



Predicting Wildfire Occurrence Risk in the Forests and Rangelands of Mazandaran Province by Comparing Regression and Machine Learning Models

Ardavan Ghorbani ^{*1}, Mohadeseh Amiri ¹

¹ Department of Range and Watershed Management, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil, Iran

ARTICLE INFO

ABSTRACT

Article History:

Received: 11 December 2025

Revised: 12 February 2026

Accepted: 20 February 2026

Available Online:

26 February 2026

Keywords:

Machine Learning Model

Environmental Drivers

Wildfire Susceptibility

Remote Sensing and GIS

Ensemble Modeling

Wildfire is a major driver of terrestrial ecosystem degradation, and its impacts have intensified in the forests and rangelands of Mazandaran Province due to climate change and human activities. This study assessed wildfire susceptibility and evaluated predictive model performance using four data-mining methods: Artificial Neural Network (ANN), Generalized Linear Model (GLM), Generalized Additive Model (GAM), and Maximum Entropy (MaxEnt), applied individually and in an ensemble framework. Climatic, topographic, vegetation, and human-related variables were used as model inputs, and performance was evaluated using the Area Under the Curve (AUC), True Skill Statistic (TSS), sensitivity, and specificity. Results showed that the ensemble model achieved the highest accuracy and stability, while MaxEnt performed best among single models. Variable-importance analysis indicated that Normalized Difference Vegetation Index (NDVI) and precipitation were the dominant factors controlling the spatial pattern of wildfire susceptibility, followed by elevation and slope. The highest susceptibility occurred in areas with moderate elevation, slopes greater than 35%, moderate to dense vegetation cover, and annual precipitation below 500 mm. The ensemble map showed a widespread and relatively uniform distribution of high-risk zones, confirming the multifactorial and complex nature of wildfire occurrence and highlighting the value of multi-model approaches for preventive and sustainable natural-resource management.

* Corresponding author: Ardavan Ghorbani

E-mail address: a_ghorbani@uma.ac.ir

How to cite this article: Ghorbani, A., & Amiri, M. (2026). Predicting Wildfire Occurrence Risk in the Forests and Rangelands of Mazandaran Province by Comparing Regression and Machine Learning Models. *Journal of Geography and Environmental Hazards*, 15(2), 187-204. <https://doi.org/10.22067/geoe.2026.96904.1629>



©2026 The author(s). This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0)

Extended Abstract

Introduction

Wildfires represent one of the most significant ecological hazards affecting Iran's natural ecosystems, resulting from the combined influences of climatic conditions, vegetation characteristics, topographic complexity, and human activities. Global evidence indicates that climate change through reduced precipitation, rising temperatures, and increased soil and vegetation dryness has intensified both the frequency and severity of wildfire events. Over the past two centuries, forests worldwide have undergone extensive degradation driven by fire, and numerous studies have highlighted the pivotal roles of natural and anthropogenic factors in shaping landscape-level fire susceptibility. In Iran, wildfires have emerged a critical environmental concern, destroying thousands of hectares of forest annually and placing the country among the most affected in the region. The ecological consequences of wildfire include biodiversity loss, alterations in soil physical and chemical properties, accelerated erosion, and increased carbon emissions. Given these impacts, the application of remote sensing, geographic information system (GIS), and data-driven modelling approaches has become essential for predicting fire occurrence and generating reliable susceptibility maps. Previous studies have demonstrated the effectiveness of neural networks, statistical methods, and machine-learning algorithms in wildfire forecasting. Building upon this body of research, the present study aims to map wildfire susceptibility in Mazandaran Province, identify the most influential environmental drivers, evaluate the performance of individual and ensemble models, and determine the most accurate predictive framework. The study is based on the hypothesis that climatic factors exert a dominant influence on wildfire occurrence and that ensemble modelling provides superior predictive performance compared to single-model approaches.

Material and Methods

To develop the wildfire susceptibility map, spatially explicit records of historical fire occurrences were collected through field surveys. After removing spatial autocorrelation, the fire locations were randomly divided into training and testing subsets. Absence data were generated using a pseudo-absence approach guided by preliminary MaxEnt outputs to ensure representative background conditions. A comprehensive set of environmental predictors was compiled, including topographic, meteorological, anthropogenic, and vegetation-related variables. Elevation, slope, aspect, topographic wetness index, and distance to rivers were derived from digital elevation models and remote-sensing data. Climatic variables—temperature, precipitation, relative humidity, and wind speed were interpolated across the study area using geostatistical methods based on observations from 32 meteorological stations. Anthropogenic factors included distance to roads and settlements, while vegetation conditions and moisture stress were characterized using the normalized difference vegetation index (NDVI) and Temperature Vegetation Dryness Index (TVDI). Wildfire susceptibility across forest and rangeland ecosystems of Mazandaran Province was modeled using four data-driven approaches: Artificial Neural Networks (ANN), Generalized Linear Models (GLM), Generalized Additive Models (GAM), and Maximum Entropy (MaxEnt). Model performance was evaluated using k-fold cross-validation, the area under the receiver operating characteristic curve (AUC), sensitivity, specificity, and the true skill statistic (TSS). To reduce uncertainty and improve predictive robustness, an ensemble model was developed using AUC-weighted averaging of the individual models, and wildfire susceptibility was classified into five categories. Finally, the relative contribution of each predictor was quantified using game-theoretic Shapley values to identify the key environmental drivers of wildfire occurrence.

Results and Discussion

The results indicate that the models exhibited varying levels of performance in predicting wildfire susceptibility. Both the MaxEnt and ensemble models achieved excellent accuracy, with AUC values of 0.92 and 0.94, respectively. Among the evaluation metrics, the ensemble model produced the highest TSS value (0.74), reflecting a strong ability to distinguish between fire presence and absence. In terms of sensitivity, the GAM and ensemble models performed best, whereas the GLM and ensemble models exhibited the highest specificity. Variable-importance analysis revealed that vegetation, climatic, and topographic factors exerted the greatest influence on wildfire susceptibility.

NDVI showed high importance in the GAM and MaxEnt models, while precipitation was identified as the dominant variable by the ANN and ensemble models. Elevation and other topographic attributes also played significant roles in fire occurrence and spread, whereas anthropogenic variables had comparatively weaker effects. Spatial patterns of wildfire risk varied among models but generally converged in identifying high-risk zones. The ensemble susceptibility map showed a widespread distribution of wildfire risk across the region, highlighting the multifactorial nature of fire occurrence. Response curves indicated that increasing NDVI is generally associated with higher wildfire probability, although this relationship weakens at very high NDVI values due to reduced fine fuel availability. Fire susceptibility was highest at moderate elevations and increased with slope, particularly on slopes exceeding 10%. An inverse relationship was observed between precipitation and wildfire susceptibility, with drier areas exhibiting the highest risk.

Conclusion

The findings demonstrate that ensemble modeling provides a robust and reliable framework for wildfire susceptibility mapping, outperforming individual algorithms in terms of predictive accuracy and spatial consistency. Wildfire risk in Mazandaran Province is controlled by a complex interaction among vegetation characteristics, climatic conditions, and topographic features, underscoring the need for integrated management strategies. The susceptibility maps produced in this study offer a valuable scientific basis for land-use planning, proactive fire management, and prioritization of high-risk areas, particularly given that preventive measures are generally more cost-effective and sustainable than post-fire suppression and restoration. Overall, this study emphasizes the importance of multi-model and systematic approaches for mitigating wildfire risk in ecologically sensitive landscapes, and the ensemble-based maps developed here can serve as effective decision-support tools for regions with similar environmental conditions.



دسترسی آزاد

نشریه علمی
جغرافیا و مخاطرات محیطی

DOI: 10.22067/GEOEH.2026.96904.1629

مقاله پژوهشی



پیش‌بینی خطر وقوع آتش‌سوزی در جنگل‌ها و مراتع استان مازندران با مقایسه مدل‌های رگرسیونی و یادگیری ماشین

اردوان قربانی^{۱*}، محدثه امیری^۱

^۱ گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل، ایران

چکیده	اطلاعات مقاله
آتش‌سوزی از مهم‌ترین عوامل تخریب اکوسیستم‌های زمینی است که در جنگل‌ها و مراتع استان مازندران تحت تأثیر همزمان تغییرات اقلیمی و فعالیت‌های انسانی تشدید شده است. این پژوهش با هدف تعیین حساسیت به آتش‌سوزی و ارزیابی کارایی مدل‌های پیش‌بینی خطر، از مدل‌های داده کاوی شامل شبکه عصبی مصنوعی (ANN)، مدل خطی تعمیم‌یافته (GLM)، مدل افزایشی تعمیم‌یافته (GAM) و حداکثر آنتروپی (MaxEnt) به‌صورت منفرد و اجماعی بهره گرفت. متغیرهای اقلیمی، توپوگرافی، پوشش گیاهی و انسانی به‌عنوان ورودی مدل‌ها در نظر گرفته شدند و عملکرد مدل‌ها با شاخص‌های سطح زیر منحنی (AUC)، آماره مهارت واقعی (TSS)، حساسیت و اختصاصی بودن ارزیابی شد. بر اساس نتایج، مدل اجماعی با تلفیق خروجی مدل‌های منفرد، بالاترین دقت و پایداری را در پیش‌بینی خطر آتش‌سوزی ارائه داد و در میان مدل‌های منفرد، حداکثر آنتروپی عملکرد بهتری داشت. تحلیل اهمیت متغیرها نقش غالب شاخص اختلاف نرمال شده پوشش گیاهی (NDVI) و بارندگی را در تبیین الگوی مکانی خطر آشکار ساخت و پس از آن ارتفاع و شیب نیز تأثیر معنی‌داری داشتند. بیشترین حساسیت در مناطق با ارتفاع متوسط، شیب بیش از ۳۵ درصد، پوشش گیاهی متوسط تا متراکم و بارندگی کمتر از ۵۰۰ میلی‌متر مشاهده شد. نقشه مدل اجماعی همچنین پراکنش گسترده و نسبتاً یکنواخت خطر را نشان داد که مؤید ماهیت چندعاملی و پیچیده پدیده آتش‌سوزی است و کارایی رویکردهای چندمدلی را در مدیریت پیشگیرانه و پایدار منابع طبیعی تأیید می‌کند.	تاریخچه مقاله: تاریخ دریافت: ۱۴۰۴/۰۹/۲۰ تاریخ بازنگری: ۱۴۰۴/۱۱/۲۳ تاریخ پذیرش: ۱۴۰۴/۱۲/۰۱
	کلمات کلیدی: مدل یادگیری ماشین پیشران‌های محیطی حساسیت به آتش سوزی سنجش از دور و سامانه اطلاعات جغرافیایی مدل‌سازی اجماعی

مقدمه

آتش‌سوزی از مهم‌ترین وقایع در اکوسیستم‌های کشورمان محسوب می‌شود که تحت تأثیر برهمکنش عوامل طبیعی نظیر اقلیم، پوشش گیاهی، توپوگرافی و عوامل انسانی قرار دارد (Bowman et al., 2019). شواهد حاکی از وجود ارتباطی قوی میان رژیم‌های آتش‌سوزی و شرایط اقلیمی است؛ به گونه‌ای که بر اساس مدل‌های تغییر اقلیم، انتظار می‌رود در دهه‌های آینده وقوع

آتش‌سوزی در جنگل‌های جهان روندی افزایشی داشته باشد؛ موضوعی که رخدادهای سال‌های اخیر نیز آن را تأیید می‌کنند (Pham et al., 2020). تغییر اقلیم با کاهش بارندگی و افزایش دما، موجب خشکی خاک و پوشش گیاهی شده و شدت و تکرار آتش‌سوزی را در مناطق مستعد افزایش می‌دهد. در این شرایط، بقایای گیاهی به‌عنوان سوخت عمل کرده و زمینه بروز آتش‌سوزی را فراهم می‌کند (Eskandari, Pourghasemi & Tiefenbacher, 2020).

طبق برآوردها، طی کمتر از دو قرن گذشته، حدود شش میلیون کیلومترمربع از جنگل‌های جهان بر اثر آتش‌سوزی از بین رفته است (Dimopoulou & Giannikos, 2004). افزون بر عوامل طبیعی، فعالیت‌های انسانی نیز به‌صورت مستقیم و غیرمستقیم احتمال وقوع آتش‌سوزی را در جنگل‌ها و مراتع افزایش می‌دهند (Lasslop & Kloster, 2017). تغییر کاربری اراضی با تشدید سایر عوامل مخرب، خطر آتش‌سوزی را تشدید می‌کند؛ بنابراین، آتش‌سوزی‌های جنگلی و مرتعی صرف‌نظر از منشاء طبیعی یا انسانی، یک فاجعه اکولوژیکی محسوب می‌شوند (Polat, Ghasemi Aghbash & Mahdavi, 2020).

پیامدهای آتش‌سوزی در اکوسیستم‌های طبیعی شامل آلودگی‌های محیط‌زیستی، تغییر در خصوصیات فیزیکی و شیمیایی خاک، کاهش تنوع زیستی، تشدید فرسایش، افت کیفیت منابع آب، تغییر در ساختار و ترکیب گیاهی و الگوهای چراست. همچنین، آتش‌سوزی‌های گسترده نقش مهمی در انتشار کربن و تشدید تغییرات اقلیمی جهان دارند (Achu et al., 2021). تکرار و شدت بالای آتش‌سوزی موجب گسترش گونه‌های نامرغوب شده و ارزش اکولوژیکی، اقتصادی و تفرجگاهی سیمای سرزمین را کاهش می‌دهد (Tessler, Wittenberg & Greenbaum, 2016).

در ایران نیز طی سال‌های اخیر، آتش‌سوزی‌های گسترده جنگلی به معضلی جدی تبدیل شده است، به‌طوری‌که سالانه بیش از ۶۰۰۰ هکتار از اراضی جنگلی تخریب می‌شود. بر اساس گزارش FAO، ایران هر سال حدود ۰/۰۶ درصد از سطح جنگل‌های خود را بر اثر آتش از دست داده و از نظر تخریب جنگل ناشی از آتش‌سوزی در رتبه چهارم خاورمیانه و شمال آفریقا قرار دارد (Abedi, 2022). این شرایط، ضرورت مدیریت علمی آتش‌سوزی و توسعه ظرفیت‌های کاهش خطر را دو چندان می‌سازد. ابزارهایی مانند سنجش از دور، سامانه اطلاعات جغرافیایی و تکنیک‌های داده کاوی قابلیت بالایی در مدل‌سازی حساسیت به آتش‌سوزی و تهیه نقشه‌های خطر دارند (Achu et al., 2021; Zhang, Wang & Liu, 2019). از سوی دیگر، ضعف در اطفای به موقع و فقدان آگاهی از الگوی گسترش حریق، ضرورت استفاده از نقشه‌های خطر و مدل‌های پیش‌بینی جهت کاهش خسارات را بیشتر می‌کند (Adab, Kanniah & Solaimani, 2013). تا کنون مطالعات متعددی در زمینه مدل‌سازی و پیش‌بینی رفتار آتش‌سوزی در عرصه‌های طبیعی انجام شده است. به‌عنوان مثال، عالی‌محمودی سراب و همکاران (Alimahmoodi Sarab, Feghhi & Jabarian Amiri, 2012) کارایی شبکه عصبی پرسپترون چند لایه را در پیش‌بینی آتش‌سوزی شهرستان ایذه تأیید کردند و نشان دادند این الگوریتم با تابع هایپربولیک در ایجاد ارتباط بین داده‌های آب و هوایی و وقوع آتش‌سوزی عملکرد بهتری دارد. مرادی و احمدی ثانی (Moradi & Ahmadi Sani, 2025) نیز با تلفیق فرآیند سلسله مراتبی گروهی و روش نسبت فراوانی، خطر آتش‌سوزی جنگل‌ها و مراتع زاگرس میانی را ارزیابی کرده و حدود نیمی از منطقه را در طبقه خطر زیاد و خیلی زیاد قرار دادند، به‌طوری‌که عوامل اقتصادی-اجتماعی و کاربری اراضی مهم‌ترین نقش را داشتند. در مطالعات بین‌المللی، هانگ و همکاران (Hong et al., 2018) در نقشه‌برداری حساسیت به آتش‌سوزی جنگل‌های جیانگشی چین نشان دادند مدل‌های بهینه و مدل جنگل تصادفی نسبت به ماشین بردار پشتیبان (SVM^1) عملکرد بهتری دارند. همچنین، مامبایل و همکاران (Mambile, Kaijage & Leo, 2025) اعلام کردند مدل پیچشی حافظه بلند کوتاه مدت ($ConvLSTM^2$) به دلیل توانایی در تحلیل روابط پیچیده مکانی-زمانی عملکرد برتری در شناسایی زودهنگام آتش‌سوزی دارد.

ادغام اطلاعات خطر آتش‌سوزی با شبکه راه‌ها به تخصیص بهینه منابع و هدایت مؤثر نیروهای اطفای به مناطق پرخطر کمک می‌کند. لذا این پژوهش با هدف ارائه اطلاعات کاربردی برای پیشگیری و مدیریت آتش‌سوزی در استان مازندران انجام شد، زیرا تاکنون ارزیابی جامعی با در نظر گرفتن عوامل طبیعی و انسانی در این استان صورت نگرفته است. اهداف این پژوهش عبارتند


1- Support Vector Machine

2- Convolutional Long-Short-Term Memory model

از: ۱) تهیه نقشه حساسیت به آتش‌سوزی؛ ۲) انتخاب مدل با بالاترین کارایی؛ ۳) تعیین سهم و شناسایی مهم‌ترین عوامل محیطی؛ و ۴) مقایسه عملکرد مدل اجماعی با مدل‌های منفرد.

منطقه مورد مطالعه

محدوده مورد بررسی، کلیه عرصه‌های جنگلی و مرتعی تحت مدیریت اداره کل منابع طبیعی استان مازندران است. این استان با وسعت ۲۳۹۷۴۴۰ هکتار، حدود ۱/۵ درصد از مساحت کشور را شامل می‌شود و بین عرض جغرافیایی $35^{\circ} 47'$ تا $36^{\circ} 25'$ شمالی و طول جغرافیایی $50^{\circ} 34'$ تا $54^{\circ} 10'$ شرقی قرار دارد (شکل ۱). مازندران از نظر توپوگرافی، به سه واحد کوهستانی، کوهپایه‌ای و جلگه‌ای و از نظر اقلیمی به سه تیپ معتدل و مرطوب خزری، معتدل کوهستانی و سرد کوهستانی تقسیم می‌شود. بارندگی و رطوبت در سطح استان به صورت ناهمگون توزیع شده و میزان آن در غرب به مراتب بیشتر از شرق است؛ به طوری که میانگین بارش سالانه در غرب ۹۷۷ و در شرق ۶۵۶/۳ میلی‌متر برآورد شده است. میانگین دمای سالانه استان ۱۷/۲ درجه سانتی‌گراد و سرعت باد نیز ۱۴/۵ متر بر ثانیه می‌باشد.



شکل ۱- نقاط رخداد آتش‌سوزی به همراه مکان ایستگاه‌های هواشناسی در منطقه مطالعاتی؛ و نمایی از وقوع آتش‌سوزی در جنگل‌های شهرستان آمل

Fig.1. Fire occurrence points along with the locations of climate stations in the study area; and a view of wildfire occurrence in the forests of Amol County

مواد و روش‌ها

برداشت داده‌های رخداد آتش‌سوزی

به منظور تهیه نقشه حساسیت به آتش‌سوزی، داده‌های مربوط به رخداد‌های پیشین آتش‌سوزی از طریق بازدیدهای میدانی، گردآوری و به صورت نقاط مکانی با مختصات جغرافیایی استاندارد ثبت شدند. برای جلوگیری از خودهمبستگی مکانی و کاهش آربیبی نمونه‌برداری، در هر پیکسل ۳۰ ثانیه‌ای (تقریباً یک کیلومترمربعی) تنها یک نقطه رخداد انتخاب و نقاط همسان در شعاع یک کیلومتری تا حد امکان حذف گردیدند. در نتیجه این فرآیند، ۲۸ نقطه خودهمبسته کنار گذاشته شد. با توجه به اهمیت استقلال داده‌های آموزشی و آزمون در فرآیند مدل‌سازی، داده‌ها به صورت تصادفی به دو مجموعه تعلیمی و ارزیابی تقسیم شدند؛ به طوری که ۷۰ درصد داده‌ها (۳۱۶ نقطه) برای ساخت و کالیبراسیون مدل‌ها و ۳۰ درصد باقیمانده (۱۳۶ نقطه) برای اعتبارسنجی به کار رفتند. برای تعیین نقاط عدم حضور نیز با اجرای یک مدل اولیه حداکثر آنتروپی، نواحی با احتمال پایین وقوع آتش‌سوزی به عنوان نقاط شبه غیاب در نظر گرفته شدند.

نقشه‌برداری متغیرهای محیطی مؤثر

شناسایی متغیرهای مؤثر در بروز و توسعه آتش‌سوزی، گامی اساسی در مدل‌سازی پتانسیل خطر آتش‌سوزی محسوب می‌شود. رفتار آتش‌سوزی از نظر گستره، مسیر و شدت گسترش، به طور قابل توجهی تحت تأثیر شرایط محیطی مانند پوشش گیاهی، توپوگرافی، عوامل اقلیمی و مؤلفه‌های انسانی قرار دارد. لذا، متغیرهای مستقل مطالعه در چهار گروه اصلی قرار گرفتند: عوامل توپوگرافی شامل ارتفاع، شیب، جهت دامنه، شاخص رطوبت توپوگرافیک (TWI^1) و فاصله از رودخانه؛ متغیرهای هواشناسی شامل دما، بارندگی، سرعت باد و رطوبت نسبی؛ عوامل انسانی شامل فاصله از سکونتگاه‌ها و فاصله از جاده‌ها؛ و متغیرهای پوشش گیاهی شامل شاخص اختلاف نرمال شده پوشش گیاهی ($NDVI^2$) و شاخص خشکی-دمایی گیاه ($TVDI^3$) که جزئیات آن‌ها در ادامه آمده است:

عوامل توپوگرافی: به دلیل ناهمواری شدید و ماهیت کوهستانی جنگل‌ها و مراتع شمال کشور، توپوگرافی نقش مهمی در وقوع و الگوی گسترش آتش‌سوزی ایفا می‌کند. در این پژوهش، متغیرهای ارتفاع، شیب و جهت دامنه از مدل رقومی ارتفاع (DEM^4) ۳۰ متری ماهواره ASTER استخراج شدند. ارتفاع ارتباط تنگاتنگی با دما و الگوهای جریانات بادی دارد و می‌تواند بر ساختار پوشش گیاهی و میزان رطوبت سوخت اثرگذار باشد (Adab et al., 2013). زاویه شیب نیز با افزایش پیش‌گرمایش مواد قابل اشتعال و سرعت گسترش حریق، شدت آتش‌سوزی را تحت تأثیر قرار می‌دهد، به ویژه زمانی که آتش از بخش‌های بالادست به سمت شیب‌های تندتر حرکت می‌کند (Weise & Biging, 1996). جهت شیب نیز از طریق میزان دریافت تابش خورشیدی، رطوبت سوخت و در نهایت الگوی پیشروی آتش، ترکیب و تراکم پوشش گیاهی را تحت تأثیر قرار می‌دهد (Denham, Waidelich & Laneri, 2022). دامنه‌های جنوبی به دلیل دریافت بیشتر انرژی تابشی خورشید، دمای بالاتر و رطوبت کمتر، و پوششی معمولاً خشک‌تر و کم‌تراکم‌تر نسبت به دامنه‌های شمالی دارند و در نتیجه، بیشتر مستعد آتش‌سوزی هستند (Najafi et al., 2015). علاوه بر این، شاخص رطوبت توپوگرافیک، به عنوان پارامتری مؤثر در اشتعال و گسترش آتش‌های سطحی در نظر گرفته می‌شود (Sivrikaya & Küçük, 2022). این شاخص، از ترکیب مساحت ویژه حوزه بالادست (As) و زاویه شیب (β) بر اساس رابطه (۱) محاسبه می‌شود و بیانگر تمایل آب به تجمع در یک نقطه از حوزه (بر مبنای As) و تمایل نیروهای گرانشی به انتقال آن به پایین‌دست (بر حسب $\tan\beta$ به عنوان شیب هیدرولیکی تقریبی) است. این شاخص به طور گسترده برای کمی‌سازی تأثیر توپوگرافی بر فرآیندهای هیدرولوژیکی به کار می‌رود (Endreny & Wood, 2003).

$$TWI = \ln (As/\tan\beta)$$

(۱)

پارامترهای هواشناسی: دما یکی از متغیرهای توضیحی مهم در رفتار آتش‌سوزی است، زیرا رطوبت سوخت را کنترل کرده و افزایش آن موجب خشک شدن سریع‌تر زی‌توده و پوشش گیاهی و حساسیت بیشتر به اشتعال می‌شود (Tuyen et al., 2021). به‌طور مشابه، کاهش رطوبت نسبی نیز احتمال وقوع آتش‌سوزی را افزایش می‌دهد، چرا که کمبود رطوبت محیط منجر به افزایش نرخ تبخیر و خشکی بیشتر سوخت می‌شود (Zhang et al., 2019). در مقابل، بارندگی اثر بازدارنده‌ای دارد و با افزایش رطوبت مواد قابل احتراق، ظرفیت اشتعال آن‌ها را کاهش می‌دهد (Achu et al., 2021). همچنین، وقوع بارش در حین آتش‌سوزی می‌تواند موجب تضعیف جبهه آتش و در نهایت خاموشی آن گردد. در همین راستا، باد با افزایش جریان اکسیژن، تسهیل گسترش مکانی حریق و پراکندگی دود، تبخیر و کاهش رطوبت سوخت‌های ریز پیرامونی را تسریع کرده و شدت آتش‌سوزی را افزایش می‌دهد (Denham et al., 2022). داده‌های مربوط به دمای هوا، رطوبت نسبی، بارندگی و سرعت باد از ایستگاه‌های هواشناسی داخل و پیرامون منطقه جمع‌آوری و با استفاده از مختصات جغرافیایی و ارتفاع ایستگاه‌ها، نقشه‌های توزیع مکانی این پارامترها با قدرت تفکیک مکانی یک کیلومتر تهیه گردید. برای این منظور از روش‌های زمین‌آماري شامل کریجینگ و معکوس

1- Topographic Wetness Index

2- Normalized Difference Vegetation Index

3- Temperature Vegetation Dryness Index

4- Digital Elevation Model

وزنی فاصله (IDW^1) برای برآورد مقادیر فضایی استفاده می‌شود تا واریانس تخمین به حداقل برسد (Hamed, Esmaeily & Faramarzi, 2020).

عوامل انسانی: بخش عمده‌ای از آتش‌سوزی‌های جنگل و مرتع با فعالیت‌های انسانی مرتبط است. از جمله این فعالیت‌ها می‌توان به ایجاد حریق در گردش‌های گروهی، آتش‌سوزی‌های عمدی، استعمال دخانیات، شکار، سوزاندن بقایای گیاهی و روشن کردن آتش توسط دامداران و چوپانان اشاره کرد (Eskandari et al., 2020). در این پژوهش، دو متغیر انسانی شامل فاصله از سکونتگاه‌ها و فاصله از جاده‌ها، با استفاده از مدل رقومی ارتفاع و ابزار فاصله اقلیدسی و با تفکیک مکانی یک کیلومتر استخراج و نقشه‌برداری شدند. نتایج پژوهش‌های پیشین نشان می‌دهد که نزدیکی عرصه‌های جنگلی و مرتعی به جاده‌ها و مناطق مسکونی، احتمال وقوع آتش‌سوزی را افزایش می‌دهد؛ به‌طوری‌که با کاهش فاصله، سطح خطر حریق به‌طور معناداری افزایش می‌یابد (Sivrikaya & Küçük, 2022).

پوشش گیاهی به‌عنوان بستر اصلی سوخت، نقش مهمی در اشتعال‌پذیری و گسترش آتش دارد و ویژگی‌هایی مانند شدت، سرعت پیشروی و الگوی توسعه حریق را تحت تأثیر قرار می‌دهد. علیرغم کاربرد گسترده شاخص‌های مختلف گیاهی به‌عنوان شاخص‌های بیوفیزیکی، در این پژوهش از دو شاخص کلیدی شامل NDVI و TVDI بهره گرفته شد. شاخص NDVI از محصول MOD13A3 سنجنده مودیس استخراج گردید و به‌صورت معادله (۲) تعریف می‌شود:

$$NDVI = \frac{\rho_{NIR} - \rho_{red}}{\rho_{NIR} + \rho_{red}} \quad (2)$$

در این معادله، ρ_{NIR} و ρ_{red} به ترتیب بیانگر میزان بازتاب در طول موج‌های قرمز ($0.6-0.7 \mu m$) و مادون قرمز نزدیک ($1.1-1.3 \mu m$) هستند. شاخص NDVI در بازه -1 تا $+1$ تغییر می‌کند؛ مقادیر بالاتر این شاخص نشان‌دهنده تراکم بیشتر زی‌توده سبز، محتوای کلروفیلی بالاتر و در نتیجه ظرفیت فتوسنتزی بیشتر پوشش گیاهی است؛ در حالی که مقادیر پایین‌تر حاکی از کاهش سلامت گیاه، تنش ناشی از افت کلروفیل و تغییرات ساختاری برگ در اثر پژمردگی می‌باشد (Rouse, Haas, Schell & Deering, 1974). لازم به ذکر است که شاخص NDVI بیانگر تراکم زی‌توده سبز و میزان بار سوخت بالقوه بوده و به‌تنهایی قادر به تفکیک مستقیم پوشش خشک از مرطوب یا تیپ‌های مختلف پوشش گیاهی نمی‌باشد؛ از این رو در این مطالعه به منظور لحاظ نمودن وضعیت رطوبتی و قابلیت اشتعال سوخت، به‌طور همزمان از شاخص TVDI و متغیرهای اقلیمی مرتبط با رطوبت استفاده شد تا تمایز نسبی پهنه‌های مستعد اشتعال از پوشش‌های مرطوب‌تر امکان‌پذیر گردد.

شاخص TVDI بر پایه یک فضای دو بُعدی حاصل از ترکیب شاخص NDVI و دمای سطح زمین (LST^2) تعریف می‌شود و با وضعیت پوشش گیاهی و رطوبت خاک ارتباط دارد. در این پژوهش، از داده‌های روزانه (MOD11A1) و هشت روزه (MOD11A2) دمای سطح زمین مودیس با تفکیک مکانی یک کیلومتر استفاده شد (<http://reverb.echo.nasa.gov>). بر اساس روش سندهولت و همکاران (Sandholt, Rasmussen & Andersen, 2002) فضای پراکنش NDVI-LST به‌صورت یک مثلث تعریف می‌شود: در فضای TVDI، ضلع افقی پایین نشان‌دهنده شرایط مرطوب و ضلع شیب‌دار بالا بیانگر شرایط خشک است. شیب ضلع خشک منفی است؛ یعنی با افزایش تراکم پوشش گیاهی، دمای سطح زمین کاهش می‌یابد. شیب ضلع مرطوب مثبت بوده و افزایش پوشش گیاهی و رطوبت کافی خاک موجب افزایش تدریجی دما می‌شود. TVDI با رطوبت خاک رابطه معکوس دارد و بین صفر (مرطوب) تا یک (خشک) تغییر می‌کند. مقدار TVDI هر پیکسل نیز با درونیابی خطی بین حداقل و حداکثر بر اساس رابطه (۳) محاسبه می‌شود:

$$TVDI = (LST - LST_{min}) / (LST_{max} - LST_{min}) \quad (3)$$

در این رابطه، LST دمای سطح پیکسل مورد نظر، LST_{max} بیشینه دمای سطح متناظر با مقدار NDVI همان پیکسل و LST_{min} کمینه دمای سطح در همان مقدار NDVI را نشان می‌دهد. مقادیر حداکثر و حداقل دمای سطح زمین (دو ضلع خشک و مرطوب) برای هر سطح NDVI از طریق برازش خطی معادلات (۴) و (۵) محاسبه می‌شوند:

$$LST_{max} = a_1 + b_1 \times NDVI \quad (۴)$$

$$LST_{min} = a_2 + b_2 \times NDVI \quad (۵)$$

در روابط فوق، ضرایب a_1 و a_2 عرض از مبدأ خطوط برازش یافته بر مقادیر بیشینه و کمینه دمای سطح زمین هستند و ضرایب b_1 و b_2 نیز شیب این خطوط را مشخص می‌کنند که مرزهای خشک و مرطوب فضای NDVI-LST را تشکیل می‌دهند. این ضرایب از برازش حداقل مربعات و داده‌های واقعی برآورد می‌شوند (Sandholt et al., 2002).

در میان متغیرهای مورد بررسی، جهت شیب به‌صورت طبقه‌بندی شده (اسمی) و مابقی متغیرها به‌صورت کمی و رتبه‌ای با مقادیر پیوسته در نظر گرفته شدند. برای همسانی با بازه زمانی رخدادهای آتش‌سوزی (۱۴۰۲-۱۴۰۳)، متغیرهای محیطی نیز برای همین دوره استخراج شدند. آماده‌سازی و استخراج شاخص‌ها در سامانه گوگل ارث انجین (GEE^1) و نرم‌افزار ArcGIS10.8.2 انجام و پردازش، تحلیل و مدل‌سازی داده‌ها با نرم‌افزار R4.5.1 صورت گرفت.

مدل‌سازی مکانی خطر آتش‌سوزی

با توجه به ماهیت مخرب آتش‌سوزی، انجام پژوهش‌های میدانی مبتنی بر رخدادهای واقعی عملاً امکان‌پذیر نیست؛ بنابراین برای تبیین دقیق‌تر الگو، رفتار و پیامدهای آتش، از مدل‌های شبیه‌سازی کامپیوتری بر اساس داده‌های میدانی استفاده می‌شود. در این پژوهش، پیش‌بینی وقوع آتش‌سوزی به دو روش یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN^2) و حداکثر آنتروپی ($MaxEnt^3$) و همچنین دو رویکرد رگرسیونی شامل مدل خطی تعمیم‌یافته (GLM^4) و مدل جمعی تعمیم‌یافته (GAM^5) با ده تکرار در محیط نرم‌افزار آماری- برنامه‌نویسی R انجام شد.

شبکه عصبی مصنوعی (ANN) شاخه‌ای از هوش مصنوعی است که برای پردازش داده‌ها و حل مسائل متنوعی مانند بهینه‌سازی، پیش‌بینی، شناسایی و کنترل کاربرد دارد (Alimahmoodi Sarab et al., 2012). هر شبکه شامل مجموعه‌ای از نورون‌ها و پیوندهای وزنی است که هر نورون سیگنال ورودی را دریافت، خروجی را محاسبه و به نورون‌های دیگر منتقل می‌کند (Chouai, Laugier & Richon, 2002). مدل خطی تعمیم‌یافته (GLM)، مدلی پارامتری و تعمیم‌یافته از رگرسیون خطی است که رابطه میان متغیرهای تبیینی و پاسخ را از طریق پارامتر برآورد ضرایب رگرسیونی و فواصل اطمینان تحلیل می‌کند. این رویکرد، زمانی کاربرد دارد که داده‌ها توزیع نرمال نداشته یا سایر مدل‌های رگرسیونی کارایی لازم را ندارند (He, Zheng, Li & Qian, 2007). در GLM ، فرض می‌شود متغیر وابسته از توزیع نرمال پیروی کرده، واریانس آن ثابت و رابطه با متغیرهای مستقل خطی است (Guisan, Edwards & Hastie, 2002). مدل‌های جمعی تعمیم‌یافته (GAM) شکل توسعه یافته‌ای از GLM هستند که انعطاف‌پذیری بیشتری داشته و با هدف بهبود دقت پیش‌بینی، شناسایی الگوهای غیرخطی و روابط غیریکنواخت بین متغیرهای وابسته و تبیینی به‌کار می‌روند. در این مدل ناپارامتری، شکل تابع پاسخ بر اساس داده‌ها تعیین شود. فرض بر این است که متغیر وابسته Y از توزیع نمایی با میانگین $\mu = E(Y|X_1, \dots, X_p)$ پیروی کرده و از طریق یک تابع پیوند به متغیرهای مستقل متصل می‌شود (Hastie & Tibshirani, 1987). مدل حداکثر آنتروپی ($MaxEnt$) بر این اساس شکل گرفته که اگر x یک موقعیت تصادفی در محدوده مورد مطالعه باشد، $\pi(x)$ توزیع احتمال هدف در آن مکان را نشان می‌دهد؛ به گونه‌ای که مقادیر آن مثبت و مجموع آن در کل منطقه برابر با یک است. در این چارچوب، $y=1$ به معنای وقوع پدیده هدف است و $P(y=1|x)$ احتمال وقوع آتش‌سوزی در موقعیت x را بیان می‌کند که از طریق $P(x|y=1)$ محاسبه می‌شود:

$$P(y=1|x) = \frac{P(y=1)p(x|y=1)}{p(x)} = \frac{p(y=1)\pi(x)}{\frac{1}{|x|}} \quad (۶)$$

1- Google Earth Engine

2- Artificial Neural Network

3- Maximum Entropy

4- Generalized Linear Model

5- Generalized Additive Model

در رابطه (۶)، $P(y=1)$ نرخ رخداد هدف و $|x|$ تعداد پیکسل‌های کل منطقه مطالعاتی است. از آنجایی که $P(y=1)$ را نمی‌توان دقیقاً از داده‌های رخداد آتش‌سوزی تعیین کرد، الگوریتم حداکثر آنتروپی به‌جای پیش‌بینی مستقیم $P(y=1|x)$ ، از توزیع $\pi(x)$ بر اساس داده‌های موجود استفاده می‌کند (Phillips, Anderson & Schapire, 2006).

ارزیابی و اعتبارسنجی مدل‌ها

برای افزایش قابلیت اطمینان الگوریتم‌های داده کاوی و کاهش عدم قطعیت، ارزیابی مدل‌ها در چندین تکرار انجام شد و از روش ارزیابی تقاطعی k -fold برای جلوگیری از بیش‌برازش استفاده گردید. منحنی مشخصه عملکرد گیرنده (ROC^1) به‌دلیل توانایی نمایش عملکرد کلی مدل و تأثیر شاخص‌هایی مانند حساسیت (Sensitivity)، اختصاصی بودن (Specificity)، نرخ مثبت درست (TPR^2)، نرخ منفی درست (TNR^3)، نرخ مثبت نادرست (FPR^4) و نرخ منفی نادرست (FNR^5) به‌کار گرفته شد. این منحنی با ترسیم حساسیت در برابر اختصاصی بودن، کیفیت مدل را ارزیابی می‌کند و در بیان تحلیلی آن، معیار سطح زیر منحنی (AUC^6) با توجه به معادله (۷) محاسبه می‌شود:

$$AUC = \int_0^1 f(FPR) dFPR = 1 - \int_0^1 f(TPR) d(TPR) \quad (7)$$

مقدار شاخص AUC بین صفر تا یک متغیر است که مقادیر بالاتر آن نشان‌دهنده عملکرد بهتر مدل می‌باشند. با استفاده از عناصر ماتریس خطا (TP، TN، FP و FN) برای داده‌های آزمون، حساسیت (معادل TPR) و اختصاصی بودن (معادل FPR) از روابط (۸ و ۹) محاسبه می‌شوند:

$$TPR = \frac{TP}{TP + FN} \quad (8)$$

$$FPR = \frac{FP}{FP + TN} \quad (9)$$

حساسیت (نرخ مثبت درست) نسبت پیکسل‌هایی را نشان می‌دهد که آتش‌سوزی در آن‌ها رخ داده و مدل نیز به‌درستی وقوع آتش‌سوزی را تشخیص داده است. در حالی‌که، اختصاصی بودن (نرخ منفی درست) نسبت پیکسل‌هایی را بیان می‌کند که آتش‌سوزی در آن‌ها رخ نداده و مدل به‌درستی عدم وقوع را شناسایی کرده است. به عبارت ساده‌تر، حساسیت درصد نقاط حضور درست و اختصاصی بودن درصد نقاط غیاب درست شناسایی شده توسط مدل می‌باشد.

برای ارزیابی مدل، آماره مهارت واقعی (TSS^7) نیز به‌کار گرفته شد که هم خطاهای آمیسیون و هم کمیسیون را در نظر می‌گیرد و عملکرد پیش‌بینی را به‌طور کامل ارزیابی می‌کند. مقدار TSS بر اساس رابطه (۱۰) محاسبه می‌شود:

$$TSS = TPR - FPR \quad (10)$$

شاخص TSS در بازه -۱ تا +۱ تغییر می‌کند؛ مقدار +۱ نشان‌دهنده توافق کامل، مقادیر ۰/۷ تا ۰/۹ عملکرد متوسط تا خوب مدل و مقادیر صفر یا منفی کارایی برابر یا کمتر از حالت تصادفی را نشان می‌دهند (Allouche, Tsoar & Kadmon, 2006).

1- Receiver Operating Characteristic
2- True Positive Rate
3- True Negative Rate
4- False Positive Rate
5- False Negative Rate
6- Area Under the Curve
7- True Skill Statistic

ایجاد مدل اجماعی

با توجه به اینکه عدم قطعیت در پیش‌بینی مدل‌ها می‌تواند تصمیم‌گیری را محدود یا غیر متمرکز کند، پس از ارزیابی مدل‌ها، نتایج چند مدل در قالب یک مدل اجماعی ترکیب شد تا خطا کاهش و اطمینان افزایش یابد. در این رویکرد، نقشه حساسیت به آتش‌سوزی با میانگین وزنی مقادیر AUC مدل‌ها به شرح رابطه (۱۱) ساخته می‌شود:

$$FS_i = \frac{\sum_j (AUC_{mj} \times mji)}{\sum_j AUC_{mj}} \quad (11)$$

که در آن؛ FS_i حساسیت به آتش‌سوزی در لامین سلول و mji احتمال وقوع آتش‌سوزی است که توسط مدل j در همان سلول پیش‌بینی شده است (Zare Chahouki, Karami & Piri Sahragard, 2022).

پس از تهیه نقشه‌های حساسیت به آتش، نقشه‌های پیوسته برای تحلیل مقایسه‌ای با روش طبقه‌بندی شکست‌های طبیعی^۱ به طبقات حساسیت بسیار کم، کم، متوسط، زیاد و خیلی زیاد تقسیم شدند.

تعیین سهم عوامل محیطی در وقوع آتش‌سوزی

روش‌های ارزیابی اهمیت متغیرها به دو گروه تقسیم می‌شوند: روش‌هایی که از اطلاعات مدل بهره می‌برند و روش‌هایی که مستقل از مدل هستند. استفاده از رویکرد مبتنی بر مدل مزیت دارد، زیرا ارتباط مستقیمی با عملکرد مدل برقرار کرده و امکان لحاظ نمودن ساختار همبستگی میان متغیرهای مستقل در محاسبه اهمیت را فراهم می‌سازد (Gholami, Mohamadifar, Rahimi, Kaskaoutis & Collins, 2021). یکی از روش‌های مؤثر برای سنجش سهم متغیرها، رویکرد مبتنی بر نظریه بازی و به‌ویژه مقادیر شاپلی^۲ می‌باشد. این شاخص، میانگین سهم هر متغیر در تمام ترکیب‌های ممکن را محاسبه نموده و درصد مشارکت آن در پیش‌بینی متغیر وابسته را مشخص می‌سازد. سهم هر متغیر به تعامل آن با سایر متغیرها بستگی دارد؛ لذا، برای حصول برآورد دقیق‌تر، محاسبه شاپلی باید برای هر متغیر چندین مرتبه تکرار شود (Myerson, 2013).

نتایج و بحث

اعتبارسنجی عملکرد مدل‌های پیش‌بینی حساسیت به آتش‌سوزی

نتایج حاصل از میانگین‌گیری معیارهای ارزیابی در تکرارهای مختلف نشان داد که کارایی مدل‌ها یکسان نیست و هر الگوریتم رفتار متفاوتی در پیش‌بینی خطر آتش‌سوزی دارد (جدول ۱). مقادیر AUC بیانگر آن است که دو مدل MaxEnt (۰/۹۲) و مدل اجماعی (۰/۹۴) توانایی بالایی در تفکیک نقاط حساس و غیر حساس دارند. این اختلاف نشان می‌دهد که مدل اجماعی با ترکیب پیش‌بینی مدل‌های منفرد، خطاها و آرببی هر مدل را کاهش داده و تعاملات پیچیده میان متغیرهای اقلیمی و محیطی را بهتر مدل‌سازی می‌کند، بنابراین شناسایی نقاط پرخطر با دقت بیشتری انجام می‌شود. پژوهش‌های پیشین (Eskandari et al., 2020; Mohajane et al., 2021; Sarkar et al., 2024) نیز کارایی مدل‌های ترکیبی را در بهبود پیش‌بینی خطر آتش‌سوزی تأیید می‌کنند. شاخص TSS که توانایی مدل در تشخیص همزمان نقاط حضور و غیاب و خطاهای آمیسیون و کمیسسیون را می‌سنجد، بالاترین مقدار را در مدل اجماعی (۰/۷۴) داشت و در MaxEnt و GAM به ترتیب ۰/۷۱ و ۰/۷۲ بود. با این حال، دقت مدل اجماعی به کیفیت مدل‌های منفرد وابسته است و ضعف هر مدل می‌تواند بر خروجی نهایی اثرگذار باشد؛ نکته‌ای که در مطالعه گذشته نیز گزارش شده است (Gholami et al., 2021). در مقابل، GLM به دلیل ماهیت خطی خود قادر به مدل‌سازی روابط پیچیده و غیرخطی میان عوامل اقلیمی، توپوگرافی، زیستی و انسانی نیست و این محدودیت موجب کاهش کارایی در تعیین مرزهای تصمیم و شناسایی الگوهای پیچیده می‌شود (Zhou, Qiu & Zhang, 2023).

1- Natural breaks/ Jenks

2- Shapley

جدول ۱- میانگین شاخص‌های ارزیابی کارایی مدل‌های رگرسیونی و یادگیری ماشین در پیش‌بینی حساسیت به آتش‌سوزی
Table 1- Mean Values of the Performance Evaluation Indices of Regression and Machine Learning Models for Predicting Fire Susceptibility

شاخص‌های ارزیابی (Evaluation metrics)	ANN	GLM	GAM	MaxEnt	مدل اجماعی (Ensemble model)
سطح زیر منحنی (AUC)	0.89	0.88	0.91	0.92	0.94
آماره مهارت واقعی (TSS)	0.69	0.54	0.72	0.71	0.74
حساسیت (Sensitivity)	90.27	61.42	94.48	93.23	94.46
اختصاصی بودن (Specificity)	78.45	92.15	77.02	77.45	79.85

تحلیل تطبیقی اهمیت متغیرها در مدل‌های منفرد و اجماعی

بررسی مقایسه‌ای اهمیت متغیرها نشان داد که بروز و گسترش آتش‌سوزی در جنگل‌ها و مراتع عمدتاً تحت تأثیر ترکیبی از عوامل پوشش گیاهی، اقلیمی و توپوگرافی قرار دارد. نتایج جدول ۲ نشان می‌دهد که شاخص NDVI در مدل‌هایی چون GAM و MaxEnt از اهمیت بالایی برخوردار است و در مدل اجماعی نیز در درجه دوم اهمیت قرار گرفته است؛ موضوعی که نقش تعیین‌کننده تراکم و وضعیت پوشش گیاهی را در فراهم‌سازی یا کاهش مواد سوختی تأیید می‌کند. بارندگی مهم‌ترین متغیر در مدل ANN و مدل اجماعی و از متغیرهای مهم در سایر مدل‌هاست و بیانگر اهمیت رطوبت و خشکی در قابلیت اشتعال و گسترش آتش‌سوزی می‌باشد. متغیرهای توپوگرافی نظیر ارتفاع به‌ویژه در مدل‌های MaxEnt، ANN و اجماعی برجسته شده‌اند که تأثیر ناهمواری زمین بر رفتار آتش، سرعت گسترش و الگوی جریان هوا را نشان می‌دهد. شاخص رطوبت توپوگرافیک (TWI) و رطوبت نسبی نیز در مدل‌های GLM و GAM اهمیت بیشتری داشته‌اند و حساسیت این مدل‌ها به تغییرات رطوبتی و روابط غیرخطی میان متغیرها را آشکار می‌سازند. در مقابل، متغیرهای انسانی مانند فاصله از سکونتگاه‌ها و متغیرهای اقلیمی مانند سرعت باد سهم کمتری در تعیین خطر وقوع آتش‌سوزی دارند.

نتایج نشان داد که ارتفاع یکی از مهم‌ترین عوامل مؤثر بر الگوی خطر است؛ به‌طوری‌که با افزایش ارتفاع، کاهش دما و تراکم پوشش گیاهی، میزان مواد سوختی کاهش می‌یابد؛ در حالی‌که، نواحی کم‌ارتفاع با دمای بالاتر و پوشش گیاهی متراکم‌تر، مستعد آتش‌سوزی هستند (Pragya et al., 2023). این الگو با یافته‌های جانی‌زاده و همکاران (Janizadeh et al., 2023) در جنگل‌های مازندران نیز همخوانی دارد. همچنین، می‌شرا و همکاران (Mishra, Panthi, Poudel & Ghimire, 2023) گزارش کرده‌اند که عوامل توپوگرافی و زیست‌اقلیمی نقش پررنگ‌تری نسبت به عوامل انسان‌ساخت در بروز آتش‌سوزی دارند؛ نتیجه‌ای که با یافته‌های این مطالعه مطابقت دارد. شاخص NDVI نیز از پارامترهای مهم در پیش‌بینی خطر آتش‌سوزی است و بارندگی علاوه بر تأثیر مستقیم بر قابلیت اشتعال، از طریق کنترل وضعیت رطوبتی و تراکم پوشش گیاهی، نقش غیر مستقیم مهمی در وقوع آتش ایفا می‌کند (Moradi & Ahmadi Sani, 2025). کاهش بارندگی و تشدید خشکسالی موجب خشک شدن زی‌توده گیاهی و افزایش مواد سوختی شده و شرایط را برای بروز آتش‌سوزی‌های گسترده‌تر فراهم می‌کند. اهمیت NDVI در مطالعه حامدی و همکاران (Hamed et al., 2020) نیز تأیید شده است. در میان عوامل انسانی، فاصله از سکونتگاه‌ها بیشترین تأثیر را داشته است؛ نتیجه‌ای که با یافته‌های مرادی و احمدی ثانی (Moradi & Ahmadi Sani, 2025) همخوانی دارد. نزدیکی به مناطق مسکونی با فعالیت‌هایی مانند گردشگری، چرای دام و سوزاندن بقایای کشاورزی مرتبط است که می‌توانند به‌عنوان محرک آغاز آتش، عمل کنند. با این حال، احتمال دارد نقش واقعی شبکه‌جاده‌ها کمتر از مقدار واقعی برآورد شده باشد، زیرا در این پژوهش صرفاً جاده‌های اصلی لحاظ شده‌اند. از سوی دیگر، مناطق مرتفع و پرشیب به دلیل دشواری دسترسی، کمتر تحت تأثیر فعالیت‌های انسانی قرار دارند و همین ویژگی می‌تواند نقش بازدارنده‌ای در افزایش احتمال وقوع آتش‌سوزی ایفا کند.

در مجموع، خطر آتش‌سوزی در منطقه، عمدتاً تابعی از تعامل پوشش گیاهی، خشکی و ویژگی‌های توپوگرافی است و مدل اجماعی با ترکیب خروجی مدل‌های منفرد و متعادل‌سازی وزن متغیرهای مهم، تصویری جامع و دقیق از الگوی مکانی خطر آتش‌سوزی ارائه می‌دهد. این رویکرد با بازنمایی همزمان عوامل طبیعی و انسانی، توانایی بالایی در شناسایی مناطق مستعد آتش‌سوزی دارد؛ این نتایج با یافته‌های اسکندری و همکاران (Eskandari et al., 2020) همسو می‌باشد.

جدول ۲- اهمیت متغیرها بر اساس مقادیر شاپلی در مدل‌های مختلف

Table 2- Variable importance based on Shapley values across different models


مدل اجماعی (Ensemble model)	MaxEnt	GAM	GLM	ANN	متغیرها (Variables)
16.10	20.14	7.58	7.70	28.99	ارتفاع (Elevation)
1.31	0.34	0.78	0.05	0.01	جهت (Aspect)
2.66	2.63	6.14	1.84	0.02	فاصله از رودخانه (Distance to river)
3.95	3.14	4.22	8.02	0.44	فاصله از جاده (Distance to road)
4.42	3.77	5.60	8.31	4.08	فاصله از سکونتگاه‌ها (Distance to settlements)
19.12	26.85	22.15	21.11	6.35	شاخص اختلاف نرمال شده پوشش گیاهی (NDVI)
19.62	14.97	15.10	14.55	33.88	بارندگی (Precipitation)
4.52	2.36	9.32	0.39	6.00	رطوبت نسبی (Relative humidity)
8.45	18.65	10.37	0.57	4.23	شیب (Slope)
3.28	2.86	2.21	5.75	2.29	درجه حرارت (Temperature)
2.14	2.20	4.73	1.28	0.36	شاخص خشکی - دمایی گیاه (TVDI)
10.07	0.87	6.41	27.33	5.68	شاخص رطوبت توپوگرافیک (TWI)
4.36	1.26	5.40	3.10	7.69	سرعت باد (Wind speed)

الگوی مکانی خطر آتش‌سوزی

نقشه‌های طبقه‌بندی شده حساسیت به آتش‌سوزی استخراج شده از چهار مدل منفرد (شکل ۲) و اجماع آن‌ها (شکل ۳) امکان مقایسه بصری الگوی مکانی خطر و عملکرد هر مدل را فراهم می‌کنند. این نقشه‌ها، الگوهای مشخصی از توزیع مکانی طبقات مختلف خطر را نشان می‌دهند. مقادیر پیش‌بینی شده توسط هر مدل، احتمال تعلق هر پیکسل به کلاس آتش (۱) را نشان می‌دهند و می‌توان آن‌ها را به‌عنوان احتمال وقوع یا آغاز آتش‌سوزی تفسیر کرد. تحلیل تطبیقی نقشه‌ها نشان داد که علیرغم همخوانی کلی در شناسایی برخی مناطق پرخطر، تفاوت‌های قابل توجهی در نحوه توزیع فضایی طبقات حساسیت میان مدل‌ها وجود دارد که ناشی از تفاوت در ساختار آماری و عملکرد الگوریتم‌های به‌کار رفته است. این الگوهای مکانی، حاصل روابط آماری میان رخداد آتش‌سوزی و عوامل محیطی و انسانی هستند که در مطالعات مشابه نیز گزارش شده است (Eskandari et al., 2020; Mohajane et al., 2021).


تفاوت در توزیع طبقات خطر میان مدل‌ها بیانگر حساسیت هر الگوریتم به وزن‌دهی متغیرهای ورودی و توان متفاوت آن‌ها در استخراج الگوهای پیچیده مکانی است. در این میان، مدل‌های اجماعی با ادغام پیش‌بینی‌های مدل‌های منفرد، تصویری پایدارتر و واقع‌گرایانه‌تر از الگوی خطر ارائه می‌دهند، مطابق با یافته‌های بهادری و همکاران (Bahadori et al., 2023) که نشان دادند مدل‌های تجمیعی نسبت به مدل‌های منفرد کارایی بالاتری در نقشه‌برداری حساسیت و بازنمایی پیچیدگی‌های فضایی و عدم قطعیت دارند. بنابراین، بهره‌گیری از رویکرد چند مدلی، به‌ویژه مدل اجماعی، نقش کلیدی در افزایش دقت پیش‌بینی و پشتیبانی از تصمیم‌گیری‌های مدیریتی برای کاهش خطر آتش‌سوزی دارد.

نقشه حاصل از تجمیع ارائه شده در شکل ۳، نشان می‌دهد که کانون‌های خطر آتش‌سوزی تقریباً در سراسر استان پراکنده شده‌اند و تمرکز مشخصی در یک ناحیه خاص مشاهده نمی‌شود. این الگوی پراکنش گسترده نشان می‌دهد که خطر آتش‌سوزی پدیده‌ای فراگیر و چند عاملی است که تحت تأثیر ترکیبی پیچیده از شرایط اقلیمی، پوشش گیاهی، ویژگی‌های توپوگرافی و فعالیت‌های انسانی شکل می‌گیرد. چنین الگویی بازتاب‌دهنده ارتباط معنادار میان رخداد آتش‌سوزی و متغیرهای محیطی است و بیان می‌کند که تعامل این عوامل موجب شکل‌گیری توزیعی غیر متمرکز و پراکنده در سطح استان می‌شود. این نتیجه با یافته‌های اسکندری و همکاران (Eskandari et al., 2020) و موهاجان و همکاران (Mohajane et al., 2021) همخوانی دارد و بر ضرورت اتخاذ رویکردهای مدیریتی جامع و منطقه محور جهت پیشگیری و کنترل آتش‌سوزی در سطح استان تأکید می‌کند.



شکل ۲- نقشه‌های حساسیت به آتش‌سوزی جنگل‌ها و مراتع در استان مازندران بر اساس مدل‌های منفرد

Fig.2. Fire Susceptibility Maps of Forests and Rangelands in Mazandaran Province Based on Individual Models



شکل ۳- نقشه حساسیت به آتش‌سوزی جنگل‌ها و مراتع در استان مازندران بر اساس مدل اجماعی


Fig.3. Fire Susceptibility Map of Forests and Rangelands in Mazandaran Province Based on the Ensemble Model

پاسخ آتش‌سوزی به مهم‌ترین متغیرهای محیطی

منحنی‌های پاسخ آتش‌سوزی نسبت به مهم‌ترین متغیرهای مؤثر بر اساس مدلی که بالاترین دقت پیش‌بینی را داشت، ترسیم شدند (شکل ۴). این منحنی‌ها رابطه بین هر متغیر و احتمال وقوع آتش‌سوزی را نشان می‌دهند و امکان تعیین آستانه‌های بحرانی را فراهم می‌کنند. نتایج حاکی از آن است که با افزایش مقادیر مثبت شاخص NDVI، احتمال وقوع آتش‌سوزی روند افزایشی پیدا می‌کند؛ موضوعی که با یافته‌های چوویکو و کونگالتون (Chuvieco & Congalton, 1989) همخوانی دارد و تأکید می‌کند که افزایش سوخت گیاهی در پوشش‌های متراکم، نقش اصلی را در افزایش حساسیت ایفا می‌کند. با این حال، کاهش

احتمال آتش‌سوزی در سطوح بسیار بالای NDVI نشانی می‌دهد که ساختار پوشش، به ویژه کاهش در زیر تاج‌های متراکم، نقش تعیین‌کننده‌ای در تبیین الگوی خطر آتش دارد. نتایج همچنین نشان داد که احتمال وقوع آتش‌سوزی در ارتفاعات متوسط بیشتر است و با افزایش ارتفاع، حساسیت منطقه به آتش‌سوزی کاهش می‌یابد؛ به‌طوری‌که کمترین رخداد آتش‌سوزی در ارتفاعات بالاتر از ۲۵۰۰ متر مشاهده شد. این الگو با نتایج مطالعات سیوری‌کایا و کوچوک (Sivrikaya & Küçük, 2022) و ادب و همکاران (Adab et al., 2013) سازگار است؛ زیرا در ارتفاعات بالا، به‌دلیل کاهش دما، محدودیت رشد پوشش گیاهی و افزایش سطوح سنگی، میزان سوخت در دسترس کمتر بوده و گسترش آتش دشوارتر می‌شود. در مقابل، ارتفاعات پایین‌تر به‌واسطه فعالیت‌های انسانی بیشتر و شرایط اقلیمی مساعدتر، بستر وقوع آتش را فراهم می‌سازند (Azizianpour, Mirzaei, Omidipour, & Jafarian, 2025).

شیب دامنه نیز از عوامل کلیدی در شکل‌دهی الگوی خطر آتش‌سوزی می‌باشد؛ به طوری‌که با افزایش شیب، به خصوص در شیب‌های بیش از ۱۰ درصد، حساسیت به طور محسوسی افزایش می‌یابد و بیشترین فراوانی آتش‌سوزی‌ها نیز در شیب‌های بالاتر از ۳۵ درصد مشاهده می‌گردد. این موضوع با نتایج فرهی آشتیانی و همکاران (Farahi Ashtiani, Daryaei & Mohamadi, 2013) و سیوری‌کایا و کوچوک (Sivrikaya & Küçük, 2022) مطابقت دارد. شیب علاوه بر افزایش سرعت پیشروی شعله‌ها، از طریق تأثیر بر رطوبت، تابش و چگالی سوخت، توسعه آتش را تسهیل می‌کند (Bountzouklis, Fox & Di Bernardino, 2022). همچنین، گزارش شده که نواحی با شیب ملایم به دلیل دسترسی بیشتر انسان، به وقوع آتش مستعدتر هستند و سرعت گسترش آتش در بالادست شیب‌های تند افزایش می‌یابد (Ghorbanzadeh & Blaschke, 2018). در نهایت، رابطه معکوس میزان بارندگی با احتمال وقوع آتش‌سوزی نشان داد که بیشترین حساسیت در مناطق با بارندگی حداکثر ۵۰۰ میلی‌متر مشاهده می‌شود. این الگو با نتایج فرهی آشتیانی و همکاران (Farahi Ashtiani et al., 2013) و اسکندری و همکاران (Eskandari et al., 2020) مطابقت دارد و تأکید می‌کند که افزایش رطوبت سوخت، قابلیت اشتعال را کاهش می‌دهد. با وجود این، ماهیت پیچیده رابطه بین بارش و آتش‌سوزی - نظیر افزایش بیوماس در مناطق پربارش و تأثیر بلندمدت آن بر افزایش بار سوخت - نیازمند بررسی هم‌زمان دینامیک پوشش گیاهی و شرایط اقلیمی کوتاه‌مدت است؛ موضوعی که واسرمن و مولر (Wasserman & Mueller, 2023) نیز بر آن تأکید کردند.



شکل ۴- نمایش بصری اثر مهم‌ترین عوامل مؤثر بر احتمال پیش‌بینی شده وقوع آتش‌سوزی بر اساس مدل MaxEnt

Fig.4. Visual Representation of the Effects of the Most Influential Factors on the Predicted Probability of Fire Occurrence Based on the MaxEnt Model

نتیجه‌گیری

یافته‌های این پژوهش نشان داد که هدف اصلی تحقیق در بهبود دقت مکانی پیش‌بینی خطر آتش‌سوزی از طریق به‌کارگیری رویکرد چندمدلی و توسعه مدل اجماعی به‌طور موفقیت‌آمیز محقق شده است؛ به‌طوری‌که مدل اجماعی نسبت به مدل‌های منفرد عملکرد دقیق‌تر و پایدارتری در شناسایی پهنه‌های پرخطر ارائه داد و با کاهش عدم قطعیت ناشی از تفاوت ساختار الگوریتم‌ها، توانست الگوی مکانی خطر را واقع‌گرایانه‌تر بازنمایی کند. تحلیل اهمیت متغیرها و منحنی‌های پاسخ نشان داد که پوشش گیاهی، میزان رطوبت و ویژگی‌های توپوگرافی، به‌ویژه ارتفاع و شیب، مهم‌ترین عوامل کنترل‌کننده حساسیت به آتش‌سوزی در استان مازندران هستند، در حالی‌که نقش عوامل انسانی در مقیاس منطقه‌ای کمتر از عوامل طبیعی برآورد شد.

الگوی پراکنش مکانی حاصل از مدل اجماعی نیز نشان داد که خطر آتش‌سوزی ماهیتی پراکنده، چندعاملی و فاقد تمرکز مکانی مشخص دارد، که این امر ضرورت طراحی راهبردهای پیشگیرانه منطقه محور، به ویژه در نواحی با تراکم سوخت گیاهی و شرایط اقلیمی با رطوبت کمتر را برجسته می‌سازد. نقشه‌های پیوسته خطر می‌توانند به‌عنوان ابزار پشتیبان تصمیم‌گیری برای اولویت‌بندی اقدامات پیشگیرانه، مدیریت سوخت، استقرار سامانه‌های پایش و هشدار سریع و تخصیص بهینه منابع اطفای حریق در مقیاس استانی به کار گرفته شوند. با این حال، محدودیت‌هایی نظیر استفاده از داده‌های رخداد در یک بازه زمانی نسبتاً کوتاه، ساده‌سازی متغیرهای انسانی و در نظر نگرفتن پویایی کوتاه‌مدت پوشش گیاهی و تغییرات اقلیمی آینده نشان می‌دهد که در پژوهش‌های آتی به‌کارگیری داده‌های زمانی پرتراکم‌تر، شاخص‌های رفتاری و کاربری اراضی پویا و مدل‌های مکانی- زمانی پیشرفته می‌تواند دقت و قابلیت اتکای پیش‌بینی خطر آتش‌سوزی را بیش از پیش افزایش دهد.

حامی مالی

این مقاله با حمایت پژوهشی دانشگاه محقق اردبیلی از طرح پژوهشی به شماره ۱۴۰۳/د/۹/۲۷۱۴۰ استخراج گردیده است.

References

- Abedi, R. (2022). Application of multi-criteria decision making models to forest fire management. *International Journal of Geoheritage and Parks*, 10(1), 84-96. <https://doi.org/10.1016/j.ijgeop.2022.02.005>
- Achu, A. L., Thomas, J., Aju, C. D., Gopinath, G., Kumar, S., & Reghunath, R. (2021). Machine-learning modelling of fire susceptibility in a forest-agriculture mosaic landscape of southern India. *Ecological Informatics*, 64, 101348. <https://doi.org/10.1016/j.ecoinf.2021.101348>
- Adab, H., Kanniah, K. D., & Solaimani, K. (2013). Modeling forest fire risk in the northeast of Iran using remote sensing and GIS techniques. *Natural Hazards*, 65(3), 1723-1743. <https://doi.org/10.1007/s11069-012-0450-8>
- Alimahmoodi Sarab, S., Fegghi, J., & Jabarian Amiri, B. (2012). Predicting the occurrence of natural fires in forests and ranges using Artificial Neural Networks (Case study: Zagros region, Izeh township). *Iranian Journal of Applied Ecology*, 1(2), 75-86. [In Persian] <https://dor.isc.ac/dor/20.1001.1.24763128.1391.1.2.7.1>
- Allouche, O., Tsoar, A., & Kadmon, R. (2006). Assessing the accuracy of species distribution models: prevalence, kappa and the true skill statistic (TSS). *Journal of Applied Ecology*, 43(6), 1223-1232.
- Azizianpour, S., Mirzaei, J., Omidipour, R., & Jafarian, N. (2025). Machine learning-based forest fire susceptibility prediction in semiarid oak forests of western Iran. *ECOPERSIA* 13(1), 49-67. <https://doi.org/10.22034/ECOPERSIA.13.1.49>
- Bahadori, N., Razavi-Termeh, S. V., Sadeghi-Niaraki, A., Al-Kindi, K. M., Abuhmed, T., Nazeri, B., & Choi, S. M. (2023). Wildfire susceptibility mapping using deep learning algorithms in two satellite imagery dataset. *Forests*, 14(7), 1325. <https://doi.org/10.3390/f14071325>
- Bountzouklis, C., Fox, D. M., & Di Bernardino, E. (2022). Environmental factors affecting wildfire-burned areas in southeastern France, 1970–2019. *Natural Hazards and Earth System Sciences*, 22(4), 1181-1200. <https://doi.org/10.5194/nhess-22-1181-2022>
- Bowman, D. M. J. S., Moreira-Muñoz, A., Kolden, C. A., Chávez, R. O., Muñoz, A. A., Salinas, F., González-Reyes, Á., ... & Johnston, F. H. (2019). Human–environmental drivers and impacts of the globally extreme 2017 Chilean fires. *Ambio*, 48(4), 350-362. <https://doi.org/10.1007/s13280-018-1084-1>
- Chouai, A., Laugier, S., & Richon, D. (2002). Modeling of thermodynamic properties using neural networks: Application to refrigerants. *Fluid Phase Equilibria*, 199(1), 53-62. [https://doi.org/10.1016/S0378-3812\(01\)00801-9](https://doi.org/10.1016/S0378-3812(01)00801-9)
- Chuvieco, E., & Congalton, R. G. (1989). Application of remote sensing and geographic information systems to forest fire hazard mapping. *Remote Sensing of Environment*, 29(2), 147-159. [https://doi.org/10.1016/0034-4257\(89\)90023-0](https://doi.org/10.1016/0034-4257(89)90023-0)
- Denham, M. M., Waidelich, S., & Laneri, K. (2022). Visualization and modeling of forest fire propagation in Patagonia. *Environmental Modelling & Software*, 158, 105526. <https://doi.org/10.1016/j.envsoft.2022.105526>
- Dimopoulou, M., & Giannikos, I. (2004). Towards an integrated framework for forest fire control. *European Journal of Operational Research*, 152(2), 476-486. [https://doi.org/10.1016/S0377-2217\(03\)00038-9](https://doi.org/10.1016/S0377-2217(03)00038-9)

- Endreny, T. A., & Wood, E. F. (2003). Maximizing spatial congruence of observed and DEM-delineated overland flow networks. *International Journal of Geographical Information Science*, 17(7), 699-713. <https://doi.org/10.1080/1365881031000135483>
- Eskandari, S., Pourghasemi, H. R., & Tiefenbacher, J. P. (2020). Relations of land cover, topography, and climate to fire occurrence in natural regions of Iran: Applying new data mining techniques for modeling and mapping fire danger. *Forest Ecology and Management*, 473, 118338. <https://doi.org/10.1016/j.foreco.2020.118338>
- Farahi Ashtiani, E., Daryaei, M. G., & Mohamadi Samani, K. (2013). Amin Amlashi, M., Review of fire sensitive areas with emphasis on drought impact with the joint use of PDSI, AHP and GIS (Case study: Forest Saravan, Guilan province). *Forest and Range Protection Research* 10(2), 83-110. [In Persian] <https://doi.org/10.22092/ijfrpr.2012.11141>
- Gholami, H., Mohamadifar, A., Rahimi, S., Kaskaoutis, D. G., & Collins, A. L. (2021). Predicting land susceptibility to atmospheric dust emissions in central Iran by combining integrated data mining and a regional climate model. *Atmospheric Pollution Research*, 12(4), 172-187. <https://doi.org/10.1016/j.apr.2021.03.005>
- Ghorbanzadeh, O., & Blaschke, T. (2018). Wildfire susceptibility evaluation by integrating an analytical network process approach into GIS-based analyses. *International Journal on Advanced Science. Engineering and Information Technology* 6, 48-53.
- Guisan, A., Edwards, T. C., & Hastie, T. (2002). Generalized linear and generalized additive models in studies of species distributions: setting the scene. *Ecological Modelling*, 157(2), 89-100. [https://doi.org/10.1016/S0304-3800\(02\)00204-1](https://doi.org/10.1016/S0304-3800(02)00204-1)
- Hamed, N., Esmaily, A., & Faramarzi, H. (2020). Analysis of the potential fire hazard scenarios using GIS and RS: A case study of Lordegan forests. *Emergency Management* 9(1), 17-27. <https://dor.isc.ac/dor/20.1001.1.23453915.1399.9.1.2.5>
- Hastie, T., & Tibshirani, R. (1987). Non-parametric logistic and proportional odds regression. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 36(3), 260-276. <https://doi.org/10.2307/2347785>
- He, M. Z., Zheng, J. G., Li, X. R., & Qian, Y. L. (2007). Environmental factors affecting vegetation composition in the Alxa Plateau, China. *Journal of Arid Environments*, 69(3), 473-489. <https://doi.org/10.1016/j.jaridenv.2006.10.005>
- Hong, H., Tsangaratos, P., Ilia, I., Liu, J., Zhu, A. X., & Xu, C. (2018). Applying genetic algorithms to set the optimal combination of forest fire related variables and model forest fire susceptibility based on data mining models. The case of Dayu County, China. *Science of The Total Environment*, 630, 1044-1056. <https://doi.org/10.1016/j.scitotenv.2018.02.278>
- Janizadeh, S., Bateni, S. M., Jun, C., Im, J., Pai, H. T., Band, S. S., & Mosavi, A. (2023). Combination four different ensemble algorithms with the generalized linear model (GLM) for predicting forest fire susceptibility. *Geomatics, Natural Hazards and Risk*, 14(1), 2206512. <https://doi.org/10.1080/19475705.2023.2206512>
- Lasslop, G., & Kloster, S. (2017). Human impact on wildfires varies between regions and with vegetation productivity. *Environmental Research Letters*, 12(11), 115011. <https://doi.org/10.1088/1748-9326/aa8c82>
- Mambile, C., Kaijage, S., & Leo, J. (2025). Deep learning models for enhanced forest-fire prediction at Mount Kilimanjaro, Tanzania: Integrating satellite images, weather data and human activities data. *Natural Hazards Research*, 5(2), 335-347. <https://doi.org/10.1016/j.nhres.2024.12.001>
- 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), 1-15. <https://doi.org/10.1186/s42408-022-00162-3>
- Mohajane, M., Costache, R., Karimi, F., Bao Pham, Q., Essahlaoui, A., Nguyen, H., Laneve, G., & Oudija, F. (2021). Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. *Ecological Indicators*, 129, 107869. <https://doi.org/10.1016/j.ecolind.2021.107869>
- Moradi, S., & Ahmadi Sani, N. (2025). Wildfire risk assessment and spatial zoning in forests and rangelands using GIS-based multi-criteria decision-making techniques in Central Zagros. *Iranian Journal of Forest*, 16(4), 531-554. [In Persian] <https://doi.org/10.22034/ijf.2024.465288.1994>
- Myerson, R. B. (2013). *Game Theory: Analysis of Conflict*. Harvard University Press.

- Najafi, A., Irannezhad, M. H., Sotoudeh, A., Mokhtari, M. H., & Kiani, B. (2015). Modeling and risk mapping of forest fires using remote sensing and GIS (Case study: Baghe-Shadi protected area, Yazd province). *Iranian Journal of Applied Ecology* 4(14), 13-26. [In Persian] <https://doi.org/10.18869/acadpub.ijae.4.14.13>
- Pham, B. T., Jaafari, A., Avand, M., Al-Ansari, N., Dinh Du, T., Yen, H. P., Phong, T. V., ... & Tuyen, T. T. (2020). Performance evaluation of machine learning methods for forest fire modeling and prediction. *Symmetry*, 12(6), 1022. <https://doi.org/10.3390/sym12061022>
- Phillips, S. J., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190(3), 231-259. <https://doi.org/10.1016/j.ecolmodel.2005.03.026>
- Polat, S., Ghasemi Aghbash, F., & Mahdavi, A. (2020). Forest fire hazard zone mapping in Ilam County forests. *Forest Research and Development*, 6(1), 135-152. <https://doi.org/10.30466/jfrd.2020.120830>
- Pragya Kumar, M., Tiwari, A., Majid, S. I., Bhadwal, S., Sahu, N., Verma, N. K., Tripathi, D. K., & Avtar, R. (2023). Integrated spatial analysis of forest fire susceptibility in the Indian western Himalayas (IWH) using remote sensing and GIS-based fuzzy AHP approach. *Remote Sensing*, 15(19), 4701. <https://doi.org/10.3390/rs15194701>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation system in the Great Plains with ERTS. Proceedings of the Third Earth Resources Technology Satellite-1 Symposium, Greenbelt, USA; NASA SP-351.
- Sandholt, I., Rasmussen, K., & Andersen, J. (2002). A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, 79(2), 213-224. [https://doi.org/10.1016/S0034-4257\(01\)00274-7](https://doi.org/10.1016/S0034-4257(01)00274-7)
- Sarkar, M. S., Majhi, B. K., Pathak, B., Biswas, T., Mahapatra, S., Kumar, D., Bhatt, I. D., ... & Nautiyal, S. (2024). Ensembling machine learning models to identify forest fire-susceptible zones in Northeast India. *Ecological Informatics*, 81, 102598. <https://doi.org/10.1016/j.ecoinf.2024.102598>
- Sivrikaya, F., & Küçük, Ö. (2022). Modeling forest fire risk based on GIS-based analytical hierarchy process and statistical analysis in Mediterranean region. *Ecological Informatics*, 68, 101537. <https://doi.org/10.1016/j.ecoinf.2021.101537>
- Tessler, N., Wittenberg, L., & Greenbaum, N. (2016). Vegetation cover and species richness after recurrent forest fires in the Eastern Mediterranean ecosystem of Mount Carmel, Israel. *Science of The Total Environment*, 572, 1395-1402. <https://doi.org/10.1016/j.scitotenv.2016.02.113>
- Tuyen, T. T., Jaafari, A., Yen, H. P. H., Nguyen-Thoi, T., Phong, T. V., Nguyen, H. D., Van Le, H., ... & Pham, B. T. (2021). Mapping forest fire susceptibility using spatially explicit ensemble models based on the locally weighted learning algorithm. *Ecological Informatics*, 63, 101292. <https://doi.org/10.1016/j.ecoinf.2021.101292>
- Wasserman, T. N., & Mueller, S. E. (2023). Climate influences on future fire severity: a synthesis of climate-fire interactions and impacts on fire regimes, high-severity fire, and forests in the western United States. *Fire Ecology*, 19(1), 43. <https://doi.org/10.1186/s42408-023-00200-8>
- Weise, D. R., & Biging, G. S. (1996). Effects of wind velocity and slope on flame properties. *Canadian Journal of Forest Research*, 26(10), 1849-1858. <https://doi.org/10.1139/x26-210>
- Zare Chahouki, M. A., Karami, P., & Piri Sahragard, H. (2022). Ensemble modeling approach to predict the potential distribution of *Artemisia sieberi* in desert rangelands of Yazd province, central Iran. *Journal of Rangeland Science*, 12(4), 326-340. <https://doi.org/10.30495/rs.2022.685569>
- Zhang, G., Wang, M., & Liu, K. (2019). Forest fire susceptibility modeling using a convolutional neural network for Yunnan province of China. *International Journal of Disaster Risk Science*, 10(3), 386-403. <https://doi.org/10.1007/s13753-019-00233-1>
- Zhou, Z., Qiu, C., & Zhang, Y. (2023). A comparative analysis of linear regression, neural networks and random forest regression for predicting air ozone employing soft sensor models. *Scientific Reports*, 13(1), 22420. <https://doi.org/10.1038/s41598-023-49899-0>