



UNIVERSIDAD NACIONAL DEL ALTIPLANO
FACULTAD DE CIENCIAS BIOLÓGICAS
ESCUELA PROFESIONAL DE BIOLOGÍA



**FACTORES CLIMÁTICOS, TOPOGRÁFICOS, ANTRÓPICOS Y
DE COMBUSTIBILIDAD QUE DETERMINAN LA OCURRENCIA
Y EXTENSIÓN DE INCENDIOS EN PASTIZALES ALTOANDINOS
DEL DEPARTAMENTO DE PUNO**

TESIS

PRESENTADA POR:

Bach. ANGELA MERCADO PALZA

**PARA OPTAR EL TÍTULO PROFESIONAL DE:
LICENCIADO EN BIOLOGÍA: ECOLOGÍA**

PUNO – PERÚ

2024



NOMBRE DEL TRABAJO

FACTORES CLIMÁTICOS, TOPOGRÁFICOS, ANTRÓPICOS Y DE COMBUSTIBILIDAD QUE DETERMINAN LA OCURRENCIA Y EX

AUTOR

Angela Mercado Palza

RECuento DE PALABRAS

43045 Words

RECuento DE CARACTERES

220311 Characters

RECuento DE PÁGINAS

174 Pages

TAMAÑO DEL ARCHIVO

6.5MB

FECHA DE ENTREGA

Aug 21, 2024 5:23 PM GMT-5

FECHA DEL INFORME

Aug 21, 2024 5:27 PM GMT-5

● **3% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 3% Base de datos de Internet
- Base de datos de Crossref
- 2% Base de datos de trabajos entregados
- 2% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● **Excluir del Reporte de Similitud**

- Material bibliográfico
- Material citado
- Material citado
- Coincidencia baja (menos de 15 palabras)

Mg. Ivon Rocío Gutiérrez Flores
Director de Tesis



UNIVERSIDAD NACIONAL DEL ALTIPLANO - PUNO
FACULTAD DE CIENCIAS BIOLÓGICAS
ESCUELA PROFESIONAL DE BIOLOGÍA

**FACTORES CLIMÁTICOS, TOPOGRÁFICOS, ANTRÓPICOS Y DE
COMBUSTIBILIDAD QUE DETERMINAN LA OCURRENCIA Y EXTENSIÓN
DE INCENDIOS EN PASTIZALES ALTOANDINOS DEL DEPARTAMENTO DE
PUNO**

TESIS PRESENTADA POR:

Bach. ANGELA MERCADO PALZA

PARA OPTAR EL TÍTULO PROFESIONAL DE:

LICENCIADO EN BIOLOGÍA: ECOLOGÍA

APROBADA POR:

PRESIDENTE:

Dr. GILMAR GAMALIEL GOYZUETA CAMACHO

PRIMER MIEMBRO:

Dra. MARTHA ELIZABETH APARICIO SAAVEDRA

SEGUNDO MIEMBRO:

M.Sc. MARISOL ROJAS BARRETO

DIRECTOR / ASESOR:

Mg. IVON ROCÍO GUTIERREZ FLORES

FECHA DE SUSTENTACIÓN: 26/08/2024

ÁREA: Ciencias Biomédicas

SUBLINEA: Conservación y Aprovechamiento de Recursos Naturales



V^oB^o Dra. VICKY CRISTINA GONZALES ALCOS
DIRECTORA DE LA UNIDAD DE INVESTIGACIÓN-FCCBB



DEDICATORIA

A Natura

A quien fui, a quien soy, a quien seré por ti

Angela Mercado Palza



AGRADECIMIENTOS

Mi gratitud a mis Padres Celestiales, terrenales y al planeta que me vio nacer. Por obsequiarme un cuerpo, un espíritu y un propósito. Proveedores de la energía, el tiempo y los recursos invertidos en este proyecto

Naturalmente expreso mi agradecimiento a mi *alma mater* y al CONCYTEC, entidad que permitió el financiamiento de mi tesis bajo el contrato:
N° PE 501082076 – 2023 – PROCIENCIA

A todos los partícipes de esta investigación
Mi agradecimiento, mi afecto

Angela Mercado Palza



ÍNDICE GENERAL

	Pág.
DEDICATORIA	
AGRADECIMIENTOS	
ÍNDICE GENERAL	
ÍNDICE DE TABLAS	
ÍNDICE DE FIGURAS	
ÍNDICE DE ANEXOS	
ACRÓNIMOS	
RESUMEN	18
ABSTRACT.....	19
CAPÍTULO I	
INTRODUCCIÓN	
1.1 OBJETIVO GENERAL	23
1.2 OBJETIVOS ESPECÍFICOS	23
CAPÍTULO II	
REVISIÓN DE LITERATURA	
2.1 MARCO TEÓRICO	24
2.1.1 Incendios en pastizales en Perú y Puno.....	24
2.1.2 Factores que influyen en la ocurrencia y extensión de incendios	25
2.1.2.1 Clima.....	25
2.1.2.2 Combustibilidad.....	26
2.1.2.3 Topografía.....	26
2.1.2.4 Vegetación	27
2.1.2.5 Actividad humana	28



2.2	ANTECEDENTES	28
------------	---------------------------	-----------

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1	ÁREA DE ESTUDIO	33
3.2	DATOS DE LOS INCENDIOS	34
3.3	VARIABLES BIOCLIMÁTICAS	38
3.4	VARIABLES TOPOGRÁFICAS	39
3.5	VARIABLES ANTRÓPICAS	40
3.6	VARIABLES DE VEGETACIÓN	40
3.7	MODELADO Y EVALUACIÓN DE LOS MODELOS DE OCURRENCIA DE INCENDIOS	44
3.7.1	Base de datos.....	44
3.7.2	Modelado de Clasificación Random Forest (RF).....	47
3.7.2.1	Evaluación de los modelos RF.....	49
3.7.2.2	Importancia de los factores empleados en la clasificación RF .	52
3.7.2.3	Selección del mejor modelo de clasificación RF	52
3.7.3	Modelado Lineal Generalizado (GLM).....	53
3.7.3.1	Evaluación de los GLMs.....	55
3.7.3.2	Importancia de los factores empleados en la clasificación GLM binomial	57
3.7.3.3	Selección del mejor GLM binomial.....	58
3.8	MODELADO Y EVALUACIÓN DE LOS MODELOS DE EXTENSIÓN DE INCENDIOS	60
3.8.1	Base de datos.....	60
3.8.2	Modelado Lineal Generalizado (GLM).....	61



3.8.2.1	Evaluación de los GLMs.....	63
3.8.2.2	Importancia de los factores empleados en la regresión GLM gaussiana	64
3.8.2.3	Selección del mejor GLM gaussiano	64

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1	IDENTIFICACIÓN DE LOS FACTORES CLIMÁTICOS, TOPOGRÁFICOS Y ANTRÓPICOS QUE DETERMINAN LA OCURRENCIA DE INCENDIOS EN PASTIZALES ALTOANDINOS DEL DEPARTAMENTO DE PUNO	68
4.1.1	Modelado de Clasificación Random Forest (RF).....	69
4.1.1.1	Selección del mejor modelo de clasificación Random Forest para modelar la ocurrencia de incendios en pastizales altoandinos en el departamento de Puno	74
4.1.2	Modelado Lineal Generalizado (GLM).....	86
4.1.2.1	Selección del mejor GLM binomial para modelar la ocurrencia de incendios en pastizales altoandinos en el departamento de Puno	96
4.1.3	Comparación entre el modelo de clasificación Random Forest, el GLM binomial y el GLM equivalente al modelo RF para modelar la ocurrencia de incendios en pastizales altoandinos en el departamento de Puno.....	113
4.2	IDENTIFICACIÓN DE LOS FACTORES CLIMÁTICOS, TOPOGRÁFICOS, ANTRÓPICOS Y DE COMBUSTIBILIDAD QUE DETERMINAN LA EXTENSIÓN DE INCENDIOS EN PASTIZALES ALTOANDINOS DEL DEPARTAMENTO DE PUNO	118



4.2.1 Selección del mejor GLM gaussiano para modelar la extensión de incendios en pastizales altoandinos en el departamento de Puno	127
V. CONCLUSIONES.....	142
VI. RECOMENDACIONES.....	144
VII. REFERENCIAS BIBLIOGRÁFICAS.....	145
ANEXOS.....	163

ÁREA: Ciencias Biomédicas.

SUBLÍNEA: Conservación y Aprovechamiento de Recursos naturales

FECHA DE SUSTENTACIÓN: 26/08/2024



ÍNDICE DE TABLAS

	Pág.
Tabla 1 Clasificación de las variables consideradas en los modelos de ocurrencia y extensión	45
Tabla 2 Normalización de variables explicativas para el modelado de ocurrencia ..	46
Tabla 3 Clasificación de la exposición topográfica	46
Tabla 4 Variables utilizadas en la modelación de la extensión y la ocurrencia de incendios en pastizales altoandinos en el área de estudio	66
Tabla 5 Resumen de los datos recopilados para el modelado de la ocurrencia de los incendios en pastizales altoandinos en el departamento de Puno (provincias de Melgar, Azángaro y Lampa) para el periodo 2017 - 2023	69
Tabla 6 Variables explicativas e hiperparámetros ajustados empleados en los modelos de clasificación Random Forest para modelar la ocurrencia de incendios ..	70
Tabla 7 Métricas de rendimiento de la selección de modelos de clasificación Random Forest para modelar la ocurrencia de incendios.....	71
Tabla 8 Orden de importancia de las variables explicativas de la base de datos completa empleada en el modelado de ocurrencia de incendios acorde al método RFE	74
Tabla 9 Detalles del modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios.....	75
Tabla 10 Matriz de confusión y métricas de rendimiento del modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios.....	76
Tabla 11 Orden y valores de importancia de las variables consideradas en el modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios	78



Tabla 12	Variables explicativas empleadas en los GLMs binomiales seleccionados para modelar la ocurrencia de incendios.....	86
Tabla 13	Evaluación general de los GLMs binomiales seleccionados para modelar la ocurrencia de incendios.....	88
Tabla 14	Métricas de rendimiento de la selección de GLMs binomiales para modelar la ocurrencia de incendios.....	89
Tabla 15	Resumen del GLM binomial saturado (m1) para modelar la ocurrencia de incendios	92
Tabla 16	Prueba χ^2 del GLM binomial saturado (m1)	93
Tabla 17	Orden de importancia de las variables explicativas del modelo saturado (m1) según el Análisis de Dominancia General y empleando la base de datos completa para modelar ocurrencia de incendios	94
Tabla 18	Coefficientes estimados de los GLMs binomiales más parsimoniosos para modelar la ocurrencia de incendios.....	95
Tabla 19	Valores p (prueba χ^2) de las comparaciones por pares entre los GLMs binomiales seleccionados para modelar la ocurrencia de incendios (pruebas de razón de verosimilitud, Likelihood Ratio Tests o LRT)	96
Tabla 20	Resumen del GLM binomial seleccionado (m5) para modelar la ocurrencia de incendios	99
Tabla 21	Prueba de multicolinealidad del GLM binomial seleccionado para modelar la ocurrencia de incendios.....	102
Tabla 22	Prueba de razón de verosimilitud (Likelihood Ratio Test o LRT) del GLM binomial seleccionado para modelar la ocurrencia de incendios.....	103
Tabla 23	Prueba χ^2	104



Tabla 24	Orden de importancia de las variables explicativas del GLM binomial seleccionado según el Análisis de Dominancia General y empleando la base de datos completa para modelar la ocurrencia de incendios.....	105
Tabla 25	Matriz de confusión y métricas de rendimiento del GLM binomial seleccionado para modelar la ocurrencia de incendios	107
Tabla 26	Resumen del GLM binomial basado en las variables explicativas empleadas en el modelo de clasificación Random Forest (m4).....	114
Tabla 27	Incendios en pastizales altoandinos registrados en 2023 en las tres provincias de estudio y evaluados en el periodo de mayo a diciembre del mismo año	119
Tabla 28	Imágenes satelitales descargadas y ubicación geográfica de los incendios en pastizales altoandinos en las tres provincias de estudio registrados y evaluados en 2023.....	120
Tabla 29	Resumen de los datos recopilados para el modelado de la extensión de los incendios en pastizales altoandinos en el departamento de Puno (provincias de Melgar, Azángaro y Lampa) para el periodo 2017 - 2023.....	121
Tabla 30	Variables explicativas de la selección de GLMs para modelar la extensión de incendios	123
Tabla 31	Evaluación general de los GLMs gaussianos seleccionados para modelar la extensión de incendios	124
Tabla 32	Coefficientes estimados de los GLMs más parsimoniosos para modelar la extensión de incendios	125
Tabla 33	Prueba F incremental	126
Tabla 34	Datos utilizados en el mejor GLM para modelar la extensión.....	128



Tabla 35	Resumen del GLM gaussiano para modelar la extensión de los incendios en pastizales altoandinos en el departamento de Puno	132
Tabla 36	Prueba de multicolinealidad del GLM gaussiano seleccionado para modelar la extensión de incendios	136
Tabla 37	Prueba de razón de verosimilitud (LRT) del GLM gaussiano seleccionado para modelar la extensión de incendios	136
Tabla 38	Prueba F incremental	137
Tabla 39	Orden de importancia de las variables explicativas del GLM gaussiano seleccionado para modelar la extensión de incendios según el Análisis de Dominancia General	138



ÍNDICE DE FIGURAS

	Pág.
Figura 1 Mapa de ubicación del área de estudio	34
Figura 2 Diseño de las parcelas de evaluación de la vegetación	43
Figura 3 Curva ROC del modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios	77
Figura 4 Gráfico de importancia de las variables consideradas en el modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios	79
Figura 5 Mapa de probabilidad de ocurrencia de incendios basado en el modelo de clasificación Random Forest seleccionado	84
Figura 6 Mapa del nivel de riesgo de incendios basado en el modelo de clasificación Random Forest seleccionado	85
Figura 7 La influencia de las variables explicativas del GLM binomial seleccionado para modelar la ocurrencia de incendios.....	98
Figura 8 Los efectos de las variables explicativas del GLM binomial seleccionado para modelar la ocurrencia de incendios.....	101
Figura 9 Gráfico de importancia de las variables consideradas en el GLM binomial seleccionado para modelar la ocurrencia de incendios	106
Figura 10 Curva ROC del GLM binomial seleccionado para modelar la ocurrencia de incendios	108
Figura 11 Mapa de probabilidad de ocurrencia de incendios basado en el GLM binomial seleccionado.....	111
Figura 12 Mapa del nivel de riesgo de incendios basado en el GLM binomial seleccionado.....	112



Figura 13	La influencia de las variables explicativas del GLM gaussiano seleccionado para modelar la extensión de incendios del 2023	130
Figura 14	Los efectos de las variables explicativas del GLM gaussiano seleccionado para modelar la extensión de incendios del 2023	134
Figura 15	Gráfico de importancia de las variables consideradas en el GLM gaussiano seleccionado para modelar la extensión de incendios.....	139



ÍNDICE DE ANEXOS

	Pág.
ANEXO 1 Mapas de ubicación de los incendios considerados en los modelados de la ocurrencia y la extensión de los incendios.	163
ANEXO 2 Distribución de las zonas de riesgo de incendios basadas en el modelo de clasificación Random Forest seleccionado. Áreas y porcentajes de superficie para los distritos de las tres provincias de estudio en el departamento de Puno	164
ANEXO 3 Distribución de las zonas de riesgo de incendios basadas en el GLM binomial seleccionado. Áreas y porcentajes de superficie para los distritos de las tres provincias de estudio en el departamento de Puno.....	166
ANEXO 4 Constancia de ejecución de proyecto.....	168
ANEXO 5 Resolución Administrativa N° D000087-2023-MIDAGRI-SERFOR-ATFFS-PUNO.....	169
ANEXO 6 Autorización para el depósito de tesis en el Repositorio Institucional....	173
ANEXO 7 Declaración jurada de autenticidad de tesis.....	174



ACRÓNIMOS

MINAM:	Ministerio del Ambiente.
MINEDU:	Ministerio de Educación.
MTC:	Ministerio de Transportes y Comunicaciones.
SERFOR:	Servicio Nacional Forestal y de Fauna Silvestre.
SENAMHI:	Servicio Nacional de Meteorología e Hidrología del Perú.
PISCO:	Datos Peruanos Interpolados de las Observaciones Climatológicas e Hidrológicas del SENAMHI (Peruvian Interpolated data of the SENAMHI's Climatological and hydrological Observations).
QGIS:	Sistema de Información Geográfica Cuántica (Quantum Geographic Information System).
SAGA:	Sistema para Análisis Automatizados Geocientíficos (System for Automated Geoscientific Analyses).
GLM:	Modelo Lineal Generalizado (Generalized Linear Model).
RF:	Random Forest.
DEM:	Modelo Digital de Elevación (Digital Elevation Model).
TWI:	Índice de Humedad Topográfica (Topographic Wetness Index).
TPI:	Índice de Posición Topográfica (Topographic Position Index).
DDF:	Frecuencia Acumulada de Días Secos (Dry-Day Frequency).
HDF:	Frecuencia Acumulada de Días Calurosos (Hot-Day Frequency).
RFE:	Eliminación Recursiva de Variables (Recursive Feature Elimination).



RESUMEN

Los incendios de pastizales en el departamento de Puno constituyen una perturbación de origen antrópico cada vez más protagónica en el funcionamiento de estos ecosistemas. Este estudio se llevó a cabo entre agosto del 2023 y enero del 2024 en las provincias de Melgar, Azángaro y Lampa, con el objetivo de identificar los factores climáticos, topográficos, antrópicos y de combustibilidad que determinan la ocurrencia y extensión de los incendios en pastizales altoandinos. Para ello, se recopiló información sobre la ocurrencia de incendios entre 2017 y 2023, se clasificaron imágenes satelitales para determinar la extensión de los incendios ocurridos en 2023, y se descargaron y calcularon variables bioclimáticas, topográficas, antrópicas y de vegetación. Además, se evaluaron cicatrices de incendios ocurridos durante el 2023. Por último, se construyeron modelos de ocurrencia y extensión con el método de aprendizaje automático Random Forest y con Modelos Lineales Generalizados. Los modelos finales obtuvieron un buen ajuste y rendimiento de predicción (AUC: 0.79 y PR^2 : 96 %, respectivamente). Asimismo, se elaboraron mapas de la probabilidad de ocurrencia de incendios. La elevación, la temperatura máxima, el SAVI y el TPI (a 1000 m), determinaron la ocurrencia de incendios en los pastizales altoandinos. Mientras que, la frecuencia acumulada de días calurosos, la cobertura de pastos y roca, la materia seca, la exposición topográfica y el TPI (a 1000 m) determinaron la extensión de los incendios. La identificación de estos factores y la zonificación del riesgo de incendios contribuirá a la aplicación de estrategias de prevención y mecanismos de respuesta más adecuados al área estudiada para evitar los perjuicios a nivel ambiental, económico y social asociados a esta perturbación ecológica.

Palabras clave: Ecología del fuego, Factores ambientales, Factores antrópicos, Modelos, Pastizales altoandinos.



ABSTRACT

Grassland fires in the department of Puno constitute an increasingly important anthropogenic disturbance in the functioning of these ecosystems. This study was carried out between August 2023 and January 2024 in the provinces of Melgar, Azángaro, and Lampa, to identify the climatic, topographic, anthropogenic, and combustibility factors that determine the occurrence and extent of fires in high Andean grasslands. To do this, information was collected on the occurrence of fires between 2017 and 2023, satellite images were classified to determine the extent of fires in 2023, and bioclimatic, topographic, anthropogenic, and vegetation variables were downloaded and calculated. In addition, scars from fires that occurred during 2023 were evaluated. Finally, occurrence and extent models were built using the Random Forest machine learning method and Generalized Linear Models. The final models showed good fit and prediction performance (AUC: 0.79 and PR^2 : 96%, respectively). Fire probability maps were also developed. Elevation, maximum temperature, SAVI, and TPI (at 1000 m) determined the occurrence of fires in high Andean grasslands. Meanwhile, the accumulated frequency of hot days, grass and rock cover, dry matter, topographic exposure, and TPI (at 1000 m) determined the extent of fires. Identifying these factors and the zoning of fire risk will contribute to applying prevention strategies and response mechanisms that are more appropriate to the studied area to avoid the environmental, economic, and social damages associated with this ecological disturbance.

Keywords: Anthropic drivers, Environmental drivers, Fire Ecology, High Andean grasslands, Models.



CAPÍTULO I

INTRODUCCIÓN

El fuego es un importante factor ecológico y evolutivo que influye tanto en la estructura, como en la composición de la biodiversidad, cuyos efectos pueden ser beneficiosos o perjudiciales dependiendo de cómo, dónde, cuándo y por qué ocurren (Berlinck et al., 2021). En consecuencia, los incendios tienen un papel importante en la alteración de las estructuras, procesos y funciones de los ecosistemas terrestres (Li et al., 2023; McLauchlan et al., 2020). Es el régimen del fuego (*i. e.* patrón del tipo de fuego, frecuencia, estacionalidad, intensidad y extensión de los incendios) el que determina los impactos en un ecosistema, sea este sensible o dependiente del fuego (como algunos pastizales que han coevolucionado junto a él) (Bernardi et al., 2019; Pivello et al., 2021). Ello puede representar un creciente desafío social, debido a incendios cada vez más destructivos, o por su exclusión en ecosistemas dependientes (McLauchlan et al., 2020).

La relación que tienen los ecosistemas con los incendios depende de los regímenes naturales del fuego y su alteración (Armenteras et al., 2020), la cual se ha incrementado en las últimas dos centurias por la influencia humana debido, principalmente, a la intensificación y expansión del uso de la tierra y al cambio climático antropogénico (Pivello et al., 2021; Sayedi et al., 2024). Los regímenes alterados suelen producir efectos negativos no solo en la biodiversidad sino también en los procesos y servicios ecosistémicos de los que dependen las poblaciones humanas (Pivello et al., 2021). De esta manera, los incendios en pastizales pueden causar graves daños al sustento de millones de personas (Wang et al., 2023).

Los pastizales han predominado en la zona altoandina a lo largo de siete oscilaciones glaciales-interglaciales. Sin embargo, el ensamble de vegetación moderna de



los pastizales altoandinos es característico de un paisaje modificado por el hombre (Schiferl et al., 2023). A pesar de que los pastizales aún se encuentran entre las coberturas dominantes, estos han ido disminuyendo en el tiempo y está asociado al aumento de las poblaciones humanas (Arizapana-Almonacid et al., 2024). Por otra parte, los incendios en los Andes no fueron frecuentes sino hasta los últimos 12000 años con la presencia humana en el paisaje (Sayedi et al., 2024; Schiferl et al., 2023).

Los expertos han predicho a nivel mundial que no se intensificarán los regímenes de fuego en los ecosistemas de pastizales (Sayedi et al., 2024). Sin embargo, la ocurrencia y extensión de incendios en los Andes peruanos se ha incrementado significativamente en las últimas dos décadas (Armenteras et al., 2020; Zubieta, Ccanchi, Martínez, et al., 2023; Zubieta et al., 2021), afectando a numerosos ecosistemas del país, como los páramos andinos y los matorrales xerofíticos y desérticos (Armenteras et al., 2020). Además, a pesar de que históricamente los incendios son un proceso ecológico importante que actúa sobre los pastizales altoandinos (Bush et al., 2005; Di Pasquale et al., 2008; Rozas-Davila et al., 2023), el fuego tiene un impacto severo en estos, particularmente durante la estación seca (Zubieta et al., 2021). Más aún, la quema de pastizales afecta directa o indirectamente a otros ecosistemas (Ticse-Otarola et al., 2023). Por ejemplo, se ha sugerido que la mayor ocurrencia de estos incendios probablemente ha contribuido al declive de queñuales (género *Polylepis*) (Bush et al., 2005). Por otro lado, el cambio climático que implica mayores temperaturas y menores precipitaciones en los departamentos del sur del país (Servicio Nacional de Meteorología e Hidrología [SENAMHI], 2009; Llacza et al., 2021) estaría asociado a una mayor ocurrencia (Achard et al., 2007) y extensión de los incendios (Parker et al., 2022).

En los Andes peruanos, los cambios observados en el clima y el régimen de incendios tendrán impactos potenciales en la estructura de sus ecosistemas y sus procesos



ecológicos (Zubieta, Ccanchi, Martínez, et al., 2023). La Puna es la principal ecorregión asociada con el riesgo de incendios en la región (Zubieta et al., 2021), los ecosistemas más afectados son los pastizales y entre ellos, el pastizal andino es el tipo de vegetación más amenazada (Manta et al., 2018). Por otra parte, el 80% de ellos ocurre entre los 1500 y los 4000 m s.n.m. (Zubieta et al., 2019). En los últimos años se observan periódicamente incendios en las laderas (Montesinos-Tubée et al., 2021). No obstante, al extremo sur del Perú, las estrategias de conservación y restauración son particularmente escasas para estos ecosistemas pese a su importancia por la provisión de servicios ecosistémicos esenciales (Guzmán et al., 2021). Al 2018, Puno registró incendios en 28 de sus distritos y se encontraba entre los cuatro departamentos que representaban el 80 % del área afectada por incendios a nivel nacional, por lo que fue clasificado en “peligrosidad muy alta” por incendios. De continuar la ocurrencia de incendios, la vegetación andina se verá comprometida, así como la regulación climática e hidrológica afectando el desarrollo socioeconómico y el bienestar de la población del departamento (Manta et al., 2018).

Los avances en las herramientas de teledetección y sistemas de información geográfica (Abdi et al., 2018; Armenteras et al., 2020; Huang et al., 2023; Wang et al., 2023), junto con la aplicación de Modelos Lineales Generalizados (GLM) (Bernardi et al., 2019) y modelos Random Forest (RF) (Jiang et al., 2020; Li et al., 2023; Liu et al., 2019; Lobos y Viviani, 2008; Wu et al., 2023) ha posibilitado a la Ecología del Fuego, estudiar la correlación entre la ocurrencia y extensión de los incendios con los múltiples factores asociados a la vegetación que determinan los regímenes de fuego. Como resultado, es posible realizar predicciones tempranas, mapear zonas de riesgo; y así, mantener el desarrollo sostenible del sector agropecuario, desarrollar sistemas de prevención y gestión de riesgo de desastres y quemadas prescritas (Buthelezi et al., 2016; Huang et al., 2023; Li et al., 2023; Liu et al., 2019; Wang et al., 2023; Wu et al., 2023).



1.1 OBJETIVO GENERAL

Identificar los factores climáticos, topográficos, antrópicos y de combustibilidad que determinan la ocurrencia y la extensión de incendios en pastizales altoandinos del departamento de Puno.

1.2 OBJETIVOS ESPECÍFICOS

- Identificar los factores climáticos, topográficos y antrópicos que determinan la ocurrencia de incendios en pastizales altoandinos del departamento de Puno.
- Identificar los factores climáticos, topográficos, antrópicos y de combustibilidad que determinan la extensión de incendios en pastizales altoandinos del departamento de Puno.



CAPÍTULO II

REVISIÓN DE LITERATURA

2.1 MARCO TEÓRICO

2.1.1 Incendios en pastizales en Perú y Puno

De acuerdo con la definición manejada por el Servicio Nacional Forestal y de Fauna Silvestre (SERFOR, 2024) y en concordancia con la definición de la Corporación Nacional Forestal de Chile (CONAF, 2011), un incendio forestal es aquel fuego de carácter injustificado que quema árboles, arbustos y pastos (materia vegetal viva o muerta que sirve como combustible), que se propaga sin control en zonas rurales y que se constituye un riesgo a los habitantes, el patrimonio y/o el ambiente. En el Perú y otros países de Latinoamérica, a diferencia de otros países, los incendios en este ecosistema no son de origen natural; sino, son de origen antrópico (Scott, 1977; Armenteras et al., 2020).

Una práctica común asociada a la agricultura, es la quema del material seco de la cosecha anterior (Oliveras et al., 2014; Oliver et al., 2017). Así mismo, quienes se dedican a la ganadería suelen quemar los pastizales para aumentar el reverdecimiento y palatabilidad de la vegetación (Kirkpatrick et al., 2011). En el año 2020, se han reportado hasta 2500 y en el 2021 hasta 500 ocurrencias de incendios, siendo las provincias del centro – sur de Puno las más afectadas (Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres [CENEPRED], 2022). Una muestra de ello fue el incendio del 15 de noviembre de 2022 en el distrito de Muñani en la provincia de Azángaro que ocasionó la muerte de 119 vicuñas y la pérdida de 800 ha de pastizales (ROAPUNO, 2022).



El Ministerio del Ambiente registra los incendios a nivel nacional desde el 2000. Por otra parte, un fenómeno que estaría ocurriendo en diversas partes de Latinoamérica, es la migración de la gente rural hacia las ciudades (Aide y Grau, 2004; Grau y Aide, 2007; Carilla y Grau, 2010), posibilitando la recuperación de la cobertura (Grau y Aide, 2007; Fedrigo et al., 2018; Jiménez-Olivencia et al., 2021) y de los herbívoros nativos desplazados por el ganado (Izquierdo et al., 2018; Grau et al., 2020). La disminución del ramoneo por el ganado está posibilitando la acumulación de biomasa (Aráoz y Grau, 2010; Carilla y Grau, 2010; Grau et al., 2020). Además, el cambio climático estaría potenciando la ocurrencia de incendios (Marques et al., 2011), debido al aumento de la temperatura (Michelutti et al., 2015), de la evaporación y la disminución de la precipitación (Wongchuig et al., 2018).

2.1.2 Factores que influyen en la ocurrencia y extensión de incendios

2.1.2.1 Clima

La mayor ocurrencia de incendios está propiciada por mayores niveles de precipitación, particularmente en la estación de crecimiento (Hudak et al., 2004; Aráoz y Grau, 2010; Buthelezi et al., 2016; Abdi et al., 2018; Montti et al., 2021), que implica una mayor generación de combustible (biomasa) (Makhaya et al., 2022), acentuada si la ganadería es restringida (Aráoz y Grau, 2010; Kirkpatrick et al., 2011; Montti et al., 2021). Así mismo, en condiciones de mayor temperatura (Cardille et al., 2001; Achard et al., 2007; Mahdavi, 2012; Buthelezi et al., 2016; Mpakairi et al., 2019; Makhaya et al., 2022), la ocurrencia de incendios es mayor; mientras que la temperatura diaria determina el área del incendio (Abdi



et al., 2018). En condiciones donde la ganadería no es una actividad importante, los incendios básicamente están regulados por el clima (Aráoz y Grau, 2010).

2.1.2.2 Combustibilidad

Los incendios se inician con facilidad y se propagan rápidamente donde hay combustible seco y muerto (Zubieta, Ccanchi, Martínez, et al., 2023). En ecosistemas como los pastizales, la vegetación es altamente inflamable durante la estación seca debido a la disponibilidad de combustible y agentes de ignición (Zubieta et al., 2021). Al fin y al cabo, la carga de combustible de los pastos (es decir su biomasa) los vuelve más susceptibles al fuego (Di Pasquale et al., 2008). A mayor carga de combustible, mayor es la altura e intensidad del fuego, que implica una disminución de la tasa de propagación, debido a una mayor flotabilidad asociada a la combustión de mayores cantidades de biomasa que conduce a llamas más altas y erectas, limitando así el precalentamiento de los combustibles no quemados por la transferencia de calor advectiva y el contacto entre las llamas (Cruz et al., 2018). La combustibilidad o tasa de combustión puede definirse en términos tanto del crecimiento del fuego como del pico de la tasa de liberación de calor (HRR) (Morandini et al., 2019). Por otro lado, la biomasa seca de muestras de vegetación es considerada un indicador de su carga de combustible (Kraaij et al., 2022).

2.1.2.3 Topografía

La elevación, el aspecto, la pendiente y el índice de humedad topográfica (TWI) influyen en la ocurrencia de incendios (Krawchuk et al.,



2016; Makhaya et al., 2022). Algunos estudios, encuentran que la ocurrencia de incendios es mayor en zonas planas o con pendientes suaves (Yang et al., 2007; Abdi et al., 2018); mientras que, otros estudios reportan en zonas de alta pendiente (*e. g.* Murphy et al., 2008; Marques et al., 2011; Oliveras et al., 2014). No obstante, el nivel de predictibilidad de la ocurrencia en sitios planos es muy bajo (Krawchuk et al., 2016). En mayores elevaciones, la ocurrencia de incendios sería mayor en sitios con menor TWI (Krawchuk et al., 2016; Kim et al., 2019). Del mismo modo, sitios de mayor exposición solar (este, noroeste en el hemisferio sur) están asociados a una mayor ocurrencia de incendios (Murphy et al., 2008; Abdi et al., 2018; Mpakairi et al., 2019). Más aún, la topografía propia de un lugar puede facilitar las quemadas (Ticse-Otarola et al., 2023).

2.1.2.4 Vegetación

La composición y biomasa de la comunidad vegetal también son factores influyentes (Mpakairi et al., 2019; Parker et al., 2022). De hecho, en ocasiones, la ocurrencia de incendios está limitado por la cantidad de combustible y no por la falta de desecación (altas temperaturas) (Carilla y Grau, 2010). La respuesta de pastizales de regiones áridas al fuego debe ser evaluada en función a las especies dominantes (Killgore et al., 2009). De este modo, una comunidad dominada por elementos finos (pastos, ramas, ramitas, espesor < 6mm) (Morvan et al., 2009; Buthelezi et al., 2016; Dewar et al., 2021; Parker et al., 2022) y por elementos escleromórficos, cuya naturaleza es pirogénica (Kirkpatrick et al., 2011), está asociado a una mayor ocurrencia de incendios (Sühs et al., 2020). Del mismo modo, elementos vegetales de mayor altura (*e. g.* arbustos o hierbas



leñosas), están asociados a una mayor tasa de propagación, debido a que el alcance vertical del fuego sería mayor (Sühs et al., 2020). En comunidades en las que elementos escleromórficos y pastos no palatables son dominantes, el efecto que puede tener la ganadería sobre la disponibilidad de combustible se reduce (Kirkpatrick et al., 2011).

2.1.2.5 Actividad humana

La densidad poblacional, cercanía a caminos o sitios urbanos, también influyen en la ocurrencia de incendios, pudiendo tener un patrón de distribución aglomerado (Yang et al., 2007) o aleatorio (Pereira et al., 2013). Que el patrón sea aleatorio implica mayores áreas de afectación y una falta de planificación (Pereira et al., 2013). Mayor ocurrencia de incendios en zonas próximas a caminos (Mahdavi, 2012; Abdi et al., 2018) y a centros urbanos (Kim et al., 2019). Sin embargo, la presencia de caminos podría actuar como una barrera en la propagación del fuego (Buthelezi et al., 2016; Dewar et al., 2021).

2.2 ANTECEDENTES

En 2022 el equipo técnico del Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres (CENEPRED, 2022) junto con el Gobierno Regional de Puno (GORE Puno), elaboró un escenario de riesgo por incendios forestales para departamento de Puno. Entre sus componentes, destaca para esta investigación, el mapa de susceptibilidad a incendios forestales con sus respectivos niveles de riesgo. Este mapa es el resultado espacial del modelamiento (por pesos asignados) de los factores condicionantes, climáticos y territoriales, que consideraron. Entre las variables utilizadas en el análisis de susceptibilidad se encuentran: la pendiente, la cobertura vegetal, el clima,



la irradiación, y el registro de ocurrencias y cicatrices. Según el análisis considerado, estas representan los elementos que favorecen o desfavorecen la propagación de los incendios forestales (es decir su extensión). De todos los incendios que emplearon (registros históricos del GORE Puno, INDECI, MINAM y SERFOR), 1348 fueron registrados en las tres provincias consideradas en este estudio para el periodo 2003 – abril, 2022 (704 en Melgar, 350 en Lampa y 294 en Azángaro).

A nivel departamental, el Centro de Operaciones de Emergencia Regional - Puno (COER Puno), en cumplimiento del Plan Regional de Contingencia Ante Incendios Forestales (GORE, 2023) utiliza los parámetros establecidos en la caracterización de incendios forestales registrados en la plataforma GeoSerfor del Servicio Nacional Forestal y de Fauna Silvestre (SERFOR). En esta se encuentra información espacial referida a incendios forestales confirmados, alertas y focos de calor. Asimismo, las alertas del COER se sustentan en la información sobre la materia proporcionada por el Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI) y/o la Comisión Multisectorial Encargada del Estudio Nacional del Fenómeno “El Niño” (ENFEN). A partir del primero, recopilan la información departamental de las Condiciones Atmosféricas Favorables a Incendios Forestales brindadas a nivel nacional por dicho organismo. A partir del segundo, los pronósticos climáticos en base a escenarios de precipitaciones relacionados al evento.

A nivel nacional y desde 2017, el SERFOR brinda datos espaciales e información georreferenciada relacionada con la gestión forestal, incluyendo la referida a incendios forestales a través de un visor geográfico denominado GeoSerfor (plataforma de acceso libre: <https://geo.serfor.gob.pe/visor>). Esta plataforma identifica indicios de fuego activo sobre la cobertura vegetal (focos de calor o anomalías térmicas detectadas por satélites y monitoreos diarios) proveniente de quemas agrícolas o incendios forestales. En base a



ello, la Autoridad Nacional Forestal emite alertas de incendios potenciales cuando los focos se agrupan sobre una zona específica, y posteriormente, proporciona información sobre las áreas afectadas por estos eventos (las extensiones o cicatrices de incendios forestales) (Ponce Vigo, 2021; SERFOR, 2024). A nivel geoespacial, un foco de calor está representado por un píxel de una imagen satelital que manifiesta una temperatura elevada en contraste con los píxeles vecinos. A su vez, la información referente a los focos de calor es recopilada de los sensores VIIRS y MODIS a una resolución de 375 y 1000 m respectivamente (SERFOR, 2019).

Por su parte, el equipo del SENAMHI proporciona información (experimental) sobre las condiciones atmosféricas favorables a los incendios forestales en el país (Aliaga Nestares et al., 2018; SENAMHI, 2020). Este organismo emite periódicamente (diario, semanal y mensual) boletines nacionales y departamentales sobre las condiciones atmosféricas favorables a incendios forestales y el Índice Meteorológico de Incendios (Fire Weather Index o FWI). La información proporcionada está relacionada con la propagación de los incendios forestales; es decir, con su extensión y es el resultado del análisis de información satelital. Así mismo, de radares atmosféricos, estaciones automáticas y convencionales. Sus pronósticos se fundamentan en el monitoreo de la precipitación acumulada en 24 h (mm, en resolución espacial de 5 km), la temperatura máxima y mínima (°C; diaria, diurna y nocturna; en resolución espacial de 2 m), los focos de calor en 24 h (obtenidos de MODIS y VIIRS), los días consecutivos de ausencia de lluvia (≥ 1 mm, ≥ 2 mm y ≥ 5 mm) en el último mes y la humedad relativa a las 13:00 h (%; en resolución espacial de 2 m). Así mismo, en el monitoreo de la velocidad y dirección del viento, la cobertura de nubes; y el contenido de humedad o vapor de agua. En relación con el FWI, este indica el peligro de un incendio forestal en el paisaje en base al estado de la vegetación, su inflamabilidad y factores meteorológicos como la temperatura, el



viento, la precipitación acumulada y la humedad relativa. A su vez, indica la dificultad en su control en función a la intensidad del fuego y la capacidad de respuesta. Este corresponde al pronóstico de la extensión con una proyección de 10 días. Por otra parte, brindan información sobre la probabilidad de un incendio activo a través del producto RGB del satélite GOES-16, representada por puntos (píxeles) de alta temperatura (SENAMHI, 2022).

Román-Cuesta y su equipo publicaron un estudio en 2014 referido a las tendencias de los incendios en la región altoandina tropical para el periodo 1982 – 2006 y que comprendió al ecosistema de Puna del país (Román-Cuesta et al., 2014). La investigación estuvo orientada a examinar, además, el rol de la elevación en el comportamiento de los incendios. De esa manera, en su base de datos consideraron información espacial de la elevación, anomalías de incendios a partir de la Superficie Global Quemada (Global Burned Surface o GBS) y el sensor MODIS (en ausencia de registros nacionales históricos de campo disponibles); y datos climáticos sobre precipitación (mm) y temperatura del aire (°C) para la estación seca, la estación húmeda y para cada año (promedio). Utilizaron modelos lineales mixtos para modelar las anomalías de incendios (su ocurrencia) empleando como variables predictoras a los porcentajes de las áreas sobre los 2000 m s.n.m. con sequía extrema o con temperaturas extremas para cada país en diferentes combinaciones. De forma complementaria, evaluaron la importancia relativa de las variables climáticas. Entre sus hallazgos, no evidenciaron que la elevación tuviera influencia alguna en la actividad del fuego; aunque sí, por parte del clima a través de un patrón periódico de la precipitación. Este patrón mostró, ser el principal factor de las tendencias de los incendios, incluso por encima de las influencias humanas y el ciclo anual/interanual de acumulación de combustible. Adicionalmente, no encontraron una relación significativa entre El Niño - Oscilación del Sur (ENOS) y los extremos de



precipitaciones, pero sí en relación con los extremos de temperatura; así como, la influencia de un forzamiento climático de alta frecuencia en la región.

En otra investigación enfocada en el estudio de la dinámica de las quemadas de biomasa en los Andes tropicales (que incluyó también parte del área de estudio), se evaluaron la ocurrencia y las emisiones brutas derivadas de los incendios suscitados en 2.8 millones de hectáreas de la vertiente oriental de los Andes peruanos, en los departamentos de Cusco, Ayacucho y Puno (Oliveras et al., 2014). El estudio cubrió altitudes sobre los 2000 m s.n.m., en un periodo de 12 años (2000 - 2011). Emplearon modelos digitales de elevación (DEMs), anomalías de incendios del sensor MODIS (ocurrencias) y áreas de cicatrices de incendios de MODIS y Landsat 5 clasificadas por tamaño (extensiones). Asimismo, clasificaron los tipos de vegetación en: bosques montañosos tropicales, pastizales altoandinos, matorrales y áreas agrícolas o degradadas. Por otro lado, recopilaron información relacionada a la variación espacial, estacional e interanual de las precipitaciones a partir de datos satelitales y de 11 estaciones meteorológicas del SENAMHI. Para determinar la relación entre la precipitación y las áreas de las cicatrices aplicaron relaciones no lineales y las siguientes variables anuales: número total de cicatrices, aquellas de gran tamaño (> 100 ha), el área total quemada, el área total quemada por cicatrices de gran tamaño, precipitaciones en la estación húmeda, en la estación seca, precipitación total y la precipitación acumulada en el año anterior. Sus resultados evidenciaron una gran variación interanual e intraanual, siendo la época seca (en particular los meses entre mayo y octubre) la que comprendió el mayor número de incendios, ubicados principalmente en pastizales. Consecutivamente, observaron que el área total de quema disminuyó cuando las precipitaciones se acentuaron.



CAPÍTULO III

MATERIALES Y MÉTODOS

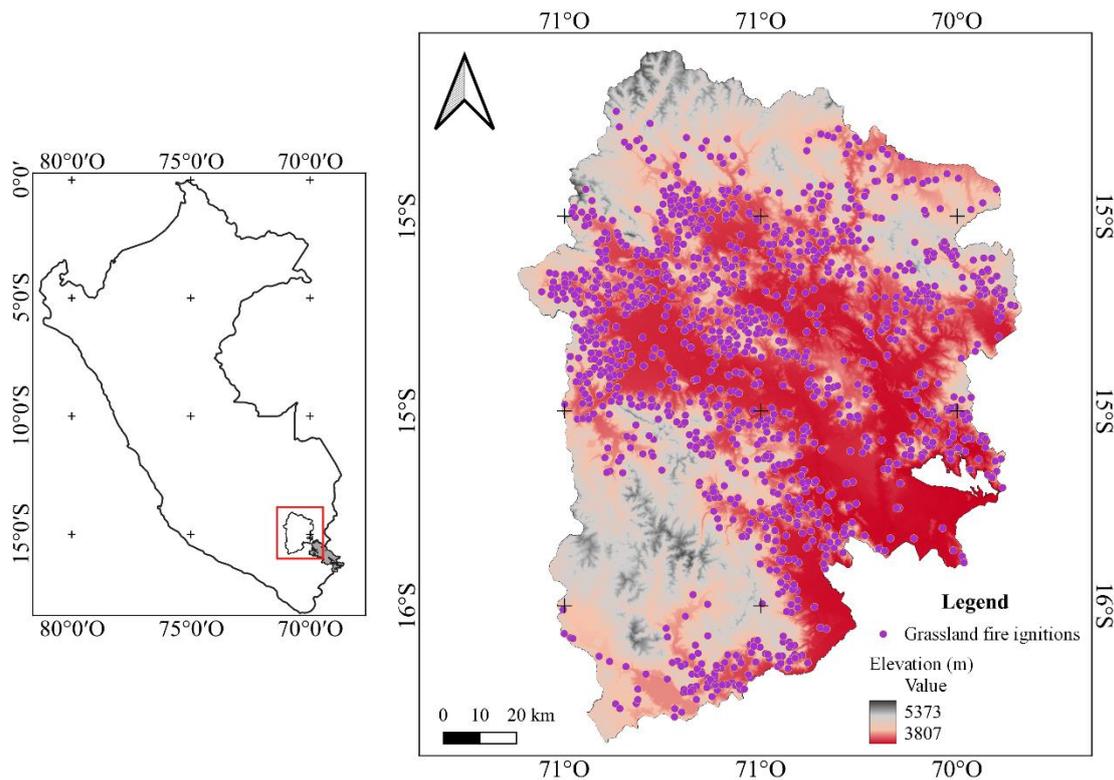
3.1 ÁREA DE ESTUDIO

El estudio comprendió las provincias de importancia ganadera y las que más fueron afectadas por incendios en el departamento de Puno: Melgar, Azángaro y Lampa (Fig. 1). El área de estudio se encuentra entre los 14 a 15° de latitud sur, y entre los 69 a 71° de longitud oeste, y entre los 3800 a 4700 m s.n.m. Cuenta con dos climas de acuerdo al sistema de clasificación climática de Warren Thornthwaite (Thornthwaite, 1948). El clima B (o, i) D'H3, caracterizado por ser un clima semifrío lluvioso, con escasas lluvias en otoño e invierno, con humedad relativa calificada como húmeda; y el clima C (o, i) C'H2, caracterizado por ser un clima semiseco, frío, con escasas lluvias en otoño e invierno y con humedad relativa calificada como seca (SENAMHI, 2021).

Fueron dos los ecosistemas de importancia en el área de estudio: pajonal de puna húmeda y pajonal de puna seca. Las especies que caracterizan a estos ecosistemas son de alta combustibilidad, por componer elementos finos (p. ej. especies de los géneros *Festuca*, *Stipa*, *Jarava*, *Calamagrostis*, *Poa* y *Bromus*); así como, elementos esclerófilos (p. ej. especies de los géneros *Baccharis*, *Parastrephia*, *Margyricarpus* y *Chersodoma*).

Figura 1

Mapa de ubicación del área de estudio



Nota: n (número de incendios): 1270. En el mapa se muestra el gradiente altitudinal y los incendios ocurridos entre el 2017 y 2022.

3.2 DATOS DE LOS INCENDIOS

Para el primer objetivo específico se utilizaron los datos históricos de incendios proporcionados por el Servicio Nacional Forestal y de Fauna Silvestre (SERFOR) y el Ministerio del Ambiente (MINAM), quienes tienen mapeados y georreferenciados los sitios de ocurrencia de incendios. Se descargaron los incendios comprendidos en el periodo del 2017 al 2022. A esto se agregó los 23 incendios evaluados durante el 2023. A través del Software libre QGIS, 4027 puntos de ausencia fueron seleccionados manualmente (utilizando un mapa satelital) de 5000 generados aleatoriamente dentro del área de estudio con la herramienta *Random points* (pseudo-ausencias aleatorias) (Stockwell y Peters, 1999), teniendo en cuenta la eliminación de aquellos puntos que se



ubicaron sobre cuerpos de agua o zonas urbanas (Lobo et al., 2010). Además, se consideró una distancia mínima de 500 m entre los puntos resultantes, estableciendo áreas de influencia (*buffers*) de 354 m de radio para cada uno. Por otro lado, se trabajó con un total 1265 puntos de presencia después de la eliminación de puntos duplicados, considerando las ubicaciones potenciales de ocurrencia de incendios en pastizales y la distancia mínima de 500 m entre ellos.

Para el segundo objetivo específico se utilizaron imágenes satelitales de la misión Sentinel 2 (Satélites Sentinel-2A y Sentinel-2B) con nivel de procesamiento 2A con el fin de identificar y determinar la extensión de los incendios ocurridos en 2023. A pesar de que existen otros sensores que proporcionan información de la ocurrencia de incendios activos (p. ej. MCD14ML, MCD45A1, MCD14DL del sensor MODIS o SUOMI y JPSS-1 de VIIRS), estos tienden a subestimar la cantidad y el área debido a que los incendios en pastizales, al menos históricamente, tienen corta duración y son de pequeña escala (Oliveras et al., 2014; Zubieta, Ccanchi y Liza, 2023). Mientras que, la resolución espacial media del sensor de la misión Sentinel-2, el Instrumento Multi Espectral (MSI) (20 m), posibilita la detección de incendios pequeños y por ende una más precisa estimación de la extensión de las cicatrices. Además, los dos satélites de la misión superan la insuficiente resolución temporal de otros sensores, mitigando la influencia de la predominante cobertura de nubes en los ecosistemas tropicales y la breve permanencia de los indicios de incendios (Roteta et al., 2019). Se trabajó únicamente con imágenes satelitales del 2023, debido a que la evaluación del efecto de la combustibilidad en la extensión de los incendios fue inmediata a su ocurrencia. Asimismo, la recuperación de la cobertura es rápida (Pereira et al., 2013; Vargas et al., 2004; van Gerrevink y Veraverbeke, 2021), perdiéndose los indicios de los incendios para la validación de la clasificación.

A razón de que la mayor ocurrencia de incendios se da entre los meses de junio a setiembre (estación seca) (Oliveras et al., 2014; Buthelezi et al., 2016; CENEPRED, 2022), se obtuvieron, en su gran mayoría, imágenes con bajos niveles de nubosidad para la adecuada clasificación. Las imágenes descargadas correspondientes al área de estudio comprendieron los tiles: T19LBE, T19LBD, T19LBC, T19LCE, T19LCD, T19LCC y T19LDD; que fueron descargados del Navegador del Ecosistema Espacial de Datos del Programa de Observación de la Tierra de la Unión Europea: Copernicus, cada cinco días, correspondientes a la frecuencia de revisita de los satélites (Drusch et al., 2012).

Respecto a la determinación de la extensión de los incendios reportados, se emplearon las imágenes temporalmente más próximas a los eventos para la clasificación. Previa a esta, se realizaron todas las acciones de preprocesamiento en el programa QGIS, *i. e.* la corrección de los valores de reflectancia de cada banda con la *Calculadora Ráster* (división entre 10000) y el apilamiento de ellas con el *Complemento de Clasificación Semiautomática* (SCP) (Congedo, 2021). Sobre las imágenes fueron superpuestos los puntos correspondientes a los incendios reportados, haciendo uso de las coordenadas proporcionadas por los organismos de respuesta de los distritos de las tres provincias de estudio. Por otro lado, los incendios no reportados fueron identificados visualmente tras inspeccionar exhaustivamente las imágenes descargadas utilizando diferentes combinaciones de bandas para la mejor visualización de las cicatrices (en particular la combinación de bandas: 12 – 8A – 4), a través de imágenes georreferenciadas tomadas en campo (incendios no reportados observados durante las evaluaciones *in situ*) o mediante el Índice Normalizado de Quema (Normalized Burn Ratio o NBR) aplicando la siguiente fórmula (NIR, banda 8 y SWIR, banda 12) (Key y Benson, 2006):

$$\text{NBR} = \frac{(\text{NIR} - \text{SWIR})}{(\text{NIR} + \text{SWIR})}$$



Cada imagen satelital procesada fue recortada a $\sim 1/49$ de su extensión, comprendiendo al incendio identificado para la creación de los polígonos de entrenamiento y con el fin de reducir el tiempo de clasificación. Al aplicar diferentes combinaciones de bandas sobre cada imagen (mapas base), fueron consideradas de 6 a 8 clases de entrenamiento, cada una comprendida por 5 a 6 polígonos representativos. Las clases comprendieron a las siguientes categorías de cobertura del suelo: sitios quemados, suelo desnudo (eriazos, barbecho y tierra arada), cuerpos de agua (ríos y lagunas), vegetación (cultivos/pasturas, pastizales, bofedales, vegetación hidrófila y bosques), zonas urbanas, sombras y nubes.

La clasificación de las imágenes satelitales se realizó utilizando el método Random Forest (Cutler et al., 2007; Toro Espín et al., 2015) en el Software libre R *Core Team* versión 4.1.3 (R Core Team, 2022). Para lo cual, los valores asociados a los polígonos (códigos de las clases) fueron transferidos a las celdas ráster de cada imagen. Luego, se extrajeron los valores de los polígonos de entrenamiento rasterizados y se creó un marco de datos a partir de ellos. Este marco se dividió en datos de entrenamiento (80 %) y datos de validación (20 %). Seguidamente, un modelo de clasificación Random Forest fue ajustado con los datos de entrenamiento para modelar las clases considerando a los valores de las bandas como predictoras y omitiendo los valores faltantes en cualquiera de ellas. Posterior a ello, se creó un ráster con las predicciones del modelo ajustado empleando los datos de imagen inicial y se calcularon los valores focales para las celdas adyacentes con la finalidad de obtener una estimación más uniforme de la extensión. Por último, cada clasificación fue validada por medio de la evaluación de las predicciones realizadas empleando los datos de validación. Para ello, se consideraron al Índice Kappa de Cohen, la exactitud global y los valores resultantes de una matriz de confusión. La clasificación se consideró como válida cuando el índice resultó mayor a 0.8

(Sühs et al., 2020). El ráster resultante de la clasificación fue poligonizado en el programa QGIS. Luego, el polígono correspondiente al incendio identificado fue extraído de este resultado y su extensión corregida manualmente. Finalmente, se calculó el área de la cicatriz con la *Calculadora de campos*. Solo los incendios con una extensión mayor o igual a 5 ha, ubicados en pastizales, con la mayor parte de su extensión ubicada fuera de campos de cultivos y sin indicios de corresponder a quemadas intencionadas y controladas (cicatrices con límites bien definidos) fueron considerados en la base de datos y para su posterior evaluación en campo.

3.3 VARIABLES BIOCLIMÁTICAS

Las variables bioclimáticas se descargaron con una resolución espacial de ~ 5 km de la información grillada de PISCO (SENAMHI HSR PISCO) (Aramayo, 2019) que brinda información diaria y mensual de parámetros como: la evapotranspiración potencial, la precipitación, la temperatura máxima y la mínima. A partir de los antecedentes revisados, se trabajó con los siguientes parámetros bioclimáticos: la evapotranspiración potencial (EVAP), la temperatura máxima (TMAX), la Frecuencia Acumulada de Días Secos (DDF) y la Frecuencia Acumulada de Días Calurosos (HDF). Existe evidencia de que estas variables están altamente asociadas con la vegetación y las condiciones que contribuyen a una mayor ocurrencia de incendios; así como, su utilidad para monitorear su aumento potencial (Espinoza et al., 2016; Gutierrez Cori, 2018; Zubieta, Ccanchi, Martínez, et al., 2023; Zubieta et al., 2021).

Con el promedio de los valores pertenecientes a los píxeles de la información grillada de temperatura y precipitación proporcionada por PISCO, se estimó en series temporales anuales y en intervalos de ocho días, la Frecuencia Acumulada de Días Secos (DDF) y la Frecuencia Acumulada de Días Calurosos (HDF), entre el inicio de la época



seca (mayo) y el inicio de la época lluviosa (noviembre), periodo en el que estos parámetros se incrementan gradualmente (Zubieta et al., 2021). De manera que, la DDF corresponde a la frecuencia acumulada de días con precipitaciones inferiores a 1 mm (Chakraborty et al., 2019; Espinoza et al., 2016) y la HDF, a la frecuencia acumulada de días con una temperatura mayor a 20 °C (Zubieta et al., 2021).

Para la evapotranspiración potencial y la temperatura máxima se aplicó el método de interpolación espacial geoestadística *Kriging*, a partir del cual los valores en las celdas ráster de menor escala espacial a la inicial fueron estimados en base a la autocorrelación espacial dependiente de la distancia modelada a partir de los datos existentes (Hoffman et al., 2023). Igualmente, la DDF y la HDF fueron remuestreadas a una escala espacial de ~ 500 m.

3.4 VARIABLES TOPOGRÁFICAS

Se obtuvieron modelos digitales de elevación (DEMs) a partir del satélite ASTER Global DEM de la colección Terra ASTER de la Japan Space System a una resolución espacial de 30 m. En base a la revisión de antecedentes, las variables topográficas que se utilizaron en el modelado fueron: la pendiente, la exposición topográfica, la elevación, el Índice de Humedad Topográfica (TWI) y el Índice de Posición Topográfica (TPI) (Pereira et al., 2013; Makhaya et al., 2022). Este último fue calculado usando píxeles de elevación dentro de los 500, 1000 y 2000 m de radio (Harris y Taylor, 2017), siguiendo el método de De Reu y colegas (2013), en el programa R con el paquete *spatialEco* (Evans, 2015). La pendiente y la exposición topográfica fueron calculadas en el programa QGIS y el TWI, en el Software libre SAGA (Conrad et al., 2015). Igualmente, todas las variables topográficas fueron remuestreadas a una resolución espacial de ~ 500 m.

3.5 VARIABLES ANTRÓPICAS

Las variables antrópicas con las que se trabajaron fueron: la distancia a redes viales, la distancia a centros poblados y la intensidad de pastoreo. Los datos fueron obtenidos de los navegadores del Ministerio de Transportes y Comunicaciones (MTC) (red vial departamental y vecinal) y del Ministerio de Educación (MINEDU) (centros poblados). La información descargada referente a los centros poblados estuvo actualizada hasta el 2 de mayo del 2020. En el caso de las redes viales, la información fue actualizada empleando imágenes satelitales y aéreas de alta resolución del Software libre Google Earth. Para las dos primeras variables se aplicó la distancia euclídea en el programa QGIS con la herramienta *r.grow.distance* del algoritmo GRASS (GRASS Development Team et al., 2024), manteniendo una resolución espacial de 500 m.

Para determinar la intensidad de pastoreo se calculó un índice de abundancia de fecas (densidad de pastadores por densidad de fecas) (Carilla y Grau, 2010). Para ello, se establecieron ocho transectos de 39 m alrededor de cada cicatriz de incendio. En cada transecto se establecieron 20 cuadrantes de 1 m², distanciados entre sí por un metro, en los que se registró la presencia o ausencia de fecas de ganado. Posteriormente se determinó la frecuencia de cuadrantes con presencia de fecas. Los valores resultantes de esta variable para cada incendio evaluado en 2023 correspondieron al promedio del porcentaje de presencia de los ocho transectos.

3.6 VARIABLES DE VEGETACIÓN

Para el primer objetivo específico, la única variable de vegetación que se consideró fue el Índice de Vegetación Ajustado al Suelo (SAVI). Este índice corrige al Índice de Vegetación de Diferencia Normalizada (NDVI) en base a la influencia del brillo del suelo en zonas donde la cobertura vegetal es reducida (Hussain et al., 2023). En

coberturas de pastos sustentadas sobre diferentes fondos de suelo, esta técnica de transformación elimina casi por completo las variaciones inducidas por el suelo en los índices de vegetación (Huete, 1988). De esta manera, proporciona resultados más confiables al minimizar la influencia de los efectos del suelo teniendo en cuenta la reflectancia de fondo (Ku et al., 2023), siendo el índice de vegetación más apropiado para el ecosistema estudiado. El índice SAVI es un indicador de la biomasa de la vegetación y es utilizado para la cartografía, modelamiento y determinación de la carga de combustible y la estimación del riesgo de incendios (Bao et al., 2022; Liu et al., 2023; Sánchez Rodríguez et al., 2000).

El índice SAVI fue calculado para el periodo comprendido entre 2017 y 2023 a partir de datos de reflectividad (producto MOD09A1) de 215 imágenes del sensor MODIS del satélite Terra (Vermote, 2021). Para ello, se utilizaron las bandas NIR (banda 2) y RED (banda 1) del sensor MODIS. El factor de corrección del brillo del suelo (L) utilizado fue 0.5, que corresponde a una densidad de vegetación intermedia y a la mayoría de tipos de cobertura terrestre. Se aplicó la siguiente fórmula (Huete, 1988; Ku et al., 2023):

$$\text{SAVI} = \frac{(\text{NIR} - \text{RED})}{(\text{NIR} + \text{RED} + L)} \times (1 + L)$$

A razón de que el segundo objetivo específico contempló el efecto de las características de la vegetación en la extensión de los incendios, se realizaron evaluaciones de campo en 23 sitios quemados correspondientes a los incendios identificados en 2023. Para ello, alrededor de cada cicatriz se establecieron cuatro parcelas de 30 m² (resolución próxima a la de las imágenes satelitales) (Delcourt et al., 2021; van Gerrevink y Veraverbeke, 2021), que fueron ubicadas en lugares homogéneos, orientadas hacia los cuatro puntos cardinales y distanciadas por al menos 30 m del sitio



quemado. Asimismo, fueron ubicadas a más de 100 m de cualquier camino o vía de acceso. Para ello, se estableció anticipadamente su ubicación a través de imágenes satelitales de la misión Sentinel 2 o el Software Google Earth, la cual fue validada en campo registrando las coordenadas geográficas en el centro de cada una.

Con el objetivo de muestrear la vegetación graminoide y arbustiva; así como, para documentar las coberturas del suelo y la composición de la vegetación por medio de la determinación de las coberturas de las principales formas de vida, se aplicó el método Punto de Intercepción por tratarse de un método de muestreo objetivo y no-destructivo de la cobertura (Bonham, 1989; Drezner y Drezner, 2021). En concordancia con este método, en el contorno de cada parcela y a cada 1 m de distancia, se registraron los siguientes tipos de coberturas: pastos, hierbas, hierbas leñosas, suelo desnudo, roca y hojarasca. A partir de estos registros se calculó el porcentaje de intercepciones de cada tipo de cobertura (Drezner y Drezner, 2021). Por otro lado, también fue registrada la altura de los individuos observados con este método (Caratti, 2006). Se trabajó con el promedio de las cuatro parcelas para el modelado de la extensión.

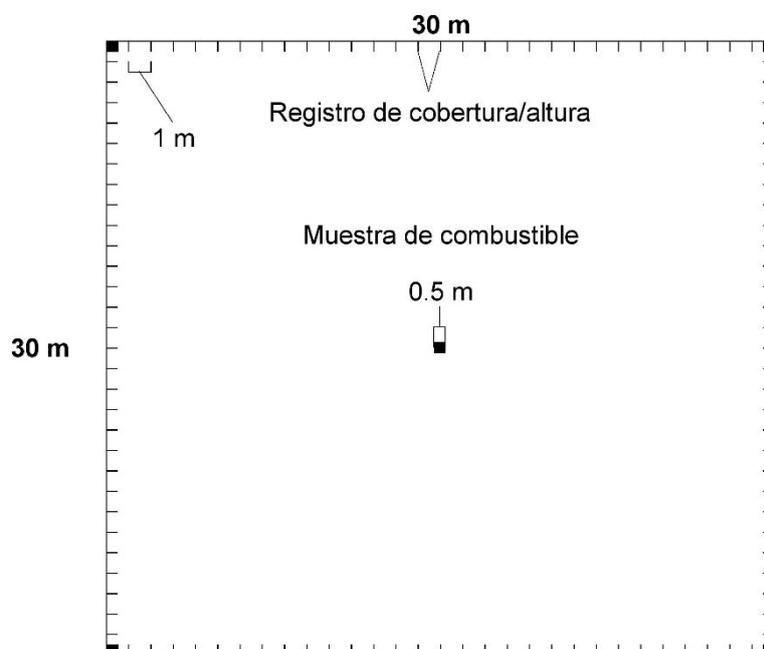
Para la determinación de la carga de combustible se establecieron cinco cuadrantes de 0.5 m² en los vértices y en el centro de cada parcela (Fig. 2). Seguidamente, se recolectó la biomasa aérea, cortando al ras del suelo toda la vegetación comprendida dentro de cada cuadrante. Las muestras fueron almacenadas en bolsas de papel rotuladas para su posterior limpieza y estimación de la materia seca. Luego, se calculó el peso promedio de los cinco cuadrantes de cada parcela. Los promedios de las cuatro parcelas de cada incendio evaluados fueron agregados a la base de datos para el modelado.

La limpieza de cada muestra de vegetación consistió en primer lugar, en la identificación de especies leñosas y/o de la fracción de la muestra con un porcentaje

elevado de celulosa o lignina. Seguidamente, la muestra fue preparada mediante la limpieza de la materia vegetal por métodos gravimétricos (tamizado y precipitación) para la remoción de partículas de suelo, fecas y tejido radicular (mediante cortes). Luego fueron clasificadas, en bolsas de papel rotuladas y codificadas, acorde a la forma de vida predominante: muestras con contenido exclusivamente herbáceo (principalmente gramíneas), para su secado a 90 °C x 24 h y muestras que incluían plantas leñosas o con un alto porcentaje de celulosa o lignina, para su secado a 90 °C x 48 h. Todas fueron colocadas en estufas de secado (Thelco 17 - Precision Scientific - 13-U-10 y Estufa universal UN110plus - Memmert) para finalmente determinar el peso de la materia seca en balanzas digitales (Electronic Scale-TM-JFDBS00003-300G, precisión: 0.001 g, Japón; XY-20002C-BOECO-17010295, precisión: 0.01 g, Alemania; CQT2601-Adam Equipment, precisión: 0.1 g, EE.UU.) cuando se alcanzó el peso seco estable o el equilibrio del peso.

Figura 2

Diseño de las parcelas de evaluación de la vegetación



Nota: Empleadas en la evaluación de la cobertura, altura de la vegetación y combustibilidad.

3.7 MODELADO Y EVALUACIÓN DE LOS MODELOS DE OCURRENCIA DE INCENDIOS

3.7.1 Base de datos

Con el fin de lidiar con el sesgo en la clasificación a causa de la frecuente sensibilidad que tiene los clasificadores para detectar la clase mayoritaria (1265 puntos de pseudo-ausencia) sobre la clase minoritaria (1265 puntos de presencia), se pre-procesó la base de datos desbalanceada antes de emplearla en el modelado. Este preprocesamiento consistió en el balanceo por submuestreo de la clase mayoritaria (en este estudio, las pseudo-ausencias).

Al tratarse de una variable de respuesta binaria (Presencia/Ausencia), se optó por la clasificación Random Forest para el modelado de la ocurrencia de incendios; y con la finalidad de realizar un análisis comparativo, adicionalmente se construyeron modelos lineales generalizados binomiales (regresiones logísticas). En primer lugar, se realizó el apilamiento de las imágenes ráster correspondientes a las 14 variables explicativas consideradas. Luego, se extrajeron los valores de las celdas ráster donde se superpusieron los puntos de ausencia y presencia. Con los valores resultantes y los propios valores de presencia/ausencia (variable categórica: 1/0) se creó un marco de datos, del cual se omitieron los valores faltantes. En base al marco resultante, se realizó la descripción estadística de los datos obtenidos.

Tabla 1

Clasificación de las variables consideradas en los modelos de ocurrencia y extensión de incendios en pastizales altoandinos en el departamento de Puno

Variable explicativa	Factor	Variable respuesta
Temperatura máxima diaria y mensual	Bioclimático	Ocurrencia Extensión
Frecuencia Acumulada de Días Secos		
Frecuencia Acumulada de Días Calurosos		
Evapotranspiración potencial diaria y mensual		
Pendiente	Topográfico	Ocurrencia Extensión
Exposición topográfica		
Elevación		
Índice de Humedad Topográfica		
Índice de Posición Topográfica a 500 m		
Índice de Posición Topográfica a 1000 m		
Índice de Posición Topográfica a 2000 m	Vegetación y combustibilidad	Ocurrencia/ Extensión
Índice de Vegetación Ajustado al Suelo (SAVI)		
Cobertura de pastos		
Cobertura de hierbas		
Cobertura de hierbas leñosas		
Cobertura de suelo desnudo		
Cobertura de roca		
Cobertura de hojarasca		
Altura de la vegetación		
Materia seca (combustible)		
Distancia a caminos/redes viales	Antrópico	Ocurrencia Extensión
Distancia a Centros Poblados		
Intensidad de pastoreo		

La base de datos para el modelado de la ocurrencia de incendios estuvo compuesta por 14 variables explicativas: cuatro variables bioclimáticas, siete variables topográficas, una variable de vegetación y dos variables antrópicas (Tabla 1). Todas las variables, excepto la exposición topográfica y el índice SAVI, fueron normalizadas a fin de evitar las diferencias en dimensión, magnitud y rango de variación, para balancear su contribución en los modelos de ocurrencia (Tabla 2). A pesar de que, el algoritmo Random Forest no requiere de la estandarización o normalización de los datos empleados en la clasificación, debido a que es insensible al rango de valores de las variables explicativas (Wall et al., 2021; Yu et al., 2019), la clasificación con datos normalizados también puede evidenciar resultados precisos y un alto desempeño (Alsubai, 2023; Ong et al., 2022).

Tabla 2

Normalización de variables explicativas para el modelado de ocurrencia

Fórmula	Descripción	Variables que se transformaron
$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$	Normalización Min-Max (0 - 1): x_i y x_i^* , los valores de las variables antes y después de la normalización, respectivamente.	Temperatura máxima DDF HDF Evapotranspiración Elevación
	x_{\max} y x_{\min} , el valor máximo y mínimo de todo el conjunto de datos de cada variable, respectivamente.	TPI TWI Distancia a centros poblados Distancia a redes viales
$x_\alpha = \text{sen}\alpha$	α , el valor de la pendiente	Pendiente

Asimismo, la exposición topográfica fue clasificada en cuatro clases de aspecto de la pendiente (Xu et al., 2023). De este modo, las pendientes orientadas al norte y al noreste representaron un aspecto soleado; las orientadas al este y noroeste, un aspecto semisoleado; las orientadas al sureste y oeste, un aspecto semisombreado; y las orientadas al sur y suroeste, uno sombreado (Tabla 3).

Tabla 3

Clasificación de la exposición topográfica

Aspecto de la pendiente	Grados	Clase de aspecto
Soleado	0 – 67.5, 337.5 – 360	1
Semisoleado	67.5 – 112.5, 292.5 – 337.5	2
Sombreado	157.5 – 247.5	3
Semisombreado	112.5 – 157.5, 247.5 – 292.5	4



3.7.2 Modelado de Clasificación Random Forest (RF)

La clasificación consistió en la creación de un nuevo marco de datos con variables seleccionadas y su subsiguiente partición, en datos de entrenamiento (80 %) y datos de validación (20 %) (Validación Cruzada con cinco iteraciones). En el modelado de la ocurrencia de incendios se usaron los datos de entrenamiento, ajustando tres hiperparámetros: *n_{tree}* (número de árboles), *m_{try}* (número de variables seleccionadas aleatoriamente en cada división) y *nodesize* (número mínimo de observaciones incluidas en cada nodo terminal). Seguidamente, en la determinación del orden de importancia de las variables que conformaron el modelo y para su evaluación con métricas de rendimiento sobre las predicciones realizadas, se emplearon los datos de validación.

La selección de variables explicativas estuvo fundamentada en la Eliminación Recursiva de Variables (Recursive Feature Elimination o RFE). Este método constó en la eliminación secuencial de las variables o características menos relevantes para el modelado en base a una medida de importancia. En este estudio, la medida de importancia general considerada para las variables explicativas fue la Disminución Media de la Exactitud (Mean Decrease Accuracy o MDA). De esta manera, para la construcción del primer modelo se tomaron en cuenta a todas las variables explicativas para la clasificación (modelo saturado) y una vez ajustados sus hiperparámetros se promediaron los órdenes de importancia de las variables de cinco iteraciones de Validación Cruzada empleando los datos de entrenamiento. La variable explicativa que ocupó el último lugar en el orden promediado no fue considerada en la construcción del segundo modelo. Se siguió esta secuencia hasta que la ocurrencia fue modelada con una sola variable explicativa.



Los hiperparámetros considerados fueron ajustados con el fin de mejorar el desempeño de la clasificación (métricas de rendimiento) y proporcionar aleatoriedad al algoritmo. En primer lugar, se ajustó el tamaño de nodo (*nodesize*), luego el número de variables (*mtry*) y finalmente el número de árboles (*nree*). El rango de valores para el tamaño mínimo que debe tener un nodo para dividirse (estructura de cada árbol individual) se estableció de 1 a 10, siendo 1 el valor por defecto para la clasificación. Se tomaron en cuenta las siguientes consideraciones prácticas para el ajuste del *nodesize*: fijar valores altos en presencia de una gran cantidad de variables de ruido y una amplia base de datos; y fijar valores bajos cuando el *mtry* también adquirió valores bajos. El rango de valores para el número de variables consideradas en cada división (nivel de aleatoriedad) se estableció a partir de la raíz cuadrada del número total de variables que conformaron cada modelo. Siendo la raíz cuadrada de las variables consideradas el valor por defecto para la clasificación. Se tomó en cuenta lo siguiente para el ajuste del *mtry*: fijar valores altos en presencia de una gran cantidad de variables relevantes; y fijar valores bajos cuando el modelo estuvo conformado por un número reducido de ellas, entre otras menos relevantes o de ruido. Respecto a la estructura y tamaño de cada *bosque*, se estableció un rango de 50 a 10000 árboles. Para el ajuste del *nree*, los valores más altos fueron preferidos en todos los casos. Concretamente, la selección del *nodesize* y el *mtry* estuvo sustentada en análisis de compensaciones (*tradeoffs*) de las métricas de rendimiento resultantes de cada modelo. Por otro lado, la selección del *nree* se sustentó en la estabilidad de los órdenes de importancia de las variables explicativas. Los hiperparámetros para la construcción del modelo base tomaron los valores de uno. De esta manera, estuvo



compuesto de un árbol de decisión individual lo suficientemente largo para representar el sesgo más bajo y a la vez, la máxima aleatoriedad.

Adicionalmente, se aplicó un análisis de correlación de Pearson entre todas las variables explicativas y la variable binaria de respuesta con la finalidad de tener una visión general de la importancia de los factores, estableciendo un orden por significancia ($p < 0.05$). Asimismo, uno de los enfoques considerados para evidenciar la multicolinealidad, fue aplicar el mismo análisis entre las variables explicativas. A partir de los valores de correlación resultantes este último análisis, se calculó una matriz de distancias y un subsiguiente agrupamiento (clúster) jerárquico aplicando el método de Ward. Posteriormente, se creó un dendrograma para la visualización de las agrupaciones. Las variables que guardaron una correlación entre sí, mayor o igual a 0.6 conformaron grupos de alta correlación. Así mismo, con la finalidad de contrastar los resultados obtenidos de la prueba de multicolinealidad basado en el Factor de Inflación de la Varianza Generalizada (Generalized Variance Inflation Factor o GVIF), también se calcularon los valores del Factor de Inflación de la Varianza (Variance Inflation Factor o VIF) de las variables empleadas en la construcción del modelo final.

3.7.2.1 Evaluación de los modelos RF

Los modelos fueron evaluados empleando el 20% de los datos y mediante el método de Validación Cruzada. Además, con la aplicación de modelos Random Forest, se obtuvo una estimación insesgada del error de generalización (Out-of-bag - OOB). El estimado OOB de la tasa de error o la tasa de error de la predicción (Liaw y Wiener, 2002) que corresponde al error medio para cada observación calculado con las predicciones de los

árboles que no contuvieron dicha observación en su respectiva muestra *Bootstrap* (Hastie et al., 2009); así cómo, el promedio de las tasas de error por clase para cada modelo se obtuvieron de los datos de entrenamiento.

Por otro lado, cada modelo fue evaluado con métricas de rendimiento sobre las predicciones realizadas empleando los datos de validación. Lo cual conllevó, en primer lugar, a la creación de matrices de confusión y a partir de esta tabulación cruzada de clases observadas y predichas que reflejó el rendimiento de la predicción, se obtuvo la tasa de verdaderos positivos (VP) o los puntos de presencia correctamente clasificados, la tasa de verdaderos negativos (VN) o las ausencias correctamente clasificadas, la tasa de falsos positivos (FP) o los puntos de ausencia incorrectamente clasificados como puntos de presencia y la tasa de falsos negativos (FN) o las presencias incorrectamente clasificados como puntos de ausencia. Las métricas de desempeño consideradas en este estudio fueron calculadas empleando dichos valores y las siguientes fórmulas:

- a. Sensibilidad = $\frac{VP}{VP + FN}$
- b. Precisión = $\frac{VP}{VP + FP}$
- c. Puntaje F1 = $\frac{2 \times \text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$
- d. Especificidad = $\frac{VN}{VN + FP}$
- e. Exactitud = $\frac{VP + VN}{VP + VN + FP + FN}$
- f. Tasa de error de los positivos = $\frac{FP}{FP + VP}$
- g. Tasa de error de los negativos = $\frac{FN}{FN + VN}$



$$h. \text{ Tasa de falsos positivos} = \frac{FP}{FP + VN} = 1 - \text{Especificidad}$$

La sensibilidad correspondió a las presencias correctamente clasificadas; la precisión, a la correcta clasificación del total de observaciones clasificadas como presencias; el puntaje F1, a la media armónica de la precisión y la sensibilidad; la especificidad, a las ausencias correctamente clasificadas y la exactitud, al total de observaciones correctamente clasificadas. Entretanto, el Área Bajo la Curva (AUC) ROC (Característica Operativa del Receptor) de cada modelo fue calculada con las correspondientes tasas de verdaderos positivos (sensibilidad) y falsos positivos (inversa de la especificidad). El valor AUC-ROC correspondió a la probabilidad de que el modelo de clasificación obtenga una puntuación mayor para una presencia extraída al azar que para una ausencia extraída al azar (Sing et al., 2005). Por otro lado, el AUC-ROC para un clasificador aleatorio toma el valor de 0.5. Se prefirieron los valores más altos para todas las métricas consideradas en la comparación de modelos.

El orden de las métricas de rendimiento de interés respondió principalmente, a la correcta predicción de las presencias; así como, al costo asociado a los falsos negativos y a los falsos positivos. De modo que, la sensibilidad fue la métrica más relevante para la evaluación de los modelos, seguida de la precisión, el puntaje F1, la especificidad, la exactitud, el valor AUC-ROC y el estimado OOB de la tasa de error. Con el objetivo de comparar los modelos ajustados y seleccionar de entre ellos a los cinco mejores, se aplicaron análisis de compensaciones para las



métricas de rendimiento promediadas de cinco iteraciones de Validación Cruzada de cada modelo siguiendo este orden.

3.7.2.2 Importancia de los factores empleados en la clasificación RF

Para evaluar la influencia relativa de los factores determinantes en la ocurrencia de los incendios, se reportó la importancia de las variables como la disminución media de la exactitud en la predicción de la variable respuesta que resultó cuando una variable determinada se permutó en el modelo (diferencias del estimado OOB de la tasa de error promediadas en todos los árboles). De esta manera, mediante la disminución media de la exactitud se estableció el orden de importancia general a partir del orden de eliminación o la permanencia de una determinada variable a lo largo del proceso de selección RFE. Mientras que, el orden de importancia de las variables que conformaron el modelo final se sustentó en el promedio de los valores normalizados de importancia de permutación de 100 iteraciones de Validación Cruzada.

3.7.2.3 Selección del mejor modelo de clasificación RF

De acuerdo con el orden de importancia de las variables explicativas, la selección de modelos de clasificación RF fue dividida en dos grupos: modelos de clasificación con variables de ruido y modelos de clasificación sin variables de ruido, tomando en cuenta como umbral la última variable de importancia no correlacionada con la subsiguiente (en orden creciente de importancia, como control de la multicolinealidad del método RFE), comprendiendo el subconjunto de variables más informativo y parsimonioso.

Una vez dividida la selección, el mejor modelo de clasificación RF fue seleccionado del grupo de modelos sin variables de ruido mediante un análisis de compensación, acorde al orden de las métricas de rendimiento de interés de cada modelo y en correspondencia con alguno de los cinco mejores modelos del análisis de compensación general. Asimismo, mediante el apilamiento de las imágenes ráster correspondientes a las variables que conformaron el modelo final y la predicción espacial a partir de las imágenes apiladas y el modelo, se creó un mapa de probabilidad de ocurrencia con los valores predichos resultantes. Adicionalmente, se clasificaron las zonas de riesgo utilizando los siguientes rangos de probabilidad de ocurrencia: 0 a 0.25 (*bajo* riesgo), 0.25 a 0.50 (riesgo *moderado*), 0.50 a 0.75 (*alto* riesgo) y 0.75 a 1 (*muy alto* riesgo).

3.7.3 Modelado Lineal Generalizado (GLM)

Se construyeron modelos lineales generalizados (Generalized Linear Models o GLMs) binomiales para el modelado de la ocurrencia de incendios, debido a que manejan bien relaciones no lineales entre una variable respuesta y variables explicativas o predictoras. Además, a partir de ellos también se pudo identificar la importancia de estas variables en la ocurrencia de incendios.

Al igual que la clasificación anterior, la clasificación GLM binomial consistió en la creación de un nuevo marco de datos con variables seleccionadas y su subsiguiente partición, en datos de entrenamiento (80 %) y datos de validación (20 %) (Validación Cruzada de cinco iteraciones). Luego, en el modelado polinomial de segundo orden se trabajó con los datos de entrenamiento. Para el modelado lineal generalizado se consideró una distribución del error o



distribución de probabilidad binomial, con función de enlace *logit*. Seguidamente, se determinó el orden de importancia de las variables que conformaron el modelo. La evaluación del modelo fue realizada con estadísticas de evaluación y métricas de rendimiento sobre las predicciones realizadas empleando los datos de entrenamiento y los datos de validación. La selección de variables explicativas estuvo fundamentada en la evaluación de los modelos creados con todas las posibles combinaciones de variables explicativas (Hollander et al., 2013).

Se construyeron modelos de referencia con la finalidad de establecer umbrales para la selección de modelos. En primer lugar, el modelo nulo como el umbral más bajo para la selección y que comprendió únicamente al intercepto (sin variables explicativas). Como segundo umbral, el modelo saturado, que estuvo conformado por todas las variables explicativas consideradas en el modelado. Así mismo, se consideró al GLM equivalente al modelo de clasificación Random Forest seleccionado (conformado por las mismas variables explicativas) para su correspondiente evaluación y análisis comparativo. Por último, se construyó un modelo conformado por todas las variables que mostraron una correlación significativa con la ocurrencia (correlación de Pearson, $p < 0.05$).

En correspondencia con lo anterior, también fueron considerados los análisis de correlación de Pearson aplicados en la clasificación Random Forest para tener una visión general de la importancia de los factores y la selección de variables. Por otro lado, se calculó iterativamente los valores del VIF para todos los modelos creados con todas las posibles combinaciones de variables, con el fin de contrastar estos resultados con los resultados de las pruebas de multicolinealidad basados en el GVIF.



3.7.3.1 Evaluación de los GLMs

Los modelos fueron evaluados empleando el 20 % de los datos y a través del método de Validación Cruzada. Asimismo, se calculó la Brecha de Generalización en base al valor AUC-ROC empleando de manera conjunta los datos de entrenamiento y los datos de validación en equivalencia al estimado OOB para cuantificar que tan bien generalizó cada modelo en la información no utilizada durante su entrenamiento. Esta métrica, comprendió la diferencia entre el desempeño (en base al AUC) empleando los datos de entrenamiento y el desempeño esperado empleando los datos de validación. Así mismo, se calcularon las tasas de error promedio para cada clase en base únicamente a los datos de entrenamiento (los valores bajos para estas métricas fueron preferidos en la comparación de modelos). En suma, se aplicaron estadísticas de evaluación; así como, métricas de rendimiento promediadas de cinco iteraciones para evaluar a cada uno de los modelos de la selección final.

Las estadísticas de evaluación comprendieron al Criterio de Información de Akaike (Akaike Information Criterion o AIC) como medida de la calidad relativa; al Pseudo R^2 ajustado de McFadden, equivalente al D^2 ajustado en este modelado, como medida de bondad de ajuste y a los resultados de la prueba de multicolinealidad. Respecto a esta última, se tomó en cuenta si cada modelo contó o no con una baja multicolinealidad o baja correlación entre las variables que lo conformaron. En suma, si todas sus variables obtuvieron un valor para el GVIF menor a 5 (Fox y Monette, 1992; Lüdecke et al., 2019).

A su vez, los valores del Pseudo R^2 (PR^2) representaron la proporción de la variación en la ocurrencia de incendios (desviación del modelo nulo) explicada por cada modelo (Barbosa A.M., Brown J.A., Jimenez-Valverde A., Real R., 2016; Guisan y Zimmermann, 2000; McFadden, 1973). Para el ajuste de esta medida se tomaron en cuenta el número de observaciones y el número de parámetros (variables) para la posterior comparación (Weisberg, 2005). Teniendo en cuenta los valores de verosimilitud logarítmica, se calculó el AIC (Akaike, 1974) para comparar los modelos ajustados por máxima verosimilitud. En cuanto a la comparación de modelos, se prefirieron los valores más bajos y los más altos para el AIC y el Pseudo R^2 ajustado, respectivamente. Se utilizaron las siguientes fórmulas para el cálculo de estas medidas y el ajuste de la primera:

i. $AIC = -2 \times \text{verosimilitud logarítmica} + 2 \times \text{número de parámetros}$

j. $PR^2 = 1 - \frac{\text{Desv. residual}}{\text{Desv. del modelo nulo}} = \frac{\text{Desv. del modelo nulo} - \text{Desv. residual}}{\text{Desv. del modelo nulo}}$

k. $PR^2 \text{ ajustado} = 1 - \left(\frac{\text{observaciones} - 1}{\text{observaciones} - \text{parámetros}} \right) \times (1 - PR^2)$

Por otro lado, las métricas de rendimiento consideradas para la evaluación de los GLMs binomiales fueron: la sensibilidad, la precisión, el puntaje F1, la especificidad, la exactitud, el valor AUC-ROC y la Brecha de Generalización. Estas fueron calculadas sobre las probabilidades predichas empleando los datos de validación (y de entrenamiento para el cálculo de la Brecha de Generalización) mediante la creación de matrices de confusión y las correspondientes tasas de verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos. Así mismo, se



establecieron dos puntos de corte (umbrales de probabilidades) para el cálculo de las métricas: 0.5 (por defecto) y el Punto de Corte Óptimo (Optimal Operating Point u OOP) basado en el valor máximo de la exactitud. Para cada modelo fueron seleccionadas las métricas del punto de corte que evidenció el más alto valor para la sensibilidad.

Con relación al orden de las estadísticas de evaluación para la selección del mejor GLM, se estableció a la baja multicolinealidad (GVIF < 5) como la medida más relevante, seguida del AIC y el Pseudo R^2 de McFadden ajustado. Se contempló un orden semejante al considerado en la clasificación RF para las métricas de rendimiento de interés. Por lo tanto, en base a las métricas y priorizando la significancia de las variables explicativas de cada modelo, fue la sensibilidad la métrica más relevante, seguida de la precisión, el puntaje F1, la especificidad, la exactitud, el valor AUC-ROC y la Brecha de Generalización. Con el objetivo de comparar los GLMs binomiales, se aplicaron análisis de compensaciones para las estadísticas de evaluación, las métricas de rendimiento (selección de los cinco mejores modelos) y la significancia de las variables, promediadas de cinco iteraciones de Validación Cruzada siguiendo las mencionadas secuencias.

3.7.3.2 Importancia de los factores empleados en la clasificación

GLM binomial

Para evaluar la influencia relativa de los factores, se reportó la importancia de las variables explicativas consideradas en el modelado como la significancia ($p < 0.05$) de los coeficientes para cada uno de sus



términos (lineales y cuadráticos), y que estuvo también representada por los valores absolutos del estadístico z ; así como, la contribución de cada una a la reducción de la desviación de la variable respuesta y su contribución condicional promedio al Pseudo R^2 . En consecuencia, se establecieron tres jerarquías de importancia generales para las variables explicativas: a partir de la prueba de Wald, el análisis de desviaciones (prueba χ^2) (que compara secuencialmente una versión más simple del modelo con una más compleja al añadir una variable a la vez) y el Análisis de Dominancia General del modelo saturado. Las mismas que fueron aplicadas para el GLM binomial seleccionado.

3.7.3.3 Selección del mejor GLM binomial

De todos los modelos construidos con todas las posibles combinaciones de variables se seleccionaron, para cada grupo de combinaciones, aquellos modelos que evidenciaron una baja correlación entre sus variables, correspondiente al promedio de cinco iteraciones de Validación Cruzada de los resultados de la prueba de multicolinealidad basada en el GVIF (< 5). Así mismo, entre estos últimos, se seleccionó al subconjunto de modelos que no superó el umbral del AIC del modelo saturado (las medidas de calidad relativa también fueron promediadas de cinco iteraciones). A partir de esta nueva selección, se evaluaron primero los modelos más parsimoniosos, seguidamente de aquellos con el menor valor AIC dentro de cada grupo de combinaciones.

La significancia general de cada modelo seleccionado fue evaluada mediante una Prueba de Razón de Verosimilitud en contraste con el



modelo nulo. Los modelos significativos fueron comparados entre sí con las mismas pruebas con el fin de evidenciar diferencias significativas en su capacidad para explicar la desviación en la ocurrencia (análisis de desviaciones). Concretamente, fueron considerados únicamente los valores p de las comparaciones por pares (pruebas χ^2) de los GLMs anidados de la selección, para evaluar comparativamente la bondad de ajuste y la parsimonia de los modelos.

En consecuencia, el mejor GLM binomial fue seleccionado conforme a los resultados de estas pruebas y a los resultados de los análisis de compensaciones. Correspondiendo, de esta manera, al modelo que tuvo una capacidad significativa para explicar la desviación en la ocurrencia, diferente a los demás modelos y con las mejores métricas de rendimiento entre el conjunto de modelos que estuvieron conformados únicamente por variables explicativas relevantes (significativas en la prueba χ^2 y la prueba de Wald).

Se calcularon puntos de inflexión para aquellas variables del modelo que contaron con coeficientes significativos en relación a sus términos cuadráticos. Así mismo, fueron exponenciadas las probabilidades logarítmicas correspondientes a los términos lineales (x_i) y cuadráticos (x_i^2); es decir, se exponenciaron los coeficientes estimados de todas las variables explicativas incluidas en el modelo seleccionado. Para dicha conversión y el cálculo de los puntos de inflexión se emplearon las siguientes fórmulas:

- l. Probabilidades del $x_i = 100 \times [1 - (e^{(\text{logit del } x_i)})]$
- m. Probabilidades del $x_i^2 = 100^2 \times [1 - (e^{(\text{logit del } x_i^2)})]$
- n. Punto de inflexión = $\frac{-(\text{logit del } x_i)}{(2 \times \text{logit del } x_i^2)}$

Análogamente a la clasificación Random Forest, se creó un mapa de probabilidad de ocurrencia de incendios a partir del GLM binomial seleccionado. Así mismo, se realizó la correspondiente clasificación espacial de la probabilidad en zonas de riesgo. Por último, la selección del modelo final para modelar la ocurrencia de incendios estuvo sustentada en un análisis de compensación entre el GLM binomial seleccionado, el modelo clasificación Random Forest seleccionado y su GLM binomial equivalente.

3.8 MODELADO Y EVALUACIÓN DE LOS MODELOS DE EXTENSIÓN DE INCENDIOS

3.8.1 Base de datos

Debido a que la extensión de los incendios (variable respuesta), tuvo naturalmente una distribución continua, se optó por el modelado lineal generalizado considerando la familia de distribución gaussiana y la función de enlace *log* (Cardille et al., 2001; Harris y Taylor, 2017; Kim et al., 2019). A partir de los GLMs también se pudo identificar la importancia de los factores en la extensión de los incendios. La base de datos para el modelado estuvo compuesta por 23 variables explicativas (Tabla 4): cuatro variables bioclimáticas, siete variables topográficas, ocho variables de vegetación, una variable de combustibilidad y tres variables antrópicas (Tabla 1). Ninguna fue normalizada



previamente al modelado. Los datos espaciales en formato *shapefile* (polígonos corregidos) correspondientes a los 23 incendios identificados, delimitados y evaluados en 2023 fueron añadidos a la interfaz del Software R, donde se realizó el modelado.

En primer lugar, se establecieron áreas de influencia (*buffers*) de 100 metros alrededor de cada polígono. Seguidamente, se apilaron las imágenes ráster correspondientes a las 14 variables explicativas previamente consideradas en el modelado de la ocurrencia. Luego, se extrajeron los valores de las celdas ráster donde se superpusieron los polígonos modificados o las extensiones de los incendios. Con los valores resultantes y la codificación de los incendios se creó un marco de datos, a partir del cual se agruparon y promediaron los valores de cada variable propios de cada incendio evaluado. Posterior a ello, se incorporaron al marco los valores de la extensión y de las nueve variables restantes: los valores de la intensidad del pastoreo, los porcentajes de las coberturas, los valores de la altura de la vegetación y de la materia seca (carga de combustible). En base al marco resultante, se realizó la descripción estadística de los datos obtenidos.

3.8.2 Modelado Lineal Generalizado (GLM)

Al igual que los modelados previos, el modelado lineal generalizado de la extensión de incendios se efectuó sobre un nuevo marco de datos conformado por variables seleccionadas. Seguidamente, se determinó el orden de importancia de las variables que conformaron a cada modelo y fueron evaluados con estadísticas de evaluación. Para la construcción de los GLMs gaussianos se empleó la base de datos completa. No se realizó la partición de los datos, ni se aplicó la técnica de Validación Cruzada por el reducido número de observaciones de la variable de



respuesta (la extensión de los incendios evaluados en 2023). Por otro lado, se construyeron modelos de referencia con la finalidad de establecer umbrales para la selección de modelos. En primer lugar, el modelo nulo como el umbral más bajo y como segundo umbral, el modelo saturado.

A razón de que la base de datos contó con un gran número de variables explicativas, se consideró en primer lugar y en semejanza con el modelado de la ocurrencia, un análisis de correlación de Pearson entre las variables explicativas y la variable continua de respuesta. A partir del cual, se estableció un orden preliminar de la importancia de los factores por significancia ($p < 0.05$ o aquellas que mantuvieron una correlación con la extensión mayor a 0.15). Asimismo, se aplicó el mismo análisis para evidenciar la multicolinealidad en el conjunto de variables explicativas (grupos de alta correlación: mayor o igual a 0.6) y adicionalmente, se calcularon los valores del VIF para cada una de ellas (Naimi et al., 2014).

La selección de variables explicativas estuvo fundamentada en la evaluación de los modelos creados con todas las posibles combinaciones de variables (Whittingham et al., 2006), en los resultados de los análisis de correlación, en los resultados de las pruebas de multicolinealidad basadas en el VIF y en el método *Backward* para la selección de variables. La eliminación *Backward* o eliminación por retroceso, como parte del proceso (o regresión) *Stepwise* (paso a paso), consistió en la remoción sucesiva de variables no significativas o menos relevantes para el modelado a través de un algoritmo partiendo del modelo saturado (o un modelo completo) y en base a la disminución del AIC (Narisetty, 2020). De este modo, se construyeron y evaluaron diversos



GLMs gaussianos aplicando uno o más de estos métodos de selección de variables explicativas de manera conjunta o sucesiva.

3.8.2.1 Evaluación de los GLMs

Los modelos fueron evaluados aplicando estadísticas de evaluación y empleando la base de datos completa. Las estadísticas comprendieron al AIC como medida de la calidad relativa, al Pseudo R^2 ajustado de Cox y Snell equivalente al Pseudo R^2 ajustado de máxima verosimilitud en este modelado, como medida de bondad de ajuste y a los resultados de la prueba de multicolinealidad basada en el GVIF (< 5). Los valores del Pseudo R^2 (PR^2) representaron, en este modelado, la proporción de la variación en la extensión de los incendios (desviación del modelo nulo) explicada por cada modelo construido (Cox y Snell, 1989). Para el ajuste de esta medida también se consideraron el número de observaciones y el número de parámetros (variables).

Juntamente con los valores para el AIC, se utilizaron los valores del Pseudo R^2 para la comparación de GLMs gaussianos, prefiriendo los valores más bajos y los más altos respectivamente. Así mismo, se estableció a la baja multicolinealidad (GVIF < 5) como la medida de evaluación más relevante, seguida del AIC y el Pseudo R^2 de Cox y Snell ajustado. Siguiendo este orden y tomando en cuenta la parsimonia, se aplicó un análisis de compensación para la selección de modelos y la elección del modelo final. Se compararon las medidas de bondad de ajuste y de calidad relativa de cada modelo con las medidas del modelo nulo y el modelo saturado.

3.8.2.2 Importancia de los factores empleados en la regresión GLM gaussiana

Para evaluar la influencia relativa de los factores determinantes en la extensión de los incendios, se reportó la importancia de las variables explicativas como la significancia ($p < 0.05$) de sus coeficientes estimados, y que estuvo también representada por los valores absolutos del estadístico t ; así como, la contribución de cada una a la reducción de la desviación de la variable respuesta y su contribución condicional promedio al Pseudo R^2 . Por consiguiente, se establecieron tres jerarquías de importancia para las variables explicativas que conformaron el GLM seleccionado, a partir de la prueba de Wald, el análisis de desviaciones (prueba F) y el Análisis de Dominancia General.

3.8.2.3 Selección del mejor GLM gaussiano

De todos los modelos construidos con todas las posibles combinaciones de variables se seleccionó al modelo que evidenció una baja correlación entre sus variables, conforme a los resultados de la prueba de multicolinealidad basada en el GVIF (< 5) y que además, contó con el menor valor para el AIC. Formaron parte de la selección final, los modelos conformados por variables que guardaron una correlación mayor a 0.15 o significativa ($p < 0.05$) con la extensión, por variables que guardaron una correlación entre sí menor a 0.6 y/o por subconjuntos de variables que evidenciaron únicamente valores para el VIF menores a 5. Además, se incluyó al mejor modelo resultante de todas las combinaciones de variables, junto con los modelos resultantes del método *Backward*.



La significancia general de cada modelo seleccionado fue evaluada mediante una Prueba de Razón de Verosimilitud en contraste con el modelo nulo (análisis de desviaciones). Los modelos fueron comparados entre sí con las mismas pruebas con el fin de evidenciar diferencias significativas en su capacidad para explicar la desviación en la extensión. En concreto, solo fueron considerados los valores p de las comparaciones por pares (pruebas F incrementales) de los GLMs anidados de la selección.

Consecutivamente, el mejor GLM gaussiano para modelar la extensión de los incendios fue seleccionado conforme a los resultados de estas pruebas y a los resultados del análisis de compensación. Representando, de este modo, al modelo que tuvo una capacidad significativa para explicar la desviación en la extensión, diferente a los demás modelos y con las mejores estadísticas de evaluación. Además, el modelo estuvo conformado únicamente por variables explicativas relevantes (significativas en prueba de Wald). Las extensiones medias logarítmicamente transformadas correspondientes a los términos lineales (x_i) fueron exponenciadas; en otras palabras, se exponenciaron los coeficientes estimados de todas las variables explicativas que conformaron el GLM seleccionado, en semejanza a la conversión aplicada en el modelado de la ocurrencia de incendios.

Tabla 4

Variables utilizadas en la modelación de la extensión y la ocurrencia de incendios en pastizales altoandinos en el área de estudio

N°	Abrev.	Nombre de la variable	Unidades	Periodo	R. T.	R. E.	Fuente
1	(Y)	Ocurrencia de incendios	-	2017 – 2023	-	-	SERFOR [comunicación personal] https://sniffs.serfor.gob.pe/monitoreo/sa/mi/incendios.html MINAM
2	(Y)	Extensión de incendios	ha	2023	5 días	20 m	https://geoservidorperu.minam.gob.pe/geocfoi/minam/downloaddata/index Sentinel 2-MSIL2A https://browser.dataspace.copernicus.eu/
3	TMAX***	Temperatura máxima diaria y mensual	°C	2017 – 2023	Diaria/ mensual	5 km	SENAMHI-HSR-PISCO https://iridl.ldeo.columbia.edu/SOURCES/SENAMHI/HSR/PISCO/
4	DDF***	Frecuencia Acumulada de Días Secos	Días	2017 – 2023 [may. – nov.]	8 días	5 km	Calculada [Precipitación (SENAMHI-HSR-PISCO)]
5	HDF***	Frecuencia Acumulada de Días Calurosos	Días	2017 – 2023 [may. – nov.]	8 días	5 km	Calculada [Temperatura máx. (SENAMHI-HSR-PISCO)]
6	EVAP***	Evapotranspiración potencial diaria y mensual	mm/día	2017 – 2023	Diaria/ mensual	5 km	SENAMHI-HSR-PISCO
7	SLOPE***	Pendiente	Grados (°)	-	-	30 m	Calculada [DEM (ASTER Global DEM)]
8	ASPECT**	Exposición topográfica	Grados (°)	-	-	30 m	Calculada [DEM (ASTER Global DEM)]
9	DEM***	Elevación	m s.n.m.	-	-	30 m	ASTER Global DEM https://gdemdl.aster.jspacesystems.or.jp/
10	TWI***	Índice de Humedad Topográfica	-	-	-	30 m	Calculada [DEM (ASTER Global DEM)]
11	TPI500***	Índice de Posición Topográfica en un radio de 500 m	-	-	-	30 m	Calculada [DEM (ASTER Global DEM)]
12	TPI1000***	Índice de Posición Topográfica en un radio de 1000 m	-	-	-	30 m	Calculada [DEM (ASTER Global DEM)]

N°	Abrev.	Nombre de la variable	Unidades	Periodo	R. T.	R. E.	Fuente
13	TP12000***	Índice de Posición Topográfica en un radio de 2000 m	-	-	-	30 m	Calculada [DEM (ASTER Global DEM)]
14	SAVI**	Índice de Vegetación Ajustado al Suelo	[-1, 1]	2017 – 2023 [may. – dic.]	8 días	~ 463 m	Terra-MODIS-MOD09A1 https://ladsweb.modaps.eosdis.nasa.gov/search/
15	Cob_pasto	Cobertura de pastos	%	2023	-	30 m	Evaluación de campo
16	Cob_hierba	Cobertura de hierbas	%	2023	-	30 m	Evaluación de campo
17	Cob_leño	Cobertura de hierbas leñosas	%	2023	-	30 m	Evaluación de campo
18	Cob_suelo	Cobertura de suelo desnudo	%	2023	-	30 m	Evaluación de campo
19	Cob_roca	Cobertura de roca	%	2023	-	30 m	Evaluación de campo
20	Cob_hoj	Cobertura de hojarasca	%	2023	-	30 m	Evaluación de campo
21	Altura	Altura de la vegetación	cm	2023	-	30 m	Evaluación de campo
22	MS	Materia seca (combustible)	g	2023	-	30 m	Evaluación de campo/laboratorio MTC
23	CAMINOS***	Distancia a caminos/redes viales	m	2023	-	500 m	https://portal.mtc.gob.pe/transportes/caminos/normas_carreteras/informacion_especial.html MINEDU
24	CP***	Distancia a Centros Poblados	m	2020	-	500 m	https://sigmed.minedu.gob.pe/descargas/
25	Pastoreo	Intensidad de pastoreo (Índice de Abundancia de Fecas)	%	2023	-	40 m	Evaluación de campo

Nota: (*) Variables remuestreadas a 500 m, (**) empleadas en el modelado de la ocurrencia y (***) normalizadas.

R. T.: Resolución temporal.

R. E.: Resolución espacial.



CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1 IDENTIFICACIÓN DE LOS FACTORES CLIMÁTICOS, TOPOGRÁFICOS Y ANTRÓPICOS QUE DETERMINAN LA OCURRENCIA DE INCENDIOS EN PASTIZALES ALTOANDINOS DEL DEPARTAMENTO DE PUNO

La base de datos para el modelado de la ocurrencia de incendios comprendió un total 2530 observaciones, con 14 variables explicativas y la variable binaria de respuesta relacionada con la ocurrencia de incendios (presencia/ausencia) (Tabla 5). La descripción estadística de los datos evidencia en líneas generales que las ubicaciones donde se suscitaron los incendios suelen tener temperaturas máximas ligeramente mayores frente a las ubicaciones donde no ocurrieron incendios; así como, una mayor Frecuencia Acumulada de Días Secos y Calurosos, una mayor tasa de evapotranspiración potencial y una menor elevación. Además, se ubicaron en colinas con mayor pendiente, con suelos menos húmedos, con menor cobertura vegetal verde, menos distanciados a redes viales y más distanciados a centros poblados.

Tabla 5

Resumen de los datos recopilados para el modelado de la ocurrencia de los incendios en pastizales altoandinos en el departamento de Puno (provincias de Melgar, Azángaro y Lampa) para el periodo 2017 - 2023

Presencia de incendios						Ausencia de incendios					
N°	Abrev.	Prom.	DE	Mín.	Máx.	N°	Abrev.	Prom.	DE	Mín.	Máx.
1	TMAX	16.10	0.61	13.88	17.07	1	TMAX	15.76	0.88	12.72	17.07
2	DDF	74	16	42	112	2	DDF	72	18	40	110
3	HDF	52	30	0	138	3	HDF	42	34	0	138
4	EVAP	57.79	3.34	43.64	63.78	4	EVAP	55.75	5.26	42.77	63.98
5	SLOPE	15.58	8.74	0.67	50.07	5	SLOPE	12.25	8.61	0.07	42.67
6	ASPECT	176.46	93.33	4.62	356.30	6	ASPECT	179.82	95.10	4.12	357.33
7	DEM	4229.2	195.8	3818.7	4995.6	7	DEM	4302.3	340.4	3813.9	5185.6
8	TWI	7.46	2.67	3.70	19.15	8	TWI	8.37	3.17	3.66	19.54
9	TPI500	0.26	1.00	-2.47	4.29	9	TPI500	0.04	0.89	-4.39	4.28
10	TPI1000	0.31	0.97	-2.37	4.18	10	TPI1000	0.04	0.88	-4.08	3.59
11	TPI2000	0.30	0.94	-2.31	4.33	11	TPI2000	0.04	0.87	-3.20	3.69
12	SAVI	0.16	0.03	0.10	0.34	12	SAVI	0.17	0.04	0.06	0.40
13	CAMINOS	5162	4008	0	30232	13	CAMINOS	6221	6080	0	38679
14	CP	1079.3	646.0	2.6	4515.6	14	CP	1077.4	728.0	29.5	6402.2

Nota: Las unidades de las variables explicativas: TMAX (°C), DDF (días), HDF (días), EVAP (mm/día), SLOPE (°), ASPECT (°), DEM (m s.n.m.), SAVI [-1, 1], Caminos (m), CP (m). Los datos corresponden a las 2530 observaciones entre presencias y ausencias.

4.1.1 Modelado de Clasificación Random Forest (RF)

El modelo saturado (*m1*), los 13 modelos resultantes de la Eliminación Recursiva de Variables (método RFE para la selección de variables), además de un modelo base (*m15*) (modelo saturado con *ntree*: 1 y *mtry*: 1) comprendieron la selección final de modelos de clasificación RF para modelar la ocurrencia de incendios en el periodo 2017 - 2023 (Tabla 6). De la selección, se evidencia que los hiperparámetros ajustados varían en función de las características propias de la combinación de variables de cada modelo: número, estabilidad en el orden de importancia y posible correlación entre ellas.

Tabla 6

VARIABLES explicativas e hiperparámetros ajustados empleados en los modelos de clasificación Random Forest para modelar la ocurrencia de incendios

N° Var.	Cod.	Nombre	Variables explicativas														Hiperparámetros		
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	<i>ntree</i>	<i>mtry</i>	<i>nodesize</i>
14	m1	RFE-0	x	x	x	x	x	x	x	x	x	x	x	x	x	x	10000	9	8
13	m2	RFE-1	x	x	x	x	x		x	x	x	x	x	x	x	x	8000	12	10
12	m3	RFE-2	x	x	x	x			x	x	x	x	x	x	x	x	2000	8	7
11	m4	RFE-3	x	x	x	x			x	x	x	x	x	x	x		8000	11	7
10	m5	RFE-4	x	x	x	x			x	x	x	x	x	x			4000	10	7
9	m6	RFE-5	x	x	x	x			x		x	x	x	x			8000	8	7
8	m7	RFE-6	x	x	x	x			x			x	x	x			2000	6	7
7	m8	RFE-7	x	x	x	x			x			x		x			2000	4	4
6	m9	RFE-8	x	x	x	x			x					x			2000	1	4
5	m10	RFE-9	x		x	x			x					x			500	2	4
4	m11	RFE-10	x			x			x					x			10000	1	5
3	m12	RFE-11	x			x			x								2000	1	4
2	m13	RFE-12				x			x								500	2	4
1	m14	RFE-13							x								500	1	5
14	(m15)	M. Base	x	x	x	x	x	x	x	x	x	x	x	x	x	x	1	1	1

Nota: Las variables explicativas son: TMAX (1), DDF (2), HDF (3), EVAP (4), SLOPE (5), ASPECT (6), DEM (7), TWI (8), TPI500 (9), TPI1000 (10), TPI2000 (11), SAVI (12), Caminos (13), CP (14).

Mediante un análisis de compensación (*tradeoff*) de las métricas de rendimiento promediadas para cada modelo (Tabla 7) se pudo evidenciar que los modelos *m4*, *m5*, *m6*, *m7* y *m8* fueron los que presentaron las mejores métricas y por lo tanto representan los mejores modelos de la selección para modelar la ocurrencia de incendios.

Tabla 7*Métricas de rendimiento de la selección de modelos de clasificación Random**Forest para modelar la ocurrencia de incendios*

Cod.	SE	Precisión	F1	SP	Exactitud	AUC	Error OOB
m1	0.7784	0.7056	0.7399	0.6616	0.7212	0.7754	0.2791
m2	0.7845	0.6921	0.7350	0.6576	0.7204	0.7756	0.2827
m3	0.7726	0.6927	0.7299	0.6543	0.7131	0.7734	0.2728
m4	0.7766	0.7206	0.7474	0.6769	0.7286	0.7853	0.2776
m5	0.7828	0.7112	0.7449	0.6663	0.7257	0.7778	0.2791
m6	0.7732	0.7018	0.7354	0.6722	0.7225	0.7853	0.2824
m7	0.7708	0.7030	0.7347	0.6745	0.7223	0.7801	0.2770
m8	0.7572	0.7116	0.7336	0.6837	0.7210	0.7808	0.2815
m9	0.7724	0.6871	0.7269	0.6487	0.7101	0.7637	0.2826
m10	0.7594	0.6802	0.7174	0.6558	0.7069	0.7704	0.2834
m11	0.7621	0.6984	0.7286	0.6838	0.7172	0.7781	0.2879
m12	0.7396	0.6959	0.7165	0.6668	0.7034	0.7500	0.3019
m13	0.6970	0.6573	0.6762	0.6361	0.6663	0.7183	0.3443
m14	0.6163	0.5873	0.6012	0.5924	0.6044	0.6582	0.4033
(m15)	0.6215	0.6112	0.6156	0.6156	0.6186	0.6185	0.3965

Nota: SE: Sensibilidad. F1: Puntaje F1. SP: Especificidad. AUC: Valor AUC-ROC. Error OOB: Estimado OOB de la tasa de error. Valores promediados a partir de cinco iteraciones de Validación Cruzada empleando los datos de validación. En negrita los mejores modelos.

Conforme al análisis y el orden de las métricas de rendimiento de interés, el mejor modelo de la selección fue *m4* con 77.66 % de sensibilidad (un incremento del 15.51 % frente al modelo base), 72.06 % de precisión (un incremento del 10.94 % frente al modelo base y del 1.5 % frente al modelo saturado), 74.74 % de puntaje F1 (un incremento del 13.18 % frente al modelo base y del 0.75 % frente al modelo saturado), 67.69 % de especificidad (un incremento del 6.13 % frente al modelo base y del 1.53 % frente al modelo saturado), 72.86 % de exactitud (un incremento del 11 % frente al modelo base y del 0.74 % frente al modelo saturado), un valor de AUC de 0.785 (un incremento de 0.285 frente a un clasificador aleatorio y de 0.01 frente al modelo saturado) y un error OOB de 27.76 % (una disminución del 11.89 % frente al modelo base y del 0.15 % frente al modelo saturado).



El segundo mejor modelo de la selección fue el modelo *m5* con 78.28 % de sensibilidad (un incremento del 16.13 % frente al modelo base y del 0.44 % frente al modelo saturado), 71.12 % de precisión (un incremento del 10 % frente al modelo base y del 0.56 % frente al modelo saturado), 74.49 % de puntaje F1 (un incremento del 12.93 % frente al modelo base y del 0.5 % frente al modelo saturado), 66.63 % de especificidad (un incremento del 5.07 % frente al modelo base y del 0.47 % frente al modelo saturado), 72.57 % de exactitud (un incremento del 10.71 % frente al modelo base y del 0.45 % frente al modelo saturado), un valor de AUC de 0.778 (un incremento de 0.278 frente a un clasificador aleatorio y de 0.003 frente al modelo saturado) y un error OOB de 27.91 % (una disminución del 11.74 % frente al modelo base).

El tercer mejor modelo de la selección fue el modelo *m6* con 77.32 % de sensibilidad (un incremento del 15.17 % frente al modelo base), 70.18 % de precisión (un incremento del 9.06 % frente al modelo base), 73.54 % de puntaje F1 (un incremento del 11.98 % frente al modelo base), 67.22 % de especificidad (un incremento del 5.66 % frente al modelo base y del 1.06 % frente al modelo saturado), 72.25 % de exactitud (un incremento del 10.39 % frente al modelo base y del 0.13 % frente al modelo saturado), un valor de AUC de 0.785 (un incremento de 0.285 frente a un clasificador aleatorio y de 0.01 frente al modelo saturado) y un error OOB de 28.24 % (una disminución del 11.41 % frente al modelo base).

El cuarto mejor modelo de la selección fue el modelo *m7* con 77.08 % de sensibilidad (un incremento del 14.93 % frente al modelo base), 70.3 % de precisión (un incremento del 9.18 % frente al modelo base), 73.47 % de puntaje F1 (un incremento del 11.91 % frente al modelo base), 67.45 % de especificidad (un incremento del 5.89 % frente al modelo base y del 1.29 % frente al modelo

saturado), 72.23 % de exactitud (un incremento del 10.37 % frente al modelo base y del 0.11 % frente al modelo saturado), un valor de AUC de 0.78 (un incremento de 0.28 frente a un clasificador aleatorio y de 0.005 frente al modelo saturado) y un error OOB de 27.7 % (una disminución del 11.95 % frente al modelo base y del 0.21 % frente al modelo saturado).

El quinto modelo de la selección fue el modelo *m8* con 75.72 % de sensibilidad (un incremento del 13.57 % frente al modelo base), 71.16 % de precisión (un incremento del 10.04 % frente al modelo base y del 0.6 % frente al modelo saturado), 73.36 % de puntaje F1 (un incremento del 11.8 % frente al modelo base), 68.37 % de especificidad (un incremento del 6.81 % frente al modelo base y del 2.21 % frente al modelo saturado), 72.1 % de exactitud (un incremento del 10.24 % frente al modelo base), un valor de AUC de 0.781 (un incremento de 0.281 frente a un clasificador aleatorio y de 0.006 frente al modelo saturado) y un error OOB de 28.15 % (una disminución del 11.5 % frente al modelo base).

A partir del método RFE se estableció el orden de importancia de todas las variables explicativas empleadas en el modelado de la ocurrencia de incendios (Tabla 8). La variable con el mayor valor de importancia de permutación, en base a la Disminución Media de la Exactitud (MDA), fue la elevación, seguida de la evapotranspiración potencial, la temperatura máxima, el Índice de Vegetación Ajustado al Suelo, la Frecuencia Acumulada de Días Calurosos, la Frecuencia Acumulada de Días Secos y el Índice de Posición Topográfica calculado a un radio de 1000 metros.

Tabla 8

Orden de importancia de las variables explicativas de la base de datos completa empleada en el modelado de ocurrencia de incendios acorde al método RFE

Imp.	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Var.	DEM	EVAP	TMAX	SAVI	HDF	DDF	TPI1000	TPI2000	TPI500	TWI	CAMINOS	CP	SLOPE	ASPECT
Mod.	m14	m13	m12	m11	m10	m9	m8	m7	m6	m5	m4	m3	m2	m1

Nota: Debajo de cada variable, el modelo correspondiente en el cual fue identificada para ser eliminada.

4.1.1.1 Selección del mejor modelo de clasificación Random Forest para modelar la ocurrencia de incendios en pastizales altoandinos en el departamento de Puno

El Índice de Posición Topográfica calculado a un radio de 1000 m fue considerado como el umbral para la división de la selección de modelos de clasificación RF. Por lo tanto, el grupo de modelos de clasificación sin variables de ruido comprendió los modelos: *m14*, *m13*, *m12*, *m11*, *m10*, *m9* y *m8*. Conforme a ello, y considerando los cinco mejores modelos resultantes del análisis de compensación de las métricas de rendimiento de toda la selección de modelos de clasificación, se seleccionó al modelo *m8* como mejor modelo RF para modelar la ocurrencia de incendios. Este modelo se caracterizó por ser lo suficientemente informativo, por ser parsimonioso, con baja multicolinealidad, por considerar variables relevantes y por tener un buen rendimiento de predicción. Los detalles para la construcción del modelo seleccionado se presentan en la Tabla 9.

Tabla 9

Detalles del modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios

Datos del modelo	Hiperparámetros		
Nombre/Código	RFE-7/m8	<i>ntree</i>	2000
Método de selección de variables	RFE	<i>mtry</i>	4
Número de variables	7	<i>nodesize</i>	4

Nota: RFE: Recursive Feature Elimination (Eliminación Recursiva de Variables).

Para la construcción del modelo se consideraron siete variables: La elevación (DEM), la evapotranspiración potencial (EVAP), la temperatura máxima (TMAX), el Índice de Vegetación Ajustado al Suelo (SAVI), la Frecuencia Acumulada de Días Calurosos (HDF), la Frecuencia Acumulada de Días Secos (DDF) y el Índice de Posición Topográfica calculado a un radio de 1000 m (TPI1000). El ajuste de los hiperparámetros dio como resultado la selección de 2000 árboles (*ntree*) para la mantener la estabilidad en el orden de importancia de las variables, la selección aleatoria de cuatro de ellas en cada división (*mtry*) y la inclusión de al menos cuatro observaciones en cada nodo terminal (*nodesize*).

Acorde al rendimiento de la predicción del modelo (Tabla 10), el promedio de 257 presencias (casos positivos observados) y 249 ausencias (casos negativos observados) reflejó el balanceo de la base de datos. Sin embargo, el clasificador se mostró ligeramente más sensible a predecir correctamente la clase mayoritaria, en este caso, las presencias. Lo que resultó en 195 puntos de presencia correctamente clasificados frente a 62 incorrectamente clasificados y a 170 puntos de ausencia correctamente clasificados frente a 79 incorrectamente clasificados. No obstante, en los

resultados del promedio de las tasas de error por clase, el 31.47 % de las predicciones para las presencias y el 26.03 % de las predicciones para las ausencias fueron incorrectas. Por consiguiente, el valor de predicción para las presencias y para las ausencias fue de 68.53 % y 73.97 %, respectivamente.

Tabla 10

Matriz de confusión y métricas de rendimiento del modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios

Matriz de confusión		Métricas de rendimiento	
Resultado	Valor	Métrica	Valor
Verdaderos positivos	195	Sensibilidad	0.7572000
Verdaderos negativos	170	Precisión	0.7116167
Falsos positivos	79	Puntaje F1	0.7336333
Falsos negativos	62	Especificidad	0.6836667
Tasas de error por clase		Exactitud	0.7210000
Tasa de error para la clase de positivos	0.3147394	Valor AUC-ROC	0.7807872
Tasa de error para la clase de negativos	0.2603273	Estimado OOB de la tasa de error	0.2814559

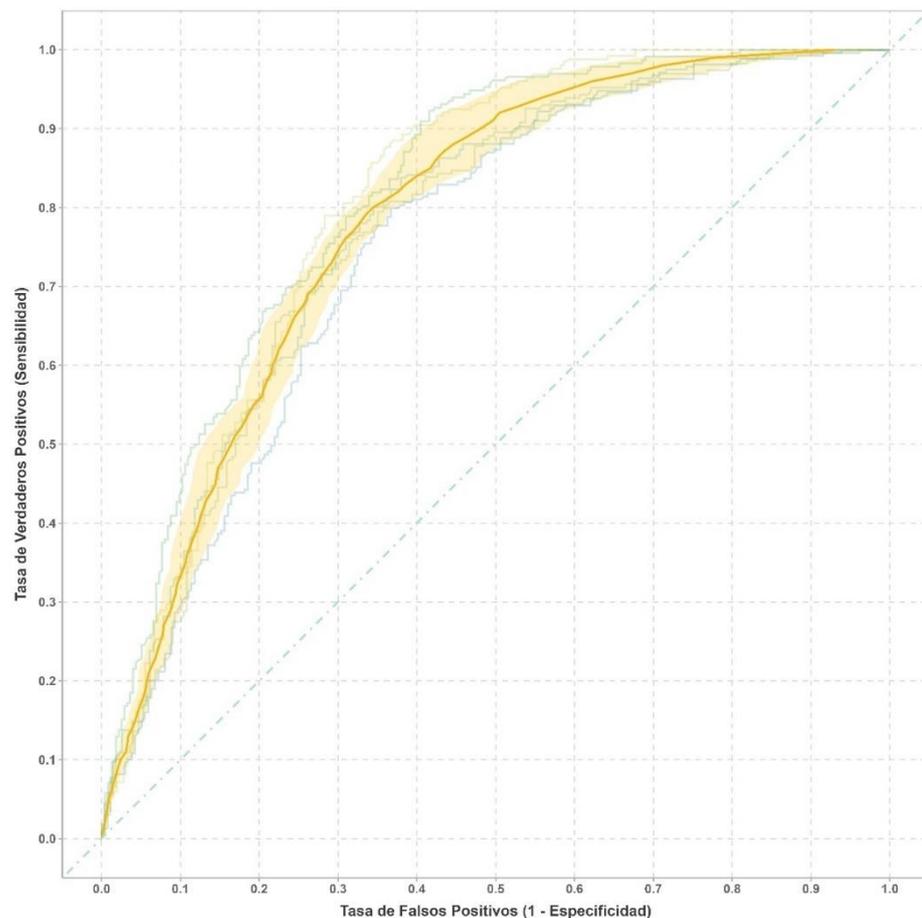
Nota: Los valores fueron promediados a partir de cinco iteraciones de Validación Cruzada empleando los datos de validación.

Del total de presencias observadas, 75.72 % fueron correctamente clasificadas y del total de observaciones clasificadas como presencias 71.16 % fueron correctas. El puntaje F1 del 73.36 % indica un buen y equilibrado desempeño, así como una alta sensibilidad y precisión. Del total de ausencias observadas, 68.37 % fueron correctamente clasificadas. En resumen, el modelo clasificó correctamente el 72.1 % del total de las observaciones. El error de predicción del modelo, basado en el promedio del error OOB estimado en la distribución de los datos de entrenamiento,

fue de 28.15 %. El valor AUC del modelo (0.781) indicó un rendimiento mejor al de un clasificador aleatorio (Fig. 3).

Figura 3

Curva ROC del modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios



Nota: La curva ROC del modelo se obtuvo promediando horizontalmente (Hogan y Adams, 2023) cinco curvas correspondientes a cinco iteraciones de Validación Cruzada, empleando los datos de validación. El área sombreada representa la Desviación Estándar de la curva promedio y la línea punteada, la línea de referencia de una clasificación aleatoria. El promedio de los valores AUC de las iteraciones: 0.7858487 y el valor AUC estimado de la curva promediada: 0.7152158.

El orden de importancia de las variables empleadas en el modelo seleccionado (Tabla 11), construido con los valores de importancia de permutación promediados de 100 iteraciones de Validación Cruzada,

guardó relación con el orden de importancia de la base de datos completa (Tabla 8). En ambos, se destacó la importancia de la elevación en la predicción de la ocurrencia de incendios. Si esta variable no hubiese sido considerada en los modelos de clasificación, el error de predicción (basado en el error OOB estimado) se habría incrementado considerablemente.

Tabla 11

Orden y valores de importancia de las variables consideradas en el modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios

Variable explicativa	Orden de importancia	Valor de importancia	Desviación Estándar
DEM	1	164.441895	6.983085
EVAP	2	74.045625	4.482958
TMAX	3	66.410421	3.880918
SAVI	4	60.035021	6.220447
HDF	5	48.651613	3.134696
DDF	6	42.309871	4.174769
TPI1000	7	31.885361	4.236749

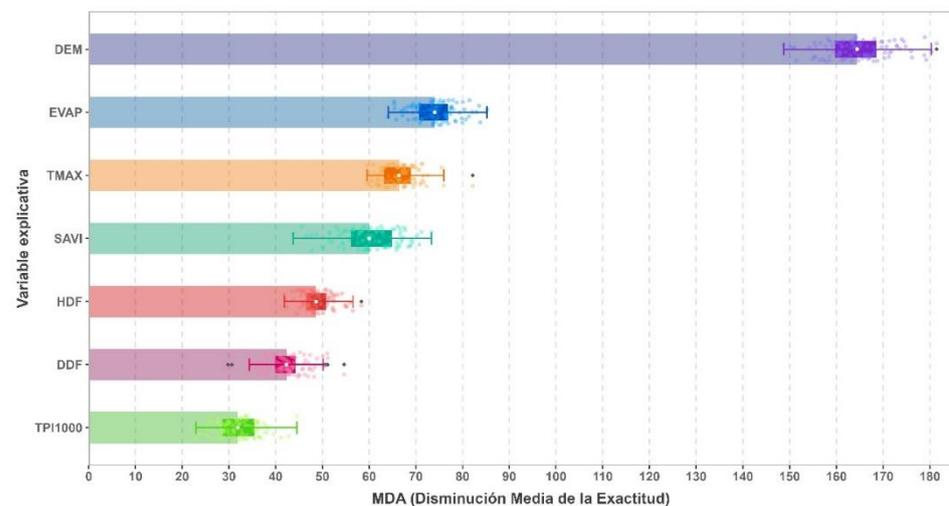
Nota: Como medida de importancia se empleó la Disminución Media de la Exactitud (MDA). Los valores normalizados fueron promediados a partir de 100 iteraciones de Validación Cruzada empleando los datos de entrenamiento.

De esta manera, la variable explicativa más importante en el modelo seleccionado corresponde a una variable topográfica, con un MDA de 164.44 ± 6.98 . Todas las bioclimáticas fueron consideradas en la construcción del modelo seleccionado. Dos de ellas, la evapotranspiración potencial y la temperatura máxima (con un MDA de 74.05 ± 4.48 y 66.41 ± 3.88 respectivamente) emergieron como variables de segundo orden de importancia en el modelo, seguidas de la única variable de vegetación considerada en el modelado de la ocurrencia de incendios, el Índice de

Vegetación Ajustado al Suelo con un MDA de 60.04 ± 6.22 . Las dos variables bioclimáticas restantes, la Frecuencia Acumulada de Días Calurosos y la Frecuencia Acumulada de Días Secos, tomaron el cuarto orden de importancia con valores de MDA de 48.65 ± 3.13 y 42.31 ± 4.17 respectivamente. Finalmente, la última variable de importancia en el modelo correspondió a otra variable topográfica, el Índice de Posición Topográfica calculado a un radio de 1000 m con un MDA de 31.89 ± 4.24 (Fig. 4).

Figura 4

Gráfico de importancia de las variables consideradas en el modelo de clasificación Random Forest seleccionado para modelar la ocurrencia de incendios



Nota: Las barras indican la importancia relativa de cada variable mediante la MDA promediada a partir de 100 iteraciones de Validación Cruzada empleando los datos de entrenamiento. Los diagramas de caja muestran la distribución de las iteraciones.

Por el método de selección de variables, todas aquellas variables empleadas en la construcción del modelo seleccionado contribuyeron en el rendimiento de la predicción de la ocurrencia de incendios



disminuyendo el error de predicción (error OOB estimado) e incrementando la exactitud del modelo.

El orden de importancia de las variables del modelo seleccionado no se amoldó a los resultados de la prueba de correlación de Pearson entre las variables explicativas y la ocurrencia. No obstante, todas las variables consideradas en el modelo guardaron una correlación significativa con la variable binaria de respuesta. Por otro lado, el modelo difirió de los resultados de la correlación aplicada entre las variables explicativas (la evapotranspiración potencial, la temperatura máxima y la frecuencia acumulada de días calurosos estuvieron altamente correlacionadas acorde a dicha prueba). De igual forma, las variables del modelo final no se ajustaron al análisis de multicolinealidad basado en el VIF (la temperatura máxima y la evapotranspiración evidenciaron valores para el VIF mayores a 5). En consecuencia, las correlaciones de Pearson y el análisis de multicolinealidad basado en el VIF no resultaron las pruebas más idóneas para la selección de variables en este estudio debido a que no reflejaron los resultados favorables del resto de pruebas aplicadas para el modelado de la ocurrencia.

De acuerdo con el INDECI, los incendios en el país son más comunes en los meses de ausencia de lluvia (julio a diciembre) (INDECI, 2022) y en los pastizales altoandinos en la estación seca (julio a septiembre), correspondiente con la frecuencia acumulada de días secos (DDF) al incrementarse el número de incendios con la disminución de la precipitación desde la estación húmeda (Oliveras et al., 2014). Así mismo, con las tendencias de incendios en la región altoandina (Román-Cuesta

et al., 2014) relacionadas con la periodicidad anual de la precipitación: un incremento en las precipitaciones previo a las temporadas más altas de incendios, seguido de períodos de sequía y temperaturas bajas inusuales (patrón característico de los pastizales por su vegetación que responde a corto plazo a los cambios en el clima). Sin embargo, los incendios no solo ocurren en la estación seca debido a la naturaleza estacional del clima regional; sino también, a razón de creencias culturales y religiosas (posibles factores antropogénicos directos) (Oliveras et al., 2014).

La probabilidad de ocurrencia de incendios estuvo en un rango de 0.0055 a 1. En el mapa de probabilidad (Fig. 5), esta guardó una buena correlación con los incendios pasados correspondientes al periodo 2017 – 2023. De los 1265 puntos de presencia considerados en el modelado, 618 (48.85 %) se ubicaron en zonas de *muy alta* probabilidad de ocurrencia de incendios (0.75 - 1), 429 (33.91 %) en zonas de *alta* probabilidad (0.50 – 0.75), 173 (13.68 %) en zonas de *moderada* probabilidad (0.25 – 0.50) y 45 (3.56 %) en zonas de *baja* probabilidad (0.01 – 0.25) (Fig. 6). En total, el 82.77 % de los puntos de presencia se ubicaron en zonas de *alta* y *muy alta* probabilidad de ocurrencia de incendios, lo cual indica una muy alta confiabilidad para el modelo RF seleccionado. El 11.53 % del área de estudio (2001.40 km²) comprendió zonas de *muy alto* riesgo de incendios, las zonas de *alto* riesgo cubrieron el 23.48 % del área (4074.87 km²), las de riesgo *moderado* el 23.95 % (4156.79 km²) y las de *bajo* riesgo el 41.02 % (7120.02 km²).

El mapa mostró una clara diferenciación geográfica en la distribución espacial de la probabilidad de riesgo de incendios en las

provincias de estudio (Fig. 6). Zonas de *muy alta* probabilidad se encontraron ubicadas en las tres provincias de estudio. Los incendios ocurrieron principalmente en el centro, sur y suroeste de la provincia de Melgar; en el noreste y sureste de la provincia de Lampa y tuvieron una distribución irregular en la provincia de Azángaro (Fig. 5).

La predicción espacial del modelo RF seleccionado (Tabla A.1) reveló que los distritos con mayor porcentaje de su superficie representado por zonas de *muy alto* riesgo de incendios fueron: Llalli (32.47 %), Cupi (32.09 %) y Ayaviri (25.08 %) en la provincia de Melgar; Chupa (26.18 %) en la provincia de Azángaro y Lampa (23.47 %) en la provincia de Lampa. En cambio, los distritos con mayor extensión de zonas de *muy alto* riesgo de incendios fueron: Ayaviri (255.08 km²), Santa Rosa (154.06 km²) y Macari (153.66 km²) en la provincia de Melgar; así como, Lampa (155.03 km²) y Santa Lucía (152.33 km²) en la provincia de Lampa.

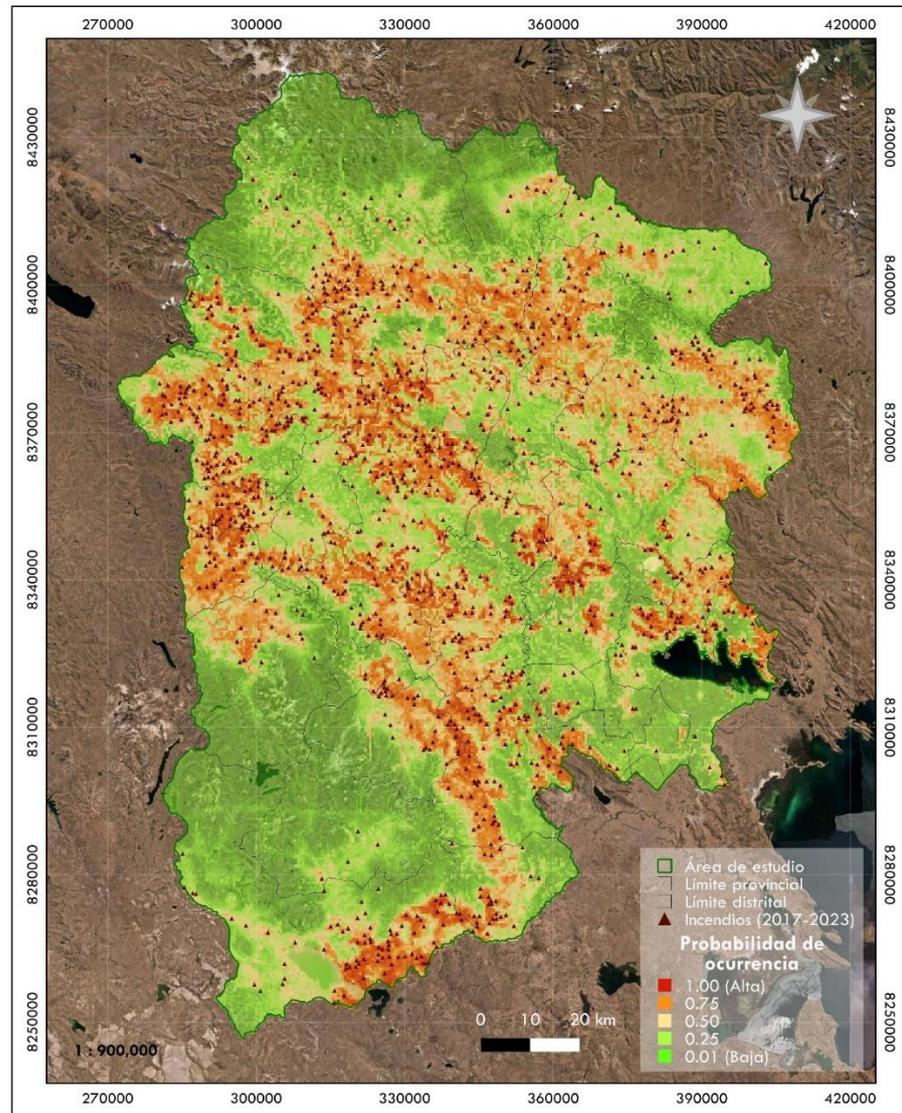
Por otro lado, aquellos con mayor porcentaje de su superficie representado por zonas de *alto* riesgo de incendios fueron: Llalli (48.11 %) y Cupi (36.80 %) en la provincia de Melgar; San José (44.04 %), San Antón (43.65 %) y Muñani (37.40 %) en la provincia de Azángaro y Pucará (36.05 %) en la provincia de Lampa. Asimismo, los distritos con mayor extensión de zonas de *alto* riesgo de incendios fueron: Nuñoa (389.91 km²), Ayaviri (311.03 km²) y Santa Rosa (264.09 km²) en la provincia de Melgar; así como, Muñani (293.10 km²) y Azángaro (254.60 km²) en la provincia de Azángaro.



Las zonas de *muy alta* probabilidad de ocurrencia se caracterizaron por estar en un rango de elevación de 3889.66 a 4770.11 m s.n.m., también por poseer tasas de evapotranspiración potencial de 48.17 a 64.06 mm/día, temperaturas máximas de 13.88 a 17.08 °C, valores del Índice de Vegetación Ajustado al Suelo de 0.10 a 0.24, Frecuencias Acumuladas de Días Calurosos de 0 a 138 días, Frecuencias Acumuladas de Días Secos de 42 a 113 días y valores del Índice de Posición Topográfica (calculado a un radio de 1000 m) entre -3.12 y 4.18. Mientras que, las zonas de *alta* probabilidad de ocurrencia se caracterizaron por ubicarse en un rango más amplio de elevación, de 3816.78 a 5135.17 m s.n.m.; por poseer menores tasas de evapotranspiración potencial (43.63 a 64.08 mm/día), temperaturas máximas ligeramente inferiores (13.73 a 17.08 °C); un rango más amplio de valores para el Índice de Vegetación Ajustado al Suelo (-0.004 a 0.35) y para el Índice de Posición Topográfica calculado a un radio de 1000 m (-3.82 a 4.22). No obstante, las Frecuencias Acumuladas de Días Calurosos y Días Secos fueron casi idénticas (de 0 a 139 días y de 42 a 113 días, respectivamente).

Figura 5

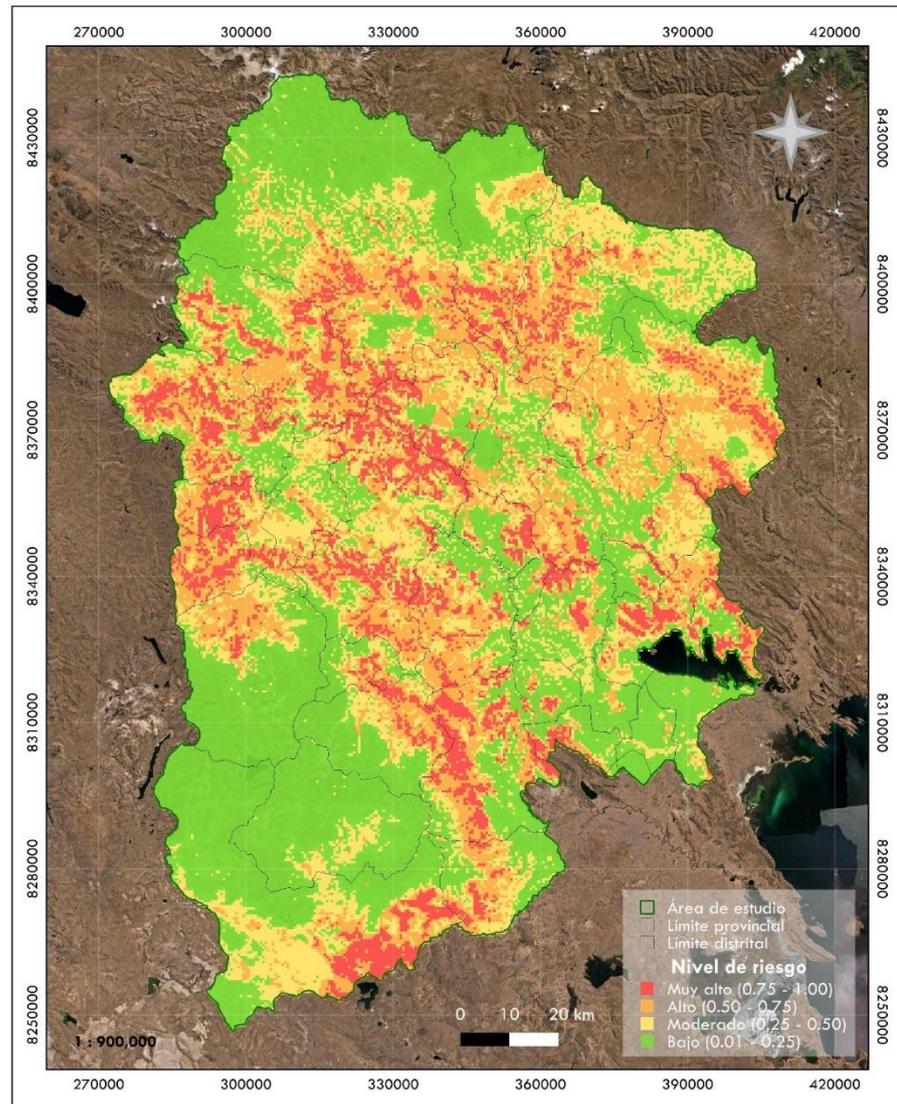
Mapa de probabilidad de ocurrencia de incendios basado en el modelo de clasificación Random Forest seleccionado



Nota: En el mapa se muestran superpuestos los puntos de ocurrencia de incendios registrados en el periodo 2017 – 2023 que fueron empleados en el modelado. Fuente satelital: Esri.

Figura 6

Mapa del nivel de riesgo de incendios basado en el modelo de clasificación Random Forest seleccionado



Nota: El mapa muestra la clasificación de los valores de probabilidad del modelo RF en zonas de riesgo de incendios: muy alto (0.75 – 1.00), alto (0.50 – 0.75), moderado (0.25 – 0.50) y bajo (0.01 – 0.25). Fuente satelital: Esri.

4.1.2 Modelado Lineal Generalizado (GLM)

La selección final de modelos lineales generalizados binomiales para modelar la ocurrencia de incendios en el periodo 2017 - 2023 (Tabla 12) comprendió: al modelo saturado ($m1$), al modelo nulo ($m2$), al modelo construido con todas las variables que guardaron una alta correlación con la variable binaria de respuesta (Correlación de Pearson, $p < 0.05$) ($m3$), al modelo construido con las variables explicativas del modelo Random Forest ($m4$) y los mejores 15 modelos del total de 16383 creados con todas las posibles combinaciones de variables explicativas.

Tabla 12

Variables explicativas empleadas en los GLMs binomiales seleccionados para modelar la ocurrencia de incendios

N° Var.	Cod.	Nombre	Variables explicativas														Todas las var. son sig.		
			1	2	3	4	5	6	7	8	9	10	11	12	13	14	> Chi (χ)	> z	
14	(m1)	Saturado	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	No	No
0	(m2)	Nulo																-	-
4	m5	m4-243	x						x		x		x					Sí	Sí
5	m6	m5-462	x			x			x		x		x					Sí	Sí
8	m88	m8-1582	x			x			x	x	x		x	x	x			No	No
8	m89	m8-1546	x			x		x	x		x		x	x	x			No	No
8	m90	m8-1490	x			x	x		x		x		x	x	x			No	No
8	m91	m8-1527	x			x		x	x	x	x		x		x			No	No
8	m92	m8-1471	x			x	x		x	x	x		x		x			No	No
7	m10	m7-1465	x			x			x	x	x		x		x			No	No
7	m11	m7-1484	x			x			x		x		x	x	x			No	No
7	m12	m7-1340	x			x	x		x		x		x		x			No	No
7	m13	m7-1410	x			x		x	x		x		x		x			No	No
7	m14	m7-751	x	x					x	x	x		x		x			No	No
5	m7	m5-675	x						x		x		x		x			No	No
5	m8	m5-652	x						x	x	x		x					Sí	No
6	m9	m6-972	x			x			x	x	x		x					Sí	No
7	m4	modRF	x	x	x	x			x		x		x					Sí	Sí
12	m3	modSig	x	x	x	x	x		x	x	x	x	x	x	x			No	No

Nota: Las variables explicativas son: TMAX (1), DDF (2), HDF (3), EVAP (4), SLOPE (5), ASPECT (6), DEM (7), TWI (8), TPI500 (9), TPI1000 (10), TPI2000 (11), SAVI (12), Caminos (13), CP (14). Se detalla para cada modelo si todas las variables explicativas empleadas (en términos lineales y/o cuadráticos) son significativas (prueba χ^2 y prueba de Wald con distribución z o normal). La significancia fue promediada a partir de cinco iteraciones de VC empleando los datos de entrenamiento.



De esta selección de modelos cuadráticos o polinomiales de segundo orden, solo tres ($m4$, $m5$ y $m6$) tuvieron a todas sus variables explicativas, en al menos alguno de sus términos, como significativas en la prueba χ^2 y la prueba de Wald. Por otro lado, los modelos $m8$ y $m9$ tuvieron a todas sus variables como significativas en la prueba χ^2 , más no en la prueba de Wald.

Como se esperaba en la evaluación general de la selección (Tabla 13), el modelo nulo tuvo el menor valor para la medida de bondad de ajuste considerada (Pseudo R^2 de McFadden o PR^2 , ajustado) (0); así como, el mayor valor para la medida de calidad relativa (AIC de 2807.53). Por lo cual, dichos valores fueron considerados como el umbral más bajo para la selección de modelos y la selección del modelo final. El modelo saturado tuvo una considerable mejora en bondad de ajuste y calidad relativa en comparación con el modelo nulo (PR^2 de 0.21 y AIC de 2253.18) y por tanto, fue considerado como nuevo umbral para la selección.

El modelo saturado ($m1$), el modelo con variables altamente correlacionadas con la ocurrencia ($m3$) y el modelo equivalente al modelo RF seleccionado ($m4$) estuvieron compuestos por variables altamente correlacionadas entre sí (con valores para el GVIF, ≥ 5). Por el contrario, los modelos restantes (los 15 mejores de todas las combinaciones) presentaron una baja multicolinealidad debido al método de selección de variables.

Entre los modelos que tuvieron todas sus variables explicativas significativas (en términos lineales y/o cuadráticos) y baja multicolinealidad ($m5$ y $m6$), fue el modelo $m5$ el que presentó un menor valor de AIC, seguido del modelo $m6$. Inversamente, el Pseudo R^2 del primero fue menor al del segundo. Consecutivamente, el modelo $m88$ tuvo el menor valor de AIC entre los modelos

de baja multicolinealidad, seguido de los modelos $m89$, $m90$, $m91$, $m92$, $m10$, $m11$, $m12$, $m13$, $m14$, $m7$, $m8$ y $m9$. Respecto al Pseudo R^2 , fue el modelo $m89$ el que tuvo el valor más alto para la medida de bondad de ajuste, seguido de los modelos $m91$, $m11$, $m10$, $m8$, $m90$, $m9$, $m13$, $m12$, $m88$, $m7$, $m92$ y $m14$. En líneas generales, todos los modelos (incluyendo al modelo saturado), explicaron del 19.85 al 20.65 % de la variación de la variable respuesta.

Tabla 13

Evaluación general de los GLMs binomiales seleccionados para modelar la ocurrencia de incendios

Cod.	Nombre	N° variables	gl residuales	Pseudo R^2 ajustado	AIC	Baja colinealidad (GVIF < 5)	Valor p ($> \chi^2$)
(m1)	Saturado	14	1995	0.205319	2253.18	No	-
(m2)	Nulo	0	2023	0.000000	2807.53	-	-
m5	m4-243	4	2015	0.199838	2249.84	Sí	
m6	m5-462	5	2013	0.202997	2252.82	Sí	
m88	m8-1582	8	2007	0.202172	2239.33	Sí	
m89	m8-1546	8	2007	0.206497	2239.41	Sí	
m90	m8-1490	8	2007	0.203687	2239.59	Sí	
m91	m8-1527	8	2007	0.205626	2240.29	Sí	
m92	m8-1471	8	2007	0.199253	2240.59	Sí	
m10	m7-1465	7	2009	0.205381	2241.86	Sí	
m11	m7-1484	7	2009	0.205465	2242.70	Sí	< 2.2e-16 ***
m12	m7-1340	7	2009	0.202334	2243.12	Sí	
m13	m7-1410	7	2009	0.203183	2243.26	Sí	
m14	m7-751	7	2009	0.198468	2244.09	Sí	
m7	m5-675	5	2013	0.201641	2253.50	Sí	
m8	m5-652	5	2013	0.204102	2253.78	Sí	
m9	m6-972	6	2011	0.203681	2253.85	Sí	
m4	modRF	7	2009	0.204591	2246.24	No	
m3	modSig	12	1999	0.201124	2264.58	No	

Nota: gl: grados de libertad. Los asteriscos indican el nivel de significancia para todos los modelos: "****" $p < 0.001$. Significancia de los GLMs por análisis de desviaciones (prueba χ^2). Los valores fueron promediados a partir de cinco iteraciones de Validación Cruzada empleando los datos de entrenamiento.

Al comparar cada modelo con el modelo nulo, mediante un análisis de desviaciones, se evidenció que todos los GLMs considerados en la selección fueron significativos ($p < 0.05$). Es decir, todos los modelos de la selección

(exceptuando el modelo nulo y el modelo saturado) redujeron, proporcional y significativamente la desviación.

A través de un análisis de compensación de las métricas de rendimiento promediadas para cada modelo (Tabla 14), los modelos *m5*, *m88*, *m89*, *m91* y *m92* fueron elegidos como los mejores para modelar la ocurrencia de incendios por contar con las mejores métricas acorde al orden de interés considerado.

Tabla 14

Métricas de rendimiento de la selección de GLMs binomiales para modelar la ocurrencia de incendios

Cod.	SE	Precisión	F1	SP	Exactitud	AUC	B. G.
(m1)	0.8234	0.6916	0.7505	0.6150	0.7225	0.7735	0.0233
(m2)	1.0000	0.4901	0.6575	0.0000	0.4901	0.5000	0.5 – 0.5*
m5	0.8261	0.7001	0.7575	0.6453	0.7364	0.7902	-0.0027
m6	0.7906	0.6777	0.7296	0.6402	0.7138	0.7867	0.0023
m88	0.8400	0.7001	0.7634	0.6323	0.7384	0.7861	0.0052
m89	0.8387	0.6901	0.7566	0.6126	0.7281	0.7780	0.0156
m90	0.8133	0.6951	0.7487	0.6408	0.7280	0.7794	0.0130
m91	0.8329	0.6836	0.7497	0.6156	0.7245	0.7753	0.0169
m92	0.8285	0.7115	0.7653	0.6453	0.7403	0.7931	-0.0047
m10	0.8108	0.6879	0.7441	0.6237	0.7182	0.7781	0.0137
m11	0.8046	0.6935	0.7442	0.6290	0.7190	0.7800	0.0124
m12	0.7927	0.6988	0.7425	0.6667	0.7289	0.7861	0.0036
m13	0.8107	0.6952	0.7468	0.6450	0.7269	0.7821	0.0093
m14	0.7939	0.7181	0.7538	0.6859	0.7403	0.7952	-0.0077
m7	0.7830	0.6933	0.7350	0.6728	0.7261	0.7869	0.0019
m8	0.8122	0.6954	0.7485	0.6426	0.7269	0.7798	0.0103
m9	0.8306	0.6871	0.7516	0.6052	0.7206	0.7800	0.0101
m4	0.8023	0.6954	0.7449	0.6443	0.7237	0.7866	0.0052
m3	0.7743	0.6958	0.7327	0.6717	0.7225	0.7934	-0.0028

Nota: SE: Sensibilidad. F1: Puntaje F1. SP: Especificidad. AUC: Valor AUC-ROC. B. G.: Brecha de Generalización. “*”: Clasificador aleatorio. Los valores fueron promediados a partir de cinco iteraciones de Validación Cruzada empleando los datos de validación. En negrita se observan los mejores modelos.

De acuerdo con el análisis y el orden de las métricas de interés, el mejor modelo de la selección fue el modelo *m92* con 82.85 % de sensibilidad (un incremento del 0.51 % frente al modelo saturado), 71.15 % de precisión (un



incremento del 22.14 % frente al modelo nulo y del 1.99 % frente al modelo saturado), 76.53 % de puntaje F1 (un incremento del 10.78 % frente al modelo nulo y del 1.48 % frente al modelo saturado), 64.53 % de especificidad (un incremento del 3.03 % frente al modelo saturado), 74.03 % de exactitud (un incremento del 25.02 % frente al modelo nulo y del 1.78 % frente al modelo saturado) y un valor de AUC de 0.793 (un incremento de 0.293 frente a un clasificador aleatorio y de 0.019 frente al modelo saturado). Mientras que el valor promedio de la Brecha de Generalización calculada para este modelo respecto al AUC fue de -0.005, lo cual indica que este modelo no mostró sobreajuste e incluso tuvo un mejor desempeño con los datos de validación.

El segundo mejor modelo de la selección fue el modelo *m88* con 84 % de sensibilidad (un incremento del 1.66 % frente al modelo saturado), 70.01 % de precisión (un incremento del 21 % frente al modelo nulo y del 0.85 % frente al modelo saturado), 76.34 % de puntaje F1 (un incremento del 10.59 % frente al modelo nulo y del 1.29 % frente al modelo saturado), 63.23 % de especificidad (un incremento del 1.73 % frente al modelo saturado), 73.84 % de exactitud (un incremento del 24.83 % frente al modelo nulo y del 1.59 % frente al modelo saturado) y un valor de AUC de 0.786 (un incremento de 0.286 frente a un clasificador aleatorio y de 0.012 frente al modelo saturado). Mientras que el valor promedio de la Brecha de Generalización calculada para este modelo respecto al AUC fue de 0.005, lo cual indica que este modelo mostró un muy bajo sobreajuste.

El tercer mejor modelo de la selección fue el modelo *m5* con 82.61 % de sensibilidad (un incremento del 0.27 % frente al modelo saturado), 70.01 % de precisión (un incremento igual al del segundo mejor modelo), 75.75 % de puntaje F1 (un incremento del 10 % frente al modelo nulo y del 0.7 % frente al modelo



saturado), 64.53 % de especificidad (un incremento igual al del primer mejor frente al modelo saturado), 73.64 % de exactitud (un incremento del 24.63 % frente al modelo nulo y del 1.39 % frente al modelo saturado) y un valor de AUC de 0.79 (un incremento de 0.29 frente a un clasificador aleatorio y de 0.016 frente al modelo saturado). Mientras que el valor promedio de la Brecha de Generalización calculada para este modelo respecto al AUC fue de -0.003, lo cual indica que este modelo no mostró sobreajuste y tuvo un mejor desempeño con los datos no utilizados en el entrenamiento.

El cuarto mejor modelo de la selección fue el modelo *m89* con 83.87 % de sensibilidad (un incremento del 1.53 % frente al modelo saturado), 69.01 % de precisión (un incremento del 20 % frente al modelo nulo), 75.66 % de puntaje F1 (un incremento del 9.91 % frente al modelo nulo y del 0.61 % frente al modelo saturado), 72.81 % de exactitud (un incremento del 23.8 % frente al modelo nulo y del 0.56 % frente al modelo saturado) y un valor de AUC de 0.778 (un incremento de 0.278 frente a un clasificador aleatorio y de 0.004 frente al modelo saturado). Mientras que el valor promedio de la Brecha de Generalización calculada para este modelo respecto al AUC fue de 0.016, lo cual indica que este modelo mostró un ligero sobreajuste.

El quinto mejor modelo de la selección fue el modelo *m91* con 83.29 % de sensibilidad (un incremento del 0.95 % frente al modelo saturado), 68.36 % de precisión (un incremento del 19.35 % frente al modelo nulo), 74.97 % de puntaje F1 (un incremento del 9.22 % frente al modelo nulo), 61.56 % de especificidad (un incremento del 0.06 % frente al modelo saturado), 72.45 % de exactitud (un incremento del 23.44 % frente al modelo nulo y del 0.2 % frente al modelo saturado) y un valor de AUC de 0.775 (un incremento de 0.275 frente a un

clasificador aleatorio y de 0.001 frente al modelo saturado). Mientras que el valor promedio de la Brecha de Generalización respecto al AUC fue de 0.017, lo cual indica que este modelo también mostró un ligero sobreajuste.

Tabla 15

Resumen del GLM binomial saturado (m1) para modelar la ocurrencia de incendios

Parámetro del modelo	Coefficiente estimado	Error Estándar (SE)	Valor del estadístico z	Valor p (> z)	Orden de Imp.
(Intercepto)	-0.18978	0.05265	-3.605	0.000313 ***	-
TMAX, 1	5.04234	8.77230	0.575	0.565425	23
TMAX, 2	-22.56946	5.01306	-4.502	6.73e-06 ***	4
DDF, 1	10.75552	4.10282	2.621	0.008755 **	6
DDF, 2	-0.47256	2.89079	-0.163	0.870148	28
HDF, 1	14.88170	7.78291	1.912	0.055863	8
HDF, 2	-2.73400	3.55014	-0.770	0.441234	20
EVAP, 1	10.45818	7.61237	1.374	0.169491	11
EVAP, 2	-11.71136	3.71174	-3.155	0.001604 **	5
SLOPE, 1	-2.59018	2.34388	-1.105	0.269123	13
SLOPE, 2	-1.21509	2.34636	-0.518	0.604555	25
ASPECT, 1	2.06597	2.34856	0.880	0.379036	16
ASPECT, 2	1.94790	2.35283	0.828	0.407729	18
DEM, 1	-27.06913	5.60198	-4.832	1.35e-06 ***	3
DEM, 2	-50.99499	4.19200	-12.165	2.00e-16 ***	1
TWI, 1	-2.80653	3.66148	-0.767	0.443378	21
TWI, 2	-3.20177	2.67024	-1.199	0.230506	12
TPI500, 1	-5.56703	6.75402	-0.824	0.409796	19
TPI500, 2	7.23517	4.74246	1.526	0.127106	10
TPI1000, 1	26.39627	10.63597	2.482	0.013072 *	7
TPI1000, 2	-3.11706	6.95056	-0.448	0.653820	26
TPI2000, 1	-7.31611	7.34564	-0.996	0.319260	14
TPI2000, 2	-2.49514	4.69878	-0.531	0.595406	24
SAVI, 1	-18.46403	3.41592	-5.405	6.47e-08 ***	2
SAVI, 2	-1.56552	3.69549	-0.424	0.671835	27
CAMINOS, 1	-3.30936	3.72135	-0.889	0.373846	15
CAMINOS, 2	2.65330	4.09626	0.648	0.517155	22
CP, 1	4.60151	2.72119	1.691	0.090839	9
CP, 2	2.15101	2.48406	0.866	0.386532	17
Pseudo R ²					0.213038
Pseudo R ² ajustado					0.204227
AIC					2818.133

Nota: Observaciones: 2530. Los asteriscos indican el nivel de sig. de los coef.: "****" p < 0.001, "****" p < 0.01, "*" p < 0.05. Orden de importancia de los términos de cada variable en base al |z| y al Valor p.

En cuanto al orden de importancia de los términos de todas las variables explicativas utilizadas en el modelado de la ocurrencia, los valores absolutos del estadístico z (y sus correspondientes Valores p) del resumen del GLM binomial saturado, evidenciaron que el de mayor importancia fue el término cuadrático de la elevación, seguido del término lineal del SAVI, el término lineal de la elevación, el término cuadrático de la temperatura máxima, el término cuadrático de la evapotranspiración potencial, el término lineal de la Frecuencia Acumulada de Días Secos y el término lineal del Índice de Posición Topográfica calculado a un radio de 1000 m (Tabla 15).

Tabla 16

Prueba χ^2 del GLM binomial saturado (m1)

VARIABLES explicativas	gl	Desviación resultante	Orden de Imp.	gl residuales	Desviación residual	Valor p ($> \chi$)
(modelo nulo)				2529	3507.33	
TMAX	2	192.58	2	2527	3314.74	< 2.2e-16 ***
DDF	2	8.94	10	2525	3305.81	0.011462 *
HDF	2	13.37	8	2523	3292.44	0.001250 **
EVAP	2	100.40	3	2521	3192.03	< 2.2e-16 ***
SLOPE	2	16.49	7	2519	3175.54	0.000262 ***
ASPECT	2	3.34	12	2517	3172.20	0.188358
DEM	2	316.49	1	2515	2855.71	< 2.2e-16 ***
TWI	2	9.46	9	2513	2846.25	0.008829 **
TPI500	2	21.80	5	2511	2824.45	1.85e-05 ***
TPI1000	2	21.43	6	2509	2803.02	2.22e-05 ***
TPI2000	2	0.29	14	2507	2802.73	0.866332
SAVI	2	37.47	4	2505	2765.26	7.31e-09 ***
CAMINOS	2	1.76	13	2503	2763.50	0.413947
CP	2	3.37	11	2501	2760.13	0.185868

Nota: gl: grados de libertad. Los asteriscos indican el nivel de sig. de la var. en el modelo: "****" $p < 0.001$, "***" $p < 0.01$, "**" $p < 0.05$. Significancia de las variables explicativas por comparaciones sucesivas entre versiones más simples y versiones más complejas del modelo, adicionando una variable a la vez (análisis de desviaciones).

En cambio, el orden de importancia de todas las variables explicativas basado en la contribución de cada variable a la disminución de la desviación como resultado del análisis de desviaciones o Prueba χ^2 (Valores p) del GLM binomial

saturado (Tabla 16), destacó a la elevación como la variable más importante, seguida de la temperatura máxima, la evapotranspiración potencial, el SAVI, el Índice de Posición Topográfica calculado a un radio de 500 m, el calculado a un radio de 1000 m y la pendiente.

A su vez, los resultados del Análisis de Dominancia General, en cuanto al orden de importancia de todas las variables explicativas (considerando la contribución condicional promedio de cada variable al Pseudo R^2), también posicionaron a la elevación en el primer lugar de importancia, seguida de la evapotranspiración potencial, la temperatura máxima, el SAVI, la Frecuencia Acumulada de Días Calurosos, el Índice de Humedad Topográfica y el Índice de Posición Topográfica calculado a un radio de 1000 m (Tabla 17). Las subsiguientes variables tuvieron valores menores o iguales al del TPI de 1000 m.

Tabla 17

Orden de importancia de las variables explicativas del modelo saturado (m1) según el Análisis de Dominancia General y empleando la base de datos completa para modelar ocurrencia de incendios

Imp.	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Var.	DEM	EVAP	TMAX	SAVI	HDF	TWI	TPI1000	CAMINOS	DDF	TPI2000	TPI500	SLOPE	CP	ASPECT
cPR ²	0.093	0.028	0.022	0.017	0.012	0.010	0.006	0.006	0.006	0.005	0.004	0.002	0.002	0.001
Esc.	100.0	29.80	23.31	18.11	11.89	9.91	5.98	5.76	5.52	4.43	3.64	1.06	0.96	0.00

Nota: Los valores corresponden a la contribución condicional promedio de cada variable al Pseudo R^2 de McFadden (cPR²) en todos los posibles modelos de subconjuntos de variables. Los valores fueron escalados de 0 a 100.

Entretanto, los modelos *m5*, *m6*, *m7*, *m8* y *m9* fueron los más parsimoniosos de la selección, conformados por 4; 5 o 6 variables explicativas. Los coeficientes estimados y promediados para cada uno de ellos se presentan en la Tabla 18.

Tabla 18

Coefficientes estimados de los GLMs binomiales más parsimoniosos para modelar la ocurrencia de incendios

Cod.	Modelo
m5	$\ln\left(\frac{Y}{I-Y}\right) = -0.19 + 24.2X_1 - 20.32X_1^2 - 30.68X_7 - 51.25X_7^2 + 14.67X_{10} + 1.15X_{10}^2 - 19.81X_{12} + 0.84X_{12}^2$
m6	$\ln\left(\frac{Y}{I-Y}\right) = -0.15 + 20.66X_1 - 16.95X_1^2 + 5.79X_4 - 4.93X_4^2 - 28.05X_7 - 47.15X_7^2 + 14.94X_{10} + 2.18X_{10}^2 - 19.56X_{12} + 0.58X_{12}^2$
m7	$\ln\left(\frac{Y}{I-Y}\right) = -0.19 + 23.21X_1 - 20.76X_1^2 - 33.44X_7 - 50.69X_7^2 + 14.98X_{10} + 1.79X_{10}^2 - 20.03X_{12} + 0.95X_{12}^2 + 2.94X_{14} + 2.44X_{14}^2$
m8	$\ln\left(\frac{Y}{I-Y}\right) = -0.17 + 23.53X_1 - 19.87X_1^2 - 30.08X_7 - 48.94X_7^2 - 2.15X_8 - 3.63X_8^2 + 14.7X_{10} + 0.75X_{10}^2 - 19.24X_{12} + 1.8X_{12}^2$
m9	$\ln\left(\frac{Y}{I-Y}\right) = -0.18 + 19.6X_1 - 17.13X_1^2 + 7.59X_4 - 6.82X_4^2 - 27.91X_7 - 45.15X_7^2 - 1.9X_8 - 4.27X_8^2 + 14.48X_{10} + 1.59X_{10}^2 - 19.51X_{12} + 2.74X_{12}^2$

Nota: Los coeficientes fueron promediados a partir de cinco iteraciones de Validación Cruzada empleando los datos de entrenamiento.

Los modelos anidados *m89*, *m90*, *m91*, *m92* y *m3* utilizaron las mismas variables que el resto de modelos de la selección. Sin embargo, incorporaron adicionalmente diferentes variables por lo que no estuvieron anidados entre sí. El resto de modelos estuvieron anidados entre sí hasta cierto punto. Teniendo ello en cuenta, todos los modelos pudieron ser evaluados comparativamente mediante pruebas de razón de verosimilitud. Los valores *p* de las comparaciones por pares (Pruebas χ^2) para los GLMs anidados de la selección (Tabla 19), evidenciaron que todos los modelos tuvieron una capacidad muy similar para explicar la variación (desviación) observada en la ocurrencia de incendios, sin diferencias significativas entre ellos (se aceptaron las hipótesis nulas de las pruebas).

Tabla 19

Valores p (prueba χ^2) de las comparaciones por pares entre los GLMs binomiales seleccionados para modelar la ocurrencia de incendios (pruebas de razón de verosimilitud, Likelihood Ratio Tests o LRT)

Cod.	m5	m6	m88	m89	m90	m91	m92	m10	m11	m12	m13	m14	m7	m8	m9	m4	m3
m5	-																
m6	0.10*	-															
m88	0.18*	0.34*	-														
m89	0.22*	0.41*	-	-													
m90	0.17*	0.33*	-	-	-												
m91	0.25*	0.45*	-	-	-	-											
m92	0.20*	0.37*	-	-	-	-	-										
m10	0.18*	0.35*	0.33*	0.49	0.29	0.54*	0.40*	-									
m11	0.16*	0.34*	0.37*	0.48*	0.35*	0.36	0.35	-	-								
m12	0.18*	0.34*	0.22	0.34	0.34*	0.37	0.43*	-	-	-							
m13	0.23*	0.45*	0.25	0.33*	0.24	0.39*	0.28	-	-	-	-						
m14	0.46*	0.65	0.05	0.08	0.06	0.10	0.08	-	-	-	-	-					
m7	0.25*	-	0.19*	0.23*	0.18*	0.28*	0.23*	0.19*	0.16*	0.19*	0.25*	0.61*	-				
m8	0.40*	-	0.15*	0.20	0.16	0.22*	0.18*	0.15*	0.14	0.17	0.21	0.46*	-	-			
m9	0.15*	0.38*	0.33*	0.43	0.34	0.46*	0.37*	0.33*	0.36	0.40	0.54	0.75	0.18	0.09*	-		
m4	0.09*	0.24*	0.18	0.31	0.33	0.39	0.47	-	-	-	-	-	0.11	0.07	0.23	-	
m3	0.13*	0.24*	0.25	0.21	0.26	0.22	0.26	0.26	0.25	0.27	0.22	0.08	0.15	0.11*	0.24*	0.29*	-

Nota: El asterisco (“*”) indica modelos anidados. Los valores fueron promediados a partir de cinco iteraciones de Validación Cruzada empleando los datos de entrenamiento.

4.1.2.1 Selección del mejor GLM binomial para modelar la ocurrencia de incendios en pastizales altoandinos en el departamento de Puno

A razón de que los modelos más complejos no proporcionaron un mejor ajuste frente a los modelos más simples, fueron estos últimos los favorecidos en la selección. En otras palabras, la complejidad en los modelos resultó injustificada en relación a la bondad de ajuste. De este modo, acorde a los resultados de las comparaciones por pares (Valores p que respaldan la hipótesis nula en todos los casos), el mejor GLM binomial para modelar la ocurrencia de incendios fue elegido por parsimonia. De la

selección, fue el GLM *m5* el modelo más parsimonioso, conformado por cuatro variables explicativas.

Por otro lado, todas fueron significativas (en sus términos lineales y/o cuadráticos) acorde a la prueba χ^2 y la prueba de Wald. Además, el modelo *m5* mostró una baja multicolinealidad (GVIF < 5 para todas sus variables) y un menor valor AIC frente al modelo *m6* (también conformado por variables significativas). En vista de lo anterior, y considerando a los cinco mejores modelos resultantes del análisis de compensación de las métricas de rendimiento de toda la selección de GLMs binomiales; así como, a la correspondencia de todas las variables explicativas de este modelo (elevación, temperatura máxima, SAVI y TPI calculado a un radio de 1000 m) a los primeros lugares de importancia de las tres jerarquías consideradas, el modelo *m5* fue seleccionado como el mejor GLM para modelar la ocurrencia de incendios.

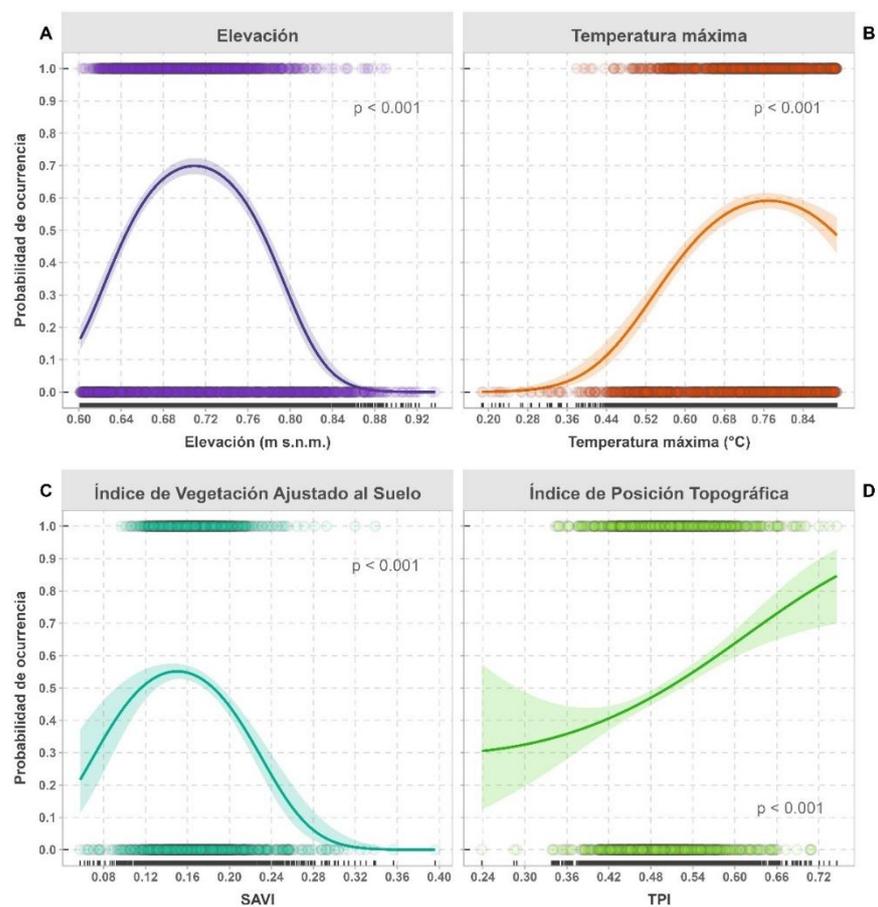
Los diagramas de dispersión de las observaciones correspondientes a la ocurrencia de incendios (variable binaria de respuesta: presencia/ausencia) con curvas suavizadas (regresión polinómica) en relación a cada variable explicativa del modelo seleccionado (Fig. 7) evidencian cómo cambió la probabilidad de ocurrencia a medida que los valores normalizados de cada variable se incrementaron.

Tanto la elevación (en el rango de 3814 y 5186 m s.n.m.), como la temperatura máxima (12.7 – 17.1 °C) y el SAVI (0.06 – 0.40) mostraron asociaciones curvilíneas con los incendios observados en el periodo 2017 – 2023. Por otro lado, el TPI calculado a un radio de 1000 m (-4.08 – 4.18)

mostró una asociación lineal y positiva. La mayor parte de ellos ocurrieron en lugares con elevaciones cercanas a los 4260 m s.n.m., con temperaturas máximas cercanas a los 16.2 °C y valores del SAVI cercanos a 0.15. Fueron menos frecuentes por encima y debajo de estos puntos de inflexión.

Figura 7

La influencia de las variables explicativas del GLM binomial seleccionado para modelar la ocurrencia de incendios



Nota: A – D) Las líneas representan la variación en la probabilidad de ocurrencia a medida que cambian independientemente las variables explicativas (valores normalizados); las regiones sombreadas, intervalos de confianza de 95 %; los círculos sombreados, los valores observados; y los valores p , del estadístico χ , la significancia de las variables por comparaciones sucesivas. TPI a un radio de 1000 m.

Conforme al resumen del GLM binomial seleccionado y construido con todas las observaciones, este explicó el 20.17 % de la variación en la

ocurrencia de incendios (PR^2 ajustado de 0.2) y contó con un AIC menor al del modelo saturado (2809.14, una reducción de 8.99) (Tabla 20). Lo que implica que el modelo fue parsimonioso y a la vez lo suficientemente informativo. En cuanto al orden de importancia de los términos de sus variables explicativas, los valores absolutos del estadístico z posicionaron al término cuadrático de la elevación en primer lugar, seguido de su término lineal, el término lineal de la temperatura máxima, el término lineal del SAVI, el término cuadrático de la temperatura máxima y el término lineal del TPI calculado a un radio de 1000 m.

Tabla 20

Resumen del GLM binomial seleccionado (m5) para modelar la ocurrencia de incendios

Parámetro del modelo	Coefficiente estimado	Error Estándar (SE)	Valor del estadístico z	Valor p ($> z $)
(Intercepto)	-0.17376	0.05063	-3.432	0.000599 ***
TMAX, 1	26.95048	3.39427	7.940	2.02e-15 ***
TMAX, 2	-23.55600	3.45464	-6.819	9.19e-12 ***
DEM, 1	-32.45455	3.92328	-8.272	< 2e-16 ***
DEM, 2	-54.21368	3.51863	-15.408	< 2e-16 ***
TPI1000, 1	15.52046	2.73344	5.678	1.36e-08 ***
TPI1000, 2	1.08790	2.72621	0.399	0.689856
SAVI, 1	-22.18706	3.00875	-7.374	1.65e-13 ***
SAVI, 2	1.08495	3.41834	0.317	0.750946
Pseudo R^2				0.20420
Pseudo R^2 ajustado				0.20167
AIC				2809.14

Nota: Observaciones: 2530. Los asteriscos indican el nivel de significancia de los coeficientes: "****" $p < 0.001$. Coeficientes estimados y su significancia (prueba de Wald con distribución z o normal) para las variables explicativas empleadas (en términos lineales y/o cuadráticos). Estos indican el incremento o disminución en la probabilidad logarítmica de ocurrencia de un incendio (*logits* o *log-odds*) por cambios unitarios de las variables.

De acuerdo con los coeficientes de regresión estimados para cada uno de los términos de las variables explicativas, la temperatura máxima



guardó una relación lineal y no lineal con las probabilidades predichas de ocurrencia de incendios (el coeficiente del término lineal fue significativamente diferente de cero y el coeficiente del término cuadrático, significativo) (Fig. 8). La probabilidad de ocurrencia de un incendio se incrementó juntamente con la temperatura máxima hasta alcanzar los 15.04 °C (punto de inflexión). Después de ese punto, la probabilidad disminuyó a medida que continuó incrementándose la temperatura. Asimismo, la elevación guardó una relación lineal y no lineal con la probabilidad de ocurrencia de incendios. Esta última tuvo una tendencia a disminuir a medida que la elevación aumentaba. El punto más alto de probabilidad alcanzado correspondió a 4220.28 m s.n.m. (punto de inflexión).

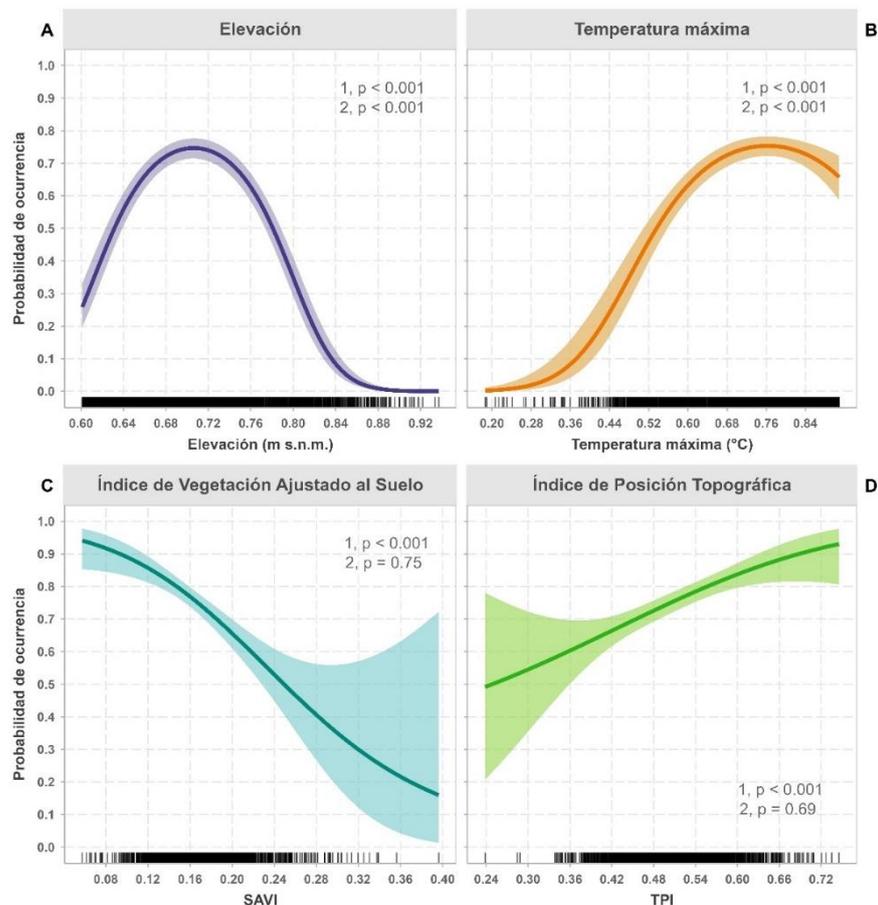
El Índice de Posición Topográfica calculado a un radio de 1000 m guardó únicamente una relación lineal con la probabilidad de ocurrencia de incendios (tan solo el coeficiente del término lineal fue significativamente diferente de cero). La probabilidad de ocurrencia de un incendio se incrementó simultáneamente con el TPI. De igual manera, el Índice de Vegetación Ajustado al Suelo mostró una relación lineal con la probabilidad de ocurrencia de incendios. Esta disminuyó a medida que el SAVI se incrementaba.

Las probabilidades logarítmicas reflejaron diferencias en la ocurrencia de incendios entre los valores observados más bajos y los más altos de cada variable explicativa utilizada en el GLM binomial seleccionado (a razón de la normalización), manteniendo, iterativamente, al resto de variables constantes. Las magnitudes de los coeficientes, por su

parte, manifestaron una posible separación casi-completa para todas las variables.

Figura 8

Los efectos de las variables explicativas del GLM binomial seleccionado para modelar la ocurrencia de incendios



Nota: A - D) Las líneas representan la variación en la probabilidad de ocurrencia a medida que cambian las variables explicativas del modelo (valores normalizados); las regiones sombreadas, intervalos de confianza de 95 %; y los valores p , del estadístico z , la significancia de los términos de las variables. TPI (1000 m).

Las líneas en los gráficos de efectos (Fig. 8) representan el ajuste del GLM para modelar la ocurrencia de incendios empleando a cada una de las variables explicativas que lo conforman sobre todas las observaciones. En otras palabras, cómo cambian las probabilidades

predichas a medida que varía cada variable explicativa, manteniendo a las demás variables constantes en sus valores promedio. Entretanto, las bandas de confianza se amplían o estrechan conforme aumentan o disminuyen las observaciones que corresponden a un determinado rango de valores para las variables. Estas indicaron que se contó con menos casos con elevaciones mayores a los ~ 4870 m s.n.m., con temperaturas inferiores a los ~ 14.6 °C, con valores del SAVI menores a ~ 0.12 o superiores a ~ 0.22, con valores del TPI calculado a un radio de 1000 m menores a ~ -1.30 o superiores a ~ 1.80; y por lo tanto, hubo una menor confiabilidad en las predicciones para estos casos. Las probabilidades predichas estuvieron reflejadas en los coeficientes estimados del modelo (puntos de inflexión) (Tabla 20).

Tabla 21

Prueba de multicolinealidad del GLM binomial seleccionado para modelar la ocurrencia de incendios

Variables explicativas	GVIF	Tolerancia (1/GVIF)	IC del GVIF	IC de la tolerancia	Aumento de SE
TMAX	1.480	0.68	1.41 – 1.56	0.64 – 0.71	1.22
DEM	1.842	0.54	1.74 – 1.95	0.51 – 0.57	1.36
TPI1000	1.202	0.83	1.15 – 1.26	0.79 – 0.87	1.10
SAVI	1.380	0.72	1.32 – 1.45	0.69 – 0.76	1.17

Nota: Estadísticas: Factor de Inflación de la Varianza Generalizada (GVIF), tolerancia, factor de aumento del error estándar por posibles correlaciones entre variables explicativas e intervalos de confianza (IC) del 95%.

Considerando el primer criterio para la selección, el GLM binomial seleccionado se caracterizó, en primer lugar, por contar con una baja multicolinealidad. La prueba de multicolinealidad del modelo (Tabla 21) mostró que el GVIF osciló entre 1.2 y 1.84, mientras que la tolerancia

(recíproca al GVIF) osciló entre 0.54 y 0.83. Todos los valores del GVIF fueron menores a 5 y sus respectivos valores de tolerancia, mayores a 0.2, indicando una muy baja y manejable multicolinealidad entre variables explicativas.

Tabla 22

Prueba de razón de verosimilitud (Likelihood Ratio Test o LRT) del GLM binomial seleccionado para modelar la ocurrencia de incendios

Mod.	gl residuales	Desviación residual	gl resultantes	Desviación resultante	Valor p ($> \chi$)
m_2	2529	3507.3			
m_5	2521	2791.1	8	716.18	$< 2.2e-16$ ***

Nota: gl: grados de libertad. Los asteriscos indican el nivel de significancia del modelo: ”***” $p < 0.001$. Significancia por comparación de la validez predictiva del GLM binomial con el modelo nulo (análisis de desviaciones, prueba χ^2).

El modelo seleccionado explicó la ocurrencia de incendios significativamente mejor que simplemente el valor promedio de los datos de ocurrencia (modelo nulo) como se observó en los resultados de la prueba de razón de verosimilitud para el modelo (Tabla 22), con un valor p menor a 0.001 (gl: 8, términos lineales y cuadráticos de las variables explicativas y una diferencia de 716.18 en las desviaciones residuales). El análisis de desviaciones respaldó la importancia del modelo para predecir la probabilidad de ocurrencia compensando el posible sobreajuste evidenciado con la separación casi-completa de los coeficientes (Tabla 20).

Tabla 23*Prueba χ^2*

Variables explicativas	gl residuales	Desviación residual	gl resultantes	Desviación resultante	Valor p (> χ)
(modelo nulo)	2529	3507.33			
TMAX	2527	3314.74	2	192.58	< 2.2e-16 ***
DEM	2525	2903.62	2	411.12	< 2.2e-16 ***
TPI1000	2523	2850.02	2	53.60	2.297e-12 ***
SAVI	2521	2791.14	2	58.88	1.635e-13 ***

Nota: gl: grados de libertad. Los asteriscos indican el nivel de significancia de la variable en el modelo: "****" $p < 0.001$. Significancia de las variables explicativas del GLM binomial seleccionado para modelar la ocurrencia de incendios por comparaciones sucesivas entre versiones más simples y versiones más complejas del modelo, adicionando una variable a la vez (análisis de desviaciones).

El orden de importancia de las variables explicativas del modelo seleccionado, basado en la contribución secuencial de cada una a la disminución de la desviación residual de la ocurrencia de incendios como resultado de la Prueba χ^2 (Tabla 23), coincidió con el orden de importancia general basado en la misma prueba (Tabla 16) identificando a la elevación como la variable más importante, seguida de la temperatura máxima, el SAVI y el TPI calculado a un radio de 1000 m. Todas ellas fueron relevantes según el análisis. Análogamente, los resultados del Análisis de Dominancia General (Tabla 24) para el GLM seleccionado concordaron con el orden de importancia de la Prueba χ^2 (Tabla 23).

Tabla 24

Orden de importancia de las variables explicativas del GLM binomial seleccionado según el Análisis de Dominancia General y empleando la base de datos completa para modelar la ocurrencia de incendios

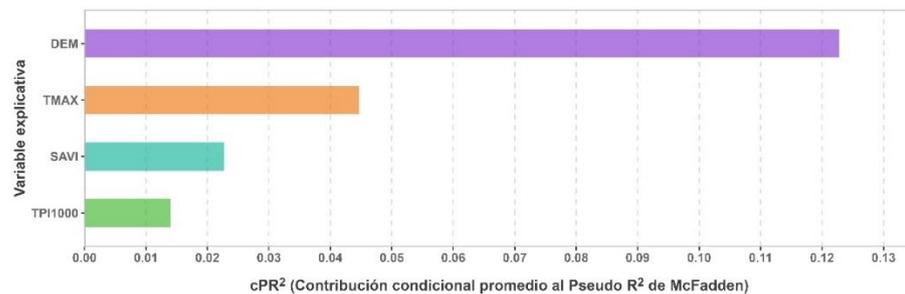
Variable explicativa	Orden de importancia	Contribución promedio al PR²	Valores escalados	Contribución relativa
DEM	1	0.1227542	100.0000	0.6011567
TMAX	2	0.0446615	28.1651	0.2187180
SAVI	3	0.0227382	7.9985	0.1113542
TPI1000	4	0.0140428	0.0000	0.0687711

Nota: Los valores corresponden a la contribución condicional promedio de cada variable al PR² en todos los posibles modelos de subconjuntos de variables. Se muestran los valores escalados de 0 a 100; así como la contribución relativa de cada variable.

Acorde a las contribuciones relativas de cada variable explicativa a la bondad de ajuste del modelo, fue la elevación la que contribuyó más a la reducción de la variación en la ocurrencia de incendios, en un 60.12 % (adición promedio al Pseudo R²: 0.123), constituyéndose como la variable más importante del GLM seleccionado. En segundo lugar, la temperatura máxima que contribuyó con el 21.87 % (adición promedio: 0.045). En tercer lugar, el Índice de Vegetación Ajustado al Suelo que contribuyó con el 11.14 % (adición promedio: 0.023). Finalmente, la última variable de importancia del modelo fue el Índice de Posición Topográfica calculado a un radio de 1000 m, que contribuyó tan solo con el 6.88 % (adición promedio: 0.014) (Fig. 9 y Tabla 24).

Figura 9

Gráfico de importancia de las variables consideradas en el GLM binomial seleccionado para modelar la ocurrencia de incendios



Nota: La importancia de cada variable mediante el Análisis de Dominancia General y empleando la base de datos completa.

Con relación al rendimiento de la predicción del GLM binomial seleccionado (Tabla 25), el promedio de 253 presencias (casos positivos observados) y 253 ausencias (casos negativos observados) reflejó indudablemente el balanceo de la base de datos. Las predicciones del clasificador comprendieron 209 puntos de presencia clasificados correctamente frente a 44 incorrectamente clasificados y a 163 puntos de ausencia correctamente clasificados frente a 90 incorrectamente clasificados. Por el contrario, en los resultados del promedio de las tasas de error por clase, el 29.99 % de las predicciones para las presencias y el 20.99 % de las predicciones para las ausencias fueron incorrectas. En consecuencia, el valor de predicción para los puntos de presencia y para los puntos de ausencia fue de 70.01 % y 79.01 % respectivamente.

Tabla 25

*Matriz de confusión y métricas de rendimiento del GLM binomial
seleccionado para modelar la ocurrencia de incendios*

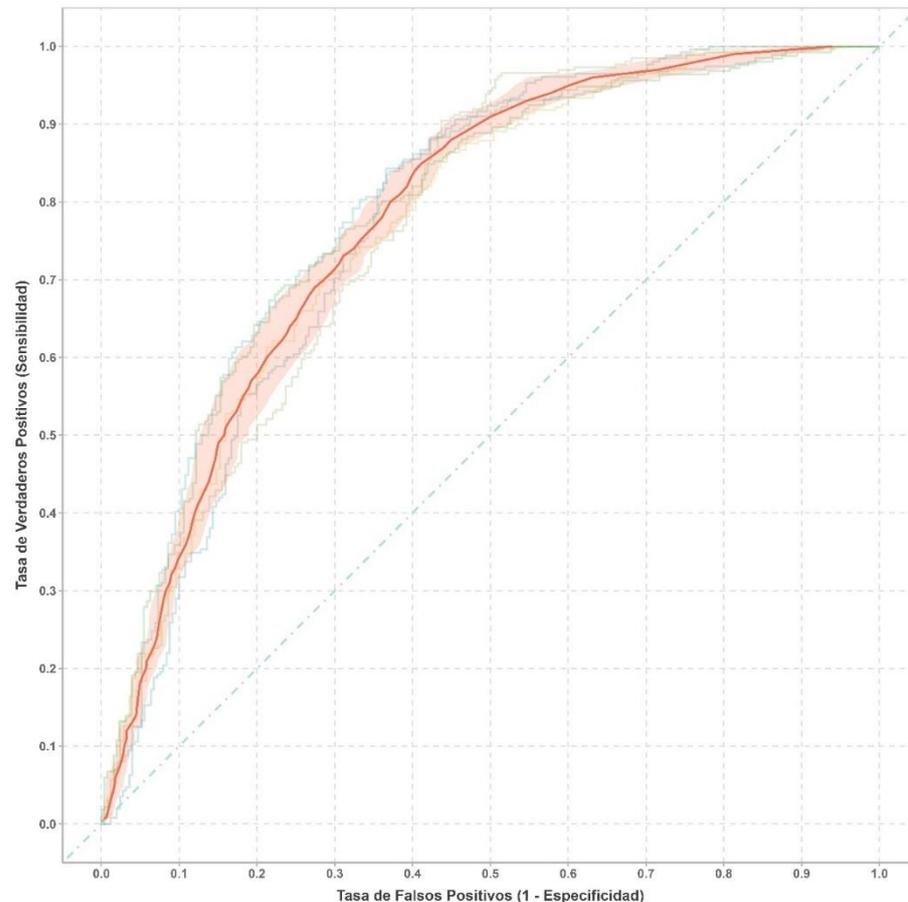
Matriz de confusión		Métricas de rendimiento	
Resultado	Valor	Métrica	Valor
Verdaderos positivos	209	Sensibilidad	0.8261
Verdaderos negativos	163	Precisión	0.7001
Falsos positivos	90	Puntaje F1	0.7575
Falsos negativos	44	Especificidad	0.6453
Tasas de error por clase		Exactitud	0.7364
Tasa de error para la clase de positivos	0.2998672	Valor AUC-ROC	0.7901948
Tasa de error para la clase de negativos	0.2099472	Brecha de Generalización	-0.0027309

Nota: Los valores fueron promediados a partir de cinco iteraciones de Validación Cruzada empleando los datos de validación.

Del total de presencias observadas, 82.61 % fueron correctamente clasificadas y del total de observaciones clasificadas como presencias, 70.01 % fueron correctas. El puntaje F1 del 75.75 % indicó un buen y equilibrado desempeño (alta sensibilidad y precisión). Del total de ausencias observadas, 64.53 % fueron correctamente clasificadas. Concretamente, el modelo clasificó correctamente el 73.64 % del total de las observaciones. El valor promedio de la Brecha de Generalización respecto al AUC fue de -0.003 indicando la ausencia de sobreajuste y que el modelo, además, tuvo un mejor rendimiento con los datos de validación. De modo que, a pesar de la magnitud observada para los coeficientes, el GLM mantuvo un buen rendimiento frente a datos no vistos durante su entrenamiento. Por su parte, el valor AUC del modelo, de 0.79, evidenció un rendimiento mejor al de un clasificador aleatorio (Fig. 10).

Figura 10

Curva ROC del GLM binomial seleccionado para modelar la ocurrencia de incendios



Nota: La curva ROC del modelo se obtuvo promediando horizontalmente (Hogan y Adams, 2023) cinco curvas correspondientes a cinco iteraciones de Validación Cruzada, empleando los datos de validación. El área sombreada representa la Desviación Estándar de la curva promedio y la línea punteada, la línea de referencia de una clasificación aleatoria. El promedio de los valores AUC de las iteraciones: 0.7805035 y el valor AUC estimado de la curva promediada: 0.7201651.

La probabilidad de ocurrencia de incendios resultante estuvo en un rango de $6.35e-07$ a 0.95. En el mapa de probabilidad correspondiente (Fig. 11), esta guardó una moderada correlación con los incendios pasados correspondientes al periodo 2017 – 2023. De los 1265 puntos de presencia considerados en el modelado, 341 (26.96 %) se ubicaron en zonas de *muy*

alta probabilidad de ocurrencia de incendios (0.75 – 0.95), 612 (48.38 %) en zonas de *alta* probabilidad (0.50 – 0.75), 250 (19.76 %) en zonas de *moderada* probabilidad (0.25 – 0.50) y 62 (4.9 %) en zonas de *baja* probabilidad ($6.35e-07$ – 0.25) (Fig. 12). En total, el 75.34 % de los puntos de presencia se ubicaron en zonas de *alta* y *muy alta* probabilidad de ocurrencia de incendios, lo cual indica una alta confiabilidad para el GLM binomial seleccionado. El 8.86 % del área de estudio (1537.72 km²) comprendió zonas de *muy alto* riesgo de incendios, las zonas de *alto* riesgo cubrieron el 27.45 % del área (4763.71 km²), las de riesgo *moderado* el 29.50 % (5119.85 km²) y las de *bajo* riesgo el 34.18 % (5931.80 km²).

El mapa para este modelo mostró una diferenciación geográfica similar a la del mapa del modelo RF en cuanto a la distribución espacial de la probabilidad de riesgo de incendios en las provincias de estudio (Fig. 12). Por ende, las zonas de *muy alta* probabilidad también estuvieron presentes en las tres provincias de estudio. Además, la distribución se asemejó en cierta medida al mapa departamental de susceptibilidad a incendios forestales elaborado por el CENEPRED (CENEPRED, 2022).

La predicción espacial del GLM binomial (Tabla A.2) reveló que los distritos con mayor porcentaje de su superficie representado por zonas de *muy alto* riesgo de incendios fueron: Llalli (20.54 %), Macari (20.42 %) y Cupi (20.27 %) en la provincia de Melgar; Arapa (19.79 %) en la provincia de Azángaro y Cabanilla (19.21 %) en la provincia de Lampa. En cambio, los distritos con mayor extensión de zonas de *muy alto* riesgo fueron: Ayaviri (176.88 km²), Macari (141.17 km²), Santa Rosa (109.21



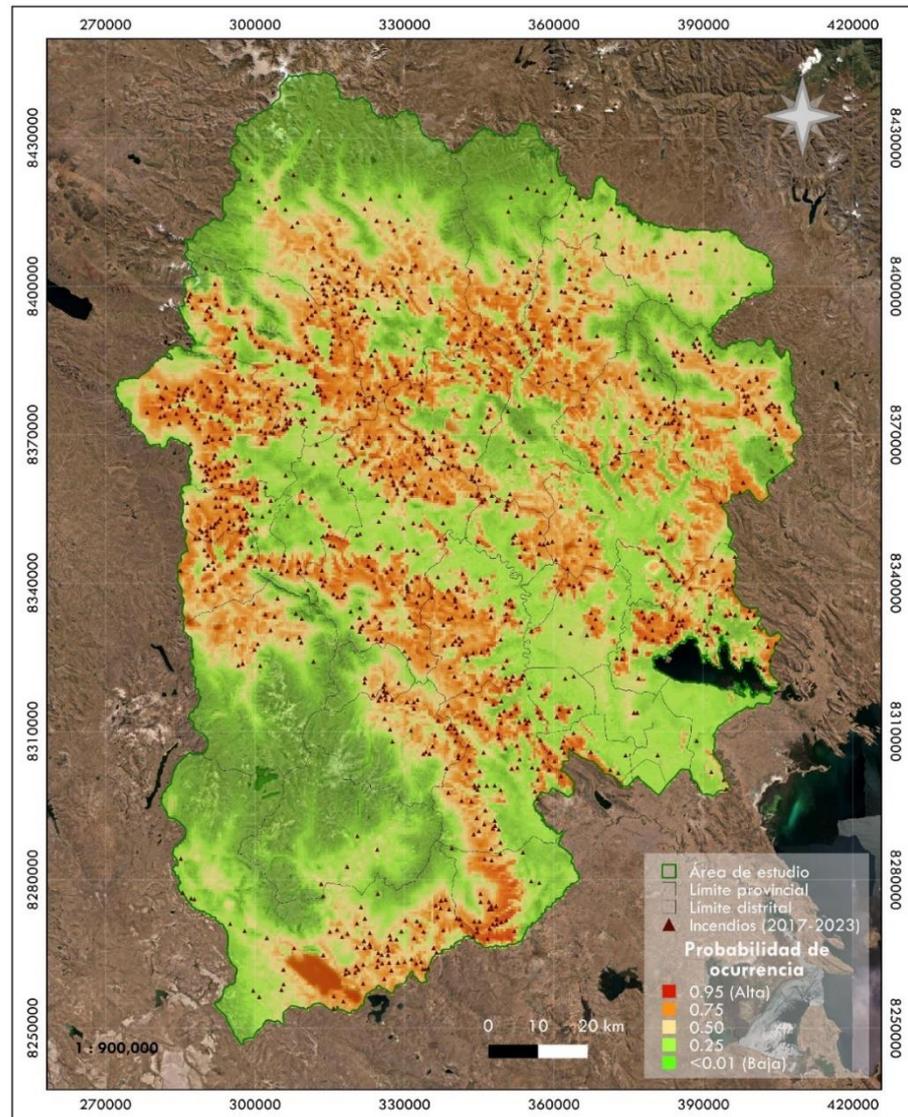
km²) y Nuñoa (100.20 km²) en la provincia de Melgar y Santa Lucía (86.44 km²) en la provincia de Lampa.

Por otro lado, aquellos con mayor porcentaje de su superficie representado por zonas de *alto* riesgo de incendios fueron: Llalli (56.54 %) y Cupi (40.51 %) en la provincia de Melgar; San Antón (45.27 %), San José (41.77 %) y Azángaro (40.29 %) en la provincia de Azángaro y Pucará (40.17 %) en la provincia de Lampa. Asimismo, los distritos con mayor extensión de zonas de *alto* riesgo fueron: Nuñoa (561.71 km²), Ayaviri (401.08 km²) y Santa Rosa (309.78 km²) en la provincia de Melgar; Santa Lucía (315.05 km²) en la provincia de Lampa y Azángaro (290.08 km²) en la provincia homónima.

Las zonas de *muy alta* probabilidad de ocurrencia se caracterizaron por estar en un rango de elevación de 3886 a 4615.36 m s.n.m., también por poseer temperaturas máximas de 14.76 a 17.08 °C, valores del Índice de Vegetación Ajustado al Suelo de -0.01 a 0.20 y valores del Índice de Posición Topográfica (calculado a un radio de 1000 m) entre -1.77 y 4.18. Mientras que, las zonas de *alta* probabilidad de ocurrencia se caracterizaron por ubicarse en un rango más amplio de elevación, de 3809 a 4727.98 m s.n.m.; por poseer temperaturas máximas ligeramente inferiores (14.47 a 17.08 °C); valores para el Índice de Vegetación Ajustado al Suelo ligeramente superiores (-0.01 a 0.24) e inferiores para el Índice de Posición Topográfica (1000 m) (-3.82 a 4.17).

Figura 11

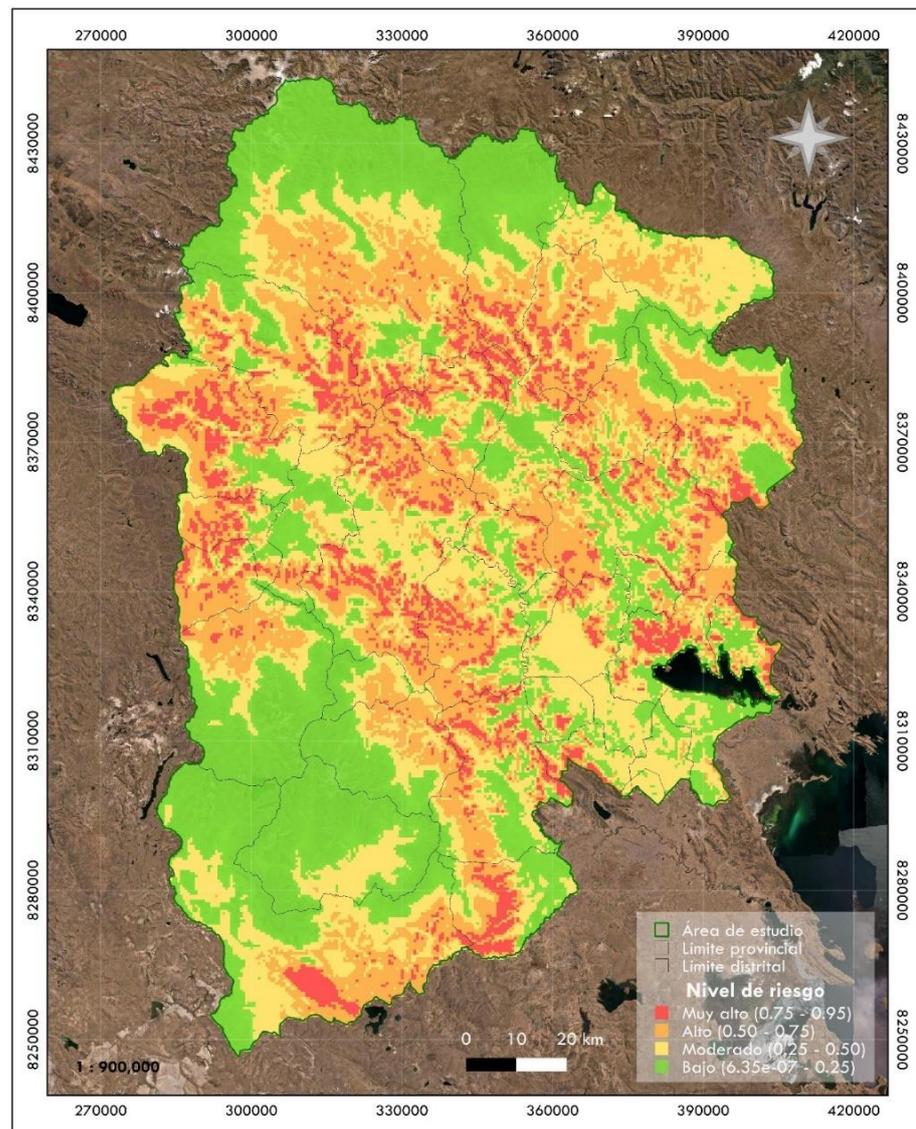
Mapa de probabilidad de ocurrencia de incendios basado en el GLM binomial seleccionado



Nota: En el mapa se muestran superpuestos los puntos de ocurrencia de incendios registrados en el periodo 2017 – 2023 que fueron empleados en la modelación. Fuente satelital: Esri.

Figura 12

*Mapa del nivel de riesgo de incendios basado en el GLM binomial
seleccionado*



Nota: El mapa muestra la clasificación de los valores de probabilidad del GLM en zonas de riesgo de incendios: *muy alto* (0.75 – 0.95), *alto* (0.50 – 0.75), *moderado* (0.25 – 0.50) y *bajo* (6.35e-07 – 0.25). Fuente satelital: Esri.

4.1.3 Comparación entre el modelo de clasificación Random Forest, el GLM binomial y el GLM equivalente al modelo RF para modelar la ocurrencia de incendios en pastizales altoandinos en el departamento de Puno

El modelo de clasificación Random Forest tuvo un rendimiento inferior respecto al GLM construido con el mismo conjunto de variables explicativas en cuanto a: sensibilidad (reducción del 4.51 %), puntaje F1 (reducción del 1.13 %), exactitud (reducción del 0.27 %) y valor AUC (reducción del 0.006). No obstante, tuvo un mejor desempeño en precisión (incremento del 1.62 %) y especificidad (incremento del 3.94 %). A pesar de que el conjunto de variables explicativas no mostró multicolinealidad entre ellas acorde al método RFE, no todas tuvieron un GVIF menor a 5, de modo que evidenciaron una alta correlación en la prueba de multicolinealidad.

Tanto el GLM binomial seleccionado como el GLM equivalente al modelo RF fueron modelos significativos al ser comparados con el modelo nulo mediante pruebas de desviaciones. Así mismo, ambos tuvieron a todas sus variables explicativas como significativas en la prueba χ^2 y la prueba de Wald. Respecto a la bondad de ajuste y a la calidad relativa, el GLM seleccionado contó con un mayor valor AIC y un menor Pseudo R^2 en relación con el GLM equivalente al modelo RF. No obstante, el valor p resultante de la comparación entre ambos modelos anidados (prueba de razón de verosimilitud) no evidenció una diferencia significativa respecto a su capacidad para explicar la desviación observada en la ocurrencia de incendios.

Tabla 26

Resumen del GLM binomial basado en las variables explicativas empleadas en el modelo de clasificación Random Forest (m4)

Parámetro del modelo	Coefficiente estimado	Error Estándar (SE)	Valor del estadístico z	Valor p (> z)
(Intercepto)	-0.19040	0.05239	-3.635	0.000279 ***
TMAX, 1	2.48379	8.52435	0.291	0.770764
TMAX, 2	-23.95508	4.92737	-4.862	1.16e-06 ***
DDF, 1	10.70540	3.98338	2.688	0.007199 **
DDF, 2	-1.27309	2.82766	-0.450	0.652547
HDF, 1	16.87854	7.54495	2.237	0.025282 *
HDF, 2	-2.13272	3.48982	-0.611	0.541116
EVAP, 1	11.98890	6.99786	1.713	0.086671
EVAP, 2	-11.44107	3.67555	-3.113	0.001854 **
DEM, 1	-26.40072	4.60507	-5.733	9.87e-09 ***
DEM, 2	-51.34492	3.67073	-13.988	< 2e-16 ***
TPI1000, 1	14.45752	2.79824	5.167	2.38e-07 ***
TPI1000, 2	0.89037	2.71968	0.327	0.743380
SAVI, 1	-20.52210	3.20374	-6.406	1.50e-10 ***
SAVI, 2	-1.14492	3.65444	-0.313	0.754056
Pseudo R ²				0.208378
Pseudo R ² ajustado				0.203972
AIC				2806.474

Nota: Observaciones: 2530. Los asteriscos indican el nivel de sig. de los coef.: "****" p < 0.001, "****" p < 0.01, "*" p < 0.05. Coeficientes estimados y su significancia para las variables explicativas (en términos lineales y/o cuadráticos).

Los coeficientes estimados del GLM equivalente al modelo RF y su significancia (Tabla 26) describieron relaciones similares para las variables explicativas compartidas con el GLM seleccionado y la probabilidad logarítmica de ocurrencia de incendios (*log-odds*): Una correlación predominantemente negativa entre las probabilidades predichas y la elevación con una asociación curvilínea cóncava (punto de inflexión: 4392.78 m s.n.m.); una correlación positiva entre las probabilidades y el TPI calculado a un radio de 1000 m y una correlación negativa entre las probabilidades y el SAVI. En cuanto a la temperatura máxima, esta mostró una asociación cuadrática-lineal cóncava hacia abajo (punto de inflexión: 11.91 °C), en lugar de la asociación curvilínea cóncava predominantemente positiva observada en el GLM seleccionado. Lo cual indica,



que esta última variable estuvo influenciada por las otras variables del modelo (la evapotranspiración potencial, la Frecuencia Acumulada de Días Secos y/o Calurosos).

Por parsimonia, el GLM binomial seleccionado (*m5*) resultó el más adecuado para modelar la ocurrencia de incendios en pastizales altoandinos del departamento de Puno, en comparación con el modelo RF seleccionado y el GLM binomial equivalente. Este modelo obtuvo menores tasas de error por clase y por ende, mayores valores de predicción para los puntos de presencia y ausencia. Además, tuvo una mejor sensibilidad, puntaje F1, exactitud y valor AUC. Sin embargo, tuvo una menor precisión y especificidad respecto al modelo RF; pero sí una mejor precisión, especificidad y brecha de generalización respecto al GLM equivalente al modelo RF. Todas las variables que lo conformaron tuvieron un GVIF menor a 5. No obstante, en cuanto a las zonas de riesgo de incendios, la mayor cantidad de puntos de presencia se ubicó en zonas de *alta* probabilidad en lugar de zonas de *muy alta* probabilidad de ocurrencia. Además, del total de puntos de presencia, el porcentaje de aquellos que se ubicaron en ambas zonas fue menor al modelo RF.

De este modo y conforme con las jerarquías de importancia, la variable explicativa más importante para modelar la ocurrencia de incendios fue la elevación, seguida de la temperatura máxima. En tercer lugar, se encontró la única variable de vegetación considerada en el modelado: el Índice de Vegetación Ajustado al Suelo. Finalmente, la última variable de importancia correspondió a otra variable topográfica: el Índice de Posición Topográfica calculado a un radio de 1000 m.



La selección de la temperatura máxima como variable relevante para el modelado de la ocurrencia, guarda relación con lo aplicado por el SERFOR y el SENAMHI para la detección de incendios activos mediante focos de calor o anomalías térmicas representados como píxeles que evidencian altas temperaturas (SENAMHI, 2020; SERFOR, 2019) o por medio del producto RGB del satélite GOES-16 (SENAMHI, 2022). Además, con la clara influencia de los cambios del clima regional en la actividad de los incendios. La ocurrencia de incendios al estar determinada por la temperatura acorde a los resultados de la presente investigación, es susceptible a la influencia de ENSO en relación con los extremos de temperatura (Román-Cuesta et al., 2014).

En conformidad con sugerido por Oliveras et al. (2014), la dinámica de incendios (en relación con su ocurrencia) estuvo influenciada por factores relacionados con la combustibilidad. Indirectamente, por la dinámica de la humedad del combustible reflejada en el Índice de Vegetación Ajustado al Suelo. Asimismo, la ausencia de la frecuencia acumulada de días secos en el modelo final converge con sus resultados, quienes tampoco encontraron un nexo claro entre las precipitaciones y la ocurrencia de incendios. Por el contrario, no se evidenció, al menos a nivel local, una influencia significativa de los factores antropogénicos. En comparación con la ocurrencia de incendios observada al noreste del país (Armenteras et al., 2017), la distancia a caminos o redes viales no resultó en un factor de importancia. Ello confirma lo mencionado por Román-Cuesta et al. (2014) sobre la mayor importancia de las variaciones climáticas que la variabilidad espacial de las actividades humanas en los incendios en la región altoandina.



A diferencia de los hallazgos de Román-Cuesta et al. (2014), en el presente estudio, la elevación fue el factor más influyente en la ocurrencia de incendios. Lo cual podría sugerir una baja o nula influencia de esta variable a nivel subcontinental (opacada por variables climáticas), empero una gran influencia a nivel local. Además, se ha observado en la Cordillera Oriental de los Andes en el país que la ocurrencia de incendios es frecuente en pendientes lineales empinadas con elevaciones medias (*backslopes*) (Oliveras et al., 2014), en correspondencia con la relevancia del Índice de Posición Topográfica calculado a un radio de 1000 m en el modelado de la ocurrencia. A razón de que este obtuvo valores que representaron, para las zonas de *muy alto* riesgo, desde ligeras depresiones a cimas de colinas o cerros, con predominancia de laderas o pendientes estables ($TPI \approx 0$) como principales accidentes geográficos.



4.2 IDENTIFICACIÓN DE LOS FACTORES CLIMÁTICOS, TOPOGRÁFICOS, ANTRÓPICOS Y DE COMBUSTIBILIDAD QUE DETERMINAN LA EXTENSIÓN DE INCENDIOS EN PASTIZALES ALTOANDINOS DEL DEPARTAMENTO DE PUNO

Un total de 23 sitios quemados correspondientes a incendios identificados en 2023 fueron evaluados *in situ* (Tabla 27). El 47.83 % se ubicó en la provincia de Melgar, el 39.13 % en la provincia de Azángaro y el 17.39 % en la provincia de Lampa. El distrito de Macari fue el que tuvo el mayor número de incendios. Los incendios registrados ocurrieron entre el 06 de abril y el 17 de noviembre del 2023. El 52.17 % de ellos no fueron reportados por los organismos distritales de respuesta frente a incendios forestales de las provincias del área de estudio. Además, se contó con información sobre el control de al menos cinco de ellos de acuerdo con los reportes distritales diarios.

Los incendios más extensos ocurrieron entre junio y noviembre. El más extenso (576.72 ha) se ubicó en el distrito de Santa Rosa en la provincia de Melgar (0.72 % de su superficie). El segundo con mayor extensión (486.51 ha), en el distrito de Ocuvi en la provincia de Lampa (0.55 % de su superficie), seguido por un incendio en Arapa (408.02 ha), en la provincia de Azángaro (1.21 % de su superficie). La distribución temporal del tamaño de las cicatrices difiere de lo mencionado por Oliveras et al. (2014); ya que, se observó una gran variabilidad a lo largo de temporada de incendios. Los detalles de las imágenes satelitales empleadas para la identificación y clasificación de los incendios; así como, la ubicación geográfica de cada uno se presentan en la Tabla 28.

Tabla 27

Incendios en pastizales altoandinos registrados en 2023 en las tres provincias de estudio y evaluados en el periodo de mayo a diciembre del mismo año

N°	Abrev.	Prov.	Dtto.	Nom.	Fecha		Rep.	Con.	Área (ha)
					De	A			
1	IMP	AZ	Arapa	Impuchi	06/04	20/07	Sí	-	78.077
2	CHAP	AZ	Arapa	Chapani	20/06	15/07	Si	-	408.021
3	PUP	AZ	Santiago de Pupuja/Azángaro	Pupuja 1	23/06	25/06	No	-	98.638
4	ORU2	ME/AZ	Orurillo/Asillo	Orurillo 2	28/06	03/07	No	-	37.647
5	CAL	LA	Lampa	Calvario	10/07	13/07	Si	-	17.445
6	SANT	AZ	San Antón	San Antón 1	15/07	18/07	Sí	-	27.968
7	MAC1	ME	Macari	Macari 1	18/07	23/07	No	-	17.836
8	QUI	ME	Macari	Quishuara	12/08	22/08	No	-	94.775
9	MOL	ME	Cupi	Molloccosi	18/08	-	Sí	Sí	60.987
10	JAP	ME	Orurillo	Japu	21/08	-	Sí	Sí	80.813
11	NIC1	LA	Nicasio	Nicasio 1	29/08	01/09	No	-	21.567
12	NIC2	LA	Nicasio	Nicasio 2	29/08	01/09	No	-	14.885
13	COM	AZ	Arapa	Compi	18/09	23/09	No	-	43.942
14	SR1	ME	Santa Rosa	Santa Rosa 1	24/09	-	Sí	Sí	576.721
15	EAC	AZ	San Antón	Estrella Alto Chilluma	24/09	27/09	Sí	Sí	132.400
16	CHAC	AZ	Santiago de Pupuja	Chacci Quilo	06/10	-	Sí	No	32.090
17	SFR	ME	Macari	San Francisco	06/10	11/10	No	-	105.000
18	MAC3	ME	Macari	Macari 3	07/10	-	No	-	7.797
19	TIC	LA	Ocuviri	Ticarjani	10/10	-	Sí	Sí	486.507
20	TOT	ME	Macari	Totorani	16/10	21/10	No	-	144.169
21	SR2	ME	Santa Rosa	Santa Rosa 2	31/10	05/11	No	-	261.977
22	ANT	ME	Orurillo/Nuñoa	Antaymarca	31/10	05/11	No	-	108.021
23	SOR	AZ	San Antón	Unión Soratira	17/11	-	Sí	-	8.643

Nota: Provincias: AZ (Azángaro), ME (Melgar), LA (Lampa). Nombres: por secuencia distrital; nombres de comunidades campesinas, localidades o cerros.

Tabla 28

Imágenes satelitales descargadas y ubicación geográfica de los incendios en pastizales altoandinos en las tres provincias de estudio registrados y evaluados en 2023

N°	Abrev.	Imagen satelital				Coordenadas		
		Satélite	Sensor	N. P.	TILE	R. E.	E (m)	N (m)
1	IMP	Sentinel 2A	MSI	L2A	T19LCD1	20 m	384513.885	8330067.058
2	CHAP	Sentinel 2B	MSI	L2A	T19LCD1	20 m	379804.280	8330464.282
3	PUP	Sentinel 2B	MSI	L2A	T19LCD1	20 m	370327.371	8342233.554
4	ORU2	Sentinel 2A	MSI	L2A	T19LCD0	20 m	343542.816	8361689.745
5	CAL	Sentinel 2A	MSI	L2A	T19LCD0	20 m	352676.284	8302660.505
6	SANT	Sentinel 2B	MSI	L2A	T19LCD0	20 m	357845.651	8388111.745
7	MAC1	Sentinel 2A	MSI	L2A	T19LBD	20 m	294636.009	8362063.632
8	QUI	Sentinel 2A	MSI	L2A	T19LBD	20 m	292466.262	8383755.949
9	MOL	Sentinel 2A	MSI	L2A	T19LBD	20 m	298248.321	8353516.164
10	JAP	Sentinel 2B	MSI	L2A	T19LCD0	20 m	339351.050	8365789.842
11	NIC1	Sentinel 2A	MSI	L2A	T19LCD0	20 m	361125.547	8314472.709
12	NIC2	Sentinel 2A	MSI	L2A	T19LCD0	20 m	360579.892	8312953.548
13	COM	Sentinel 2B	MSI	L2A	T19LCD1	20 m	389204.390	8330496.594
14	SR1	Sentinel 2B	MSI	L2A	T19LBD	20 m	305373.734	8379164.562
15	EAC	Sentinel 2B	MSI	L2A	T19LCE0	20 m	358001.472	8398772.442
16	CHAC	Sentinel 2B	MSI	L2A	T19LCD0	20 m	361454.414	8331344.963
17	SFR	Sentinel 2A	MSI	L2A	T19LBD	20 m	281123.595	8377665.666
18	MAC3	Sentinel 2A	MSI	L2A	T19LBD	20 m	284497.692	8376962.000
19	TIC	Sentinel 2A	MSI	L2A	T19LBD	20 m	299779.593	8335824.024
20	TOT	Sentinel 2A	MSI	L2A	T19LBD	20 m	297247.986	8360581.085
21	SR2	Sentinel 2B	MSI	L2A	T19LCE0	20 m	310594.159	8393411.050
22	ANT	Sentinel 2B	MSI	L2A	T19LCD0	20 m	343781.600	8387767.096
23	SOR	Sentinel 2A	MSI	L2A	T19LCE0	20 m	362550.926	8393175.185

Nota: N. P.: Nivel de procesamiento. R. E.: Resolución espacial. Sistema de coordenadas UTM. Datum WGS84. Zona 19S.

La base de datos para el modelado de la extensión de incendios comprendió las 23 observaciones (incendios evaluados) con 23 variables explicativas y la variable continua de respuesta relacionada con la extensión de incendios (ha) (Tabla 29).

Tabla 29

Resumen de los datos recopilados para el modelado de la extensión de los incendios en pastizales altoandinos en el departamento de Puno (provincias de Melgar, Azángaro y Lampa) para el periodo 2017 - 2023

N°	Abrev.	Promedio	Desviación Estándar	Valor mínimo	Valor máximo
1	(Y)	124.61 ha	154.63 ha	7.80 ha	576.72 ha
2	TMAX	16.33 °C	0.39 °C	15.56 °C	17.05 °C
3	DDF	72 días	13 días	48 días	92 días
4	HDF	62 días	23 días	7 días	108 días
5	EVAP	59.26 mm/día	2.45 mm/día	51.79 mm/día	62.69 mm/día
6	SLOPE	17.61 °	6.86 °	3.89 °	33.96 °
7	ASPECT	200.24 °	54.29 °	83.50 °	330.87 °
8	DEM	4171.25 m s.n.m.	134.05 m s.n.m.	3907.88 m s.n.m.	4376.98 m s.n.m.
9	TWI	7.64	1.89	5.15	13.77
10	TPI500	0.21	0.55	-1.15	1.62
11	TPI1000	0.23	0.58	-1.05	1.69
12	TPI2000	0.27	0.72	-1.40	2.03
13	SAVI	0.16	0.02	0.13	0.20
14	Cob_pasto	30.17 %	11.21 %	15.21 %	67.83 %
15	Cob_hierba	1.93 %	1.33 %	0.00 %	6.04 %
16	Cob_leño	1.23 %	1.63 %	0.00 %	6.46 %
17	Cob_suelo	31.29 %	9.37 %	13.13 %	50.63 %
18	Cob_roca	9.47 %	7.87 %	0.00 %	26.04 %
19	Cob_hoj	26.17 %	9.74 %	10.21 %	46.88 %
20	Altura	25.57 cm	8.04 cm	11.88 cm	39.39 cm
21	MS	85.78 g	28.16 g	33.14 g	143.71 g
22	CAMINOS	4279.07 m	3154.21 m	114.49 m	12763.92 m
23	CP	1073.10 m	530.28 m	371.96 m	2400.38 m
24	Pastoreo	37.69 %	25.14 %	0.00 %	88.13 %

La selección final de modelos lineales generalizados (gaussianos) para modelar la extensión de los incendios evaluados en el 2023 (Tabla 30) comprendió: al modelo saturado ($m1$), al modelo nulo ($m2$), al mejor modelo del total de 8388606 creados con todas las posibles combinaciones de variables explicativas, que corresponde al modelo con el menor AIC de las combinaciones de seis variables que tuvieron una baja multicolinealidad ($GVIF < 5$) ($m12$) y a los 13 mejores modelos resultantes del análisis de correlación entre las variables explicativas y la variable continua de respuesta (la extensión de incendios) y el análisis de correlación entre variables explicativas.



Entre estos últimos: el modelo construido únicamente con variables que guardaron una alta correlación con la extensión de incendios (Correlación de Pearson, $p < 0.05$) (*m4*) y en base a este, el modelo resultante de la aplicación del método *Backward* (selección por eliminación hacia atrás) (*m5*). Así mismo, el modelo construido con las variables que tuvieron una correlación con la extensión mayor a 0.15 (*m10*), su modelo resultante del método *Backward* (*m14*), su versión de baja multicolinealidad (luego de la remoción de las variables con un VIF mayor a 5) (*m8*) y el modelo resultante del método *Backward* sobre este último (*m9*).

Por otro lado, el modelo con el menor AIC del conjunto de modelos construidos con variables explicativas que guardaron una correlación entre sí menor a 0.6 (*m15*); el modelo con el menor AIC de todos los modelos resultantes del método *Backward* de este conjunto (*m16*); el modelo con el menor AIC entre los que tuvieron baja multicolinealidad ($VIF < 5$) (*m6*) y su modelo resultante del método *Backward* (*m7*); y aquel que tuvo baja multicolinealidad respecto al GVIF (menor a 5) entre los modelos resultantes del método *Backward* aplicado a los modelos con baja multicolinealidad en relación al VIF (*m11*). Por último, el modelo con el menor AIC del conjunto de modelos construidos con variables que guardaron una correlación con la extensión mayor a 0.15 y que tuvieron una correlación entre sí menor a 0.6 (*m11*); así como, su modelo resultante del método *Backward* (*m13*).

Tabla 30

VARIABLES explicativas de la selección de GLMs para modelar la extensión de incendios

Cod.	Nombre	Variables explicativas																						
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
(m1)	Saturado	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
(m2)	Nulo																							
m3	Mod. D1			x					x			x												
m4	Mod. C1					x								x					x					
m5	Mod. C3													x					x					
m6	Mod. D4										x				x					x		x		x
m7	Mod. D5														x					x		x		x
m8	Mod. B2					x		x						x	x	x			x	x				x
m9	Mod. B6					x								x	x	x			x	x				
m10	Mod. B1	x		x	x	x		x						x	x	x	x	x		x	x			x
m11	Mod. E1			x		x		x						x	x	x	x			x	x			x
m12	Mod. 37			x				x						x					x			x		
m13	Mod. E2			x		x								x		x	x					x		
m14	Mod. B3			x		x								x					x	x			x	
m15	Mod. D2	x	x			x	x	x					x	x	x	x	x			x	x	x	x	x
m16	Mod. D3		x	x				x		x				x	x	x	x	x		x	x	x	x	x

Nota: Las variables explicativas son: TMAX (1), DDF (2), HDF (3), EVAP (4), SLOPE (5), ASPECT (6), DEM (7), TWI (8), TPI500 (9), TPI1000 (10), TPI2000 (11), SAVI (12), Cob_pasto (13), Cob_hierba (14), Cob_leño (15), Cob_suelo (16), Cob_roca (17), Cob_hoj (18), Altura (19), MS (20), Caminos (21), CP (22), Pastoreo (23).

Como estuvo previsto, en la evaluación general de la selección, el modelo nulo tuvo el menor valor para la medida de bondad de ajuste (Pseudo R^2 de máxima verosimilitud ajustado) (0); así como, el mayor valor para la medida de calidad relativa (AIC) (301.16) (Tabla 31). Por lo tanto, estos valores fueron considerados como el umbral más bajo para la selección de modelos y el modelo final. En contraparte, los valores del modelo saturado para estas medidas evidenciaron el máximo sobreajuste posible ($PR^2 > 1$ y AIC de -1077.05) y por tanto, fue considerado como el umbral superior para la selección.

Tabla 31

Evaluación general de los GLMs gaussianos seleccionados para modelar la extensión de incendios

Cod.	Nombre	N° variables	gl residuales	Pseudo R ² ajustado	AIC	Baja colinealidad (GVIF < 5)	Valor p (> F)
(m1)	Saturado	23	0	1.53	-1077.05	-	-
(m2)	Nulo	0	22	0.00	301.16	-	-
m3	Mod. D1	3	19	0.21	298.50	Sí	0.06213
m4	Mod. C1	3	19	0.35	293.75	Sí	0.009985 **
m5	Mod. C3	2	20	0.39	291.76	Sí	0.002952 **
m6	Mod. D4	5	17	0.65	281.15	No	0.0002352 ***
m7	Mod. D5	4	18	0.66	279.73	No	7.603e-05 ***
m8	Mod. B2	9	13	0.75	275.37	No	0.0004352 ***
m9	Mod. B6	7	15	0.88	257.22	No	4.062e-07 ***
m10	Mod. B1	13	9	0.94	241.35	No	1.105e-05 ***
m11	Mod. E1	10	12	0.95	238.86	No	9.037e-08 ***
m12	Mod. 37	6	16	0.96	233.69	Si	4.201e-11 ***
m13	Mod. E2	6	16	0.96	232.43	No	2.725e-11 ***
m14	Mod. B3	6	16	0.96	232.36	No	2.661e-11 ***
m15	Mod. D2	17	5	1.00	163.67	No	6.225e-07 ***
m16	Mod. D3	15	7	1.00	162.18	No	1.13e-09 ***

Nota: Los asteriscos indican los niveles de significancia de los modelos: "****" $p < 0.001$, "***" $p < 0.01$. Significancia de los GLMs por análisis de desviaciones (prueba F incremental); gl: grados de libertad.

Los modelos $m3$, $m4$, $m5$ y $m12$ presentaron una baja multicolinealidad. Estos modelos estuvieron compuestos por variables explicativas que guardaron una baja correlación entre sí, con valores para el Factor de Inflación de la Varianza Generalizada o GVIF menor a 5. Los 10 modelos restantes presentaron una alta multicolinealidad ($GVIF \geq 5$).

Entre los modelos que tuvieron baja multicolinealidad, fue el modelo *m12* el que presentó un menor valor de AIC, seguido del modelo *m5*, el modelo *m4* y el modelo *m3*. Sus valores para el Pseudo R^2 siguieron la misma secuencia. Consecutivamente, el modelo *m16* tuvo el menor valor de AIC entre los modelos de alta multicolinealidad, seguido de los modelos *m15*, *m14*, *m13*, *m11*, *m10*, *m9*, *m8*, *m7* y *m6*. De igual manera, se observó la misma secuencia para la medida de bondad de ajuste de cada modelo. En líneas generales, todos los modelos (excluyendo al modelo saturado y al modelo nulo), explicaron del 21 al 100 % (posible sobreajuste) de la variación de la variable respuesta.

Al comparar cada modelo con el modelo nulo, mediante un análisis de desviaciones, se evidenció que la mayoría de GLMs considerados en la selección fueron significativos. Es decir, todos los modelos de la selección (a excepción del modelo *m3*, el modelo nulo y modelo saturado) redujeron, proporcional y significativamente la desviación de la extensión de incendios. Entretanto, los modelos *m3*, *m4*, *m5*, *m6*, *m7*, *m9*, *m12*, *m13* y *m14* fueron los modelos más parsimoniosos de la selección. Estos estuvieron conformados por 2 a 7 variables explicativas. Los coeficientes estimados para cada uno de ellos se presentan en la Tabla 32.

Tabla 32

Coefficientes estimados de los GLMs más parsimoniosos para modelar la extensión de incendios

Cod.	Modelo
m3	$\ln(Y) = 4.32 - 0.03X_3 + 0.26X_8 + 0.52X_{11}$
m4	$\ln(Y) = 4.59 + 3.57 \cdot 10^{-3} X_5 + 0.03X_{13} - 0.1X_{17}$
m5	$\ln(Y) = 4.62 + 0.03X_{13} - 0.1X_{17}$
m6	$\ln(Y) = -227 - 8.95X_{10} + 27.31X_{14} + 2.3X_{19} + 2.39 \cdot 10^{-3} X_{21} + 1.71X_{23}$
m7	$\ln(Y) = -335.4 + 40.69X_{14} + 3.6X_{19} + 1.9 \cdot 10^{-3} X_{21} + 2.47X_{23}$
m9	$\ln(Y) = -8.54 + 0.13X_5 + 0.2X_{13} + 0.84X_{14} - 12.36X_{15} - 0.47X_{17} + 0.37X_{19} - 0.02X_{20}$
m12	$\ln(Y) = 6.04 - 0.03X_3 - 0.01X_6 + 0.79X_{10} + 0.05X_{13} - 0.14X_{17} + 0.01X_{20}$
m13	$\ln(Y) = 1.91 - 0.02X_3 - 0.12X_5 + 0.07X_{13} - 0.53X_{15} + 0.05X_{16} + 0.02X_{20}$
m14	$\ln(Y) = 3.04 - 0.02X_3 - 0.08X_5 + 0.06X_{13} + 0.04X_{16} - 0.08X_{17} + 0.02X_{20}$

Los modelos anidados *m6*, *m10*, *m12*, *m15* y *m16* utilizaron las mismas variables que el resto de modelos de la selección; no obstante, incorporaron adicionalmente diferentes variables por lo que no estuvieron anidados entre sí. El resto de modelos estuvieron anidados entre sí hasta cierto punto. Teniendo ello en cuenta, todos los modelos fueron evaluados comparativamente mediante pruebas de razón de verosimilitud. Los valores *p* de las comparaciones por pares (Pruebas *F* incremental) para los GLMs anidados de la selección (Tabla 33) evidenciaron que los pares de modelos *m4* y *m5*, *m6* y *m7*, *m10* y *m11*, *m10* y *m13*, *m10* y *m14*, *m11* y *m13*, tuvieron una capacidad muy similar para explicar la variación (desviación) observada en la extensión de los incendios, sin diferencias significativas entre ellos (aceptándose las hipótesis nulas de las pruebas). Por el contrario, los valores *p* de los pares remanentes reflejaron diferencias significativas en la capacidad de los modelos para explicar la desviación en la extensión (se aceptaron las hipótesis alternativas de las pruebas).

Tabla 33

Prueba F incremental

Cod.	m3	m4	m5	m6	m7	m8	m9	m10	m11	m12	m13	m14	m15	m16
m3	-													
m4	-	-												
m5	-	0.92*	-											
m6	<0.001	<0.01	<0.01	-										
m7	<0.001	<0.001	<0.01	0.52*	-									
m8	<0.01	<0.01*	<0.01*	0.08	0.11	-								
m9	<0.001	<0.001*	<0.001*	<0.001	<0.001	-	-							
m10	<0.001	<0.001*	<0.001*	<0.001	<0.001	<0.01*	0.04*	-						
m11	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001*	<0.01	0.7*	-					
m12	<0.001	<0.001	<0.001*	<0.001	<0.001	-	-	0.88	0.81	-				
m13	<0.001	<0.001	<0.001	<0.001	<0.001	-	-	0.93*	0.93*	-	-			
m14	<0.001	<0.001*	<0.001*	<0.001	<0.001	-	-	0.93*	0.93	-	-	-		
m15	<0.001	<0.001	<0.001	<0.001	<0.001*	<0.001	<0.001	<0.001	<0.001	<0.01	<0.01	<0.01	-	
m16	<0.001*	<0.001	<0.001*	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	0.76	-

Nota: El asterisco (“*”) indica modelos anidados. Valores *p* de las comparaciones por pares entre los GLMs gaussianos seleccionados para modelar la extensión de incendios (pruebas de razón de verosimilitud, Likelihood Ratio Tests o LRT).

4.2.1 Selección del mejor GLM gaussiano para modelar la extensión de incendios en pastizales altoandinos en el departamento de Puno

En base a los resultados de las comparaciones por pares que respaldaron la hipótesis nula ($p \geq 0.05$) (Tabla 33), los mejores GLMs gaussianos para modelar la extensión de incendios fueron elegidos por parsimonia. A razón de que los modelos más complejos no proporcionaron un mejor ajuste frente a los modelos más simples (complejidad injustificada en relación a la bondad de ajuste). Dentro de este grupo de modelos, fueron los GLMs: $m5$, $m7$, $m13$ y $m14$ los modelos más parsimoniosos, conformados por 2; 4 y 6 variables explicativas. En cuanto a los resultados que respaldaron la hipótesis alternativa ($p < 0.05$), los mejores GLMs fueron elegidos por su complejidad (justificada en relación a la bondad de ajuste). De esta manera, los modelos $m10$, $m11$, $m12$, $m14$, $m15$ y $m16$ explicaron una variación significativamente mayor para la extensión de los incendios que los modelos $m3$, $m4$, $m5$, $m7$, $m8$ y $m9$. En vista de lo anterior, los modelos $m12$, $m13$, $m14$, $m15$ y $m16$ fueron los mejores modelos resultantes.

Mediante un análisis de compensación para los modelos resultantes, se seleccionó al modelo $m12$ como el mejor GLM gaussiano para modelar la extensión de incendios. Este modelo mostró una baja multicolinealidad (GVIF < 5 para todas sus variables) y el menor valor AIC de entre todos los modelos con baja multicolinealidad construidos con todas las combinaciones de variables posibles. Adicionalmente, todos los modelos resultantes fueron significativos cuando fueron comparados con el modelo nulo. De estos, los modelos $m12$, $m13$ y $m14$ fueron los más parsimoniosos comprendiendo 6 variables cada uno. En cambio, los modelos $m15$ y $m16$ estuvieron conformados por 17 y 15 variables explicativas respectivamente, sugiriendo un evidente sobreajuste que además se

vio reflejado en sus valores para el Pseudo R^2 (valores de 1 o perfectos). Los tres primeros explicaron el 96 % de la desviación en la extensión de incendios. Además, tuvieron valores de AIC y PR^2 mejores a los valores del modelo nulo, sin sobrepasar a los valores del modelo saturado. El GLM seleccionado estuvo conformado por la Frecuencia Acumulada de Días Calurosos, la exposición topográfica, el Índice de Posición Topográfica calculado a un radio de 1000 m, la cobertura de pastos, la cobertura de roca y la materia seca como variables explicativas (Tabla 34).

Tabla 34

Datos utilizados en el mejor GLM para modelar la extensión

Incendio	Extensión (ha)	HDF (días)	Exposición (grados)	TPI	Cob. de pastos (%)	Cob. de roca (%)	Materia Seca (g)
ANT	108.02	80.32	231.99	0.40	26.88	5.83	111.38
CAL	17.45	82.01	245.11	0.82	28.33	17.29	105.69
CHAC	32.09	88.41	229.12	0.00	39.38	0.00	49.68
CHAP	408.02	84.26	178.08	-0.12	67.83	2.51	93.40
COM	43.94	63.67	105.92	0.56	16.88	14.58	64.76
EAC	132.40	32.52	244.41	0.27	22.92	2.92	91.26
IMP	78.08	76.68	125.42	0.79	18.13	26.04	64.99
JAP	80.81	94.60	226.22	-0.30	30.00	2.08	126.01
MAC1	17.84	47.79	271.30	1.69	34.79	20.42	82.70
MAC3	7.80	45.80	204.28	-1.05	22.29	8.75	66.72
MOL	60.99	50.16	83.50	-0.06	32.92	12.71	82.58
NIC1	21.57	64.10	258.32	1.22	18.96	7.50	84.21
NIC2	14.89	67.16	213.24	0.31	15.21	21.88	109.24
ORU2	37.65	107.85	147.62	0.13	26.25	1.46	85.84
PUP	98.64	91.60	164.13	0.47	41.25	6.67	64.91
QUI	94.78	63.90	173.81	-0.70	36.88	6.46	124.97
SANT	27.97	55.75	172.24	-0.31	29.09	10.78	75.46
SFR	105.00	44.79	189.16	0.16	28.33	11.67	119.73
SOR	8.64	36.20	330.87	-0.23	18.13	25.42	33.14
SR1	576.72	50.99	189.11	0.15	35.83	0.63	143.71
SR2	261.98	39.17	192.22	0.18	33.33	1.25	45.10
TIC	486.51	6.52	234.07	0.15	43.33	3.96	50.63
TOT	144.17	56.23	195.36	0.69	26.88	7.08	96.84

Los diagramas de dispersión de las observaciones correspondientes a la extensión de los incendios evaluados en 2023 (variable continua de respuesta: extensión en ha) con curvas suavizadas en relación a cada variable explicativa del

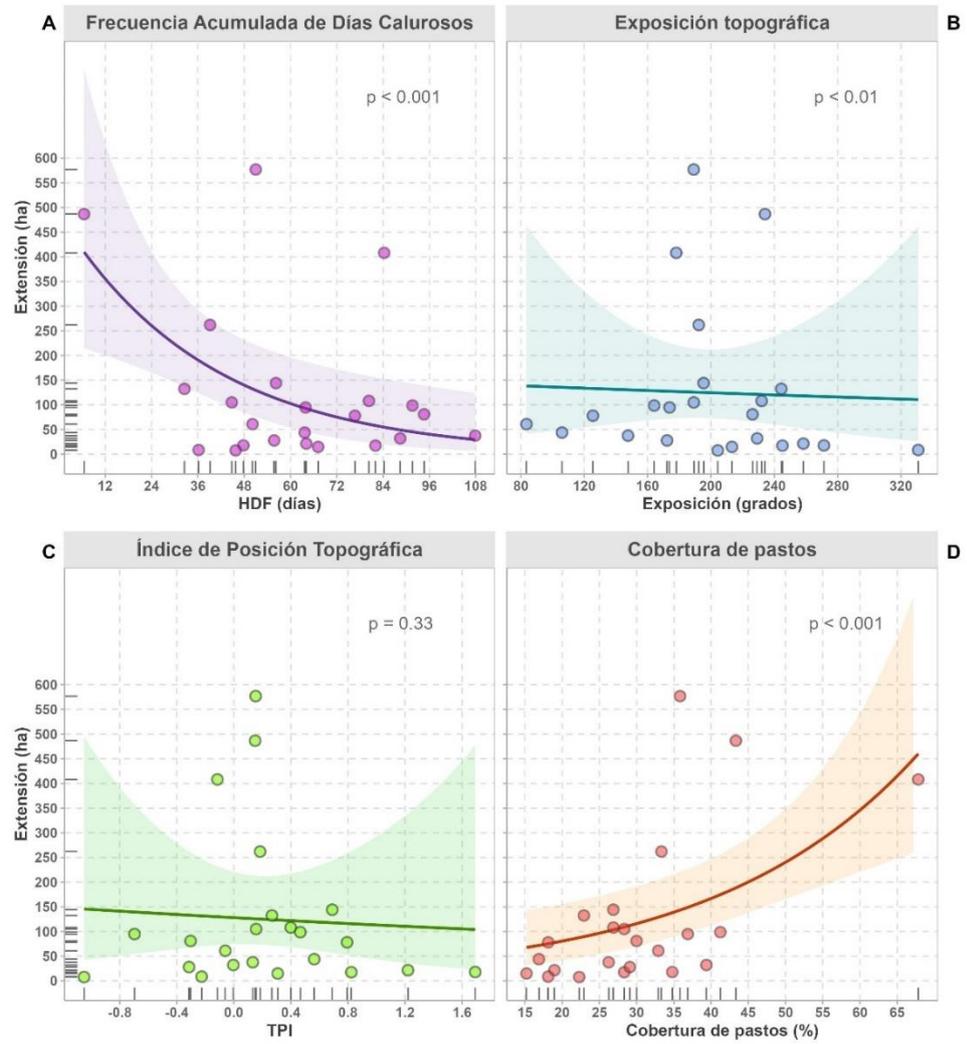


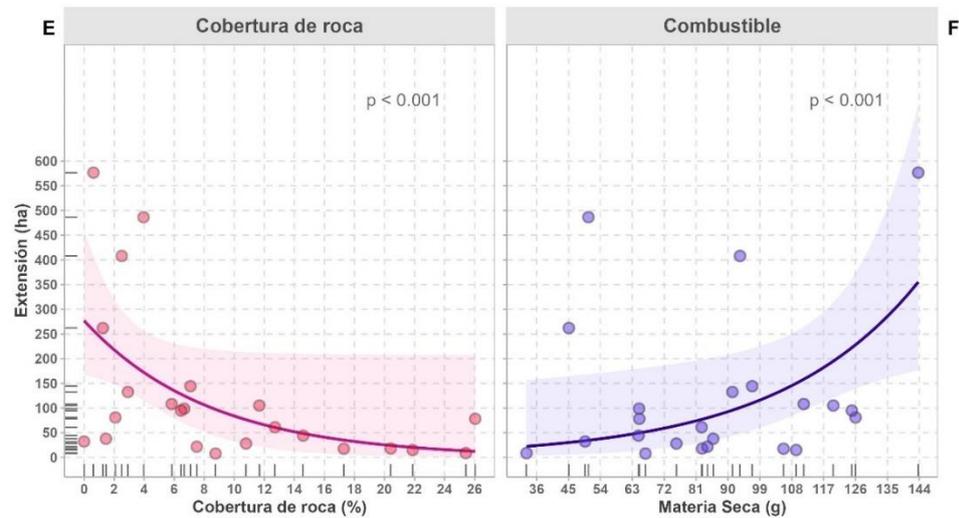
modelo seleccionado (Fig. 13) evidencian cómo cambió la extensión de los incendios a medida que los valores de cada variable se incrementaron.

La Frecuencia Acumulada de Días Calurosos (en el rango de 7 a 108 días), la cobertura de pastos (15.21 – 67.83 %), la cobertura de roca (0.00 – 26.04 %) y la materia seca (33.14 – 143.71 g) mostraron asociaciones curvilíneas (cuadráticas-lineales convexas) con las extensiones observadas en el año 2023. Por otro lado, la exposición topográfica (83.50° – 330.87°) y el TPI calculado a un radio de 1000 m (-1.05 – 1.69) mostraron asociaciones lineales y negativas con la extensión. Los incendios de mayor extensión se caracterizaron por contar con una menor Frecuencia de Días Calurosos, una menor cobertura de roca, una mayor cobertura de pastos y una mayor carga de combustible en comparación con los incendios de menor extensión. Además, fueron más frecuentes en sitios con ligeras depresiones, orientados ligeramente hacia el este.

Figura 13

La influencia de las variables explicativas del GLM gaussiano seleccionado para modelar la extensión de incendios del 2023





Nota: A – F) Las líneas representan la variación en la extensión observada a medida que cambian independientemente las variables explicativas; las regiones sombreadas, intervalos de confianza de 95 %; los círculos sombreados, los valores observados; y los valores p , del estadístico F , la significancia de las variables por comparaciones sucesivas. TPI a un radio de 1000 m.

Conforme al resumen del GLM gaussiano seleccionado (Tabla 35), este modelo explicó el 95.66 % de la variación en la extensión de los incendios (PR^2 ajustado de 0.96) y contó con un AIC menor al del modelo nulo (233.69, una reducción de 67.47). Lo cual indica que el modelo fue parsimonioso y al mismo tiempo lo suficientemente informativo. En cuanto al orden de importancia de sus variables explicativas, los valores absolutos del estadístico t posicionaron a la Frecuencia Acumulada de Días de Calurosos en primer lugar, seguida de la cobertura de pastos, la cobertura de roca, la materia seca, la exposición topográfica y el TPI calculado a un radio de 1000 m. Sus coeficientes fueron significativamente diferentes de cero; es decir, todas las variables fueron relevantes acorde a la prueba de Wald ($p < 0.05$).

Tabla 35

Resumen del GLM gaussiano para modelar la extensión de los incendios en pastizales altoandinos en el departamento de Puno

Parámetro del modelo	Coefficiente estimado	Error Estándar (SE)	Valor del estadístico t	Valor p ($> t $)
(Intercepto)	6.042132	0.577140	10.469	1.45e-08 ***
HDF	-0.027033	0.002501	-10.811	9.19e-09 ***
ASPECT	-0.007385	0.002288	-3.227	0.00527 **
TPI1000	0.794918	0.263987	3.011	0.00828 **
Cob_pasto	0.045430	0.004502	10.092	2.42e-08 ***
Cob_roca	-0.138613	0.018337	-7.559	1.15e-06 ***
MS	0.009941	0.001417	7.017	2.91e-06 ***
Pseudo R ²				0.968425
Pseudo R ² ajustado				0.956584
AIC				233.6861

Nota: Observaciones: 23. Los asteriscos indican los niveles de significancia de los coeficientes: "****" $p < 0.001$, "***" $p < 0.01$. Coeficientes estimados y su significancia (prueba de Wald, distribución t de Student) para las variables explicativas del modelo seleccionado. Estos indican el incremento o disminución logarítmica en la extensión de un incendio por cambios unitarios de las variables explicativas.

De acuerdo con los coeficientes de regresión estimados y su significancia para cada una de las variables explicativas, la extensión esperada de un incendio se incrementó a medida que la HDF, la exposición topográfica y la cobertura de roca disminuyeron. Por el contrario, la extensión esperada se incrementó juntamente con la cobertura de pastos, la materia seca y el TPI calculado a un radio de 1000 m.

Los coeficientes manifestaron una relación predominantemente lineal con la extensión esperada de incendios (Fig. 14). Se observó una disminución del 2.67; 0.74 y 12.94 % en la extensión esperada por cada día de incremento en la Frecuencia Acumulada de Días Calurosos, cada grado en la exposición topográfica y cada unidad porcentual en la cobertura de roca, respectivamente. Además, un incremento del 4.65; 1.00 y 121.43 % por cada unidad porcentual de

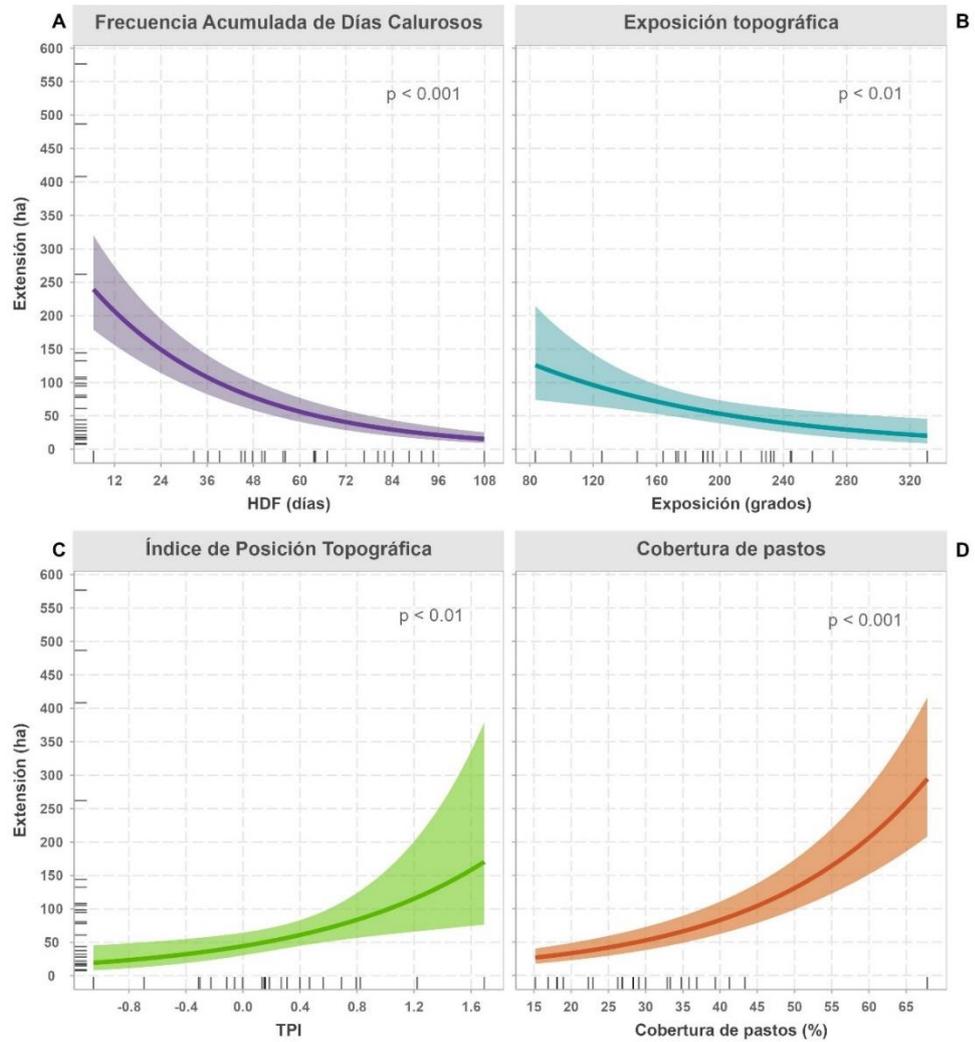


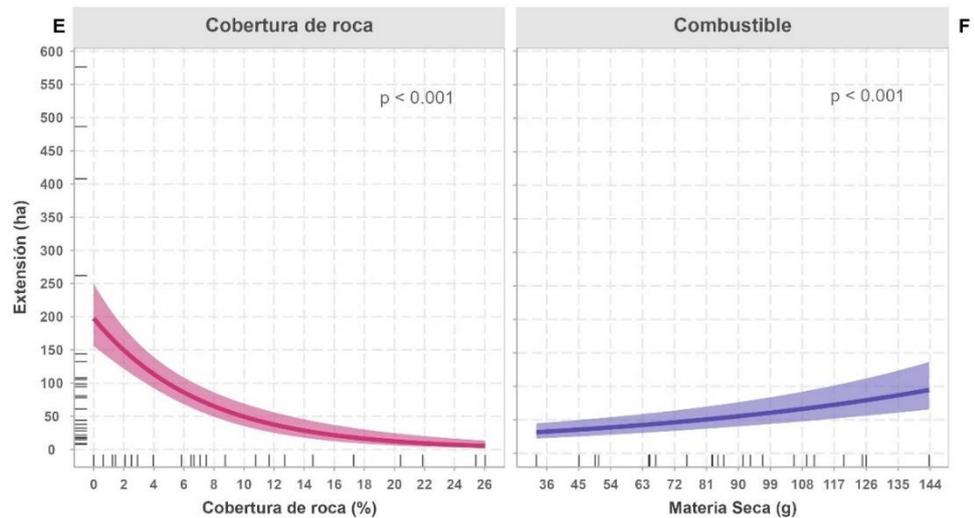
incremento en la cobertura de pastos, cada gramo de materia seca y cada unidad del TPI calculado a un radio de 1000 m, respectivamente. De esta manera, los coeficientes reflejaron los cambios en la extensión esperada a medida que se incrementaron los valores observados para cada variable explicativa, asumiendo (iterativamente) que los valores de las demás variables se mantuvieron constantes.

Las líneas en los gráficos de efectos (Fig. 14) representan el ajuste del GLM para modelar la extensión de incendios empleando a cada una de las variables explicativas que lo conforman sobre las 23 observaciones. En otras palabras, cómo cambia la extensión esperada a medida que varía cada variable explicativa, manteniendo a las demás variables constantes en sus valores promedio. Entretanto, las bandas de confianza se amplían o estrechan conforme aumentan o disminuyen las extensiones esperadas que corresponden a un determinado rango de valores para las variables. Estas indicaron que se contó con menos observaciones de cicatrices de gran extensión (> 60 ha aprox.) con Frecuencias Acumuladas de Días Calurosos menores a los ~ 57 días, con exposiciones menores a los $\sim 184^\circ$, con valores del TPI calculado a un radio de 1000 m mayores a ~ 0.4 , con coberturas de pastos mayores a $\sim 33\%$, con coberturas de roca menores a $\sim 8.7\%$ y con cargas de combustible mayores a ~ 99 g. Por lo tanto, hubo una menor confiabilidad en las predicciones para estos casos. Los cambios en las extensiones esperadas estuvieron reflejados en los coeficientes estimados del modelo (Tabla 35).

Figura 14

Los efectos de las variables explicativas del GLM gaussiano seleccionado para modelar la extensión de incendios del 2023





Nota: A - F) Las líneas representan la variación en la extensión esperada a medida que cambian las variables explicativas del modelo; las regiones sombreadas, intervalos de confianza de 95 %; y los valores p , del estadístico t , la significancia de las variables. TPI a un radio de 1000 m.

Teniendo en cuenta el primer criterio para la selección, el GLM gaussiano seleccionado se caracterizó, en primer lugar, por contar con una baja multicolinealidad. En consecuencia, la prueba de multicolinealidad del modelo (Tabla 36) mostró que el GVIF osciló entre 1.49 y 3.88, mientras que la tolerancia, entre 0.26 y 0.67. Todos los valores del GVIF fueron menores a 5 y sus respectivos valores de tolerancia, mayores a 0.2, indicando una muy baja y manejable multicolinealidad entre variables explicativas.

Tabla 36

Prueba de multicolinealidad del GLM gaussiano seleccionado para modelar la extensión de incendios

Variables explicativas	GVI	Tolerancia (1/GVI)	IC del GVI	IC de la tolerancia	Aumento de SE
HDF	3.881	0.26	2.60 – 6.19	0.16 – 0.38	1.97
ASPECT	3.068	0.33	2.11 – 4.86	0.21 – 0.47	1.75
TPI1000	2.025	0.49	1.49 – 3.16	0.32 – 0.67	1.42
Cob_pasto	2.807	0.36	1.95 – 4.43	0.23 – 0.51	1.68
Cob_roca	1.490	0.67	1.18 – 2.35	0.43 – 0.85	1.22
MS	2.638	0.38	1.85 – 4.15	0.24 – 0.54	1.62

Nota: Estadísticas: Factor de Inflación de la Varianza Generalizada (GVI), tolerancia, factor de aumento del error estándar por posibles correlaciones entre variables explicativas e intervalos de confianza (IC) del 95%.

El modelo seleccionado explicó la extensión de incendios significativamente mejor que simplemente el valor promedio de los datos extensión (modelo nulo) como se observó en los resultados de la prueba de razón de verosimilitud para el modelo (Tabla 37), con un valor p menor a 0.001 (una diferencia de 532605 en las desviaciones residuales). El análisis de desviaciones respaldó la importancia del modelo para predecir la extensión.

Tabla 37

Prueba de razón de verosimilitud (LRT) del GLM gaussiano seleccionado para modelar la extensión de incendios

Mod.	gl residuales	Desviación residual	gl resultantes	Desviación resultante	Valor del estadístico F	Valor p ($>F$)
<i>m2</i>	22	549970				
<i>m12</i>	16	17365	6	532605	81.785	4.201e-11 ***

Nota: gl: grados de libertad. Los asteriscos indican el nivel de significancia del modelo: "****" $p < 0.001$. Significancia por comparación de la validez predictiva del GLM gaussiano con el modelo nulo (análisis de desviaciones, prueba F incremental).

El orden de importancia de las variables explicativas del modelo seleccionado, basado en la contribución secuencial de cada una a la disminución

de la desviación residual de la extensión de incendios como resultado de la Prueba F incremental (Tabla 38), se identificó a la cobertura de pastos como la variable más importante, seguida de la cobertura de roca, la Frecuencia Acumulada de Días Calurosos, la materia seca, la exposición topográfica y el TPI calculado a un radio de 1000 m. Todas ellas, exceptuando al TPI, fueron relevantes (significativas) según el análisis. Por el contrario, los resultados del Análisis de Dominancia General (Tabla 39) para el GLM seleccionado no concordaron con este orden, más sí con el orden de importancia de la prueba de Wald (Tabla 35).

Tabla 38

Prueba F incremental

Variables explicativas	gl residuales	Desviación residual	gl resultantes	Desviación resultante	Valor del estadístico F	Valor p ($>F$)
(modelo nulo)	22	549970				
HDF	21	448537	1	101432	93.454	4.390e-08 ***
ASPECT	20	431556	1	16982	15.646	0.001133 **
TPI1000	19	430459	1	1097	1.011	0.329750
Cob_pasto	18	240244	1	190215	175.253	4.898e-10 ***
Cob_roca	17	88860	1	151384	139.476	2.592e-09 ***
MS	16	17365	1	71495	65.871	4.598e-07 ***

Nota: gl: grados de libertad. Los asteriscos indican el nivel de sig. de la var. en el modelo: "****" $p < 0.001$, "***" $p < 0.01$. Significancia de las variables explicativas del GLM gaussiano seleccionado para modelar la extensión de incendios por comparaciones sucesivas entre versiones más simples y versiones más complejas del modelo, adicionando una variable a la vez (análisis de desviaciones).

Acorde a las contribuciones relativas de cada variable explicativa a la medida de bondad de ajuste del modelo (Pseudo R^2 ajustado de Cox y Snell, equivalente al Pseudo R^2 de máxima verosimilitud ajustado), fue la Frecuencia Acumulada de Días Calurosos la que contribuyó más a la reducción de la variación en la extensión de incendios, en un 31.33 % (adición promedio al Pseudo R^2 : 0.303) (Tabla 39, Fig. 15), constituyéndose como la variable más importante del GLM seleccionado para modelar la extensión de incendios.

Tabla 39

*Orden de importancia de las variables explicativas del GLM gaussiano
seleccionado para modelar la extensión de incendios según el Análisis de
Dominancia General*

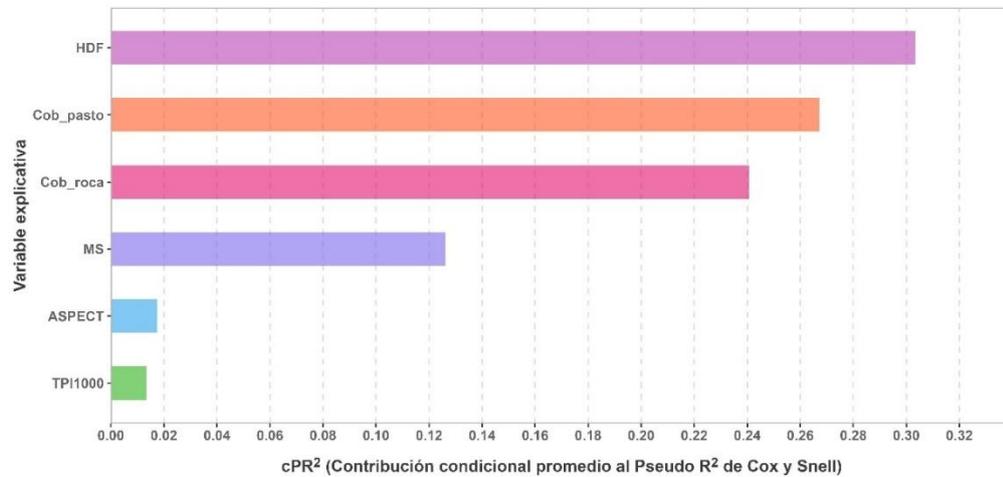
Variable explicativa	Orden de importancia	Contribución promedio al PR²	Valores escalados	Contribución relativa
HDF	1	0.3034237	100.0000	0.3133166
Cob_pasto	2	0.2671962	87.5073	0.2759080
Cob_roca	3	0.2405977	78.3350	0.2484422
MS	4	0.1262799	38.9135	0.1303972
ASPECT	5	0.0174923	1.3990	0.0180626
TPI1000	6	0.0134353	0.0000	0.0138734

Nota: Los valores corresponden a la contribución condicional promedio de cada variable al Pseudo R² en todos los posibles modelos de subconjuntos de variables. Se muestran los valores escalados de 0 a 100 y la contribución relativa de cada variable.

En segundo lugar, la cobertura de pastos que contribuyó con el 27.59 % (adición promedio: 0.267). En tercer lugar, la cobertura de roca que contribuyó con el 24.84 % (adición promedio: 0.241). En cuarto lugar, la carga de combustible que contribuyó con el 13.04 % (adición promedio: 0.126). En quinto lugar, la exposición topográfica que contribuyó con el 1.81 % (adición promedio: 0.017). Finalmente, la última variable de importancia del modelo fue el TPI calculado a un radio de 1000 m, que contribuyó únicamente con el 1.39 % (adición promedio: 0.013) (Tabla 39, Fig. 15).

Figura 15

*Gráfico de importancia de las variables consideradas en el GLM gaussiano
seleccionado para modelar la extensión de incendios*



Nota: La importancia de cada variable mediante el Análisis de Dominancia General.

Las variables explicativas que conformaron el modelo final y su orden de importancia no concordaron con los resultados de la prueba de correlación de Pearson aplicada para las variables explicativas en relación con la extensión de incendio (la exposición topográfica y el TPI calculado en un radio de 1000 m no guardaron una correlación significativa ni mayor a 0.15 con la variable binaria de respuesta). Sin embargo, el GLM seleccionado se ajustó de los resultados de la correlación aplicada entre las variables explicativas (mas no en el orden de las variables). Ninguna de las consideradas guardó una correlación entre sí mayor a 0.6. Asimismo, las variables se alinearon al análisis de multicolinealidad basado en el VIF (< 5). Por ende, estas pruebas resultaron parcialmente apropiadas para la selección de variables en el modelado de la extensión, a razón de que no reflejaron, en su totalidad, los resultados favorables de las demás pruebas aplicadas.



En definitiva y en correspondencia con las jerarquías de importancia consideradas (la prueba de Wald y el Análisis de Dominancia General), la variable explicativa más importante para modelar la extensión de incendios resultó una variable bioclimática, la Frecuencia Acumulada de Días Calurosos, seguida de la cobertura de pastos y la cobertura de roca (variables vegetacionales). En tercer orden de importancia, la variable de combustibilidad; es decir, la carga de combustible por estimación de la materia seca. Finalmente, las últimas variables de importancia correspondieron a dos variables topográficas, la exposición y el Índice de Posición Topográfica calculado a un radio de 1000 m.

El modelo final de extensión no incluye a la pendiente, ni a la frecuencia de días secos; sí consideradas (pendiente y climas predominantemente semisecos por casi medio año) en el Escenario de Riesgo de Incendios elaborado por el Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres (CENEPRED, 2022). Por el contrario, si incluyó a la cobertura de pastos y a la materia seca en equivalencia con la cobertura de vegetación (pastos y hierbas con mayor peso en su estudio); así como, al aspecto, en relación con los niveles de irradiación solar en el Escenario de Riesgos. Las asociaciones positivas de la cobertura de pastos y la carga de combustible con la extensión de incendios concuerdan con lo considerado en la elaboración del Escenario. Respecto a la exposición topográfica, los resultados concuerdan parcialmente debido a que consideraron los sitios más soleados para los incendios más extensos; por el contrario, fueron los sitios semisoleados en los resultados del presente estudio.

Acorde a lo sugerido por Oliveras et al. (2014), la dinámica de los incendios (con relación a su extensión) estuvo influenciada por factores de combustibilidad. En particular, por la carga de combustible, reflejada en la



estimación de la materia seca e indirectamente en la cobertura de pastos. Por el contrario, no se evidenció a nivel local, como sugirieron estos autores, una influencia significativa de factores antropogénicos.

La tendencia negativa de la frecuencia acumulada de días calurosos (HDF) difiere con lo estipulado por el Instituto Nacional de Defensa Civil (INDECI, 2022) y el SENAMHI (Aliaga Nestares et al., 2018), quienes mencionan que los incendios se propagan con mayor facilidad en presencia de altas temperaturas. No obstante, esta podría deberse a las oscilaciones térmicas diarias de altas y bajas temperaturas (heladas) características de la época seca en el área de estudio y que por su parte, también promoverían la desecación del combustible (Armenteras et al., 2020; Román-Cuesta et al., 2014) o a aquellos incendios que se suscitaron durante la noche, a pesar de que la ocurrencia en la noche es menos probable debido a altos niveles de humedad (Oliveras et al., 2014).

Además, ambos organismos (INDECI y CENEPRED), también recalcan la mayor propagación en ausencia de precipitaciones. Sin embargo, en el modelado no fue seleccionada la frecuencia acumulada de días secos (DDF). Lo cual indica únicamente que a pesar de su posible influencia en la extensión, no resultó lo suficientemente relevante para predecir la extensión de los incendios en el área de estudio. No obstante, mencionan la importancia de la inflamabilidad (en particular la combustibilidad) reflejada en una cantidad elevada de ramas y hojas senescentes; así como, los residuos del deshierbe y la presencia de hojarasca en pie, dentro de la cual se encuentran pastos secos completamente desarrollados, en concordancia con la selección de la materia seca (carga de combustible) y la cobertura de pastos.



V. CONCLUSIONES

- Los factores determinantes de la ocurrencia de incendios en pastizales altoandinos, identificados entre todas las variables consideradas y en base al estudio de tres provincias ganaderas del departamento de Puno (Melgar, Azángaro y Lampa), fueron: la elevación (factor topográfico), la temperatura máxima (factor climático), el Índice de Vegetación Ajustado al Suelo (factor de vegetación) y el Índice de Posición Topográfica calculado a un radio de 1000 m (factor topográfico). En relación a la topografía, la probabilidad de ocurrencia de incendios aumentó a medida que la elevación se incrementaba hasta llegar a una altitud determinada, a partir de la cual, la probabilidad disminuyó (correspondiente a zonas de alta montaña); además, la probabilidad se incrementó simultáneamente con el TPI (desde ligeras depresiones a cimas de cerros). Asimismo, respecto al clima, la probabilidad de ocurrencia de incendios se incrementó hasta una temperatura determinada, a partir de la cual la probabilidad disminuyó. Inversamente, la probabilidad disminuyó a medida que el SAVI se incrementaba.
- Los factores determinantes de la extensión de los incendios en pastizales altoandinos; identificados entre todas las variables consideradas, incluyendo aquellas de evaluación inmediata en campo posterior a la ocurrencia, y en base al estudio de las tres provincias ganaderas del departamento de Puno; fueron: la frecuencia acumulada de días calurosos (factor climático), la cobertura de pastos (factor de vegetación), la cobertura de roca, la materia seca (factor de combustibilidad), la exposición topográfica (factor topográfico) y el Índice de Posición Topográfica calculado a un radio de 1000 m (factor topográfico). En relación al clima, la extensión esperada de incendios disminuyó a medida que la



HDF se incrementaba (posiblemente por las oscilaciones térmicas diarias o incendios suscitados durante la noche). Respecto a la vegetación y la combustibilidad, la extensión esperada disminuyó a medida que la cobertura de roca aumentaba; y por el contrario, se incrementó juntamente con la cobertura de pastos y la materia seca. Referente a la topografía, la extensión esperada se incrementó simultáneamente con el TPI y disminuyó conforme la exposición topográfica se incrementaba (los incendios más extensos se ubicaron en sitios semisoleados).



VI. RECOMENDACIONES

- Actualizar el sistema de alerta temprana a nivel distrital y provincial en base a los resultados presentados en esta investigación.
- Considerar otras variables ambientales con influencia potencial en la ocurrencia y extensión de incendios en pastizales altoandinos, como la dirección y velocidad del viento, la precipitación o la humedad relativa.
- Desarrollar un método de clasificación específico para el departamento de Puno, que facilite la delimitación de incendios y por ende, permita una mejor diferenciación entre las firmas espectrales de las superficies aradas y los sitios quemados; además de un proceso de automatización para esta o la adecuación del NBR para incendios en pastizales altoandinos.
- Evaluar los eventos de ignición (p. ej. impulsores culturales y religiosos) presentes en el área de estudio para el planteamiento de las medidas más efectivas para la prevención de los incendios en los pastizales.



VII. REFERENCIAS BIBLIOGRÁFICAS

- Abdi, O., Kamkar, B., Shirvani, Z., Teixeira da Silva, J. A. y Buchroithner, M. F. (2018). Spatial-statistical analysis of factors determining forest fires: A case study from Golestan, Northeast Iran. *Geomatics, Natural Hazards and Risk*, 9(1), 267–280. <https://doi.org/10.1080/19475705.2016.1206629>
- Achard, F., Eva, H. D., Mollicone, D. y Beuchle, R. (2007). The effect of climate anomalies and human ignition factor on wildfires in Russian boreal forests. *Philosophical Transactions of the Royal Society B: Biological Sciences*. <https://doi.org/10.1098/rstb.2007.2203>
- Aide, T. M. y Grau, H. R. (2004). Ecology. Globalization, migration, and Latin American ecosystems. *Science (New York, N.Y.)*, 305(5692), 1915–1916. <https://doi.org/10.1126/science.1103179>
- Akaike, H. (1974). A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. <https://doi.org/10.1109/TAC.1974.1100705>
- Aliaga Nestares, V., Quispe, N., Ramos, I. y Rodríguez Zimmermann, D. (2018, marzo). *Estudio de condiciones atmosféricas favorables a los incendios forestales en el Perú*. SENAMHI. <https://repositorio.senamhi.gob.pe/handle/20.500.12542/199>
- Alsubai, S. (2023). Emotion Detection Using Deep Normalized Attention-Based Neural Network and Modified-Random Forest. *Sensors*, 23(1), Article 1. <https://doi.org/10.3390/s23010225>
- Aramayo, W. L. (2019). *Distribución espacial del riesgo de sequía en la región andina de Puno, Perú* [Maestría, Universidad Nacional Agraria La Molina]. <http://repositorio.lamolina.edu.pe/handle/20.500.12996/3815>
- Aráoz, E. y Grau, H. R. (2010). Fire-Mediated Forest Encroachment in Response to Climatic and Land-Use Change in Subtropical Andean Treelines. *Ecosystems*, 13(7), 992–1005. <https://doi.org/10.1007/s10021-010-9369-7>
- Arizapana-Almonacid, M. A., Pariona-Antonio, V. H., Castañeda-Tinco, I., Ascención Mendoza, J. C., Gutiérrez Gómez, E. y Ramoni-Perazzi, P. (2024). Land cover



- changes and comparison of current landscape metrics in a region of the Central Andes affected by population migration. *Annals of GIS*, 0(0), 1–16. <https://doi.org/10.1080/19475683.2024.2304203>
- Armenteras, D., Barreto, J. S., Tabor, K., Molowny-Horas, R. y Retana, J. (2017). Changing patterns of fire occurrence in proximity to forest edges, roads and rivers between NW Amazonian countries. *Biogeosciences*, 14(11), 2755–2765. <https://doi.org/10.5194/bg-14-2755-2017>
- Armenteras, D., González, T. M., Vargas Ríos, O., Meza Elizalde, M. C., Oliveras, I., Armenteras, D., González, T. M., Vargas Ríos, O., Meza Elizalde, M. C. y Oliveras, I. (2020). Incendios en ecosistemas del norte de Suramérica: Avances en la ecología del fuego tropical en Colombia, Ecuador y Perú. *Caldasia*, 42(1), 1–16. <https://doi.org/10.15446/caldasia.v42n1.77353>
- Bao, W., Yu, F., Chang, Y., Guo, M., Zhou, F. y Zhong, C. (2022). Estimation of fuel load using remote sensing data in Hulunbuir Grassland. *Natural Hazards Research*, 2(4), 375–383. <https://doi.org/10.1016/j.nhres.2022.11.004>
- Barbosa A.M., Brown J.A., Jimenez-Valverde A., Real R. (2016). *modEvA: Model Evaluation and Analysis* (p. 3.17) [Dataset]. <https://doi.org/10.32614/CRAN.package.modEvA>
- Berlinck, C. N., Lima, L. H. A. y Carvalho Junior, E. A. R. de. (2021). Historical survey of research related to fire management and fauna conservation in the world and in Brazil. *Biota Neotropica*, 21, e20201144. <https://doi.org/10.1590/1676-0611-BN-2020-1144>
- Bernardi, R. E., Staal, A., Xu, C., Scheffer, M. y Holmgren, M. (2019). Livestock Herbivory Shapes Fire Regimes and Vegetation Structure Across the Global Tropics. *Ecosystems*, 22(7), 1457–1465. <https://doi.org/10.1007/s10021-019-00349-x>
- Bonham, C. D. (1989). *Measurements for terrestrial vegetation*. Wiley.
- Bush, M. B., Hansen, B. C. S., Rodbell, D. T., Seltzer, G. O., Young, K. R., León, B., Abbott, M. B., Silman, M. R. y Gosling, W. D. (2005). A 17 000-year history of



- Andean climate and vegetation change from Laguna de Chochos, Peru. *Journal of Quaternary Science*, 20(7–8), 703–714. <https://doi.org/10.1002/jqs.983>
- Buthelezi, H. Z., Munien, S. y Nkambule, S. S. (2016). Opportunities and constraints for community-based conservation: The case of the KwaZulu-Natal Sandstone Sourveld grassland, South Africa. *Bothalia - African Biodiversity & Conservation*, 46(2), 1–8. <https://doi.org/10.4102/abc.v46i2.2120>
- Caratti, J. F. (2006). Point Intercept (PO). In: Lutes, Duncan C.; Keane, Robert E.; Caratti, John F.; Key, Carl H.; Benson, Nathan C.; Sutherland, Steve; Gangi, Larry J. 2006. *FIREMON: Fire Effects Monitoring and Inventory System. Gen. Tech. Rep. RMRS-GTR-164-CD. Fort Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. p. PO-1-17, 164.* <https://research.fs.usda.gov/treearch/24062>
- Cardille, J. A., Ventura, S. J. y Turner, M. G. (2001). Environmental and Social Factors Influencing Wildfires in the Upper Midwest, United States. *Ecological Applications*, 11(1), 111–127. [https://doi.org/10.1890/1051-0761\(2001\)011\[0111:EASFIW\]2.0.CO;2](https://doi.org/10.1890/1051-0761(2001)011[0111:EASFIW]2.0.CO;2)
- Carilla, J. y Grau, H. R. (2010). 150 Years of Tree Establishment, Land Use and Climate Change in Montane Grasslands, Northwest Argentina: Tree Establishment, Land-Use, and Climate Change. *Biotropica*, 42(1), 49–58. <https://doi.org/10.1111/j.1744-7429.2009.00565.x>
- Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres. (2022). *Escenario de riesgo por incendios forestales de la región de Puno* (p. 57). Centro Nacional de Estimación, Prevención y Reducción del Riesgo de Desastres. <https://sigrid.cenepred.gob.pe/sigridv3/documento/14573>
- Chakraborty, R., Guha, B. K., Talukdar, S., Ratnam, M. V. y Maitra, A. (2019). Growth in mid-monsoon dry phases over the Indian region: Prevailing influence of anthropogenic aerosols. *Atmospheric Chemistry and Physics*, 19(19), 12325–12341. <https://doi.org/10.5194/acp-19-12325-2019>



- Congedo, L. (2021). Semi-Automatic Classification Plugin: A Python tool for the download and processing of remote sensing images in QGIS. *Journal of Open Source Software*, 6(64), 3172. <https://doi.org/10.21105/joss.03172>
- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V. y Böhner, J. (2015). System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geoscientific Model Development*, 8(7), 1991–2007. <https://doi.org/10.5194/gmd-8-1991-2015>
- Corporación Nacional Forestal (Chile). (2011). *Manual con Medidas para la Prevención de Incendios Forestales: Región O'Higgins*. <https://simef.minagri.gob.cl/bibliotecadigital/items/5f64b56c-a67b-4728-9344-43d794238165>
- Cox, D. R. y Snell, E. J. (1989). *Analysis of binary data* (2nd ed). Chapman and Hall.
- Cruz, M. G., Sullivan, A. L., Gould, J. S., Hurley, R. J., Plucinski, M. P., Cruz, M. G., Sullivan, A. L., Gould, J. S., Hurley, R. J. y Plucinski, M. P. (2018). Got to burn to learn: The effect of fuel load on grassland fire behaviour and its management implications. *International Journal of Wildland Fire*, 27(11), 727–741. <https://doi.org/10.1071/WF18082>
- Cutler, D. R., Edwards Jr., T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J. y Lawler, J. J. (2007). Random Forests for Classification in Ecology. *Ecology*, 88(11), 2783–2792. <https://doi.org/10.1890/07-0539.1>
- De Reu, J., Bourgeois, J., Bats, M., Zwertvaegher, A., Gelorini, V., De Smedt, P., Chu, W., Antrop, M., De Maeyer, P., Finke, P., Van Meirvenne, M., Verniers, J. y Crombé, P. (2013). Application of the topographic position index to heterogeneous landscapes. *Geomorphology*, 186, 39–49. <https://doi.org/10.1016/j.geomorph.2012.12.015>
- Delcourt, C. J. F., Combee, A., Izbicki, B., Mack, M. C., Maximov, T., Petrov, R., Rogers, B. M., Scholten, R. C., Shestakova, T. A., van Wees, D. y Veraverbeke, S. (2021). Evaluating the Differenced Normalized Burn Ratio for Assessing Fire Severity Using Sentinel-2 Imagery in Northeast Siberian Larch Forests. *Remote Sensing*, 13(12), Article 12. <https://doi.org/10.3390/rs13122311>



- Dewar, J. J., Falk, D. A., Swetnam, T. W., Baisan, C. H., Allen, C. D., Parmenter, R. R., Margolis, E. Q. y Taylor, E. J. (2021). Valleys of fire: Historical fire regimes of forest-grassland ecotones across the montane landscape of the Valles Caldera National Preserve, New Mexico, USA. *Landscape Ecology*, 36(2), 331–352. <https://doi.org/10.1007/s10980-020-01101-w>
- Di Pasquale, G., Marziano, M., Impagliazzo, S., Lubritto, C., De Natale, A. y Bader, M. Y. (2008). The Holocene treeline in the northern Andes (Ecuador): First evidence from soil charcoal. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 259(1), 17–34. <https://doi.org/10.1016/j.palaeo.2006.12.016>
- Drezner, T. D. y Drezner, Z. (2021). Informed cover measurement: Guidelines and error for point-intercept approaches. *Applications in Plant Sciences*, 9(9–10), e11446. <https://doi.org/10.1002/aps3.11446>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. y Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25–36. <https://doi.org/10.1016/j.rse.2011.11.026>
- Espinoza, J. C., Segura, H., Ronchail, J., Drapeau, G. y Gutierrez-Cori, O. (2016). Evolution of wet-day and dry-day frequency in the western Amazon basin: Relationship with atmospheric circulation and impacts on vegetation. *Water Resources Research*, 52(11), 8546–8560. <https://doi.org/10.1002/2016WR019305>
- Evans, J. S. (2015). *spatialEco: Spatial Analysis and Modelling Utilities* (p. 2.0-2) [Dataset]. <https://doi.org/10.32614/CRAN.package.spatialEco>
- Fedriago, J. K., Ataide, P. F., Filho, J. A., Oliveira, L. V., Jaurena, M., Laca, E. A., Overbeck, G. E. y Nabinger, C. (2018). Temporary grazing exclusion promotes rapid recovery of species richness and productivity in a long-term overgrazed Campos grassland. *Restoration Ecology*, 26(4), 677–685. <https://doi.org/10.1111/rec.12635>



- Fox, J. y Monette, G. (1992). Generalized Collinearity Diagnostics. *Journal of the American Statistical Association*, 87(417), 178–183. <https://doi.org/10.2307/2290467>
- Gobierno Regional de Puno. (2023). *Plan regional de contingencia ante incendios forestales: 2023*. <https://www.regionpuno.gob.pe/planes-de-contingencia-3/>
- GRASS Development Team, Landa, M., Neteler, M., Metz, M., Petrášová, A., Petráš, V., Clements, G., Zigo, T., Larsson, N., Kladvivová, L., Haedrich, C., Blumentrath, S., Andreo, V., Cho, H., Gebbert, S., Nartišš, M., Kudrnovsky, H., Delucchi, L., Zambelli, P., ... Bowman, H. (2024). *GRASS GIS* (Versión 8.4.0RC1) [Software]. Zenodo. <https://doi.org/10.5281/ZENODO.5176030>
- Grau, H. R. y Aide, T. M. (2007). Are Rural–Urban Migration and Sustainable Development Compatible in Mountain Systems? *Mountain Research and Development*, 27(2), 119–123. <https://doi.org/10.1659/mrd.0906>
- Grau, H. R., Aráoz, E., Navarro, C. J., Nanni, A. S. y Malizia, A. (2020). Pathways of megaherbivore rewilding transitions: Typologies from an Andean gradient. *Elementa: Science of the Anthropocene*, 8, 19. <https://doi.org/10.1525/elementa.415>
- Guisan, A. y Zimmermann, N. E. (2000). Predictive habitat distribution models in ecology. *Ecological Modelling*, 135(2), 147–186. [https://doi.org/10.1016/S0304-3800\(00\)00354-9](https://doi.org/10.1016/S0304-3800(00)00354-9)
- Gutierrez Cori, O. E. (2018). Estimación de índices de sequía mediante sensoramiento remoto integrando MODIS y TRMM en la cuenca andino -amazónica, Perú. *Universidad Nacional Agraria La Molina*. <http://repositorio.lamolina.edu.pe/handle/20.500.12996/3807>
- Guzmán, M. A. N., Sardón, M. A. P., Arteaga, G. C. R. y Soto, S. N. F. (2021). Fragmentación Antropogénica de los ecosistemas de Puna en el extremo sur del Perú. *Estudios Geográficos*, 82(290), Article 290. <https://doi.org/10.3989/estgeogr.202070.070>



- Harris, L. y Taylor, A. H. (2017). Previous burns and topography limit and reinforce fire severity in a large wildfire. *Ecosphere*, 8(11), e02019. <https://doi.org/10.1002/ecs2.2019>
- Hastie, T., Tibshirani, R. y Friedman, J. (2009). Random Forests. En T. Hastie, R. Tibshirani y J. Friedman (Eds.), *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (pp. 587–604). Springer. https://doi.org/10.1007/978-0-387-84858-7_15
- Hoffman, C. M., Ziegler, J. P., Tinkham, W. T., Hiers, J. K. y Hudak, A. T. (2023). A Comparison of Four Spatial Interpolation Methods for Modeling Fine-Scale Surface Fuel Load in a Mixed Conifer Forest with Complex Terrain. *Fire*, 6(6), Article 6. <https://doi.org/10.3390/fire6060216>
- Hogan, J. y Adams, N. M. (2023). On Averaging ROC Curves. *Transactions on Machine Learning Research*. <https://openreview.net/forum?id=FByH3qL87G>
- Hollander, F. A., Titeux, N. y Van Dyck, H. (2013). Habitat-dependent prey availability and offspring provisioning explain an ecological trap in a migratory bird. *Functional Ecology*, 27(3), 702–709. <https://doi.org/10.1111/1365-2435.12077>
- Huang, Y., Xia, X., Zhou, Q., Pan, Y., Chen, Y. y Li, H. (2023). Spatial and temporal patterns and causes of grassland fires in Qinghai Province. *Progress in Geography*, 42(10), 1973–1983. <https://doi.org/10.18306/dlkxjz.2023.10.009>
- Hudak, A. T., Fairbanks, D. H. K. y Brockett, B. H. (2004). Trends in fire patterns in a southern African savanna under alternative land use practices. *Agriculture, Ecosystems & Environment*, 101(2), 307–325. <https://doi.org/10.1016/j.agee.2003.09.010>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Hussain, S., Raza, A., Abdo, H. G., Mubeen, M., Tariq, A., Nasim, W., Majeed, M., Almohamad, H. y Al Dughairi, A. A. (2023). Relation of land surface temperature with different vegetation indices using multi-temporal remote sensing data in Sahiwal region, Pakistan. *Geoscience Letters*, 10(1), 33. <https://doi.org/10.1186/s40562-023-00287-6>



- Instituto Nacional de Defensa Civil. (2022, septiembre 1). *Preparados ante incendios forestales*. Gob.pe: Plataforma digital única del Estado Peruano. <https://www.gob.pe/institucion/indeci/campa%C3%B1as/1582-preparados-ante-incendios-forestales-evitar-los-incendios-forestales-esta-en-nuestras-manos>
- Izquierdo, A. E., Grau, H. R., Navarro, C. J., Casagrande, E., Castilla, M. C. y Grau, A. (2018). Highlands in Transition: Urbanization, Pastoralism, Mining, Tourism, and Wildlife in the Argentinian Puna. *Mountain Research and Development*, 38(4), 390–400. <https://doi.org/10.1659/MRD-JOURNAL-D-17-00075.1>
- Jiang, Y., Zhou, L. y Raghavendra, A. (2020). Observed changes in fire patterns and possible drivers over Central Africa. *Environmental Research Letters*, 15(9), 0940b8. <https://doi.org/10.1088/1748-9326/ab9db2>
- Jiménez-Olivencia, Y., Ibañez-Jiménez, Á., Porcel-Rodríguez, L. y Zimmerer, K. (2021). Land use change dynamics in Euro-mediterranean mountain regions: Driving forces and consequences for the landscape. *Land Use Policy*, 109, 105721. <https://doi.org/10.1016/j.landusepol.2021.105721>
- Key, C. H. y Benson, N. C. (2006). Landscape Assessment (LA). In: Lutes, Duncan C.; Keane, Robert E.; Caratti, John F.; Key, Carl H.; Benson, Nathan C.; Sutherland, Steve; Gangi, Larry J. 2006. *FIREMON: Fire Effects Monitoring and Inventory System. Gen. Tech. Rep. RMRS-GTR-164-CD. Fort Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. p. LA-1-55, 164.* <https://research.fs.usda.gov/treearch/24066>
- Killgore, A., Jackson, E. y Whitford, W. G. (2009). Fire in Chihuahuan Desert grassland: Short-term effects on vegetation, small mammal populations, and faunal pedoturbation. *Journal of Arid Environments*, 73(11), 1029–1034. <https://doi.org/10.1016/j.jaridenv.2009.04.016>
- Kim, S. J., Lim, C.-H., Kim, G. S., Lee, J., Geiger, T., Rahmati, O., Son, Y. y Lee, W.-K. (2019). Multi-Temporal Analysis of Forest Fire Probability Using Socio-Economic and Environmental Variables. *Remote Sensing*, 11(1), Article 1. <https://doi.org/10.3390/rs11010086>



- Kirkpatrick, J. B., Marsden-Smedley, J. B. y Leonard, S. W. J. (2011). Influence of grazing and vegetation type on post-fire flammability. *Journal of Applied Ecology*, 48(3), 642–649. <https://doi.org/10.1111/j.1365-2664.2011.01962.x>
- Kraaij, T., Msweli, S. T. y Potts, A. J. (2022). Fuel trait effects on flammability of native and invasive alien shrubs in coastal fynbos and thicket (Cape Floristic Region). *PeerJ*, 10, e13765. <https://doi.org/10.7717/peerj.13765>
- Krawchuk, M. A., Haire, S. L., Coop, J., Parisien, M.-A., Whitman, E., Chong, G. y Miller, C. (2016). Topographic and fire weather controls of fire refugia in forested ecosystems of northwestern North America. *Ecosphere*, 7(12), e01632. <https://doi.org/10.1002/ecs2.1632>
- Ku, K.-B., Mansoor, S., Han, G. D., Chung, Y. S. y Tuan, T. T. (2023). Identification of new cold tolerant Zoysia grass species using high-resolution RGB and multi-spectral imaging. *Scientific Reports*, 13(1), Article 1. <https://doi.org/10.1038/s41598-023-40128-2>
- Li, Y., Xu, S., Fan, Z., Zhang, X., Yang, X., Wen, S. y Shi, Z. (2023). Risk Factors and Prediction of the Probability of Wildfire Occurrence in the China–Mongolia–Russia Cross-Border Area. *Remote Sensing*, 15(1). <https://doi.org/10.3390/rs15010042>
- Liaw, A. y Wiener, M. (2002). *Classification and Regression by randomForest* (p. 4.7-1.1) [Dataset]. R news. <https://doi.org/10.32614/CRAN.package.randomForest>
- Liu, X., Tong, Z., Zhang, J. y Song, C. (2023). Uncertainty simulation of large-scale discrete grassland fire spread based on Monte Carlo. *Fire Safety Journal*, 135, 103713. <https://doi.org/10.1016/j.firesaf.2022.103713>
- Liu, X., Zhang, G., Lu, J. y Zhang, J. (2019). Risk assessment using transfer learning for grassland fires. *Agricultural and Forest Meteorology*, 269–270, 102–111. <https://doi.org/10.1016/j.agrformet.2019.01.011>
- Llacza, A., Acuña, D., Jácome, G., De la Cruz, G., Paredes, J., Bruno, J., Alvarez, E., Flores, W., Urdanivia, F. y Sulca, B. (2021). *Escenarios climáticos al 2050 en el Perú: Cambios en el clima promedio*. (PE2021; Proyecto Apoyo a la Gestión del Cambio Climático - Fase 2, p. 79). Ministerio del Ambiente.



<https://sinia.minam.gob.pe/documentos/escenarios-climaticos-cambios-extremos-climaticos-peru-2050>

- Lobo, J. M., Jiménez-Valverde, A. y Hortal, J. (2010). The uncertain nature of absences and their importance in species distribution modelling. *Ecography*, 33(1), 103–114. <https://doi.org/10.1111/j.1600-0587.2009.06039.x>
- Lobos, G. y Viviani, J.-L. (2008). Factores determinantes de la utilización de instrumentos públicos para la gestión del riesgo en la industria vitivinícola chilena: Un modelo logit binomial. *Lecturas de Economía*, 69, 63–84. http://www.scielo.org.co/scielo.php?script=sci_abstract&pid=S0120-25962008000200003&lng=en&nrm=iso&tlng=es
- Lüdecke, D., Makowski, D., Ben-Shachar, M. S., Patil, I., Waggoner, P., Wiernik, B. M. y Thériault, R. (2019). *performance: Assessment of Regression Models Performance* (p. 0.12.0) [Dataset]. <https://doi.org/10.32614/CRAN.package.performance>
- Mahdavi, A. (2012). Forests and rangelands? Wildfire risk zoning using GIS and AHP techniques. *Caspian Journal of Environmental Sciences*, 10(1), 43–52. https://cjes.guilan.ac.ir/article_1084.html
- Makhaya, Z., Odindi, J. y Mutanga, O. (2022). The influence of bioclimatic and topographic variables on grassland fire occurrence within an urbanized landscape. *Scientific African*, 15, e01127. <https://doi.org/10.1016/j.sciaf.2022.e01127>
- Manta, M., Kometter, R. y Navia, A. (2018, noviembre 12). *Evaluation of wildfire danger in the Peruvian Andes: First step for its reduction and adaptation*. https://doi.org/10.14195/978-989-26-16-506_4
- Marques, S., Borges, J. G., Garcia-Gonzalo, J., Moreira, F., Carreiras, J. M. B., Oliveira, M. M., Cantarina, A., Botequim, B. y Pereira, J. M. C. (2011). Characterization of wildfires in Portugal. *European Journal of Forest Research*, 130(5), 775–784. <https://doi.org/10.1007/s10342-010-0470-4>
- McFadden, D. (1973). Conditional Logit Analysis of Qualitative Choice Behaviour. En *Frontiers in Econometrics* (pp. 105–142). Academic Press New York.



- McLauchlan, K. K., Higuera, P. E., Miesel, J., Rogers, B. M., Schweitzer, J., Shuman, J. K., Tepley, A. J., Varner, J. M., Veblen, T. T., Adalsteinsson, S. A., Balch, J. K., Baker, P., Batllori, E., Bigio, E., Brando, P., Cattau, M., Chipman, M. L., Coen, J., Crandall, R., ... Watts, A. C. (2020). Fire as a fundamental ecological process: Research advances and frontiers. *Journal of Ecology*, *108*(5), 2047–2069. <https://doi.org/10.1111/1365-2745.13403>
- Michelutti, N., Wolfe, A. P., Cooke, C. A., Hobbs, W. O., Vuille, M. y Smol, J. P. (2015). Climate Change Forces New Ecological States in Tropical Andean Lakes. *PLOS ONE*, *10*(2), e0115338. <https://doi.org/10.1371/journal.pone.0115338>
- Montesinos-Tubée, D. B., Cleef, A. M. y Sýkora, K. V. (2021). The Subnival Vegetation of Moquegua, South Peru: Chasmophytes, Grasslands and Cushion Communities. *Ecologies*, *2*(1), Article 1. <https://doi.org/10.3390/ecologies2010005>
- Montti, L., Velazco, S. J. E., Travis, J. M. J. y Grau, H. R. (2021). Predicting current and future global distribution of invasive *Ligustrum lucidum* W.T. Aiton: Assessing emerging risks to biodiversity hotspots. *Diversity and Distributions*, *27*(8), 1568–1583. <https://doi.org/10.1111/ddi.13303>
- Morandini, F., Santoni, P. A., Tramoni, J. B. y Mell, W. E. (2019). Experimental investigation of flammability and numerical study of combustion of shrub of rockrose under severe drought conditions. *Fire Safety Journal*, *108*, 102836. <https://doi.org/10.1016/j.firesaf.2019.102836>
- Morvan, D., Méradji, S. y Accary, G. (2009). Physical modelling of fire spread in Grasslands. *Fire Safety Journal*, *44*(1), 50–61. <https://doi.org/10.1016/j.firesaf.2008.03.004>
- Mpakairi, K. S., Tagwireyi, P., Ndaimani, H. y Madiri, H. T. (2019). Distribution of wildland fires and possible hotspots for the Zimbabwean component of Kavango-Zambezi Transfrontier Conservation Area. *South African Geographical Journal*, *101*(1), 110–120. <https://doi.org/10.1080/03736245.2018.1541023>
- Murphy, K. A., Reynolds, J. H., Koltun, J. M., Murphy, K. A., Reynolds, J. H. y Koltun, J. M. (2008). Evaluating the ability of the differenced Normalized Burn Ratio (dNBR) to predict ecologically significant burn severity in Alaskan boreal forests.



- International Journal of Wildland Fire*, 17(4), 490–499.
<https://doi.org/10.1071/WF08050>
- Naimi, B., Hamm, N. A. S., Groen, T. A., Skidmore, A. K. y Toxopeus, A. G. (2014). Where is positional uncertainty a problem for species distribution modelling? *Ecography*, 37(2), 191–203. <https://doi.org/10.1111/j.1600-0587.2013.00205.x>
- Narisetty, N. N. (2020). Bayesian model selection for high-dimensional data. En *Handbook of Statistics* (Vol. 43, pp. 207–248). Elsevier.
<https://doi.org/10.1016/bs.host.2019.08.001>
- Oliver, V., Oliveras, I., Kala, J., Lever, R. y Teh, Y. A. (2017). The effects of burning and grazing on soil carbon dynamics in managed Peruvian tropical montane grasslands. *Biogeosciences*, 14(24), 5633–5646. <https://doi.org/10.5194/bg-14-5633-2017>
- Oliveras, I., Anderson, L. O. y Malhi, Y. (2014). Application of remote sensing to understanding fire regimes and biomass burning emissions of the tropical Andes: Fire regimes of the tropical Andes. *Global Biogeochemical Cycles*, 28(4), 480–496. <https://doi.org/10.1002/2013GB004664>
- Ong, A. K. S., Prasetyo, Y. T., Velasco, K. E. C., Abad, E. D. R., Buencille, A. L. B., Estorninos, E. M., Cahigas, M. M. L., Chuenyindee, T., Persada, S. F., Nadlifatin, R. y Sittiwatethanasiri, T. (2022). Utilization of random forest classifier and artificial neural network for predicting the acceptance of reopening decommissioned nuclear power plant. *Annals of Nuclear Energy*, 175, 109188. <https://doi.org/10.1016/j.anucene.2022.109188>
- Parker, N. J., Sullins, D. S., Haukos, D. A., Fricke, K. A. y Hagen, C. A. (2022). Recovery of working grasslands following a megafire in the southern mixed-grass prairie. *Global Ecology and Conservation*, 36, e02142. <https://doi.org/10.1016/j.gecco.2022.e02142>
- Pereira, A., Barros, D., Jr, F. W., Pereira, J. y Reis, A. (2013). Spatial distribution analysis of burned areas through the K-Ripley function. *Scientia Forestalis/Forest Sciences*, 41, 445–455.



- Pivello, V. R., Vieira, I., Christianini, A. V., Ribeiro, D. B., da Silva Menezes, L., Berlinck, C. N., Melo, F. P. L., Marengo, J. A., Tornquist, C. G., Tomas, W. M. y Overbeck, G. E. (2021). Understanding Brazil's catastrophic fires: Causes, consequences and policy needed to prevent future tragedies. *Perspectives in Ecology and Conservation*, 19(3), 233–255. <https://doi.org/10.1016/j.pecon.2021.06.005>
- Ponce Vigo, B. V. (2021). *Implementación de un sistema de monitoreo satelital del patrimonio forestal a escala nacional aplicado a incendios forestales* [Trabajo de Suficiencia Profesional, Universidad Nacional Agraria La Molina]. <https://repositorio.lamolina.edu.pe/handle/20.500.12996/5199>
- R Core Team. (2022). *R: A Language and Environment for Statistical Computing* [Software]. R Foundation for Statistical Computing. <https://www.R-project.org/>
- ROAPUNO. (2022, noviembre 16). Más de 100 vicuñas murieron quemadas en el incendio forestal en varios sectores del distrito de Muñani. *Radio Onda Azul*. <https://radioondaazul.com/mas-de-100-vicunas-murieron-quemadas-en-el-incendio-forestal-en-varios-sectores-del-distrito-de-munani/>
- Román-Cuesta, R. M., Carmona-Moreno, C., Lizcano, G., New, M., Silman, M., Knoke, T., Malhi, Y., Oliveras, I., Asbjornsen, H. y Vuille, M. (2014). Synchronous fire activity in the tropical high Andes: An indication of regional climate forcing. *Global Change Biology*, 20(6), 1929–1942. <https://doi.org/10.1111/gcb.12538>
- Roteta, E., Bastarrika, A., Padilla, M., Storm, T. y Chuvieco, E. (2019). Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. *Remote Sensing of Environment*, 222, 1–17. <https://doi.org/10.1016/j.rse.2018.12.011>
- Rozas-Davila, A., Rodbell, D. T. y Bush, M. B. (2023). Pleistocene megafaunal extinction in the grasslands of Junín-Peru. *Journal of Biogeography*, 50(4), 755–766. <https://doi.org/10.1111/jbi.14566>
- Sánchez Rodríguez, E., Torres Crespo, M. Á., Fernández-Palacios Carmona, A., Aguilar Alba, M., Pino Serrato, I. L. y Granado Ruiz, L. (2000). *Comparación del NDVI con el PVI y el SAVI como indicadores para la asignación de modelos de*



combustible para la estimación del riesgo de incendios en Andalucía.
<https://idus.us.es/handle/11441/30498>

Sayedí, S. S., Abbott, B. W., Vannièrè, B., Leys, B., Colombaroli, D., Romera, G. G., Słowiński, M., Aleman, J. C., Blarquez, O., Feurdean, A., Brown, K., Aakala, T., Alenius, T., Allen, K., Andric, M., Bergeron, Y., Biagioni, S., Bradshaw, R., Bremond, L., ... Daniau, A.-L. (2024). Assessing changes in global fire regimes. *Fire Ecology*, 20(1), 18. <https://doi.org/10.1186/s42408-023-00237-9>

Schiferl, J., Kingston, M., Åkesson, C. M., Valencia, B. G., Rozas-Davila, A., McGee, D., Woods, A., Chen, C. Y., Hatfield, R. G., Rodbell, D. T., Abbott, M. B. y Bush, M. B. (2023). A neotropical perspective on the uniqueness of the Holocene among interglacials. *Nature Communications*, 14(1), 7404. <https://doi.org/10.1038/s41467-023-43231-0>

Scott, G. A. J. (1977). The Role of Fire in the Creation and Maintenance of Savanna in the Montana of Peru. *Journal of Biogeography*, 4(2), 143. <https://doi.org/10.2307/3038159>

Servicio Nacional de Meteorología e Hidrología. (2009). *Escenarios Climáticos en el Perú para el año 2023* (Segunda comunicación nacional de Cambio Climático, p. 26) [Resumen técnico]. Ministerio del Ambiente. https://idesepe.senamhi.gob.pe/portalidesepe/files/tematica/cambio_climatico/Escenarios_climaticos_en_el_Peru_para_el_ano_2030.pdf

Servicio Nacional de Meteorología e Hidrología. (2021). *Climas del Perú – Mapa de Clasificación Climática Nacional* (Proyecto Apoyo a la Gestión del Cambio Climático, p. 70) [Documento Técnico]. Ministerio del Ambiente. <https://www.gob.pe/institucion/senamhi/informes-publicaciones/2158106-climas-del-peru-mapa-de-clasificacion-climatica>

Servicio Nacional de Meteorología e Hidrología del Perú. (2020, septiembre 18). *Conocer áreas más probables donde se podrían expandir incendios forestales*. Gob.pe: Plataforma digital única del Estado Peruano. <https://www.gob.pe/9409-conocer-areas-mas-probables-donde-se-podrian-expandir-incendios-forestales>



- Servicio Nacional de Meteorología e Hidrología del Perú. (2022). *Guía de interpretación del GOES – 16 Producto: RGB – Temperatura de Fuego*. Servicio Nacional de Meteorología e Hidrología del Perú. <https://repositorio.senamhi.gob.pe/handle/20.500.12542/2518>
- Servicio Nacional Forestal y de Fauna Silvestre. (2019). *Sistema de Alerta Temprana y Monitoreo de Incendios Forestales*. Servicio Nacional Forestal y de Fauna Silvestre. <https://repositorio.serfor.gob.pe/handle/SERFOR/727>
- Servicio Nacional Forestal y de Fauna Silvestre. (2024, julio 16). *Servicio Nacional Forestal y de Fauna Silvestre—SERFOR*. Gob.pe: Plataforma digital única del Estado Peruano. <https://www.gob.pe/serfor>
- Sing, T., Sander, O., Beerenwinkel, N. y Lengauer, T. (2005). *ROCR: Visualizing the Performance of Scoring Classifiers* (p. 1.0-11) [Dataset]. <https://doi.org/10.32614/CRAN.package.ROCR>
- Stockwell, D. y Peters, D. (1999). The GARP modelling system: Problems and solutions to automated spatial prediction. *International Journal of Geographical Information Science*, 13(2), 143–158. <https://doi.org/10.1080/136588199241391>
- Sühs, R. B., Giehl, E. L. H. y Peroni, N. (2020). Preventing traditional management can cause grassland loss within 30 years in southern Brazil. *Scientific Reports*, 10(1), Article 1. <https://doi.org/10.1038/s41598-020-57564-z>
- Thornthwaite, C. W. (1948). An Approach toward a Rational Classification of Climate. *Geographical Review*, 38(1), 55–94. <https://doi.org/10.2307/210739>
- Ticse-Otarola, G., Vidal, O. D., Andreu-Hayles, L., Quispe-Melgar, H. R., Amoroso, M. M., Santos, G. M. y Requena-Rojas, E. J. (2023). Age structure and climate sensitivity of a high Andean relict forest of *Polylepis rodolfo-vasquezii* in central Peru. *Dendrochronologia*, 79, 126071. <https://doi.org/10.1016/j.dendro.2023.126071>
- Toro Espín, N. del, Cánovas García, F., Alonso Sarria, F. y Gomariz-Castillo Castillo, F. (2015). Comparación de métodos de clasificación de imágenes de satélite en la cuenca del río Argos (Región de Murcia). *Boletín de la Asociación de Geógrafos*



- Españoles*, 67 (1^o Cuatrimestre), 327–347.
<https://dialnet.unirioja.es/servlet/articulo?codigo=5035579>
- van Gerrevink, M. J. y Veraverbeke, S. (2021). Evaluating the Near and Mid Infrared Bi-Spectral Space for Assessing Fire Severity and Comparison with the Differenced Normalized Burn Ratio. *Remote Sensing*, 13(4), Article 4.
<https://doi.org/10.3390/rs13040695>
- Vargas, D. L. T., Guerra, R. Q. y Morales, J. J. (2004). EFECTO DE UNA QUEMA CONTROLADA SOBRE LA POBLACIÓN MICROBIANA EN SUELOS CON PASTURAS EN LA SAIS TUPAC AMARU – JUNÍN, PERÚ. *Ecología Aplicada*, 3(1–2), Article 1–2. <https://doi.org/10.21704/rea.v3i1-2.283>
- Vermote, E. (2021). *MODIS/Terra Surface Reflectance 8-Day L3 Global 500m SIN Grid V061* [Dataset]. NASA EOSDIS Land Processes Distributed Active Archive Center. <https://doi.org/10.5067/MODIS/MOD09A1.061>
- Wall, W. A., Hohmann, M. G., Just, M. G. y Hoffmann, W. A. (2021). Characterizing past fire occurrence in longleaf pine ecosystems with the Mid-Infrared Burn Index and a Random Forest classifier. *Forest Ecology and Management*, 500, 119635. <https://doi.org/10.1016/j.foreco.2021.119635>
- Wang, Z., Huang, R., Yao, Q., Zong, X., Tian, X., Zheng, B. y Trouet, V. (2023). Strong winds drive grassland fires in China. *Environmental Research Letters*, 18(1), 015005. <https://doi.org/10.1088/1748-9326/aca921>
- Weisberg, S. (2005). *Applied Linear Regression* (1^a ed.). Wiley.
<https://doi.org/10.1002/0471704091>
- Whittingham, M. J., Stephens, P. A., Bradbury, R. B. y Freckleton, R. P. (2006). Why do we still use stepwise modelling in ecology and behaviour? *Journal of Animal Ecology*, 75(5), 1182–1189. <https://doi.org/10.1111/j.1365-2656.2006.01141.x>
- Wongchuig, S. C., Mello, C. R. y Chou, S. C. (2018). Projections of the impacts of climate change on the water deficit and on the precipitation erosive indexes in Mantaro River Basin, Peru. *Journal of Mountain Science*, 15(2), 264–279. <https://doi.org/10.1007/s11629-017-4418-8>



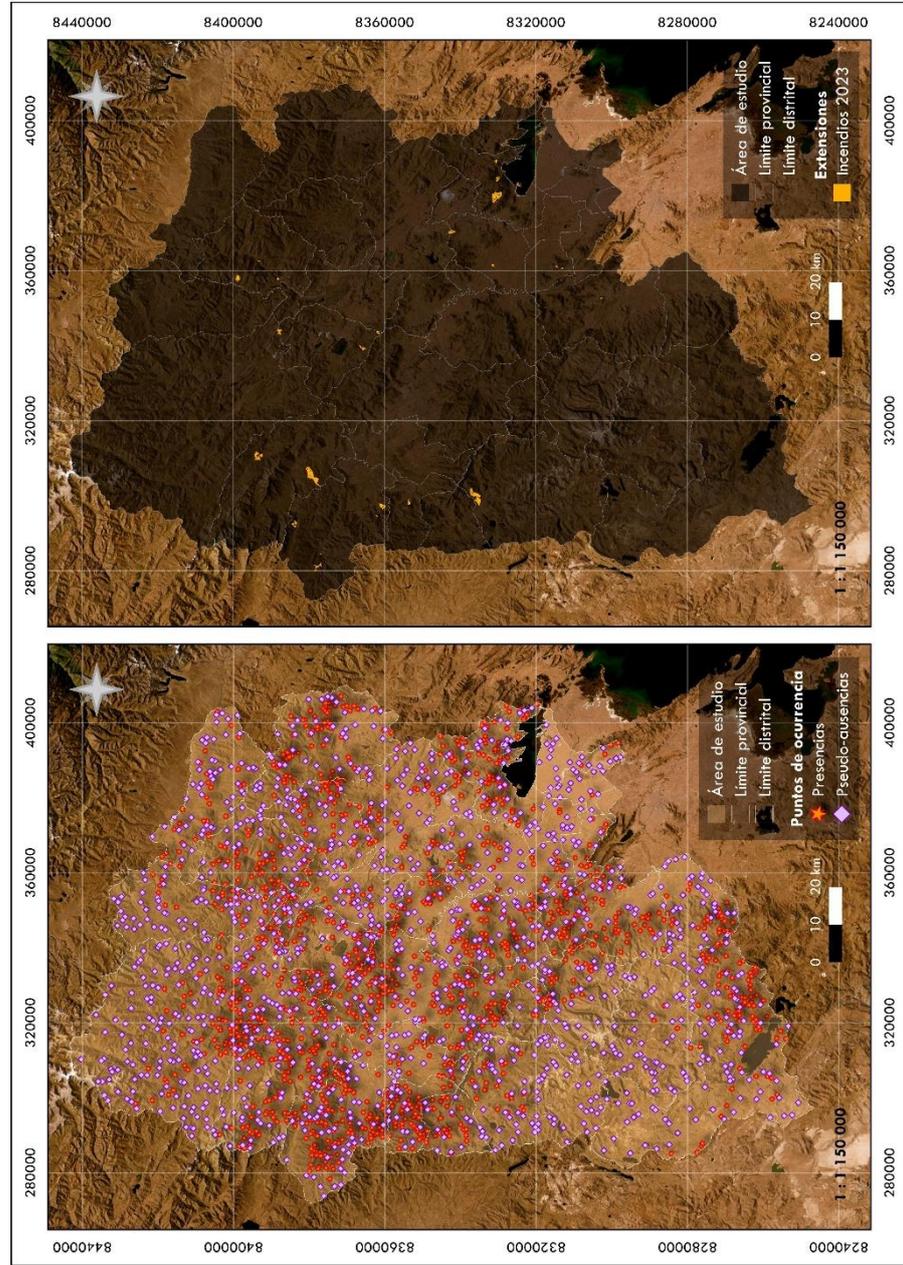
- Wu, X., Zhang, G., Yang, Z., Tan, S., Yang, Y. y Pang, Z. (2023). Machine Learning for Predicting Forest Fire Occurrence in Changsha: An Innovative Investigation into the Introduction of a Forest Fuel Factor. *Remote Sensing*, 15(17), Article 17. <https://doi.org/10.3390/rs15174208>
- Xu, F., Xu, Z., Xu, C. y Yu, T. (2023). Automatic Extraction of the Spatial Distribution of *Picea schrenkiana* in the Tianshan Mountains Based on Google Earth Engine and the Jeffries–Matusita Distance. *Forests*, 14(7), Article 7. <https://doi.org/10.3390/f14071373>
- Yang, J., He, H. S., Shifley, S. R. y Gustafson, E. J. (2007). Spatial Patterns of Modern Period Human-Caused Fire Occurrence in the Missouri Ozark Highlands. *Forest Science*, 53(1), 1–15. <https://doi.org/10.1093/forestscience/53.1.1>
- Yu, H., Wang, L., Wang, Z., Ren, C. y Zhang, B. (2019). Using Landsat OLI and Random Forest to Assess Grassland Degradation with Aboveground Net Primary Production and Electrical Conductivity Data. *ISPRS International Journal of Geo-Information*, 8(11), Article 11. <https://doi.org/10.3390/ijgi8110511>
- Zubieta, R., Ccanchi, Y. y Liza, R. (2023). Performance of heat spots obtained from satellite datasets to represent burned areas in Andean ecosystems of Cusco, Peru. *Remote Sensing Applications: Society and Environment*, 32, 101020. <https://doi.org/10.1016/j.rsase.2023.101020>
- Zubieta, R., Ccanchi, Y., Martínez, A., Saavedra, M., Norabuena, E., Alvarez, S., Ilbay, M., Zubieta, R., Ccanchi, Y., Martínez, A., Saavedra, M., Norabuena, E., Alvarez, S. y Ilbay, M. (2023). The role of drought conditions on the recent increase in wildfire occurrence in the high Andean regions of Peru. *International Journal of Wildland Fire*, 32(4), 531–544. <https://doi.org/10.1071/WF21129>
- Zubieta, R., Prudencio, F., Alarco, G. y Reupo, J. (2019). Ocurrencia de incendios forestales en el Perú durante eventos El Niño. *Boletín técnico: Generación de información y monitoreo del Fenómeno El Niño*, 6(5), 5–9. <https://repositorio.igp.gob.pe/handle/20.500.12816/4704>
- Zubieta, R., Prudencio, F., Ccanchi, Y., Saavedra, M., Sulca, J., Reupo, J., Alarco, G., Zubieta, R., Prudencio, F., Ccanchi, Y., Saavedra, M., Sulca, J., Reupo, J. y



Alarco, G. (2021). Potential conditions for fire occurrence in vegetation in the Peruvian Andes. *International Journal of Wildland Fire*, 30(11), 836–849. <https://doi.org/10.1071/WF21029>

ANEXOS

ANEXO I. Mapas de ubicación de los incendios considerados en los modelados de la ocurrencia y la extensión de los incendios.



ANEXO 2. Distribución de las zonas de riesgo de incendios basadas en el modelo de clasificación Random Forest seleccionado. Áreas y porcentajes de superficie para los distritos de las tres provincias de estudio en el departamento de Puno

N°	Provincia/ Distrito	N° de incendios		Muy alto		Alto		Moderado		Bajo		Área total del distrito	
		ha	%	ha	%	ha	%	ha	%	ha	%	ha	%
1	(A) Achaya	2	25.06	0.20	5.72	723.35	19.09	2413.46	9479.07	74.99	12640.93	100.00	
2	(A) Arapa	43	5676.86	16.90	31.93	10729.52	26.16	8790.74	8196.37	24.40	33598.30	99.39	
3	(A) Asillo	22	1859.30	4.61	29.14	11752.20	28.33	11427.85	15294.32	37.92	40333.65	100.00	
4	(A) Azángaro	34	5302.74	7.37	35.37	25460.16	30.42	21898.66	19266.20	26.76	71992.31	99.91	
5	(A) Caminaca	1	0.00	0.00	2.98	350.73	14.72	1734.53	9692.48	82.27	11780.78	99.97	
6	(A) Chupa	22	3976.84	26.18	29.77	4523.57	14.07	2138.17	4103.31	27.01	15193.06	97.03	
7	(A) J. D. Choquehuanca	1	593.19	8.87	14.52	971.32	15.23	1018.82	4105.12	61.38	6688.45	100.00	
8	(A) Muñani	63	9072.94	11.58	37.40	29310.40	29.66	23246.11	16044.23	20.47	78365.85	99.12	
9	(A) Potoni	26	769.65	1.24	10.42	6480.42	54.96	34173.06	19733.06	31.74	62178.91	98.36	
10	(A) Samán	4	72.62	0.36	4.01	816.04	12.56	2555.14	16131.41	79.27	20350.64	96.19	
11	(A) San Antón	47	8849.95	17.17	43.65	22494.31	21.65	11157.35	9027.93	17.52	51529.54	100.00	
12	(A) San José	38	2063.19	5.20	44.04	17484.86	32.58	12932.45	7219.84	18.19	39700.33	100.00	
13	(A) S. J. de Salinas	7	852.70	8.16	14.20	1484.51	19.26	2013.94	6104.31	58.38	10455.45	100.00	
14	(A) S. de Pupuja	13	3724.29	11.69	15.93	5076.80	23.39	7452.39	15613.03	49.00	31866.50	100.00	
15	(A) Tirapata	20	3629.47	18.09	24.11	4835.79	21.23	4259.31	7333.65	36.56	20058.21	100.00	
16	(L) Cabanilla	28	3294.57	8.56	23.83	9168.28	28.66	11026.41	14850.75	38.60	38475.08	99.65	
17	(L) Calapuja	12	2389.26	17.32	17.35	2392.91	11.58	1596.46	7395.66	53.63	13791.24	99.88	
18	(L) Lampa	70	15503.15	23.47	29.88	19735.73	15.77	10412.53	20134.31	30.49	66042.50	99.61	
19	(L) Nicasio	9	676.48	5.08	10.59	1411.08	21.19	2822.07	8409.52	63.14	13319.16	100.00	
20	(L) Ocuvi	18	1953.43	2.22	13.78	12126.55	13.78	12123.44	61492.53	69.90	87978.10	99.68	
21	(L) Palca	25	4600.51	9.30	18.95	9377.68	18.87	9335.52	26166.62	52.88	49480.32	100.00	
22	(L) Paratía	5	0.00	0.00	0.91	678.60	10.15	7588.89	66464.19	88.94	74731.67	100.00	
23	(L) Pucará	53	7429.64	14.14	36.05	18936.75	25.77	13534.09	12627.50	24.04	52527.98	100.00	



N°	Provincia/ Distrito	N° de incendios	Muy alto		Alto		Moderado		Bajo		Área total del distrito	
			ha	%	ha	%	ha	%	ha	%	ha	%
24	(L) Santa Lucía	78	15233.24	9.59	16559.80	10.42	37009.98	23.29	89254.15	56.16	158924.84	99.45
25	(L) Vila Vila	8	1754.27	10.89	3037.38	18.86	3786.79	23.51	7527.37	46.74	16105.80	100.00
26	(M) Antauta	25	5079.00	7.76	11659.26	17.80	14420.65	22.02	33645.79	51.38	65488.37	98.96
27	(M) Ayaviri	122	25508.37	25.08	31103.25	30.59	30313.84	29.81	14765.26	14.52	101690.66	100.00
28	(M) Cupi	48	6952.83	32.09	7971.69	36.80	5179.38	23.91	1442.41	6.66	21663.82	99.46
29	(M) Llalli	25	7429.14	32.47	11006.91	48.11	3605.31	15.76	588.25	2.57	22880.62	98.90
30	(M) Macari	100	15366.44	22.23	22179.89	32.08	17473.60	25.27	13481.06	19.50	69138.39	99.08
31	(M) Nuñoa	123	14359.39	6.52	38991.29	17.72	41274.08	18.75	123839.47	56.27	220079.93	99.27
32	(M) Orurillo	49	7948.67	20.01	13762.85	34.65	11670.74	29.38	6342.84	15.97	39725.10	100.00
33	(M) Santa Rosa	101	15406.46	19.17	26408.69	32.86	18154.58	22.59	20166.97	25.09	80374.62	99.70
34	(M) Umachiri	23	1865.99	5.63	6901.26	20.81	14900.26	44.93	9498.34	28.64	33165.85	100.00

Nota: Provincias: (A) Azángaro; (L) Lampa; (M) Melgar.

ANEXO 3. Distribución de las zonas de riesgo de incendios basadas en el GLM binomial seleccionado. Áreas y porcentajes de superficie para los distritos de las tres provincias de estudio en el departamento de Puno

N°	Provincia/ Distrito	N° de incendios	Muy alto		Alto		Moderado		Bajo		Área total del distrito	
			ha	%	ha	%	ha	%	ha	%	ha	%
1	(A) Achaya	2	0.00	0.00	50.12	0.40	9163.07	72.49	3427.74	27.12	12640.93	100.00
2	(A) Arapa	43	6647.76	19.79	10887.74	32.41	9884.12	29.42	5973.87	17.78	33598.30	99.39
3	(A) Asillo	22	3669.26	9.10	12052.54	29.88	11480.87	28.46	13130.98	32.56	40333.65	100.00
4	(A) Azángaro	34	7778.68	10.80	29008.36	40.29	18039.39	25.06	17101.33	23.75	71992.31	99.91
5	(A) Caminaca	1	0.00	0.00	250.61	2.13	7975.05	67.70	3552.08	30.15	11780.78	99.97
6	(A) Chupa	22	2330.98	15.34	4028.15	26.51	3873.88	25.50	4508.89	29.68	15193.06	97.03
7	(A) J. D. Choquehuana	1	298.03	4.46	1063.31	15.90	3062.53	45.79	2264.58	33.86	6688.45	100.00
8	(A) Muñani	63	7463.71	9.52	27022.56	34.48	19303.42	24.63	23883.98	30.48	78365.85	99.12
9	(A) Potoni	26	0.00	0.00	12208.37	19.63	38687.84	62.22	10259.97	16.50	62178.91	98.36
10	(A) Samán	4	94.72	0.47	656.42	3.23	7328.45	36.01	11495.62	56.49	20350.64	96.19
11	(A) San Antón	47	6896.36	13.38	23325.42	45.27	15491.25	30.06	5816.52	11.29	51529.54	100.00
12	(A) San José	38	2916.26	7.35	16583.70	41.77	11835.96	29.81	8364.41	21.07	39700.33	100.00
13	(A) S. J. de Salinas	7	613.10	5.86	1977.38	18.91	2943.54	28.15	4921.43	47.07	10455.45	100.00
14	(A) S. de Pupuja	13	2354.35	7.39	4494.91	14.11	19530.14	61.29	5487.10	17.22	31866.50	100.00
15	(A) Tirapata	20	1891.63	9.43	6487.17	32.34	7054.51	35.17	4624.90	23.06	20058.21	100.00
16	(L) Cabanilla	28	7392.46	19.21	9069.33	23.57	9764.64	25.38	12113.58	31.48	38475.08	99.65
17	(L) Calapuja	12	2295.32	16.64	2194.45	15.91	5611.54	40.69	3672.99	26.63	13791.24	99.88
18	(L) Lampa	70	8590.42	13.01	21292.03	32.24	18583.49	28.14	17319.80	26.23	66042.50	99.61
19	(L) Nicasio	9	641.41	4.82	1107.53	8.32	7128.30	53.52	4441.92	33.35	13319.16	100.00
20	(L) Ocuvi	18	1211.93	1.38	16968.25	19.29	15205.04	17.28	54310.74	61.73	87978.10	99.68
21	(L) Palca	25	1300.89	2.63	11631.75	23.51	11755.06	23.76	24792.61	50.11	49480.32	100.00
22	(L) Paratía	5	0.00	0.00	84.07	0.11	14972.85	20.04	59674.75	79.85	74731.67	100.00
23	(L) Pucará	53	6799.34	12.94	21098.01	40.17	17665.17	33.63	6965.48	13.26	52527.98	100.00



N°	Provincia/ Distrito	N° de incendios	Muy alto		Alto		Moderado		Bajo		Área total del distrito	
			ha	%	ha	%	ha	%	ha	%	ha	%
24	(L) Santa Lucía	78	8644.31	5.44	31505.32	19.82	47945.49	30.17	69962.05	44.02	158924.84	99.45
25	(L) Vila Vila	8	50.96	0.32	4167.99	25.88	4842.13	30.06	7044.73	43.74	16105.80	100.00
26	(M) Antauta	25	3757.38	5.74	9770.38	14.92	10712.61	16.36	40564.32	61.94	65488.37	98.96
27	(M) Ayaviri	122	17688.19	17.39	40107.56	39.44	33855.91	33.29	10039.02	9.87	101690.66	100.00
28	(M) Cupi	48	4390.52	20.27	8775.91	40.51	4786.57	22.09	3593.33	16.59	21663.82	99.46
29	(M) Llalli	25	4699.37	20.54	12936.73	56.54	4055.02	17.72	938.48	4.10	22880.62	98.90
30	(M) Macari	100	14116.64	20.42	27065.13	39.15	19030.51	27.53	8288.76	11.99	69138.39	99.08
31	(M) Nuñoa	123	10019.54	4.55	56171.22	25.52	47624.66	21.64	104648.84	47.55	220079.93	99.27
32	(M) Orurillo	49	6431.32	16.19	14934.72	37.60	10876.68	27.38	7482.37	18.84	39725.10	100.00
33	(M) Santa Rosa	101	10921.44	13.59	30978.18	38.54	23495.31	29.23	14741.70	18.34	80374.62	99.70
34	(M) Umachiri	23	903.93	2.73	4909.44	14.80	12967.23	39.10	14385.24	43.37	33165.85	100.00

Nota: Provincias: (A) Azángaro; (L) Lampa; (M) Melgar.



ANEXO 4. Constancia de ejecución de proyecto



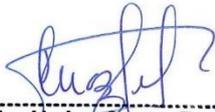
PROYECTO DE INVESTIGACIÓN BÁSICA: Efectos de los incendios y factores ambientales y antrópicos que determinan la ocurrencia y extensión en pastizales altoandinos de importancia ganadera en la región Puno - PE501082076 2023



CONSTANCIA

Yo, IVON ROCIO GUTIERREZ FLORES, responsable técnico del proyecto "Efectos de los incendios y factores ambientales y antrópicos que determinan la ocurrencia y extensión en pastizales altoandinos de importancia ganadera en la región Puno - PE501082076 2023", financiado por el CONCYTEC, identificado con DNI 45818801, hago constar que la **Bachiller Ángela Mercado Palza**, ha ejecutado las actividades inherentes a su tesis titulada: Factores climáticos, topográficos, antrópicos y de combustibilidad que determinan la ocurrencia y la extensión de incendios en pastizales altoandinos del departamento d Puno" por el periodo de seis meses, desde agosto del 2023 a enero del 2024. La ejecución de sus tesis implicó la evaluación de 23 incendios ocurridos en las provincias Melgar, Azángaro y Lampa, para posteriormente analizar los datos en los laboratorios de Ecología Acuática de la Facultad de Ciencias Biológicas y laboratorio de suelo y agua de la Facultad de Agronomía.

Firmo la presente constancia a los 25 días de julio del 2024.



Bfga. Mg. Ivon Gutierrez Flores
DOCENTE - FCCBB
UNA - PUNO

ANEXO 5. Resolución Administrativa N° D000087-2023-MIDAGRI-SERFOR-ATFFS-PUNO



Firmado digitalmente por IDME
HANARI Grover FAU 20562836927
soft
Cargo: Administrador Técnico Ffs (E)
Motivo: Soy el autor del documento
Fecha: 04.07.2023 18:51:34 -05:00

RESOLUCIÓN ADMINISTRATIVA

Puno, 04 de Julio del 2023

RA N° D000087-2023-MIDAGRI-SERFOR-ATFFS-PUNO

VISTO:

El Informe Técnico N° D000014-2023-MIDAGRI-SERFOR-ATFFS-PUNO-YPM de evaluación de autorización con fines de investigación científica presentada por la administrada la señora IVON ROCIO GUTIERREZ FLORES identificada con DNI N° 45818801, y,

CONSIDERANDO:

- Que, el artículo 66° de la Constitución Política del Perú, establece que los recursos naturales, renovables y no renovables, son patrimonio de la Nación. El Estado es soberano en su aprovechamiento; asimismo, en su artículo 68° establece que es obligación del Estado promover la conservación de la diversidad biológica;
- Que, la Ley N° 26821, Ley Orgánica para el Aprovechamiento Sostenible de los Recursos Naturales, establece en su artículo 9°, referido a la investigación científica, que el Estado promueve la investigación científica y tecnológica sobre la diversidad, calidad, composición, potencialidad y gestión de los recursos naturales. Asimismo, promueve la información y el conocimiento sobre los recursos naturales. Para estos efectos, podrán otorgarse permisos para investigación en materia de recursos naturales;
- Que, el artículo 13° de la Ley N° 29763, crea el Servicio Nacional Forestal y de Fauna Silvestre-SERFOR, como organismo público técnico especializado, con personería jurídica de derecho público interno, como pliego presupuestal adscrito al Ministerio de Agricultura y Riego. Asimismo, se señala que el SERFOR es la autoridad nacional forestal y de fauna silvestre, ente rector del Sistema Nacional de Gestión Forestal y de Fauna Silvestre (SINAFOR), y se constituye en su autoridad técnico normativa a nivel nacional, encargada de dictar las normas y establecer los procedimientos relacionados a su ámbito;
- Que, mediante Decreto Supremo N° 007-2013-MINAGRI del 18 de julio del 2013, y modificado por Decreto Supremo N° 016-2014-MINAGRI del 03 de setiembre del 2014, aprobó el Reglamento de Organización y Funciones - ROF del Servicio Nacional Forestal y de Fauna Silvestre - SERFOR, el mismo que en la parte de disposiciones complementarias transitorias señala que las administraciones técnicas forestales y de fauna silvestre se incorporan al SERFOR, como órganos desconcentrados de actuación local del SERFOR, ejerciendo una de las funciones de las Administraciones Técnicas Forestales y de Fauna Silvestre, la de actuar como primera instancia en la gestión y administración de los recursos forestales y de fauna silvestre, dentro del ámbito territorial de su competencia; y acorde a las atribuciones reconocidas;
- Que, mediante Resolución de Dirección Ejecutiva N° 060-2016-SERFOR/DE, se aprueba los "Lineamientos para el otorgamiento de la autorización con fines de investigación científica de flora y/o fauna silvestre";
- Que, mediante Decreto Supremo N° 018-2015-MINAGRI, vigente desde 01 de octubre de 2015, se aprobó el Reglamento para la Gestión Forestal, el mismo que en el artículo 154°, menciona que la investigación científica del Patrimonio se aprueba mediante autorizaciones, salvaguardando los derechos del país, respecto a su patrimonio genético nativo, así mismo, las ARFFS otorgan autorizaciones con fines de investigación científica, que impliquen la utilización de métodos directos e indirectos para especies no categorizadas como amenazadas, no listadas en los apéndices CITES y que en ningún caso otorgue el acceso a los recursos genéticos o sus productos derivados, de acuerdo a los lineamientos

Esta es una copia auténtica imprimible de un documento electrónico archivado en el Servicio Forestal y de Fauna Silvestre, aplicando lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. 026-2016-PCM. Su autenticidad e integridad pueden ser contrastadas a través de la siguiente dirección web: Url: <https://sgd.serfor.gob.pe/validadorDocumental/> Clave: OLF8MGK



RESOLUCIÓN ADMINISTRATIVA

aprobados por el SERFOR para la evaluación para las solicitudes, así como los criterios para la verificación del cumplimiento de los compromisos de los investigadores;

- Que, mediante solicitud de fecha 06 de junio de 2023, la administrada la señora IVON ROCIO GUTIERREZ FLORES, investigadora, solicita autorización con fines de investigación científica de flora silvestre fuera de áreas naturales protegidas, para el proyecto denominado: "*Efectos de los incendios y factores ambientales y antrópicos que determinan su ocurrencia y extensión en pastizales altoandinos de importancia ganadera en la región de Puno*" siendo el objeto evaluar el efecto de los incendios de pastizales en la vegetación, los sitios de estudios estarán en función al lugar en el que ocurran los incendios en el año 2023 y en el año 2024, por lo que es responsabilidad del investigados contar con los permisos de los titulares de los predios a fin de que cuente con el acceso correspondiente;
- Que, el Informe Técnico N° D000014-2023-MIDAGRI-SERFOR-ATFFS-PUNO-YPM, señala que la solicitud materia de resolución cumple todos los requisitos establecidos en los lineamientos para el otorgamiento de la autorización con fines de investigación de flora y/o fauna silvestre, aprobado por Resolución de Dirección Ejecutiva N° 060-2016-SERFOR/DE.
- Adicional a ello precisa que la investigación de flora silvestre prevé la colecta de ejemplares enteros para la determinación taxonómica y (bio)masa seca para la determinación de la carga de combustible;
- Que, de conformidad con la Ley Forestal y de Fauna Silvestre Ley N° 29763; el Reglamento para la Gestión de Fauna Silvestre aprobado mediante Decreto Supremo N° 019-2015-MINAGRI, TUO de la Ley N° 27444 Ley del Procedimiento Administrativo General, y el Reglamento de Organización y Funciones del Servicio Nacional Forestal y de Fauna Silvestre, aprobado por Decreto Supremo N° 007-2013-MINAGRI, modificado por el Decreto Supremo N° 016-2014-MINAGRI, y en uso de sus atribuciones conferidas por la presente disposición.

SE RESUELVE:

Artículo 1°.- Otorgar la autorización con fines de investigación científica de flora silvestre fuera de las Áreas Naturales Protegidas, con colecta de ejemplares conforme especifica el Informe Técnico N° D000014-2023-MIDAGRI-SERFOR-ATFFS-PUNO-YPM, que es parte integrante de la presente resolución, a favor de la administrada la señora IVON ROCIO GUTIERREZ FLORES identificada con DNI N° 45818801, correspondiéndole el siguiente Código de Autorización **21-PUN/AUT-IFL-2023-002**.

Artículo 2°.- El proyecto titulado "*Efectos de los incendios y factores ambientales y antrópicos que determinan su ocurrencia y extensión en pastizales altoandinos de importancia ganadera en la región de Puno*", a realizarse en el año 2023 y 2024 por un periodo de 18 meses en el departamento de Puno, conforme al plan de investigación, participaran los siguientes investigadores.

NOMBRE	FUNCION	NACIONALIDAD	DOC	DNI N°
IVON ROCIO GUTIERREZ FLORES	Investigador principal	Peruana	DNI	45818801
ERNESTO JAVIER CHURA YUPANQUI	Co-investigador	Peruano	DNI	01204009

Artículo 3°.- El titular de la autorización tiene las siguientes obligaciones:

- a) Colectar únicamente las muestras autorizadas.
- b) No ceder el material colectado a terceros, ni utilizarlo para fines distintos a lo autorizado.

Esta es una copia auténtica imprimible de un documento electrónico archivado en el Servicio Forestal y de Fauna Silvestre, aplicando lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. 026-2016-PCM. Su autenticidad e integridad pueden ser contrastadas a través de la siguiente dirección web: Url: <https://sgd.serfor.gob.pe/validadorDocumental/> Clave: OLF8MGK



RESOLUCIÓN ADMINISTRATIVA

- c) Si por razones científicas acotadas, se requiere enviar al extranjero parte del material colectado, los interesados deberán gestionar el correspondiente Permiso para la Exportación ante la Dirección General de Gestión Sostenible del Patrimonio Forestal y de Fauna Silvestre del SERFOR, así como pasar el control respectivo.
- d) No contactar, ni ingresar a los territorios comunales sin contar con la autorización de las autoridades comunales correspondientes.
- e) Entregar a la Administración Técnica Forestal y de Fauna Silvestre de Puno una (01) copia del Informe Parcial anual (incluyendo versión digital), al término de cada año, contado a partir de la emisión de la presente autorización. Asimismo, entregar una (01) copia de las publicaciones producto de la investigación realizada en formato impreso y digital.
- f) Entregar a la Administración Técnica Forestal y de Fauna Silvestre de Puno, una (01) copia del Informe Final (incluyendo versión digital) como resultado de la autorización otorgada, copias del material fotográfico y/o slides que puedan ser utilizadas para difusión. Asimismo, entregar una (01) copia de las publicaciones producto de la investigación realizada en formato impreso y digital.
- g) Los Informes Parciales y Final deberán contener una lista taxonómica de las especies de fauna colectadas o registradas bajo la presente autorización, en formato MS Excel. Esta lista deberá contar con sus respectivas coordenadas en formato UTM (Datum WGS84), incluyendo la zona (17, 18 ó 19). El formato de Informe Parcial y Final que debe ser usado se encuentra en el Anexo 1 de la presente resolución.
- h) La entrega de lo indicado en el literal e), no deberá exceder los seis (06) meses luego de terminado cada año de la autorización; y en el caso del literal f) no deberá ser mayor a los seis (06) meses al vencimiento de la presente autorización
- i) Indicar el número de la Resolución en las publicaciones generadas a partir de la autorización concedida.
- j) Solicitar anticipadamente al SERFOR o ARFFS y dentro del plazo de vigencia de la autorización, cualquier cambio en las características del proyecto (p. ej. Cronograma, especialistas, puntos de muestreo, etc) que demanden la modificación de la presente Resolución.

Artículo 4º.- El investigador/a deberá tener en consideración el bienestar animal y flora en la colecta de especímenes de ser el caso.

Artículo 5º.- La Administración Técnica Forestal y de Fauna Silvestre del SERFOR, no se responsabiliza por accidentes o daños sufridos por la o el solicitante de esta autorización, durante la ejecución del proyecto; asimismo, se reserva el derecho de demandar del proyecto de investigación los cambios a que hubiese lugar en los casos en que se formulen ajustes sobre la presente autorización.

Artículo 6º.- Notificar la presente Resolución Administrativa que autoriza la investigación a la administrada IVON ROCIO GUTIERREZ FLORES, a la Dirección General de Información y Ordenamiento Forestal y de Fauna Silvestre, a la Dirección General de Gestión Sostenible del Patrimonio Forestal y de Fauna Silvestre, y a la Policía Nacional del Perú.

Artículo 7º.- Disponer la publicación de la presente Resolución en el Portal Web del Servicio Nacional Forestal y de Fauna Silvestre: www.serfor.gob.pe.

Regístrese, comuníquese.

Firmado Digitalmente

Blgo. GROVER IDME HAÑARI
Administrador Técnico (e)
Forestal y de Fauna Silvestre de Puno
Servicio Nacional Forestal y de Fauna Silvestre – SERFOR

Esta es una copia auténtica imprimible de un documento electrónico archivado en el Servicio Forestal y de Fauna Silvestre, aplicando lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. 026-2016-PCM. Su autenticidad e integridad pueden ser contrastadas a través de la siguiente dirección web: Url: <https://sgd.serfor.gob.pe/validadorDocumental/> Clave: OLF8MGK



RESOLUCIÓN ADMINISTRATIVA

ANEXO 1

FORMATO DE INFORME PARCIAL Y/O FINAL DE INVESTIGACION

Cada año, y una vez culminada la investigación autorizada, el investigador responsable deberá revisar el cumplimiento de las obligaciones indicadas en su autorización, teniendo en cuenta lo siguiente:

- 1) Entregar a la ATFFS del SERFOR una (01) copia del informe parcial o final en idioma español, como resultado de la autorización otorgada, en formato impreso y soporte digital (CD), para ello adjunto el formato de informe a presentar:

a.	Título del Proyecto.
b.	Área estudiada (indicando coordenadas geográficas para todas las zonas de colecta, en formato UTM (Datum WGS84), incluyendo la zona (17, 18 ó 19). Dicha información deberá ser presentada en un cuadro en formato excel).
c.	Nº de Autorización.
d.	Autores.
e.	Institución.
f.	Resumen para ser publicado en la web del SERFOR (donde se deberá señalar los resultados y la relevancia de lo encontrado en forma sintetizada)
g.	Marco teórico.
h.	Material y Métodos.
i.	Resultados.
j.	Discusión.
k.	Conclusiones.
l.	Bibliografía.
m.	Anexos

- 2) Entregar copias del material fotográfico y/o slides que puedan ser utilizadas para difusión institucional no comercial.
- 3) Entregar copia de la(s) publicación(es), producto de la investigación realizada en formato impreso y digital, o de lo contrario señalar que no cuenta con publicación alguna en la remisión de su carta.
- 4) Presentar la lista taxonómica de las especies de fauna y/o flora encontradas en las zonas evaluadas con las respectivas coordenadas formato UTM (Datum WGS84), incluyendo la zona (17, 18 ó 19). Dicha información deberá ser presentada en un cuadro en formato Excel.
- 5) Además, se deberá adjuntar copias de los permisos de exportación otorgados (para el caso de autorización con colecta).

Esta es una copia auténtica imprimible de un documento electrónico archivado en el Servicio Forestal y de Fauna Silvestre, aplicando lo dispuesto por el Art. 25 de D.S. 070-2013-PCM y la Tercera Disposición Complementaria Final del D.S. 026-2016-PCM. Su autenticidad e integridad pueden ser contrastadas a través de la siguiente dirección web: Url: <https://sgd.serfor.gob.pe/validadorDocumental/> Clave: OLF8MGK



ANEXO 6. Autorización para el depósito de tesis en el Repositorio Institucional



Universidad Nacional
del Altiplano Puno



Vicerrectorado
de Investigación



Repositorio
Institucional

AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo Angela Mercado Palza,
identificado con DNI 71135569 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

de Biología,
informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

“ Factores climáticos, topográficos, antropicos y de combustibilidad que determinan la ocurrencia y extensión de incendios en pastizales altoandinos del departamento de Puno ”

para la obtención de Grado, Título Profesional o Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los “Contenidos”) que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno 21 de agosto del 2024

FIRMA (obligatoria)



Huella



ANEXO 7. Declaración jurada de autenticidad de tesis



Universidad Nacional
del Altiplano Puno



Vicerrectorado
de Investigación



Repositorio
Institucional

DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo Angela Mercado Palza,
identificado con DNI 71135569 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado
de Biología

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

“ Factores climáticos, topográficos, antrópicos y de combustibilidad que determinan
la ocurrencia y extensión de incendios en pastizales altoandinos del departamento
de Puno ”

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y **no existe plagio/copia** de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno 21 de agosto del 2024

FIRMA (obligatoria)



Huella