

PREDICCIÓN DEL RIESGO DE INCENDIOS FORESTALES MEDIANTE TELEDETECCIÓN E IA (2020-2025)

FOREST FIRE RISK PREDICTION USING REMOTE SENSING AND ARTIFICIAL INTELLIGENCE

Rodrigo ÁLVAREZ¹, Javier SANTOS², Thide E. LLORENTE³, Stephany NIEVES⁴
y Samuel REY⁵

¹ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ ralvarezmartin@usal.es

🌐 <https://orcid.org/0009-0004-1157-4373>

² *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ javier.santos@usal.es

🌐 <https://orcid.org/0009-0008-4310-4746>

³ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ llorentel@usal.es

🌐 <https://orcid.org/0000-0001-6543-0026>

⁴ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ snievesu@usal.es

🌐 <https://orcid.org/0009-0003-6937-2072>

⁵ *Universidad de Salamanca. Salamanca, Castilla y León, España*

✉ srey@usal.es

🌐 <https://orcid.org/0009-0002-4675-5065>

RESUMEN: Se sintetizan los avances de 2020-2025 en predicción del riesgo de incendios forestales mediante teledetección y modelos de inteligencia artificial. Se resume el uso de índices espectrales (NDVI, EVI, NDMI), variables térmicas, topográficas y antrópicas, y se comparan líneas base (regresión, Random Forest, SVM) con arquitecturas profundas (CNN, ConvLSTM, Transformers). Se destacan resultados recientes con AUC entre 0.85 y 0.96 y F1 entre 0.67 y 0.85, así como la incorporación de autosupervisión y adaptación eficiente de parámetros para transferir modelos entre regiones. Se proponen buenas prácticas de evaluación (F1/AUC, RMSE/MAE y Kappa) y recomendaciones para despliegue operativo con datos multifuente y restricciones de costo computacional.

Palabras clave: wildfire risk; teledetección; CNN; ConvLSTM; Transformers; LoRA.

ABSTRACT: Advances from 2020-2025 in forest fire risk prediction using remote sensing and artificial intelligence are synthesized. The use of spectral indices (NDVI, EVI, NDMI), thermal, topographic, and anthropogenic variables is summarized, and baseline approaches (regression, Random Forest, SVM) are compared with deep learning architectures (CNN, ConvLSTM, Transformers). Recent results reporting AUC values between 0.85 and 0.96 and F1 scores between 0.67 and 0.85 are highlighted, along with the incorporation of self-supervised learning and parameter-efficient fine-tuning techniques to transfer models across regions. Best practices for evaluation (F1/AUC, RMSE/MAE, and Kappa) and recommendations for operational deployment using multi-source data under computational cost constraints are also proposed.

Keywords: wildfire risk; remote sensing; CNN; ConvLSTM; Transformers; LoRA.

1. INTRODUCCIÓN

Los incendios forestales amenazan ecosistemas, economías y salud pública. Entre 2019 y 2023 los grandes incendios en Australia y Canadá quemaron millones de hectáreas y generaron pérdidas superiores a 100 000 millones de dólares, mientras que en España la superficie quemada en 2022 (~247,667 ha) quintuplicó la del año previo. El incremento simultáneo de temperaturas, sequías y presión antrópica refuerza la necesidad de mapas de riesgo más precisos para orientar prevención y preposicionamiento de recursos.

La literatura reciente combina datos satelitales ópticos y térmicos, reanálisis meteorológicos y variables socioeconómicas para estimar probabilidades de ignición y propagación. Revisiones recientes destacan la integración de datos multifuente y modelos profundos para mejorar la predicción en diferentes regiones [4]. Este artículo condensa los hallazgos clave 2020-2025 sobre fuentes de datos, modelos de predicción y métricas de evaluación, con foco en la aplicabilidad operativa y la transferibilidad espacio-temporal.

2. DATOS SATELITALES Y VARIABLES DE ENTRADA

2.1. ÍNDICES ESPECTRALES Y HUMEDAD

El NDVI continúa como indicador estándar de vigor de la vegetación, aunque sufre saturación en coberturas densas y sensibilidad al fondo del suelo [1]. El EVI añade la banda azul para corregir aerosoles y mejorar la respuesta en bosques densos [2]. El SAVI incorpora un factor de suelo y el NDMI combina NIR-SWIR para estimar el contenido hídrico de la vegetación, con valores negativos asociados a suelo desnudo y positivos altos a vegetación sin estrés [3].

Estos índices se complementan con NDWI y NBR para humedad y áreas quemadas y con temperatura superficial (LST) para detectar estrés térmico previo a la ignición. Los productos de área quemada como MCD64A1 (MODIS, colección 6) sirven para calibrar

y validar mapas de riesgo [10]. El preprocesamiento incluye enmascarado de nubes, armonización radiométrica y remuestreo a celdas comunes; las series diarias o semanales suelen suavizarse con ventanas móviles para reducir ruido. En regiones con alta nubosidad se recurre a interpolaciones y a la fusión con radar de apertura sintética para mantener continuidad en estimaciones de humedad del combustible [11].

2.2. TOPOGRAFÍA, USOS DEL SUELO Y METEOROLOGÍA

Pendiente, orientación y altitud condicionan la acumulación de combustible y la dirección de propagación; la proximidad a carreteras y áreas urbanas explica la mayor parte de igniciones de origen humano. Variables meteorológicas (temperatura del aire, humedad relativa, precipitación, viento) se integran mediante reanálisis como ERA5 y el índice Fire Weather Index, mejorando la predicción diaria y subestacional del riesgo [9].

La combinación de capas multifuente demanda normalización espacial y temporal para evitar sesgos por resolución. La inclusión de indicadores socioeconómicos (densidad de población, usos del suelo) ha demostrado incrementar la sensibilidad del modelo en interfaces urbano-forestales sin degradar la especificidad en áreas remotas.

Para reducir el desequilibrio entre celdas con y sin incendio, se emplean muestreos estratificados y ponderaciones temporales que priorizan días cercanos a eventos. Los conjuntos se dividen respetando la independencia espacial (por cuencas o cuadrículas) para evitar fugas de información entre entrenamiento y prueba.

3. MODELOS DE PREDICCIÓN

3.1. MODELOS TRADICIONALES

Las regresiones logísticas y los árboles de decisión fueron las primeras líneas base; permiten interpretar el efecto de variables como pendiente o NDVI, pero capturan de forma limitada umbrales no lineales. Random Forest y SVM mejoran la precisión en conjuntos heterogéneos y siguen siendo útiles como referencias rápidas y explicables [4].

No obstante, la autocorrelación espacial y la dinámica temporal reducen su capacidad predictiva frente a métodos que modelan patrones espaciales y secuencias. Por ello se emplean como línea de base o para generar mapas explicativos que acompañen a modelos más complejos.

Variantes geográficamente ponderadas y modelos de mezcla permiten cierta adaptación local, pero su rendimiento decrece en escenarios multiespectrales de alta dimensión. El valor principal de estas líneas base reside en su interpretabilidad y en su uso para auditorías y detección de sesgos.

3.2. CNN Y ARQUITECTURAS HÍBRIDAS

Las CNN explotan la estructura espacial de los mapas de riesgo. Un estudio con 11 507 incendios históricos en Guangdong (China) reportó en test precisión del 89.7 %, *recall* del 90.7 %, F1 = 84.9 % y AUC = 0.962, superando a árboles de decisión, RF y regresión logística [5]. Las variables más influyentes fueron humedad relativa, temperatura, NDVI y precipitación.

Variantes tipo ResNet y U-Net preservan detalles finos y se combinan con *autoencoders* o módulos LSTM para segmentación semántica del riesgo. Estos enfoques mejoran la detección de focos dispersos y reducen falsas alarmas en paisajes heterogéneos, manteniendo inferencias en segundos por escena.

La interpretabilidad se apoya en mapas de calor (Grad-CAM) que resaltan zonas críticas y en estimadores de incertidumbre (por ejemplo, dropout Monte Carlo) para priorizar revisiones humanas. Ensamblajes ligeros de CNN incrementan la robustez sin penalizar severamente el tiempo de inferencia.

3.3. MODELOS ESPACIO-TEMPORALES Y *TRANSFORMERS*

Las ConvLSTM mantienen la coherencia espacial en secuencias multitemporales y han mostrado mejoras frente a LSTM y XGBoost en escenarios mediterráneos [4]. A escala global, redes híbridas ConvLSTM alcanzan AUC cercanas a 0.89 y F1 alrededor de 0.72 al equilibrar memoria temporal y precisión espacial. *Transformers* geoespaciales capturan dependencias de largo alcance y correlaciones climáticas; variantes deformables y con atención en ventanas han superado a CNN en bosques de pino al integrar variables meteorológicas y combustibles [4]. En detección en tiempo casi real, enfoques autosupervisados como SIT-FUSE distinguen frentes de fuego y columnas de humo con SSIM de 0.71-0.86 [6]. La adaptación eficiente de parámetros mediante LoRA permite afinar modelos de fundación geoespacial usando solo 5-10 % de los parámetros, facilitando su traslado entre regiones [7].

La mayoría de estos modelos se entrenan con validación cruzada espacio-temporal y ventanas deslizantes que respetan la causalidad. La adaptación de dominio incorpora capas de ajuste o pérdidas adversarias para reducir el corrimiento entre regiones; los mejores resultados combinan preentrenamiento autosupervisado, *fine-tuning* eficiente y datos locales de alta resolución.

4. EVALUACIÓN Y MÉTRICAS

Las métricas principales son precisión, *recall*, F1 y área bajo la curva ROC (AUC). Los mejores resultados recientes con CNN se sitúan en AUC cercanas a 0.96 y F1 alrededor de 0.85 [5], mientras que modelos espacio-temporales se mantienen en AUC cercanas a 0.89. En mapas categóricos, el coeficiente Kappa y su versión ponderada cuantifican el acuerdo espacial más allá del azar [8].

Se recomienda evaluar un vector de métricas: F1/AUC para discriminación, RMSE/MAE para errores absolutos en probabilidades o superficie quemada, y Kappa para acuerdo

espacial. Para despliegue operativo deben añadirse tiempo de inferencia y consumo energético, priorizando modelos eficientes cuando el refresco diario sea crítico.

La partición de datos debe evitar fugas: separar por bloques espaciales o periodos completos y reservar años recientes como conjunto de prueba. En contextos desbalanceados, las curvas *precision-recall* y el costo de falsas alarmas por región ofrecen una lectura más informativa que la ROC agregada.

5. RETOS Y OPORTUNIDADES FUTURAS

Interpretabilidad y confianza siguen siendo críticas: técnicas SHAP y LIME permiten derivar umbrales de cobertura o humedad donde el riesgo se dispare, como mostró el proyecto Wildfire Genome al asociar coberturas de coníferas y altitud con incrementos bruscos de riesgo [8]. La transferibilidad espacial requiere adaptaciones ligeras (LoRA, adaptadores) para ajustar modelos preentrenados a nuevas regiones con pocos datos [7].

La fusión de datos multiresolución (ópticos, térmicos, radar, socioeconómicos) demanda normalización robusta y puede beneficiarse de autosupervisión para explotar grandes volúmenes sin etiquetar [6, 11]. Reducir el costo computacional mediante compresión y actualización parcial de parámetros es clave para que los modelos profundos sean sostenibles en centros operativos y dispositivos de borde.

La gobernanza de datos (versionado, trazabilidad de capas imputadas y control de acceso) y la estandarización de formatos facilitan la replicabilidad entre agencias. La integración de LiDAR para estimar carga de combustible tridimensional complementa las señales ópticas y radar y mejora la estimación de la humedad en la subcopia [12].

6. CONCLUSIONES

Los índices de vegetación y humedad continúan siendo la base de los mapas de riesgo, pero su integración con variables topográficas, meteorológicas y antrópicas incrementa la sensibilidad y la especificidad. Las CNN y ConvLSTM superan de forma consistente a regresiones, RF y SVM, con AUC entre 0.85 y 0.96 y F1 superiores a 0.7 [4, 5], mientras que *Transformers* y enfoques autosupervisados amplían el horizonte de predicción y reducen la dependencia de etiquetas [6].

Las métricas combinadas (F1/AUC, RMSE/MAE, Kappa) y el reporte de tiempos de inferencia deben acompañar cualquier despliegue operativo. La adaptación eficiente de parámetros habilita la transferencia entre regiones sin reentrenar desde cero, acercando modelos de alta precisión a escenarios reales con limitaciones de datos y recursos [7, 9].

7. AGRADECIMIENTOS

Esta investigación forma parte del Proyecto de Cátedra Internacional sobre Inteligencia Artificial Fiable y Reto Demográfico dentro de la Estrategia Nacional de Inteligencia

Artificial (ENIA), en el marco del Plan Europeo de Recuperación, Transformación y Resiliencia. Referencia: TSI-100933-2023-0001. Este proyecto está financiado por la Secretaría de Estado para la Digitalización y la Inteligencia Artificial y por la Unión Europea (Next Generation).

8. REFERENCIAS

1. NASA Earthdata. (s.f.). *Normalized Difference Vegetation Index (NDVI)*. Earth Science Data Systems, NASA. <https://www.earthdata.nasa.gov/topics/land-surface/normalized-difference-vegetation-index-ndvi>
2. U.S. Geological Survey. (s.f.). *Landsat Enhanced Vegetation Index (EVI)*. U.S. Department of the Interior. <https://www.usgs.gov/landsat-missions/landsat-enhanced-vegetation-index>
3. Geovisualization.net. (2022, 14 de julio). *Measuring moisture – Normalized Difference Moisture Index (NDMI) Sentinel-2, 2022*. <https://geovisualization.net/2022/07/14/measuring-moisture-normalized-difference-moisture-index-ndmi-sentinel-2-2022/>
4. Xu, Z., Wang, X., & Zhang, Y. (2024). *Wildfire risk prediction: A review* (arXiv:2405.01607). arXiv. <https://arxiv.org/abs/2405.01607>
5. Jiang, W., Wang, L., Chen, H., & Liu, J. (2024). Wildfire risk assessment using deep learning in Guangdong Province, China. *International Journal of Applied Earth Observation and Geoinformation*, 128, Artículo 103750. <https://doi.org/10.1016/j.jag.2024.103750>
6. LaHaye, N., El-Kadi, H., & Garay, M. (2025). Harnessing self-supervised deep learning and geostationary remote sensing for advancing wildfire and associated air quality monitoring (SIT-FUSE). In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2025)*. IEEE. <https://doi.org/10.1109/IGARSS55030.2025.11243034>
7. Thoreau, R., Lefèvre, S., & Courty, N. (2025). Parameter-efficient adaptation of geospatial foundation models through embedding deflection. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV 2025)*. IEEE. <https://doi.org/10.1109/ICCV51701.2025.00895>
8. Liu, C., & Mostafavi, A. (2025). *WildfireGenome: Interpretable machine learning reveals local drivers of wildfire risk and their cross-county variation* (arXiv:2511.11589). arXiv. <https://arxiv.org/abs/2511.11589>
9. Vitolo, C., Di Giuseppe, F., Krzeminski, B., & San-Miguel-Ayanz, J. (2020). ERA5-based global meteorological wildfire danger maps. *Scientific Data*, 7, Artículo 214. <https://doi.org/10.1038/s41597-020-0554-z>
10. Giglio, L., Boschetti, L., Roy, D. P., Humber, M. L., & Justice, C. O. (2018). The Collection 6 MODIS burned area mapping algorithm and product. *Remote Sensing of Environment*, 217, 72-85. <https://doi.org/10.1016/j.rse.2018.08.005>
11. Chrysafis, I., Mallinis, G., Gitas, I., & Tsakiri-Strati, M. (2023). Vegetation fuel mapping using Sentinel-1, Sentinel-2, and DEM derivatives—East Macedonia and Thrace, Greece. *Remote Sensing*, 15(4), Artículo 1015. <https://doi.org/10.3390/rs15041015>
12. Bright, B. C., Hudak, A. T., Meddens, A. J. H., Hawbaker, T. J., Briggs, J., & Kennedy, R. E. (2022). Multitemporal lidar captures heterogeneity in fuel loads and consumption on the Kaibab Plateau. *Fire Ecology*, 18, Artículo 16. <https://doi.org/10.1186/s42408-022-00142-7>