J. RS. GEOINF. RES. 4(2): 321-334, Summer & Autumn 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Analyzing and predicting the process of vegetation regeneration post fire using multi-sensor data and machine learning algorithms

A. Sh. Amini*, J. Mahjoorian Namari

Department of Surveying Engineering, South Tehran Branch, Islamic Azad University, Tehran, Iran

Received: 11 May 2026
Reviewed: 22 June 2026
Revised: 17 August 2026
Accepted: 20 October 2026

KEYWORDS:
Wildfire
Vegetation Recovery
Machine Learning
Remote Sensing

* Corresponding author
ashamini@iau.ac.ir
(+98912) 4475100

ABSTRACT

Background and Objectives: Forest fires are one of the most important factors in the destruction of natural ecosystems and cause the loss of a large part of vegetation cover, biodiversity loss, habitat destruction, and changes in ecological cycles every year. Therefore, monitoring the process of vegetation recovery after a fire and assessing the speed of ecosystem return to pre-fire conditions are important issues in natural resource management, environmental protection, and planning restoration measures. The development of remote sensing technologies and access to time-series satellite data have enabled long-term monitoring of vegetation changes. Also, the use of machine learning methods has become an efficient tool for predicting vegetation changes due to its high ability to model nonlinear relationships between environmental variables. The purpose of this study is to investigate the process of vegetation recovery after a fire and evaluate the performance of machine learning models in the Bastrop and Zaka fire areas.

Methods: In this study, time series data of various spectral indices, including NDVI, SAVI, SAVI2, NBR, EVI, EVI2, and NDWI, were extracted for the period from 2000 to 2022, and their temporal variations after wildfire events were investigated. After preprocessing steps, including the removal of incomplete data, feature selection, and data normalization, three machine learning algorithms, including Random Forest (RF), Support Vector Regression (SVR), and Extreme Gradient Boosting (XGBoost), were trained to predict NDVI using a chronological data partitioning approach, with 70% of the data used for training and 30% for testing. The performance of the models was then evaluated, and the importance of input features was analyzed using feature importance and permutation importance methods. Finally, the vegetation recovery process and the vegetation greenness recovery rate were assessed.

Findings: The results showed that the occurrence of fires in both regions caused a sharp decrease in greening indices, indicating extensive destruction of vegetation. Although the vegetation recovery process began in the years after the fires, neither region returned to the pre-fire level by the end of 2022. The results of the model evaluation showed that all three algorithms had high accuracy, but the SVR model performed best in the test data, with the highest R^2 value and the lowest RMSE value. In addition, the vegetation recovery rate showed that the Bastrop region had a faster recovery process with a recovery rate of 0.0128 compared to the Zaka region with a rate of 0.0092, which could be due to differences in climatic conditions, vegetation characteristics, and fire severity.

Conclusion: The results of this study show that the integration of remote sensing data and machine learning models provides an accurate and efficient approach for monitoring and predicting the process of vegetation recovery after fire. The findings of this study can be used in assessing the long-term effects of fire, monitoring the health of forest ecosystems, planning vegetation restoration operations, and developing intelligent natural resource management systems, and pave the way for a wider use of machine learning methods in remote sensing studies and environmental monitoring.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
20	7	2

مقاله پژوهشی

تحلیل و پیش‌بینی روند احیای پوشش گیاهی پس از آتش‌سوزی با استفاده از داده‌های چند سنجنده‌ای و الگوریتم‌های یادگیری ماشین

امیر شاهرخ امینی*، جواد مهجوریان نماری

گروه مهندسی نقشه برداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران

چکیده

پیشینه و اهداف: آتش‌سوزی‌های جنگلی یکی از مهم‌ترین عوامل تخریب اکوسیستم‌های طبیعی به شمار می‌روند و هرساله موجب از بین رفتن بخش وسیعی از پوشش گیاهی، کاهش تنوع زیستی، تخریب زیستگاه‌ها و تغییر در چرخه‌های اکولوژیکی می‌شوند. ازاین‌رو، پایش روند بازیابی پوشش گیاهی پس از وقوع آتش‌سوزی و ارزیابی سرعت بازگشت اکوسیستم به شرایط پیش از حریق، از موضوعات مهم در مدیریت منابع طبیعی، حفاظت محیط‌زیست و برنامه‌ریزی اقدامات احیایی محسوب می‌شود. توسعه فناوری‌های سنجش‌ازدور و دسترسی به داده‌های ماهواره‌ای سری زمانی، امکان پایش بلندمدت تغییرات پوشش گیاهی را فراهم کرده است. همچنین، استفاده از روش‌های یادگیری ماشین به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی میان متغیرهای محیطی، به ابزاری کارآمد برای پیش‌بینی تغییرات پوشش گیاهی تبدیل‌شده است. هدف این پژوهش، بررسی روند بازیابی پوشش گیاهی پس از آتش‌سوزی و ارزیابی عملکرد مدل‌های یادگیری ماشین در دو منطقه آتش‌سوزی باستروپ و زاکا است.

روش‌ها: در این پژوهش، سری زمانی شاخص‌های طیفی مختلف NDVI، SAVI، SAVI2، NBR، EVI، EVI2 وNDWI در بازه زمانی ۲۰۰۰ تا ۲۰۲۲ استخراج و روند تغییرات آن‌ها پس از وقوع آتش‌سوزی بررسی شد. پس از انجام مراحل پیش‌پردازش شامل حذف داده‌های ناقص، انتخاب ویژگی‌ها و نرمال‌سازی داده‌ها انجام شد. سپس سه الگوریتم یادگیری ماشین شامل Random Forest (RF)، Support Vector Regression (SVR) و Extreme Gradient Boosting (XGBoost) با استفاده از تقسیم‌بندی زمانی داده‌ها به مجموعه‌های آموزش (۷۰ درصد) و آزمون (۳۰ درصد) برای پیش‌بینی NDVI آموزش داده شدند. سپس عملکرد مدل‌ها ارزیابی‌شده و اهمیت ویژگی‌های ورودی با استفاده از روش اهمیت ویژگی و اهمیت جایگشتی بررسی شد. در ادامه روند بازیابی پوشش گیاهی و نرخ بازیابی سبزینگی مورد ارزیابی قرار گرفت.

یافته‌ها: نتایج نشان داد که وقوع آتش‌سوزی در هر دو منطقه باعث کاهش شدید شاخص‌های سبزینگی شده و بیانگر تخریب گسترده پوشش گیاهی است. اگرچه روند بازیابی پوشش گیاهی در سال‌های پس از آتش‌سوزی آغاز شد، اما تا پایان سال ۲۰۲۲ هیچ‌یک از دو منطقه به سطح پیش از آتش‌سوزی بازنگشت. نتایج ارزیابی مدل‌ها نشان داد که هر سه الگوریتم از دقت بالایی برخوردار بودند، اما مدل SVR در داده‌های آزمون بهترین عملکرد را ارائه داد و بالاترین مقدار R^2 و کمترین مقدار RMSE را به خود اختصاص داد. علاوه بر این، بررسی نرخ بازیابی پوشش گیاهی نشان داد که منطقه باستروپ با نرخ بازیابی ۰.۰۱۲۸ نسبت به منطقه زاکا با نرخ ۰.۰۰۹۲ روند احیای سریع‌تری داشته است که می‌تواند ناشی از تفاوت در شرایط اقلیمی، ویژگی‌های پوشش گیاهی و شدت آتش‌سوزی باشد.

نتیجه‌گیری: نتایج این پژوهش نشان می‌دهد که تلفیق داده‌های سنجش‌ازدور و مدل‌های یادگیری ماشین، رویکردی دقیق و کارآمد برای پایش و پیش‌بینی روند بازیابی پوشش گیاهی پس از آتش‌سوزی فراهم می‌کند. یافته‌های این پژوهش می‌تواند در ارزیابی اثرات بلندمدت آتش‌سوزی، پایش سلامت اکوسیستم‌های جنگلی، برنامه‌ریزی عملیات احیای پوشش گیاهی و توسعه سامانه‌های هوشمند مدیریت منابع طبیعی مورداستفاده قرار گیرد و زمینه را برای بهره‌گیری گسترده‌تر از روش‌های یادگیری ماشین در مطالعات سنجش‌ازدور و پایش محیط‌زیست فراهم سازد.

تاریخ دریافت: ۲۱ اردیبهشت ۱۴۰۵
تاریخ داوری: ۰۱ تیر ۱۴۰۵
تاریخ اصلاح: ۲۶ مرداد ۱۴۰۵
تاریخ پذیرش: ۲۸ مهر ۱۴۰۵

واژگان کلیدی:
آتش‌سوزی جنگل
بازیابی پوشش گیاهی
یادگیری ماشین
سنجش‌ازدور

* نویسنده مسئول
ashamini@iau.ac.ir
۰۹۱۲-۴۴۷۵۱۰۰

مقدمه

جنگل‌ها مهم‌ترین منبع طبیعی و اکولوژیکی در کره زمین به شمار می‌آیند و عملکرد آن‌ها نقش اساسی در حفظ تعادل در چرخه طبیعت دارد. علاوه بر این جنگل‌ها مانع وقوع بسیاری از بلایای طبیعی مانند سیل، گرم شدن زمین و... بوده و می‌تواند با این تهدیدهای بزرگ انسانی مقابله کند[۱]. همچنین جنگل‌ها به‌عنوان یکی از مهم‌ترین منابع طبیعی تجدیدشونده نقش حیاتی در استمرار حیات، حفظ و پایداری زیست‌بوم‌ها ایفا می‌نمایند. این مساله به‌ویژه در ایران که در زمره‌ی کشورهای خشک و کم‌آب جهان به شمار می‌رود و از محدودیت شدید پوشش گیاهی رنج می‌برد بسیار حائز اهمیت است [۲].

آتش، علت قابل‌توجهی از تخریب محیط‌زیست است که درنتیجه ی آن جنگل‌ها کم تراکم شده و تبدیل به درختان صدمه‌دیده یا نابودشده

می‌شوند. علاوه بر این باعث از دست رفتن تنوع زیستی شده که باعث تخریب زیستگاه‌ها و فرسایش خاک می‌شود [۳, ۴]. به‌عنوان‌مثال در مقیاس منطقه‌ای، مولدر و کراما در سال ۲۰۰۷ مشاهده کرده‌اند که از دست دادن پوشش گیاهی می‌تواند زبری سطح و بازتاب را تغییر دهد. درنتیجه بر شار انرژی بین سطح و جو تأثیر می‌گذارد که باعث تغییر آب‌وهوا می‌شود [۵] و همچنین امیرا و همکاران در سال ۱۹۹۹ مشاهده کرده‌اند که مناطق آتش‌سوزی شده تا ۱۵ سال گرم‌تر از جنگل‌های دست‌نخورده است که نشان می‌دهد آتش‌سوزی می‌تواند آب‌وهوا در مقیاس محلی را تحت تأثیر قرار دهد [۶]. در سطح جهانی سوختن زیست‌توده، باعث تولید قابل‌توجهی از دی‌اکسید کربن و سایر گازهای گلخانه‌ای می‌شود. با آتش گرفتن ۸۷۰۰ تن زیست‌توده ازجمله پوشش گیاهی، سالانه در جهان ۳۵۰۰ تن دی‌اکسید کربن منتشر می‌شود [۷]. آتش‌سوزی جنگل یک نوع آتش‌سوزی کنترل ناپذیر است که در منطقه‌ای با گیاهان اشتعال‌پذیر در نواحی روستایی یا در طبیعت وحش روی می‌دهد.

آتش‌سوزی جنگل با دیگر انواع آتش‌سوزی‌ها ازنظر گستردگی، سرعت گسترش از منشأ، پتانسیل تغییر جهت ناگهانی و توانایی جهیدن از میان فضاهای خالی مانند جاده‌ها، رودخانه‌ها و دیگر نقاط اشتعال‌پذیر تفاوت دارد. آتش‌سوزی جنگل ازنظر علت آتش‌سوزی، ویژگی‌های فیزیکی آن مانند سرعت پراکندگی، وجود مواد اشتعال‌پذیر و تأثیر آب‌وهوا بر آتش توصیف می‌شود [۸].

تکنیک‌های سنجش از راه دور برای پیش‌گیری از آتش‌سوزی جنگل، ارزیابی و نظارت از اواسط دهه ۱۹۸۰ توسعه‌یافته‌اند [۹]. این تکنیک‌ها برای رسیدگی به سه مرحله اثرات آتش زمانی مختلف بکار گرفته‌شده‌اند: شرایط قبل از آتش‌سوزی، ویژگی‌های آتش‌سوزی فعال و واکنش‌های اکوسیستم پس از آتش[۱۰]. سنجنده‌های ماهواره‌ای سنجش‌ازدور باقدرت تفکیک مکانی و زمانی مناسب، اطلاعات مهمی را برای هشدارهای زودهنگام آتش‌سوزی در دسترس قرار می‌دهند[۱۱]. الگوریتم‌های متعدد و رویکردهای مختلفی برای دو فاز اولیه توسعه‌یافته‌اند [۱۲]؛ بااین‌حال تلاش کمی برای ارزیابی داده‌های سنجش‌ازدور مناسب و روش‌های موجود در محیط‌های بسیار فضایی و زمانی به‌خصوص در توصیف و ارزیابی الگوهای چگونگی واکنش اکوسیستم جنگل به اختلالات ناشی از آتش، اختصاص داده‌شده است [۹, ۱۳, ۱۴].

در تحقیقی، باهدف تحلیل سری‌های زمانی EVI مادیس برای بررسی رشد مجدد پوشش گیاهی پس از آتش‌سوزی، از شبکه‌های عصبی مصنوعی استفاده کردند. آن‌ها با مقایسه سری‌های زمانی واقعی پس از آتش‌سوزی و سری‌های زمانی شبیه‌سازی‌شده بر اساس شبکه‌های عصبی، اختلالات ناشی از آتش‌سوزی را برآورد کردند. سپس با استفاده از تکنیک Dynamic Time Warping شباهت این پاسخ‌ها را در تمام سایت‌های نمونه‌برداری محاسبه کرده و با به‌کارگیری مقیاس بندی چندبعدی و خوشه‌بندی فازی بهینه، الگوهای منحصربه‌فردی در بازیابی پوشش گیاهی شناسایی کردند. نتایج نشان داد که در دو سال اول پس از آتش‌سوزی، سایت‌های با شدت سوختگی متوسط تا بالا، به‌ویژه در ارتفاعات بالاتر از ۲۰۰ متر، با درختان بلوط غالب بودند و پاسخ‌های تجمعی (غالب) در بازسازی پوشش گیاهی نسبت به سایر سایت‌ها ارائه دادند[۱۵]. کیم و همکاران، باهدف ارزیابی بازیابی پوشش گیاهی جنگل در مناطق سوخته جمهوری کره، مطالعه‌ای انجام دادند. آن‌ها از داده‌های ماهواره‌ای سنتینل ۲ و شاخص‌های گیاهی مانند NDVI، EVI، SAVI و NBR برای برآورد میزان تجدید حیات گیاهی استفاده کردند. نتایج نشان داد که ترکیب این شاخص‌ها می‌تواند مناطق هدف برای احیای جنگل را با دقت بیشتری شناسایی کند. این مطالعه با ارائه روش‌های دقیق‌تر برای پایش بازیابی پوشش گیاهی، به بهبود مدیریت منابع جنگلی پس از آتش‌سوزی کمک می‌کند[۱۶]. بائو و همکاران در سال ۲۰۲۴، باهدف بررسی بازیابی طیفی و ترکیبی پس از آتش‌سوزی‌های بزرگ در جنگل‌های بورئال سیبری، مطالعه‌ای انجام دادند. آن‌ها از سری زمانی تصاویر ماهواره‌ای لندست و روش جداسازی مبتنی بر رگرسیون برای تحلیل تغییرات پوشش جنگلی در دوره زمانی ۱۹۸۷ تا ۲۰۲۲ استفاده کردند. نتایج نشان داد که آتش‌سوزی‌های بزرگ منجر به تغییر در انواع پوشش جنگلی شده و نسبت جنگل‌های پهن‌برگ افزایش و نسبت جنگل‌های سوزنی‌برگ کاهش‌یافته است. همچنین نرخ بازیابی طیفی سریع‌تر از نرخ بازیابی ترکیبی بود و جنگل‌های پهن‌برگ سریع‌تر از جنگل‌های سوزنی‌برگ به حالت قبل از آتش‌سوزی بازگشتند. این مطالعه نشان می‌دهد که آتش‌سوزی‌های بزرگ می‌توانند منجر به تغییرات پایدار در ترکیب جنگل‌ها شوند و تاب‌آوری این جنگل‌ها را در برابر آتش‌سوزی‌های با شدت بالا کاهش دهند[۱۷]. آوستیان و همکاران در سال ۲۰۲۳، عملکرد شاخص‌های طیفی پوشش گیاهی برای پایش پس از آتش‌سوزی در جنگل‌های مختلف ارزیابی نمودند. این پژوهش باهدف بررسی کارایی شاخص‌های گیاهی در شناسایی و تفکیک مناطق سوخته شده و ارزیابی بازیابی پوشش گیاهی پس از آتش‌سوزی انجام شد. نتایج نشان داد که شاخص‌های گیاهی ابزارهای مؤثری برای نظارت و ارزیابی تغییرات پوشش گیاهی، به‌ویژه در دوره‌های زمانی پس از آتش‌سوزی، هستند[۱۸]. گیبسون و همکاران به‌منظور اعتبارسنجی شاخص‌های سنجش‌ازدور در پیش‌بینی پاسخ‌های زیستی به آتش‌سوزی، مطالعه‌ای در جنوب‌شرق استرالیا انجام دادند. آن‌ها داده‌های میدانی گسترده از ۹۸۲ گونه گیاهی و جانوری را با شاخص‌های ناهمگنی آتش‌سوزی و بازیابی تأخیری توده زیستی مقایسه کردند. نتایج نشان داد که مناطق با آتش‌سوزی یکنواخت و شدید و نیز مناطق دارای بازیابی تأخیری، با کاهش معنی‌دار فراوانی گونه‌ها همراه بودند. این مطالعه تأکید نمود که شاخص‌های مذکور ابزارهای مناسبی برای پایش محیط‌زیست در غیاب داده‌های میدانی هستند[۱۹]. اوتارا و همکاران ، به‌منظور ارزیابی تأثیرات آتش‌سوزی و روند بازیابی پوشش گیاهی در ساوانای آفریقای غربی، مطالعه‌ای ده‌ساله (۲۰۱۴-۲۰۲۳) با استفاده از تصاویر ماهواره‌ای HLS (ترکیب هماهنگ‌شده لندست و سنتینل۲) انجام

دادند. آن‌ها با محاسبه شاخص‌های طیفی و برآورد افت بهره‌وری خالص اولیه (NPP) دریافتند که حدود ۶۵ درصد مناطق سوخته ظرف یک سال بازیابی می‌شوند، اما بازیابی در مناطق جنگلی و مرطوب با کندی بیشتری همراه است. نتایج نشان داد که عوامل محیطی نظیر رطوبت و نیتروژن خاک، بیش از ویژگی‌های خود آتش (نظیر بسامد آن) در تعیین سرعت بازیابی نقش دارند[۲۰].

باوجود پیشرفت‌های قابل‌توجه در استفاده از داده‌های سنجش‌ازدور برای پایش اثرات آتش‌سوزی و ارزیابی بازیابی پوشش گیاهی، بسیاری از مطالعات پیشین عمدتاً بر تشخیص مناطق سوخته، برآورد شدت خسارت یا تحلیل روندهای گذشته بازیابی تمرکز داشته‌اند. به‌عنوان‌مثال، استفاده از شاخص‌هایی مانند NDVI، EVI و NBR در مطالعات مختلف نشان داده است که داده‌های طیفی قابلیت مناسبی برای پایش تغییرات پوشش گیاهی پس از آتش‌سوزی دارند؛ بااین‌حال، این مطالعات اغلب به تحلیل‌های آماری سنتی یا بررسی یک شاخص منفرد محدودشده‌اند و کمتر به بررسی مدل‌های پیش‌بینی کننده برای تخمین روند آینده تغییرات پوشش گیاهی پرداخته‌اند.

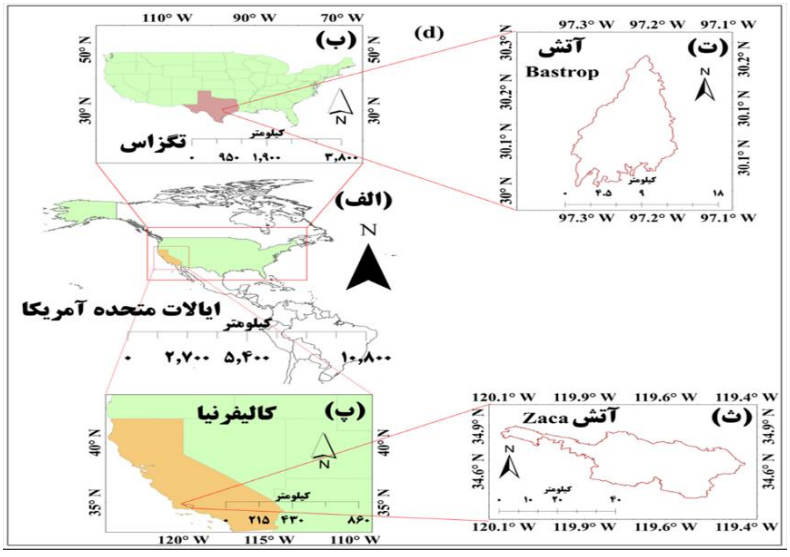
همچنین اگرچه مطالعاتی کارایی شاخص‌های طیفی مختلف را در ارزیابی بازیابی پوشش گیاهی بررسی کرده‌اند، اما انتخاب ویژگی‌های مؤثر، حذف اطلاعات افزونه و ارزیابی همزمان چندین الگوریتم یادگیری ماشین در مقیاس زمانی بلندمدت کمتر موردتوجه قرارگرفته است. از سوی دیگر، برخی پژوهش‌ها نشان داده‌اند که بازیابی طیفی پوشش گیاهی الزاماً معادل بازگشت کامل ساختار اکوسیستم نیست؛ بنابراین، نیاز به روش‌هایی وجود دارد که علاوه بر بررسی تغییرات شاخص‌های طیفی، توانایی پیش‌بینی روند بازیابی و شناسایی عوامل مؤثر بر این فرآیند را داشته باشند.

با توجه به این شکاف پژوهشی، پژوهش حاضر باهدف توسعه یک چارچوب مبتنی بر یادگیری ماشین برای پیش‌بینی شاخص NDVI پس از آتش‌سوزی و تحلیل روند بازیابی پوشش گیاهی انجام‌شده است. نوآوری اصلی این مطالعه در سه بخش قابل‌بیان است: (۱) استفاده از سری زمانی بلندمدت داده‌های سنجش‌ازدور (۲۰۰۰ تا ۲۰۲۲) برای بررسی رفتار پوشش گیاهی قبل و بعد از آتش‌سوزی؛ (۲) مقایسه عملکرد سه الگوریتم یادگیری ماشین شامل Random Forest، XGBoost و Support Vector Regression در پیش‌بینی NDVI با استفاده از ترکیب چندین شاخص طیفی؛ و (۳) تحلیل اهمیت ویژگی‌های ورودی مدل‌ها به‌منظور شناسایی شاخص‌های مؤثر در فرآیند بازیابی پوشش گیاهی. علاوه بر این، استفاده از دو آتش‌سوزی بزرگ باستروپ و زاکا با شرایط اکولوژیکی متفاوت، امکان ارزیابی قابلیت تعمیم روش پیشنهادی در محیط‌های مختلف را فراهم می‌کند.

منطقه مورد مطالعه

در این پژوهش، دو آتش‌سوزی شاخص شامل باستروپ و زاکا به‌عنوان مناطق موردمطالعه انتخاب شدند. موقعیت این دو منطقه در شکل ۱ نشان داده‌شده است. انتخاب این مناطق به دلیل وسعت آتش‌سوزی، تفاوت در شرایط اقلیمی و اکولوژیکی، تنوع پوشش گیاهی و همچنین دسترسی به داده‌های ماهواره‌ای بلندمدت برای پایش روند بازیابی پوشش گیاهی پس از آتش‌سوزی انجام شد.

منطقه باستروپ در شهرستان باستروپ، ایالت تگزاس و در محدوده جنگل لوس پاینس واقع‌شده است. این منطقه دارای اقلیم نیمه گرمسیری مرطوب و پوشش غالب جنگل‌های کاج و بلوط است. آتش‌سوزی باستروپ در سپتامبر ۲۰۱۱ رخ داد و با سوزاندن بیش از ۳۲ هزار هکتار از اراضی، به‌عنوان مخرب‌ترین آتش‌سوزی تاریخ ایالت تگزاس شناخته می‌شود. خشک‌سالی شدید، دمای بالا و وزش بادهای ناشی از طوفان گرمسیری Lee از مهم‌ترین عوامل گسترش سریع این حریق بودند که خسارات گسترده‌ای به پوشش گیاهی، اکوسیستم منطقه و مناطق مسکونی وارد کرد.



شکل ۱: منطقه موردمطالعه

Fig. 1: Study area

منطقه زاکا در رشته‌کوه‌های سن رافائل، واقع در جنگل ملی لوس پادرس در شهرستان سانتا باربارا، ایالت کالیفرنیا، قرار دارد. این منطقه دارای اقلیم مدیترانه‌ای، توپوگرافی ناهموار و پوشش گیاهی متشکل از چاپارال، جنگل‌های بلوط و گونه‌های مخروطیان است. آتش‌سوزی زاکا در ژوئیه ۲۰۰۷ آغاز شد و بیش از ۲۴۰ هزار هکتار از اراضی را دربر گرفت. اگرچه این حریق خسارات محدودی به زیرساخت‌های انسانی وارد کرد، اما اثرات قابل‌توجهی بر پوشش گیاهی، زیستگاه‌های طبیعی و فرآیندهای بازیابی اکوسیستم بر جای گذاشت.

تفاوت شرایط اقلیمی، نوع پوشش گیاهی و ویژگی‌های اکولوژیکی این دو منطقه، در کنار شدت و وسعت آتش‌سوزی، امکان مقایسه روند بازیابی پوشش گیاهی در دو اکوسیستم متفاوت و ارزیابی عملکرد مدل‌های یادگیری ماشین را در شرایط محیطی مختلف فراهم می‌کند.

داده‌های مورداستفاده

در این پژوهش، به‌منظور بررسی روند تغییرات و بازیابی پوشش گیاهی پس از آتش‌سوزی، از مجموعه‌ای از شاخص‌های طیفی استخراج‌شده از تصاویر سه نسل از ماهواره‌های لندست شامل لندست۵ (سنجنده TM)، لندست۷ (سنجنده ETM+) و لندست۸ (سنجنده OLI) استفاده شد. تصاویر لندست به دلیل دارا بودن آرشیو طولانی‌مدت، پوشش مناسب مناطق موردمطالعه و قابلیت استخراج شاخص‌های مرتبط با پوشش گیاهی و اثرات آتش‌سوزی انتخاب شدند. از طرف دیگر پلت فرم گوگل ارث انجین نیز تصاویر با تصحیحات مورد نیاز را فراهم نموده که باعث شده پیش پردازش تصاویر ماهواره ای از نظر وقت و هزینه بهینه تر باشد. این داده‌ها برای دو منطقه آتش‌سوزی باستروپ و زاکا در بازه زمانی ۲۰۰۰ تا ۲۰۲۲ تهیه شدند. شاخص‌های طیفی به دلیل توانایی در نمایش وضعیت پوشش گیاهی، شدت سوختگی و شرایط رطوبتی، به‌عنوان متغیرهای ورودی مدل‌های یادگیری ماشین مورداستفاده قرار گرفتند. مشخصات شاخص‌های مورداستفاده در جدول ۱ ارائه‌شده است.

روش تحقیق

روش پیشنهادی این پژوهش به‌منظور ارزیابی روند بازیابی پوشش گیاهی پس از آتش‌سوزی و پیش‌بینی شاخص NDVI با استفاده از مدل‌های یادگیری ماشین طراحی‌شده است. مراحل کار به‌طور مفصل در زیر آمده است.

پیش‌پردازش داده‌ها

قبل از ورود داده‌ها به مدل‌های یادگیری ماشین، چند مرحله پیش‌پردازش انجام شد. ابتدا داده‌های فاقد مقدار (NaN) و داده‌های غیر معتبر حذف شدند. سپس ویژگی‌های ورودی بررسی و ویژگی‌های دارای همبستگی بسیار بالا با متغیر هدف یا ویژگی‌های تکراری حذف شدند تا از افزایش پیچیدگی مدل و بیش برازش جلوگیری شود.

جدول ۱: شاخص‌های مورد استفاده

Table 1: Indicators used

شاخص Index	رابطه formula
NDVI	$\frac{NIR-RED}{NIR+RED}$
NBR	$\frac{NIR-SWIR1}{NIR+SWIR1}$
NDWI	$\frac{Green-NIR}{Green+NIR}$
EVI	$2.5\times\frac{NIR-RED}{NIR+6\times \mathrm{R}\,ED-7.5\times Blue+1}$
EVI2	$2.5\times\frac{NIR-RED}{NIR+2.4\times RED+1}$
SAVI	$1.5\times\frac{NIR-RED}{NIR+RED+0.5}$
SAVI2	$2\times\frac{NIR-RED}{NIR+RED+1}$

با توجه به شباهت عملکرد شاخص‌هایSAVI، SAVI2، EVI2 و EVI با NDVI، این شاخص‌ها از مجموعه ویژگی‌های ورودی حذف شدند. در نهایت، شاخص‌هایی انتخاب شدند که اطلاعات مستقل‌تری درباره شدت آسیب آتش‌سوزی، شرایط رطوبتی و روند بازیابی پوشش گیاهی ارائه می‌کردند. برای جلوگیری از اثر اختلاف مقیاس بین متغیرها، تمام ویژگی‌های ورودی با استفاده از روش Min-Max Scaling در بازه صفر تا یک نرمال‌سازی شدند. فرآیند نرمال‌سازی تنها با استفاده از داده‌های مجموعه آموزش انجام شد و سپس پارامترهای حاصل برای تبدیل مجموعه آزمون به کار رفت تا از نشت اطلاعات (Data Leakage) جلوگیری شود.

تقسیم داده‌ها و آموزش مدل‌ها

با توجه به ماهیت سری زمانی داده‌ها، تقسیم مجموعه داده به‌صورت تصادفی انجام نشد. داده‌ها بر اساس ترتیب زمانی مرتب‌شده و ۷۰ درصد داده‌های ابتدایی برای آموزش مدل و ۳۰ درصد انتهایی برای آزمون اختصاص یافتند. این روش باعث شد مدل تنها با استفاده از اطلاعات گذشته آموزش‌دیده و توانایی آن در پیش‌بینی دوره‌های زمانی آینده ارزیابی شود.

سه مدل یادگیری ماشین شامل Random Forest (RF)، Support Vector Regression (SVR) و Extreme Gradient Boosting (XGBoost) برای پیش‌بینی NDVI توسعه داده شدند. تنظیم ابر پارامترهای مدل‌ها با استفاده از روش GridSearchCV همراه با اعتبارسنجی متقابل سری زمانی (Time Series Cross Validation) انجام شد. در این روش، داده‌ها بدون تغییر ترتیب زمانی به چند بخش تقسیم شدند و بهترین ترکیب پارامترها بر اساس کمینه کردن خطای پیش‌بینی انتخاب گردید. برای بهینه‌سازی مدل Random Forest پارامترهای تعداد درخت‌ها (n_estimators)عمق درخت(max_depth) حداقل نمونه لازم برای تقسیم گره (min_samples_split)، حداقل نمونه موجود در برگ (min_samples_leaf) و تعداد ویژگی‌های انتخابی (max_features) بررسی شدند.

در مدل SVR ، پارامترهای kernel، C، gamma و epsilon مورد ارزیابی قرار گرفتند.

در مدل XGBoost نیز پارامترهای اصلی شامل تعداد درخت‌ها (n_estimators)، عمق درخت (max_depth) و نرخ یادگیری (learning_rate)برای یافتن بهترین ترکیب مدل بررسی شدند.

اهمیت ویژگی‌ها

برای بررسی تأثیر هر یک از متغیرهای ورودی، اهمیت ویژگی‌ها پس از آموزش مدل محاسبه شد. در مدل‌های مبتنی بر درخت تصمیم شامل Random Forest و XGBoost اهمیت ویژگی‌ها مستقیماً از ساختار مدل استخراج شد. برای مدل SVR، به دلیل نبود معیار اهمیت داخلی، از روش Permutation Importance استفاده شد. در این روش، کاهش عملکرد مدل پس از جابه‌جایی تصادفی مقادیر هر ویژگی به‌عنوان معیار اهمیت آن ویژگی در نظر گرفته شد.

ارزیابی مدل‌ها

عملکرد مدل‌ها با استفاده از دو معیار آماری شامل ریشه میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) ارزیابی شد. همچنین برای تحلیل بهتر عملکرد مدل‌ها، نمودارهای سری زمانی مقادیر واقعی و پیش‌بینی‌شده NDVI، نمودار پراکندگی و نمودار اهمیت ویژگی‌ها تهیه شدند.

درنهایت، روند بازیابی پوشش گیاهی پس از آتش‌سوزی با استفاده از تغییرات سری زمانی NDVI و محاسبه نرخ بازیابی (Sen's Slope) در دوره پس از آتش‌سوزی ارزیابی شد. این شاخص به‌عنوان یک تخمین گر نا پارامتریک روند، میزان افزایش یا کاهش سبزینگی را در طول دوره بازیابی نشان می‌دهد.

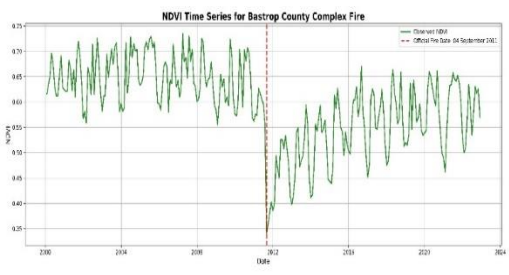
نتایج و بحث

تحلیل روند پس از آتش با استفاده از سری زمانی شاخص‌های طیفی

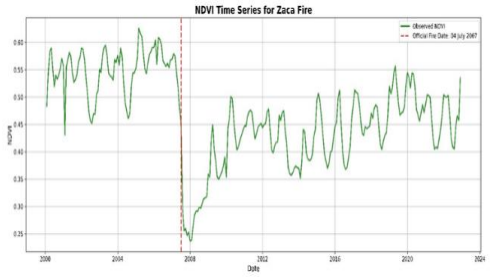
به‌منظور بررسی تغییرات پوشش گیاهی پس از آتش‌سوزی، روند زمانی شاخص‌های طیفیNDVI ، SAVI، SAVI2، NBR، EVI، EVI2 وNDWI در دو منطقه باستروپ و زاکا مورد تحلیل قرار گرفت (شکل ۲). نتایج نشان داد که تمامی شاخص‌ها بلافاصله پس از وقوع آتش‌سوزی کاهش محسوسی را تجربه کردند که بیانگر تخریب گسترده پوشش گیاهی و تغییر شرایط اکولوژیکی منطقه است. باگذشت زمان، روند بازیابی در تمامی شاخص‌ها مشاهده شد، اما سرعت این بازیابی در دو منطقه متفاوت بود و در پایان دوره مطالعه، مقادیر شاخص‌ها به وضعیت پیش از آتش‌سوزی بازنگشت.

شاخص NDVI روند کلی تغییرات سبزینگی و بازیابی پوشش گیاهی را به‌خوبی نشان داد. درحالی‌که SAVI و SAVI2 با کاهش اثر روشنایی خاک، الگوی مشابهی با NDVI ارائه کردند و برای ارزیابی مناطق با پوشش گیاهی تنک مناسب‌تر بودند. NBR بیشترین حساسیت را نسبت به وقوع آتش‌سوزی نشان داد و به‌وضوح شدت سوختگی و روند بهبود پس‌ازآن را آشکار کرد. همچنین، شاخص‌های EVI و EVI2 به دلیل حساسیت بیشتر به تراکم پوشش گیاهی، تغییرات سبزینگی را با نوسانات کمتر نسبت به NDVI نمایش دادند. از سوی دیگر، NDWI بیانگر تغییرات رطوبت پوشش گیاهی و خاک بود و نشان داد بازیابی شرایط رطوبتی پس از آتش‌سوزی با تأخیر بیشتری نسبت به سایر شاخص‌های پوشش گیاهی رخ می‌دهد.

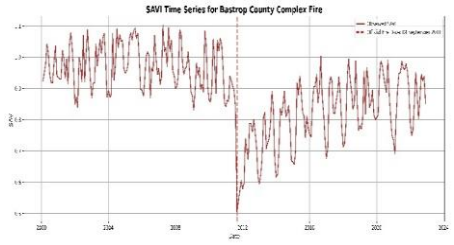
درمجموع، نتایج بیانگر آن است که استفاده همزمان از این شاخص‌های طیفی، دید جامع‌تری از اثرات آتش‌سوزی و روند بازیابی اکوسیستم فراهم می‌کند؛ به‌طوری‌که هر شاخص جنبه متفاوتی از وضعیت پوشش گیاهی، شدت سوختگی و تغییرات رطوبتی را منعکس کرده و در کنار یکدیگر امکان ارزیابی دقیق‌تر فرآیند بازسازی پوشش گیاهی را فراهم می‌سازند.



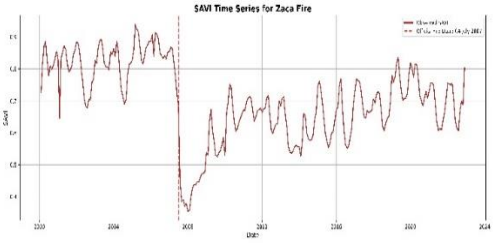
(الف)



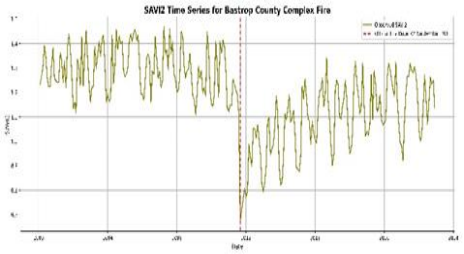
(ب)



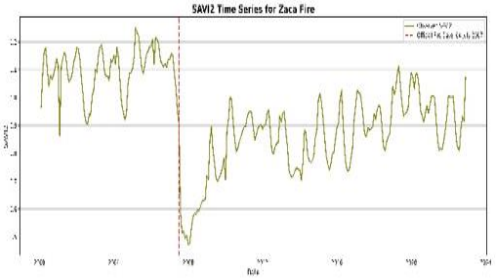
(پ)



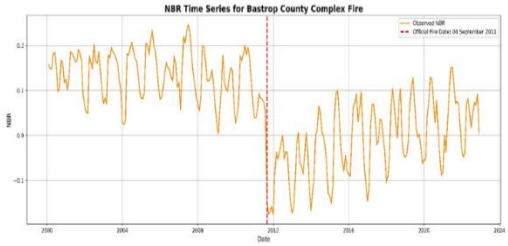
(ت)



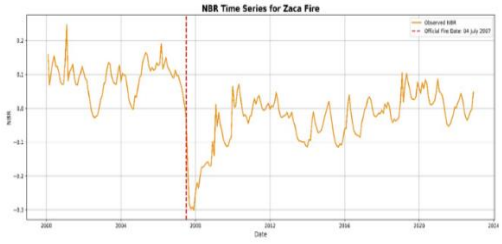
(ث)



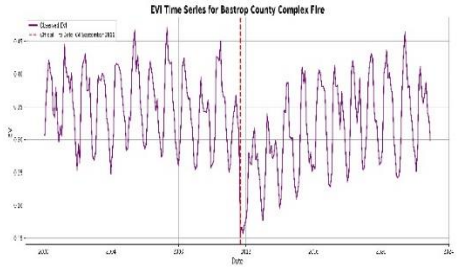
(ج)



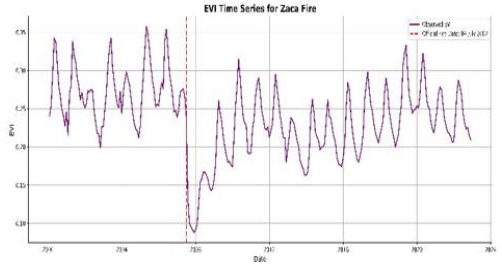
(چ)



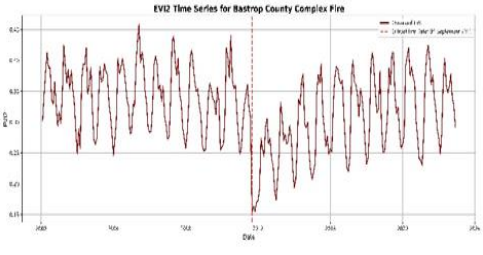
(ح)



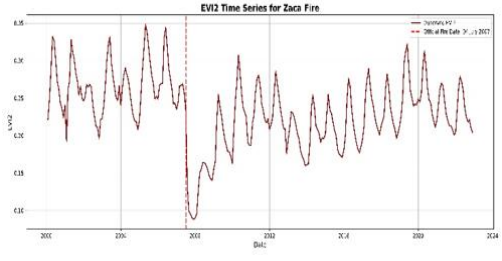
(خ)



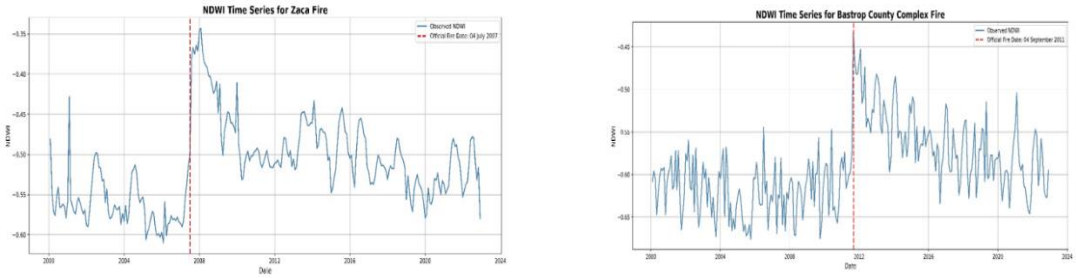
(د)



(ذ)



(ر)



(ژ) (ز)

شکل ۲: سری زمانی شاخص‌های NDVI، SAVI، SAVI2، NBR، EVI، EVI2 و NDWI برای مناطق آتش‌سوزی مجتمع باستروپ (ستون سمت راست) و زاکا (ستون سمت چپ) در بازه زمانی ۲۰۰۰ تا ۲۰۲۲. خط قرمز عمودی تاریخ وقوع آتش‌سوزی را نشان می‌دهد.

Fig. 2: Time series of the NDVI, SAVI, SAVI2, NBR, EVI, EVI2, and NDWI indices for the Bastrop Complex (right column) and Zaca (left column) wildfire areas from 2000 to 2022. The vertical red line indicates the wildfire occurrence date.

نتایج مدل‌های یادگیری ماشین

به‌منظور ارزیابی توانایی مدل‌های یادگیری ماشین در پیش‌بینی تغییرات شاخص NDVI، سه الگوریتم (RF)، (SVR) و XGBoost بر روی‌داده‌های دو منطقه آتش‌سوزی باستروپ و زاکا اجرا شدند. نتایج پیش‌بینی در شکل ۳ و معیارهای ارزیابی در جدول ۲ ارائه‌شده است. با توجه به ماهیت سری زمانی داده‌های ماهواره‌ای و وجود وابستگی زمانی میان مشاهدات متوالی، استفاده از آزمون‌های آماری کلاسیک که بر استقلال داده‌ها فرض دارند، می‌تواند موجب تفسیر نادرست نتایج شود. بنابراین در این پژوهش، عملکرد مدل‌ها بر اساس معیارهای ارزیابی یادگیری ماشین شامل RMSE و R^2 و همچنین تقسیم‌بندی زمانی داده‌ها مورد بررسی قرار گرفت.

نتایج نشان داد که هر سه مدل توانایی مناسبی در یادگیری ارتباط بین شاخص‌های طیفی ورودی و تغییرات زمانی NDVI داشته‌اند. مقادیر بالای R^2و مقادیر پایین RMSE در هر دو منطقه بیانگر قابلیت مدل‌ها در بازنمایی الگوهای غیرخطی موجود در روابط بین متغیرهای طیفی و وضعیت پوشش گیاهی است. بااین‌حال، مقایسه عملکرد مدل‌ها در مجموعه آموزش و آزمون نشان داد که میزان تعمیم‌پذیری الگوریتم‌ها متفاوت بوده است.

در منطقه باستروپ، مدل SVR در مجموعه آزمون با مقدار R^2=0.9556 و RMSE=0.0118بهترین عملکرد را در میان مدل‌های بررسی‌شده ارائه کرد. درحالی‌که مدل XGBoost بالاترین دقت را در مجموعه آموزش به دست آورد. در منطقه زاکا نیز مدل SVR با مقدار R^2=0.9337 و RMSE=0.0122 در مقایسه با سایر مدل‌ها عملکرد بهتری در مجموعه آزمون نشان داد. در مقابل، مدل‌های XGBoost و Random Forest مقادیر بسیار بالای دقت را در داده‌های آموزش ثبت کردند، اما کاهش نسبی عملکرد آن‌ها در داده‌های آزمون مشاهده شد. این اختلاف بین عملکرد آموزش و آزمون می‌تواند نشان‌دهنده حساسیت بیشتر مدل‌های مبتنی بر درخت تصمیم به الگوهای خاص موجود در داده‌های آموزش و احتمال وقوع بیش برازش نسبی باشد.

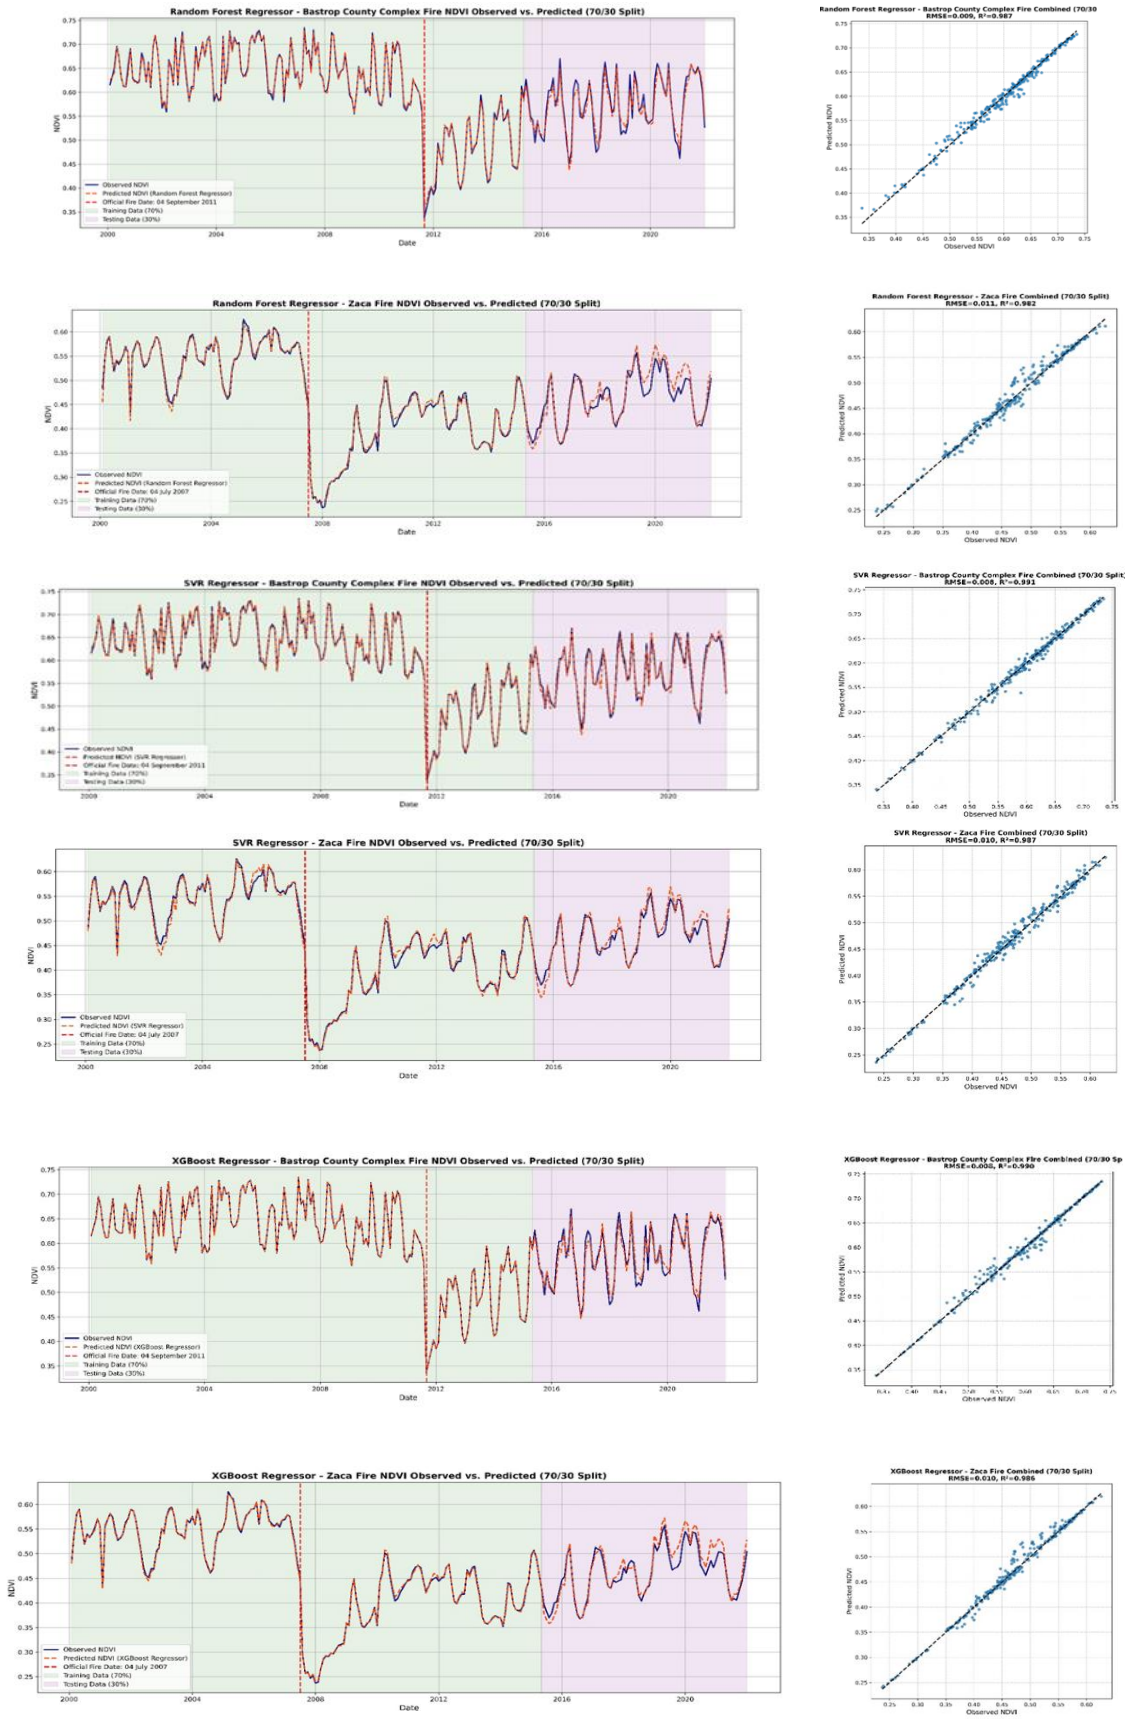
عملکرد بهتر SVR در مجموعه آزمون را می‌توان به توانایی این مدل در کنترل پیچیدگی مدل و ایجاد تعادل مناسب بین برازش داده‌های آموزشی و قابلیت تعمیم نسبت داد. همچنین استفاده از توابع هسته‌ای در SVR امکان مدل‌سازی روابط غیرخطی میان متغیرهای ورودی و NDVI را فراهم می‌کند، بدون آنکه مدل بیش از اندازه به جزئیات داده‌های آموزش وابسته شود. این ویژگی در داده‌های سری زمانی سنجش‌ازدور که معمولاً تحت تأثیر نوسانات زمانی و عوامل محیطی متعدد قرار دارند، می‌تواند نقش مهمی در بهبود عملکرد پیش‌بینی ایفا کند.

درمجموع، نتایج نشان داد که هر سه الگوریتم قابلیت مناسبی برای پیش‌بینی تغییرات NDVI پس از آتش‌سوزی دارند، اما SVR در هر دو منطقه موردمطالعه عملکرد پایدارتر و قابلیت تعمیم بهتری در داده‌های آزمون ارائه کرده است. در مقابل، عملکرد بالای XGBoost و Random Forestدر مرحله آموزش همراه با کاهش نسبی دقت در مرحله آزمون، اهمیت کنترل پیچیدگی مدل و جلوگیری از یادگیری بیش‌ازحد الگوهای خاص داده‌های آموزشی را در کاربردهای سری زمانی سنجش‌ازدور نشان می‌دهد.

بررسی اهمیت ویژگی‌های مورداستفاده در پیش‌بینی NDVI

به‌منظور شناسایی مؤثرترین متغیرها در پیش‌بینی شاخص NDVI، اهمیت ویژگی‌ها در سه مدل Random Forest (RF)، Support Vector Regression (SVR) و Extreme Gradient Boosting (XGBoost) محاسبه و نتایج آن در شکل ۴ ارائه‌شده است. برای بررسی اثرگذاری متغیرهای ورودی، اهمیت ویژگی‌ها در مدل‌های Random Forest و XGBoost بر اساس معیار اهمیت استخراج‌شده از ساختار درختی مدل محاسبه شد. از آنجا که مدل SVR فاقد معیار اهمیت ویژگی مستقیم است، از روش Permutation Importanceاستفاده شد. در این روش، مقادیر هر ویژگی به‌صورت تصادفی جابه‌جا شده و میزان کاهش عملکرد مدل پس از این تغییر بررسی گردید. کاهش بیشتر عملکرد مدل نشان‌دهنده اهمیت بالاتر آن ویژگی در فرآیند پیش‌بینی NDVI است.

نتایج نشان داد که اگرچه میزان اهمیت ویژگی‌ها در مدل‌های مختلف اندکی متفاوت است، اما الگوی کلی آن‌ها مشابه بوده و برخی متغیرها به‌طور پیوسته نقش بیشتری در پیش‌بینی NDVI ایفا کرده‌اند.



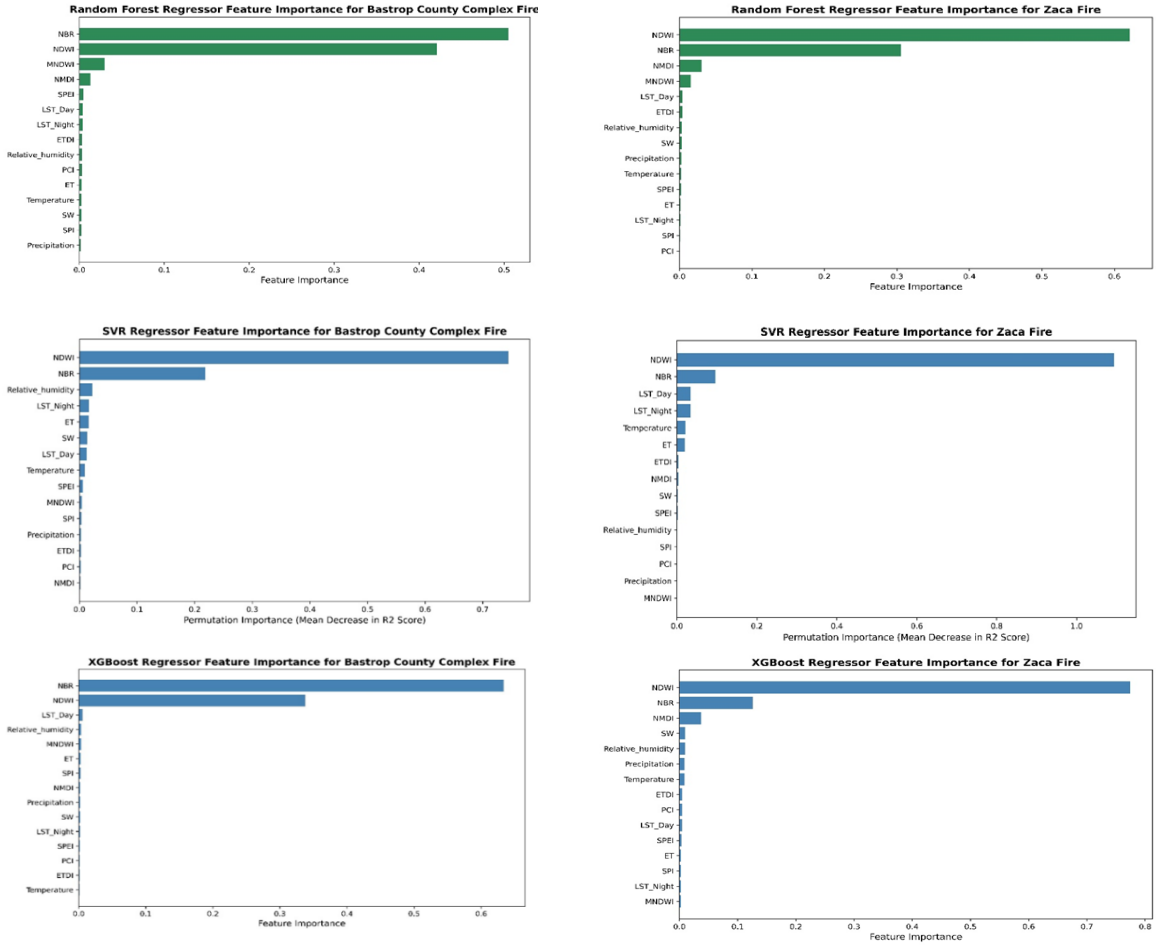
شکل ۳: نمودار سمت راست مقایسه مقادیر مشاهده‌شده و پیش‌بینی‌شده شاخص NDVI با استفاده از سه روش یادگیری ماشین شامل (Random Forest)، (SVR) و XGBoost برای دو منطقه آتش‌سوزی باستروپ و آتش‌سوزی زاکا. نمودار سمت چپ سری زمانی NDVI مشاهده‌شده و پیش‌بینی‌شده

Fig. 3: The right panels compare the observed and predicted NDVI values obtained using three machine learning algorithms (Random Forest, SVR, and XGBoost) for the Bastrop and Zaca wildfire areas. The left panels show the observed and predicted NDVI time series

جدول ۲: ارزیابی دقت الگوریتم‌های یادگیری ماشین در پیش‌بینی NDVI منطقه مورد مطالعه

Table 2: Accuracy assessment of machine learning algorithms for predicting NDVI in the study area

منطقه	مدل Model	داده‌ها Data	RMSE	R^2
باستروپ Bastrop	SVR	Training (70%) آموزش (٪۷۰)	۰.۰۰۴۸	۰.۹۹۷
		Training (30%) آزمون (٪۳۰)	۰.۰۱۱۸	۰.۹۵۵۶
	XGBoost	Training (70%) آموزش (٪۷۰)	۰.۰۰۱۲	۰.۹۹۹۸
		Training (30%) آزمون (٪۳۰)	۰.۰۱۴۶	۰.۹۳۲۳
	RF	Training (70%) آموزش (٪۷۰)	۰.۰۰۵۴	۰.۹۹۶۳
		Training (30%) آزمون (٪۳۰)	۰.۰۱۴۵	۰.۹۳۲۶
زاکا Zaka	SVR	Training (70%) آموزش (٪۷۰)	۰.۰۰۸	۰.۹۹۲۸
		Training (30%) آزمون (٪۳۰)	۰.۰۱۲۲	۰.۹۳۳۷
	XGBoost	Training (70%) آموزش (٪۷۰)	۰.۰۰۳۲	۰.۹۹۸۹
		Training (30%) آزمون (٪۳۰)	۰.۰۱۷۳	۰.۸۶۷۲
	RF	Training (70%) آموزش (٪۷۰)	۰.۰۰۶۳	۰.۹۹۵۶
		Training (30%) آزمون (٪۳۰)	۰.۰۱۸۱	۰.۸۵۵۸



شکل ۴: اهمیت ویژگی‌های ورودی در مدل‌های یادگیری ماشین. ستون سمت راست مربوط به منطقه آتش‌سوزی زاکا و ستون سمت چپ مربوط به منطقه آتش‌سوزی مجتمع باستروپ است.

Fig. 4: Feature importance of the input variables in the machine learning models. The right column corresponds to the Zaca wildfire area, while the left column corresponds to the Bastrop Complex wildfire area

در هر دو منطقه موردمطالعه، شاخص‌های NBR و NDWI بیشترین اهمیت را در اکثر مدل‌ها به خود اختصاص دادند. اهمیت بالای NBR نشان می‌دهد که شدت سوختگی و میزان تخریب پوشش گیاهی، مهم‌ترین عامل تعیین‌کننده تغییرات NDVI پس از آتش‌سوزی است. همچنین، اهمیت زیاد NDWI بیانگر نقش کلیدی وضعیت رطوبت خاک و پوشش گیاهی در روند بازیابی اکوسیستم پس از حریق است. این نتایج نشان

می‌دهد که متغیرهای استخراج‌شده از تصاویر ماهواره‌ای، اطلاعات مؤثرتری نسبت به سایر متغیرها برای پیش‌بینی وضعیت پوشش گیاهی فراهم می‌کنند.

در مقابل، متغیرهای اقلیمی شامل بارش، دمای سطح زمین (روز و شب)، تبخیر و تعرق، رطوبت نسبی و شاخص خشک‌سالی (SPI) سهم کمتری در پیش‌بینی NDVI داشتند. این موضوع نشان می‌دهد که اگرچه این عوامل در رشد و توسعه پوشش گیاهی مؤثر هستند، اما در مقیاس زمانی و مکانی این پژوهش، اثر آن‌ها نسبت به شاخص‌های مرتبط با سوختگی و رطوبت کمتر بوده است.

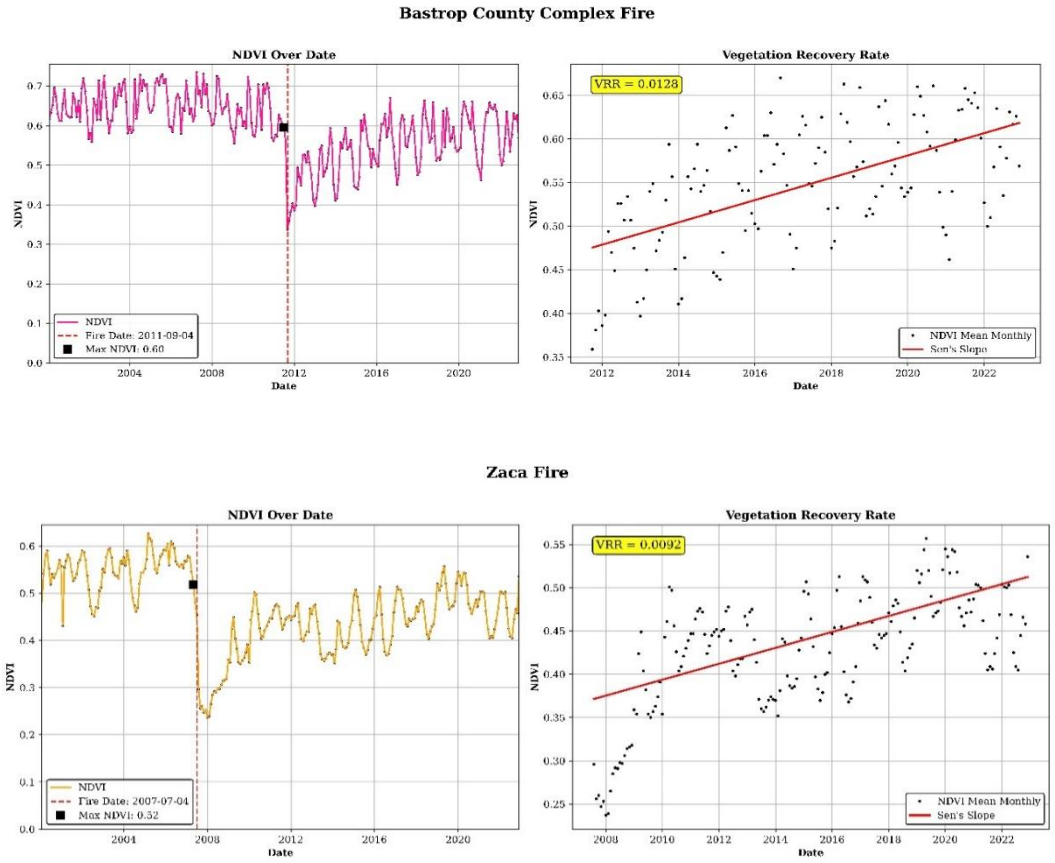
به‌طورکلی، نتایج تحلیل اهمیت ویژگی‌ها بیانگر آن است که استفاده هم‌زمان از شاخص‌های NBR و NDWI می‌تواند دقت مدل‌های یادگیری ماشین را در پیش‌بینی تغییرات NDVI پس از آتش‌سوزی افزایش دهد. همچنین این دو شاخص بالاترین مقادیر اهمیت نسبی را در مدل‌های بررسی‌شده نشان دادند.

بررسی بازیابی زمان برگشت پوشش گیاهی و نرخ رشد سبزینگی

به‌منظور ارزیابی روند بازیابی پوشش گیاهی پس از آتش‌سوزی، تغییرات شاخص NDVI، نرخ رشد سبزینگی (VRR) و وضعیت بازگشت پوشش گیاهی در دو منطقه باستروپ و زاکا موردبررسی قرار گرفت. نتایج در شکل ۵ ارائه‌شده است.

نتایج نشان داد که در هر دو منطقه، پس از کاهش شدید NDVI در زمان وقوع آتش‌سوزی، روند بازیابی پوشش گیاهی آغازشده و طی سال‌های بعد افزایش تدریجی مقادیر NDVI مشاهده می‌شود. بااین‌حال، مقادیر نهایی NDVI تا پایان دوره مطالعه (سال ۲۰۲۲) در هیچ‌یک از دو منطقه به سطح پیش از آتش‌سوزی نرسید که بیانگر تداوم اثرات آتش‌سوزی بر ساختار و عملکرد اکوسیستم است.

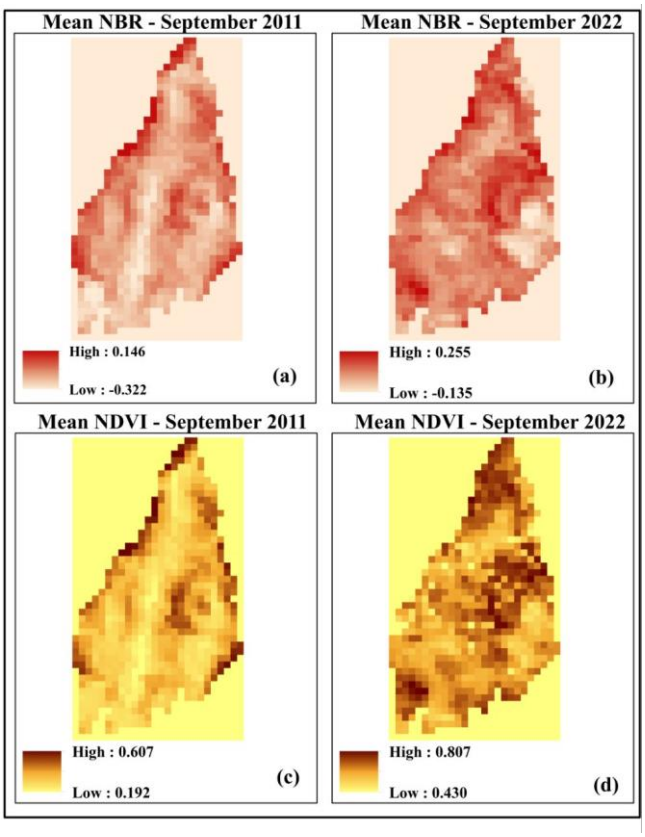
مقایسه مقادیر نرخ رشد سبزینگی نشان داد که مقدار VRR در منطقه باستروپ (۰.۰۱۲۸) بیشتر از منطقه زاکا (۰.۰۰۹۲) محاسبه شد. این اختلاف بیانگر تفاوت در روند مشاهده‌شده بازیابی پوشش گیاهی بین دو منطقه است؛ بااین‌حال، با توجه به ماهیت سری زمانی داده‌ها و بررسی دو رخداد آتش‌سوزی مستقل، این تفاوت به‌عنوان یک الگوی مشاهده‌شده تفسیر شده و برای تعمیم آن به سایر مناطق نیاز به بررسی نمونه‌های بیشتر و تحلیل‌های آماری تکمیلی وجود دارد.



شکل ۵: نتایج بازیابی پوشش گیاهی و نرخ رشد سبزینگی پس از آتش‌سوزی در منطقه باستروپ (بالا) و زاکا (پایین)

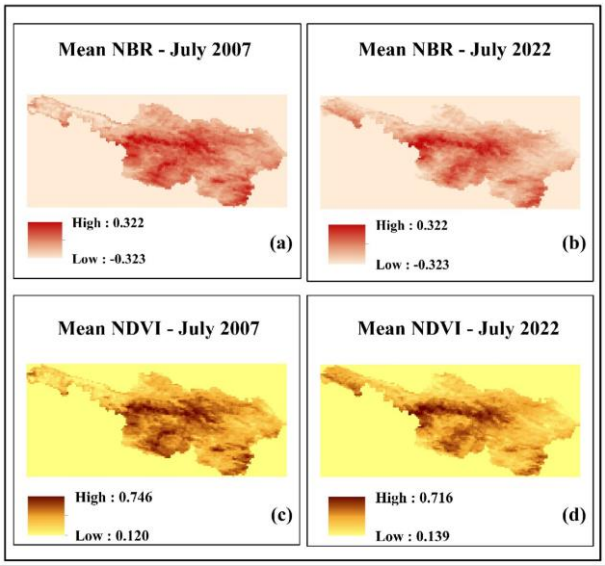
Fig. 5: Vegetation recovery and post-fire greening rate in the Bastrop Complex wildfire area (top) and the Zaca wildfire area (bottom)

بررسی نقشه‌های NDVI و NBR نیز مؤید نتایج سری زمانی است (شکل ۶ و شکل ۷). در منطقه باستروپ، افزایش مقادیر NDVI و کاهش وسعت نواحی با مقادیر پایین NBR تا سال ۲۰۲۲ نشان‌دهنده بهبود قابل‌توجه پوشش گیاهی است، درحالی‌که در منطقه زاکا، اگرچه نشانه‌هایی از احیای پوشش گیاهی مشاهده می‌شود، اما بخش‌هایی از منطقه همچنان آثار سوختگی و کاهش سبزینگی را حفظ کرده‌اند. این نتایج نشان می‌دهد که بازیابی پوشش گیاهی پس از آتش‌سوزی فرآیندی بلندمدت است و سرعت آن به شرایط اکولوژیکی و محیطی هر منطقه وابستگی زیادی دارد. همچنین نتایج حاصل از این پژوهش در خصوص کاهش شدید شاخص‌های پوشش گیاهی پس از وقوع آتش‌سوزی با یافته‌های مطالعات پیشین که کاهش NDVI و سایر شاخص‌های طیفی را به عنوان نشانه‌ای از تخریب پوشش گیاهی گزارش کرده‌اند، مطابقت دارد. همچنین تفاوت مشاهده‌شده در نرخ بازیابی دو منطقه مورد مطالعه می‌تواند به عواملی نظیر تفاوت شرایط اقلیمی، نوع پوشش گیاهی، شدت آتش‌سوزی و ویژگی‌های محیطی مناطق مرتبط باشد.



شکل ۶: مقایسه شاخص‌های NBR وNDVI در منطقه آتش‌سوزی باستروپ در دو مقطع زمانی سپتامبر ۲۰۱۱ (سال وقوع آتش) و سپتامبر ۲۰۲۲

Fig. 6: Comparison of the NBR and NDVI indices in the Bastrop Complex wildfire area for two time points: September 2011 (the year of the wildfire) and September 2022



شکل ۷: مقایسه شاخص‌های NBR و NDVI در منطقه آتش‌سوزی زاکا در دو مقطع زمانی ژوئیه ۲۰۰۷ (سال وقوع آتش) و ژوئیه ۲۰۲۲

Fig. 7: Comparison of the NBR and NDVI indices in the Zaca wildfire area at two time points: July 2007 (the year of the wildfire) and July 2022

نتیجه‌گیری

در این پژوهش، به‌منظور بررسی و پیش‌بینی روند بازیابی پوشش گیاهی پس از آتش‌سوزی‌های بزرگ، دو مطالعه موردی شامل آتش‌سوزی مجتمع شهرستان باستروپ و آتش‌سوزی زاکا، طی بازه زمانی ۲۰۰۰ تا ۲۰۲۲ مورد تحلیل قرار گرفتند. داده‌های مورداستفاده شامل شاخص‌های طیفی مختلف با تمرکز ویژه‌بر شاخص NDVI بود که از تصاویر ماهواره‌ای استخراج گردید.

تحلیل سری‌های زمانی نشان داد که هر دو حادثه باعث کاهش شدید شاخص‌های پوشش گیاهی و رطوبتی شده‌اند، با این تفاوت که شدت کاهش و الگوی بازیابی در دو منطقه متفاوت بوده است. در باستروپ، افت شاخص‌ها نسبتاً ملایم‌تر بوده و روند بازیابی تدریجی طی چند سال به مقادیر نزدیک به قبل از حادثه بازگشته است. در مقابل، در زاکا کاهش شدیدتر و ماندگارتری مشاهده شد و روند ترمیم کندتر بوده است، به‌گونه‌ای که اثرات آتش‌سوزی برای سال‌ها در مقادیر شاخص‌ها باقی‌مانده است.

برای پیش‌بینی سری زمانی NDVI پس از آتش‌سوزی، سه الگوریتم یادگیری ماشین شامل Random Forest (RF)، Support Vector Regression (SVR) و Extreme Gradient Boosting (XGBoost) پیاده‌سازی و ارزیابی شدند. مدل SVR با دقت R^2 و RMSE به ترتیب ۰.۹۵۵۶ و ۰.۰۱۱۸ برای منطقه باستروپ در داده‌های آزمون بهترین عملکرد را داشت. تحلیل اهمیت متغیرها در RF نشان داد که دو شاخص NBR و NDWI بیشترین سهم را در پیش‌بینی تغییرات NDVI داشته‌اند که بیانگر اهمیت ترکیب شاخص‌های حساس به سوختگی و رطوبت در مدل‌سازی فرایند بازیابی است. همچنین نرخ بازگشت پوشش گیاهی (VRR) در باستروپ ۰.۰۱۲۸ و در زاکا ۰.۰۰۹۲ محاسبه شد که نشان داد بازگشت پوشش گیاهی در باستروپ سریع‌تر و در زاکا کندتر است. این اعداد حاکی از روند نسبتاً پیوسته اما آهسته بازیابی اکوسیستم پس از تغییرات محیطی هستند.

در نهایت، این پژوهش نشان داد که ترکیب روش‌های پیشرفته یادگیری ماشین با تحلیل‌های دقیق شاخص‌های پوشش گیاهی، می‌تواند به ابزاری توانمند برای مدیریت و برنامه‌ریزی منابع طبیعی پس از حوادث گسترده مانند آتش‌سوزی تبدیل شود. استفاده از چنین رویکردهایی در کنار داده‌های به‌روز و متنوع، گامی مهم در جهت بهبود تاب‌آوری اکوسیستم‌ها و کاهش اثرات منفی حریق بر زیست‌بوم‌های حساس خواهد بود.

در تحقیقات آینده پیشنهاد می‌شود با افزایش تعداد مناطق موردمطالعه، استفاده از داده‌های باقدرت تفکیک مکانی و زمانی بالاتر و ترکیب متغیرهای اقلیمی، توپوگرافی و اطلاعات میدانی، مدل‌های جامع‌تری برای پیش‌بینی بلندمدت تاب‌آوری اکوسیستم‌ها پس از آتش‌سوزی توسعه یابد. همچنین بررسی روش‌های پیشرفته‌تر یادگیری عمیق و مدل‌های ترکیبی می‌تواند مسیر مناسبی برای بهبود دقت پیش‌بینی تغییرات پوشش گیاهی در مقیاس‌های گسترده‌تر باشد.

مشارکت نویسندگان

در این مقاله، نویسندگان به نسبت سهم برابر مشارکت داشته‌اند.

تشکر و قدردانی

بدین‌وسیله از همکارانی که ما را در انجام این تحقیق یاری کردند، صمیمانه تشکر می‌کنیم.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان‌نشده است.»

منابع و مآخذ

[1] Sitanggang, I.S., N.M. Razali Yaakob, and A. Ainuddin, *Based on Physical, Socio-Economic, and Peatlands Data.* Discovering New Roads to Development, 2020. 19.

[2] Salamati, H., et al. Evaluation and provision of forest fire risk map using GIS in Golestan forests. in Proceeding of the First International Conference on Fire in Natural Resources, Gorgan, Iran. 2011.

[3] Eva, H. and E.F. Lambin, Fires and land-cover change in the tropics: a remote sensing analysis at the landscape scale. Journal of Biogeography, 2000. 27(3): p. 765–776. https://doi.org/10.1046/j.1365-2699.2000.00441.x

[4] Matricardi, E.A., et al., Assessment of tropical forest degradation by selective logging and fire using Landsat imagery. Remote Sensing of Environment, 2010. 114(5): p. 1117–1129. https://doi.org/10.1016/j.rse.2010.01.001

[5] Mölders, N. and G. Kramm, Influence of wildfire induced land-cover changes on clouds and precipitation in Interior Alaska—A case study. Atmospheric Research, 2007. 84(2): p. 142–168. https://doi.org/10.1016/j.atmosres.2006.06.004

[6] Amiro, B., J. MacPherson, and R. Desjardins, BOREAS flight measurements of forest-fire effects on carbon dioxide and energy fluxes. Agricultural and Forest Meteorology, 1999. 96(4): p. 199–208. https://doi.org/10.1016/S0168-1923(99)00050-7

[7] Palacios-Orueta, A., et al., Biomass burning emissions: a review of models using remote-sensing data. Environmental monitoring and assessment, 2005. 104(1-3): p. 189–209. https://doi.org/10.1007/s10661-005-1611-y

[8] Flannigan, M.D., et al., Forest fires and climate change in the 21 st century. Mitigation and adaptation strategies for global change, 2006. 11(4): p. 847–859. https://doi.org/10.1007/s11027-005-9020-7

[9] Lentile, L.B., et al., Remote sensing techniques to assess active fire characteristics and post-fire effects. International Journal of Wildland Fire, 2006. 15(3): p. 319–345. https://doi.org/10.1071/WF05097

Global Ecology and Biogeography, 2025. 34(4): p. e70040. https://doi.org/10.1111/geb.70040

[20] Ouattara, B., et al., Fire Impacts, vegetation Recovery, and environmental drivers in West African savannas (2014–2023): A High-Resolution remote sensing assessment. International Journal of Applied Earth Observation and Geoinformation, 2025. 143: p. 104783. https://doi.org/10.1016/j.jag.2025.104783

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



امیر شاهرخ امینی دانشیار گروه مهندسی نقشه‌برداری دانشگاه آزاد اسلامی واحد تهران جنوب هستند .ایشان مدرک کارشناسی ارشد و دکتری خود را در رشته مهندسی نقشه‌برداری، گرایش فتوگرامتری، به‌ترتیب در سال‌های ۱۳۸۵ و ۱۳۹۳ از دانشگاه صنعتی خواجه نصیرالدین طوسی دریافت کرده‌اند .زمینه‌های تخصصی ایشان شامل فتوگرامتری، سنجش از دور و کاربردهای سنجش از دور در مدیریت بلایای طبیعی است.

Amini,A. Assistant professor of Remote Sensing Department, Islamic Azad University, South Tehran Branch, Tehran, Iran

sh_amini@azad.ac.ir



جواد مهجوریان نماری کارشناس ارشد مهندسی نقشه برداری- سنجش از دور از دانشگاه آزاد اسلامی واحد تهران جنوب می‌باشد. همچنین در حال حاضر عضو هیات علمی دانشگاه شمال در گروه نقشه برداری است.

Mohjoorian namari, M.Sc. in Remote Sensing, Faculty of Technical Engineering, Islamic Azad University, South Tehran Branch, Tehran, Iran

javadmahjoorian1001@shomal.ac.ir

[10] French, N.H., et al., Using Landsat data to assess fire and burn severity in the North American boreal forest region: an overview and summary of results. International Journal of Wildland Fire, 2008. 17(4): p. 443–462. https://doi.org/10.1071/WF08007

[11] Veraverbeke, S., et al., The temporal dimension of differenced Normalized Burn Ratio (dNBR) fire/burn severity studies: The case of the large 2007 Peloponnese wildfires in Greece. Remote Sensing of Environment, 2010. 114(11): p. 2548–2563. https://doi.org/10.1016/j.rse.2010.05.029

[12] Seidl, R., et al., Modelling natural disturbances in forest ecosystems: a review. Ecological modelling, 2011. 222(4): p. 903–924. https://doi.org/10.1016/j.ecolmodel.2010.09.040

[13] Leon, J.R.R., W.J. Van Leeuwen, and G.M. Casady, Using MODIS-NDVI for the modeling of post-wildfire vegetation response as a function of environmental conditions and pre-fire restoration treatments. Remote sensing, 2012. 4(3): p. 598–621. https://doi.org/10.3390/rs4030598

[14] Hadi, D.P., A RS/GIS–Based Multi-Criteria Approaches to Assess Forest Fire Hazard in Indonesia. 2008, Citeseer.

[15] Vasilakos, C., et al., Neural-network time-series analysis of MODIS EVI for post-fire vegetation regrowth. ISPRS International Journal of Geo-Information, 2018. 7(11): p. 420. https://doi.org/10.3390/ijgi7110420

[16] Kim, Y., et al., Recovery of forest vegetation in a burnt area in the Republic of Korea: A perspective based on sentinel-2 data. Applied Sciences, 2021. 11(6): p. 2570. https://doi.org/10.3390/app11062570

[17] Bao, S.G., et al., Revealing post-megafire spectral and compositional recovery in the Siberian boreal forest using Landsat time series and regression-based unmixing approach. Remote Sensing of Environment, 2024. 311: p. 114307. https://doi.org/10.1016/j.rse.2024.114307

[18] Avetisyan, D., N. Stankova, and Z. Dimitrov, Assessment of spectral vegetation indices performance for post-fire monitoring of different forest environments. Fire, 2023. 6(8): p. 290. https://doi.org/10.3390/fire6080290

[19] Gibson, R.K., et al., Remotely sensed fire heterogeneity and biomass recovery predicts empirical biodiversity responses.

Citation (Vancouver): Amini A. Sh, Mahjoorian Namari J. [Analyzing and predicting the process of vegetation regeneration post fire using multi-sensor data and machine learning algorithms]. *J. RS. GEOINF. RES. 2026; 4(2): 321-334*

https://doi.org/10.22061/jrsgr.2026.113280.1133

COPYRIGHTS

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)