



Informe mensual de actividades

Anexo WP1.3.2 Modelo de Alertas para
movimientos en masa detonados por lluvias -
Equipo Geotecnia

Agosto de 2025

Contrato
CCT 261 de 2025

Contenido

WP1.3	Información para la gestión y herramientas operacionales que permitan la consolidación del observatorio de amenazas y riesgos	2
	Modelo de Alertas por Movimientos en Masa detonados por lluvias	2
	Referencias	26

WP1

Observatorio de amenazas y riesgos

Este WP tiene como objetivo generar conocimiento que sirva como insumo para la alerta temprana y la toma de decisiones a partir del monitoreo, análisis, modelación y generación de alarmas y alertas sobre múltiples componentes físicos, a través de actividades de investigación y operaciones que permitan avanzar en la caracterización, entendimiento, seguimiento y pronóstico de múltiples amenazas ambientales y evaluación de riesgos asociados.

Se avanzará en la consolidación del observatorio de múltiples amenazas, el cual es fundamental dada la variedad de amenazas que pueden impactar la sociedad y el territorio. Para este fin, el WP1 está constituido por tres grandes grupos de actividades: WP1.1 - Caracterización y monitoreo de variables y procesos asociados con las amenazas. El grupo WP1.2 - Modelación y pronóstico de la calidad del aire, las lluvias y otros fenómenos asociados con las amenazas. Por último, el grupo WP1.3 - Información para la gestión y herramientas operacionales que permitan la consolidación del observatorio de amenazas y riesgos en su primera fase, para el apoyo a emergencias, se enfoca en la aplicación (transferencia) de esta investigación a las operaciones para generar alertas y apoyar la gestión, a través de la consolidación de un observatorio multi-amenaza.

WP1.3

Información para la gestión y herramientas operacionales que permitan la consolidación del observatorio de amenazas y riesgos

Modelo de Alertas por Movimientos en Masa detonados por lluvias

Introducción

Los movimientos en masa representan una de las amenazas naturales más significativas, que causan extensas pérdidas de vidas y daños ambientales cada año (Petley, 2012). La lluvia es uno de los factores más comunes que desencadenan estos eventos (Guzzetti et al., 2000; Kirschbaum et al., 2010; Petley, 2012). A nivel regional, una de las estrategias más efectivas para estudiar la lluvia que puede provocar un movimiento en masa es a través de los umbrales de lluvia. Un umbral se define como la cantidad mínima de precipitación a partir de la cual es probable que se produzcan movimientos en masa (Reichenbach et al., 1998; Guzzetti et al., 2007; Segoni et al., 2015). Por esta razón, al desarrollar herramientas para sistemas de alerta temprana de movimientos en masa, los umbrales de lluvia se consolidan como un instrumento esencial. Una de las ventajas de los sistemas de alerta temprana basados en umbrales críticos de lluvia radica en que el monitoreo de la precipitación es relativamente sencillo y económicamente eficiente en extensas zonas geográficas (IEWP, 2005).

Los umbrales de lluvia se establecen mediante diversas técnicas y metodologías. Fundamentalmente, hay algunos enfoques para su cálculo: mediante modelos estadísticos y modelos físicos (Guzzetti et al., 2000; Kirschbaum et al., 2010; Petley, 2012; Wu et al., 2015).

Los umbrales estadísticos se determinan a partir de la recopilación de datos históricos de precipitaciones, que pueden estar o no vinculados a registros históricos de movimientos en masa. Este análisis implica una revisión estadística detallada de los registros antiguos para identificar la correlación entre la ocurrencia de deslizamientos y las lluvias que los provocaron (Gariano et al., 2015; Wu et al., 2015). Los umbrales definidos a través de métodos estadísticos suelen utilizar modelos frecuentistas (Brunetti et al., 2010; Peruccacci et al., 2012, 2017), modelos bayesianos (Guzzetti et al., 2008) y la probabilidad condicionada (Berti et al., 2012).

Por otro lado, los umbrales de lluvia establecidos mediante modelos físicos se basan en procesos físicos y utilizan métodos numéricos. Estos modelos analizan principalmente la interacción entre las precipitaciones y las condiciones del terreno, utilizando modelos hidrológicos y de estabilidad para establecer dicha relación (Iverson, 2000; Guzzetti et al., 2008; Baum et al., 2008; Alvioli et al., 2014). Para la elaboración de estos umbrales, es esencial contar con datos detallados sobre las condiciones hidrológicas, la geología, la morfología y las características específicas de los suelos que influyen directamente en la activación de los movimientos en masa (Aleotti, 2004; Crosta and Frattini, 2001).

En Colombia, aún no se ha establecido una metodología específica y detallada para implementar un Sistema de Alerta Temprana regional dirigido a movimientos en masa inducidos por lluvias. Si bien en el Valle de Aburrá, al igual que en otras partes del país, se han llevado a cabo investigaciones sobre la temática, la relación entre las condiciones de lluvia y los deslizamientos ha sido insuficientemente estudiada (Hidalgo and Vega, 2014).

Moreno et al. (2006) fueron pioneros en modelar la influencia de la lluvia en los movimientos en masa en Antioquia. Propusieron umbrales de precipitación basados en la lluvia acumulada durante tres días anteriores y los 15 días que le siguen, relacionando estos valores con la ocurrencia de deslizamientos. Por su parte, Aristizábal et al. (2010) determinaron umbrales específicos para el Valle de Aburrá, sugiriendo combinaciones de lluvias acumuladas de 0 a 100 mm en 5 días con lluvias antecedentes de 60 mm en 30 días, 160 mm en 60 días y 200 mm en 90 días. Recientemente, Marin and Velásquez (2020) presenta una metodología que establece umbrales basados en la Intensidad-Duración de la lluvia, utilizando un modelo físico aplicándolo a 108 subcuencas del Valle de Aburrá. A pesar de los estudios mencionados, aún no se ha consolidado una herramienta que opere en tiempo real y que proporcione información acerca de las lluvias que pueden desencadenar movimientos en masa en la región. Si bien actualmente el IDEAM presenta un mapa diario de las condiciones de susceptibilidad por movimientos en masa para cada municipio, teniendo en cuenta la lluvia diaria, no existe documentación que presente una metodología replicable en otros entornos y escalas.

Este documento presenta un resumen general de la metodología desarrollada para un modelo regional de alertas por movimientos en masa, basado en la lluvia antecedente. Dicho modelo, formulado en vigencias anteriores y actualmente operado diariamente por el equipo de geotecnia, genera mapas de probabilidad de ocurrencia de movimientos en masa clasificados por barrios y veredas. Además, se describen los análisis y procedimientos implementados para reducir la incertidumbre y ofrecer productos más confiables. Finalmente, se resalta la importancia de continuar evaluando las limitaciones del modelo e incorporar nuevas metodologías que fortalezcan su mejora continua.

Metodología

En la Figura 1 se presenta un esquema general de la metodología propuesta para el modelo de alertas. Esta se compone de cuatro pasos principales: **1) Procesamiento de los datos, 2) Ajuste y definición de umbrales, 3) Espacialización, y 4) Generación del mapa de alertas.** Es posible que con el tiempo el modelo se ajuste y algunos de estos componentes se modifiquen. A continuación, se explica en detalle cada uno de los pasos.




Figura 1. Esquema general de la metodología propuesta para el modelo de alertas por movimientos en masa detonados por lluvias.

1. Procesamiento de datos

Inventario de movimientos en masa: Se utilizaron dos fuentes principales para esta base de datos: el Departamento Administrativo de Gestión del Riesgo y Desastres (DAGR) y el Semillero de Investigación Geohazards de la Universidad Nacional de Colombia, sede Medellín. El DAGRD proporciona datos de emergencias reportadas a través de la línea de atención 123, cubriendo el período de septiembre de 2020 a marzo de 2023, con 4,153 eventos. El Semillero Geohazards complementa esta información con registros desde 1970 hasta 2023, para los demás municipios del Valle de Aburrá, fuera de Medellín.

Se seleccionó el período de 2013 a 2023 para alinear con los registros históricos de lluvias de SIATA. Se realizó una depuración, asegurando que los eventos seleccionados se relacionaban principalmente con lluvias y no con otras causas, como factores antrópicos. Para esto, se seleccionaron aquellos eventos que tuvieron más de 20 mm de acumulado en el día previo a la ocurrencia del evento y que tuviera más de 300 mm de acumulados durante los 90 días antecedentes. Finalmente, se obtuvieron 801 eventos relacionados principalmente con lluvias. El 97 % de estos eventos provienen del inventario del DAGRD, destacando la importancia de Medellín debido a su densidad poblacional y su avanzada sistematización en el registro de eventos de movimientos en masa. La Figura 2 muestra la distribución espacial de los eventos del inventario recopilado.

A pesar de la rigurosa depuración realizada en los datos de movimientos en masa y precipitación, existen limitaciones significativas que deben considerarse al interpretar y valorar los resultados obtenidos. Estas limitaciones incluyen incertidumbres en la ubicación espacial y temporal de los movimientos en masa, la calidad de los datos de lluvia registrados, el área de influencia de las estaciones pluviométricas y las incertidumbres inherentes a las metodologías aplicadas. Aunque se asume que los movimientos en masa analizados fueron desencadenados por lluvias, otros factores, como la actividad antrópica, podrían haber contribuido. La exactitud en la fecha y hora de cada evento está sujeta a la precisión del organismo o entidad que completó el registro, lo cual puede introducir un grado de subjetividad. Asimismo, la localización de los eventos no siempre refleja con exactitud el lugar del suceso; en algunos casos, se basa en direcciones o áreas conocidas, con un margen de error que podría alcanzar decenas de metros.

Datos de precipitación: Para el análisis de la precipitación, se tomó el registro pluviómetro de la red de sensores del proyecto SIATA. Se seleccionaron 35 estaciones con el registro histórico más extenso, que abarca desde el año 2012 hasta la actualidad. Estas estaciones fueron las primeras instaladas por el proyecto y registran datos cada minuto. La Figura 2 muestra la ubicación de los pluviómetros utilizados en los análisis, junto con la proximidad de los eventos del inventario de movimientos en masa. Para correlacionar los eventos de lluvia con los movimientos en masa del inventario, se consideraron los eventos que ocurrieron dentro de un radio de 5 km alrededor de cada pluviómetro. En casos donde un evento estuviera en el rango de dos estaciones (dentro del radio de 5 km), se asoció al pluviómetro más cercano al sitio del evento. Así, cada evento del inventario tiene asignado el pluviómetro más próximo.

Algunas limitaciones del registro pluviométrico se asocian a la variación en la altura de las estaciones pluviométricas, aumentando la incertidumbre sobre la lluvia específica que desencadenó el movimiento en masa. Además, la calidad de los datos de lluvia puede verse afectada por diversos factores, como daños en las estaciones, fallos de energía eléctrica del lugar o fallos en el registro y almacenamiento de los datos, lo que impide una representación precisa de las precipitaciones reales que provocaron los eventos.




Figura 2. Mapa del Valle de Aburrá mostrando las ubicaciones de los eventos de los inventarios recopilados, con un total de 801 eventos. Los eventos del DAGRD (Medellín) abarcan el período de 2020 a 2023, y los de Geohazards de 2013 a 2023. Los 35 pluviómetros seleccionados del SIATA están marcados con triángulos azules.

Definición variables de precipitación: Los umbrales de lluvia Reciente - Antecedente, referidos en la literatura como umbrales de lluvia antecedente, están relacionados con los tipos de umbrales de precipitación que se derivan utilizando metodologías estadísticas y empíricas o modelo basados en datos (Balducci et al., 2006; Chleborad et al., 2006). Estos umbrales se basan en el acumulado total de precipitación registrado en los días previos a un movimiento en masa. Para establecer estos umbrales, el estudio se centró en el análisis de dos variables específicas de precipitación antecedente. La primera variable, nombrada precipitación antecedente a Corto Plazo (CP), refleja el acumulado de lluvia registrado en los días previos al evento. Por ejemplo, un CP de 7 días evalúa la precipitación acumulada en esos 7 días previos al evento. La segunda variable, llamada precipitación de Largo Plazo (LP), representa el acumulado de lluvia en los días anteriores al período considerado para CP. Por ejemplo, un LP de 90 días indicaría la precipitación acumulada durante los 90 días antes del período de 7 días de CP. La Figura 3 muestra un gráfico esquemático de una serie temporal de lluvia ilustrando estas dos variables.




Figura 3. Esquema de una serie de tiempo de precipitación donde se indican las dos variables de precipitación antecedente que utiliza el modelo: Lluvia de Corto Plazo y Lluvia de Largo Plazo.

Se realizó el cálculo de la lluvia antecedente para diferentes intervalos temporales correspondientes a cada evento. Se realizaron variadas combinaciones de días para la CP y LP. Para CP, los períodos estudiados fueron de 1, 3, 5 y 7 días, y para LP, de 15, 30, 60 y 90 días. Combinando estos intervalos de CP y LP, se buscó determinar cuáles ofrecían mayor claridad para distinguir entre los patrones de precipitación que incrementan la probabilidad de movimientos en masa y aquellos que no.

2. Ajuste modelo y definición de umbrales

Entrenamiento del modelo y ajuste: Para la definición del modelo y ajuste se emplearon algunas técnicas de clasificación supervisada. Se exploraron tres algoritmos: Regresión Logística (RL), Máquina de Vectores de Soporte (SVM) y Análisis Discriminante Lineal (LDA), elegidos por su prevalencia en la literatura y su eficacia en clasificar linealmente entre grupos, diferenciando los eventos de lluvia que causan deslizamientos de los que no. Adicionalmente, se usaron 801 eventos de lluvia que no resultaron en movimientos en masa tomados aleatoriamente entre 2013 y 2023, que superaron los 5 mm de precipitación diaria y 100 mm en 90 días, para entrenar y evaluar los modelos, dividiendo los eventos en aquellos que resultaron y no resultaron en movimientos en masa.

Métricas de validación: Para cada combinación de días considerada, se evaluó el rendimiento de los tres algoritmos de clasificación anteriormente mencionados. Con el objetivo de identificar cuál combinación de días y qué algoritmo mostraban un desempeño superior en la clasificación de eventos de lluvia que generan movimientos en masa frente a los que no, se calcularon diversas métricas de rendimiento. Estas incluyen Accuracy, F1-Score, la curva ROC y el Área Bajo la Curva ROC (AUC). Para el entrenamiento y evaluación de cada algoritmo y combinación de días, se utilizó una división del 80 % de los datos para entrenamiento y el 20 % restante para evaluación.

Definición de umbrales y categorías de alertas: Los umbrales definidos se basaron en las métricas obtenidas de la Curva ROC. Esta curva es un gráfico cartesiano bidimensional que describe el rendimiento y la eficacia de un modelo, mostrando la tasa de verdaderos positivos (eje y: TPR) contra la tasa de falsos positivos (eje x: 1-TNR) para diferentes escenarios de probabilidad. En este contexto, el TPR, también conocido como Sensibilidad, mide la proporción de casos de deslizamiento correctamente identificados (es decir, deslizamientos que superaron el umbral) entre todos los eventos de lluvia con deslizamientos observados. Por ejemplo, un TPR del 95 % indica que el modelo identifica correctamente el 95 % de las lluvias que provocaron deslizamientos. Por otro lado, el TNR evalúa la capacidad del modelo para identificar correctamente los días de lluvia sin deslizamientos, es decir, la proporción de días lluviosos correctamente clasificados sin deslizamientos (que no superan el umbral) entre todos los eventos de lluvia observados sin deslizamientos.

Considerando lo anterior, un umbral óptimo se puede definir cuando tanto el TPR como el TNR son altos. Por esta razón, un TPR del 95 % puede interpretarse como un umbral con una probabilidad de excedencia del 5 %, un criterio común en la literatura que sugiere que el 95 % de las lluvias asociadas con deslizamientos superan el umbral definido, mientras que solo el 5 % no lo hace. En este análisis, se extrajeron tres umbrales de probabilidad. El primer umbral se asocia con un TPR del 95 %, el segundo corresponde al punto óptimo en la Curva ROC, que es el punto más cercano a la clasificación perfecta, es decir, un TPR y TNR del 100 % (esquina superior izquierda de la gráfica ROC). El tercer umbral se define con una probabilidad asociada a un TNR del 95 %, es decir, la más alta proporción de días sin deslizamientos correctamente clasificados.

En resumen, el **umbral alto** corresponde a una tasa de verdaderos positivos del 95 % (es decir, un 5 % de falsos negativos), mientras que el **umbral bajo** se asocia a una tasa de verdaderos negativos del 95 % (equivalente a un 5 % de falsos positivos). Con base en estos valores, se definieron tres categorías de probabilidad de ocurrencia de movimientos en masa: **Baja**, para valores inferiores al umbral bajo; **Media**, para valores comprendidos entre el umbral bajo y el umbral alto; y **Alta**, para valores superiores al umbral alto. En la Figura 4 se presenta un ejemplo gráfico de cómo se definieron los umbrales y cada una de las categorías de probabilidad.




Figura 4. Ejemplo de la definición de los umbrales de lluvia a partir de la tasa de verdaderos positivos (95 %) y la tasa de falsos negativos (5 %). Se ilustran las categorías de probabilidad de ocurrencia de movimientos en masa: Baja, Media y Alta.

3. Especialización de la precipitación acumulada

Para evaluar los umbrales definidos en todo el Valle de Aburrá es necesario que las dos variables de entrada —la lluvia de corto plazo (CP) y la lluvia de largo plazo (LP)— estén representadas espacialmente en toda el área de estudio. Para ello, el modelo se apoya en dos fuentes de información de precipitación registradas por el proyecto SIATA: la red de pluviómetros y el radar meteorológico.

Cada fuente presenta ventajas y limitaciones. La red de pluviómetros ofrece mediciones puntuales de alta confiabilidad, pero no representa de manera continua la variabilidad espacial de la lluvia en toda la región. Por su parte, el radar permite caracterizar los patrones espaciales de la precipitación, aunque el cálculo del acumulado puede presentar mayor incertidumbre, dado que se trata de una medición indirecta realizada a una altura específica.

Con el fin de aprovechar lo mejor de ambas fuentes, se empleó una técnica de interpolación que combina la precisión de los acumulados medidos por la red de pluviómetros con la capacidad espacial del radar. La técnica utilizada corresponde al **Kriging Simple con Medias Locales (KSML)**.

El Kriging Simple con Medias Locales (SKLM) es una variante del Kriging Simple que incorpora una media local variable en lugar de una media constante. En este caso, la media local se estima utilizando datos auxiliares, como los datos de radar, que proporcionan una mejor representación de la variabilidad espacial en la región de estudio. Permite que la media local cambie de un punto a otro, utilizando datos de radar para capturar mejor los patrones espaciales.

La estimación de la precipitación en un punto no muestreado s_0 se realiza combinando la media local en esa ubicación con una suma ponderada de las diferencias entre los valores observados en los pluviómetros y la media local en las ubicaciones de esos pluviómetros. La fórmula es:

$$Z^*(s_0) = m(s_0) + \sum_{i=1}^N \lambda_i [Z(s_i) - m(s_i)], \quad (1)$$

donde:

- $Z^*(s_0)$ es la estimación de la precipitación en el punto no muestreado s_0 ,

- $m(s_0)$ es la media local en la posición s_0 , derivada de los datos de radar,
- $Z(s_i)$ es el valor de precipitación medido en el pluviómetro ubicado en s_i ,
- $m(s_i)$ es la media local en el punto s_i , también obtenida del radar,
- λ_i es el peso asignado a cada observación en el pluviómetro s_i , que se determina minimizando la varianza de la estimación, es decir, buscando la mayor precisión posible.

Para validar su eficacia, se seleccionaron fechas aleatorias con eventos de lluvia en cada uno de los trimestres del año. Esto permitió evaluar el comportamiento del modelo de interpolación tanto en temporadas con alta incidencia de lluvias como en aquellas con menor actividad o días con lluvia. En la Figura 5 se presenta un ejemplo de evento de lluvia específico registrado con la red pluviométrica y con el radar meteorológico y cómo sería el mapa final interpolado.




Figura 5. Ejemplo de evento de lluvia específico registrado con la red pluviométrica y con el radar meteorológico y cómo sería el mapa final interpolado.

4. Mapa de alertas

Finalmente, se presenta el mapa de alertas con las categorías previamente definidas. En términos generales, el modelo integra el mapa de lluvia acumulada de corto plazo con el de largo plazo, y evalúa en cada píxel de la región si estos valores superan los umbrales establecidos. De esta manera, se obtiene un mapa de probabilidad para todo el Valle de Aburrá, como se observa en la Figura 6.

Posteriormente, este mapa de probabilidad se cruza con una máscara que excluye las grandes áreas con pendientes menores a 5° , que corresponden principalmente a zonas planas asociadas a la llanura de inundación del río Aburrá y a algunos valles de quebradas mayores. En estas áreas, la probabilidad de que se presenten movimientos en masa detonados por lluvia es prácticamente nula, por lo que se clasifican en la categoría **No aplica**.

Luego, el mapa resultante se intersecta con la capa vectorial de barrios y veredas del Valle de Aburrá. La categoría de probabilidad asignada a cada barrio o vereda corresponde a la categoría más frecuente entre los píxeles contenidos en su polígono. Por ejemplo, si en la vereda Piedras Blancas la mayoría de los píxeles presentan una probabilidad baja, entonces la vereda se clasifica con probabilidad baja.




Figura 6. Mapas de las variables de lluvia de corto plazo y largo plazo, evaluadas en los umbrales establecidos para obtener las diferentes categorías de probabilidad de ocurrencia de movimientos en masa.




Figura 7. Mapa final de alertas por probabilidad de ocurrencia de movimientos en masa detonados por lluvias, agregado por veredas y barrios de los distintos municipios del Valle de Aburrá.

Resultados

Los resultados de las métricas de Accuracy y F1-Score, expresados en porcentajes, se presentan en la Tabla 1 para cada combinación de días y algoritmo de clasificación evaluados. Es notorio que los tres modelos de clasificación presentaron un rendimiento óptimo. Todas las combinaciones de días exhibieron un Accuracy y un F1-Score superiores al 70 %, lo cual sugiere que casi cualquier selección de días logra distinguir eficazmente entre las lluvias que incrementan la probabilidad de ocasionar movimientos en masa y aquellas que no. Las combinaciones más efectivas, de acuerdo con las métricas evaluadas, son las de 1 día versus 90 días, 3 días versus 90 días, 5 días versus 90 días y 7 días versus 90 días, destacadas en negrita en la Tabla 3.

Tabla 1. Evaluación de algoritmos de clasificación con Accuracy y F1-Score para todas las combinaciones de días con lluvia registrada por pluviómetros.

Pluvios CP vs. LP	Regresión Logística		SVM		LDA	
	Accuracy	F1-score	Accuracy	F1-score	Accuracy	F1-score
1dvs.15d	83.49	83.49	85.36	85.36	80.06	80.06
1dvs.30d	86.29	86.29	88.79	88.79	83.18	83.18
1dvs.60d	88.47	88.47	87.85	87.85	83.49	83.49
1dvs.90d	89.72	89.72	89.1	89.1	88.16	88.16
3dvs.15d	77.26	77.26	77.26	77.26	76.95	76.95
3dvs.30d	77.88	77.88	77.88	77.88	74.77	74.77
3dvs.60d	79.13	79.13	79.44	79.44	80.37	80.37
3dvs.90d	81.31	81.31	83.49	83.49	79.75	79.75
5dvs.15d	72.9	72.9	73.83	73.83	73.52	73.52
5dvs.30d	76.32	76.32	75.39	75.39	74.45	74.45
5dvs.60d	76.95	76.95	80.06	80.06	76.95	76.95
5dvs.90d	80.69	80.69	80.37	80.37	80.37	80.37
7dvs.15d	73.52	73.52	73.83	73.83	74.77	74.77
7dvs.30d	78.19	78.19	77.57	77.57	78.19	78.19
7dvs.60d	78.82	78.82	79.13	79.13	79.13	79.13
7dvs.90d	81.31	81.31	81.93	81.93	81.31	81.31

Finalmente, de las combinaciones más efectivas (1 día vs. 90, 3 días vs. 90 días, 5 días vs. 90 días y 7 días vs. 90 días) se escogieron 3 combinaciones de lluvias para la evaluación en tiempo real en la plataforma SIAMMO, estos fueron la combinación de 1 días vs. 90 días, 3 días vs. 90 días y las de 7 días vs. 90 días, esto por qué las primeras combinaciones refleja un poco las lluvias diaria o detonante, mientras que la segunda se asocia más a la lluvia antecedente que posiblemente aporta a la humedad en el suelo días anteriores a un evento de lluvia detonante.

En las Figuras 8, 9 y 10 se presentan los resultados de cada modelo evaluado. El gráfico de la izquierda representa la combinación de 90 días prior a los 7 días contra los 7 días y sus respectivos valores de probabilidades de lluvia crítica, presentados con diferentes gamas de colores. También se muestran los eventos de lluvia que detonaron movimientos en masa, así como aquellos que no lo hicieron y que formaron parte del testeo o evaluación del modelo, junto con los tres umbrales definidos por la Curva ROC, que se muestran en el segundo gráfico a la derecha, donde se indican con puntos cada uno de los valores de los umbrales. Se puede observar que los tres modelos presentaron un comportamiento similar tanto en la curva ROC como en los umbrales definidos. Por esta razón, para la combinación de días de 1 día contra 90 días anteriores a un día, solo se mostró el resultado obtenido con el modelo de Regresión Logística, como se observa en la Figura 11.




Figura 8. (a) Combinación de CP de 7 días y LP de 90 días prior a 7 días y su respectiva probabilidad hallada con Regresión Logística. Las líneas negra, roja y azul representan los umbrales determinados con la Curva ROC mostrados en forma de puntos en el gráfico (b). También se muestra los datos de validación utilizados para construir la curva ROC (puntos verdes y triángulos rojos). (b) Curva ROC para la combinación de CP de 7 días y LP de 90 días prior a 7 días con Regresión Logística. El punto azul representa el umbral hallado con un TPR de 95 %, el punto rojo es el punto Óptimo y el negro el TNR de 95 %.




Figura 9. (a) Combinación de CP de 7 días y LP de 90 días prior a 7 días y su respectiva probabilidad hallada con Support Vector Machine. Las líneas negra, roja y azul representan los umbrales determinados con la Curva ROC mostrados en forma de puntos en el gráfico (b). También se muestra los datos de validación utilizados para construir la curva ROC (puntos verdes y triángulos rojos). (b) Curva ROC para la combinación de CP de 7 días y LP de 90 días prior a 7 días con Support Vector Machine. El punto azul representa el umbral hallado con un TPR de 95 %, el punto rojo es el punto Óptimo y el negro el TNR de 95 %.




Figura 10. (a) Combinación de CP de 7 días y LP de 90 días prior a 7 días y su respectiva probabilidad hallada con Análisis Lineal Discriminante. Las líneas negra, roja y azul representan los umbrales determinados con la Curva ROC mostrados en forma de puntos en el gráfico (b). También se muestra los datos de validación utilizados para construir la curva ROC (puntos verdes y triángulos rojos). (b) Curva ROC para la combinación de CP de 7 días y LP de 90 días prior a 7 días con Análisis Lineal Discriminante. El punto azul representa el umbral hallado con un TPR de 95 %, el punto rojo es el punto Óptimo y el negro el TNR de 95 %.




Figura 11. (a) Combinación de CP de 1 día y LP de 90 días prior a 1 día y su respectiva probabilidad hallada con Regresión Logística. Las líneas negra, roja y azul representan los umbrales determinados con la Curva ROC mostrados en forma de puntos en el gráfico (b). También se muestra los datos de validación utilizados para construir la curva ROC (puntos verdes y triángulos rojos). (b) Curva ROC para la combinación de CP de 1 día y LP de 90 días prior a 1 días con Regresión Logística. El punto azul representa el umbral hallado con un TPR de 95 %, el punto rojo es el punto Óptimo y el negro el TNR de 95 %.

Finalmente, se realiza una evaluación visual del desempeño del modelo mediante la comparación de los mapas generados para distintos eventos de lluvia que ocasionaron emergencias y afectaciones en varios sectores del Valle de Aburrá. Adicionalmente, se incluye un caso de lluvia en el que no se reportaron movimientos en masa, con el fin de contrastar los resultados.

En la Figura 12 se presentan, en la parte superior izquierda, los mapas de lluvia acumulada de corto plazo (1 día) y de largo plazo (90 días). A la derecha se observa el mapa de probabilidad correspondiente al 25 de mayo de 2023, fecha en la que se registró un número significativo de movimientos en masa de tipo flujo en la vereda San Andrés del municipio de Girardota. En este evento se contabilizaron alrededor de 350 deslizamientos que afectaron vías, viviendas y parcelaciones.

De manera similar, en la Figura 13 se muestra el resultado para el 9 de mayo de 2024, considerando una lluvia acumulada de corto plazo de 7 días y una acumulación de largo plazo de 90 días. En este caso, el modelo indicó una alta probabilidad de movimientos en masa en el sur del valle, lo que coincidió con la ocurrencia de un flujo en el sector Himalaya, en el municipio de La Estrella, que obligó a la evacuación de más de 100 personas.

En las Figuras 14 y 15 se ilustran otros dos eventos relevantes: el del 29 de abril de 2025 en el corregimiento de Altavista (Medellín) y el del 6 de mayo de 2025 en el sector Los Balsos (El Poblado). Ambos eventos estuvieron asociados a lluvias intensas en los días previos y generaron pérdidas materiales considerables.

Finalmente, en la Figura 16 se presenta el mapa correspondiente al 30 de enero de 2025, fecha en la que se registró un evento de lluvia sin reportes de movimientos en masa en el Valle de Aburrá. En este caso, el modelo asignó predominantemente la categoría de probabilidad **Baja**, lo cual concuerda con la ausencia de emergencias y representa el comportamiento esperado del sistema en este tipo de situaciones.




Figura 12. Mapas de lluvia acumulada de corto plazo (1 día), largo plazo (90 días) y mapa de probabilidad para el 25 de mayo de 2023, cuando se registraron alrededor de 350 movimientos en masa en la vereda San Andrés, Girardota.

El Himalaya, La Estrella (9-05-2024)




Figura 13. Mapas de lluvia acumulada y probabilidad para el 9 de mayo de 2024, día en que se presentó un flujo en el sector Himalaya (La Estrella), que obligó a la evacuación de más de 100 personas.

Altavista, Medellín (29-04-2025)




Figura 14. Mapas de probabilidad para el 29 de abril de 2025, eventos de deslizamientos registrados en el corregimiento de Altavista (Medellín).

Los Balsos, Medellín (06-05-2025)




Figura 15. Mapas de probabilidad para el 6 de mayo de 2025, evento ocurrido en el sector Los Balsos (El Poblado, Medellín).

Evento de lluvia (30-01-2025)




Figura 16. Mapa de probabilidad correspondiente al 30 de enero de 2025, evento de lluvia en el que no se registraron movimientos en masa en el Valle de Aburrá.

Discusión y conclusiones

Este estudio presenta una metodología para un modelo regional de alertas por movimientos en masa detonados por lluvia, basada en dos variables de precipitación antecedente: *corto plazo* (CP) y *largo plazo* (LP). Se entrenaron y evaluaron tres clasificadores supervisados (Regresión Logística, SVM y LDA) con un conjunto de eventos con deslizamientos (801) y un conjunto equivalente de eventos sin deslizamientos seleccionados aleatoriamente. Los resultados muestran desempeños consistentes (Accuracy y F1-score $> 70\%$) y destacan como combinaciones más informativas aquellas que usan LP de 90 días junto con CP

de 1, 3, 5 y 7 días. Con base en ello, se seleccionaron tres configuraciones (1–90, 3–90 y 7–90 días) para operación en tiempo casi real.

Operacionalmente, la metodología integra: (i) umbrales derivados de la Curva ROC (umbral alto con TPR = 95 %, umbral bajo con TNR = 95 %), (ii) fusión y espacialización de la precipitación mediante Kriging Simple con Medias Locales (KSML), combinando la precisión puntual de los pluviómetros con el patrón espacial del radar, y (iii) agregación de probabilidades por unidades administrativas (barrios y veredas) tras enmascarar zonas de pendiente $< 5^\circ$ (*No aplica*). Estudios de caso recientes evidencian coherencia espacial entre las áreas clasificadas con probabilidad *Alta* y la ocurrencia de afectaciones reportadas.

Pese a los resultados alentadores, deben considerarse varias fuentes de incertidumbre: (i) sesgos y vacíos del inventario (concentración espacial de reportes, precisión variable en fecha/hora y localización de eventos), (ii) incertidumbres instrumentales y operativas de la red de pluviómetros (fallos, mantenimiento, entorno local) y del radar (calibración, atenuación, conversión a acumulados) y (iii) la suposición de fronteras aproximadamente lineales en los clasificadores aplicados. Además, los umbrales son estáticos en el tiempo y no capturan explícitamente estacionalidad, variabilidad intra-anual o condicionantes climáticos de gran escala.

Recomendaciones y trabajo futuro

Se proponen las siguientes líneas de mejora para robustecer el sistema:

- **Evaluación y calibración probabilística:** complementar la ROC/AUC con curvas precisión–recuperación y diagramas de fiabilidad.
- **Validación espaciotemporal rigurosa:** esquemas de validación cruzada por estación/sector y retroevaluaciones por temporadas, para medir generalización fuera de muestra.
- **Enriquecimiento de predictores:** explorar otras ventanas CP/LP y variables auxiliares (índices topográficos, litología, cobertura/uso del suelo, proxies de humedad antecedente), y métodos que capturen no linealidades (bosques aleatorios, *gradient boosting*) con control de sobreajuste.
- **Umbrales dinámicos y regionalización:** permitir que los umbrales varíen por subregiones hidroclimáticas o clusters de lluvia, y por estado climático (p. ej., temporadas o fases ENSO).
- **Fusión radar–pluviómetros:** evaluar variantes del KSML y esquemas de corrección por sesgo/escala del radar, cuantificando la incertidumbre de la interpolación (mapas de varianza kriging).
- **Métricas operativas:** incorporar indicadores orientados a alerta (POD, FAR, CSI) y análisis de costos/beneficios de falsas alarmas vs. omisiones, alineados con las necesidades de gestión del riesgo.

La estrategia propuesta genera mapas de probabilidad interpretables y operables para apoyo a la toma de decisiones a escala regional. Si bien persisten incertidumbres asociadas a datos, modelos y agregación espacial, los resultados indican capacidad para discriminar condiciones de *Alta* vs. *Baja* probabilidad en concordancia con eventos observados. La implementación de las mejoras sugeridas —en especial calibración probabilística, validación espaciotemporal y umbrales dinámicos— fortalecerá la confiabilidad del sistema y su utilidad práctica para la gestión del riesgo por movimientos en masa detonados por lluvia en el Valle de Aburrá.

Productos

Poner los mapas, siammo y el repositorio.

Tabla 2. Productos relacionados con análisis de lluvia y movimientos en masa.

Producto / Tema	Descripción resumida
Repositorio Código Git-Hub	https://github.com/siatalandslides/alert_model
Mapas diarios	https://siata.gov.co/geotecnia/alertas_diarias/
Mapas en la plataforma SIAMMO	https://siata.gov.co/geotecnia/siammo.html

Avances

Mes de Julio

Durante el mes de julio se enfocaron esfuerzos en mejorar los mapas de lluvia acumulada interpolados a partir de la red pluviométrica y del radar meteorológico. Se identificó que el principal problema provenía de la información del radar en zonas altas, como el Cerro Padre Amaya o el Cerro La Baldía, donde el haz del radar impacta el relieve, generando valores artificialmente altos de precipitación.

En conjunto con el equipo de meteorología, se evaluaron diferentes estrategias para corregir este sesgo. Finalmente, se implementó una máscara que excluye estos valores no representativos, evitando que distorsionen la interpolación. Las pruebas realizadas con diferentes metodologías concluyeron que la opción más efectiva fue dejar estas áreas como “sin datos”, permitiendo que el proceso de interpolación las completara usando la información de las celdas vecinas.

A partir de esta mejora, los mapas de interpolación de lluvia dejaron de verse afectados por valores extremos irreales, y los mapas de probabilidad resultantes mostraron coherencia con las condiciones reales. Se espera seguir avanzando en esta línea, no solo filtrando la información del radar con mayor precisión, sino también adoptando técnicas de interpolación que consideren el error en los datos, de forma que estos sean filtrados o eliminados en lugar de amplificados, garantizando así productos de lluvia más fiables.

Mes de agosto

Máscara datos acumulados de Radar Durante el mes de julio se aplicó una máscara que eliminaba (dejaba “sin datos”) las celdas de acumulados de lluvia muy altos del radar—típicos cuando el haz impacta en zonas montañosas muy altas—. Esto resolvía los picos irreales, pero dejaba huecos que luego distorsionaban la interpolación (Lluvia pluvios + Radar). En agosto se mejoró el procesamiento con una estrategia robusta que se aplica en dos pasos: (i) **detección** de picos altos usando estadística robusta local y (ii) **relleno** (*inpainting*) de las celdas marcadas como picos altos con el valor del píxel válido más cercano. El objetivo es obtener campos acumulados realistas sin suavizar en exceso la lluvia acumulada real.

El procesamiento se puede dividir en los siguientes pasos:

- **Acumulado temporal:** Sea $R(x, y, t)$ la lluvia horaria de radar. Para un periodo $[t_0 - D, t_0]$, el

acumulado es:

$$A(x, y) = \sum_{t \in [t_0 - D, t_0]} R(x, y, t), \quad (2)$$

donde t_0 es la fecha objetivo y D los días previos a acumular (p.ej., $D = 90$).

- **Detección robusta de picos (MAD local):** Se recorre la malla $A(x, y)$, para cada celda i , se evalúa A_i respecto a su vecindario W_i (vecindario cuadrado de tamaño $s \times s$ centrado en i , aquí $s = 9$):

$$m_i = \text{med}\{A_j : j \in W_i\}, \quad (3)$$

$$\text{MAD}_i = \text{med}\{|A_j - m_i| : j \in W_i\}, \quad (4)$$

$$\sigma_i = 1,4826 \text{ MAD}_i. \quad (5)$$

Aquí, m_i es la mediana local, MAD_i mide la dispersión robusta y σ_i convierte MAD a una escala comparable con la desviación estándar bajo normalidad. Se marca como *pico alto* la celda i si

$$(A_i - m_i) > k \sigma_i \quad \text{y} \quad \sigma_i > \varepsilon, \quad (6)$$

donde k controla cuán estricta es la detección y ε evita activar la máscara en zonas prácticamente uniformes. **Parámetros usados:** $s = 9$ (aprox. $4,5 \times 4,5$ km si la celda es de 500 m), $k = 3,5$, $\varepsilon = 0$.¹

- **Máscara y relleno por vecino más cercano:** La detección anterior produce una máscara booleana M sobre todo el Valle de Aburrá, donde $M(p) = 1$ (verdadero) indica “pico alto” y $M(q) = 0$ indica celda válida. Para cada celda marcada $p=1$ se busca el píxel válido más cercano:

$$q^* = \arg \min_{q: M(q)=0} \|p - q\|_2,$$

y se define el campo corregido

$$\hat{A}(p) = A(q^*), \quad \hat{A}(q) = A(q) \text{ si } M(q) = 0.$$

Esta estrategia preserva bordes y acumulados reales al no promediar sobre áreas extensas.

Elección de parámetros y consideraciones

- **Ventana s :** ventanas mayores son más robustas al ruido, pero pueden pasar por alto picos pequeños; $s = 9$ equilibra robustez y sensibilidad a la escala de 500 m.
- **Umbral k :** valores típicos $k \in [3, 5]$. Aquí $k = 3,5$ captura ecos orográficos intensos sin afectar núcleos convectivos reales.
- **Tolerancia ε :** útil para evitar disparos en campos muy planos (baja variabilidad).
- **NaN y bordes:** si todo el vecindario es inválido, no se rellena; opcionalmente puede extenderse la máscara a celdas NaN.

Resultados Tras aplicar la corrección, los mapas de acumulado de D días muestran una reducción clara de columnas y píxeles extremos alineados con los picos montañosos, donde la señal del radar no es

¹En operación, $\varepsilon \in [0, 1, 0, 5]$ mm ayuda a reducir falsos positivos en campos muy homogéneos.

clara, manteniendo el acumulado de lluvia real. La fracción de celdas corregidas se mantiene baja (como es esperable para artefactos localizados) y los máximos regionales descienden a rangos físicamente reales para las fechas de acumulados ensayadas.

En las Figuras 17, 18 y 19 se presentan, respectivamente: (i) el mapa de acumulado sin posprocesamiento, (ii) la máscara que identifica los píxeles no realistas y (iii) el acumulado final corregido con la metodología. En la Figura 17 se observan valores anómalamente altos tanto en el acumulado de 7 días como en el acumulado de 90 días previos; la Figura 19 muestra la máscara utilizada, donde se destacan las celdas que no corresponden a valores reales (picos muy altos); y la Figura 18 evidencia que, tras el procesamiento descrito, los mapas de acumulado son más acordes con la realidad, lo cual también se refleja en la escala de valores.




Figura 17. Mapa de acumulado de radar para los 7 días anteriores al día 21 de agosto de 2025 y los 90 días anteriores a esos 7 días. Se observan en ambos mapas valores extremos de lluvia superiores a los 1000 mm en ciertas zonas que coinciden con puntos donde el haz del radar choca con partes altas de montaña, principalmente hacia el occidente.




Figura 18. Máscara de las zonas identificadas como valores muy altos, fuera de lo normal, coherente con puntos donde el haz del radar choca con partes altas de montaña, principalmente hacia el occidente.




Figura 19. Mapa de acumulado de radar corregido con la metodología del vecino más cercano. Se observan que los picos muy altos ya no están.

Fragmentos de implementación (Python) Máscara de picos (MAD local):

```
def mascara_spike_mad(da, size=9, k=3.5, min_mad=0.0):
    arr = da.values
    def _med(x): return np.nanmedian(x)
    def _mad(x):
```



```
m = np.nanmedian(x)
return np.nanmedian(np.abs(x - m))
med = ndi.generic_filter(arr, _med, size=size, mode="nearest")
mad = ndi.generic_filter(arr, _mad, size=size, mode="nearest")
sigma = 1.4826 * mad
valid = np.isfinite(arr) & np.isfinite(med) & np.isfinite(sigma) & (sigma > min_mad)
mask = valid & ((arr - med) > (k * sigma))
return xr.DataArray(mask, coords=da.coords, dims=da.dims, name="mask_spike_mad")
```

Relleno por vecino más cercano:

```
def rellenar_vecino_mas_cercano(da, bad_mask):
    arr = da.values.copy()
    mask = bad_mask.values # | ~np.isfinite(arr) (activar si se desea)
    if mask.all():
        return da.copy()
    inds = ndi.distance_transform_edt(mask, return_distances=False, return_indices=True)
    out = arr.copy()
    out[mask] = arr[inds[0][mask], inds[1][mask]]
    return xr.DataArray(out, coords=da.coords, dims=da.dims, attrs=da.attrs, name=da.name)
```

Uso en la cadena de acumulación:

```
da_perodo, da_90d = acumulado.generar_mapa_acumulado()
mask_mala = mascara_spike_mad(da_perodo, size=9, k=3.5, min_mad=0.0)
da_perodo_fix = rellenar_vecino_mas_cercano(da_perodo, mask_mala)
```

Cálculo de la incertidumbre del Modelo de Alertas Uno de los objetivos principales de esta vigencia es realizar una evaluación detallada de la **incertidumbre del modelo de alertas**. Para ello es necesario plantear una metodología que permita abordar de manera integral los diferentes componentes del modelo y, en lo posible, cuantificar dicha incertidumbre.

Durante el mes se avanzó en la revisión y recopilación de estudios que proponen metodologías para evaluar la incertidumbre y validar sistemas de alerta temprana por movimientos en masa en distintas regiones del mundo. Estos trabajos constituyen una base conceptual y metodológica importante para orientar el proceso local. Entre los estudios más relevantes se destacan:

- *Assessing the performance of regional landslide early warning models: the EDuMaP method*. Revista *Natural Hazards and Earth System Sciences*, 2016 (Calvellido and Piciullo, 2016).
- *Adapting the EDuMaP method to test the performance of the Norwegian early warning system for weather-induced landslides*. Revista *Natural Hazards and Earth System Sciences*, 2017 (Piciullo et al., 2017).
- *Critical rainfall thresholds for triggering shallow landslides in the Serchio River Valley (Tuscany, Italy)*. Revista *Natural Hazards and Earth System Sciences*, 2012 (Giannecchini et al., 2012).
- *Calibration and validation of rainfall thresholds for shallow landslide forecasting in Sicily, southern Italy*. Revista *Geomorphology*, 2015 (Gariano et al., 2015).

- *Rainfall thresholds for the forecasting of landslide occurrence at regional scale*. Revista *Landslides*, 2012 (Martelloni et al., 2012).
- *Territorial early warning systems for rainfall-induced landslides*. Revista *Earth-Sciences Reviews*, 2018 (Piciullo et al., 2018).

Estos estudios plantean diferentes enfoques para la calibración, validación y análisis de incertidumbre en modelos de alerta por deslizamientos, lo que permitirá seleccionar e implementar las metodologías más adecuadas para el contexto del Valle de Aburrá.

Mes de septiembre

Durante agosto el trabajo se orientó al procesamiento de los acumulados de lluvia obtenidos por el radar meteorológico, incorporando una metodología que mitiga varias de sus limitaciones.

En septiembre el esfuerzo se centró en mejorar y actualizar la sección de *Movimientos en masa* del reporte hidrometeorológico semanal. Hasta ahora, el reporte evaluaba los umbrales únicamente con información de estaciones pluviométricas puntuales; por lo tanto, no se realizaba una espacialización a nivel de barrios y veredas de los municipios del Valle de Aburrá. En la Figura 20 se ilustra el formato anterior del reporte, en el que la probabilidad de movimientos en masa se presentaba sólo por estación.

Para contextualizar, el reporte se divide en dos partes: (i) **Resumen semanal** y (ii) **Condiciones actuales**. En el formato previo, el *Resumen semanal* mostraba un gráfico de barras con el número de estaciones en probabilidad alta (rojo), media (amarillo) y baja (verde) para cada día de la semana anterior (lunes a domingo; ver Figura 20). A la derecha, en *Condiciones actuales*, se incluía un mapa con la ubicación de las estaciones del valle coloreadas según la probabilidad del día de emisión del reporte (los lunes), acompañado de una tabla con los conteos por nivel de probabilidad y los municipios con estaciones en probabilidad alta (ver Figura 20). Finalmente, en la parte inferior se incluía una explicación breve y general del modelo de alertas.

Durante septiembre se actualizó este reporte para ofrecer alertas y un resumen semanal **especializados a nivel de barrio y vereda**, y no sólo por estaciones. Se diseñó un nuevo formato (Figura 21) que preserva la estructura original (izquierda: resumen semanal; derecha: condiciones actuales) pero incorpora:

- **Resumen semanal (izquierda):** gráfico de barras apiladas por municipio, que resume la proporción de barrios y veredas en probabilidades alta, media y baja para cada día de la última semana. Además, se listan los barrios/veredas que acumulan tres o más días en probabilidad alta (rojo), como insumo para priorizar monitoreo continuo, emisión de reportes y, de ser necesario, inspecciones de campo.
- **Condiciones actuales (derecha):** mapa de probabilidad de movimientos en masa para cada barrio o vereda de los municipios del Valle de Aburrá, correspondiente a la fecha de emisión del reporte (los lunes), junto con una tabla resumen del número de barrios/veredas en cada nivel de probabilidad y el listado de municipios asociados.

Asimismo, se actualizó la explicación metodológica del modelo en la sección inferior del reporte, aclarando de manera concisa en qué consiste, cómo se interpretan los niveles de probabilidad (alta/rojo, media/amarillo, baja/verde) y cómo se integra la información de lluvia antecedente.

Con esta nueva versión se espera mejorar la comprensibilidad del modelo de alertas por movimientos en masa detonados por lluvia y aumentar la utilidad de la información para la toma de decisiones.




Figura 20. Sección *Movimientos en masa* del reporte hidrometeorológico semanal (versión anterior basada en estaciones pluviométricas).




Figura 21. Nueva versión de la sección *Movimientos en masa* del reporte hidrometeorológico: resultados espacializados por barrios y veredas, con resumen semanal por municipios y condiciones actuales.

Cálculo de la incertidumbre del Modelo de Alertas Paralelamente, durante el mes de septiembre se avanzó en uno de los objetivos propuestos para esta vigencia: la cuantificación de la incertidumbre del modelo de alertas.

Durante el mes de agosto se realizó una revisión de literatura con el propósito de identificar metodologías científicas aplicadas a la evaluación del desempeño e incertidumbre de sistemas y modelos de alerta temprana por movimientos en masa.

Como resultado de esta búsqueda, se identificó que la metodología que mejor se ajusta a la estructura y funcionamiento del modelo de alertas actualmente operado es la propuesta por Calvello y Piciullo (2016) en el artículo titulado “Assessing the performance of regional landslide early warning models: the EDuMaP method” Calvello and Piciullo (2016).

Dicho trabajo plantea una metodología denominada EDuMaP (Event–Duration Matrix–Performance), orientada a evaluar y cuantificar la incertidumbre de modelos regionales de alerta temprana por deslizamientos a partir del análisis conjunto de los eventos de deslizamiento registrados y las alertas emitidas por el sistema en un periodo determinado.

Se decidió adoptar esta metodología para la cuantificación de la incertidumbre del modelo de alertas actualmente en operación. A continuación, se presenta una descripción general de su estructura y etapas principales:

El método EDuMaP evalúa el desempeño técnico de un modelo de alerta temprana mediante tres pasos sucesivos:

- I. **Análisis de eventos:** Se identifican y clasifican los **eventos de deslizamiento (LE)** y los **eventos de alerta (WE)** registrados en un mismo periodo temporal. Los deslizamientos se agrupan según su magnitud o densidad espacial, mientras que las alertas se agrupan según su nivel (baja, media, alta, muy alta).
- II. **Construcción de la matriz de duración:** Se genera una matriz temporal en la que cada celda representa el tiempo total durante el cual coincidieron un nivel de alerta (baja, media, alta, muy alta) y una clase de deslizamiento específicos (Eventos pequeños, intermedios y grandes). Esta matriz permite cuantificar cuánto tiempo el sistema estuvo emitiendo alertas correctas, falsas alarmas o sin alertas frente a eventos reales.
- III. **Evaluación del desempeño:** A partir de la matriz de duración se aplican criterios de clasificación y de grado de corrección, los cuales permiten identificar:
 - **Alertas Correctas (CA):** coincidencia entre alerta y evento real.
 - **Falsas alarmas (FA):** alerta sin evento asociado.
 - **Alertas omitidas (MA):** evento sin alerta emitida.
 - **Verdaderos negativos (TN):** ausencia de alerta y de evento.

Luego, se calculan indicadores estadísticos de desempeño tales como eficiencia, tasa de detección, razón de falsas alarmas y poder predictivo, entre otros.

Estos indicadores permiten cuantificar la precisión, sensibilidad y confiabilidad del modelo, y por ende, estimar su nivel de incertidumbre operacional.

En síntesis, la metodología EDuMaP ofrece un marco cuantitativo y reproducible para analizar la correspondencia temporal entre las alertas emitidas y los eventos de deslizamiento observados, permitiendo identificar de manera objetiva los aciertos, errores y omisiones del sistema, y con ello evaluar su incertidumbre y capacidad predictiva.

Referencias

- Aleotti, P. (2004). A warning system for rainfall-induced shallow failures. *Engineering Geology*, 73:247–265.
- Alvioli, M., Guzzetti, F., and Rossi, M. (2014). Scaling properties of rainfall induced landslides predicted by a physically based model. *Geomorphology*, 213:38–47.
- Aristizábal, E., Gamboa, F., and Leoz, F. (2010). Sistema de alerta temprana por movimientos en masa inducidos por lluvia para el valle de aburrá, colombia. *Revista EIA*, pages 155–169.
- Balducci, V., Guzzetti, F., Peruccacci, S., and Rossi, M. (2006). Rainfall thresholds for the initiation of landslides.
- Baum, R. L., Savage, W. Z., and Godt, J. W. (2008). Trigrs- a fortran program for transient rainfall infiltration and grid-based regional slope-stability analysis, version 2. 0. Technical report.
- Berti, M., Martina, M. L., Franceschini, S., Pignone, S., Simoni, A., and Pizziolo, M. (2012). Probabilistic rainfall thresholds for landslide occurrence using a bayesian approach. *Journal of Geophysical Research: Earth Surface*, 117.
- Brunetti, M. T., Peruccacci, S., Rossi, M., Luciani, S., Valigi, D., and Guzzetti, F. (2010). Natural hazards and earth system sciences rainfall thresholds for the possible occurrence of landslides in italy. Technical report.
- Calvello, M. and Piciullo, L. (2016). Assessing the performance of regional landslide early warning models: The edumap method. *Natural Hazards and Earth System Sciences*, 16:103–122.
- Chleborad, A. F., Baum, R. L., Godt, J. W., and Leahy, P. P. (2006). Rainfall thresholds for forecasting landslides in the seattle, washington, area-exceedance and probability.
- Crosta, G. B. and Frattini, P. (2001). Rainfall thresholds for soil slip and debris flow triggering. *Proceedings of the 2nd EGS Plinius Conference on Mediterranean Storms*, pages 463–487.
- Gariano, S. L., Brunetti, M. T., Iovine, G., Melillo, M., Peruccacci, S., Terranova, O., Vennari, C., and Guzzetti, F. (2015). Calibration and validation of rainfall thresholds for shallow landslide forecasting in sicily, southern italy. *Geomorphology*, 228:653–665.
- Gianecchini, R., Galanti, Y., and Avanzi, G. D. (2012). Critical rainfall thresholds for triggering shallow landslides in the serchio river valley (tuscany, italy). *Natural Hazards and Earth System Science*, 12:829–842.
- Guzzetti, F., Cardinali, M., Reichenbach, P., and Carrara, A. (2000). Comparing landslide maps: A case study in the upper tiber river basin, central italy. *Environmental Management*, 25:247–263.

- Guzzetti, F., Peruccacci, S., Rossi, M., and Stark, C. P. (2007). Rainfall thresholds for the initiation of landslides in central and southern europe. *Meteorology and Atmospheric Physics*, 98:239–267.
- Guzzetti, F., Peruccacci, S., Rossi, M., and Stark, C. P. (2008). The rainfall intensity-duration control of shallow landslides and debris flows: An update. *Landslides*, 5:3–17.
- Hidalgo, C. A. and Vega, J. A. (2014). Estimación de la amenaza por deslizamientos detonados por sismos y lluvia (valle de aburrá-colombia). *Revista EIA*, 11:103 – 117.
- IEWP (2005). Dedicated to reducing disasters through effective people-centred early warning systems, world conference on disaster reduction. Technical report.
- Iverson, R. M. (2000). Landslide triggering by rain infiltration. *Water Resources Research*, 36:1897–1910.
- Kirschbaum, D. B., Adler, R., Hong, Y., Hill, S., and Lerner-Lam, A. (2010). A global landslide catalog for hazard applications: method, results, and limitations. *Springer*, pages 561–575.
- Marin, R. J. and Velásquez, M. F. (2020). Influence of hydraulic properties on physically modelling slope stability and the definition of rainfall thresholds for shallow landslides. *Geomorphology*, 351:106976.
- Martelloni, G., Segoni, S., Fanti, R., and Catani, F. (2012). Rainfall thresholds for the forecasting of landslide occurrence at regional scale. *Landslides*, 9:485–495.
- Moreno, H. A., Vélez, M. V., Montoya, J. D., and Rhenals, R. (2006). La lluvia y los deslizamientos de tierra en antioquia: análisis de su ocurrencia en las escalas interanual, intraanual y diaria. *Revista EIA*, 5:59 – 69.
- Peruccacci, S., Brunetti, M. T., Gariano, S. L., Melillo, M., Rossi, M., and Guzzetti, F. (2017). Rainfall thresholds for possible landslide occurrence in italy. *Geomorphology*, 290:39–57.
- Peruccacci, S., Brunetti, M. T., Luciani, S., Vennari, C., and Guzzetti, F. (2012). Lithological and seasonal control on rainfall thresholds for the possible initiation of landslides in central italy. *Geomorphology*, 139-140:79–90.
- Petley, D. (2012). Global patterns of loss of life from landslides. *Geology*, 40:927–930.
- Piciullo, L., Calvello, M., and Cepeda, J. M. (2018). Territorial early warning systems for rainfall-induced landslides.
- Piciullo, L., Dahl, M. P., Devoli, G., Colleuille, H., and Calvello, M. (2017). Adapting the edumap method to test the performance of the norwegian early warning system for weather-induced landslides. *Natural Hazards and Earth System Sciences*, 17:817–831.
- Reichenbach, P., Cardinali, M., De, P., Guzzetti, V. F., Vita, P. D., and Guzzetti, F. (1998). Regional hydrological thresholds for landslides and floods in the tiber river basin (central italy). Technical report.
- Segoni, S., Lagomarsino, D., Fanti, R., Moretti, S., and Casagli, N. (2015). Integration of rainfall thresholds and susceptibility maps in the emilia romagna (italy) regional-scale landslide warning system. *Landslides*, 12:773–785.
- Wu, Y. M., Lan, H. X., Gao, X., Li, L. P., and Yang, Z. H. (2015). A simplified physically based coupled rainfall threshold model for triggering landslides. *Engineering Geology*, 195:63–69.