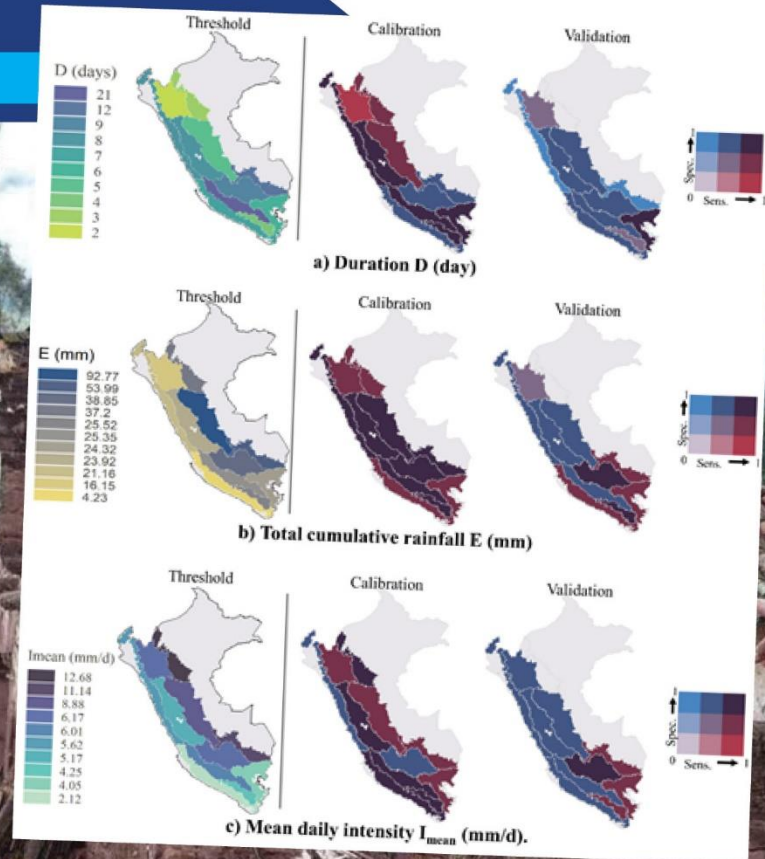


ESTIMACIÓN DE UMBRALES DE LLUVIA PARA MOVIMIENTOS EN MASA POTENCIALES A PARTIR DE DATOS DIARIOS GRILLADOS EN EL PERÚ

ESTUDIO FINAL



Citar:

Millán, C.; Lavado-Casimiro, W. y Felipe, O. (2022) *Estimación de umbrales de lluvia para movimientos en masa potenciales a partir de datos diarios grillados en el Perú.* Estudio Final. Servicio Nacional de Meteorología e Hidrología del Perú –SENAMHI. <https://repositorio.senamhi.gob.pe/handle/20.500.12542/1781>

ESTIMACIÓN DE UMBRALES DE LLUVIA PARA MOVIMIENTOS EN MASA POTENCIALES A PARTIR DE DATOS DIARIOS GRILLADOS EN EL PERÚ

ESTUDIO FINAL





DIRECTORIO

PhD. Guillermo Antonio Baigorria Paz
PRESIDENTE EJECUTIVO DEL SENAMHI

Ing. Oscar Gustavo Felipe Obando
DIRECTOR DE HIDROLOGÍA DEL SENAMHI

PhD. Waldo Sven Lavado Casimiro
SUBDIRECTOR DE ESTUDIOS E INVESTIGACIONES HIDROLÓGICAS DEL
SENAMHI

REVISORES DEL ESTUDIO

PhD. Waldo Sven Lavado Casimiro
Ing. Oscar Gustavo Felipe Obando

AUTORES

Ing. Carlos E. Millán Arancibia
PhD. Waldo Sven Lavado Casimiro
Ing. Oscar Gustavo Felipe Obando

Lima-Perú

Mayo – 2022

Contenido

Resumen.....	9
1. Introducción	9
2. Materiales y métodos	11
2.1 Dominio de estudio	12
2.2 Datos de precipitación: PISCOpd_Op	14
2.3 Datos de eventos de movimientos en masa causados por lluvias	14
2.4 Modelo de umbral de lluvia	15
2.5 Regionalización	16
2.6 Calibración y validación de umbrales	17
3. Resultados.....	19
3.1 Umbrales de precipitación de movimientos en masa	19
3.2 Impacto de la regionalización	23
3.3 Efecto de las condiciones antecedentes	25
3.4 Evaluación del desempeño de umbrales	25
4. Discusiones	26
5. Conclusiones	28
6. Referencias bibliográficas	29
Anexos	34

Contenido de figuras

Figura 1. Esquema metodológico seguido en el presente estudio	12
Figura 2. Dominio del estudio con once regiones para Perú con información de elevaciones de fondo. Además, se muestra la distribución espacial del Catálogo de Deslizamientos Global (puntos rojos) y el Inventario de Deslizamientos de SENAMHI (puntos amarillos).....	13
Figura 3. Ejemplo de determinación de Eventos de Lluvia para el escenario de Evento Entero. El escenario de Evento Antecedente es definido de la misma forma sin considerar el día que ocurrió el movimiento en masa.....	15
Figura 4. Matriz de confusión para modelos de clasificación.....	18
Figura 5. Gráfico de cajas de eventos desencadenantes (amarillo) y no desencadenantes (azul) para la lluvia acumulada total E por región para el Perú. El gráfico de cajas incluye outliers.....	22
Figura 6. Gráfico de dispersión en escala logarítmica entre la Intensidad Media vs la duración con los umbrales regionales tipo curva ($I_{mean}-D$). El fondo con puntos de colores en una escala verde-azul-negro muestra la densidad de los eventos de lluvia que no desencadenan movimientos en masa. Los eventos de lluvia que desencadenan movimientos en masa tienen el mismo color que el umbral regional.....	22
Figura 7. La primera columna muestra la distribución espacial de los umbrales de lluvias para cada variable independiente: día D (a), lluvia acumulada total E (b), intensidad media diaria I_{mean} (c) e intensidad máxima diaria I_{max} (d). Los mapas bivariados de la segunda y tercera columna muestran la distribución espacial de la sensibilidad (probabilidad de predecir correctamente los eventos de precipitación desencadenantes de movimientos en masa) y la especificidad (probabilidad de predecir correctamente los eventos de lluvia no desencadenantes de movimientos en masa) de los umbrales de Calibración (segunda columna) y Validación (tercera columna).....	24
Figura 8. Distribución espacial a escala regional del número de eventos de deslizamientos de tierra (izquierda), número de eventos de lluvia (centro) y una probabilidad (derecha) de deslizamientos de tierra que desencadenan eventos de lluvia.....	25

Contenido de tablas

Tabla 1: Resumen de productos PISCOpd y PISCOpd_Op	14
Tabla 2: Umbrales de lluvias de características independientes	20
Tabla 3: Umbrales de lluvias de dos variables.....	21
Tabla 4: Mejores umbrales de una y dos variables para cada región.....	23

Contenido de figuras en anexos

Fig. 1 Distribución de frecuencias de las áreas de las cuencas de GEOGloWS ECMWF (David et al., 2011; Qiao et al., 2019; Souffront Alcantara et al., 2019). El dominio del estudio fue discretizado en 5373 cuencas con áreas cuya mediana es de aproximadamente 105 km ²	34
Fig. 2 Diagrama de dispersión 3D de los eventos de lluvia para las 11 regiones de análisis del estudio. Los 3 ejes son Duración (días) vs Intensidad Máxima (mm/d) vs Lluvia acumulada (mm). Los colores representan cada región. Los puntos más grandes representan eventos de lluvia desencadenantes de eventos de movimientos en masa y los puntos más pequeños son eventos de lluvia no desencadenantes.	35
Fig. 3 Gráfico de cajas de las variables explicativas en el Escenario Antecedente para cada región.	36
Fig. 4 Gráfico de cajas de las variables explicativas en el Escenario Entero para cada región.	37
Fig. 5 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 1.	38
Fig. 6 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 2.	39
Fig. 7 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 3.	40
Fig. 8 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 4.	41
Fig. 9 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 5.	42
Fig. 10 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 6.	43
Fig. 11 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 7.	44
Fig. 12 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 8.	45
Fig. 13 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 9.	46
Fig. 14 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 10.	47
Fig. 15 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 11.	48

Contenido de tablas en anexos

Tabla A.1 *Características y variables analizadas de los eventos de lluvias desencadenantes de movimientos en masa.....49*

ESTIMACIÓN DE UMBRALES DE LLUVIA PARA MOVIMIENTOS EN MASA POTENCIALES A PARTIR DE DATOS DIARIOS GRILLADOS EN EL PERÚ

Resumen

El objetivo de este trabajo fue generar y evaluar umbrales de lluvia regionales obtenidos a partir de la combinación de datos de precipitación grillada de alta resolución (PISCOpd_Op) desarrollado por el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) y la información de eventos observados de movimientos en masa desencadenados por lluvias (ML) para obtener umbrales regionales de lluvia. Los datos de eventos de ML se relacionaron con las lluvias desencadenantes y no desencadenantes de estos eventos, obteniéndose propiedades de los eventos de lluvia a partir de los cuales se determinaron umbrales de lluvia. Se realizó una validación del desempeño de los umbrales con eventos ocurridos durante el año 2020 enfocado en evaluar la operatividad de estos umbrales en sistemas de alerta frente a ML en Perú. La determinación de umbrales se realizó para 11 regiones homogéneas determinados en base a las precipitaciones máximas para todo el Perú. El método de determinación de los umbrales fue bajo un enfoque empírico-estadístico; y el rendimiento predictivo de los umbrales se evaluó a partir del “True Skill Statistic” (TSS) y el Área Bajo la Curva ROC (AUC). El mejor rendimiento predictivo se obtuvo mediante la curva de umbral intensidad media-duración $I_{mean}-D$ seguido por la lluvia acumulada E . Este trabajo, es la primera aproximación de estimación de umbrales regionales a escala del Perú para entender los movimientos en masa (MM) y los resultados obtenidos serán utilizados para el monitoreo y pronóstico de MM causados por lluvias intensas para soportar las acciones de Gestión de Riesgos de Desastres.

1. Introducción

Los movimientos en masa (MM) son uno de los peligros de mayor impacto a nivel global causando víctimas y daños a propiedades públicas y privadas, y es responsables de al menos el 17 % de todas las muertes por peligros naturales en el mundo (Chae et al. 2017; Segoni, Piciullo, and Gariano 2018). De estos MM, los provocados por lluvias son los más frecuentes, responsables de víctimas y pérdidas económicas en todo el mundo (Petley 2012). En Perú, los MM son el quinto peligro natural que más emergencias han generado en los últimos 16 años (INDECI 2019), junto con las lluvias intensas, bajas temperaturas, vientos fuertes e inundaciones. Sin embargo, en el Perú aún no se ha investigado la relación de las lluvias con los MM, que considere al entorno fisiográfico y

climático del país. Por lo que conocer y entender la interrelación entre los MM y su principal desencadenante, las lluvias; ayudará a proponer herramientas útiles en el monitoreo de las zonas más propensas a MM.

Los MM encuentran en la saturación del terreno la causa primigenia para su ocurrencia, este efecto de saturación puede ocurrir de diferentes formas, por ejemplo, las lluvias intensas, deshielo, cambio en el nivel de las aguas subterráneas, y desembalse de agua en lagos, lagunas y reservorios, y un incremento del flujo en canales, quebradas y ríos. Con estas formas de saturar y alterar las condiciones de estabilidad del terreno, las lluvias es el factor más frecuente e importante para desencadenar los diferentes tipos de MM (Prenner et al. 2018; Segoni et al. 2018). Sin embargo, la máxima probabilidad de ocurrencia de MM no siempre está asociada a las condiciones extremas de las lluvias intensas y humedad del suelo, sino que también existe una influencia de las condiciones antecedentes de los días lluviosos previos a la ocurrencia de los MM (Abraham et al. 2020; Leonarduzzi, Molnar, and McArdell 2017).

Una de las técnicas usadas en el estudio de la interrelación de las lluvias como factor desencadenante de los ML es la determinación de umbrales, la cual ha sido ampliamente estudiado a nivel mundial, mediante diferentes métodos (por ejemplo, métodos empíricos, estadísticos, manuales, probabilísticos y con bases físicas) (Guzzetti et al. 2007; Segoni et al. 2014). Para los MM inducidos por lluvia, un umbral puede definirse como la lluvia, la humedad del suelo o las condiciones hidrológicas que, cuando se alcanzan o se exceden, es probable que se presente un MM. Se han desarrollado umbrales a diferentes escalas temporales (sub horario, horario, diario, mensual) y espaciales (locales, cuenca, regionales, nacionales y globales) dependiendo de la información con la que se cuenta (Segoni et al. 2018). Por ejemplo, se han desarrollado umbrales globales basados en índices de precipitación antecedente (Caine 1980; Guzzetti et al. 2008; Kirschbaum and Stanley 2018) y umbrales nacionales bajo un enfoque empírico-estadístico (Leonarduzzi et al. 2017; Peruccacci et al. 2017a; Uwhirwe, Hrachowitz, and Bogaard 2020).

Los enfoques empíricos para pronosticar la ocurrencia de ML superficiales inducidos por la lluvia dependen de la definición de los umbrales de lluvia (RTH) que se vinculen a las variables hidrometeorológicas (Gariano et al. 2015; Segoni et al. 2018). Existen una gran cantidad de variables de análisis que se podrían definir para estudiar los RTH (se reportaron hasta veintidós parámetros) (Guzzetti et al. 2007, 2008). Bajo este enfoque, cuando se dispone de información sobre eventos de lluvia que no resultaron en MM, los RTH tiene como objetivo separar los eventos de lluvia que han desencadenado MM de los aquellos eventos de lluvia que no resultaron en MM. Este enfoque empírico es ampliamente aplicado pues su análisis e implementación no requiere el monitoreo constante de otras variables físicas en los cuales se basan otros tipos de enfoque, además, esta metodología tiene la capacidad de abarcar áreas locales, regionales e incluso a escala global.

Lo umbrales pueden ser establecidos para diferentes escalas espaciales dependiendo de la extensión de análisis, los cuales se pueden categorizar en cinco clases: global,

nacional, regional, cuenca, local y a escala de ladera. Entendiéndose como escala regional a la subdivisión administrativa de una nación, que típicamente se extiende por miles de kilómetros cuadrados (Segoni et al. 2018). En el estudio de territorios nacionales, es necesario tomar en cuenta la alta variabilidad meteorológica y fisiográfica espacial del área de estudio, para obtener umbrales de lluvia más precisos y confiables. Esto se logra a través de la regionalización del área de estudio, en zonas con condiciones meteorológicas homogéneas (Segoni et al. 2014). La regionalización de las lluvias en el análisis de umbrales asociados a MM ha sido usada con diferentes enfoques, por ejemplo, se han utilizado índices de precipitación como la media anual, máxima diaria, media mensual, máxima diaria mensual de precipitación, entre otros (e.g. Augusto Filho, da Silva Júnior, and Eiras 2020; Segoni et al. 2014), la erodabilidad, y climatología representada por la intensidad máxima diaria de un evento de precipitación (Leonarduzzi et al. 2017). En este estudio nos referimos a regiones como la subdivisión del territorio peruano a partir de una variable hidroclimática.

Este estudio tiene como objetivo estimar umbrales regionales de lluvia para el monitoreo de las condiciones favorables para la ocurrencia de MM generados por lluvias a partir de uno de los subproductos derivados de la base de datos de precipitación PISCO (Aybar et al. 2020), denominada PISCO Operativo a paso diario (PISCOpd_Op) el cual es utilizado en los servicios operativos de SENAMHI. Estos umbrales se desarrollaron, en primer lugar, a través de la caracterización de los eventos de lluvias asociadas a eventos de MM desencadenados por lluvias recolectados de dos diferentes catálogos, el primero corresponde a un catálogo de eventos de MM observados y registrados por el SENAMHI y el segundo catálogo corresponde al Catálogo Global Landslides filtrado para Perú (Kirschbaum, Stanley, and Zhou 2015). Posteriormente se determinaron los umbrales para las regiones y se evaluó su rendimiento predictivo para la ocurrencia de MM potenciales en Perú. Por último, se analizó el rendimiento de estos umbrales, en un escenario que simule su incorporación en un sistema de alerta operativo, con los eventos registrados durante el año 2020, siendo este periodo, un periodo de validación de los umbrales.

2. Materiales y métodos

La metodología usada en este estudio junto con la descripción para cada paso se presenta en la Figura 1.

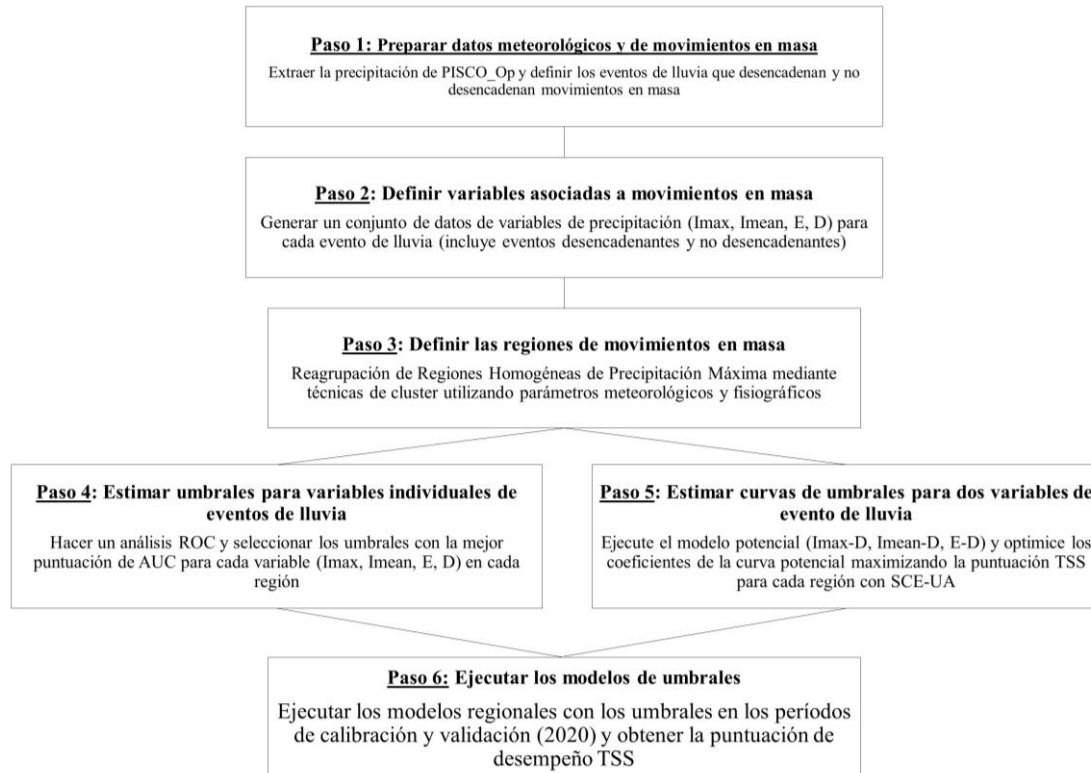


Figura 1. Esquema metodológico seguido en el presente estudio

2.1 Dominio de estudio

Este estudio adopta el dominio de estudio definido para el Sistema de Monitoreo de Movimientos en Masa Potenciales generados por Lluvias Intensas - SILVIA (Millán 2020; Millán et al. 2021) del Servicio Nacional de Meteorología e Hidrología (SENAMHI) para Perú. Este dominio fue obtenido a partir de la unión de dos bases de datos, el primero es el mapa susceptibilidad a MM del Instituto Geológico, Minero y Metalúrgico del Perú (Villacorta, Fidel, and Zavala Carrión 2012), el cual cuenta con cinco (5) categorías de susceptibilidad, para la metodología de SILVIA no se incluyeron las zonas con susceptibilidad muy baja. La segunda base de datos, fueron las cuencas usadas en el servicio de caudales GEOGloWS ECMWF (David et al. 2011; Qiao et al. 2019; Souffront Alcantara et al. 2019), a partir del cual el dominio de este estudio fue discretizado contando con 5373 cuencas con áreas cuya mediana es de aproximadamente 105 km². El área de estudio y la distribución del área de las cuencas en el área de estudio se muestra en la Figura 2.

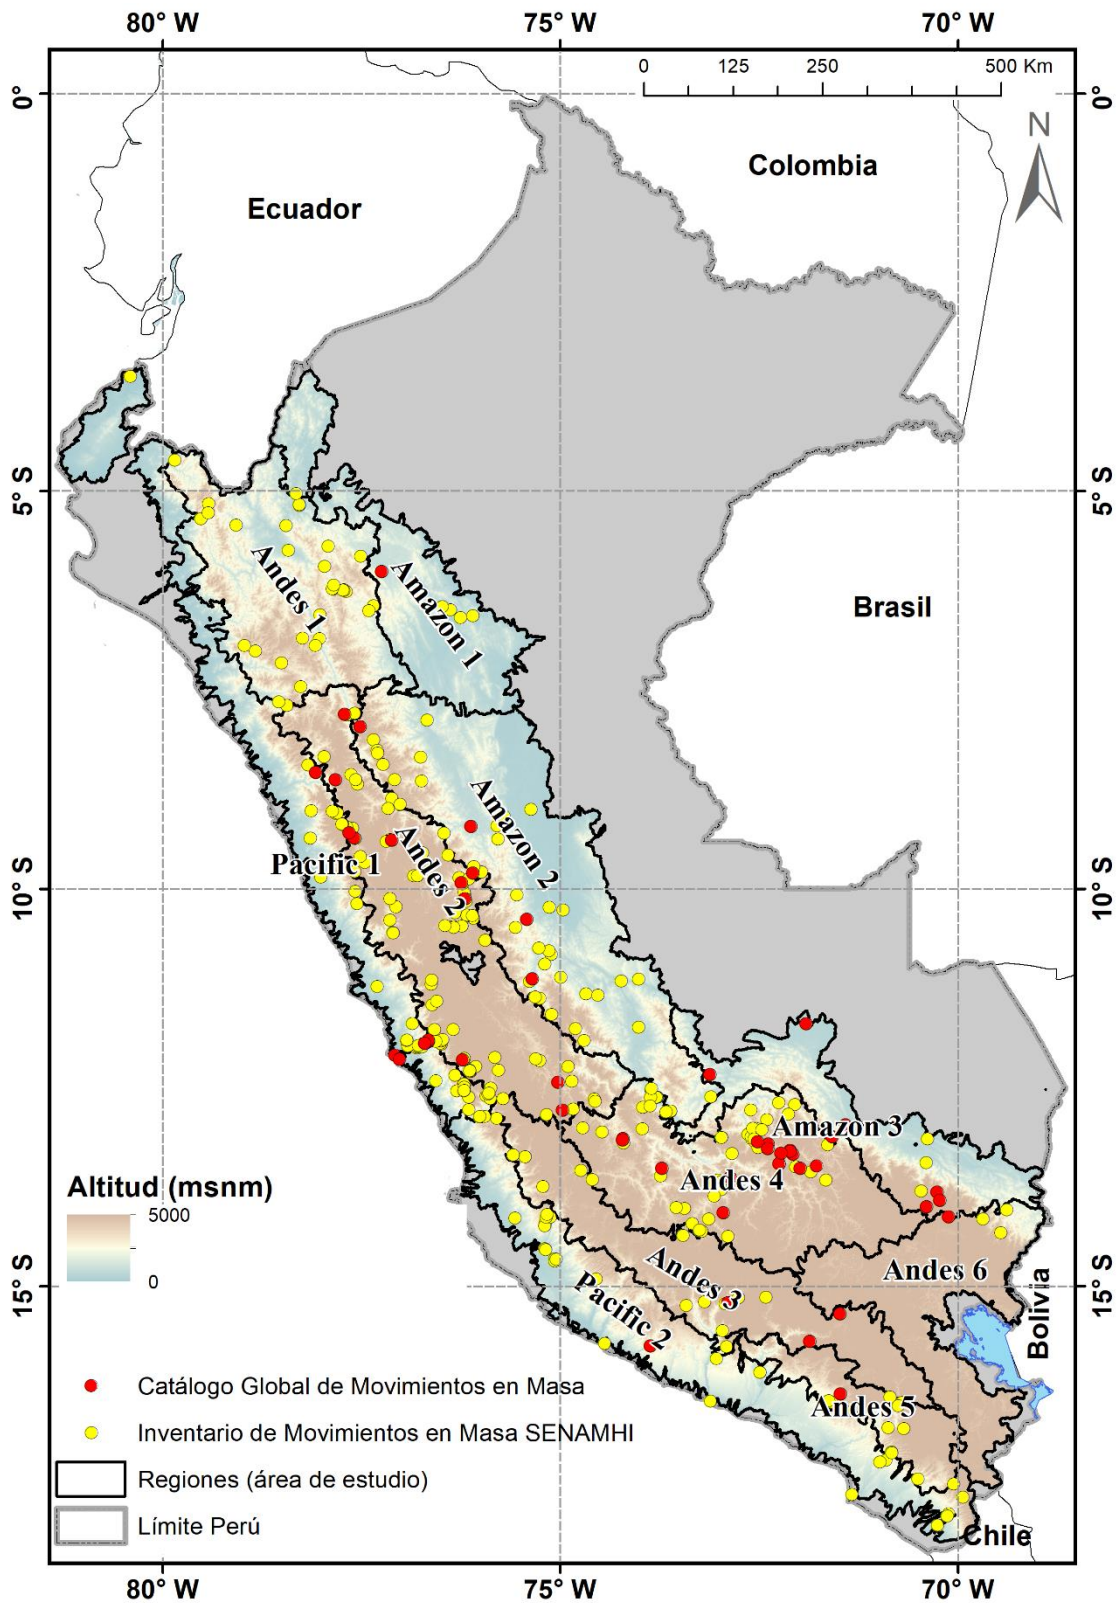


Figura 2. Dominio del estudio con once regiones para Perú con información de elevaciones de fondo. Además, se muestra la distribución espacial del Catálogo de Deslizamientos Global (puntos rojos) y el Inventario de Deslizamientos de SENAMHI (puntos amarillos).

2.2 Datos de precipitación: PISCOpd_Op

La principal fuente de información de este estudio, es la base de datos de precipitaciones diarias grillada PISCOpd_Op (Producto grillado operativo de SENAMHI de lluvia diaria). PISCOpd_Op es el conjunto de datos derivado del producto de precipitación Peruvian Interpolated data of SENAMHI's Climatological and Hydrological Observations (PISCOpd) (Aybar et al. 2020). PISCOpd_Op son datos operativos de precipitación que se estima diariamente (7 a.m. a 7 a.m.), generada a partir de la red de estaciones meteorológicas convencionales. PISCOpd_Op se ha generado en base a un método de interpolación genRE (Van Osnabrugge, Weerts, and Uijlenhoet 2017), que consiste en una interpolación mediante Distancias Inversas Ponderadas (IDW) e incluye multiplicadores que se basan en la climatología mensual de PISCOpd. Ver Tabla 1.

Tabla 1: Resumen de productos PISCOpd y PISCOpd_Op

Characteristic	PISCO _{op}	PISCOp v2.1
Paso de tiempo	Diario	Diario
Resolución espacial	10 km	10 km
Periodo	1981-actualidad	1981-2016
Dominio	Perú	Perú
Actualización	Diaria	Esporádica

2.3 Datos de eventos de movimientos en masa causados por lluvias

La otra fuente de información que se utilizó para el desarrollo de esta investigación son dos fuentes de inventarios de eventos de MM observados y recopilados: el primero es el Inventario de Movimientos en Masa Generados por Lluvias del SENAMHI (IMMS) y el segundo es el Catálogo Global de Deslizamientos de Tierra (GLC por sus siglas en inglés) de la NASA (Kirschbaum et al. 2015). Estos catálogos fueron desarrollados con el objetivo de identificar eventos de MM provocados por lluvias en el Perú y todo el mundo respectivamente. Ambos catálogos consideran todo tipo de MM provocados por la lluvia, que han sido reportados en los medios de comunicación, bases de datos de agencias asociadas a desastres, informes científicos u otras fuentes disponibles.

El IMMS cuenta con 330 registros hasta el 2020, que se distribuyen durante el período 2018-2020. Cabe resaltar que este inventario fue implementado desde enero de 2019. Por lo que estos años tienen un mayor grado de certidumbre en la cantidad de eventos registrados, clave para los análisis del estudio. El GLC cuenta con 6788 registros para todo el mundo, mientras que para Perú se ha registrado 53 eventos de MM, los cuales están distribuidos temporalmente entre 2007 y 2014. Para el uso de estos datos, se realizaron análisis exploratorios para evitar incoherencias en el registro de los eventos. Se evaluó la correspondencia espacial de los datos a través de un análisis geoespacial de los puntos y las áreas de dominio del estudio para Perú, posteriormente se excluyó y/o corrigió la información de registro. También se evaluó la coherencia de los datos debido a errores antropogénicos. Como resultado se determinó dos eventos incongruentes, el primero debido a que se reportaba en un lugar sin condiciones de ocurrencia de MM, el cual no se consideró en el análisis y el segundo evento, se

determinó un error en su tabulación espacial el cual fue corregido e incluido en el análisis. La distribución espacial de los eventos se observa en la Figura 2.

2.4 Modelo de umbral de lluvia

Para definir los umbrales de lluvia para las zonas susceptibles a MM, se empleó un enfoque empírico-estadístico que consistió en los siguientes pasos: (1) la determinación de eventos de lluvia a partir de series históricas de precipitación, (2) la definición de variables de los eventos de lluvias, (3) la identificación de eventos que desencadenaron movimientos en masa y los que no desencadenaron; y (4) la calibración de umbrales para las propiedades de los eventos de lluvia basados en la maximización objetiva del rendimiento predictivo. A continuación, se presentan los detalles de los umbrales.

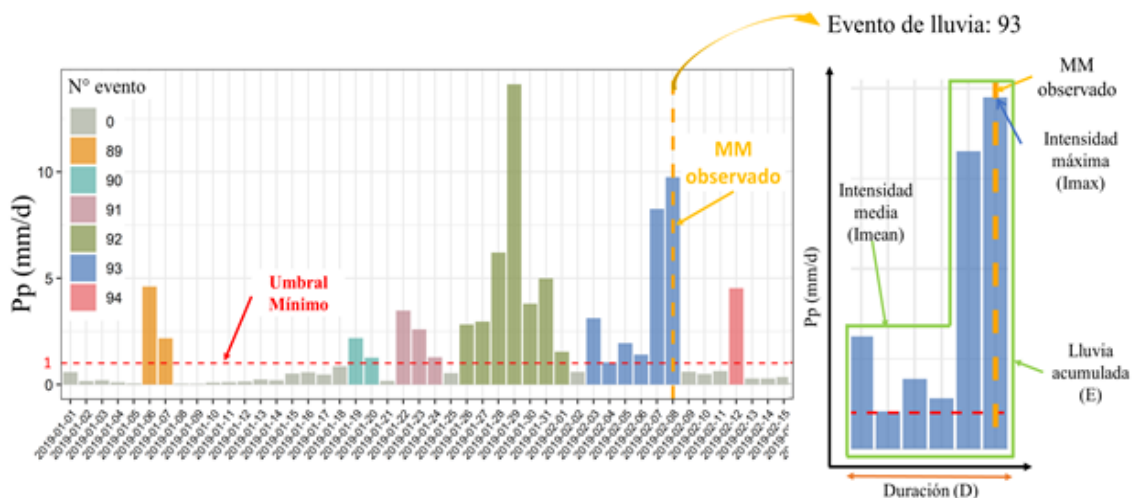


Figura 3. Ejemplo de determinación de Eventos de Lluvia para el escenario de Evento Entero. El escenario de Evento Antecedente es definido de la misma forma sin considerar el día que ocurrió el movimiento en masa.

El primer paso es construir la serie histórica de precipitación para cada cuenca que cuenta con por lo menos un evento de movimiento en masa dentro del dominio de estudio a partir de los datos de lluvia grillada. Luego se determina eventos de lluvia a partir de dicha serie para cada cuenca incluida en el análisis. Para este trabajo definimos un evento independiente de lluvia como una serie consecutiva de días lluviosos en donde ha llovido por encima de un umbral mínimo de lluvia (Fig. 3). Diversidad de autores usaron umbrales mínimos de 1 mm para discriminar días lluviosos (Dai 2006; Dai, Lin, and Hsu 2007; Han et al. 2016; Leonarduzzi et al. 2017; Shen et al. 2021; Tian et al. 2007; Yong et al. 2010). Sin embargo, dada la gran variabilidad espacial climatológica en el dominio de estudio, no se consideró tener un solo umbral mínimo para todo el territorio, sino que este umbral mínimo se determinó a partir del sesgo de días no lluviosos de PISCOpd_Op, es decir que se determinó la diferencia del producto PISCOpd_Op cuando las estaciones pluviométricas terrestres reportaban un valor 0 de lluvia, y se definió el umbral mínimo (U_{min}) de lluvia especializado para el dominio de estudio según la siguiente Eq. (1):

$$U_{min} = \{1 \text{ si } s < 1 \text{ s si } s > 1 \text{ ,} \quad (1)$$

Donde s es promedio del sesgo simple cuando las estaciones pluviométricas reportaban un valor 0 de lluvia en comparación con lo estimado en PISCOpd_Op. Para las regiones costeras, se consideró 0.5 mm como el umbral mínimo de lluvia.

Una vez definido el evento de lluvia, se estableció si son eventos desencadenantes o no desencadenantes. Se considera un evento desencadenante si está asociada a un evento de movimiento en masa registrado. Para cada evento de lluvia se calcularon la intensidad diaria máxima I_{max} [mm/d], la precipitación acumulada E [mm], la duración D [d] y la intensidad diaria media $I_{med} = E/D$ [mm/d] (Leonarduzzi et al. 2017). Con respecto a los eventos desencadenantes, se consideraron dos escenarios, para el primer escenario (evento entero) se definen las propiedades del evento de lluvia completo es decir incluye la tasa de precipitación del día de ocurrencia del MM. El segundo escenario (evento antecedente) define las propiedades hasta un día antes de la ocurrencia, es decir no considera la tasa de precipitación del día de ocurrencia. El motivo de investigar el segundo escenario es evaluar el nivel de incidencia que se le atribuye a solo las condiciones antecedentes para la ocurrencia de los MM, esto permite evaluar si es posible pronosticar o alertar de posibles MM en base a solo a las condiciones antecedentes.

El segundo paso consiste en seleccionar objetivamente un umbral de lluvia que separe los eventos de lluvia desencadenantes de los que no son desencadenantes, con el mejor nivel de rendimiento predictivo. Los umbrales de lluvia se establecieron maximizando el rendimiento predictivo de dos maneras, la primera solo incluyó las variables independientes de las propiedades de la lluvia (I_{max} , E , D , I_{med}) y la segunda fue a través de umbrales tipo curva que relacionaran dos propiedades ($I_{max}-D$, $E-D$, $I_{med}-D$) en la forma Eq. (2):

$$V = a \cdot D^{-b}, \quad (2)$$

donde V representa las variables I_{max} , E y I_{med} , a es el parámetro de intersección o factor de escala y b es la pendiente de la curva potencial o parámetro de forma.

2.5 Regionalización

Debido a que el dominio de estudio es a escala nacional, es necesario considerar la alta variabilidad meteorológica y fisiográfica espacial gobernante para obtener umbrales de lluvia más confiables, ya que un solo umbral global o nacional no puede representar dicha variabilidad. Para lograr obtener umbrales de lluvia a escala nacional, el enfoque utilizado es a través de la regionalización del área de estudio, en zonas con condiciones meteorológicas homogéneas (Segoni et al. 2014). Para la regionalización de las lluvias en el análisis de umbrales asociados a MM se han utilizado como base de información índices de precipitación como la media anual, máxima diaria, media mensual, máxima diaria mensual de precipitación, entre otros (e.g. Augusto Filho et al. 2020; Segoni et al. 2014), la erodabilidad y la climatología representada por la intensidad máxima diaria de un evento de precipitación (Leonarduzzi et al. 2017).

En esta investigación es de interés analizar las lluvias como factor desencadenante, pues es el factor más frecuente y más importante para desencadenar los MM superficiales. Al tener las lluvias una gran variabilidad espacio-temporal, además que las lluvias antecedentes proporcionan información acerca de las condiciones de estabilidad del terreno asociadas a la humedad del suelo. Estas precipitaciones desencadenantes pueden originarse por lluvias de larga duración o tormentas de corta duración. Por lo que la evolución temporal de las variables hidrometeorológicas proporciona una idea de cómo se desarrollan las condiciones críticas de activación de estos eventos (Prenner et al. 2018; Segoni et al. 2018).

En este estudio se utiliza las Regiones Homogéneas de Precipitación Máxima del SENAMHI determinadas por Tupac et al. (2017) y actualizadas por Montesinos et al. (2020) como insumo para la regionalización del área de estudio. Estas regiones se determinaron basado en técnicas de “clustering” a partir de la información de precipitación de 535 estaciones automáticas. En la cual nativamente se identificaron 10 macrorregiones y 30 subregiones de precipitación máxima. Las regiones climáticas establecidas para el presente estudio, consistió en un agrupamiento de las 30 regiones de precipitación máximas. El reagrupamiento consistió en un análisis multicriterio basado principalmente en que las regiones agrupadas no superen un umbral del valor 10 en el test de heterogeneidad (Hosking and Wallis 1997), que incluyeran eventos registrados en las bases de datos además de compartir similitud de las covariables de relieve (altitud) y climatología (precipitación media). Si bien es cierto que este valor de 10 supera el nivel de heterogeneidad recomendados en 2, se contempla esta tolerancia pues se tratan de regiones obtenidas de un reagrupamiento. A partir de este análisis, se obtuvo 11 regiones para el área de estudio, ver Figura 2. Se definieron 4 umbrales de variables independientes (I_{max} , E , D , I_{med}) y 3 umbrales curva (I_{max-D} , $E-D$, I_{med-D}) para cada región. Siendo el total de 7 umbrales para cada región.

2.6 Calibración y validación de umbrales

La calibración y validación es un proceso fundamental para definir de forma objetiva los umbrales. La calibración tiene como finalidad la estimación de umbrales a partir de la maximización de la capacidad del rendimiento predictivo o clasificador del modelo de umbral analizado. Y la validación, tiene como finalidad mostrar el potencial de la capacidad de predicción o de diferenciar aquellos eventos de lluvias desencadenantes. Entre los enfoques de calibración y validación, se tiene que el más recomendado es dividir los conjuntos de datos para la estimación de umbrales y otro conjunto independiente para la validación (Segoni et al. 2018). En este trabajo, se utilizaron los 273 eventos de MM registrados para calibrar y validar los umbrales de lluvia en Perú.

Para la evaluación del modelo de umbral, se utilizó la matriz de confusión o tabla de contingencia, el cual es una herramienta para determinar la precisión de modelos de clasificación binaria (eventos de lluvias desencadenantes y no desencadenantes) y evaluar el análisis de concordancia entre los resultados del modelo y los datos observados. A partir del cual se determina la cantidad de acierto verdaderos o

verdaderos positivos (TP), la cantidad de falsos positivos (FP), la cantidad de verdaderos negativos (TN) y la cantidad de falsos negativos (FN) (Figura 4).

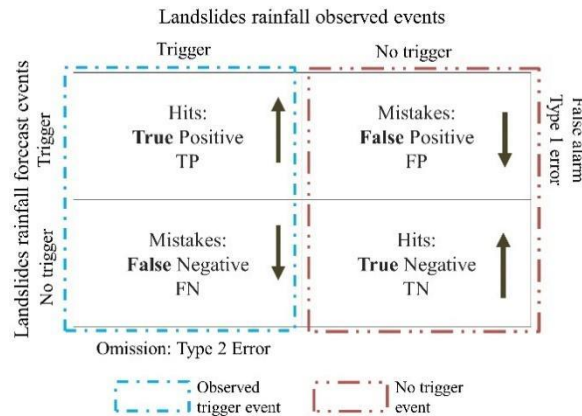


Figura 4. Matriz de confusión para modelos de clasificación

Con respecto a la calibración, se seleccionaron todos los eventos ocurridos antes del 2020, lo que representa alrededor del 70% (71.2%) de los eventos registrados. Para la elección de umbrales de una sola variable (I_{max} , E , D , I_{med}), se realizó un análisis mediante la curva característica operativa del receptor (ROC) para seleccionar las variables en función de su desempeño (Fawcett 2006), esto se realizó entre la tasa de verdaderos positivos ($TPR = s_e$) y la tasa de falsos positivos ($FPR = 1 - s_p$). Esta técnica es una de las técnicas más usadas para medir el rendimiento de modelos de umbrales de lluvia (Abraham et al. 2020; Gariano et al. 2015; Leonarduzzi et al. 2017).

La impresión general del poder predictivo de cada variable se estimó con el área bajo la curva ROC (AUC), y el umbral seleccionado es aquel valor que maximice el estadístico *True skill statistics* (TSS). TSS es también conocido como Puntaje de habilidad de Peirce (Peirce 1884), Índice de Youden (Youden 1950) o Hanssen and Kuipers (Hanssen and Kuipers 1965). TSS es un estadístico de eficiencia que ayuda en la medición de bondad de modelos de umbrales, pues es una medida integradora del rendimiento predictivo del modelo. TSS es más objetivo que simplemente una estimación manual aleatoria (Fratini, Crosta, and Carrara 2010). Varía entre 1 y -1, siendo su puntaje óptimo igual a 1, el cual indica un rendimiento máximo del modelo. TSS se define en la siguiente Eq. (3):

$$TSS = TPR - FPR = s_e - (1 - s_p), \tag{3}$$

donde el TSS se puede expresar en términos de la sensibilidad s_e y especificidad s_p , pues lo que busca el TSS es maximizar la tasa verdaderos acierto (s_e) y la tasa de verdaderos negativos (s_p). s_e y s_p se definen según las ecuaciones Eq. (4) y Eq. (5):

$$s_e = \frac{TP}{TP+FN}, \tag{4}$$

$$s_p = \frac{VN}{TN+FP}, \tag{5}$$

Donde TP, FN, TN y FP se definen a partir de la matriz de confusión.

La elección de umbrales de dos variables (curvas I_{max-D} , I_{med-D}), se realizó al determinar el mejor rendimiento mediante la optimización de la función objetivo que maximice el TSS para cada umbral propuesto. Los parámetros a y b se calibraron automáticamente utilizando el algoritmo evolutivo de complejo barajado (SCEA-UA) (Duan, Gupta, and Sorooshian 1993), considerando el TSS como la función objetivo.

Esto se realizó para cada región dentro del área de análisis, encontrándose diferentes umbrales para cada una de ellas. El proceso de validación de los umbrales consistió en evaluar los umbrales para los eventos de movimientos en masa registrados en el año 2020, los cuales representan alrededor del 30% (28.8%) de los eventos registrados. Se realizó este proceso para el año 2020, pues se deseaba conocer cómo sería el desempeño de los umbrales cuando se asimilen a un sistema de alerta temprana regional. Ya que el valor del TSS varía entre 0 y 1, se considera que rendimientos por encima de 0.4 son medidas buenas a aceptables de los umbrales y valores por encima de 0.7 se considera como muy buenos rendimientos.

3. Resultados

3.1 Umbrales de precipitación de movimientos en masa

Los umbrales calibrados, para las propiedades individuales de los eventos (E , I_{max} , I_{mean}) se muestran en la Tabla 2 y los umbrales curva (I_{max-D} , I_{mean-D} , $E-D$) se muestran en la Tabla 3. Se presentan para dos escenarios, el primero describe los eventos de lluvia que incluyen el mismo día de ocurrencia del MM, denominado Entire Event (EE) y el segundo que solo incluye las condiciones antecedentes hasta un día antes de la ocurrencia de MM, denominado Antecedent Event (AE), esto dado que se tiene el interés de analizar eventos de MM bajo un enfoque que incluya la capacidad predictora de las condiciones antecedentes y su influencia en la ocurrencia de eventos futuros para la operatividad de servicios de avisos de alerta temprana.

A partir de los resultados se observa que los umbrales con mejores rendimientos promedios para los eventos enteros fueron E (TSS = 0,59) para las Propiedades Individuales y I_{mean-D} (TSS=0.65) para las Curvas Combinadas. La Figura 5 muestra el diagrama de cajas de la Lluvia Acumulada E que muestra su poder predictivo para discriminar eventos de lluvias desencadenantes y no desencadenantes. Según lo esperado, la integración de propiedades en curvas produjo un mejor rendimiento general en comparación con las propiedades de eventos individuales. De las tres curvas (I_{max-D} , I_{mean-D} , $E-D$), la que mejor desempeño tuvo fue la curva I_{mean-D} (Figura 6), con un TSS=0.65 para la calibración y TSS=0.42 para la validación.

Tabla 2: Umbrales de lluvias de características independientes

Escenario	Región	E [mm]				I_mean [mm/d]				Imax [mm/d]				D [d]			
		Umbral	AUC	TSS		Umbral	AUC	TSS		Umbral	AUC	TSS		Umbral	AUC	TSS	
				Cal	Val			Cal	Val			Cal	Val.			cal	Val.
Evento Entero	Pacific 1	21.16	0.85	0.66	0.20	5.62	0.81	0.54	0.60	10.11	0.85	0.68	0.58	8	0.80	0.56	-0.09
	Pacific 2	4.23	0.76	0.44	0.39	2.12	0.83	0.61	0.20	4.55	0.80	0.51	0.27	7	0.61	0.30	0.39
	Andes 1	16.15	0.64	0.39	0.12	6.20	0.70	0.43	0.18	11.84	0.69	0.38	0.23	2	0.57	0.19	-0.16
	Andes 2	23.92	0.86	0.58	0.41	5.17	0.80	0.51	0.28	8.59	0.84	0.58	0.47	8	0.82	0.54	0.33
	Andes 3	25.35	0.94	0.78	0.41	6.01	0.93	0.83	0.22	16.72	0.97	0.92	0.34	21	0.88	0.69	0.28
	Andes 4	38.85	0.78	0.51	0.61	6.17	0.74	0.45	0.61	8.44	0.75	0.43	0.69	9	0.77	0.45	0.33
	Andes 5	25.52	0.81	0.67	0.39	4.25	0.69	0.52	0.37	9.75	0.76	0.61	0.51	4	0.82	0.54	0.03
	Andes 6	24.32	0.78	0.64	0.66	4.05	0.50	0.40	0.44	5.56	0.57	0.45	0.46	6	0.84	0.68	0.69
	Amazon 1	37.20	0.79	0.64	-	12.68	0.85	0.74	-	20.73	0.85	0.66	-	3	0.64	0.29	-
	Amazon 2	92.77	0.84	0.57	0.52	8.88	0.73	0.41	0.34	16.15	0.80	0.46	0.38	5	0.83	0.51	0.37
Amazon 3	53.99	0.82	0.68	0.66	11.14	0.69	0.41	0.39	17.74	0.72	0.52	0.55	12	0.70	0.44	-0.10	
Evento Antecedente	Pacific 1	19.01	0.86	0.63	0.35	4.87	0.80	0.51	0.90	10.11	0.84	0.65	0.91	7	0.82	0.60	-0.11
	Pacific 2	18.60	0.71	0.53	-0.17	2.98	0.71	0.43	-0.21	10.56	0.71	0.43	-0.11	6	0.67	0.49	0.55
	Andes 1	7.57	0.56	0.14	0.42	5.70	0.67	0.35	0.63	7.57	0.63	0.30	0.57	7	0.48	0.04	-0.11
	Andes 2	40.03	0.85	0.59	0.42	5.26	0.80	0.51	0.30	9.74	0.84	0.59	0.33	7	0.81	0.54	0.38
	Andes 3	127.47	0.90	0.69	0.53	6.08	0.89	0.55	0.33	16.72	0.94	0.77	0.44	20	0.83	0.69	0.34
	Andes 4	31.73	0.80	0.53	0.57	5.77	0.77	0.51	0.59	8.44	0.78	0.50	0.60	9	0.78	0.46	0.24
	Andes 5	15.77	0.74	0.57	0.32	2.22	0.70	0.43	0.28	8.25	0.76	0.57	0.31	3	0.71	0.44	0.01
	Andes 6	18.76	0.74	0.55	0.60	3.75	0.47	-0.14	0.41	4.75	0.50	0.33	0.44	5	0.81	0.61	0.67
	Amazon 1	70.79	0.62	0.31	-	10.18	0.67	0.32	-	13.26	0.67	0.34	-	15	0.50	0.14	-
	Amazon 2	175.88	0.84	0.53	0.64	8.81	0.72	0.44	0.40	16.15	0.79	0.48	0.45	17	0.83	0.51	0.47
Amazon 3	137.64	0.66	0.35	0.30	11.05	0.63	0.41	0.39	16.90	0.62	0.51	0.53	11	0.56	0.10	-0.10	

Tabla 3: Umbrales de Lluvias de dos variables

Escenario	Región	I_{mean} (mm) - D (d)				I_{max} (mm) - D (d)				E (mm) - D (d)			
		Umbral		TSS		Umbral		TSS		Umbral		TSS	
		a	b	Cal	Val	a	b	Cal	Val	a	b	Cal	Val
Evento Entero	Pacific 1	11.55	-0.437	0.68	0.26	16.73	-0.17	0.71	0.28	27.92	-0.16	0.66	0.21
	Pacific 2	2.10	-0.002	0.61	0.20	4.58	-0.0043	0.51	0.27	4.54	-0.10	0.44	0.38
	Andes 1	7.34	-0.103	0.44	0.19	20.97	-0.98	0.36	0.09	18.30	-0.13	0.39	0.11
	Andes 2	14.28	-0.531	0.62	0.28	13.62	-0.17	0.64	0.34	150.75	-0.59	0.57	0.34
	Andes 3	10.84	-0.254	0.89	0.33	16.77	-0.01	0.91	0.34	27.47	-0.12	0.77	0.57
	Andes 4	25.69	-0.814	0.52	0.68	44.51	-0.66	0.49	0.70	132.84	-0.56	0.48	0.61
	Andes 5	16.68	-0.765	0.66	0.39	15.08	-0.25	0.64	0.38	45.36	-0.41	0.66	0.26
	Andes 6	16.93	-0.809	0.62	0.63	19.25	-0.69	0.56	0.63	117.52	-0.90	0.65	0.67
	Amazon 1	14.25	-0.047	0.77	-	20.91	-0.02	0.66	-	37.89	-0.03	0.64	-
	Amazon 2	42.06	-0.540	0.57	0.53	66.35	-0.56	0.57	0.48	206.71	-0.73	0.58	0.44
Amazon 3	36.74	-0.445	0.73	0.68	49.54	-0.42	0.73	0.70	54.10	0.00	0.68	0.66	
Evento Antecedente	Pacific 1	8.50	-0.500	0.68	0.84	18.60	-0.28	0.67	0.44	156.39	-0.67	0.67	-0.06
	Pacific 2	14.85	-0.876	0.53	-0.17	25.15	-0.3111	0.47	-0.08	34.46	-0.37	0.53	0.19
	Andes 1	6.45	-0.078	0.36	0.66	7.52	0.00	0.30	0.56	9.21	-0.03	0.18	0.46
	Andes 2	11.54	-0.389	0.65	0.39	19.37	-0.54	0.60	0.43	113.10	-0.53	0.58	0.31
	Andes 3	13.98	-0.264	0.80	0.48	16.01	-0.49	0.73	0.48	387.59	-0.37	0.69	0.54
	Andes 4	19.29	-0.724	0.56	0.66	34.81	-0.69	0.51	0.66	31.59	-0.0012	0.53	0.57
	Andes 5	8.59	-0.631	0.53	0.41	23.61	-0.66	0.62	0.22	45.51	-0.67	0.60	0.06
	Andes 6	16.39	-0.923	0.55	0.59	18.54	-0.89	0.51	0.57	83.96	-0.93	0.61	0.64
	Amazon 1	51.63	-0.562	0.43	-	49.46	-0.17	0.37	-	69.73	0.00	0.30	-
	Amazon 2	22.41	-0.418	0.53	0.51	33.70	-0.32	0.54	0.49	388.25	-0.30	0.53	0.64
Amazon 3	16.81	-0.136	0.55	0.55	16.83	-0.01	0.50	0.53	485.20	-0.53	0.39	0.35	

Los resultados muestran que los componentes con menor rendimiento para la determinación de umbrales fueron la duración (D) tanto para el periodo de calibración como para la validación, seguida por la tasa promedio de lluvia (I_{mean}). En el caso de las curvas combinadas, se observa una menor diferencia en sus rendimientos, siendo la $E-D$ la de menor rendimiento. Estos umbrales no tienen una buena capacidad de discriminar eventos de lluvia desencadenantes en MM y no desencadenantes.




Figura 5. Gráfico de cajas de eventos desencadenantes (amarillo) y no desencadenantes (azul) para la lluvia acumulada total E por región para el Perú. El gráfico de cajas incluye outliers.




Figura 6. Gráfico de dispersión en escala logarítmica entre la Intensidad Media vs la duración con los umbrales regionales tipo curva (I_{mean}-D). El fondo con puntos de colores en una escala verde-azul-negro muestra la densidad de los eventos de lluvia que no desencadenan movimientos en masa. Los eventos de lluvia que desencadenan movimientos en masa tienen el mismo color que el umbral regional.

3.2 Impacto de la regionalización

Los resultados estimados evidencian la variabilidad pluviométrica de Perú en las magnitudes de los umbrales para cada región como se presentan en la Tabla 2. A nivel regional, el umbral con mejor rendimiento de una sola variable, lluvia acumulada E , tiene un promedio de 33 mm, que varía entre 4.23 mm (región Pacific 2) y 92.77 mm (región Amazon 2). I_{max} varía entre 4.55 mm/d (región Pacific 2) a 20.73 mm/d (región Amazon 1) con una media de 11.83 mm/d. La región con mejor desempeño predictivo fue Andes 3 con un TSS_{ind} de 0.84 y TSS_{com} de 0.9, el umbral con mejor desempeño para esta región fue $I_{max} = 16.72$ mm/d ($TSS = 0.92$) que separó correctamente el 100 % de los MM y solo tuvo una tasa de 8% de falsas alarmas. De igual forma la curva I_{max} -D ($TSS = 0.91$) separó correctamente el 100 % de los MM y solo tuvo un 9 % de falsas alarmas. Un resumen de los mejores umbrales de una sola variable o tipo curva para cada región se presentan en la Tabla 4.

Tabla 4: Mejores umbrales de una y dos variables para cada región

Region	Better Thresh. 1 variable	TSS	Better Thresh. 2 variables	TSS
Pacific 1	I_{max} [mm/d]	0.68	I_{max} [mm]-D [d]	0.71
Pacific 2	I_{mean} [mm/d]	0.61	I_{mean} [mm]-D [d]	0.61
Andes 1	I_{mean} [mm/d]	0.43	I_{mean} [mm]-D [d]	0.44
Andes 2	E [mm] / I_{mean} [mm/d]	0.58	I_{max} [mm]-D [d]	0.64
Andes 3	I_{max} [mm/d]	0.92	I_{max} [mm]-D [d]	0.91
Andes 4	E [mm]	0.51	I_{mean} [mm]-D [d]	0.52
Andes 5	E [mm]	0.67	I_{mean} [mm]-D [d] & E [mm]-D [d]	0.66
Andes 6	D [d]	0.68	E [mm]-D [d]	0.65
Amazon 1	I_{mean} [mm/d]	0.74	I_{mean} [mm]-D [d]	0.77
Amazon 2	E [mm]	0.57	E [mm]-D [d]	0.58
Amazon 3	E [mm]	0.68	I_{mean} [mm]-D [d] & I_{max} [mm]-D [d]	0.73

La regionalización logra obtener una mejor separación de las distribuciones desencadenantes y no desencadenantes. Los resultados para los umbrales de una sola variable se presentan de forma espacializada en la Figura 7. Los umbrales calibrados tienen un mejor rendimiento de forma general en las zonas de los Andes 3 ($TSS = 0.83$) a diferencia de la región Andes 1 ($TSS = 0.4$), Andes 4 ($TSS = 0.47$) y Amazon 1 ($TSS = 0.5$) que son las regiones con menor rendimiento. De hecho, la mayoría de los movimientos en masa registrados ocurrieron en la región de los Andes 3 (Figura 8). Con respecto a las dos regiones del Pacífico, la región Pacific 1 ($TSS = 0.66$) tiene un mejor rendimiento que la del Pacific 2 ($TSS = 0.51$). En las regiones más húmedas de la amazonia, la región Amazon 1 fue la de mejor rendimiento, seguido por las regiones Amazon 3 y Amazon 2. Esta región Amazónica y la región altiplánica (Andes 6) fueron las regiones con menos eventos de calibración.

Los resultados no muestran que alguna vertiente se resalte en poder separar eventos de lluvia desencadenantes de los que no son desencadenantes, por el contrario, hay regiones con buen desempeño y regular desempeño a lo largo del Pacífico, Andes y Amazonas. Las regiones Andes 6 (3 eventos de MM), Amazon 1 (6 eventos) y Amazon

3 (8 eventos), son las que tuvieron menor cantidad de eventos para la calibración y validación, las demás regiones incluyeron más de 10 eventos (Figura 8), resaltando las regiones Andes 2 (63 eventos), Andes 4 (58 eventos) y Amazon 2 (46 eventos).

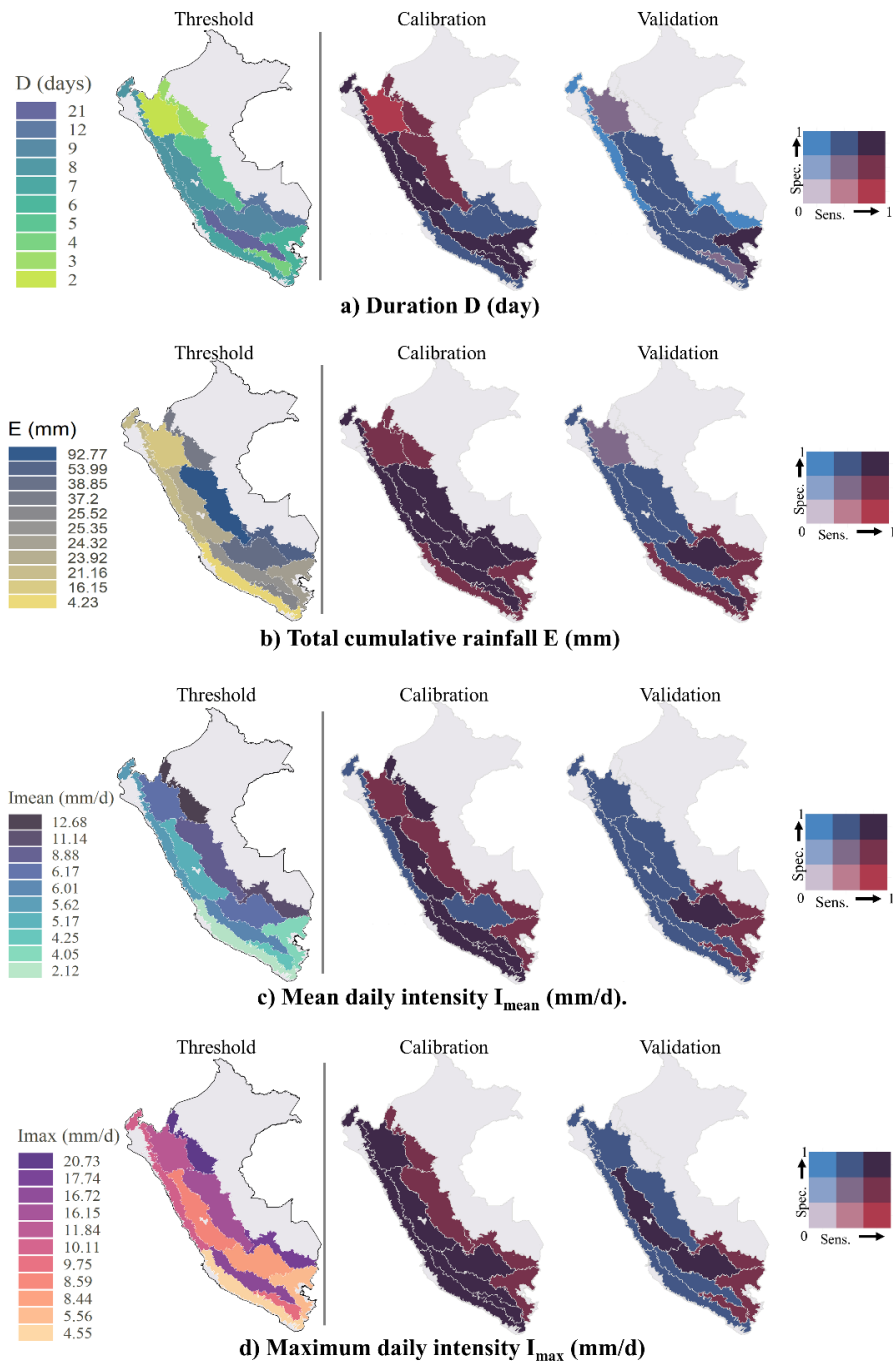


Figura 7. La primera columna muestra la distribución espacial de los umbrales de lluvias para cada variable independiente: día D (a), lluvia acumulada total E (b), intensidad media diaria I_{mean} (c) e intensidad máxima diaria I_{max} (d). Los mapas bivariados de la segunda y tercera columna muestran la distribución espacial de la sensibilidad (probabilidad de predecir correctamente los eventos de precipitación desencadenantes de movimientos en masa) y la especificidad (probabilidad de predecir correctamente los eventos de lluvia no desencadenantes de movimientos en masa) de los umbrales de Calibración (segunda columna) y Validación (tercera columna).

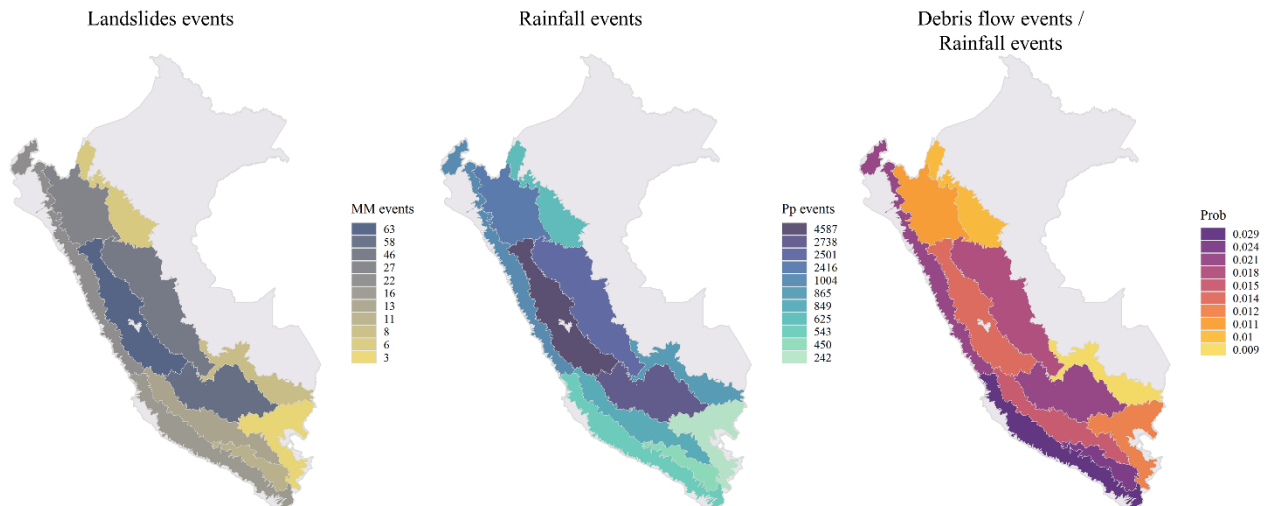


Figura 8. Distribución espacial a escala regional del número de eventos de deslizamientos de tierra (izquierda), número de eventos de lluvia (centro) y una probabilidad (derecha) de deslizamientos de tierra que desencadenan eventos de lluvia.

3.3 Efecto de las condiciones antecedentes

Es conocido que las condiciones antecedentes del terreno juegan un rol importante en la ocurrencia de lo MM y sobre todo en su magnitud, esta es la razón por la cual se analizó este escenario, que incluya la separación de eventos de lluvia que solo consideran la tasa de lluvia hasta un día previo del día de ocurrencia. Se observa que, en la fase de calibración, el escenario de condiciones antecedentes (antecedent event) obtuvo rendimientos menores que el escenario de eventos enteros. Sin embargo, en la etapa de validación para el año 2020, se observó que para algunos umbrales de forma aislada su rendimiento fue superior, por ejemplo para la región Pacific 1, los umbrales I_{max} e I_{mean} obtuvieron rendimientos superiores que el escenario de evento entero (incluyendo la tasa de precipitación del día del evento de MM), esto significa que días previos al día de ocurrencia hubo un día con una lluvia intensa mayor al del día de ocurrencia que permite separar ese evento como evento desencadenante y además de alterar la tasa de lluvia promedio asociada a dicho evento.

3.4 Evaluación del desempeño de umbrales

La validación se realizó para los eventos ocurridos el año 2020 simulando la operatividad de los umbrales calibrados en un sistema de alerta regional. La región Amazon 1 no contempla eventos de MM para este año por lo que no entro en esta evaluación. A partir de esta evaluación se observó que en la mayoría de las regiones y umbrales hay un claro decremento de los mismos. Por ejemplo, el umbral I_{max} , que obtuvo el mejor rendimiento en la calibración decreció para este periodo, a excepción de las regiones Andes 4, Andes 6 y Amazon 3 que mejoraron en esta validación; esto significa que el umbral permitió separar los eventos de lluvias del 2020 mejor de lo que se esperaba en la calibración.

La variable D se confirma que es, por si sola, un mal umbral separador de eventos de lluvia desencadenantes de los que no lo son, incluso teniendo rendimientos negativos

(Pacific 1, Andes 1 y Amazon 3), esta negatividad está asociada a que la sensibilidad (correcta predicción de movimientos en masa) del modelo para estas regiones es 0 es decir que el umbral estimado en la calibración no ha sido capaz de separar los eventos de lluvias. Sin embargo, esta variable muestra que podemos asociar los movimientos en masa a eventos de lluvia continua con una duración antecedente de 8 días.

Con respecto a este periodo de validación, se utilizaron 61 eventos en total, por lo que el estadístico TSS es más sensible, principalmente debido a la creciente sensibilidad del modelo (es decir, la probabilidad de predecir correctamente los eventos de lluvia desencadenantes de MM), mientras que la especificidad se mantuvo aproximadamente igual (es decir, la probabilidad de predecir correctamente los eventos de lluvias no desencadenantes de MM). Este efecto apunta a la importancia de obtener inventarios de deslizamientos amplios.

4. Discusiones

En esta investigación, se determinaron umbrales de precipitación que permiten separar eventos de lluvias desencadenantes y no desencadenan de movimientos en masa para dos escenarios, a partir de parámetros de eventos de lluvias asociados a los MM, este tipo de análisis ya se desarrollaron objetivamente en estudios previos (Abraham, Pothuraju, and Satyam 2019; Leonarduzzi et al. 2017; Peruccacci et al. 2012, 2017b; Rosi et al. 2012; Segoni et al. 2014; Uwihirwe et al. 2020). Este trabajo es la primera aproximación de umbrales regionales a escala del Perú, lo cual servirá de punto de partida y referencia para continuar el desarrollo de este tipo de investigaciones en el Perú.

Los umbrales individuales se eligieron maximizando el estadístico AUC (ver Tabla 2). De los resultados se observa que los umbrales con mejor rendimiento fueron E para las propiedades individuales de eventos de lluvia y $I_{mean}-D$ para propiedades combinadas. La propiedad que menor rendimiento tuvo fue la duración del evento, D , por lo que no se debe de utilizar de forma independiente, sino que, combinada con otras propiedades de eventos, pero sí nos permite asociar eventos de MM con las condiciones antecedentes de lluvia de los últimos 8 días para futuras investigaciones.

Con respecto a los umbrales de dos variables o bivariados (ver Tabla 3), el modelo de optimización tiene un enfoque basado en maximizar el TSS, mediante el cual se busca tener una alta tasa de detección de eventos de MM (sensibilidad), manteniendo en lo posible una baja tasa de detección de falsos positivos (especificidad), sin embargo, se observa que con el objetivo de buscar esta optimización se sacrifica la detección de MM (dando falsos negativos), este es un dilema en cuanto a sistemas de alertas. Sin embargo, el TSS en todos los umbrales que relacionan dos variables, tiene una ligera mejora, superando todos el 0.5 en la calibración del umbral $I_{mean}-D$ (el umbral con mejor rendimiento para los umbrales curva) con excepción de Andes 1.

La región Pacific 1, donde se encuentran varias quebradas de alto impacto por los MM de especial importancia en Perú, se observa que el I_{\max} (TSS = 0.68) y $I_{\max-D}$ (TSS = 0.71) fueron los mejores umbrales para el escenario de eventos enteros y los umbrales I_{\max} (TSS = 0.65) y $I_{\text{mean}-D}$ (TSS = 0.68) para el escenario de condiciones antecedentes. Los rendimientos para la validación en el escenario de condiciones antecedentes fueron superiores al de la calibración, lo cual nos indica que las quebradas en esta región son altamente susceptibles a eventos de máxima intensidad y podrían aumentar la probabilidad de ocurrencia de MM, esto particularmente debido a que en la etapa de validación esta región mostró un crecimiento importante en su rendimiento con respecto a la calibración, mostrando que las condiciones antecedentes de lluvias tienen un alto impacto condicionador en el desarrollo de MM.

La regionalización se vio necesaria dada la alta variabilidad climática en Perú, evidenciado en las diferencias de magnitud entre los umbrales. Esta regionalización nos ayudó a observar las regiones de Perú donde hay mayor actividad de MM y su respuesta a este tipo de umbrales diarios. Por ejemplo, observamos que la región Andes 2 (la región con mayor número de eventos registrados en los últimos años) tiene una mejor respuesta para el umbral I_{\max} tanto para la calibración como para la validación. En general las regiones con mejores desempeños se observan en la Tabla 4.

Con respecto a la evaluación del desempeño de los umbrales, se realizó mediante una validación con los eventos del año 2020, sin embargo, se observó que los rendimientos disminuyeron, esto se puede deber a que en el año 2020 no se presentaron eventos de lluvias extremos como en otros años y la cantidad de MM fue inferior que, en otros años, incluso la región Amazon 1 no tuvo registros de eventos de activaciones, por lo que podemos decir que el bajo rendimiento se debe a que los umbrales no representan eventos de MM con magnitud de impacto bajo, esto asociado a que uno de los enfoques del modelo es aminorar la tasa de falsas alarmas.

Aún existen diferentes fuentes de limitaciones para los estudios a escala regional en materia de MM y su interrelación con las lluvias como agente desencadenante en Perú. La principal fuente de incertidumbre en este estudio se debe a la incertidumbre de las bases de datos disponibles usadas como es el de (i) precipitación de PISCOpd_Op por la resolución espacio-temporal; (ii) las cuencas o unidades de análisis, las cuales cubren varias quebradas, torrenteras, cuencas pequeñas; (iii) los catálogos de MM observados registrados pues el objetivo del estudio no se centró en la revisión del registro de los eventos, aunque si se realizó un análisis global de las bases de datos, y (iv) las regiones climáticas, debido a la gran variabilidad espacial de las variables descriptoras de MM estudiadas en esta investigación. Estos factores descritos generan incertidumbres en la generación de umbrales regionales que se traducen en los índices de rendimiento usados para la evaluación de los umbrales.

5. Conclusiones

Este estudio es la primera aproximación de umbrales regionales desencadenantes de MM, para estimar y analizar la interrelación entre las lluvias y su efecto desencadenador de MM para 11 regiones de precipitación en Perú, a partir de un método empírico-estadístico. La ventaja de este estudio es el uso de eventos reales observados de MM para realizar la calibración de umbrales. La información de precipitación grillada especializada diaria y el registro de eventos nos permitió estimar la lluvia desencadenante en los MM, y así determinar propiedades de eventos de lluvia desencadenantes y no desencadenantes en sitios susceptibles, y usarlos para determinar los umbrales de lluvia para la activación de movimientos en masa de tipo flujo desencadenados por lluvias y validar su rendimiento. Nuestras principales conclusiones son:

- a. La generación de umbrales mediante el método empírico-estadístico, y la calibración basada en la optimización los estadísticos *Area Under the Curve AUC* y el *True Skill Statistic TSS*, tuvieron éxito en la definición de umbrales de lluvia para MM. El mejor rendimiento predictivo se obtuvo mediante la curva umbral intensidad media-duración $I_{mean}-D$, seguida de la intensidad diaria acumulada E . La duración del evento de forma independiente tiene un poder predictivo muy bajo.
- b. El desempeño de los umbrales en las regiones Andes 3, Andes 2, Andes 5, Pacific 1 y Amazon 1 tuvieron un buen desempeño. Los modelos clasificaron aceptablemente los eventos de lluvias desencadenantes de los que no desencadenan. Las regiones con peores rendimientos fueron: Andes 1, Andes 4 y Amazon 1.
- c. A través de los productos operativos de lluvia PISCOpd_Op y las bases de datos de MM observados es posible generar umbrales de lluvia diarios desencadenantes de MM. Sin embargo, las incertidumbres asociadas a estas bases de datos son la principal fuente de error de los umbrales, razón por la cual la fase de validación tuvo una alta sensibilidad.

Los resultados de este trabajo demuestran el potencial de los umbrales de lluvias basado en las características de eventos de lluvias asociados a MM para su implementación en el monitoreo de MM en Perú. Futuros trabajos se deben de enfocar en tres perspectivas principales: i) mejorar la resolución espacio-temporal de la precipitación grillada; ii) la mejora de la discretización espacial de regiones donde se desarrollan la mayor cantidad de eventos de MM, esto es dependiente de la primera perspectiva de mejorar la resolución temporal-espacial de las lluvias; y iii) incluir más bases de datos de MM para mejorar la certidumbre de los umbrales y aminorar la sensibilidad de los mismos.

6. Referencias bibliográficas

- Abraham, Minu Treesa, Deekshith Pothuraju, and Neelima Satyam. 2019. "Rainfall Thresholds for Prediction of Landslides in Idukki, India: An Empirical Approach." *Water (Switzerland)* 11(10):1–16. doi: 10.3390/w11102113.
- Abraham, Minu Treesa, Neelima Satyam, Biswajeet Pradhan, and Abdullah M. Alamri. 2020. "Forecasting of Landslides Using Rainfall Severity and Soil Wetness: A Probabilistic Approach for Darjeeling Himalayas." *Water* 12(3):804. doi: 10.3390/w12030804.
- Augusto Filho, Oswaldo, Paulo Sérgio da Silva Júnior, and Cahio Guimarães Seabra Eiras. 2020. "Simple Rainfall Indices for Forecasting Hazardous Events of Hydrologic and Geologic Nature." *Natural Hazards* (0123456789). doi: 10.1007/s11069-020-03890-4.
- Aybar, Cesar, Carlos Fernández, Adrian Huerta, Waldo Lavado, Fiorella Vega, and Oscar Felipe-Obando. 2020. "Construction of a High-Resolution Gridded Rainfall Dataset for Peru from 1981 to the Present Day." *Hydrological Sciences Journal* 65(5):770–85. doi: <https://doi.org/10.1080/02626667.2019.1649411>.
- Boers, N., B. Bookhagen, H. M. J. Barbosa, N. Marwan, J. Kurths, and J. A. Marengo. 2014. "Prediction of Extreme Floods in the Eastern Central Andes Based on a Complex Networks Approach." *Nature Communications* 5:1–7. doi: 10.1038/ncomms6199.
- Bookhagen, Bodo, and Manfred R. Strecker. 2008. "Orographic Barriers, High-Resolution TRMM Rainfall, and Relief Variations along the Eastern Andes." *Geophysical Research Letters* 35(6):1–6. doi: 10.1029/2007GL032011.
- Caine, Nel. 1980. "The Rainfall Intensity-Duration Control of Shallow Landslides and Debris Flows." *Geografiska Annaler A* 62(1–2):23–27. doi: 10.2307/520449.
- Chae, Byung Gon, Hyuck Jin Park, Filippo Catani, Alessandro Simoni, and Matteo Berti. 2017. "Landslide Prediction, Monitoring and Early Warning: A Concise Review of State-of-the-Art." *Geosciences Journal* 21(6):1033–70. doi: 10.1007/s12303-017-0034-4.
- Dai, Aiguo. 2006. "Precipitation Characteristics in Eighteen Coupled Climate Models." *Journal of Climate* 19(18):4605–4630. doi: <https://doi.org/10.1175/JCLI3884.1>.
- Dai, Aiguo, Xin Lin, and Kuo-Lin Hsu. 2007. "The Frequency, Intensity, and Diurnal Cycle of Precipitation in Surface and Satellite Observations over Low- and Mid-Latitudes." *Climate Dynamics* 29:727–744. doi: <https://doi.org/10.1007/s00382-007-0260-y>.
- David, Cédric H., David R. Maidment, Guo Yue Niu, Zong Liang Yang, Florence Habets, and Victor Eijkhout. 2011. "River Network Routing on the NHDPlus Dataset." *Journal of Hydrometeorology* 12(5):913–34. doi: 10.1175/2011JHM1345.1.

- Duan, Q. Y., V. K. Gupta, and S. Sorooshian. 1993. "Shuffled Complex Evolution Approach for Effective and Efficient Global Minimization." *J Optim Theory Appl* 76(76):501–521. doi: <https://doi.org/10.1007/BF00939380>.
- Fawcett, Tom. 2006. "An Introduction to ROC Analysis." *Pattern Recognition Letters* 27(8):861–74. doi: 10.1016/j.patrec.2005.10.010.
- Frattini, Paolo, Giovanni Crosta, and Alberto Carrara. 2010. "Techniques for Evaluating the Performance of Landslide Susceptibility Models." *Engineering Geology* 111(1–4):62–72. doi: 10.1016/j.enggeo.2009.12.004.
- Gariano, S. L., M. T. Brunetti, G. Iovine, M. Melillo, S. Peruccacci, O. Terranova, C. Vennari, and F. Guzzetti. 2015. "Calibration and Validation of Rainfall Thresholds for Shallow Landslide Forecasting in Sicily, Southern Italy." *Geomorphology* 228:653–65. doi: 10.1016/j.geomorph.2014.10.019.
- Guzzetti, Fausto, S. Peruccacci, M. Rossi, and C. P. Stark. 2007. "Rainfall Thresholds for the Initiation of Landslides in Central and Southern Europe." *Meteorology and Atmospheric Physics* 98(3–4):239–67. doi: 10.1007/s00703-007-0262-7.
- Guzzetti, Fausto, Silvia Peruccacci, Mauro Rossi, and Colin P. Stark. 2008. "The Rainfall Intensity-Duration Control of Shallow Landslides and Debris Flows: An Update." *Landslides* 5(1):3–17. doi: 10.1007/s10346-007-0112-1.
- Han, Zheng, Guangqi Chen, Yange Li, Linrong Xu, and Fusong Fan. 2016. "Geotechnical Hazards from Large Earthquakes and Heavy Rainfalls." *Geotechnical Hazards from Large Earthquakes and Heavy Rainfalls*. doi: 10.1007/978-4-431-56205-4.
- Hanssen, A. W., and W. J. A. Kuipers. 1965. *On the Relationship between the Frequency of Rain and Various Meteorological Parameters*. edited by M. en Verhandelingen.
- Hosking, J. R. M., and James R. Wallis. 1997. *Regional Frequency Analysis*. Cambridge University Press.
- INDECI. 2019. *Compendio Estadístico Del INDECI 2019. En La Preparación, Respuesta y Rehabilitación de La GRD*. Lima.
- Kirschbaum, Dalia, and Thomas Stanley. 2018. "Satellite-Based Assessment of Rainfall-Triggered Landslide Hazard for Situational Awareness." *Earth's Future* 6(3):505–23. doi: 10.1002/2017EF000715.
- Kirschbaum, Dalia, Thomas Stanley, and Yaping Zhou. 2015. "Spatial and Temporal Analysis of a Global Landslide Catalog." *Geomorphology* 249:4–15. doi: 10.1016/j.geomorph.2015.03.016.
- Lavado Casimiro, Waldo Sven, David Labat, Jean Loup Guyot, and Sandra Ardoin-Bardin. 2011. "Assessment of Climate Change Impacts on the Hydrology of the Peruvian Amazon-Andes Basin." *Hydrological Processes* 25(24):3721–34. doi: 10.1002/hyp.8097.

- Leonarduzzi, Elena, Peter Molnar, and Brian W. McArdell. 2017. "Predictive Performance of Rainfall Thresholds for Shallow Landslides in Switzerland from Gridded Daily Data." *Water Resources Research* 53(8):6612–25. doi: 10.1002/2017WR021044.
- Llauca, Harold, Waldo Lavado-Casimiro, Cristian Montesinos, William Santini, and Pedro Rau. 2021. "PISCO_HyM_GR2M: A Model of Monthly Water Balance in Peru (1981–2020)." *Water (Switzerland)* 13(8):1–19. doi: 10.3390/w13081048.
- Millan, Carlos. 2020. "Sistema de Monitoreo de Movimientos En Masa Potenciales Generados Por Lluvias Intensas Del SENAMHI (SILVIA)." Pp. 17–21 in *Estudios Hidrológicos del SENAMHI Resúmenes Ejecutivos - 2020*, edited by W. (SENAMHI) Lavado. Lima.
- Millan, Carlos, Waldo Lavado, Fiorella Vega, Oscar Felipe, Julia Acuña, and Ken Takahashi. 2021. "SILVIA : An Operational System to Monitoring Landslides Forced by Heavy Precipitations at National Scale in Peru." P. 10970 in *EGU General Assembly 20220*. Vol. 1.
- Peirce, C. S. 1884. "The Numerical Measure of Success in Predictions." *Science* 453–54. doi: <http://dx.doi.org/10.1126/science.ns-4.93.453-a>.
- Peruccacci, Silvia, Maria Teresa Brunetti, Stefano Luigi Gariano, Massimo Melillo, Mauro Rossi, and Fausto Guzzetti. 2017a. "Rainfall Thresholds for Possible Landslide Occurrence in Italy." *Geomorphology* 290(January):39–57. doi: 10.1016/j.geomorph.2017.03.031.
- Peruccacci, Silvia, Maria Teresa Brunetti, Stefano Luigi Gariano, Massimo Melillo, Mauro Rossi, and Fausto Guzzetti. 2017b. "Rainfall Thresholds for Possible Landslide Occurrence in Italy." *Geomorphology*. doi: 10.1016/j.geomorph.2017.03.031.
- Peruccacci, Silvia, Maria Teresa Brunetti, Silvia Luciani, Carmela Vennari, and Fausto Guzzetti. 2012. "Lithological and Seasonal Control on Rainfall Thresholds for the Possible Initiation of Landslides in Central Italy." *Geomorphology* 139–140:79–90. doi: 10.1016/j.geomorph.2011.10.005.
- Petley, David. 2012. "Global Patterns of Loss of Life from Landslides." *Geology* 40(10):927–30. doi: 10.1130/G33217.1.
- Poveda, Germán, Liliana Jaramillo, and Luisa F. Vallejo. 2014. "Seasonal Precipitation Patterns along Pathways of South American Low-Level Jets and Aerial Rivers." *Water Resources Research* 50(1):98–118. doi: 10.1002/2013WR014087.
- Prenner, D., R. Kaitna, K. Mostbauer, and M. Hrachowitz. 2018. "The Value of Using Multiple Hydrometeorological Variables to Predict Temporal Debris Flow Susceptibility in an Alpine Environment." *Water Resources Research* 54(9):6822–43. doi: 10.1029/2018WR022985.
- Qiao, Xiaohui, E. James Nelson, Daniel P. Ames, Z. Li, Cédric H. David, Gustavious P. Williams, Wade Roberts, Jorge Luis Sánchez Lozano, C. Edwards, Michael

- Souffront, and M. A. Matin. 2019. "A Systems Approach to Routing Global Gridded Runoff through Local High-Resolution Stream Networks for Flood Early Warning Systems." *Environmental Modelling and Software* 120(July). doi: 10.1016/j.envsoft.2019.104501.
- Rosi, Ascanio, Samuele Segoni, Filippo Catani, and Nicola Casagli. 2012. "Statistical and Environmental Analyses for the Definition of a Regional Rainfall Threshold System for Landslide Triggering in Tuscany (Italy)." *Journal of Geographical Sciences* 22(4):617–29. doi: 10.1007/s11442-012-0951-0.
- Segoni, S., A. Rosi, G. Rossi, F. Catani, and N. Casagli. 2014. "Analysing the Relationship between Rainfalls and Landslides to Define a Mosaic of Triggering Thresholds for Regional-Scale Warning Systems." *Natural Hazards and Earth System Sciences* 14(9):2637–48. doi: 10.5194/nhess-14-2637-2014.
- Segoni, Samuele, Luca Piciullo, and Stefano Luigi Gariano. 2018. "A Review of the Recent Literature on Rainfall Thresholds for Landslide Occurrence." *Landslides* 15(8):1483–1501. doi: 10.1007/s10346-018-0966-4.
- Shen, Zhehui, Bin Yong, Jonathan J. Gourley, and Weiqing Qi. 2021. "Real-Time Bias Adjustment for Satellite-Based Precipitation Estimates over Mainland China." *Journal of Hydrology* 596(January):126133. doi: 10.1016/j.jhydrol.2021.126133.
- Souffront Alcantara, Michael A., E. James Nelson, Kiran Shakya, Christopher Edwards, Wade Roberts, Corey Krewson, Daniel P. Ames, Norman L. Jones, and Angelica Gutierrez. 2019. "Hydrologic Modeling as a Service (HMaaS): A New Approach to Address Hydroinformatic Challenges in Developing Countries." *Frontiers in Environmental Science* 7(October). doi: 10.3389/fenvs.2019.00158.
- Tian, Yudong, Christa D. Peters-Lidard, Bhaskar J. Choudhury, and Matthew Garcia. 2007. "Multitemporal Analysis of TRMM-Based Satellite Precipitation Products for Land Data Assimilation Applications." *Hydrometeorology* 8(6):1165–1183. doi: https://doi.org/10.1175/2007JHM859.1.
- Uwihirwe, Judith, Markus Hrachowitz, and Thom A. Bogaard. 2020. "Landslide Precipitation Thresholds in Rwanda." *Landslides* 17(10):2469–81. doi: 10.1007/s10346-020-01457-9.
- Van Osnabrugge, B., A. H. Weerts, and R. Uijlenhoet. 2017. "GenRE: A Method to Extend Gridded Precipitation Climatology Data Sets in Near Real-Time for Hydrological Forecasting Purposes." *Water Resources Research* 53(11):9284–9303. doi: 10.1002/2017WR021201.
- Villacorta, Sandra, Lionel Fidel, and Bilberto Zavala Carrión. 2012. "Mapa de Susceptibilidad Por Movimientos En Masa Del Perú." *Revista de La Asociacion Geologica Argentina* 69(3):393–99.
- Yong, Bin, Li-Liang Ren, Yang Hong, Jia-Hu Wang, Jonathan J. Gourley, Shan-Hu Jiang, Xi Chen, and Wen Wang. 2010. "Hydrologic Evaluation of Multisatellite Precipitation

Analysis Standard Precipitation Products in Basins beyond Its Inclined Latitude Band: A Case Study in Laohahe Basin, China.” *Water Resources Research*. doi: <https://doi.org/10.1029/2009WR008965>.

Youden, W. J. 1950. “Index for Rating Diagnostic Tests.” *Cancer* 3(1):32–35. doi: [10.1002/1097-0142\(1950\)3:1<32::AID-CNCR2820030106>3.0.CO;2-3](https://doi.org/10.1002/1097-0142(1950)3:1<32::AID-CNCR2820030106>3.0.CO;2-3).

Anexos

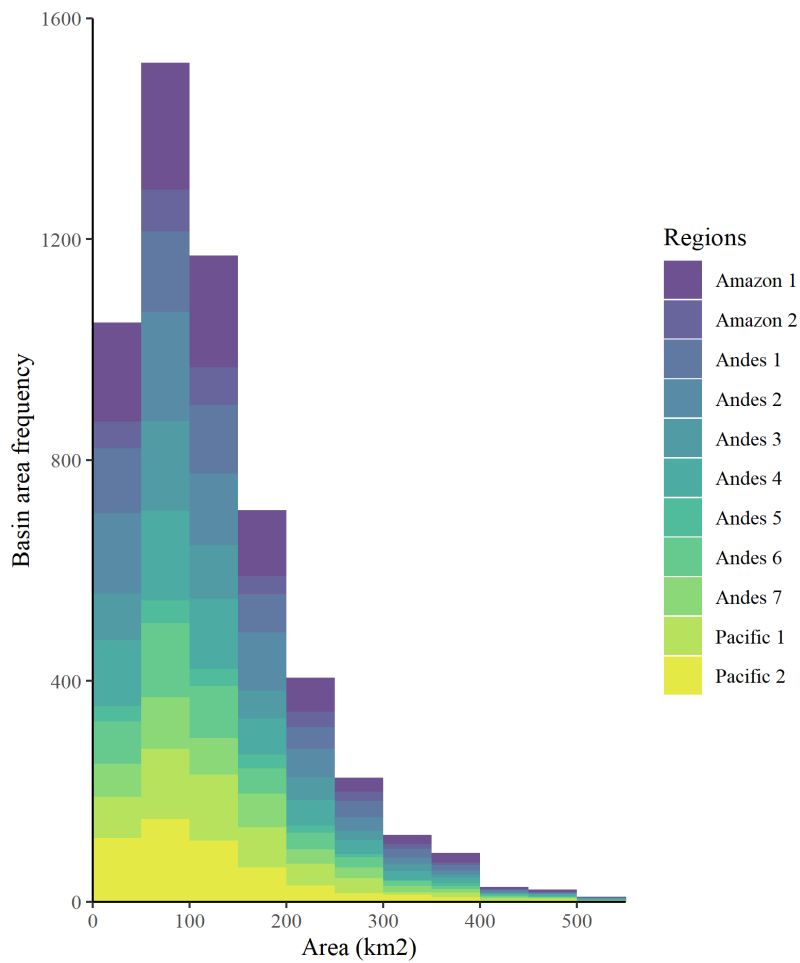


Fig. 1 Distribución de frecuencias de las áreas de las cuencas de GEOGloWS ECMWF (David et al., 2011; Qiao et al., 2019; Souffront Alcantara et al., 2019). El dominio del estudio fue discretizado en 5373 cuencas con áreas cuya mediana es de aproximadamente 105 km².




Fig. 2 Diagrama de dispersión 3D de los eventos de lluvia para las 11 regiones de análisis del estudio. Los 3 ejes son Duración (días) vs Intensidad Máxima (mm/d) vs Lluvia acumulada (mm). Los colores representan cada región. Los puntos más grandes representan eventos de lluvia desencadenantes de eventos de movimientos en masa y los puntos más pequeños son eventos de lluvia no desencadenantes.

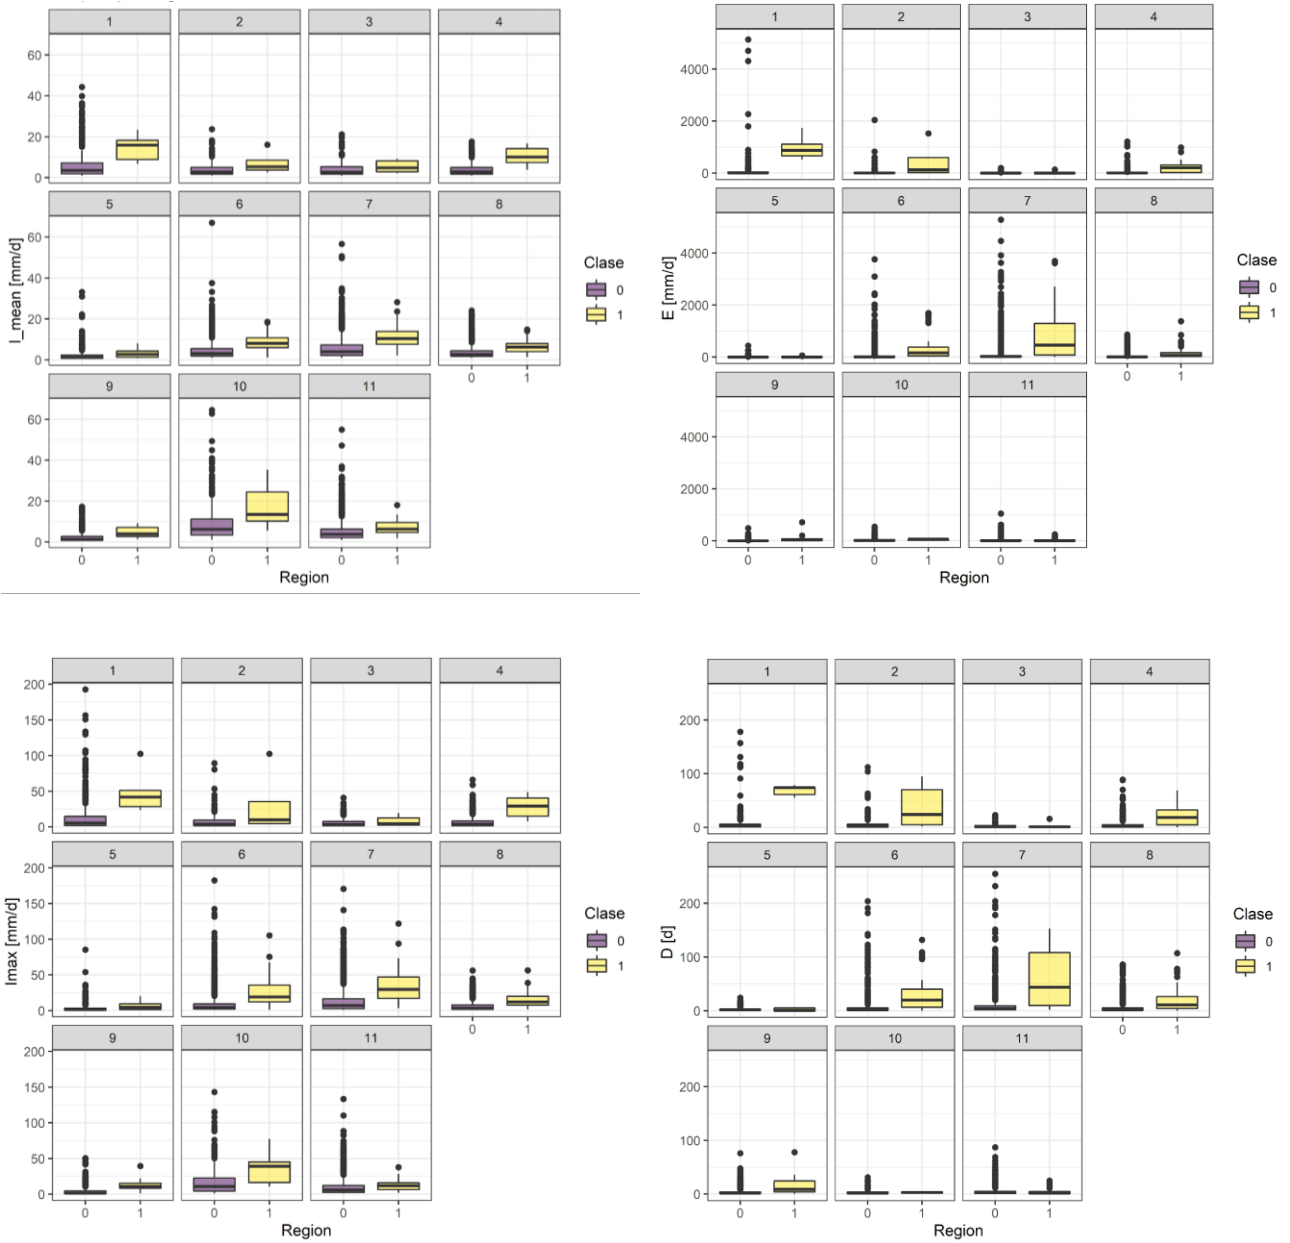


Fig. 3 Gráfico de cajas de las variables explicativas en el Escenario Antecedente para cada región.

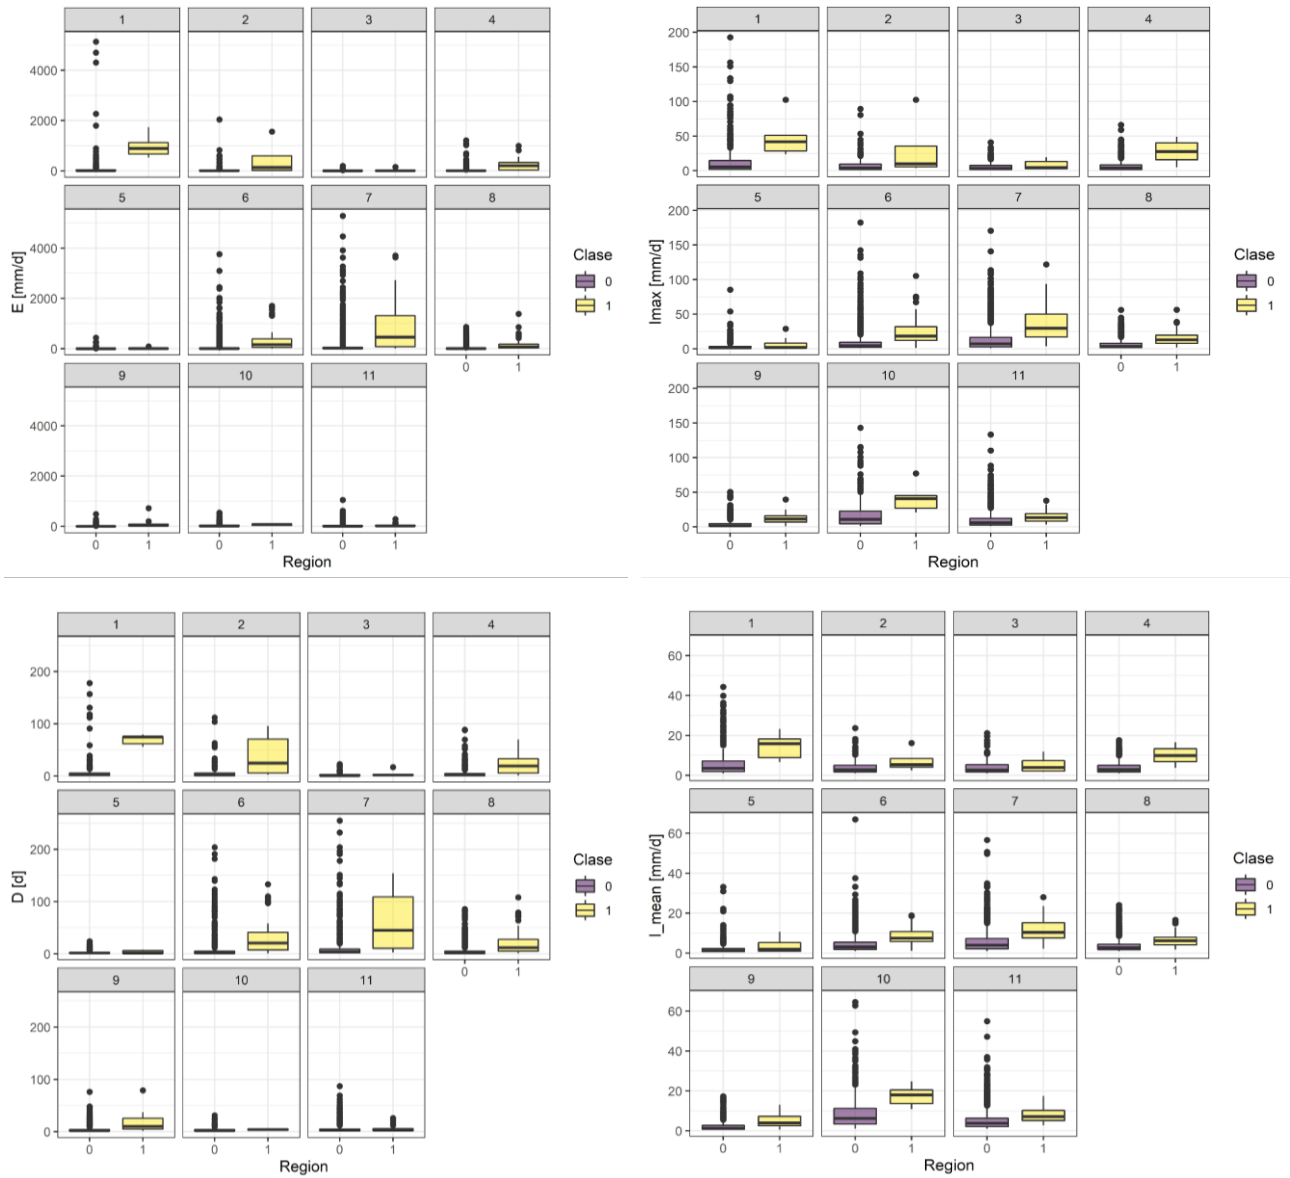
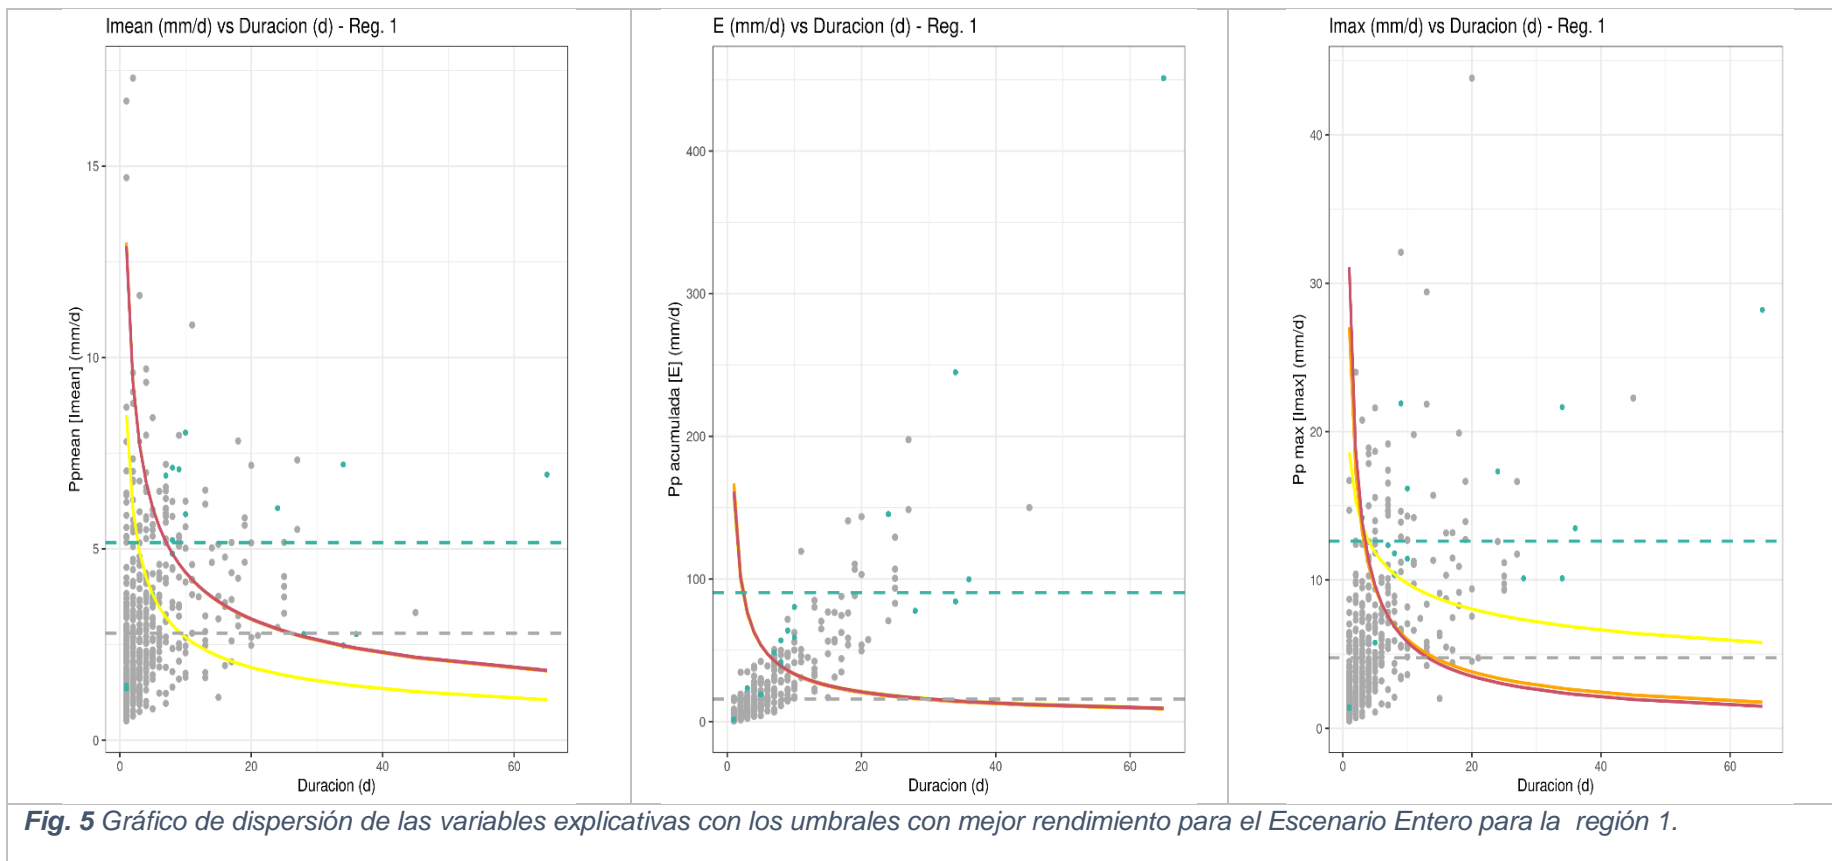


Fig. 4 Gráfico de cajas de las variables explicativas en el Escenario Entero para cada región.



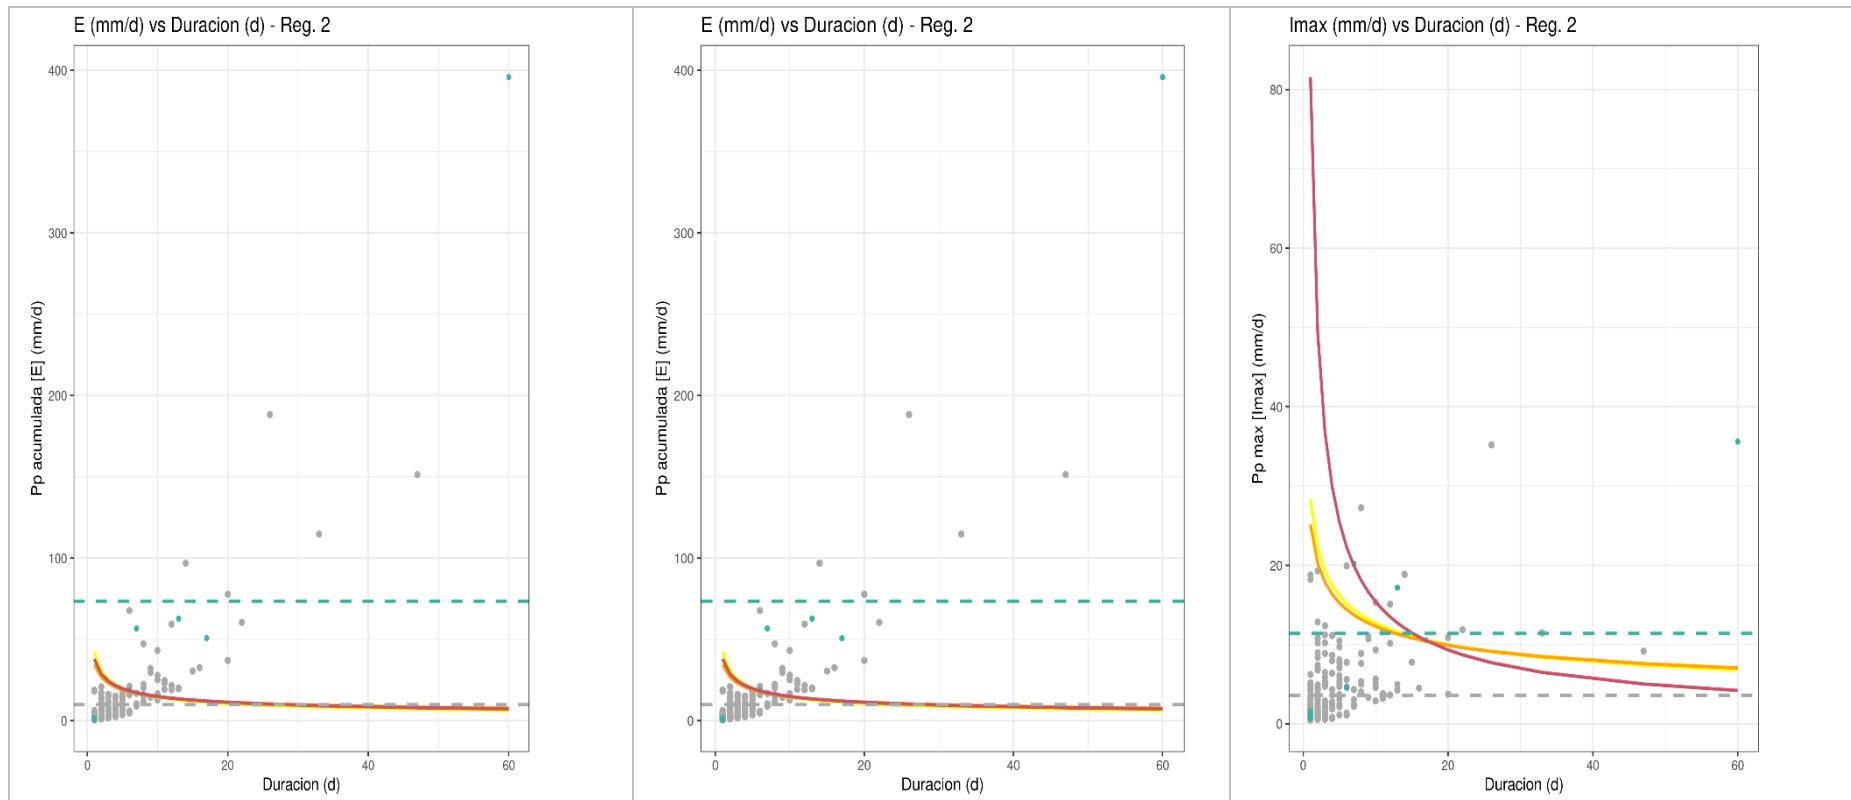


Fig. 6 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 2.




Fig. 7 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 3.

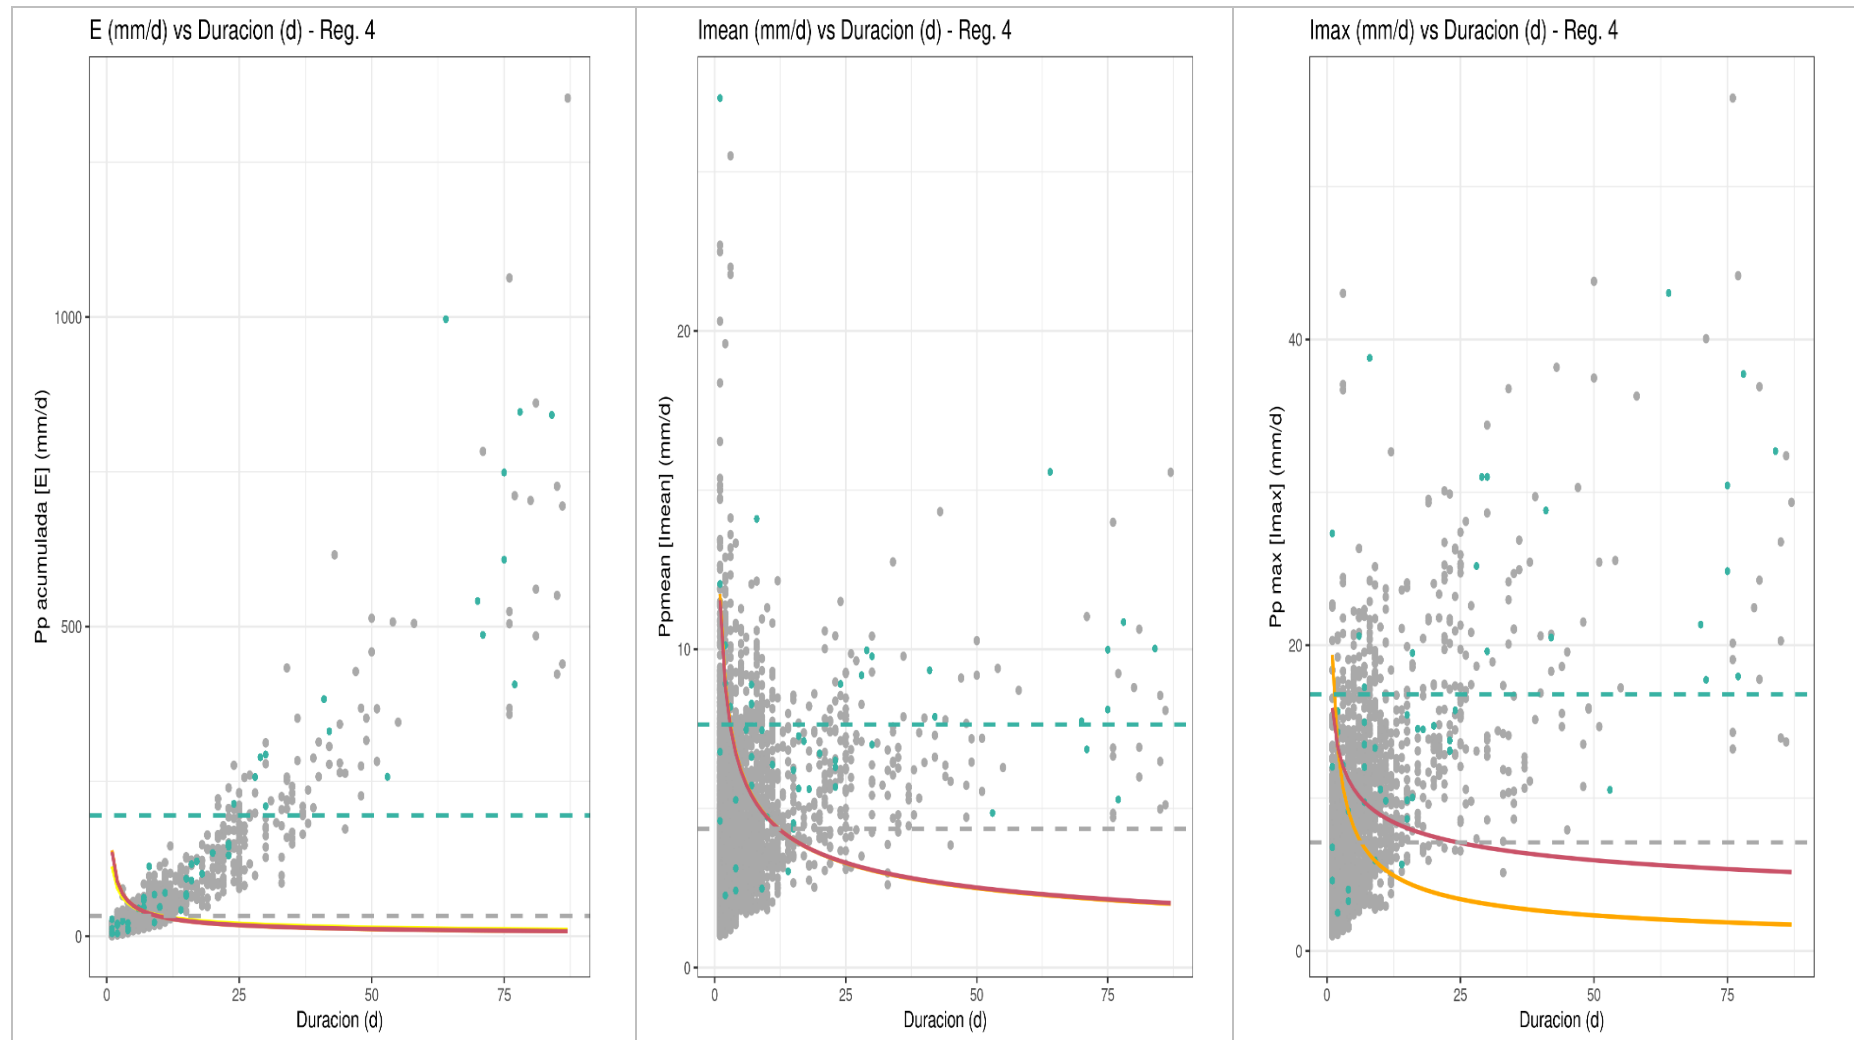
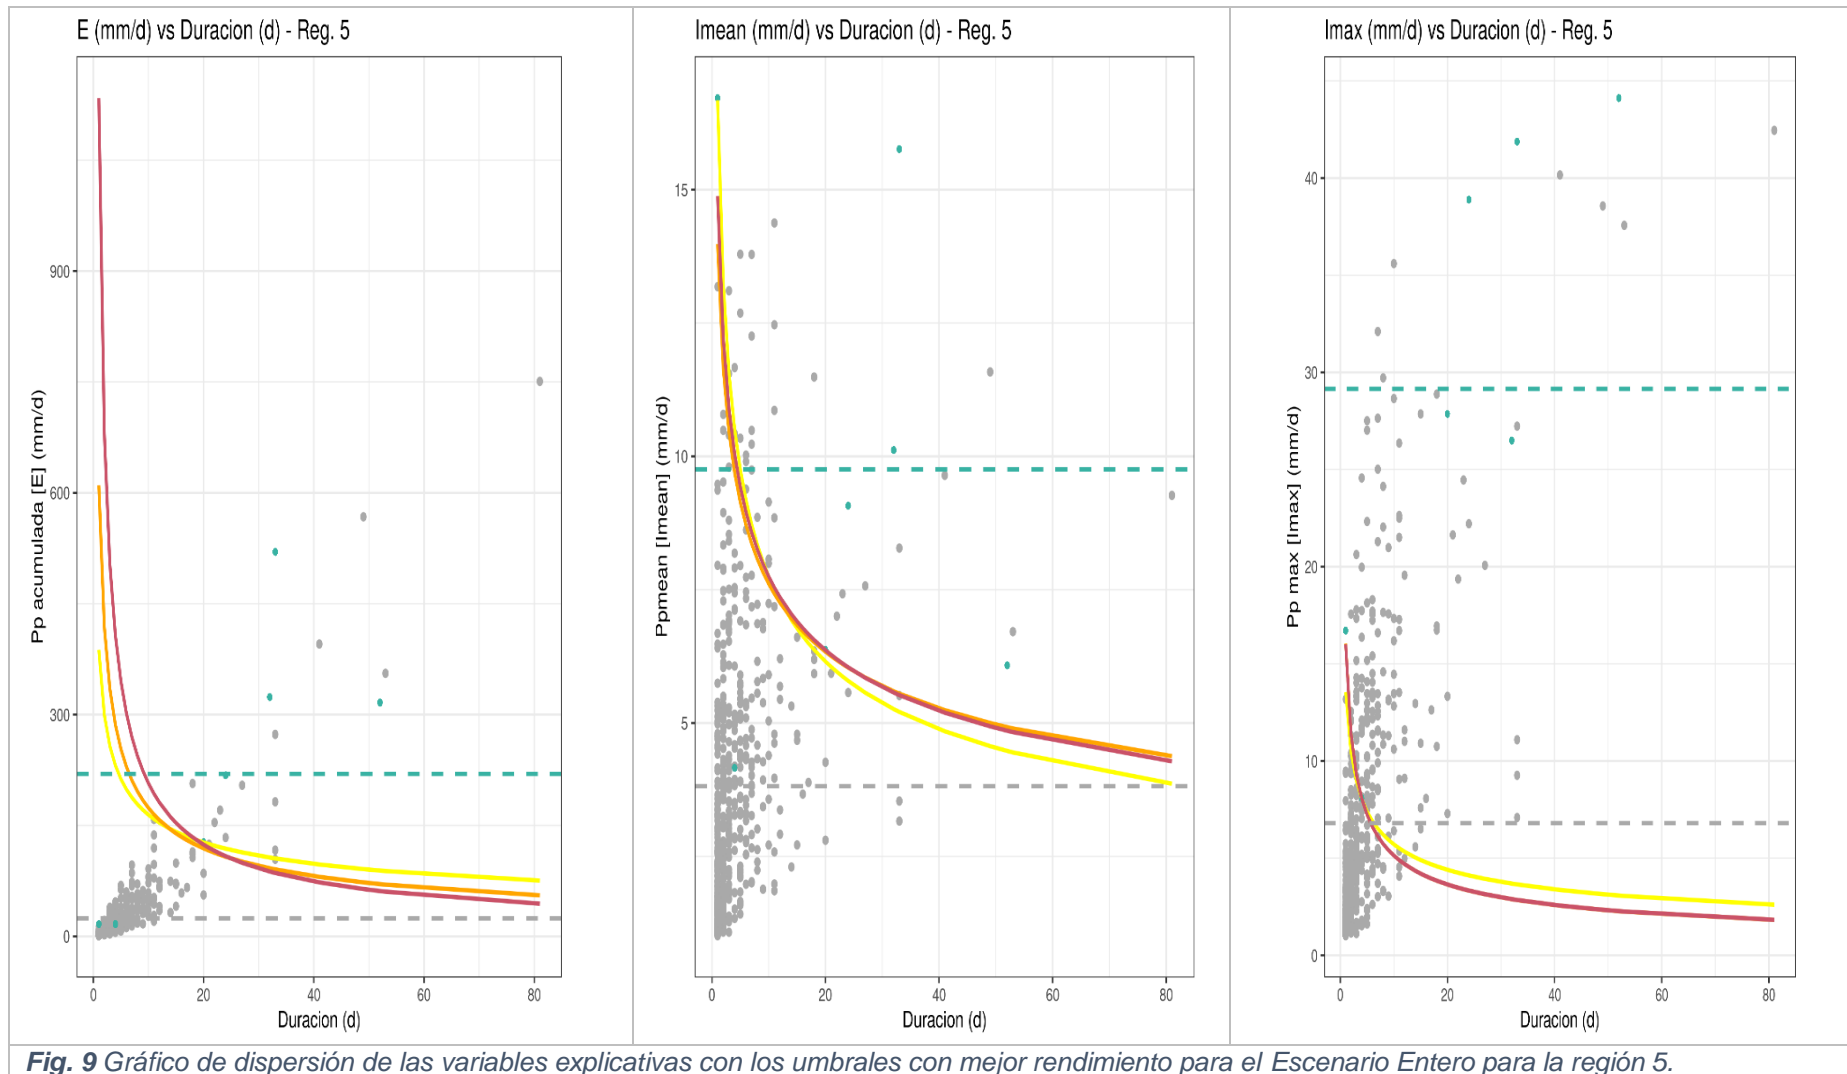


Fig. 8 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 4.



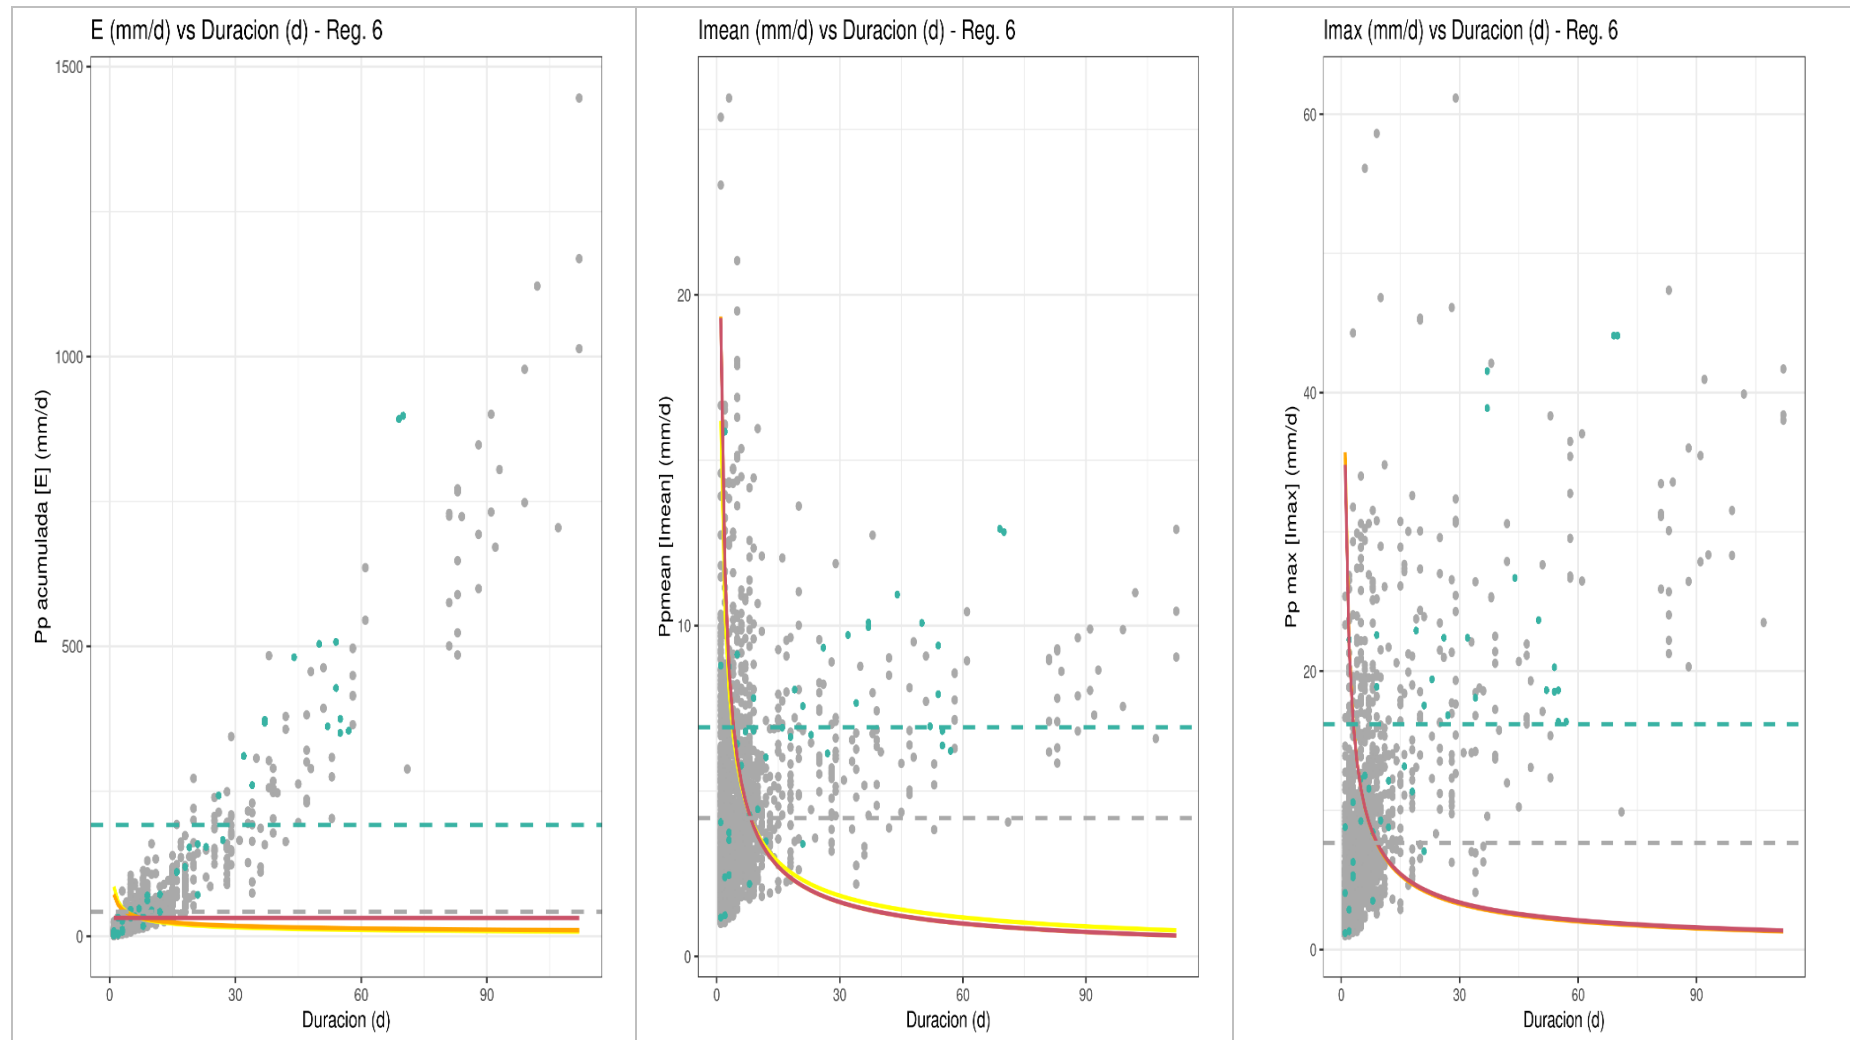
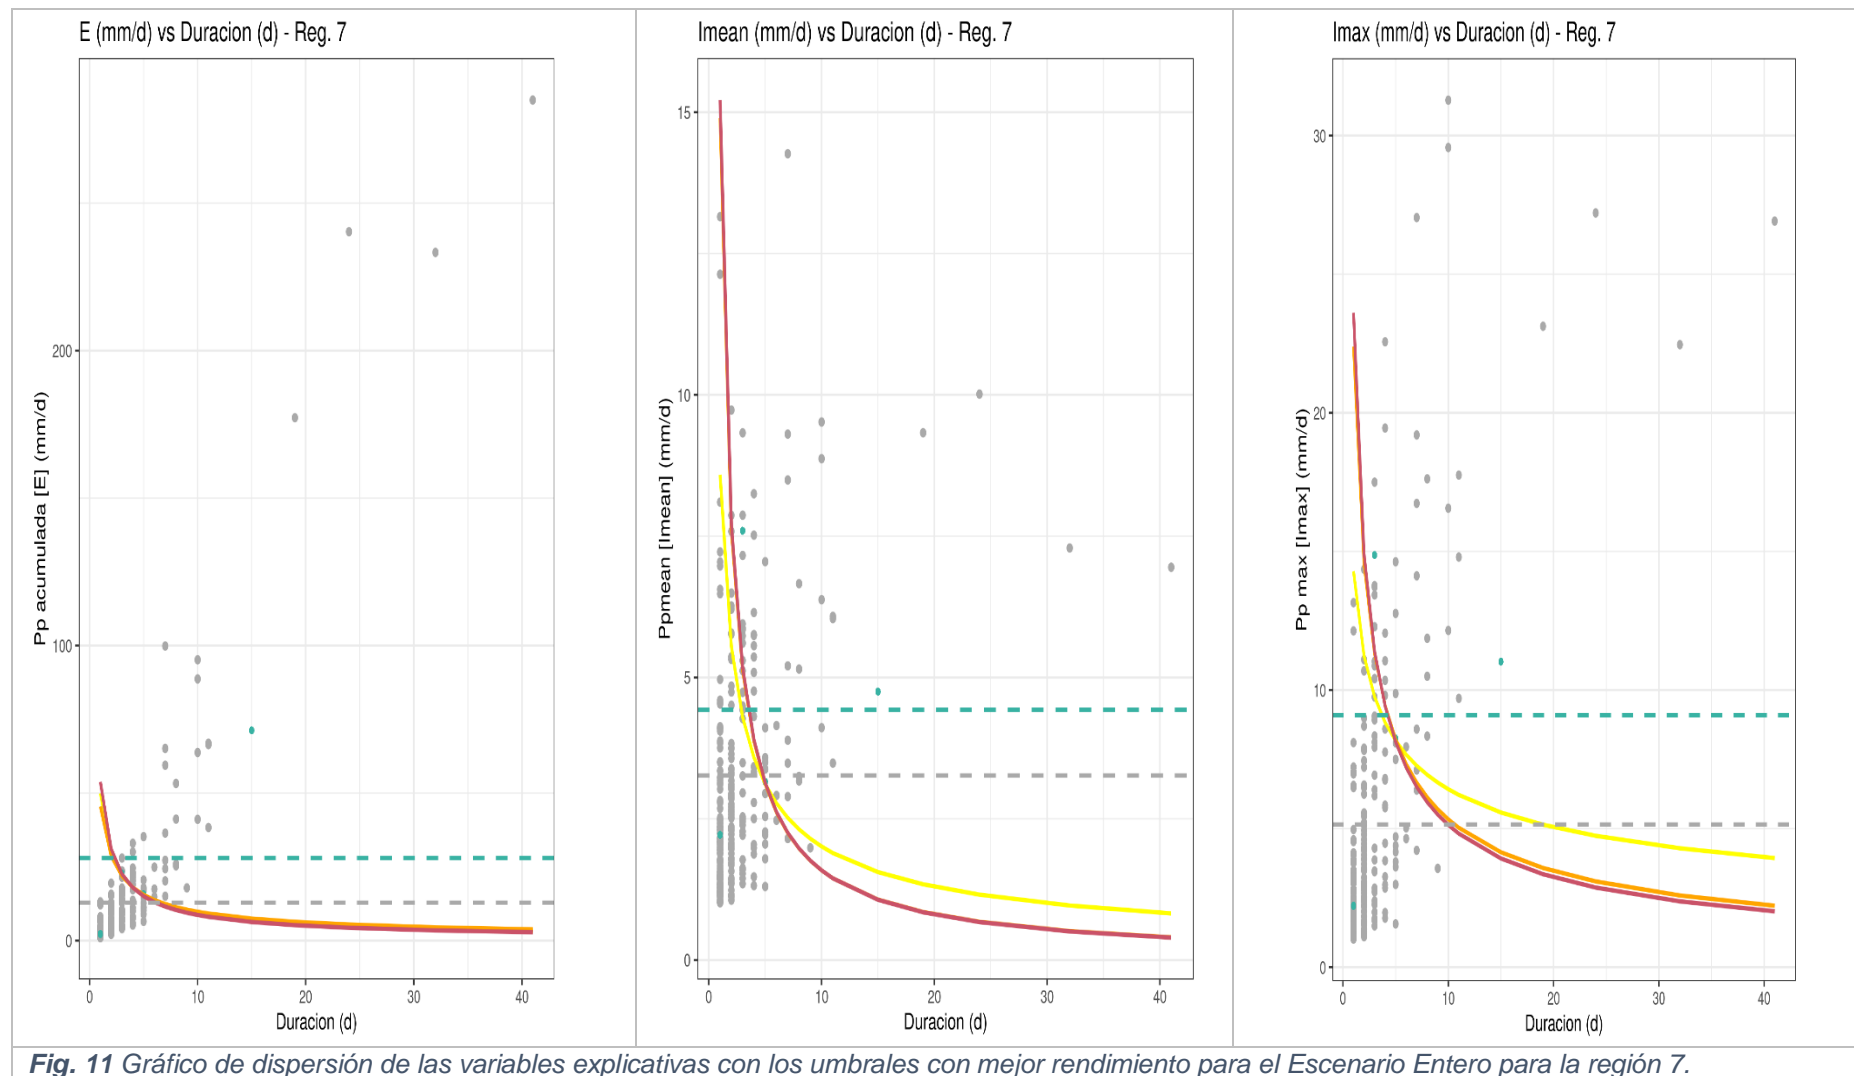


Fig. 10 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para |el Escenario Entero para la región 6.



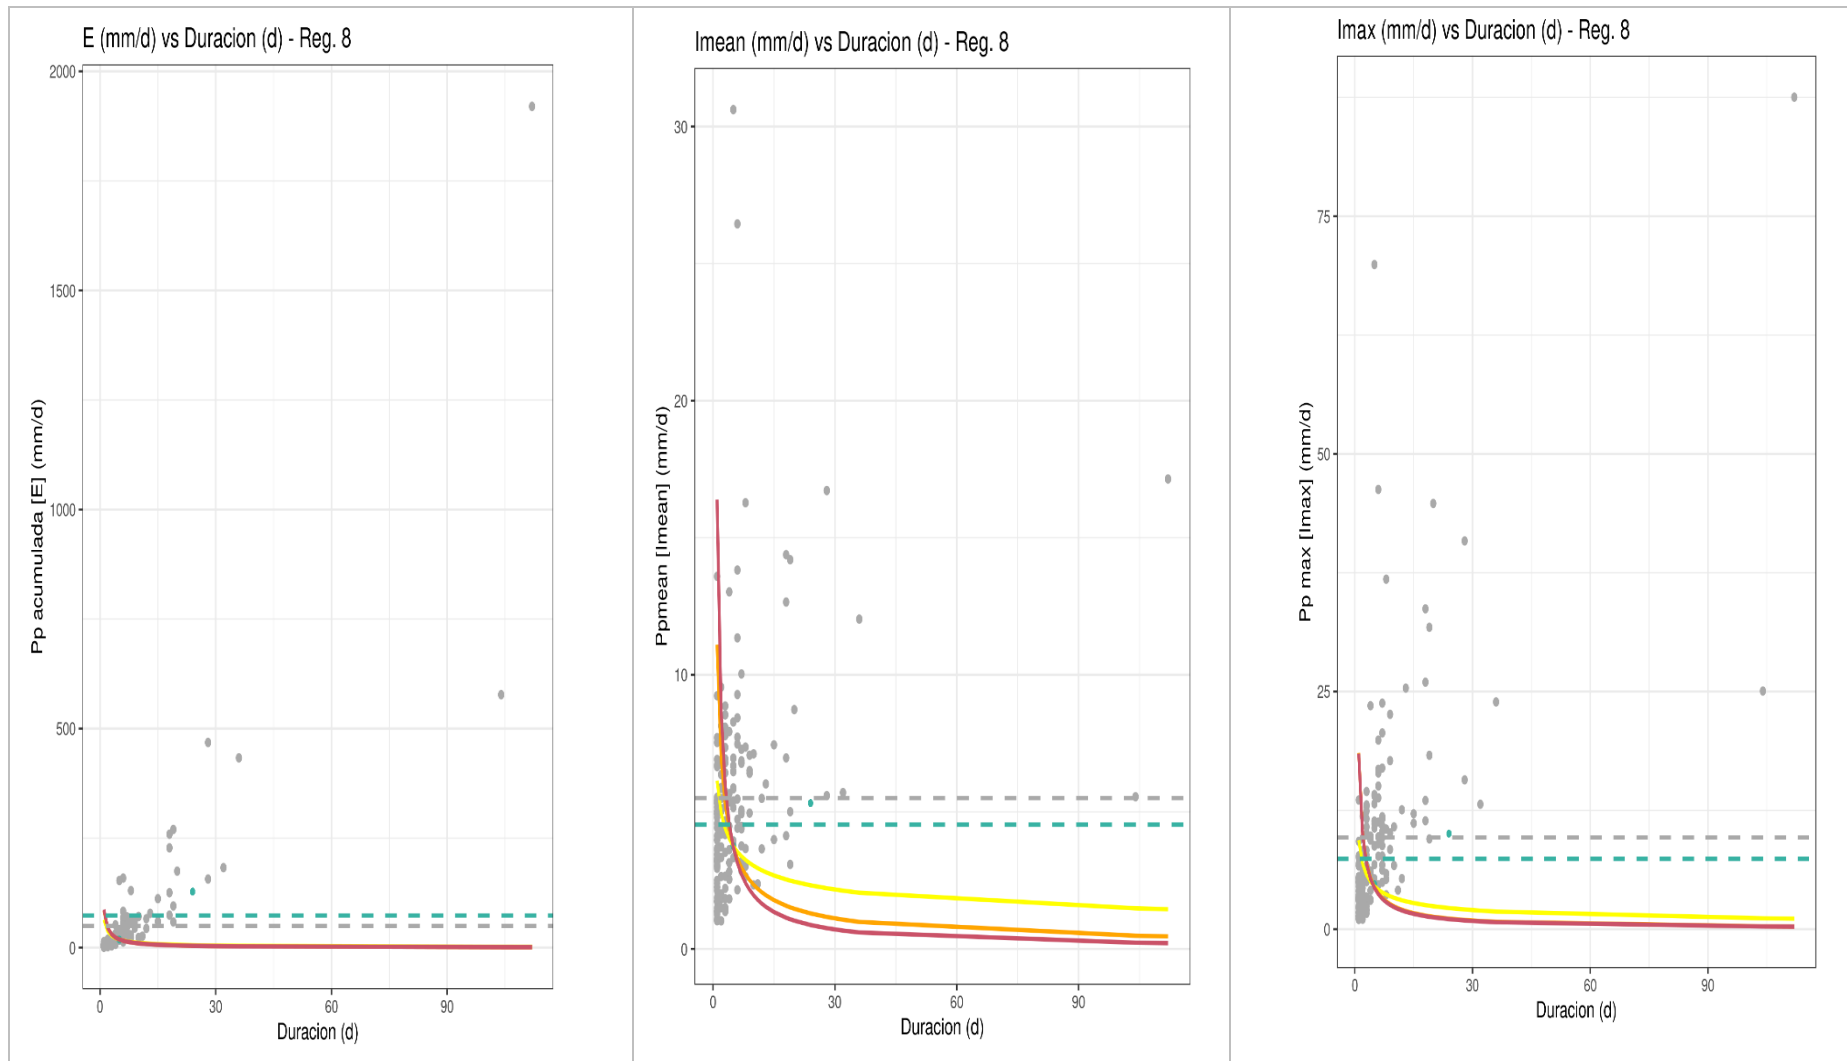
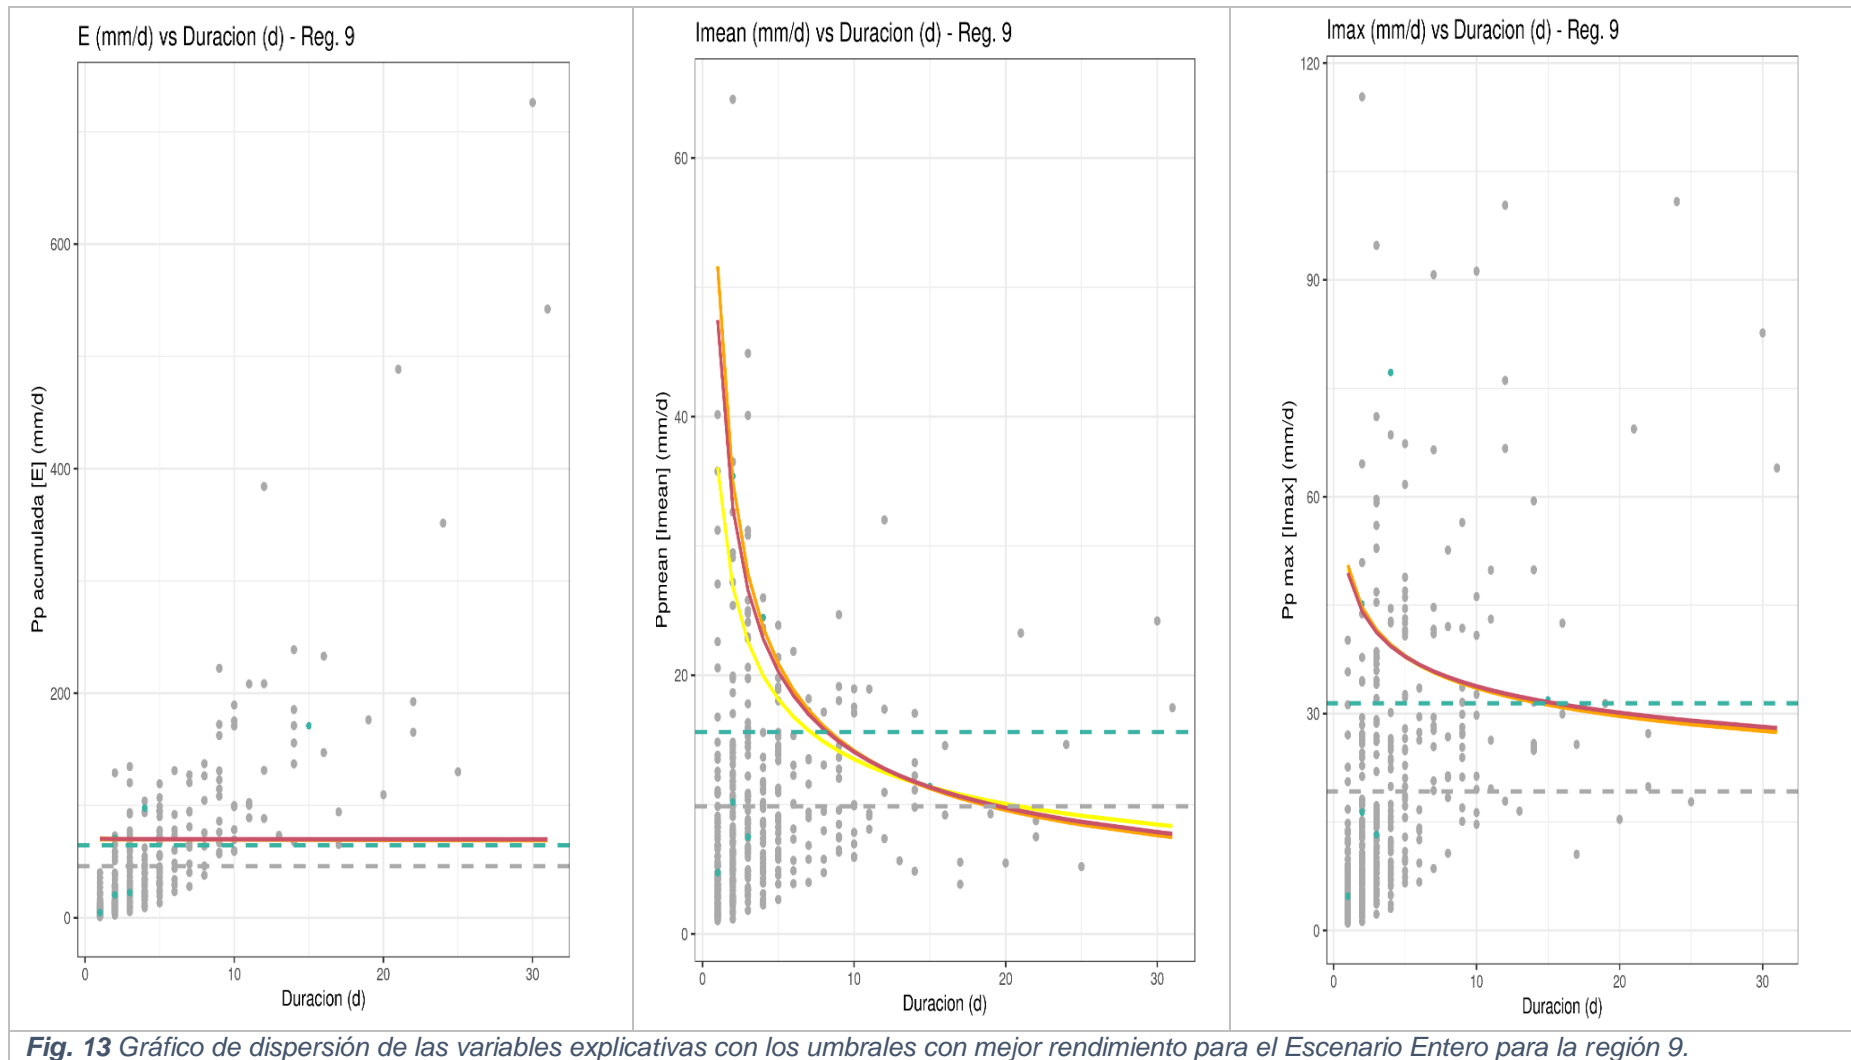


Fig. 12 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 8.



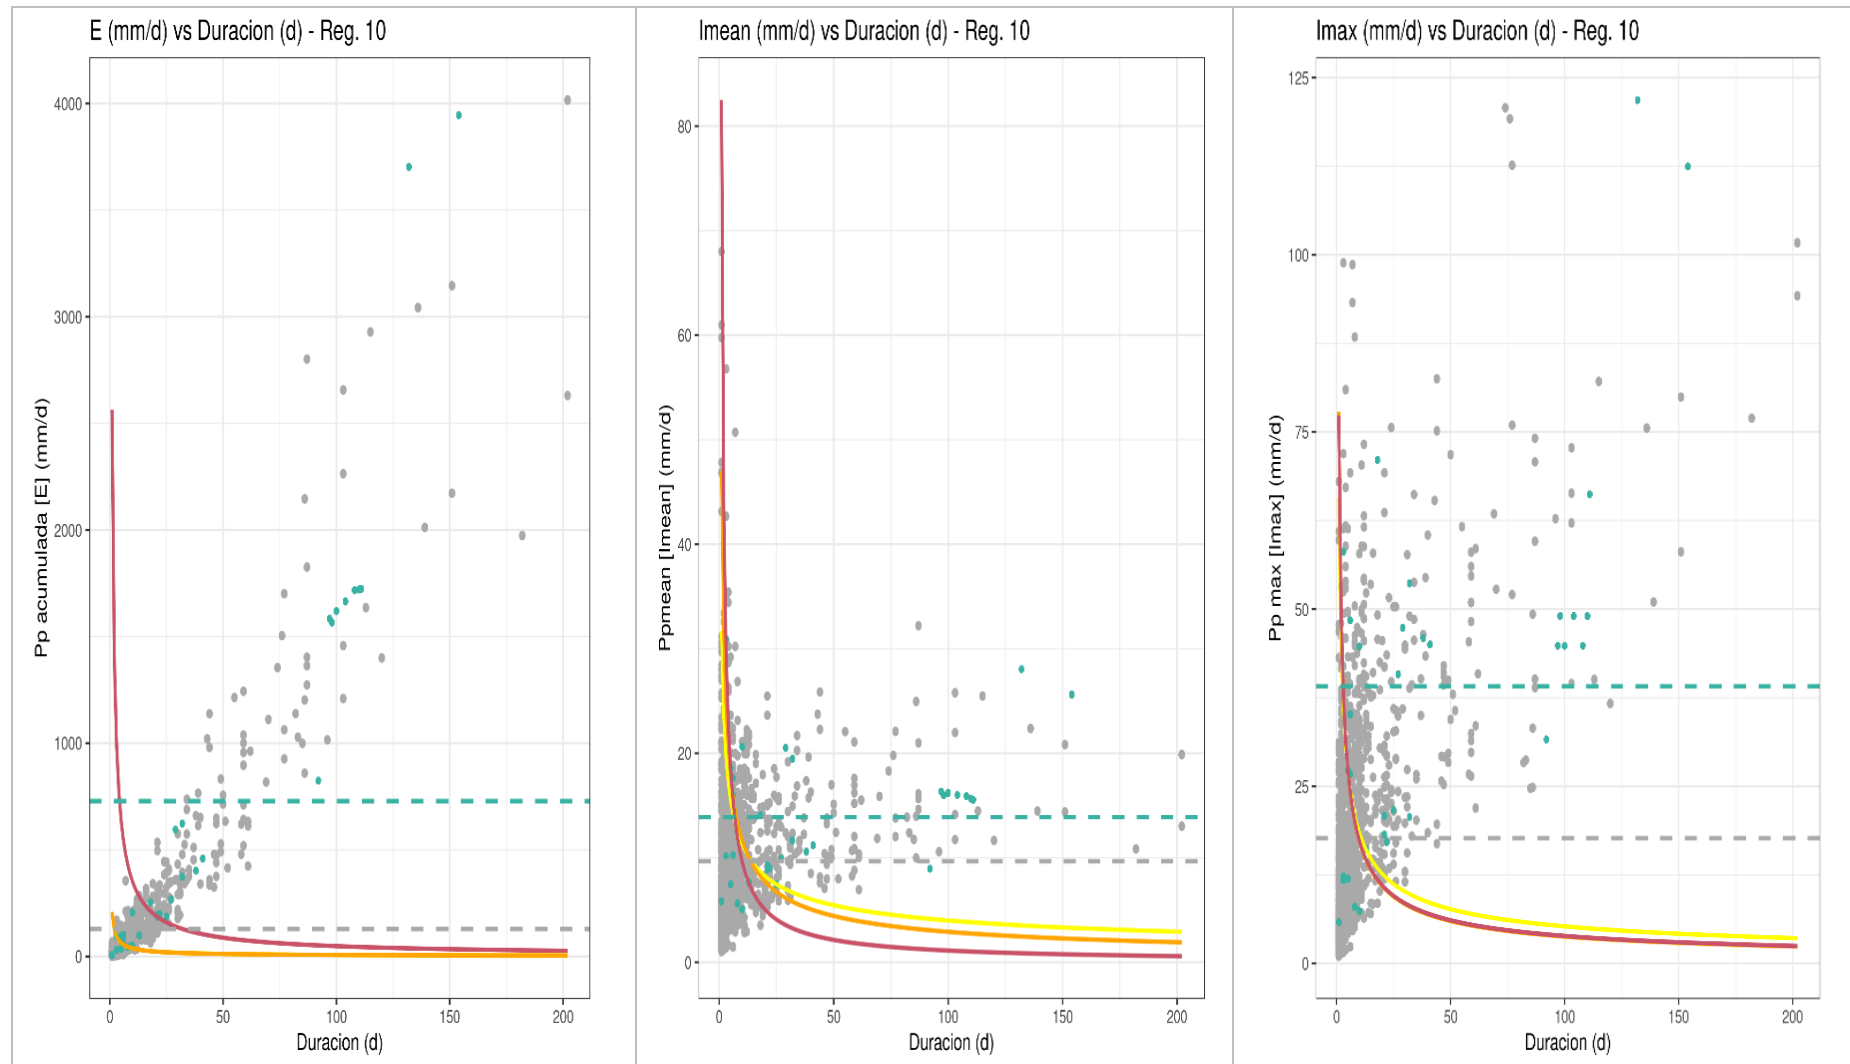


Fig. 14 Gráfico de dispersión de las variables explicativas con los umbrales con mejor rendimiento para el Escenario Entero para la región 10.

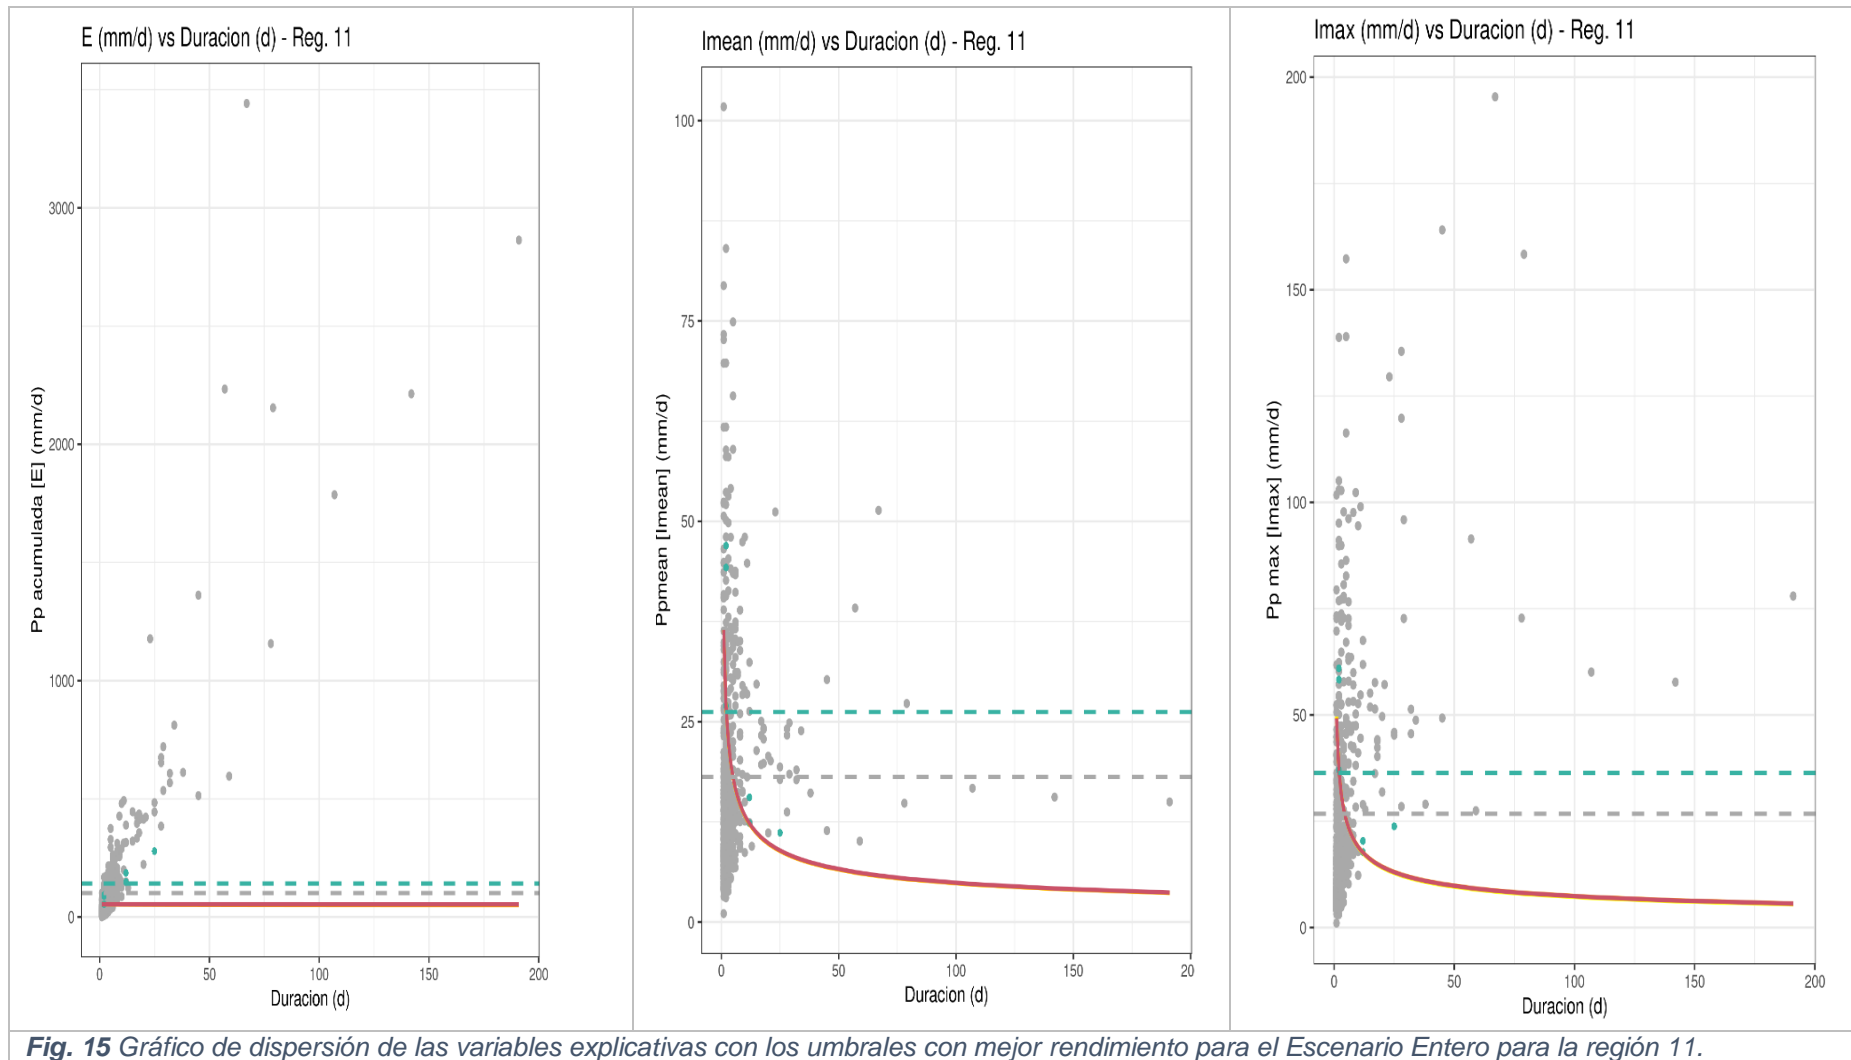


Tabla A.1: Características y variables analizadas de los eventos de lluvias desencadenantes de movimientos en masa

Fecha	ID_Hydro	Nº Evento	I _{max} [mm/d]	E [mm/d]	D [d]	I _{mean} [mm/d]	Class	Cluster	Zero_mod
12/20/2018	75412	172	11.55	51.35	8	6.42	1	6	1.00
1/8/2019	61158	255	58.10	92.82	3	30.94	1	10	4.12
1/18/2019	75099	290	9.26	53.33	11	4.85	1	6	1.00
2/2/2019	53877	264	14.49	102.24	19	5.38	1	4	1.00
1/25/2019	61028	241	11.44	62.89	11	5.72	1	1	1.00
1/23/2019	53678	283	1.28	1.28	1	1.28	1	1	1.00
10/12/2018	75172	263	3.17	7.97	3	2.66	1	6	1.00
10/14/2018	68515	151	11.95	37.28	5	7.46	1	10	1.00
1/25/2019	60983	260	10.57	50.33	11	4.58	1	4	1.00
1/29/2019	92401	141	29.00	85.70	8	10.71	1	2	0.50
2/7/2019	86799	16	0.75	0.75	1	0.75	1	2	0.50
2/7/2019	46214	184	26.83	124.82	12	10.40	1	3	1.03
1/30/2019	75330	202	41.55	401.84	38	10.57	1	6	1.00
2/3/2019	46250	525	20.73	41.10	3	13.70	1	9	1.17
2/1/2019	53904	246	14.52	123.22	18	6.85	1	4	1.00
1/27/2019	61095	391	4.34	4.34	1	4.34	1	4	2.84
2/3/2019	87061	174	38.89	240.75	25	9.63	1	5	1.00
1/22/2019	75074	62	45.03	459.25	41	11.20	1	10	1.00
2/8/2019	80911	228	44.83	564.95	34	16.62	1	5	1.00
2/8/2019	80767	122	8.78	9.83	2	4.92	1	2	0.50
2/9/2019	61048	404	13.28	70.89	10	7.09	1	4	3.22
2/8/2019	87195	93	9.75	25.52	6	4.25	1	7	1.00
2/8/2019	92409	115	17.17	78.07	14	5.58	1	2	0.50
2/6/2019	61047	225	14.19	25.39	4	6.35	1	1	1.00
2/8/2019	80734	92	8.68	9.37	2	4.68	1	2	0.50
2/8/2019	80729	63	8.21	8.21	1	8.21	1	2	0.50
2/7/2019	38440	520	37.43	149.88	10	14.99	1	3	3.58
1/22/2019	61180	579	44.71	206.32	10	20.63	1	10	4.04
11/12/2018	75426	149	3.12	4.30	2	2.15	1	6	1.00
11/25/2018	38462	366	18.75	20.68	2	10.34	1	3	1.86
11/16/2018	61115	279	3.26	11.98	5	2.40	1	4	1.61
2/12/2019	68265	253	5.92	25.58	10	2.56	1	4	1.00
2/22/2018	75478	419	22.25	39.76	3	13.25	1	6	1.00
4/5/2018	38500	381	12.71	53.83	8	6.73	1	3	2.38
3/26/2018	60972	179	15.45	103.48	16	6.47	1	4	1.00
3/10/2018	75441	237	11.99	131.41	19	6.92	1	6	1.00
2/28/2018	75390	161	13.16	117.42	17	6.91	1	6	1.00
2/7/2018	75139	374	1.13	1.13	1	1.13	1	6	1.00
2/15/2018	68245	220	24.62	25.97	2	12.99	1	1	0.50
2/6/2018	46214	168	17.11	34.96	4	8.74	1	3	1.03
12/25/2017	68324	137	16.15	99.26	13	7.64	1	10	2.67

12/20/2017	75330	181	8.44	38.85	9	4.32	1	6	1.00
2/12/2019	38423	390	14.75	22.32	2	11.16	1	3	1.00
4/1/2017	68421	37	121.83	3702.40	132	28.05	1	10	1.00
4/7/2017	60882	186	37.73	852.25	79	10.79	1	4	1.00
4/7/2017	60900	252	3.58	5.01	2	2.50	1	1	1.00
1/7/2019	61355	91	35.16	96.01	6	16.00	1	10	3.43
11/26/2018	46231	159	9.43	22.42	3	7.47	1	3	1.00
2/15/2019	46249	491	31.98	202.94	16	12.68	1	9	1.27
2/14/2019	81041	227	26.50	337.98	33	10.24	1	5	1.00
2/7/2019	86728	32	2.35	2.35	1	2.35	1	2	0.50
2/22/2018	61100	449	15.65	15.65	1	15.65	1	4	2.51
1/15/2019	61100	483	15.69	23.92	3	7.97	1	4	2.51
2/6/2019	86892	147	14.87	26.55	4	6.64	1	7	1.00
2/16/2019	74882	356	16.83	173.43	28	6.19	1	6	1.11
11/16/2018	61281	443	12.26	30.40	3	10.13	1	10	4.41
1/27/2019	92409	115	2.71	4.23	2	2.12	1	2	0.50
1/28/2019	45887	460	1.91	1.91	1	1.91	1	3	1.49
1/28/2019	68215	273	14.73	144.71	21	6.89	1	4	1.00
2/18/2019	74841	304	28.82	387.33	42	9.22	1	4	1.24
3/2/2017	68686	435	26.71	61.54	6	10.26	1	10	2.84
1/6/2015	68572	222	8.64	71.60	16	4.48	1	4	1.03
12/7/2014	75174	274	4.08	8.14	2	4.07	1	6	1.00
10/10/2014	75426	98	22.58	66.41	10	6.64	1	6	1.00
10/25/2014	46167	205	9.17	21.71	3	7.24	1	3	1.44
4/3/2018	75388	207	1.34	1.34	1	1.34	1	6	1.00
3/7/2018	75078	73	45.89	402.27	38	10.59	1	10	1.00
11/13/2018	61384	209	7.99	45.08	8	5.64	1	10	3.27
3/29/2018	60933	259	13.50	49.75	8	6.22	1	4	1.00
3/27/2018	61133	219	10.04	93.76	17	5.52	1	4	1.00
3/27/2018	68324	140	20.66	373.57	32	11.67	1	10	2.67
3/26/2018	75256	205	18.08	261.88	35	7.48	1	6	1.00
3/25/2018	74942	208	44.12	318.65	53	6.01	1	5	1.00
3/23/2018	68557	430	12.11	24.16	2	12.08	1	4	1.24
3/16/2018	81474	201	10.05	135.08	25	5.40	1	8	1.00
2/25/2019	68273	88	2.20	2.20	1	2.20	1	1	0.50
2/23/2019	74976	210	19.43	36.08	5	7.22	1	5	1.00
2/25/2019	75252	217	23.66	509.78	51	10.00	1	6	1.00
1/23/2018	68598	425	14.32	21.59	3	7.20	1	4	1.17
1/23/2018	81141	79	2.22	3.65	2	1.82	1	7	1.00
1/23/2018	81049	163	16.72	25.35	2	12.67	1	5	1.00
1/18/2018	60966	313	9.15	26.12	5	5.22	1	4	2.66
1/15/2018	75415	155	22.39	318.46	33	9.65	1	6	1.00
1/9/2018	75415	155	22.39	259.33	27	9.60	1	6	1.00

1/9/2018	38415	354	32.46	37.20	2	18.60	1	9	3.58
11/29/2017	75518	323	7.27	9.76	3	3.25	1	6	1.00
4/23/2017	68371	30	112.49	3945.05	154	25.62	1	10	1.00
1/3/2018	75199	307	3.50	20.68	9	2.30	1	6	1.00
12/18/2017	75279	169	13.07	47.69	7	6.81	1	6	1.00
4/4/2017	60977	192	30.45	760.23	76	10.00	1	4	1.00
4/3/2017	68289	228	32.69	859.42	85	10.11	1	4	1.00
3/31/2017	60927	152	17.74	491.63	72	6.83	1	4	1.00
2/15/2017	74742	186	13.48	100.43	37	2.71	1	1	0.50
2/7/2017	68303	177	31.00	293.33	30	9.78	1	4	1.00
3/17/2017	68181	256	19.49	118.69	17	6.98	1	4	1.00
2/27/2017	74859	178	35.60	398.05	61	6.53	1	2	0.50
3/28/2017	61133	195	17.96	411.59	78	5.28	1	4	1.00
2/23/2017	68551	243	12.03	62.91	8	7.86	1	4	1.00
3/15/2017	74738	213	31.54	482.67	66	7.31	1	1	0.50
3/15/2017	68270	221	38.79	150.22	9	16.69	1	4	1.00
3/24/2017	75029	185	4.55	19.88	7	2.84	1	2	0.50
3/24/2017	80732	167	10.56	51.71	18	2.87	1	2	0.50
1/17/2017	74738	213	11.79	61.87	9	6.87	1	1	0.50
2/12/2017	74738	213	21.64	249.76	35	7.14	1	1	0.50
3/27/2017	74742	187	10.11	85.66	35	2.45	1	1	0.50
3/21/2017	74742	187	10.11	78.75	29	2.72	1	1	0.50
2/8/2017	68303	177	31.00	300.57	31	9.70	1	4	1.00
2/2/2017	68308	163	17.32	148.85	25	5.95	1	1	1.00
2/8/2017	68172	189	20.50	338.90	43	7.88	1	4	1.00
2/8/2017	68265	223	19.60	224.62	31	7.25	1	4	1.00
2/2/2017	68263	248	4.02	15.66	5	3.13	1	4	1.00
2/17/2017	61107	261	6.78	11.13	2	5.57	1	4	1.59
1/17/2017	74813	216	17.25	62.56	8	7.82	1	4	1.00
1/17/2017	74816	194	27.86	134.95	21	6.43	1	5	1.00
1/17/2017	74799	220	12.34	52.57	8	6.57	1	1	1.00
1/17/2017	74785	236	9.74	43.94	8	5.49	1	4	1.00
1/17/2017	74798	220	14.96	68.37	8	8.55	1	4	1.00
3/14/2019	68461	393	21.66	186.80	25	7.47	1	10	1.00
3/14/2019	68491	163	31.61	824.43	92	8.96	1	10	1.00
3/13/2019	38088	337	25.53	34.92	2	17.46	1	3	1.00
3/12/2019	38471	353	5.15	8.85	3	2.95	1	3	1.00
3/22/2019	75112	61	44.83	1620.16	100	16.20	1	10	1.00
3/19/2019	75112	61	44.83	1583.88	97	16.33	1	10	1.00
3/1/2019	46065	311	17.02	22.03	2	11.02	1	3	1.00
3/2/2019	75251	280	16.37	352.51	56	6.29	1	6	1.00
3/2/2019	46224	346	45.13	74.39	3	24.80	1	9	1.00
3/3/2019	45970	225	11.84	25.49	4	6.37	1	3	1.00

3/3/2019	75330	202	44.10	897.83	70	12.83	1	6	1.00
3/3/2019	75300	262	20.27	511.23	55	9.30	1	6	1.00
3/3/2019	53757	129	12.15	30.40	4	7.60	1	4	1.00
3/3/2019	75293	280	18.51	431.64	55	7.85	1	6	1.00
3/4/2019	75330	202	44.10	902.36	71	12.71	1	6	1.00
3/4/2019	75251	280	16.37	357.70	58	6.17	1	6	1.00
3/7/2019	53519	274	13.44	49.90	8	6.24	1	3	1.00
3/7/2019	68437	94	43.04	1008.30	65	15.51	1	4	1.00
3/13/2019	61100	494	27.32	37.65	2	18.82	1	4	2.51
3/15/2019	46032	251	12.77	37.19	6	6.20	1	3	1.00
3/15/2019	53678	292	5.77	21.16	6	3.53	1	1	1.00
2/8/2019	53612	248	11.63	50.61	9	5.62	1	1	1.00
3/20/2019	75074	62	49.03	1566.17	98	15.98	1	10	1.00
3/20/2019	61073	189	24.84	617.33	76	8.12	1	4	1.22
3/20/2019	53799	285	18.18	186.54	21	8.88	1	10	2.40
3/20/2019	53527	268	16.16	89.61	11	8.15	1	1	1.00
3/21/2019	53873	241	17.11	198.10	22	9.00	1	10	2.36
3/21/2019	81532	298	5.56	24.32	6	4.05	1	8	1.00
3/21/2019	45919	398	28.57	151.57	17	8.92	1	3	1.10
3/24/2019	75427	297	22.91	160.76	20	8.04	1	6	1.00
3/26/2019	75074	62	49.03	1665.08	104	16.01	1	10	1.00
3/27/2019	60974	261	10.54	261.53	54	4.84	1	4	1.53
3/30/2019	75112	61	44.83	1717.61	108	15.90	1	10	1.00
4/1/2019	75074	62	49.03	1721.10	110	15.65	1	10	1.00
4/3/2019	68314	124	11.78	30.41	3	10.14	1	10	2.36
4/3/2019	45829	464	18.77	30.27	3	10.09	1	3	2.11
4/3/2019	46214	186	27.48	45.72	3	15.24	1	3	1.03
4/3/2019	45919	400	16.24	28.08	3	9.36	1	3	1.10
4/3/2019	75254	213	6.28	12.00	4	3.00	1	6	1.00
4/6/2019	54260	356	48.41	105.66	6	17.61	1	10	4.02
10/27/2019	68382	53	40.84	267.91	27	9.92	1	10	1.00
10/30/2019	46035	325	5.37	16.55	4	4.14	1	3	1.00
11/3/2019	80876	197	6.27	17.50	4	4.38	1	6	1.00
12/5/2019	75412	183	9.23	39.49	6	6.58	1	6	1.00
12/6/2019	75469	275	13.96	59.59	6	9.93	1	6	1.00
12/7/2019	38449	439	2.38	2.38	1	2.38	1	3	1.06
12/10/2019	53744	178	5.74	10.35	2	5.17	1	4	1.05
12/4/2019	53905	290	27.24	92.77	5	18.55	1	10	3.49
12/23/2019	75412	183	19.42	168.88	24	7.04	1	6	1.00
12/23/2019	61115	307	13.77	157.19	24	6.55	1	4	1.61
12/23/2019	61121	318	13.12	135.04	24	5.63	1	4	1.12
12/23/2019	60887	364	21.90	75.40	10	7.54	1	1	1.00
10/18/2019	75074	63	71.05	253.61	18	14.09	1	10	1.00

10/20/2019	46236	537	77.19	102.59	5	20.52	1	9	1.00
10/25/2019	75090	99	3.04	3.04	1	3.04	1	6	1.00
10/30/2019	46039	337	7.94	16.15	3	5.38	1	3	1.00
11/10/2019	46036	349	12.05	16.87	2	8.43	1	3	1.00
11/14/2019	74800	288	8.59	50.92	15	3.39	1	4	1.10
1/7/2020	75118	385	18.73	59.24	8	7.41	1	6	1.00
1/1/2020	53843	220	43.69	655.53	36	18.21	1	10	3.69
12/29/2019	53848	298	20.84	195.01	21	9.29	1	10	2.65
12/22/2019	60887	364	21.90	63.70	9	7.08	1	1	1.00
12/24/2019	75101	351	8.78	47.29	13	3.64	1	6	1.00
12/23/2019	68573	211	9.82	75.34	12	6.28	1	4	1.00
12/22/2019	68215	289	9.85	69.09	16	4.32	1	4	1.00
1/6/2020	61367	70	70.55	1704.12	74	23.03	1	10	3.18
1/7/2020	75775	556	59.38	338.95	8	42.37	1	11	12.03
1/3/2020	87076	151	16.30	27.22	3	9.07	1	7	1.00
1/12/2020	46227	149	3.70	3.70	1	3.70	1	3	1.00
1/2/2020	61212	298	63.70	822.12	37	22.22	1	10	4.34
1/20/2020	53938	340	4.16	4.16	1	4.16	1	10	2.48
1/17/2020	81048	231	5.68	22.20	6	3.70	1	5	1.00
1/19/2020	87222	133	15.65	35.41	7	5.06	1	7	1.00
1/21/2020	60887	366	10.80	14.40	2	7.20	1	1	1.00
1/21/2020	87119	120	13.66	29.72	3	9.91	1	7	1.00
1/21/2020	68265	276	11.32	16.81	3	5.60	1	4	1.00
1/21/2020	53947	340	3.63	7.17	2	3.58	1	10	2.69
1/21/2020	53896	230	8.88	30.98	8	3.87	1	4	1.00
1/29/2020	75058	53	67.29	1512.99	121	12.50	1	10	1.00
1/28/2020	80786	23	1.41	1.41	1	1.41	1	2	0.50
1/28/2020	74847	238	18.79	174.86	21	8.33	1	4	1.00
1/22/2020	80874	30	7.20	15.38	4	3.85	1	2	0.50
1/23/2020	68273	91	0.50	0.50	1	0.50	1	1	0.50
1/28/2020	46034	283	19.50	43.13	5	8.63	1	3	1.00
1/28/2020	81295	210	48.90	306.06	17	18.00	1	5	1.00
1/28/2020	75860	228	100.49	651.98	19	34.31	1	8	2.89
1/20/2020	80903	236	18.78	88.79	12	7.40	1	6	1.00
2/1/2020	75282	226	34.63	240.16	24	10.01	1	6	1.00
1/31/2020	74897	246	30.55	222.54	22	10.12	1	5	1.00
2/5/2020	74897	246	30.55	246.61	27	9.13	1	5	1.00
2/7/2020	75419	381	40.65	143.45	8	17.93	1	6	1.00
2/8/2020	74884	344	11.76	42.34	8	5.29	1	6	1.03
2/10/2020	60901	130	31.58	429.55	31	13.86	1	4	2.81
2/9/2020	60978	379	27.06	369.09	30	12.30	1	10	3.48
2/10/2020	75205	243	25.81	255.87	34	7.53	1	6	1.00
2/9/2020	53969	188	9.91	108.18	30	3.61	1	4	1.00

2/24/2020	87135	202	22.85	181.60	17	10.68	1	7	1.00
2/22/2020	87176	97	10.01	15.91	2	7.95	1	7	1.00
2/15/2020	74947	230	26.21	318.55	36	8.85	1	6	1.00
4/1/2020	81088	204	8.73	25.77	5	5.15	1	5	1.00
3/31/2020	61402	352	3.51	3.51	1	3.51	1	4	2.80
3/16/2020	61089	334	2.57	2.57	1	2.57	1	4	1.88
3/27/2020	53848	315	7.99	11.88	2	5.94	1	10	2.65
3/21/2020	80795	227	5.55	18.52	7	2.65	1	2	0.50
3/21/2020	80728	225	2.97	12.41	7	1.77	1	2	0.50
3/12/2020	74928	256	3.94	3.94	1	3.94	1	5	1.00
3/14/2020	86871	41	3.42	4.49	2	2.24	1	7	1.00
3/17/2020	75254	229	14.08	65.17	9	7.24	1	6	1.00
3/16/2020	45919	439	4.31	4.31	1	4.31	1	3	1.10
3/2/2020	60887	375	15.50	40.40	4	10.10	1	1	1.00
3/2/2020	61023	251	9.43	26.96	4	6.74	1	4	1.20
3/2/2020	61088	244	5.33	16.27	4	4.07	1	4	1.06
11/29/2020	75120	283	13.49	36.45	5	7.29	1	6	1.00
11/14/2020	60946	228	12.14	25.82	3	8.61	1	10	3.81
12/2/2020	45859	536	19.52	57.74	4	14.44	1	3	1.77
12/7/2020	75478	509	19.67	93.19	13	7.17	1	6	1.00
12/6/2020	60983	311	17.85	73.73	10	7.37	1	4	1.00
12/11/2020	61190	262	41.04	315.66	16	19.73	1	10	4.27
12/29/2020	86786	162	18.39	39.33	8	4.92	1	7	1.00
12/11/2020	60946	230	51.93	336.78	16	21.05	1	10	3.81
12/25/2020	75266	438	22.11	34.54	6	5.76	1	6	1.00
12/26/2020	61355	115	74.03	786.18	31	25.36	1	10	3.43
12/27/2020	68247	291	21.46	64.99	6	10.83	1	4	1.00
12/28/2020	75743	529	56.68	163.98	4	40.99	1	11	12.96
1/4/2014	69046	99	37.09	53.99	2	27.00	1	11	3.84
4/5/2010	75398	110	60.94	93.92	2	46.96	1	11	4.22
1/9/2011	68895	19	23.81	278.61	25	11.14	1	11	1.00
2/15/2011	75826	102	20.38	186.70	12	15.56	1	11	8.03
3/2/2009	75853	60	17.74	148.34	12	12.36	1	11	6.88
2/15/2011	75320	61	26.69	489.12	45	10.87	1	6	1.00
1/23/2010	75428	106	7.06	76.52	22	3.48	1	6	1.00
4/5/2010	75418	92	58.34	88.49	2	44.24	1	11	2.82
3/9/2012	81111	35	4.64	4.64	1	4.64	1	2	0.50
4/14/2009	53791	62	7.40	50.73	10	5.07	1	10	2.29
10/17/2012	46182	133	40.25	62.71	4	15.68	1	9	1.04
1/23/2010	75427	83	38.88	382.77	38	10.07	1	6	1.00
1/9/2011	53632	88	2.49	5.93	3	1.98	1	4	1.00
4/1/2010	61280	148	5.84	5.84	1	5.84	1	10	3.39
11/19/2014	60929	99	13.07	148.76	24	6.20	1	4	1.00

4/3/2011	75478	176	18.87	72.89	10	7.29	1	6	1.00
1/20/2010	75174	124	12.12	74.78	13	5.75	1	6	1.00
1/23/2010	75443	133	10.58	33.31	4	8.33	1	6	1.00
1/19/2009	68383	6	66.20	1724.16	111	15.53	1	10	1.00
1/20/2014	68597	283	20.61	55.18	7	7.88	1	4	1.29
3/18/2012	75232	92	17.53	160.97	22	7.32	1	6	1.00
1/23/2010	74841	77	15.74	225.12	25	9.00	1	4	1.24
10/17/2010	75443	150	5.19	12.15	4	3.04	1	6	1.00
12/17/2009	75174	120	8.79	15.18	2	7.59	1	6	1.00
2/6/2010	75468	67	18.63	367.07	53	6.93	1	6	1.00
2/9/2010	75468	67	18.63	380.31	56	6.79	1	6	1.00
4/14/2009	53748	31	25.17	275.29	29	9.49	1	4	1.00
3/5/2008	60894	15	47.39	595.21	29	20.52	1	10	3.84
2/2/2007	75428	21	2.78	2.78	1	2.78	1	6	1.00
1/3/2007	61366	2	53.65	623.24	32	19.48	1	10	3.29
3/7/2009	86834	31	11.02	74.22	16	4.64	1	7	1.00
4/11/2008	60921	24	21.36	549.14	71	7.73	1	4	1.00