cenepred. (2014). *Manual para la evaluación de riesgos originados por fenómenos naturales*. http://www.cenepred.gob.pe/web/wp-content/uploads/Guia_Manuales/Manual-Evaluacion-de-Riesgos_v2.pdf.
- [6] Senamhi. (2017). *Uso del producto grillado Pisco de precipitación en estudios, investigaciones y sistemas operacionales de monitoreo y pronóstico hidrometeorológico*. <https://www.senamhi.gob.pe/load/file/01402SENA-8.pdf>.
- [7] Senamhi. (s.f.). *SILVIA*. Sistema de Monitoreo de Movimientos en Masa Potenciales generados por Lluvias Intensas. https://www.senamhi.gob.pe/public/images/esquema_SILVIA_2.jpg.
- [8] Betancourt, C. A., & Castro, A. (2018). Evaluación de susceptibilidad a deslizamientos mediante redes neuronales en la avenida Simón Bolívar. Congreso de Ciencia y Tecnología ESPE, 13(1), Article 1. <https://doi.org/10.24133/ctespe.v13i1.723>.

- [9] García, A. C. F., & Castillo, J. N. P. (2019). Técnicas para la predicción espacial de zonas susceptibles a deslizamientos. *Avances Investigación en Ingeniería*, 16(1), 20-48. <https://doi.org/10.18041/1794-4953/avances.1.5188>.
- [10] Aristizábal, E., Vásquez, M., & Ruíz, D. (2019). Métodos estadísticos para la evaluación de la susceptibilidad por movimientos en masa. *Tecnológicas*, 22(46), 39-60. <https://www.redalyc.org/journal/3442/344261485006/html/>.
- [11] Arabameri, A., Pradhan, B., Rezaei, K., & Lee, C.-W. (2019). Assessment of Landslide Susceptibility Using Statistical- and Artificial Intelligence-Based FR-RF Integrated Model and Multiresolution DEMs. *Remote Sensing*, 11(9), 999. <https://doi.org/10.3390/rs11090999>.
- [12] Chen, W., Shahabi, H., Shirzadi, A., Hong, H., Akgun, A., Tian, Y., Liu, J., Zhu, A.-X., & Li, S. (2019). Novel hybrid artificial intelligence approach of bivariate statistical-methods-based kernel logistic regression classifier for landslide susceptibility modeling. *Bulletin of Engineering Geology and the Environment*, 78(6), 4397-4419. <https://doi.org/10.1007/s10064-018-1401-8>.
- [13] Hong, H., Liu, J., & Zhu, A.-X. (2019). Landslide susceptibility evaluating using artificial intelligence method in the Youfang district (China). *Environmental Earth Sciences*, 78(15), 488. <https://doi.org/10.1007/s12665-019-8415-9>.
- [14] Lei, X., Chen, W., & Pham, B. T. (2020). Performance Evaluation of GIS-Based Artificial Intelligence Approaches for Landslide Susceptibility Modeling and Spatial Patterns Analysis. *ISPRS International Journal of Geo-Information*, 9(7), 443. <https://doi.org/10.3390/ijgi9070443>.
- [15] Nguyen, V. V., Pham, B. T., Vu, B. T., Prakash, I., Jha, S., Shahabi, H., Shirzadi, A., Ba, D. N., Kumar, R., Chatterjee, J. M., & Tien Bui, D. (2019). Hybrid Machine Learning Approaches for Landslide Susceptibility Modeling. *Forests*, 10(2), 157. <https://doi.org/10.3390/f10020157>.
- [16] Nhu, V.-H., Mohammadi, A., Shahabi, H., Ahmad, B. B., Al-Ansari, N., Shirzadi, A., Clague, J. J., Jaafari, A., Chen, W., & Nguyen, H. (2020). Landslide Susceptibility Mapping Using Machine Learning Algorithms and Remote Sensing Data in a Tropical Environment. *International Journal of Environmental Research and Public Health*, 17(14), 4933. <https://doi.org/10.3390/ijerph17144933>.
- [17] Ahmed, N., Firoze, A., & Rahman, R. M. (2020). Machine learning for predicting landslide risk of Rohingya refugee camp infrastructure. *Journal of Information and Telecommunication*, 4(2), 175-198. <https://doi.org/10.1080/24751839.2019.1704114>.
- [18] Saaty, T. L. (1977). A scaling method for priorities in hierarchical structures. *Journal of Mathematical Psychology*, 15(3), 234-281. [https://doi.org/10.1016/0022-2496\(77\)90033-5](https://doi.org/10.1016/0022-2496(77)90033-5).
- [19] Sujatha, E. R., Kumaravel, P., & Rajamanickam, G. V. (2014). Assessing landslide susceptibility using Bayesian probability-based weight of evidence model. *Bulletin of Engineering Geology and the Environment*, 73(1), 147-161. <https://doi.org/10.1007/s10064-013-0537-9>.