

PROBABILIDAD DE OCURRENCIA DE INCENDIOS FORESTALES EN APURÍMAC

PROBABILITY OF OCCURRENCE OF FOREST FIRES IN APURÍMAC

Nilton B. Rojas-Briceño¹  Carolina Soto Carrión¹  Shirley Tuesta-Mendoza² 
Jhonsy O. Silva-López²  Gregorio Sáenz Pohl³ 

¹Universidad Tecnológica de los Andes-Abancay-Perú

²Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas-Chachapoyas- Perú

³Universidad Nacional Santiago Antúnez de Mayolo- Huaraz-Perú

Correspondencia:

Nilton B. Rojas-Briceño
nrojasb@utea.edu.pe

Como citar este artículo:

Rojas, N., Soto, C., Tuesta, S., Silva, J., & Sáenz, G. (2023). Probabilidad de ocurrencia de incendios forestales en Apurímac. *Hatun Yachay Wasi*, 2 (2), 85–97. <https://doi.org/10.57107/hyw.v2i2.49>

RESUMEN

Los incendios forestales son una inquietud global debido a su impacto negativo en los ecosistemas y la vida que albergan. En Perú, entre 2013 y 2017, se quemaron aproximadamente 200 mil hectáreas, siendo la región de Apurímac una de las más afectadas. El objetivo de este estudio fue desarrollar un mapa de probabilidad de incendios forestales, basándose en 1312 registros recopilados entre 2003 y 2022, utilizando Sistemas de Información Geográfica (SIG) y algoritmo de aprendizaje automático MaxEnt. Se usaron 17 variables ambientales predictoras (11 climáticas, dos orográficas y cuatro relacionadas con la actividad humana), seleccionadas estadísticamente de un total de 31 variables. La capacidad predictiva del modelo fue 'buena', con Área Bajo la Curva de 0.819. 5,4 % (1134.2 km²) y 15 % (3171.54 km²) de la superficie de Apurímac, principalmente en el norte, presentan 'muy alta' y 'alta' probabilidad de ocurrencia de incendios forestales, respectivamente. Los ecosistemas de matorral andino (561.25 km²), zona agrícola (277.01 km²) y pajonal de puna húmeda (230.37 km²) presentan las mayores superficies con probabilidad 'muy alta' de ocurrencia de incendios forestales. Los SIG y MaxEnt son herramientas útiles e importantes en la toma de decisiones preventivas y de lucha contra los incendios forestales.

Palabras clave: ecosistemas, MaxEnt, ocurrencia, incendios forestales, mapa de predicción

ABSTRACT

Forest fires are a global concern due to their negative impact on ecosystems and the life they harbor. In Peru, between 2013 and 2017, approximately 200,000 hectares burned, with the Apurímac region being one of the most affected. The aim of this study was to develop a wildfire probability map, based on 1312 records collected between 2003 and 2022, using Geographic Information Systems (GIS) and MaxEnt machine learning algorithm. 17 predictor environmental variables were used (11 climatic, two orographic and four related to human activity), statistically selected from a total of 31 variables. The predictive capacity of the



model was 'good', with an Area Under the Curve of 0.819. 5.4 % (1134.2 km²) and 15 % (3171.54 km²) of the surface of Apurímac, mainly in the north, present a 'very high' and 'high' probability of occurrence of forest fires, respectively. The ecosystems of Andean scrub (561.25 km²), agricultural zone (277.01 km²) and humid puna grassland (230.37 km²) present the largest areas with 'very high' probability of occurrence of forest fires. GIS and MaxEnt are useful and important tools in making preventive decisions and fighting forest fires.

Key words: ecosystems, MaxEnt, occurrence, forest fires, prediction map

INTRODUCCIÓN

El incendio forestal es una amenaza y un desafío constante para el manejo forestal en todo el mundo, y los ecosistemas amazónicos y andinos no son la excepción (Zubieta et al., 2021). Entre 2013 y 2017, el fuego forestal quemó severamente casi 200 000 ha en las regiones de los Andes y Amazonía del Perú, siendo Apurímac una de las regiones más afectadas (SERFOR, 2018). Por tanto, el pronóstico científico y el monitoreo de los incendios forestales son de gran importancia práctica para apoyar los esfuerzos para frenar la ocurrencia y reducir las pérdidas por incendios forestales. Como parte de la evaluación del riesgo de incendios forestales, los estudios de zonificación proporcionan una base científica importante, para construir sistemas de defensa contra riesgos de incendios forestales, desplegar fuerzas de prevención y guiar el trabajo de prevención (Yang et al., 2021).

Los Sistemas de Información Geográfica (SIG) y los métodos modernos de Teledetección son un medio popular y efectivo, para identificar los factores más importantes que afectan los incendios (Janiec & Gadal, 2020). Se han realizado varios estudios previos de modelado del riesgo a incendios forestales en diferentes partes del mundo (Banerjee, 2021; Janiec & Gadal, 2020; Mishra et al., 2023; Renard et al., 2012; Tariq et al., 2022; Usmadi, 2023; Yang et al., 2021). En Perú, estudios previos usaron el enfoque de lógica difusa (Anticona et al., 2023) o el algoritmo AdaBoost (Bax, 2018), para identificar zonas de elevada probabilidad de ocurrencia de incendios, basados en variables ambientales en un

entorno de Sistemas de Información Geográfica (GIS). Sin embargo, dado su enfoque de modelado, no utilizaron registros históricos de ocurrencias de incendios.

Este estudio tuvo por objetivo modelar la probabilidad de ocurrencia de incendios en Apurímac. Para lo cual, se identificaron los registros históricos de incendios y las variables ambientales que pueden predecir la ocurrencia de incendios generándose mapas de las variables, para reducir su colinealidad, creándose el modelo de probabilidad, utilizando el algoritmo de aprendizaje automático (MaxEnt) (Phillips et al., 2006).

MATERIAL Y MÉTODOS

Obtención de ocurrencias de incendios

Se empleó data histórica (octubre de 2003 a enero de 2022) del servicio de Monitoreo de las Condiciones Favorables para la Ocurrencia de Incendios – CFOI. (Ministerio del Ambiente [MINAM], 2019).

Se registraron 1312 ocurrencias de incendios, los cuales se evaluaron mediante imágenes satelital de sensor Landsat, registro en campo por el COEN INDECI y Policía Nacional.

Identificación de variables predictoras

La identificación de variables ambientales que favorecen/condicionan la ocurrencia de incendios se basó en la revisión de estudios previos de modelado (Banerjee, 2021; Janiec & Gadal, 2020; Mishra et al., 2023; Renard et al., 2012; Tariq et

al., 2022; Usmadi, 2023; Yang et al., 2021). La disponibilidad de datos espaciales de las variables también fue considerada. Se identificaron 24 variables de clima, tres de orografía y cuatro de actividad humana (Tabla 1).

Tabla 1

Variables ambientales para modelar probabilidad de ocurrencia de incendios forestales.

Categoría	Variable	Abreviatura	Unidad
Clima	Temperatura media anual	bio01	°C
	Bioclimáticas derivadas de temperatura (10)	bio02 – bio11	
	Precipitación anual	bio12	mm
	Bioclimáticas derivadas de precipitación (7)	bio13 – bio19	
	Temperatura máxima media anual	tmax	°C
	Temperatura mínima media anual	tmin	°C
	Velocidad del viento	viento	m s ⁻¹
	Humedad relativa	humedad	%
	Radiación solar	rsolar	kJ m ⁻² day ⁻¹
	Orografía	Elevación	elevación
Pendiente del terreno		pendiente	°
Aspecto (orientación cardinal)		aspecto	°
Actividad humana	Distancia a poblaciones	dpob	m
	Distancia a la red vial	dvias	m
	Distancia a área agrícola	dagro	m
	Distancia a fuentes de agua	dagua	m

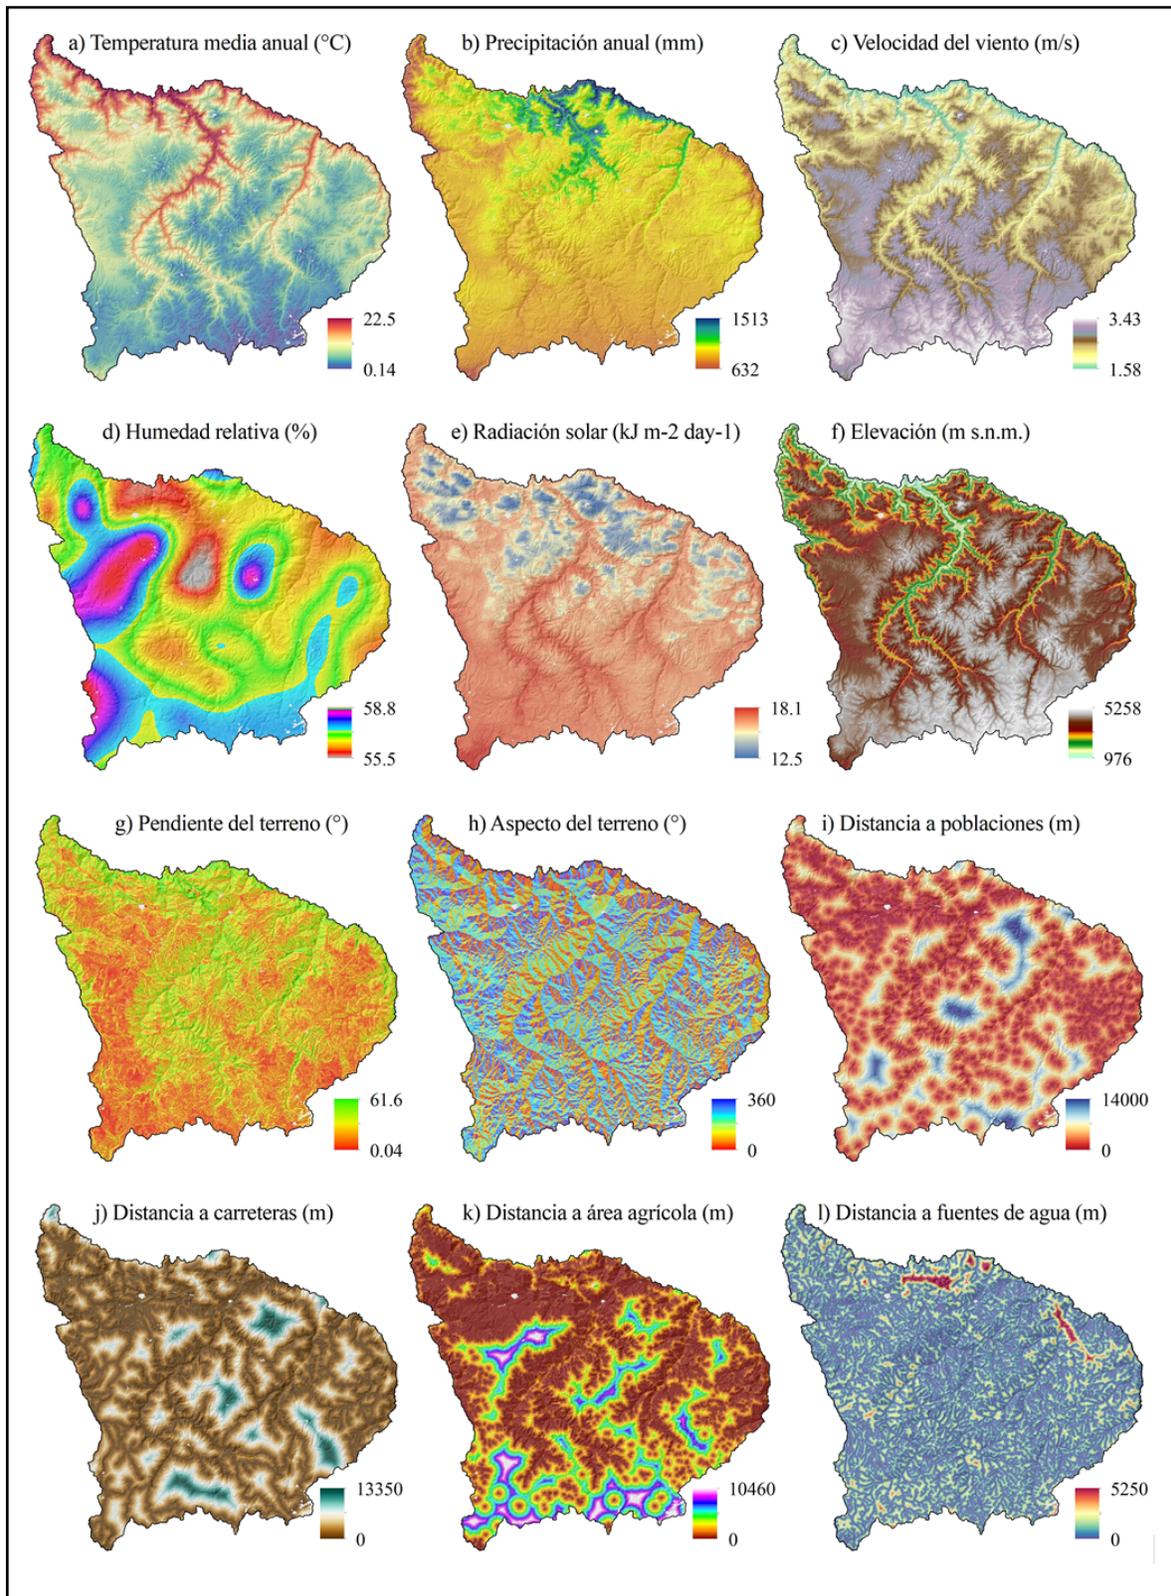
Mapeo de variables

Las capas climáticas (excepto humedad relativa) se obtuvieron de WorldClim 2.1 (Fig.1) (Fick & Hijmans, 2017). Las variables orográficas se derivaron del Modelo de Elevación Digital del CGIAR (*Consortium for Spatial Information*), el cual ha sido generado con datos de la *Shuttle Radar Topography Mission* (Farr et al., 2007).

La humedad relativa fue obtenida de Rojas et al. (2022), quién procesó datos puntuales de la Unidad de Investigación Climática [*Climatic Research Unit*] (New et al., 2002)

FIGURA 1

Variables ambientales para modelar probabilidad de ocurrencia de incendios forestales.



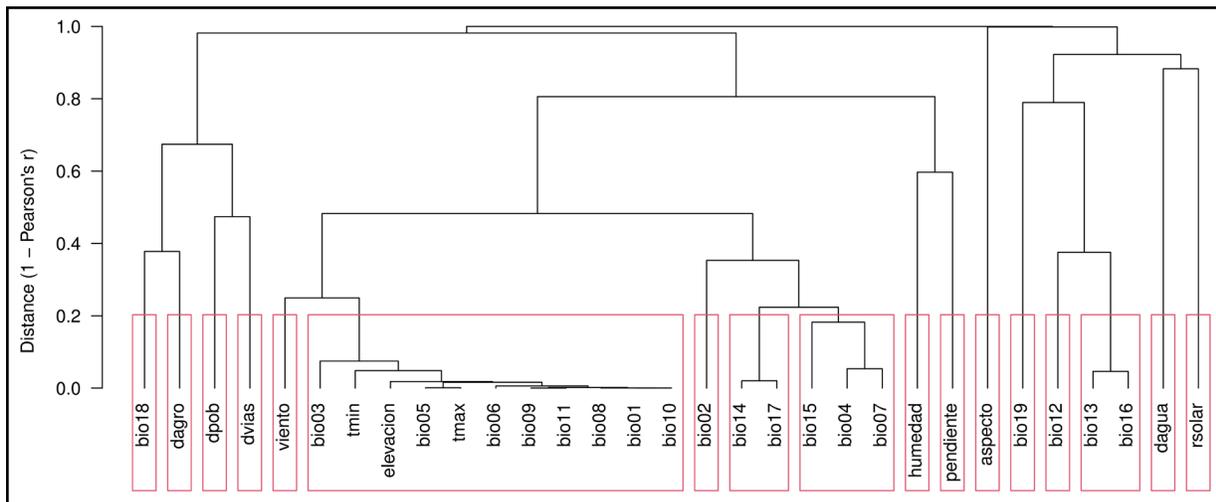
Los centros poblados (puntos) se obtuvieron del Ministerio de Educación (MINEDU, 2020). La zona urbana y agrícola se obtuvo del Esri 2022 Land Cover (ESRI, 2022) y Mapa Nacional de Ecosistemas del Perú (MINAM, 2019). Además, la zona agrícola fue complementada con el Ministerio de Desarrollo Agrario y Riego (MIDAGRI., 2020). Se utilizaron tres categorías de red vial (nacional–eje, departamental y vecinal) obtenidas del Ministerio de Transportes y Comunicaciones (MTC, 2018). Los ríos y lagos de 15 Cartas Nacionales del Instituto Geográfico Nacional se descargaron del MINEDU (2020) y se ensamblaron; luego, las distancias a carreteras, ríos, poblaciones y áreas agrícolas se calcularon utilizando Distancia Euclidiana (ArcGIS 10.5).

Selección de variables ambientales

La colinealidad entre variables disminuye el poder estadístico del modelamiento, causa problemas de sobreajuste y aumenta la incertidumbre (Dormann et al., 2013). Por tanto, se utilizó la función ‘removeCollinearity’ del paquete ‘virtualspecies’ (Leroy et al., 2016) en R 3.6, para agrupar las variables según un umbral de correlación de Pearson $r \geq 0.8$ (Fig. 2). Esta es una medida aceptable para minimizar la multicolinealidad de los modelos ajustados (Dormann et al., 2013). Para seleccionar una variable por cada clúster jerárquico, se ejecutó un modelo MaxEnt preliminar utilizando todas las variables y se seleccionó la variable con mejor comportamiento en la prueba Jackknife (Meza et al., 2020).

FIGURA 2

Clúster jerárquico de variables intercorrelacionadas en el punto de corte 0.8



Generación del modelo

El modelo de probabilidad de ocurrencia de incendios se generó mediante MaxEnt 3.4.4 (Phillips et al., 2006). El 75 % y 25 % de los registros georreferenciados (seleccionados al azar) se utilizaron para el entrenamiento y la validación de cada modelo, respectivamente (Phillips et al., 2006). El algoritmo se ejecutó utilizando

10 réplicas en 1000 iteraciones con diferentes particiones aleatorias (método Bootstrap), un umbral de convergencia de 0.00001 y 10000 puntos de fondo máximos (Rojas-Briceño et al., 2020). El modelo se evaluó según cinco niveles de rendimiento del Área Bajo la Curva (AUC: excelente (>0.9), bueno (0.8–0.9), aceptado (0.7–0.8), malo

(0.6–0.7) e inválido (<0.6) (Araujo et al., 2005). El formato de salida Cloglog del modelo generó un mapa de valores de probabilidad continua de ocurrencia de incendios que van de 0 a 1 (Phillips & Dudík, 2008). Estos se reclasificaron en cuatro niveles de probabilidad: ‘muy alta’ (>0.8), ‘alta’ (0.6–0.8), ‘moderada’ (0.4–0.6), ‘baja’ (0.2–0.4) y ‘muy baja’ (<0.2) (Tariq et al., 2022).

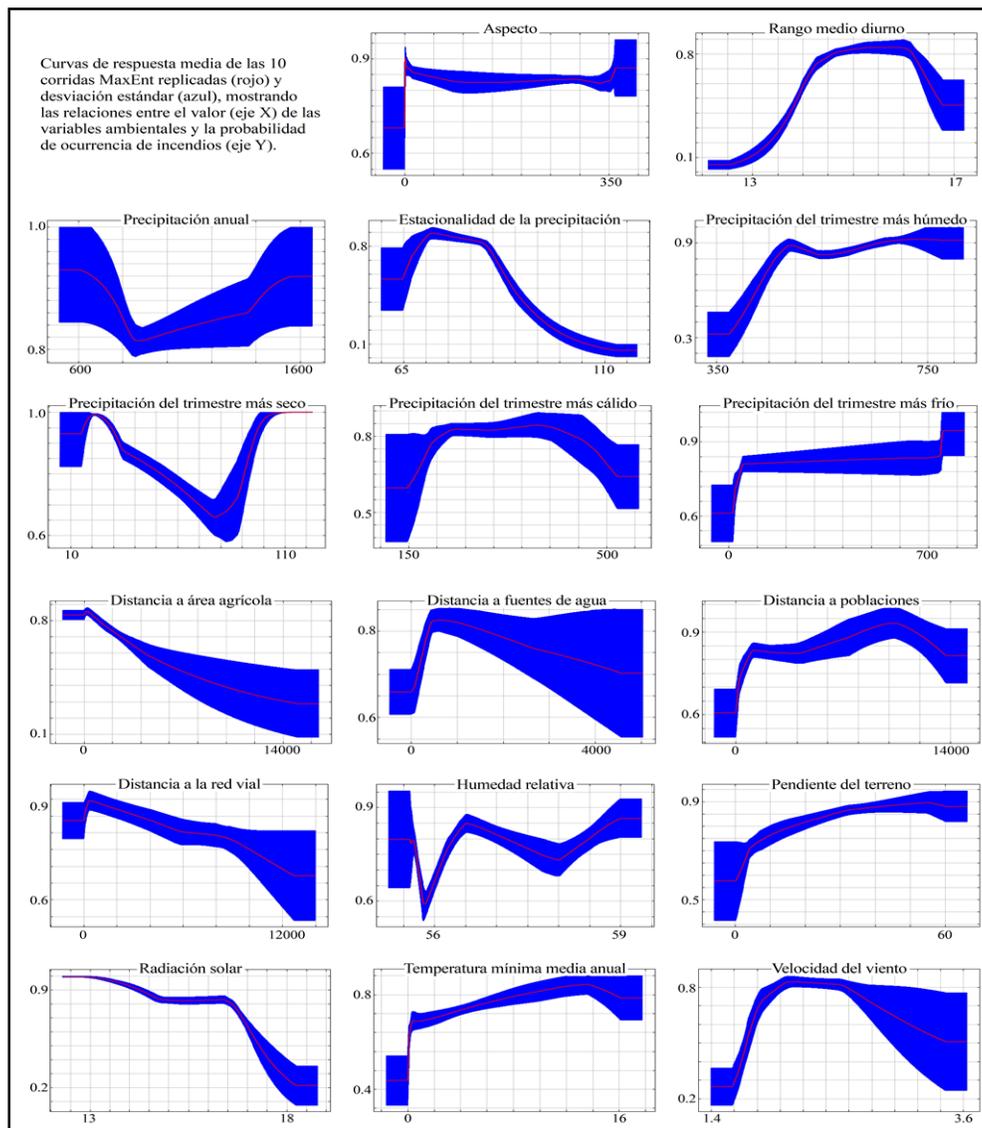
seleccionaron 17 para generar el modelo de probabilidad de ocurrencia de incendios. Estas variables incluyen 11 variables de clima (seis son derivadas de la precipitación), dos de orografía (pendiente y aspecto del terreno) y las cuatro de actividad humana (distancia a poblaciones, cuerpos de agua, vías y área agrícola). Las curvas de respuesta muestran cómo cambia la probabilidad prevista de ocurrencia de incendios a medida que varía cada variable ambiental, manteniendo todas las demás variables ambientales en su valor de muestra promedio (Fig. 3).

RESULTADOS

Comportamiento de variables

De las 31 variables de entrada (Tabla 1), se

FIGURA 3
Curvas de respuesta de variables



Las variables ambientales presentaron tendencias más claras (menor desviación estándar). La probabilidad de incendios disminuye cuando el territorio se encuentra lejos de un cuerpo de agua, vía o áreas agrícolas, pero aumenta en zonas lejanas a poblaciones. A mayor pendiente, mayor probabilidad de incendios.

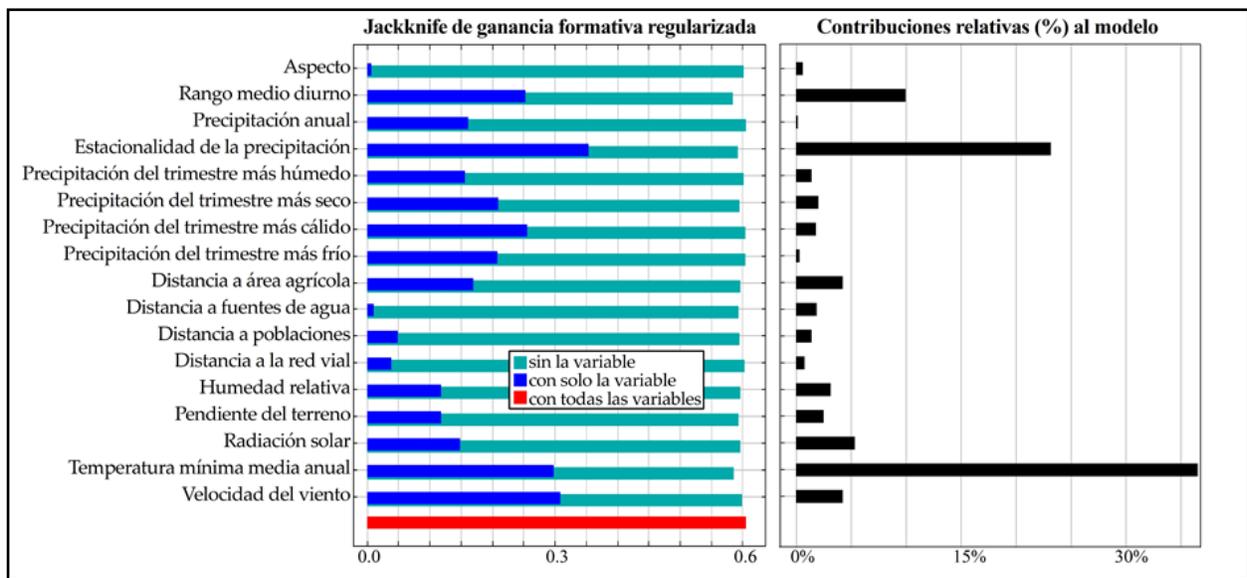
La prueba Jackknife de importancia variable indique que la variable ambiental con mayor ganancia cuando se usa aisladamente es la Estacionalidad de la precipitación, que por lo tanto parece tener la información más útil por sí sola (Fig. 4). La variable

ambiental que más disminuye la ganancia cuando se omite es Rango medio diurno (media mensual (temp. máx. - temp. mín.)), que por lo tanto parece tener la mayor cantidad de información que no está presente en las otras variables.

Se encontró que el 75.6 % de la probabilidad de ocurrencia de incendios está impulsada por cuatro variables ambientales, es decir, temperatura mínima media anual (37,4 %), estacionalidad de la precipitación (23 %), rango medio diurno (9,9 %) y radiación solar (5,3 %). La contribución de las demás variables es menor a 4,2 % (Fig.4).

FIGURA 4

Prueba Jackknife de importancia variable y contribución de variables al modelo.



Mapa de probabilidad de ocurrencia de incendios

El AUC de entrenamiento promedio para las 10 ejecuciones replicadas del modelado fue 0.819 y desviación estándar de 0.005, indicando un ‘buen’ (0.8–0.9) rendimiento predictivo.

La Figura 5 muestra el mapa de probabilidad continua (de 0 a 1) y el mapa de niveles de probabilidad de ocurrencia de incendios, en Apurímac. Se observa que, el norte de la región presenta elevadas probabilidades de incendios. El 5.4 % (1134.20

km²) y 15 % (3171.54 km²) del territorio presenta probabilidad ‘Muy alta’ y ‘Alta’, respectivamente, para la ocurrencia de incendios (Tabla 2).

A nivel de provincias, Abancay (656.30 km²) y Andahuaylas (339.10 km²) presentan las mayores superficies con probabilidad ‘Muy alta’, mientras que Aymaraes (14.64 km²) y Grau (12.55 km²) presentan las menores áreas. Antabamba no presenta probabilidades ‘Muy alta’ y ‘Alta’.

FIGURA 5

Mapas de probabilidad de ocurrencia de incendios en los ecosistemas de Apurímac, según provincias

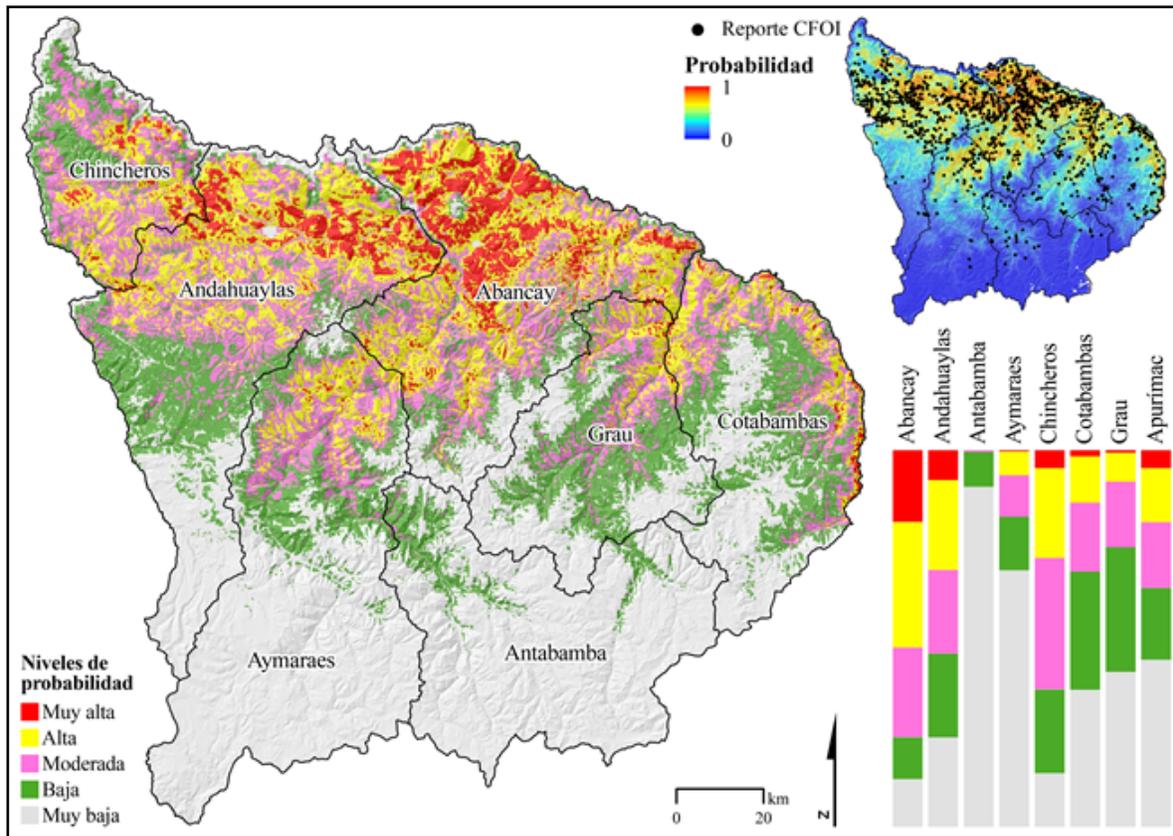


TABLA 2

Área de probabilidad de ocurrencia de incendios de Apurímac, según provincias

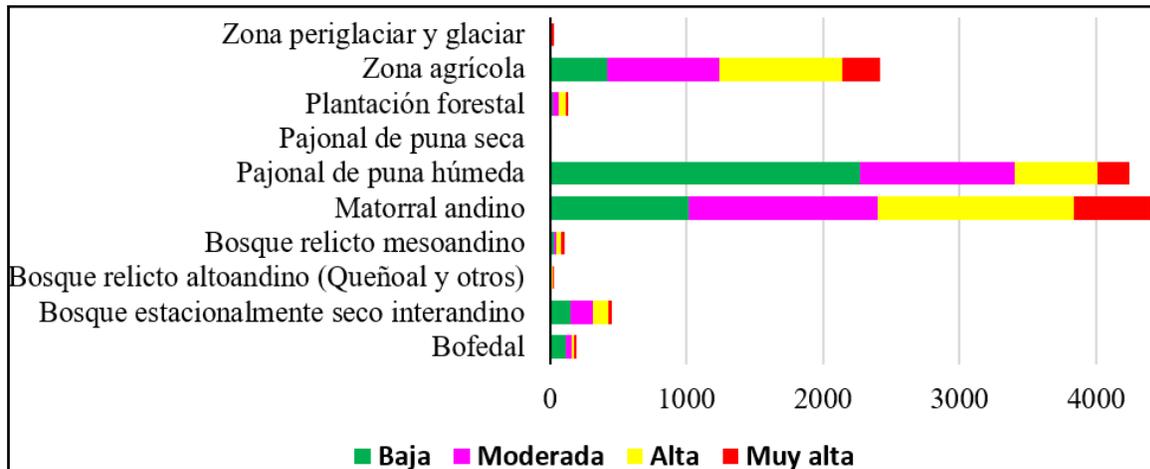
Provincias	Muy alta		Alta		Moderada		Baja		Muy baja	
	km ²	%	km ²	%	km ²	%	km ²	%	km ²	%
Abancay	656.30	19.0	1153.27	33.3	822.04	23.8	396.07	11.5	430.58	12.5
Andahuaylas	339.10	8.4	936.08	23.2	916.59	22.7	893.43	22.1	950.33	23.5
Antabamba	0.00	0.0	0.00	0.0	13.89	0.4	293.24	9.1	2923.66	90.5
Aymaraes	14.64	0.4	257.82	6.2	470.53	11.4	582.49	14.1	2803.15	67.9
Chincheros	73.96	4.9	353.93	23.5	535.39	35.5	337.22	22.4	207.37	13.8
Cotabambas	37.63	1.4	314.11	12.0	496.55	18.9	817.99	31.2	956.79	36.5
Grau	12.55	0.6	156.32	7.3	371.98	17.5	718.72	33.7	870.39	40.9
Apurímac	1134.20	5.4	3171.54	15.0	3626.97	17.2	4039.16	19.1	9142.27	43.3

La Figura 6 muestra la superficie de probabilidad de ocurrencia de incendios de Apurímac, según ecosistemas: matorral andino (561.25 km²), zona agrícola (277.01 km²) y pajonal de puna húmeda

(230.37 km²) son los ecosistemas que presentan las mayores superficies con probabilidad 'Muy alta' de ocurrencia de incendios forestales.

Figura 6

Área (km²) de probabilidad de ocurrencia de incendios de Apurímac, según ecosistemas.



Con respecto al porcentaje de área del ecosistema, el Bosque relicto mesoandino (16,9 %) y matorral andino (11,1 %) son los ecosistemas más afectados con probabilidad 'Muy alta' de ocurrencia de incendios forestales. En la probabilidad 'Alta' destacan bosque relicto altoandino (Queñoal et al.,) (51,4 %) y plantación forestal (41,6 %)

(Tariq et al., 2022; Usmadi, 2023; Yang et al., 2021). Esto, porque se consideró que el rendimiento de los modelos es mejor cuando se usan solo variables cuantitativas. Pero futuros estudios pueden analizar modelos con otras variables. Al igual que los escenarios de riesgo de incendios en la región San Martín (CENEPRED, 2022), este estudio atribuye que las causas antropogénicas incrementan la probabilidad de ocurrencia de incendios, destacando la proximidad a la acción humana (poblaciones, carreteras y agricultura).

DISCUSIÓN

En este estudio, los modelos de previsión realizados por CFOI indican un alarmante aumento de los incendios forestales en Apurímac, en la última década; por lo tanto, se modeló el mapa de predicción de incendios forestales de Apurímac utilizando el método de aprendizaje automático MaxEnt y uso de los SIG.

El modelo identifica áreas bien definidas en el norte de Apurímac con alto riesgo de ocurrencia de incendios. Estas zonas se correlacionan con el reporte favorable de ocurrencia de incendios sobre cobertura vegetal del CFOI, que afectan principalmente las provincias de Abancay y Andahuaylas. Cabe mencionar que en estas provincias se presenta como ecosistema dominante los matorrales y pajonales (MINAM, 2019). Donde los pastizales son vulnerables a la ocurrencia de

incendios, después de los bosques (Ferreira et al., 2021). En efecto, esto podría deberse a que estas áreas poseen características ambientales que favorecen la ignición y propagación del fuego, como temperaturas más elevadas, menor humedad del suelo y vegetación más inflamable (Thapa et al., 2021). Por el contrario, las provincias de Aymaraes, Grau y Antabamba muestran menor riesgo de incendios, posiblemente porque presentan condiciones menos propicias para la ocurrencia de fuegos, tales como las de acción humana (Pérez et al., 2011).

Sin embargo, es importante destacar que este estudio presenta limitaciones en la predicción de la ocurrencia de incendios forestales, lo que puede afectar la implementación de estrategias de manejo del fuego efectivas. Por ejemplo, es necesario tener en cuenta la heterogeneidad detallada de los paisajes, lo cual se podría lograr utilizando nuevas tecnologías como los Sistemas de Aeronaves Pilotadas de Forma Remota (RPAS, por sus siglas en inglés) (Arkin et al., 2023). Además, se recomienda realizar evaluaciones posteriores de las áreas afectadas por incendios para comprender mejor los impactos de los incendios forestales (Christensen, 2015). Estas consideraciones adicionales permitirían mejorar la precisión de las estrategias de manejo del fuego y maximizar su efectividad.

CONCLUSIONES

Se desarrolló un modelo SIG - MaxEnt para evaluación de riesgos de incendios forestales y crear un mapa de probabilidad, el cual mostró una capacidad predictiva 'buena'.

La superficie de Apurímac, principalmente en el norte, presentan 'muy alta' y 'alta' probabilidad de ocurrencia de incendios forestales.

Los ecosistemas de Matorral andino (561.25 km²), Zona agrícola (277.01 km²) y Pajonal de puna húmeda (230.37 km²) presentan las mayores superficies con

probabilidad 'muy alta' de ocurrencia de incendios forestales.

Este estudio muestra la utilidad de los SIG y MaxEnt como herramientas importantes en la toma de decisiones preventivas y de lucha contra los incendios forestales.

REFERENCIAS BIBLIOGRÁFICAS

- Anticona, A., Zúñiga, C., Santos, A., Lorenzon, A., & Filho, P. (2023). Gis and fuzzy logic approach for forest fire risk modeling in the Cajamarca region, Peru. *Decision Science Letters*, *12*(2), 353–368. <https://doi.org/10.5267/j.dsl.2023.1.002>
- Araujo, M., Pearson, R., Thuiller, W., & Erhard, M. (2005). Validation of species-climate impact models under climate change. *Global Change Biology*, *11*(9), 1504–1513. <https://doi.org/10.1111/j.1365-2486.2005.001000.x>
- Arkin, J., Coops, N., Daniels, L., & Plowright, A. (2023). A novel post-fire method to estimate individual tree crown scorch height and volume using simple RPAS-derived data. *Fire Ecology*, *19*(1), 17. <https://doi.org/10.1186/s42408-023-00174-7>
- Banerjee, P. (2021). Maximum entropy-based forest fire likelihood mapping: analyzing the trends, distribution, and drivers of forest fires in Sikkim Himalaya. *Scandinavian Journal of Forest Research*, *36*(4), 275–288. <https://doi.org/10.1080/02827581.2021.1918239>
- Bax, V. (2018). Mapping the risk of forest fires in Peru's Amazon and Andean Forest regions using the AdaBoost algorithm and Geographic Information Systems. *2018 IEEE XXV International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*, 1–4. <https://doi.org/10.1109/INTERCON.2018.8526470>

- CENEPRED. (2022). *Escenario de riesgo por incendios forestales de la Región San Martín*. Dirección de Gestión de Procesos. <https://sigrid.cenepred.gob.pe/sigridv3/documento/14419>
- CGIAR (Consortium for Spatial Information). www.srtm.csi.cgiar.org
- Christensen, B. R. (2015). Use of UAV or remotely piloted aircraft and forward-looking infrared in forest, rural and wildland fire management: evaluation using simple economic analysis. *New Zealand Journal of Forestry Science*, 45(1), 16. <https://doi.org/10.1186/s40490-015-0044-9>
- Dormann, C., Elith, J., Bacher, S., Buchmann, C., Carl, G., Carré, G., García, M., Gruber, B., Lafourcade, B., Leitão, P., Münkemüller, T., McClean, C., Osborne, P., Reineking, B., Schröder, B., Skidmore, A., Zurell, D., & Lautenbach, S. (2013). Collinearity: A review of methods to deal with it and a simulation study evaluating their performance. *Ecography*, 36(1), 27–46. <https://doi.org/10.1111/j.1600-0587.2012.07348.x>
- ESRI Land Cover (2022). *Sentinel-2 10-Meter Land Use/Land Cover*. <https://livingatlas.arcgis.com/landcover/>
- Farr, T., Rosen, P., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., Seal, D., Shaffer, S., Shimada, J., Umland, J., Werner, M., Oskin, M., Burbank, D., & Alsdorf, D. (2007). The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(RG2004), 1–33. <https://doi.org/10.1029/2005RG000183>
- Ferreira, P., Ely, C., & Beal, M. (2021). Different post-fire stages encompass different plant community compositions in fire-prone grasslands from Southern Brazil. *Flora*, 285, 151937. <https://doi.org/10.1016/j.flora.2021.151937>
- Fick, S., & Hijmans, R. (2017). WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37(12), 4302–4315. <https://doi.org/10.1002/joc.5086>
- Janiec, P., & Gadal, S. (2020). A Comparison of Two Machine Learning Classification Methods for Remote Sensing Predictive Modeling of the Forest Fire in the North-Eastern Siberia. *Remote Sensing*, 12(24), 4157. <https://doi.org/10.3390/rs12244157>
- Leroy, B., Meynard, C., Bellard, C., & Courchamp, F. (2016). Virtual species, an R package to generate virtual species distributions. *Ecography*, 39(6), 599–607. <https://doi.org/10.1111/ecog.01388>
- Meza, G., Barboza C., Torres G., Cotrina S., Guzmán V., Oliva, M., Bandopadhyay, S., Salas L., & Rojas B., (2020). Predictive Modelling of Current and Future Potential Distribution of the Spectacled Bear (*Tremarctos ornatus*) in Amazonas, Northeast Peru. *Animals*, 10(1816), 1–21. <https://doi.org/10.3390/ani10101816>
- Ministerio de Desarrollo Agrario y Riego. (2020). R.M. N° 0322-2020-MIDAGRI. *Oficializan el Mapa Nacional de Superficie Agrícola del Perú*. <https://www.gob.pe/institucion/midagri/normas-legales/1433393-0322-2020-midagri>
- Ministerio del Ambiente. (2019). *Mapa Nacional de Ecosistemas del Perú: Memoria Descriptiva*. Dirección General de Ordenamiento Territorial Ambiental. https://cdn.www.gob.pe/uploads/document/file/309735/Memoria_descriptiva_mapa_Nacional_de_Ecosistemas.pdf
- Ministerio del Ambiente (2019). *Monitoreo de las condiciones favorables para la ocurrencia de incendios sobre la cobertura vegetal – CFOI*. <https://repositoriodigital.minam.gob.pe/>

- handle/123456789/652
- org/10.1071/WF10109
- MINEDU. (2020). *Descarga de Información espacial del MED*. <http://sigmed.minedu.gob.pe/descargas/>
- Mishra, B., Panthi, S., Poudel, S., & Ghimire, B. R. (2023). Forest fire pattern and vulnerability mapping using deep learning in Nepal. *Fire Ecology*, *19*(1), 3. <https://doi.org/10.1186/s42408-022-00162-3>
- MTC. (2023). *Descarga de datos espaciales*. <https://portal.mtc.gob.pe/estadisticas/descarga.html>
- New, M., Lister, D., Hulme, M., & Makin, I. (2002). A high-resolution data set of surface climate over global land areas. *Climate Research*, *21*(1), 1–25. <https://doi.org/10.3354/cr021001>
- Pérez, Y., Pastor, E., Àgueda, A., & Planas, E. (2011). Effect of Wind and Slope When Scaling the Forest Fires Rate of Spread of Laboratory Experiments. *Fire Technology*, *47*(2), 475–489. <https://doi.org/10.1007/s10694-010-0168-7>
- Phillips, S., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, *190*(2–3), 231–252. <https://doi.org/10.1016/j.ecolmodel.2005.03.026>
- Phillips, S., & Dudík, M. (2008). Modeling of species distributions with Maxent: new extensions and a comprehensive evaluation. *Ecography*, *31*, 161–175. <https://doi.org/10.1111/j.2007.0906-7590.05203.x>
- Renard, Q., Pélissier, R., Ramesh, B., & Kodandapani, N. (2012). Environmental susceptibility model for predicting forest fire occurrence in the Western Ghats of India. *International Journal of Wildland Fire*, *21*(4), 368. <https://doi.org/10.1071/WF10109>
- Rojas, N., Cotrina S., Barboza C., Barrena G., Sarmiento, F., Sotomayor, D., Oliva, M., & Salas, L. (2020). Current and Future Distribution of Five Timber Forest Species in Amazonas, Northeast Peru: Contributions towards a Restoration Strategy. *Diversity*, *12*(8), 305. <https://doi.org/10.3390/d12080305>
- Rojas, N., García, L., Cotrina, A., Goñas, M., Salas, R., Silva, J., & Oliva, M. (2022). Land Suitability for Cocoa Cultivation in Peru: AHP and MaxEnt Modeling in a GIS Environment. *Agronomy*, *12*(12), 2930. <https://doi.org/10.3390/agronomy12122930>
- SERFOR. (2018). *Plan de prevención y reducción de riesgos de incendiarios forestales 2019 – 2022*. SERFOR.
- Tariq, A., Shu, H., Siddiqui, S., Munir, I., Sharifi, A., Li, Q., & Lu, L. (2022). Spatio-temporal analysis of forest fire events in the Margalla Hills, Islamabad, Pakistan using socio-economic and environmental variable data with machine learning methods. *Journal of Forestry Research*, *33*(1), 183–194. <https://doi.org/10.1007/s11676-021-01354-4>
- Thapa, S., Chitale, V., Pradhan, S., Shakya, B., Sharma, S., Regmi, S., Bajracharya, S., Adhikari, S., & Dangol, G. (2021). Forest Fire Detection and Monitoring. In *Earth Observation Science and Applications for Risk Reduction and Enhanced Resilience in Hindu Kush Himalaya Region*, Springer International Publishing. https://doi.org/10.1007/978-3-030-73569-2_8
- Usmadi, D. (2023). Maximum entropy application in predicting the vulnerability of land and forest fires in South Sumatra Province, Indonesia. *IOP Conference Series: Earth and Environmental*

Science, 1183(1), 012105. <https://doi.org/10.1088/1755-1315/1183/1/012105>

Yang, X., Jin, X., & Zhou, Y. (2021). Wildfire Risk Assessment and Zoning by Integrating Maxent and GIS in Hunan Province, China. *Forests*, 12(10), 1299. <https://doi.org/10.3390/f12101299>

Zubieta, R., Prudencio, F., Ccanchi, Y., Saavedra, M., Sulca, J., Reupo, J., & 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>