

Predicting the Impacts of Climate Change on Vegetation Dynamics (NDVI) in Arid Ecosystems Using Machine Learning Models: A Case Study of Hormozgan Province

Masoomeh Forozanfard¹, Ommolbanin Bazrafshan^{*2}, Yahya Esmacilpour³, Hossein Zamani⁴, Mojtaba Mohammadi⁵

- 1- PhD Student, Department of Natural Resources Engineering, Faculty of Agricultural and Natural Resources Engineering, University of Hormozgan, Bandar Abbas, Iran.
- 2- Professor, Department of Natural Resources Engineering, Faculty of Agricultural and Natural Resources Engineering, University of Hormozgan, Bandar Abbas, Iran.
- 3- Associate Professor, Department of Natural Resources Engineering, Faculty of Agricultural and Natural Resources Engineering, University of Hormozgan, Bandar Abbas, Iran.
- 4- Department of Statistics and Mathematics, Faculty of Science, University of Hormozgan, Bandar Abbas, Iran.
- 5- Associate Professor, Department of Desert Management and Control, Faculty of Environmental Sciences, Planning and Sustainable Development, University of Saravan, Saravan, Iran.

* Corresponding Author Email: o.bazrafshan@hormozgan.ac.ir

Introduction

Arid and semi-arid ecosystems, which constitute a significant portion of the Earth's land surface, are exceptionally vulnerable to the impacts of climate change. Water scarcity, high temperature fluctuations, and fragile ecological balances characterize these regions. Vegetation in these areas serves a critical role in preventing soil erosion, maintaining biodiversity, and supporting local livelihoods. The Normalized Difference Vegetation Index (NDVI) is a widely used satellite-derived metric that serves as a robust indicator of vegetation health, density, and photosynthetic activity. Understanding and predicting the long-term dynamics of NDVI is therefore essential for sustainable land management and developing effective strategies to mitigate the effects of climate change. Traditional modeling approaches often struggle to capture complex, non-linear interactions between climatic factors and vegetation responses. In recent years, machine learning (ML) models have emerged as powerful tools for environmental modeling due to their ability to learn intricate patterns from large datasets. This study aims to leverage multiple ML models to predict future vegetation dynamics in two distinct locations within the arid ecosystem of Hormozgan Province, Iran. Specifically, the objective is to forecast NDVI changes through 2100 under the SSP3-7.0 high-emission scenario, thereby providing valuable insights for regional drought management and conservation planning.

Materials and Methods

This study was conducted at two specific points within Hormozgan Province, an area representative of Iran's arid southern coastal ecosystems. The historical dataset used for model training and validation spanned from 2000 to 2018. Vegetation data were sourced from the MODIS Terra MOD13A1 product, providing monthly NDVI values at a 500-meter spatial resolution. Corresponding historical climate data, including temperature and precipitation, were obtained from the ERA5 reanalysis dataset. For future climate projections, downscaled data from the Coupled Model Intercomparison Project Phase 6 (CMIP6) were utilized, based on the Shared Socioeconomic Pathway SSP3-7.0, which represents a medium-to-high emissions and challenging adaptation scenario. Four distinct machine learning models were selected for their proven capabilities in regression tasks: Gaussian Process Regression (GPR), Generalized Additive Model (GAM), Random Forest (RF), and eXtreme Gradient Boosting (XGBoost). The dataset was partitioned into training (80%) and testing (20%) sets to ensure robust model evaluation. The performance of each model was rigorously assessed using a suite of statistical metrics: Kling-Gupta Efficiency (KGE), Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and the coefficient of determination (R^2). KGE was considered the primary metric for selecting the best-performing model for each location, as it provides a comprehensive assessment by incorporating correlation, bias, and variability.

Results and Discussion

The evaluation of the machine learning models revealed distinct performance differences between the two selected locations. For the first point, the Gaussian Process Regression (GPR) model demonstrated the highest predictive accuracy, achieving a Kling-Gupta Efficiency (KGE) value greater than 0.88 during the testing phase. For the second point, the eXtreme Gradient Boosting (XGBoost) model proved to be the most effective, also yielding a KGE value above 0.88. These high KGE scores, supported by strong R^2 values and low RMSE and MAE, indicate that both GPR and XGBoost were highly successful in capturing the complex, non-linear relationships between climatic variables and NDVI in their respective locations. The superior performance of different models in different areas underscores the spatial heterogeneity of the ecosystem and highlights the importance of selecting appropriate models for specific local conditions rather than applying a one-size-fits-all approach. Using the best-performing model for each site, future NDVI dynamics were projected until the year 2100 under the SSP3-7.0 climate change scenario. The projections forecast a significant increase in vegetation activity for both locations. For the first point (modeled with GPR), the results indicate a potential increase in NDVI of approximately 42% by the end of the century. For the second point (modeled with XGBoost), a more moderate but still significant increase of 10.9% was predicted. This projected "greening" trend, despite the general aridity of the region, could be attributed to several factors, including the CO₂ fertilization effect and altered rainfall patterns, which may favor certain types of vegetation. However, this increase does not necessarily equate to improved ecosystem health, as it may also reflect shifts in plant species composition, including the spread of invasive species, which requires careful ecological monitoring. The findings emphasize that climate change impacts are not uniform and necessitate location-specific analysis for accurate environmental planning.

Conclusion

This study successfully demonstrated the utility of machine learning models for predicting long-term vegetation dynamics in arid ecosystems under a high-emission climate change scenario. The results confirmed that there is no single best model for all ecological settings; GPR and XGBoost were identified as the most robust models for the two different study sites in Hormozgan Province, respectively. The long-term projections up to 2100 forecast a notable increase in NDVI for both locations, suggesting a potential greening trend. This outcome highlights the complex response of arid vegetation to changing climatic conditions. The primary implication of this research is the critical need for developing location-specific drought management and ecosystem conservation strategies. By providing detailed, localized future scenarios, policymakers and resource managers can better anticipate challenges and implement targeted interventions to enhance the resilience of these vulnerable ecosystems against the adverse impacts of climate change.

Keywords: Climate Change, Vegetation Dynamics, NDVI, Machine Learning, Arid Ecosystems, Hormozgan Province.

پیش‌بینی اثرات تغییر اقلیم بر پویایی پوشش گیاهی (NDVI) در اکوسیستم‌های خشک با استفاده از مدل‌های یادگیری ماشین: مطالعه موردی استان هرمزگان

- معصومه فروزان فرد^۱، ام البنین بذرافشان^{۲*}، یحیی اسماعیل پور^۳، حسین زمانی^۴، مجتبی محمدی^۵
- ۱- دانشجوی دکتری مدیریت و کنترل بیابان، گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران.
 - ۲- استاد گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران.
(o.bazrafshan@hormozgan.ac.ir)
 - ۳- دانشیار گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران.
 - ۴- استادیار گروه آمار، دانشکده علوم پایه، دانشگاه هرمزگان، هرمزگان، ایران.
 - ۵- دانشیار، گروه مدیریت و کنترل بیابان، دانشکده علوم محیطی، برنامه ریزی و توسعه پایدار، دانشگاه سراوان، سیستان و بلوچستان، ایران.

*ایمیل نویسنده مسئول: o.bazrafshan@hormozgan.ac.ir

چکیده:

تغییرات اقلیمی، اکوسیستم‌های شکننده مناطق خشک مانند استان هرمزگان را تهدید می‌کند. هدف این پژوهش، پیش‌بینی پویایی آینده پوشش گیاهی (NDVI) تا سال ۲۱۰۰ با استفاده از مقایسه مدل‌های پیشرفته یادگیری ماشین و تحت سناریوی بدبینانه تغییر اقلیم (SSP3-7.0) است. در این راستا، سری زمانی NDVI محصول MODIS (2000-2018) و داده‌های اقلیمی ERA5 برای دو نقطه نماینده در استان استخراج شد. عملکرد چهار الگوریتم یادگیری ماشین (GPR, GAM, RF, XGBoost) با معیارهای آماری دقیق ارزیابی و مدل بهینه برای پیش‌بینی آینده با استفاده از داده‌های مدل GFDL-ESM4 تحت سناریوی SSP3-7.0 به کار گرفته شد. نتایج ارزیابی نشان داد که مدل‌های رگرسیون فرآیند گاوسی (GPR) برای نقطه اول و تقویت گرادبان شدید (XGBoost) برای نقطه دوم با کارایی کلینگ-گوپتا (KGE) بالاتر از ۰.۸۸، برترین عملکرد را در مرحله آزمون داشتند. پیش‌بینی‌ها تا افق ۲۱۰۰، دو پاسخ اکولوژیکی واگرا را آشکار ساخت: نقطه اول با رشد چشمگیر ۴۲ درصدی NDVI (پدیده سبز شدن) و نقطه دوم با رشدی ملایم و سپس رسیدن به پایداری (افزایش ۱۰.۹ درصدی) مواجه خواهد شد. این ناهمگونی مکانی نشان می‌دهد که اکوسیستم‌های منطقه پاسخ‌های متفاوتی از خود نشان می‌دهند. نتیجه‌گیری می‌شود که راهکارهای مدیریتی برای مقابله با خشکسالی باید مکان‌محور بوده و بر اساس پتانسیل رشد یا تاب‌آوری هر منطقه تدوین شوند.

واژه‌های کلیدی: تاب‌آوری اکولوژیک، سناریوهای SSP، مدیریت تطبیقی، پیش‌پوشش گیاهی، مدل‌های داده‌محور

مقدمه

پوشش گیاهی، به عنوان یک جزء حیاتی و پیونددهنده میان اتمسفر، خاک و آب، نقشی اساسی در تنظیم چرخه‌های بیوژئوشیمیایی، تعادل آب و کربن، و دستیابی به اهداف پایداری محیطی ایفا می‌کند (Tobore et al., 2025; Li et al., 2025). به ویژه در اکوسیستم‌های شکننده مانند جنگل‌های کوهستانی که نقاط داغ تنوع زیستی و برج‌های آب حیاتی هستند، پویایی پوشش گیاهی به عنوان یک شاخص کلیدی برای ارزیابی سلامت و تاب‌آوری اکوسیستم در برابر تغییرات اقلیمی عمل می‌کند (Otieno et al., 2025; Li et al., 2024). با پیشرفت فناوری سنجش از دور، شاخص تفاضل نرمال شده پوشش گیاهی (NDVI) به دلیل همبستگی قوی با سلامت و تراکم پوشش گیاهی، به ابزاری استاندارد برای پیش‌بینی تغییرات زیست‌محیطی در مقیاس‌های زمانی و مکانی مختلف تبدیل شده است (Pato et al, 2025; Sun et al., 2023; Liu et al., 2021).

این چالش‌ها به ویژه در مناطق خشک و نیمه‌خشک جهان، که ذاتاً به تغییرات اقلیمی حساس‌تر هستند، تشدید می‌شوند. استان هرمزگان در جنوب ایران، نمونه بارزی از یک اکوسیستم تحت تنش شدید اقلیمی است. این منطقه با آب و هوای گرم و خشک، تابستان‌های بسیار داغ و مرطوب که دما در آن می‌تواند از ۵۰ درجه سانتی‌گراد فراتر رود و میانگین بارش سالانه آن کمتر از

۲۰۰ میلی‌متر است، مشخص می‌شود (Dehghanisani et al., 2025; Shamsaei et al., 2025; Sharifi et al., 2025). خاک‌های منطقه عمدتاً از نوع Entisols و Aridisols هستند که با محتوای کم مواد آلی و ظرفیت محدود نگهداری آب، آسیب‌پذیری اکوسیستم را در برابر خشکسالی افزایش می‌دهند (Sharifi et al., 2025). این شرایط سخت اقلیمی، استان هرمزگان را با چالش‌های زیست‌محیطی متعددی نظیر خطر بالای بیابان‌زایی، تخریب سرزمین، و وقوع مکرر طوفان‌های گرد و غبار مواجه کرده است، به طوری که مطالعات نشان داده‌اند فقر پوشش گیاهی و کمبود رطوبت خاک از عوامل اصلی تشدید این پدیده در منطقه هستند (Kazemi et al., 2020). بنابراین، پایش و مهم‌تر از آن، پیش‌بینی دقیق واکنش پوشش گیاهی به تغییرات اقلیمی در این استان، نه تنها یک کنجکاو علمی، بلکه یک ضرورت انکارناپذیر برای تدوین سیاست‌های مدیریتی مؤثر جهت حفاظت از منابع طبیعی، مقابله با بیابان‌زایی و کاهش آسیب‌پذیری جوامع محلی است.

با این حال، مدل‌سازی و پیش‌بینی پویایی NDVI یک چالش علمی پیچیده است، زیرا این فرآیند تحت تأثیر تعاملات پیچیده و غیرخطی میان عوامل متعدد اقلیمی و انسانی قرار دارد (Ma et al., 2021). روش‌های آماری کلاسیک که اغلب بر فرض خطی بودن و توزیع نرمال داده‌ها استوار هستند، در درک کامل این روابط با محدودیت مواجه هستند (Buczynski, & Dawidowicz, 2025). به عنوان مثال، واکنش پوشش گیاهی به عواملی مانند بارش اغلب با تأخیر زمانی همراه بوده و پاسخ آن به دما می‌تواند غیرخطی باشد که این پیچیدگی‌ها از توانایی مدل‌های رگرسیون سنتی فراتر است (Wagle et al., 2024; Phan et al., 2021). این محدودیت‌ها، ضرورت گذار به رویکردهای مدل‌سازی پیشرفته‌تر را برجسته می‌سازد.

برای غلبه بر این چالش‌ها، الگوریتم‌های یادگیری ماشین (Machine Learning) به دلیل توانایی استثنایی در مدیریت داده‌های چندمتغیره و غیرخطی، بدون نیاز به فرض آماری سخت‌گیرانه، به ابزارهای مؤثری در علوم محیطی تبدیل شده‌اند (Tobore et al., 2025). مطالعات اخیر به طور فزاینده‌ای نشان می‌دهند که الگوریتم‌های مبتنی بر درخت تصمیم، به‌ویژه مدل‌های گروهی (ensemble) مانند جنگل تصادفی (Random Forest) و تقویت گرادیان شدید (XGBoost)، به دلیل مقاومت بالا در برابر بیش‌برازش (overfitting) و توانایی در ثبت روابط پیچیده، عملکردی به‌مراتب بهتر از مدل‌های رگرسیون خطی در شبیه‌سازی شاخص‌های پوشش گیاهی دارند (Otiño et al., 2025; Sun et al., 2023). با این حال، باید توجه داشت که مدل‌های مختلف یادگیری ماشین دارای نقاط قوت و ضعف متفاوتی هستند؛ برای مثال، مدل‌های خطی منظم‌شده سرعت محاسباتی بالاتر و تفسیرپذیری بهتری را ارائه می‌دهند، در حالی که مدل‌های غیرخطی مانند شبکه‌های عصبی و جنگل تصادفی در مدل‌سازی تعاملات پیچیده دقیق‌تر عمل می‌کنند (Buczynski, 2025 & Dawidowicz). این تفاوت‌ها، انجام یک تحلیل مقایسه‌ای برای انتخاب مناسب‌ترین مدل برای یک مسئله خاص را ضروری می‌سازد.

فراتر از تحلیل‌های گذشته‌نگر، یک مرز تحقیقاتی حیاتی و رو به رشد، استفاده از این مدل‌های قدرتمند برای پیش‌بینی واکنش‌های آینده اکوسیستم‌ها تحت سناریوهای مختلف تغییر اقلیم است. مطالعاتی مانند Nguyen et al. (۲۰۲۳) و Otiño et al. (۲۰۲۵) با موفقیت نشان داده‌اند که می‌توان با تلفیق مدل‌های یادگیری ماشین با داده‌های خروجی مدل‌های گردش عمومی جو (GCMs) از پروژه CMIP6، تغییرات آبی پوشش گیاهی را پیش‌بینی کرده و مناطق آسیب‌پذیر را شناسایی نمود. این رویکرد پیش‌نگرانه، علم را از تحلیل‌های واکنشی به سمت ابزاری برای برنامه‌ریزی پیشگیرانه و مدیریت تطبیقی سوق می‌دهد. درک اینکه چگونه پوشش گیاهی در دهه‌های آینده تحت سناریوهای مختلف انتشار (SSPs) تغییر خواهد کرد، برای سیاست‌گذاری‌های مبتنی بر شواهد در زمینه حفاظت از تنوع زیستی و مدیریت پایدار منابع طبیعی از اهمیت ویژه‌ای برخوردار است (Nguyen et al., 2023).

بنابراین، این پژوهش با هدف بهره‌گیری از قابلیت‌های مدل‌های پیشرفته یادگیری ماشین برای پر کردن شکاف تحقیقاتی موجود در زمینه پیش‌بینی آینده پوشش گیاهی در یک منطقه حساس به تغییرات اقلیمی طراحی شده است. اهداف اصلی این مطالعه عبارت‌اند از: (۱) ارزیابی و مقایسه عملکرد مدل‌های یادگیری ماشین شامل رگرسیون فرایند گاوسی (GPR)، مدل‌های افزودنی تعمیم‌یافته (GAM)، XGBoost و Random Forest در شبیه‌سازی دقیق شاخص NDVI برای دوره تاریخی در استان هرمزگان؛ (۲) شناسایی مهم‌ترین متغیرهای اقلیمی مؤثر بر پویایی پوشش گیاهی؛ و (۳) پیش‌بینی تغییرات مکانی و زمانی NDVI برای دوره آینده تحت سناریوهای مختلف تغییر اقلیم با استفاده از مدل بهینه. نتایج این تحقیق می‌تواند به درک عمیق‌تری از واکنش

اکوسیستم‌های منطقه‌ای به تغییرات اقلیمی کمک کرده و مبنای علمی لازم برای مدیریت پایدار منابع طبیعی در این منطقه آسیب‌پذیر را فراهم آورد.

مواد و روش‌ها

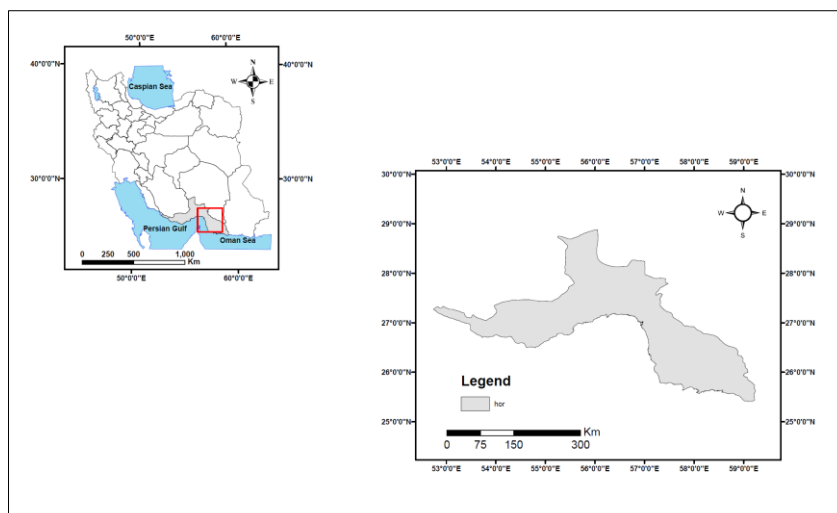
منطقه مورد مطالعه

استان هرمزگان، در جنوب ایران بین عرض‌های جغرافیایی $24^{\circ} 25'$ تا $28^{\circ} 57'$ شمالی و طول‌های جغرافیایی $41^{\circ} 53'$ تا $59^{\circ} 15'$ شرقی واقع شده است (شکل ۱). این استان با خط ساحلی به طول تقریبی ۹۰۰ کیلومتر در امتداد خلیج فارس و دریای عمان، از موقعیتی استراتژیک برخوردار است. توپوگرافی منطقه دارای تنوع قابل توجهی بوده و از مناطق کوهستانی متأثر از رشته‌کوه‌های زاگرس در شمال و شمال شرق تا دشت‌های پست ساحلی در جنوب امتداد می‌یابد. اقلیم حاکم بر استان، گرم و خشک تا نیمه‌خشک است که با میانگین دمای سالانه حدود ۲۷ درجه سانتی‌گراد و بارش سالانه نامنظم و اندک (کمتر از ۲۰۰ میلی‌متر) مشخص می‌شود. این شرایط، دسترسی به آب را به اصلی‌ترین عامل محدودکننده رشد گیاهی تبدیل کرده است. در نتیجه، پوشش گیاهی منطقه عمدتاً از گونه‌های مقاوم به خشکی و شوری تشکیل شده و شامل مراتع بیابانی و اکوسیستم‌های منحصربه‌فرد جنگل‌های حرا (مانگرو) با گونه غالب *Avicennia marina* می‌شود. حساسیت بالای این اکوسیستم‌های شکننده به نوسانات اقلیمی، دلیل اصلی انتخاب این استان برای تحلیل روند تغییرات پوشش گیاهی است.

به‌منظور بررسی دقیق واکنش پوشش گیاهی به متغیرهای اقلیمی، تحلیل به‌صورت نقطه‌ای بر روی دو مکان منتخب متمرکز گردید. این نقاط به‌گونه‌ای انتخاب شدند که نماینده دو زیرمنطقه اقلیمی-اکولوژیکی متمایز در استان باشند. با انتخاب دو نقطه که دارای حداکثر فاصله جغرافیایی از یکدیگر در سطح استان هستند، هدف آن بود که طیف وسیعی از گرادیان‌های محیطی، به‌ویژه تفاوت در رژیم‌های دمایی و بارشی بین مناطق داخلی و شمالی‌تر استان با مناطق ساحلی و جنوبی، در تحلیل لحاظ گردد. نقطه شماره ۱: (طول جغرافیایی: 55.75 ، عرض جغرافیایی: 28.5)، نقطه شماره ۲: (طول جغرافیایی: 57 ، عرض جغرافیایی: 27). نقطه شماره ۱ در مناطق داخلی و شمالی‌تر استان واقع شده است که تحت تأثیر رژیم‌های اقلیمی بری‌تر و توپوگرافی کوهستانی قرار دارد. در مقابل، نقطه شماره ۲ در مناطق جنوبی‌تر و نزدیک به نوار ساحلی قرار گرفته که بیشتر تحت تأثیر رطوبت خلیج فارس و اقلیم دریایی است. انتخاب نقاطی در امتداد این گرادیان جغرافیایی شمال به جنوب، تضمین می‌کند که داده‌های ورودی به مدل، طیف وسیع‌تری از شرایط اقلیمی و پاسخ‌های اکولوژیکی موجود در استان هرمزگان را پوشش دهند. این تنوع در داده‌های آموزشی، به ساخت مدل‌های قوی‌تر (robust) کمک کرده و ارزیابی عملکرد آن‌ها را در شرایط محیطی گوناگون ممکن می‌سازد.

به‌منظور اطمینان از نمایندگی آماری نقاط منتخب، تحلیل دقیقی بر روی داده‌های اقلیمی بلندمدت (میانگین دمای سالانه و مجموع بارش سالانه) این دو نقطه و مقایسه آن با توزیع آماری مشابه در کل استان هرمزگان انجام شد. نتایج این مقایسه نشان داد که دو نقطه انتخاب شده به ترتیب در صدک‌های ۱۰ و ۹۰ توزیع آماری متغیرهای کلیدی اقلیمی (مانند دما و بارش) در سطح استان قرار دارند. این بدان معناست که انتخاب این دو نقطه، دامنه وسیعی از شرایط اقلیمی استان را پوشش داده و ۸۰٪ از تنوع اقلیمی مشاهده شده در استان را در داده‌های آموزشی لحاظ می‌کند. این رویکرد آماری، اطمینان از قدرت تعمیم‌پذیری مدل نهایی را افزایش می‌دهد.





شکل ۱. موقعیت جغرافیایی استان هرمزگان در ایران

Fig 1. Geographical location of Hormozgan Province in Iran.

داده‌های شاخص پوشش گیاهی (NDVI)

در این پژوهش، برای ساخت مدل‌های یادگیری ماشین، از سری زمانی داده‌های شاخص تفاضل نرمال شده پوشش گیاهی محصول MOD13Q1 نسخه ۶ استفاده گردید. این داده‌ها توسط سنجنده MODIS که بر روی ماهواره Terra نصب شده است، جمع‌آوری می‌شوند. محصول MOD13Q1 دارای قدرت تفکیک مکانی ۲۵۰ متر و قدرت تفکیک زمانی ۱۶ روزه است. بازه زمانی مورد استفاده، دوره ۱۹ ساله از ژانویه ۲۰۰۰ تا دسامبر ۲۰۱۸ را در بر می‌گیرد.

از آنجا که قدرت تفکیک زمانی داده‌های محصول MOD13Q1 برابر با ۱۶ روز است، در حالی که داده‌های اقلیمی استخراج شده دارای مقیاس زمانی ماهانه بودند، همگام‌سازی زمانی (Temporal Synchronization) این دو مجموعه داده برای ورود به مدل‌های یادگیری ماشین الزامی بود. به همین منظور، داده‌های ۱۶ روزه NDVI به مقیاس ماهانه تبدیل شدند. در این پژوهش برای استخراج یک مقدار واحد در هر ماه، از روش میانگین‌گیری ماهانه مقادیر استفاده گردید. استفاده از این روش نه تنها تطابق زمانی داده‌های ورودی و خروجی مدل را تضمین کرد، بلکه باعث کاهش تأثیرات باقیمانده احتمالی ناشی از نویزهای جوی در طول یک ماه تقویمی شد.

با استفاده از پلتفرم گوگل ارث انجین، سری زمانی مقادیر NDVI برای دو نقطه مشخص شده در بخش قبل استخراج گردید. این فرایند منجر به ایجاد دو مجموعه داده سری زمانی مجزا برای هر نقطه شد که به‌عنوان متغیر هدف (پاسخ) در مدل‌های یادگیری ماشین مورد استفاده قرار گرفت. انتخاب محصول MODIS به دلیل قدرت تفکیک زمانی بسیار بالای آن (۱۶ روزه) بود که برای مدل‌سازی دقیق دینامیک‌های فصلی و ماهانه پوشش گیاهی ضروری است. شاخص NDVI بر اساس تفاوت بازتاب سطوح در باندهای قرمز (Red) و فروسرخ نزدیک (NIR) محاسبه می‌شود (رابطه ۱):

$$NDVI = (NIR - Red) / (NIR + Red) \quad (1)$$

کیفیت رادیومتریک بالا و تصحیحات اتمسفری انجام شده بر روی این محصول، قابلیت اطمینان آن را برای استفاده در این پژوهش تضمین می‌کند.

با وجود اعمال تصحیحات اتمسفری و رادیومتریک اولیه بر روی محصول MOD13Q1 نسخه ۶، داده‌های سری زمانی خام اپتیکال معمولاً همچنان حاوی نویزهای باقیمانده ناشی از ابرها، سایه ابرها و ذرات معلق جوی هستند که می‌توانند بر نتایج مدل‌سازی تأثیر منفی بگذارند؛ بنابراین، برای شفافیت و افزایش دقت علمی پژوهش، یک مرحله پیش‌پردازش و پاک‌سازی داده‌ها در پلتفرم گوگل ارث انجین پیاده‌سازی شد. بدین منظور، از باندهای کنترل کیفیت (Quality Assurance) یا (QA) تعبیه شده در این محصول استفاده گردید. با اعمال فیلتر بر روی مقادیر QA، تمامی پیکسل‌های دارای پوشش ابر، سایه ابر و

کیفیت نامطلوب شناسایی شده و از سری زمانی ماسک (Mask) شدند تا در نهایت، تنها پیکسل‌های با کیفیت بالا (High-quality) و بدون نویز به‌عنوان متغیر هدف وارد الگوریتم‌های یادگیری ماشین گردند.

داده‌های اقلیمی (متغیرهای ورودی/پیش‌بین)

به‌منظور شبیه‌سازی و پیش‌بینی NDVI، مجموعه‌ای از متغیرهای اقلیمی کلیدی که به‌طور مستقیم بر فرایندهای فیزیولوژیک گیاهان تأثیر می‌گذارند، به‌عنوان متغیرهای پیش‌بین (مستقل) انتخاب شدند. این داده‌ها از مجموعه داده بازتحلیل ERA5 که توسط مرکز اروپایی پیش‌بینی‌های میان‌مدت جوی (ECMWF) ارائه می‌شود، استخراج گردیدند (Hersbach et al., 2020). مجموعه داده ERA5 به دلیل پوشش جهانی، تفکیک زمانی و مکانی بالا، و همگنی در طول زمان، به‌عنوان یکی از معتبرترین منابع داده اقلیمی در مطالعات محیطی شناخته می‌شود (Mohammadi, 2026).

سری زمانی ماهانه این متغیرها برای دوره زمانی مشابه با داده‌های NDVI (ژانویه ۲۰۰۰ تا دسامبر ۲۰۱۸) برای مختصات جغرافیایی دقیق دو نقطه مورد مطالعه استخراج شد. متغیرهای اقلیمی مورد استفاده در این پژوهش عبارتند از: دمای متوسط، کمینه و بیشینه هوا (tasmax, tas, tasmin): دما به‌عنوان یکی از اصلی‌ترین کنترل‌کننده‌های فرآیندهای فتوسنتز و رشد گیاه در نظر گرفته شد. تابش موج کوتاه فرودی (rsds): این متغیر میزان انرژی خورشیدی در دسترس برای فتوسنتز را نشان می‌دهد. رطوبت نسبی (hurs): این پارامتر به‌عنوان شاخصی از تنش آبی اتمسفری که بر تعرق گیاه تأثیر می‌گذارد، استفاده شد. در مرحله پیش‌پردازش، تمامی مقادیر دما که در واحد کلوین (K) بودند، به درجه سلسیوس ($^{\circ}\text{C}$) تبدیل شدند تا تفسیرپذیری آن‌ها در تحلیل‌های بعدی ساده‌تر شود. در نهایت، برای هر نقطه یک ماتریس داده یکپارچه تشکیل شد که در آن هر ردیف معرف یک گام زمانی ماهانه و هر ستون معرف یکی از متغیرهای اقلیمی پیش‌بین یا متغیر هدف NDVI بود.

لازم به ذکر است که در این پژوهش، متغیرهای مستقل اقلیمی صرفاً با مقادیر هم‌زمان (ماه متناظر با ثبت شاخص NDVI) وارد فرایند مدل‌سازی شدند و تأخیر زمانی احتمالی (Temporal Lag) در واکنش پوشش گیاهی به این عوامل در نظر گرفته نشده است. اگرچه پدیده‌ی تأخیر زمانی در بوم‌شناسی امری شناخته شده است، اما بررسی و بهینه‌سازی وقفه‌های زمانی مؤثر برای هر متغیر در این اقلیم خاص، مستلزم تحلیل‌های سری زمانی گسترده‌تری بود که در فاز اولیه این مطالعه (که تمرکز آن بر ارزیابی توانمندی الگوریتم‌های مختلف یادگیری ماشین است) لحاظ نگردید.

داده‌های اقلیمی آینده

به‌منظور پیش‌بینی تغییرات آینده شاخص NDVI، از داده‌های اقلیمی شبیه‌سازی شده توسط مدل گردش عمومی جو (GCM) GFDL-ESM4 که از پروژه مقایسه تطبیقی مدل‌های جفت شده فاز ۶ (CMIP6) استخراج شده، استفاده گردید. این داده‌ها از طریق پورتال پروژه بین‌بخشی مقایسه تطبیقی مدل‌های تأثیرات (ISIMIP) دریافت شد. پورتال ISIMIP داده‌های خام GCMs را با استفاده از روش‌های پیشرفته تصحیح بایاس (در این پژوهش، روش W5E5) پردازش کرده و آن‌ها را برای مطالعات تأثیرات منطقه‌ای مناسب‌سازی می‌کند (Lange, 2019). با این وجود، باید توجه داشت که پیش‌بینی‌های اقلیمی همواره با عدم قطعیت‌های ذاتی همراه هستند. اگرچه مدل GFDL-ESM4 عملکرد مناسبی در شبیه‌سازی چرخه‌های بیوژئوشیمیایی دارد، اما تکیه بر یک مدل گردش عمومی (GCM) منفرد، تمام دامنه عدم قطعیت‌های مدل‌سازی اقلیمی را پوشش نمی‌دهد. علاوه بر این، سناریوی SSP3-7.0 نمایانگر یک مسیر توسعه بدبینانه (رقابت منطقه‌ای با انتشار بالای گازهای گلخانه‌ای) است؛ لذا مفروضات این سناریو در خصوص تغییرات کاربری اراضی و واکنش‌های پیچیده اکولوژیکی (نظیر اثر لجاج دی‌اکسید کربن)، محدودیت‌ها و عدم قطعیت‌هایی را در پیش‌بینی دقیق پاسخ‌های طولانی‌مدت اکوسیستم به همراه دارد که باید در تفسیر نتایج لحاظ گردند. برای ارزیابی اثرات بالقوه شدید تغییر اقلیم بر اکوسیستم آسیب‌پذیر منطقه، در این پژوهش سناریوی SSP3-7.0 از مسیرهای مشترک اقتصادی-اجتماعی (SSPs) انتخاب شد (Riahi et al., 2017). این سناریو که با عنوان رقابت منطقه‌ای (Regional Rivalry) یا یک جاده سنگی (A Rocky Road) شناخته می‌شود، آینده‌ای چندقطبی با همکاری بین‌المللی ضعیف و چالش‌های جدی برای سازگاری و کاهش انتشار گازهای گلخانه‌ای را به تصویر می‌کشد. این مسیر به نیروی تابشی ۷ وات بر متر مربع در انتهای قرن منجر می‌شود و به‌عنوان یک سناریوی بدبینانه (Pessimistic Scenario) یا کسب‌وکار طبق روال معمول با چالش‌های

زیاد (High-Challenge Business-as-Usual) در نظر گرفته می‌شود که برای ارزیابی ریسک‌های حداکثری بر منابع طبیعی بسیار مناسب است.

داده‌های روزانه مربوط به همان متغیرهای اقلیمی دوره تاریخی (شامل tasmin, tasmax, tas, rsds, hurs) برای دوره آینده ۲۰۱۹ تا ۲۱۰۰ برای مختصات جغرافیایی دو نقطه مورد مطالعه استخراج گردید. این داده‌ها به عنوان ورودی به مدل یادگیری ماشین بهینه داده خواهند شد تا سری زمانی آینده NDVI برای هر نقطه، هر مدل GCM و هر سناریوی SSP به صورت مجزا پیش‌بینی شود.

الگوریتم‌های یادگیری ماشین

به‌منظور شبیه‌سازی و پیش‌بینی شاخص NDVI، از سه الگوریتم یادگیری ماشین با رویکردهای متفاوت استفاده شد. این مدل‌ها شامل رگرسیون فرایند گاوسی (GPR)، مدل‌های افزودنی تعمیم‌یافته (GAM)، XGBoost و Random Forest در شبیه‌سازی هستند. انتخاب این مجموعه از مدل‌ها امکان ارزیابی عملکرد روش‌های خطی و غیرخطی پیچیده را در حل مسئله فراهم می‌آورد. در ادامه، هر یک از این مدل‌ها به تفصیل شرح داده می‌شوند.

منطق اصلی در انتخاب هم‌زمان این الگوریتم‌ها، ارزیابی طیف متنوعی از رویکردهای مدل‌سازی و ایجاد تعادل میان قدرت تفسیرپذیری و دقت پیش‌بینی است. به‌عنوان نمونه، استفاده هم‌زمان از مدل‌های افزودنی تعمیم‌یافته (GAM) و تقویت‌گرادین شدید (XGBoost) امکان بررسی دو جنبه متفاوت از ساختار داده‌ها را فراهم می‌آورد؛ الگوریتم GAM به‌عنوان یک چارچوب نیمه‌پارامتریک، روابط بین متغیرهای اقلیمی و شاخص NDVI را به‌صورت هموار (Smooth) و با تفسیرپذیری بالا مدل‌سازی می‌کند که برای درک فیزیکی تأثیر هر متغیر بسیار کارآمد است. در مقابل، الگوریتم XGBoost به‌عنوان یک روش گروهی مبتنی بر درخت تصمیم، اگرچه ساختار پیچیده‌تر و تفسیرپذیری کمتری دارد، اما از قدرت استثنایی در کشف تعاملات غیرخطی و چندگانه (Non-linear interactions) میان متغیرهای اقلیمی برخوردار است. مقایسه این رویکردهای متفاوت، انتخاب ساختار بهینه برای شبیه‌سازی دقیق شرایط آینده را تضمین می‌کند.

رگرسیون فرایند گاوسی (Gaussian Process Regression - GPR)

رگرسیون فرایند گاوسی یک رویکرد غیرپارامتریک، بیزی (Bayesian) و مبتنی بر هسته برای مسائل رگرسیون است که به دلیل انعطاف‌پذیری بالا در مدل‌سازی روابط پیچیده و توانایی منحصربه‌فرد در ارائه تخمینی از عدم قطعیت پیش‌بینی‌ها، شهرت یافته است (Williams, 2006 & Rasmussen). برخلاف مدل‌های پارامتریک که یک تابع با پارامترهای مشخص را بر داده‌ها برازش می‌دهند، GPR یک توزیع احتمال بر روی تمام توابع ممکن تعریف می‌کند. این مدل فرض می‌کند که هر مجموعه‌ای از نقاط داده از یک توزیع گاوسی چندمتغیره پیروی می‌کنند.

یک فرایند گاوسی به طور کامل توسط دو مؤلفه تعریف می‌شود: یک تابع میانگین و یک تابع هم‌پراکنش یا هسته. تابع میانگین، مقدار مورد انتظار تابع را نشان می‌دهد و معمولاً برای سادگی، صفر در نظر گرفته می‌شود. قلب مدل GPR، تابع هسته، $k(\mathbf{x}, \mathbf{x}')$ است که میزان شباهت یا همبستگی بین دو نقطه ورودی \mathbf{x} و \mathbf{x}' را تعریف می‌کند. این تابع، فرض بنیادین مدل را کدگذاری می‌کند: نقاطی که در فضای ورودی به یکدیگر نزدیک‌تر هستند، مقادیر خروجی مشابهی خواهند داشت. یکی از رایج‌ترین توابع هسته، هسته تابع پایه شعاعی (Radial Basis Function - RBF) است که به دلیل انعطاف‌پذیری و قابلیت اعمال بر روی طیف وسیعی از مسائل، در این پژوهش نیز استفاده شد (Verrelst et al., 2012).

در مرحله آموزش، مدل GPR با بهینه‌سازی فرایندسازی پارامترهای تابع هسته از طریق بهینه‌سازی لگاریتم احتمال حاشیه‌ای (log marginal likelihood) بر روی داده‌های آموزشی، بهترین تابع هم‌پراکنش را پیدا می‌کند. پس از آموزش، مدل یک توزیع پسین (posterior distribution) بر روی توابع ایجاد می‌کند. برای یک نقطه ورودی جدید، GPR نه تنها یک پیش‌بینی نقطه‌ای (که همان میانگین توزیع پیش‌بینی است) ارائه می‌دهد، بلکه یک واریانس نیز محاسبه می‌کند که بیانگر عدم قطعیت آن پیش‌بینی است. این ویژگی، GPR را به ابزاری بسیار قدرتمند در علوم محیطی تبدیل می‌کند، زیرا امکان ارزیابی قابلیت اطمینان

پیش‌بینی‌های مدل، به‌ویژه در شرایط اقلیمی متغیر، را فراهم می‌سازد (Rasmussen & Williams, 2006; Salehnia et al, 2025).

جنگل تصادفی (Random Forest - RF)

جنگل تصادفی یک الگوریتم یادگیری گروهی قدرتمند است که بر پایه ساخت تعداد زیادی درخت تصمیم عمل می‌کند (Breiman, 2001). این مدل از تکنیک "تجمیع بوت‌استرپ" یا "بگینگ" (Bagging) برای آموزش هر درخت بر روی یک زیرمجموعه تصادفی از داده‌های آموزشی استفاده می‌کند. علاوه بر این، در هر گره از هر درخت، تنها زیرمجموعه‌ای تصادفی از متغیرهای پیش‌بین برای یافتن بهترین تقسیم در نظر گرفته می‌شود. این دو سطح از تصادفی‌سازی باعث می‌شود که مدل مقاومت بالایی در برابر بیش‌برازش داشته باشد. در مسائل رگرسیون، پیش‌بینی نهایی مدل جنگل تصادفی، میانگین پیش‌بینی‌های تمام درختان منفرد است. توانایی بالا در مدل‌سازی روابط غیرخطی پیچیده و ارائه معیاری برای اهمیت متغیرها (feature importance) از مزایای کلیدی این الگوریتم است.

تقویت گرادیان شدید (XGBoost)

تقویت گرادیان شدید (eXtreme Gradient Boosting) یک الگوریتم یادگیری گروهی مبتنی بر روش تقویت گرادیان است که به دلیل سرعت بالا و عملکرد استثنایی خود شهرت یافته است (Chen, 2016). برخلاف جنگل تصادفی که درختان را به صورت موازی و مستقل می‌سازد، XGBoost درختان تصمیم را به صورت متوالی ایجاد می‌کند. هر درخت جدید با هدف تصحیح خطاهای باقیمانده از مجموع درختان قبلی آموزش داده می‌شود. XGBoost با افزودن تکنیک‌های منظم‌سازی به تابع هزینه و بهینه‌سازی‌های محاسباتی پیشرفته، توانسته است مشکل بیش‌برازش را به خوبی کنترل کرده و به یکی از کارآمدترین الگوریتم‌ها برای مسائل رگرسیون و طبقه‌بندی تبدیل شود.

مدل‌های افزودنی تعمیم‌یافته (Generalized Additive Models - GAM)

مدل‌های افزودنی تعمیم‌یافته، یک چارچوب نیمه‌پارامتریک قدرتمند هستند که به‌عنوان تعمیمی بر مدل‌های خطی تعمیم‌یافته (GLM) توسعه یافته‌اند (Hastie and Tibshirani, 1990). مزیت اصلی GAM نسبت به روش‌های رگرسیون سنتی در این است که فرض وجود رابطه خطی میان متغیر پاسخ (NDVI) و متغیرهای پیش‌بین (اقلیمی) را کنار می‌گذارد. در عوض، این مدل اجازه می‌دهد تا داده‌ها خودشان شکل رابطه را تعیین کنند. در ساختار GAM، ترم‌های خطی ($\beta_i X_i$) با توابع هموارکننده غیرخطی (Smooth functions) جایگزین می‌شوند. ساختار کلی این مدل برای پیش‌بینی NDVI را می‌توان به صورت رابطه (۲) زیر بیان کرد:

$$g(E[Y]) = \beta_0 + \sum_{j=1}^p f_j(X_j) \quad (2)$$

که در آن، $E[Y]$ امید ریاضی متغیر پاسخ (NDVI)، $g(\cdot)$ تابع پیوند (Link function)، β_0 عرض از مبدأ، X_j متغیرهای پیش‌بین اقلیمی و $f_j(\cdot)$ توابع هموارکننده غیرپارامتریک هستند. معمولاً برای برازش این توابع هموارکننده از "اسپلاین‌های رگرسیونی" استفاده می‌شود که انعطاف‌پذیری بالایی در مدل‌سازی الگوهای غیرخطی و پیچیده اکولوژیک دارند (Wood, 2017). ویژگی متمایز GAM این است که به دلیل ساختار "افزودنی" خود، همچنان قابلیت تفسیرپذیری بالایی دارد و امکان بررسی اثر مجزای هر متغیر اقلیمی بر روی NDVI را فراهم می‌سازد.

استراتژی مدل‌سازی و ارزیابی

فرایند مدل‌سازی در این پژوهش طی مراحل نظام‌مند زیر انجام گردید. ابتدا در مرحله پیش‌پردازش، تمامی متغیرهای ورودی و هدف در بازه $[0, 1]$ نرمال‌سازی شدند. سپس، داده‌های سری زمانی تاریخی (۲۰۰۰-۲۰۱۸) برای هر نقطه با حفظ ترتیب زمانی به دو بخش تقسیم شدند: ۸۰ درصد ابتدایی داده‌ها (ژانویه ۲۰۰۰ تا دسامبر ۲۰۱۵) جهت آموزش (Training) و تنظیم

مدل‌ها، و ۲۰ درصد انتهایی (ژانویه ۲۰۱۶ تا دسامبر ۲۰۱۸) جهت آزمون (Testing) و ارزیابی قابلیت تعمیم‌پذیری مدل‌ها بر روی داده‌های دیده‌نشده اختصاص یافت.

در گام دوم، برای دستیابی به بهترین عملکرد، فرایند تنظیم فرآپارامترها (Hyperparameter Tuning) با استفاده از روش اعتبارسنجی متقابل ۱۰ لایه (۱۰-fold Cross-Validation) بر روی داده‌های آموزشی اجرا شد. برای مدل RF و XGBoost، پارامترهایی نظیر تعداد درختان و عمق درختان بهینه شدند. برای مدل GPR، پارامترهای تابع هسته (سیگما) تنظیم گردید. برای مدل GAM، درجات آزادی برای توابع هموارکننده اسپلاین بهینه‌سازی شد تا از بیش‌برازش جلوگیری شود. در نهایت، مدل بهینه بر اساس معیارهای آماری و نمودار تیلور انتخاب شده و برای پیش‌بینی آینده تحت سناریوهای اقلیمی به کار گرفته شد. کلیه تحلیل‌ها در محیط زبان برنامه‌نویسی R و با استفاده از بسته‌های نرم‌افزاری mgcv، caret (برای GAM)، randomForest، kernlab و xgboost انجام شد.

با توجه به همبستگی بسیار بالا و هم‌خطی چندگانه میان متغیرهای دمای متوسط، کمینه و بیشینه (tasmax, tasmin, tas)، به‌منظور جلوگیری از اثرات منفی آن بر عملکرد مدل، از روش تحلیل مؤلفه‌های اصلی (PCA) استفاده شد. در این فرایند، این سه متغیر به یک مؤلفه اصلی اول (PC1) که بیشترین واریانس داده‌های اصلی دما را تبیین می‌کند، کاهش داده شدند. این مؤلفه جدید که در این پژوهش temp_component نامیده می‌شود، به‌عنوان نماینده یکپارچه رژیم دمایی در مدل‌ها استفاده گردید.

انتخاب متغیرهای کلیدی و پیش‌پردازش داده‌ها در این پژوهش طی دو گام متوالی انجام پذیرفت. در گام نخست، به‌منظور رفع مشکل هم‌خطی شدید بین سه متغیر دمایی (میانگین دما، حداقل دما و حداکثر دما)، تکنیک تحلیل مؤلفه‌های اصلی (PCA) بر روی آن‌ها اعمال شد که منجر به تقلیل آن‌ها به یک شاخص ترکیبی واحد تحت عنوان temp_component گردید. برای تضمین هماهنگی کامل و یکپارچگی روش‌شناختی بین داده‌های تاریخی و آینده، ضرایب انتقال خطی PCA تنها یک‌بار و بر اساس داده‌های تاریخی (ERA5) محاسبه و برازش شدند. سپس، دقیقاً همان ضرایب و ماتریس تبدیل (Transformation Matrix) برای کاهش ابعاد متغیرهای دمایی در خروجی مدل‌های اقلیمی آینده (CMIP6) به کار گرفته شدند. بدین ترتیب، اطمینان حاصل شد که مؤلفه دما بدون تغییر در مقیاس یا ساختار ریاضی، برای هر دو مجموعه داده (تاریخی و پیش‌بینی آینده) به‌صورت کاملاً همگن محاسبه شده است. در گام دوم، به‌منظور بررسی و تأیید قطعی اهمیت آماری متغیرهای ورودی نهایی (شامل متغیرهای ترکیبی دما، رطوبت نسبی و تابش موج‌کوتاه فرودی، از الگوریتم انتخاب ویژگی Boruta استفاده شد. این الگوریتم که مستقیماً بر روی خروجی‌های مرحله پیش‌پردازش (PCA) اعمال گردید، یک روش پوششی مبتنی بر مدل جنگل تصادفی است که به‌طور مکرر اهمیت هر ویژگی را با اهمیت مجموعه‌ای از ویژگی‌های تصادفی (Shadow features) مقایسه کرده و متغیرهای معنادار را پیش از ورود نهایی به مدل‌های یادگیری ماشین به‌طور قطعی شناسایی و غربال می‌کند.

اگرچه بارش یکی از عوامل محدودکننده اصلی در اکوسیستم‌های خشک مانند استان هرمزگان (با میانگین بارش سالانه کمتر از ۲۰۰ میلی‌متر) محسوب می‌شود، اما در این پژوهش به‌عنوان متغیر مستقل نهایی وارد مدل‌های یادگیری ماشین نشد. این تصمیم بر سه پایه علمی استوار است: نخست، نتایج الگوریتم انتخاب ویژگی Boruta نشان داد که متغیرهای ترکیبی دما تابش و رطوبت نسبی دارای بیشترین قدرت پیش‌بینی‌کنندگی برای NDVI هستند و بارش را به‌عنوان یک ویژگی برتر انتخاب نکرد. دوم، در محیط‌های به‌شدت گرم و متأثر از اقلیم دریایی (مانند خلیج فارس)، رطوبت نسبی در کنار دما، نقش کلیدی در کنترل تقاضای تبخیری اتمسفر (VPD) و در نتیجه استرس رطوبتی گیاه ایفا می‌کند. سوم، پیش‌بینی‌های مدل‌های اقلیمی (CMIP6) برای متغیر بارش در مقیاس نقطه‌ای در مناطق بسیار خشک دارای عدم قطعیت بالایی است، درحالی‌که متغیرهای دما و تابش با قطعیت بسیار بالاتری شبیه‌سازی می‌شوند. با این وجود، به‌منظور در نظر گرفتن نقش بارش در پویایی‌های اکولوژیک، دو نقطه انتخاب شده در این پژوهش به‌گونه‌ای مکان‌یابی شدند که نماینده صدک‌های ۱۰ و ۹۰ توزیع بارش کلی استان باشند و از این طریق، گرادپان رطوبتی منطقه در طراحی تحقیق لحاظ گردید.

معیارهای ارزیابی عملکرد مدل (Model Performance Metrics)

برای ارزیابی و مقایسه کمی دقت پیش‌بینی مدل‌های توسعه‌یافته، از سه معیار آماری استاندارد که به طور گسترده در مسائل رگرسیون مورد استفاده قرار می‌گیرند، استفاده شد (Hastie et al., 2009; Moriasi et al., 2007). این ارزیابی بر روی مجموعه داده‌های آزمون انجام گرفت تا عملکرد تعمیم‌پذیری مدل‌ها بر روی داده‌های دیده‌نشده به صورت بی‌طرفانه سنجیده شود. این معیارها عبارت‌اند از:

ضریب تعیین (Coefficient of Determination, R^2)

این معیار نشان‌دهنده نسبتی از واریانس در مقادیر مشاهداتی NDVI است که توسط متغیرهای ورودی مدل قابل توضیح است. به عبارت دیگر، R^2 میزان تطابق مدل با داده‌های واقعی را می‌سنجد. مقادیر آن بین ۰ و ۱ متغیر است و مقادیر نزدیک به ۱ بیانگر عملکرد بهتر و تطابق بالاتر مدل است (Chicco et al., 2021). این معیار از رابطه (۳) محاسبه می‌شود:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

ریشه میانگین مربعات خطا (Root Mean Square Error, RMSE)

این معیار، انحراف استاندارد پسماندها (تفاوت بین مقادیر واقعی و پیش‌بینی شده) را اندازه‌گیری می‌کند. از آنجایی که خطاها قبل از میانگین‌گیری به توان دو می‌رسند، RMSE به خطاهای بزرگ وزن بیشتری می‌دهد و بنابراین به وجود مقادیر پرت در خطاها حساس است (Willmott and Matsuura, 2005). این معیار در واحد متغیر هدف (NDVI) بیان می‌شود و مقادیر کمتر آن نشان‌دهنده دقت بالاتر و خطای کمتر مدل است. رابطه (۴) نحوه محاسبه آن را نشان می‌دهد:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

میانگین قدرمطلق خطا (Mean Absolute Error, MAE)

این معیار، میانگین قدرمطلق تفاوت بین مقادیر پیش‌بینی‌شده و مقادیر واقعی را محاسبه می‌کند. برخلاف RMSE، این معیار به تمام خطاها وزن یکسانی می‌دهد و تفسیر ساده‌تری از میانگین بزرگی خطا ارائه می‌دهد (Willmott and Matsuura, 2005). MAE نیز هم‌واحد با متغیر هدف است و مقادیر کمتر آن بیانگر عملکرد بهتر مدل می‌باشد. این معیار از طریق رابطه (۵) به دست می‌آید:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

در روابط فوق، n تعداد کل مشاهدات در مجموعه داده آزمون، y_i مقدار مشاهداتی (واقعی) NDVI برای مشاهده i ام، \hat{y}_i مقدار پیش‌بینی‌شده توسط مدل برای همان مشاهده، و \bar{y} میانگین کل مقادیر مشاهداتی NDVI است. در نهایت، مدلی که به طور کلی بهترین عملکرد را بر اساس این سه معیار از خود نشان دهد، به عنوان مدل بهینه برای پیش‌بینی تغییرات آینده NDVI انتخاب خواهد شد.

شاخص کارایی کلینگ-گوپتا (Kling-Gupta Efficiency - KGE)

شاخص KGE یک معیار تشخیصی جامع است که عملکرد مدل را بر اساس سه مؤلفه اصلی به صورت هم‌زمان ارزیابی می‌کند: همبستگی خطی، بایاس (Bias) و نسبت تغییرپذیری بین مقادیر شبیه‌سازی‌شده و مشاهداتی (Kling et al., 2012). این تجزیه به درک بهتر نقاط قوت و ضعف مدل کمک می‌کند. مقدار بهینه KGE برابر با ۱ است. این شاخص از رابطه (۶) محاسبه می‌شود:

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (6)$$

که در آن، $\mathbf{\Gamma}$ ضریب همبستگی پیرسون، $\alpha = \frac{\sigma_s}{\sigma_o}$ نسبت انحراف معیار مقادیر شبیه‌سازی شده (σ_s) به مشاهداتی (σ_o)، و $\beta = \frac{\mu_s}{\mu_o}$ نسبت میانگین مقادیر شبیه‌سازی شده (μ_s) به مشاهداتی (μ_o) است.

نمودار تیلور (Taylor Diagram)

به منظور مقایسه جامع و هم‌زمان عملکرد مدل‌ها از نمودار تیلور استفاده شد. این نمودار به طور خلاصه سه معیار آماری کلیدی را در یک فضای دوبعدی نمایش می‌دهد: ضریب همبستگی پیرسون، انحراف معیار (SD)، و ریشه میانگین مربعات خطای مرکزی (Centered RMSE). در این نمودار، نقطه‌ای به عنوان مرجع برای داده‌های مشاهداتی در نظر گرفته می‌شود و عملکرد هر مدل با یک نقطه نمایش داده می‌شود. هرچه نقطه مربوط به یک مدل به نقطه مرجع نزدیک‌تر باشد، آن مدل عملکرد کلی بهتری دارد (Taylor, 2001).

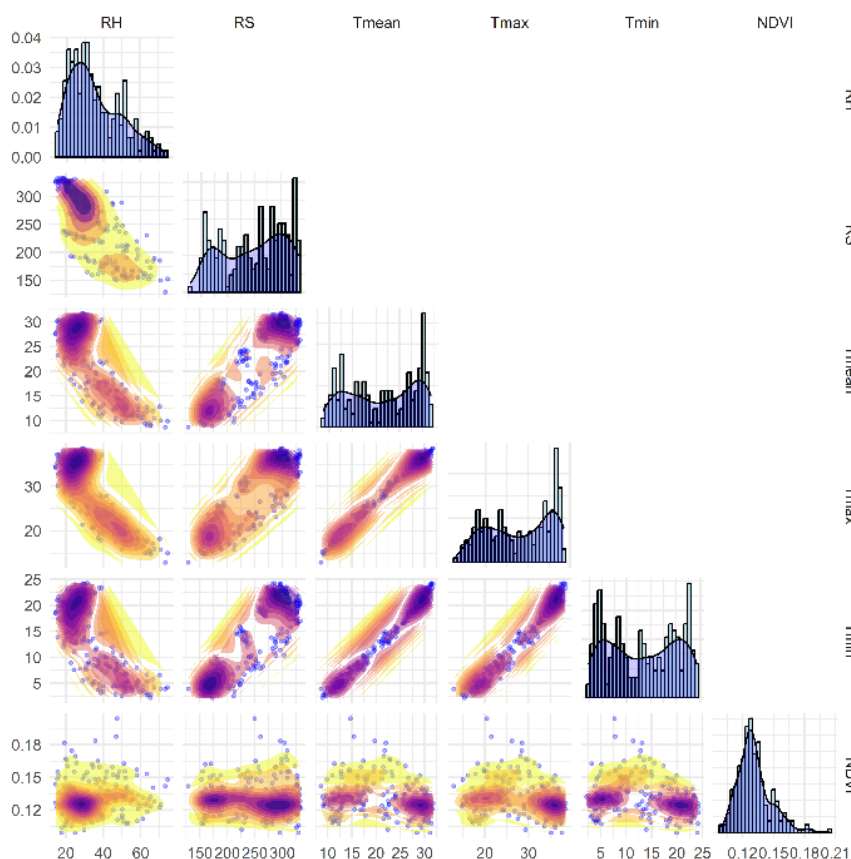
نتایج و بحث

تحلیل اکتشافی داده‌ها و روابط بین متغیرها

پیش از توسعه مدل‌های یادگیری ماشین، یک تحلیل اکتشافی برای درک توزیع داده‌ها و شناسایی روابط بین متغیرهای اقلیمی پیش‌بین و متغیر هدف (NDVI) انجام شد. شکل (۲) ماتریس پراکندگی و توزیع متغیرهای مورد استفاده را نشان می‌دهد. همانطور که در نمودارهای روی قطر اصلی مشخص است، متغیرهای دما توزیعی دو مُدی از خود نشان می‌دهند که منعکس‌کننده وجود دو فصل متمایز اقلیمی در منطقه مورد مطالعه است. در مقابل، همان‌طور که در هیستوگرام‌های توزیع فراوانی (قطر اصلی شکل ۲) قابل مشاهده است، توزیع داده‌های NDVI دارای چولگی به راست بوده و مقادیر آن عمدتاً در بازه پایین (کمتر از ۰.۱۵) متمرکز شده‌اند که این الگوی توزیع، با ماهیت پوشش گیاهی تنک و پراکنده در اکوسیستم‌های خشک و نیمه‌خشک کاملاً سازگار است.

مهم‌ترین یافته این تحلیل، شناسایی روابط پیچیده و غیرخطی بین متغیرهای دما و NDVI است. همان‌طور که در ردیف آخر شکل ۲ مشاهده می‌شود، رابطه NDVI با Tmean, Tmax و Tmin به شکل یک منحنی کمان-شکل است. این الگو نشان می‌دهد که NDVI در یک بازه دمایی بهینه به حداکثر مقدار خود می‌رسد و دماهای بسیار پایین یا بسیار بالا به عنوان عامل محدودکننده رشد عمل کرده و منجر به کاهش مقادیر NDVI می‌شوند. این پاسخ غیرخطی، که ریشه در فرآیندهای فیزیولوژیک گیاهی دارد، ضرورت استفاده از الگوریتم‌های یادگیری ماشین پیشرفته و غیرخطی مانند RF, GAM, GPR و XGBoost را برای شبیه‌سازی دقیق دینامیک پوشش گیاهی تأیید می‌کند. همچنین، همبستگی خطی بالایی بین متغیرهای مختلف دما مشاهده شد که نشان‌دهنده وجود پدیده هم‌خطی چندگانه است؛ پدیده‌ای که مدل‌های مبتنی بر درخت و هسته به کار رفته در این پژوهش، مقاومت خوبی در برابر آن دارند.





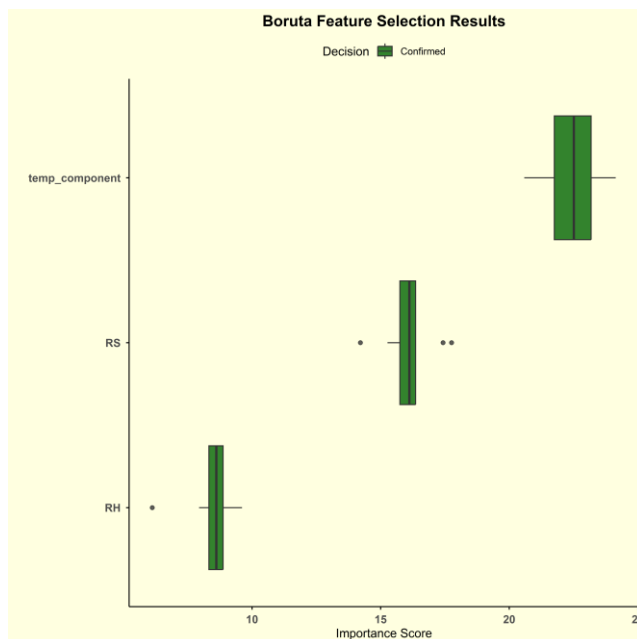
شکل ۲. ماتریس نمودار پراکندگی (Pairs Plot) برای متغیرهای اقلیمی و شاخص NDVI. نمودارهای روی قطر اصلی، هیستوگرام توزیع هر متغیر را نشان می‌دهند. نمودارهای زیر قطر اصلی، رابطه بین هر دو متغیر را به صورت نمودار پراکندگی همراه با کانترهای تخمین چگالی هسته دو بعدی نمایش می‌دهند.

Fig 2. Scatterplot matrix (pairs plot) for the climatic variables and the NDVI index. The diagonal panels show the distribution histogram for each variable, while the lower off-diagonal panels display the bivariate scatterplots overlaid with 2D kernel density estimation contours.

کاهش ابعاد و انتخاب متغیرهای کلیدی اقلیمی

پیش از اجرای مدل‌های یادگیری ماشین، یک تحلیل اکتشافی بر روی متغیرهای پیش‌بین اقلیمی انجام شد. بررسی ماتریس همبستگی نشان داد که متغیرهای دمای متوسط، کمینه و بیشینه دارای همبستگی خطی بسیار بالا و معناداری با یکدیگر هستند ($r > 0.95$) که این امر نشان‌دهنده وجود مشکل هم‌خطی چندگانه (Multicollinearity) در مجموعه داده‌ها است. به منظور رفع این مشکل و جلوگیری از ناپایداری در آموزش مدل‌های یادگیری ماشین، از تحلیل مؤلفه‌های اصلی (PCA) برای تقلیل ابعاد متغیرهای دمای استفاده گردید. نتایج این تحلیل نشان داد که مؤلفه اصلی اول ($PC1$) به تنهایی بیش از ۹۸٪ از واریانس کل سه متغیر دمای را تبیین می‌کند. بنابراین، این مؤلفه با حفظ حداکثری اطلاعات اولیه، به عنوان یک شاخص ترکیبی دما با نام متغیرهای ترکیبی دما انتخاب و در روند مدل‌سازی جایگزین سه متغیر دمای اولیه گردید. در گام بعدی، به منظور شناسایی و رتبه‌بندی اهمیت متغیرهای پیش‌بین نهایی (شامل مؤلفه ترکیبی دما، تابش موج کوتاه فرودی و رطوبت نسبی) در پیش‌بینی NDVI، از الگوریتم انتخاب متغیر بوراتا (Boruta) استفاده شد. این الگوریتم که مبتنی بر مدل جنگل تصادفی است، اهمیت هر متغیر را به صورت آماری ارزیابی می‌کند. نتایج تحلیل بوراتا (شکل ۳) نشان داد که هر سه متغیر ورودی به عنوان پیش‌بین‌های "تأیید شده" و معنادار برای شبیه‌سازی NDVI شناخته شدند. همان‌طور که در نمودار اهمیت متغیرها مشاهده می‌شود، مؤلفه ترکیبی دما (temp_component) با بالاترین امتیاز، به عنوان تأثیرگذارترین عامل اقلیمی بر پویایی NDVI در منطقه مورد مطالعه شناسایی شد. پس از آن، به ترتیب، تابش موج کوتاه فرودی و رطوبت نسبی در رتبه‌های

بعدی اهمیت قرار گرفتند. این یافته‌ها نشان می‌دهد که رژیم حرارتی، انرژی خورشیدی در دسترس و تنش رطوبتی، سه محور اصلی کنترل‌کننده تغییرات پوشش گیاهی در اکوسیستم‌های منطقه هستند.



شکل ۳. نتایج حاصل از الگوریتم انتخاب ویژگی Boruta. نمودار جعبه‌ای امتیاز اهمیت (Importance Score) را برای هر یک از متغیرهای پیش‌بین نشان می‌دهد. رنگ سبز به معنای تأیید شدن اهمیت آماری متغیر است.

Fig 3. Results of the Boruta feature selection algorithm. The boxplot shows the Importance Score for each predictor variable. The green color indicates that the variable's statistical importance has been confirmed.

ارزیابی عملکرد مدل‌ها در مرحله آموزش (نقطه ۱)

در این بخش، عملکرد چهار مدل یادگیری ماشین (GPR, GAM, RF, XGBoost) در شبیه‌سازی مقادیر NDVI بر روی داده‌های دوره آموزش برای نقطه شماره ۱ ارزیابی می‌شود. نتایج کمی این ارزیابی در جدول (۱) و تحلیل گرافیکی آن در نمودار تیلور (شکل [۴]) ارائه شده است.

جدول ۱. نتایج معیارهای ارزیابی عملکرد برای مدل‌های مختلف در مرحله آموزش (نقطه اول)

Table 1. Performance evaluation metrics for the different models during the training phase (Point 1)

Model	R2	RMSE	MAE	KGE
GPR	0.978	0.0001	0.0001	0.995
GAM	0.458	0.0112	0.0084	0.543
FR	0.908	0.0054	0.0041	0.761
XGB	0.907	0.0003	0.0002	0.995

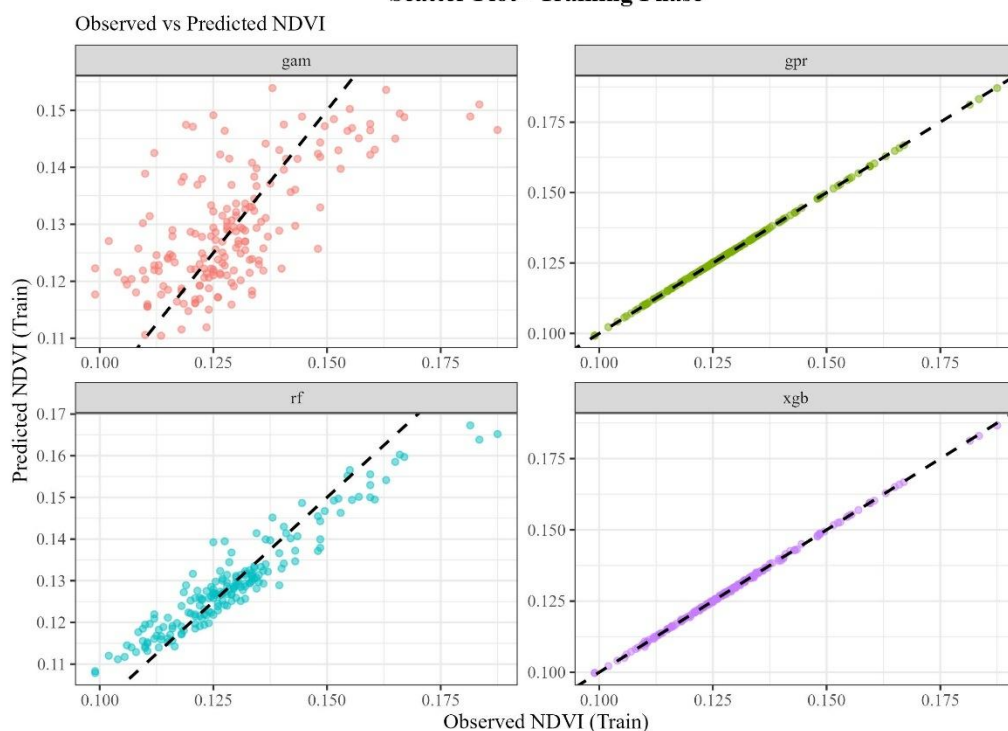
تحلیل کمی مبتنی بر معیارها:

بر اساس نتایج جدول (۱)، مدل‌های GPR و XGBoost عملکردی تقریباً بی‌نقص و بسیار مشابه یکدیگر در مرحله آموزش از خود نشان دادند. هر دو مدل به مقادیر ضریب کارایی کلینگ-گوپتا (KGE) برابر با ۰/۹۹۵ دست یافتند. همچنین مقادیر خطای آن‌ها بسیار ناچیز بود؛ به طوری که برای مدل GPR مقادیر RMSE و MAE هر دو برابر با ۰/۰۰۰۱ و برای مدل XGBoost مقادیر RMSE و MAE به ترتیب برابر با ۰/۰۰۰۳ و ۰/۰۰۰۲ به دست آمد. این نتایج نشان‌دهنده ظرفیت بسیار بالای این دو الگوریتم در یادگیری الگوهای پیچیده و غیرخطی حاکم بر داده‌های آموزشی است. مدل Random Forest (RF) نیز با R^2 برابر با ۰/۹۰۵ و KGE برابر با ۰/۷۶۱ خطای پایین عملکرد بسیار خوبی را به ثبت رساند، هرچند با اختلاف قابل توجهی نسبت به دو

مدل برتر قرار گرفت. در مقابل، مدل GAM با ثبت KGE برابر با 0.543 ، R^2 برابر با 0.458 و بیشترین میزان خطا و ضعیف‌ترین عملکرد را در بین مدل‌های ارزیابی شده داشت و نتوانست به خوبی دینامیک NDVI را در این مرحله شبیه‌سازی کند. عملکرد ضعیف‌تر مدل GAM نسبت به سایر مدل‌ها، ریشه در ساختار ریاضی این الگوریتم دارد. مدل GAM یک مدل جمع‌پذیر (Additive) است که اگرچه می‌تواند روابط غیرخطی را از طریق توابع هموارساز (Smoothing functions) مدل‌سازی کند، اما در ثبت تعاملات پیچیده و چندگانه (Interactions) بین متغیرهای مستقل محدودیت دارد. از آنجاکه پویایی شاخص NDVI تحت تأثیر تعاملات پیچیده، هم‌افزا و غیرخطی عوامل محیطی و اقلیمی است، ساختار جمع‌پذیر GAM توانایی کافی برای شبیه‌سازی این دینامیک‌های درهم‌تنیده را ندارد.

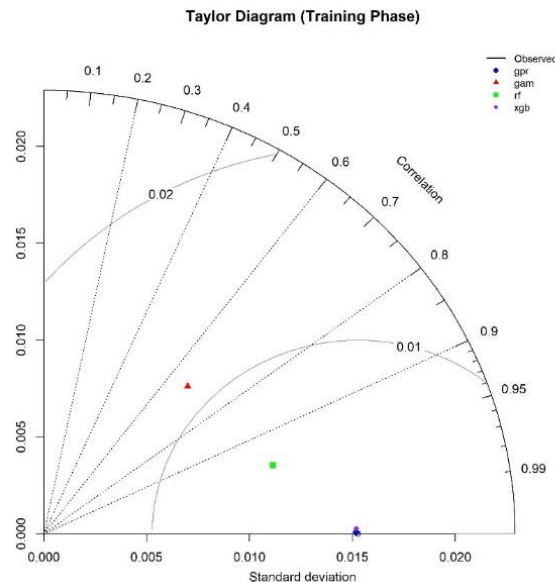
از سوی دیگر، اگرچه مدل Random Forest (RF) عملکرد بسیار خوبی ($KGE = 0.761$) نشان داد، اما با دو مدل برتر ($XGBoost$ و GPR) فاصله دارد. دلیل این امر به ماهیت رویکرد $Bagging$ در RF برمی‌گردد. مدل RF با میانگین‌گیری از درختان تصمیم مستقل، واریانس را کاهش می‌دهد، اما این میانگین‌گیری باعث می‌شود مدل در پیش‌بینی مقادیر فرین (نقاط حداقل و حداکثر ناگهانی NDVI) تمایل به هموارسازی (Smoothing) داشته باشد. در مقابل، مدل $XGBoost$ با استفاده از رویکرد Boosting، بهینه‌سازی متوالی انجام داده و به طور مستمر روی خطاهای پیش‌بینی مراحل قبل تمرکز می‌کند که این امر دقت آن را در ثبت نوسانات پیچیده افزایش می‌دهد. همچنین، مدل GPR به دلیل استفاده از توابع کرنل (Kernel functions) و ماهیت غیرپارامتریک خود، انعطاف‌پذیری بسیار بالایی در مدل‌سازی کوواریانس داده‌ها دارد و می‌تواند الگوهای محلی و تغییرات پیوسته فضایی-زمانی NDVI را با دقت بالاتری نسبت به ساختار پله‌ای درختان تصمیم در RF شبیه‌سازی کند. برای ارزیابی بصری و جامع‌تر عملکرد مدل‌ها، از نمودار تیلور استفاده شد (شکل ۵). این نمودار سه معیار کلیدی (همبستگی، انحراف معیار و خطای RMSE مرکزی) را به صورت همزمان نمایش می‌دهد. همانطور که در نمودار تیلور مشاهده می‌شود، نقاط مربوط به مدل‌های GPR و $XGBoost$ بسیار نزدیک به نقطه مشاهداتی قرار گرفته‌اند. این مجاورت قابل توجه نشان می‌دهد که این دو مدل نه تنها همبستگی بسیار بالایی (نزدیک به 0.9) با داده‌های واقعی دارند، بلکه قادر بوده‌اند دامنه نوسانات (انحراف معیار) آن‌ها را نیز با دقت مطلوبی شبیه‌سازی کنند. مدل RF همبستگی خوبی را نشان می‌دهد اما دامنه نوسانات NDVI را کمتر از واقعیت برآورد کرده است. مدل GAM نیز با فاصله زیاد از نقطه مشاهداتی، هم در بازتولید واریانس و هم در میزان همبستگی، ضعیف‌ترین عملکرد را در این نمودار به ثبت رسانده است.

Scatter Plot - Training Phase



شکل ۴. نمودارهای پراکندگی مقادیر NDVI مشاهداتی در مقابل مقادیر شبیه‌سازی شده توسط چهار مدل مختلف در مرحله آموزش برای نقطه اول.

Fig 4. Scatter plots of observed versus simulated NDVI values by the four different models during the training phase for point 1.



شکل ۵. نمودار تیلور برای مقایسه عملکرد مدل‌ها در مرحله آموزش (نقطه اول)

Fig 5. Taylor diagram comparing the performance of the models during the training phase (Point 1).

ارزیابی و انتخاب مدل نهایی در مرحله آزمون (نقطه ۱)

مرحله آزمون به منظور ارزیابی قابلیت تعمیم‌پذیری مدل‌ها بر روی داده‌های جدید و دیده‌نشده (۲۰۱۶-۲۰۱۸) انجام شد که مهم‌ترین گام برای انتخاب مدل بهینه محسوب می‌شود. نتایج کمی و کیفی این مرحله به ترتیب در جدول (۲) و شکل (۶) ارائه شده است.

تحلیل کمی و شناسایی بیش‌برازش: نتایج مرحله آزمون تفاوت چشمگیری در عملکرد مدل‌ها را آشکار ساخت. مدل GPR با حفظ عملکرد فوق‌العاده خود، به مقادیر KGE برابر با ۰/۹۹۳ و R^2 برابر با ۰/۹۹۵ دست یافت که نشان‌دهنده پایداری و قدرت بالای این مدل در پیش‌بینی شرایط جدید است. مدل XGBoost نیز با KGE برابر با ۰/۹۱۶ و R^2 برابر با ۰/۹۸۵، عملکرد بسیار قوی و قابل اعتمادی را به ثبت رساند.

در مقابل، عملکرد مدل‌های Random Forest (RF) و GAM به شدت افت کرد. به طور مشخص، ضریب تبیین مدل RF از ۰/۹۰۸ در مرحله آموزش به تنها ۰/۲۴ در مرحله آزمون سقوط کرد. این افت شدید، یک نشانه کلاسیک از پدیده بیش‌برازش است؛ به این معنی که مدل RF به جای یادگیری الگوهای کلی حاکم بر داده‌ها، نویز موجود در داده‌های آموزشی را حفظ کرده و در نتیجه، توانایی پیش‌بینی بر روی داده‌های جدید را از دست داده است. مدل GAM نیز با کسب KGE برابر با ۰/۲۵۷، عملکرد ضعیفی از خود نشان داد.

شکل (۶) این نتایج کمی را به صورت بصری تأیید می‌کند. در پنل‌های مربوط به مدل‌های GPR و XGBoost، نقاط به ترتیب با رنگ‌های سبز و بنفش، تراکم بسیار بالایی در اطراف خط انطباق کامل (۱:۱) دارند که نشان‌دهنده خطای بسیار پایین و تطابق عالی بین مقادیر پیش‌بینی شده و مشاهداتی است. در مقابل، پنل‌های مربوط به مدل‌های GAM و RF، ابر پراکنده‌ای از نقاط را بدون هیچ‌گونه روند مشخصی در اطراف خط ۱:۱ نشان می‌دهند. این پراکندگی بالا به وضوح نشان می‌دهد که پیش‌بینی‌های این دو مدل با مقادیر واقعی همبستگی بسیار ضعیفی دارند.

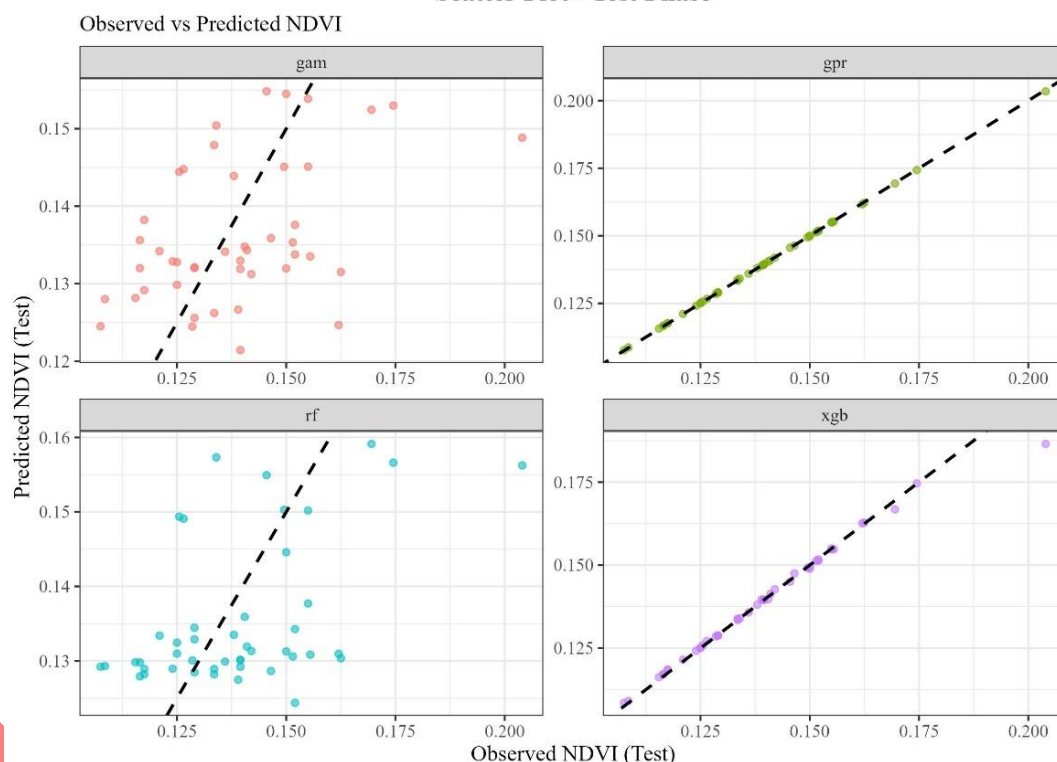
انتخاب مدل برتر برای نقطه ۱: با جمع‌بندی نتایج هر دو مرحله آموزش و آزمون، مدل رگرسیون فرایند گاوسی (GPR) به دلیل کسب بالاترین امتیاز در تمامی معیارهای ارزیابی (به‌ویژه KGE)، پایداری عملکرد در هر دو فاز و عدم بروز پدیده بیش‌برازش، به‌عنوان مدل برتر و بهینه برای شبیه‌سازی و پیش‌بینی NDVI در نقطه شماره ۱ انتخاب گردید.

جدول ۲. معیارهای ارزیابی عملکرد چهار مدل یادگیری ماشین برای نقطه ۱ در مرحله آزمون

Table 2. Performance evaluation metrics of the four machine learning models for Point 1 during the test phase.

Model	R2	RMSE	MAE	KGE
GPR	0.995	0.0002	0.0001	0.993
GAM	0.21	0.0167	0.0135	0.257
RF	0.24	0.0165	0.0135	0.303
XGB	0.985	0.0027	0.009	0.916

Scatter Plot - Test Phase



شکل ۶. نمودارهای پراکنش مقادیر NDVI مشاهداتی در مقابل پیش‌بینی شده توسط چهار مدل برای نقطه ۱ در مرحله آزمون

Fig 6. Scatter plots of observed versus predicted NDVI values by the four models for Point 1 during the test phase.

ارزیابی عملکرد مدل‌ها در مرحله آموزش (نقطه دوم)

در نقطه دوم، نتایج مرحله آموزش (جدول ۳ و شکل‌های ۷ و ۸) الگوی متفاوتی از عملکرد مدل‌ها را در مقایسه با نقطه اول نشان داد. مدل XGBoost مجدداً با کسب KGE برابر با ۰.۹۹۹ و R^2 برابر با ۰.۹۸، عملکردی تقریباً بی‌نقص از خود به نمایش گذاشت و توانایی بالای خود در یادگیری روابط پیچیده را تأیید کرد. برخلاف نقطه اول، در این ایستگاه مدل GAM با R^2 برابر با ۰.۷۵۳ و KGE برابر با ۰.۷۰۳، عملکردی قوی و قابل قبول ارائه داد و پس از XGBoost در جایگاه دوم قرار گرفت. مدل GPR با KGE برابر با ۰.۶۷۹ عملکردی متوسط داشت. نکته قابل توجه در نتایج این نقطه، عملکرد مدل Random Forest (RF) بود. با وجود اینکه این مدل ضریب تبیین مناسبی ($R^2=0.752$) کسب کرد، مقدار KGE آن (۰.۴۱۶) به طور نامتناسبی پایین بود.

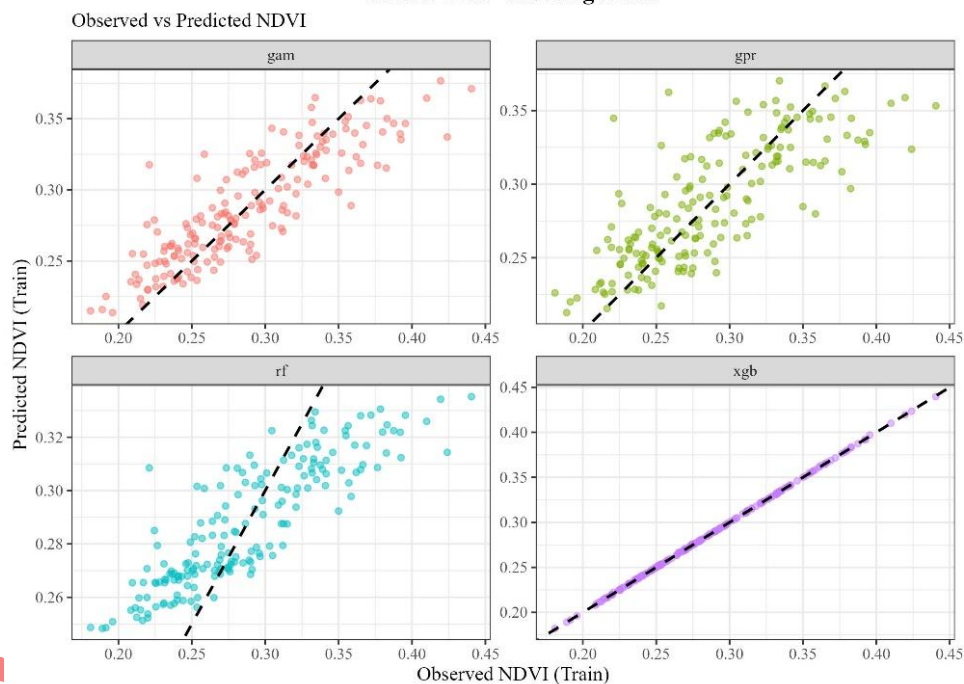
نمودار تیلور (شکل ۸) دلیل این اختلاف را به وضوح نشان می‌دهد. در حالی که نقطه مربوط به مدل XGBoost تقریباً بر نقطه مشاهداتی منطبق است، نقطه مدل RF با اینکه همبستگی خوبی را نشان می‌دهد (موقعیت زاویه‌ای مناسب)، اما انحراف معیار آن (فاصله از مبدأ) به شدت کمتر از انحراف معیار داده‌های مشاهداتی است. این بدان معناست که مدل RF در شبیه‌سازی دامنه نوسانات واقعی NDVI ناموفق بوده و این ضعف توسط معیار جامع KGE به درستی شناسایی شده است.

جدول ۳. نتایج معیارهای ارزیابی عملکرد برای مدل‌ها در نقطه دوم طی مرحله آموزش.

Table 3. Performance evaluation metrics for the models at Point 2 during the training phase

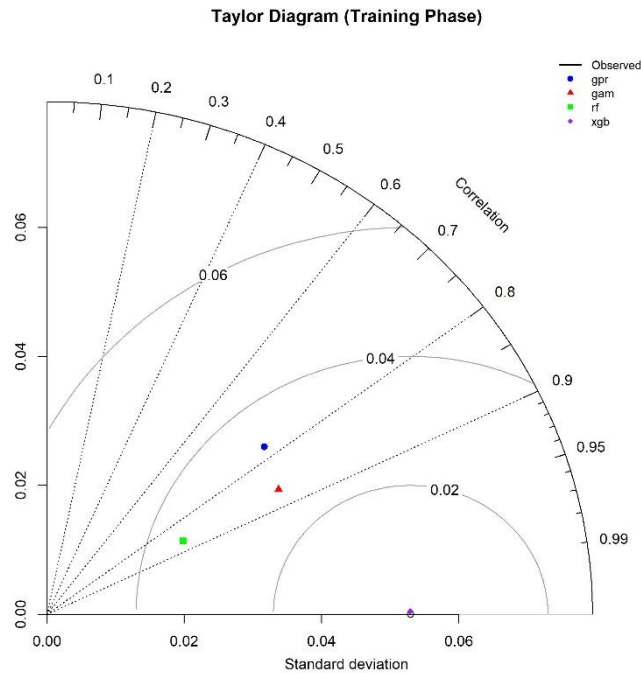
Model	R2	RMSE	MAE	KGE
GPR	0.598	0.0336	0.0257	0.679
GAM	0.753	0.0273	0.0211	0.703
RF	0.752	0.0351	0.0281	0.416
XGB	0.98	0.0005	0.0004	0.999

Scatter Plot - Training Phase



شکل ۷. نمودارهای پراکنش مقادیر مشاهداتی در مقابل شبیه‌سازی شده در نقطه دوم طی مرحله آموزش.

Fig 7. Scatter plots of observed versus simulated values for Point 2 during the training phase.



شکل ۸. نمودار تیلور برای مقایسه عملکرد مدل‌ها در نقطه دوم طی مرحله آموزش.

Fig 8. Taylor diagram comparing the performance of the models at Point 2 during the training phase

ارزیابی عملکرد در مرحله آزمون و انتخاب مدل بهینه (نقطه دوم)

ارزیابی نهایی مدل‌ها در مرحله آزمون برای نقطه دوم، تفاوت‌های چشمگیری را در قابلیت تعمیم‌پذیری و استحکام الگوریتم‌ها آشکار ساخت. نتایج کمی در جدول (۴) و تحلیل بصری در شکل‌های [۹ و ۱۰] ارائه شده است. تحلیل کمی و عملکرد متضاد مدل‌ها: نتایج مرحله آزمون به‌وضوح برتری مطلق مدل XGBoost را در این نقطه نشان می‌دهد. این مدل با حفظ عملکرد فوق‌العاده خود، به KGE برابر با ۰/۸۸۶ و R^2 برابر با ۰/۹۸۸ دست یافت. پایداری عملکرد XGBoost بین دو مرحله آموزش و آزمون، نشان‌دهنده قابلیت تعمیم‌پذیری بالای آن و عدم وقوع بیش‌برازش است.

جدول ۴. نتایج معیارهای ارزیابی عملکرد برای مدل‌ها در نقطه دوم طی مرحله آزمون

Table 4. Performance evaluation metrics for the models at Point 2 during the test phase.

Model	R2	RMSE	MAE	KGE
GPR	0.172	0.0785	0.0605	-0.091
GAM	0.162	0.0669	0.0536	0.248
RF	0.139	0.0615	0.0501	0.045
XGB	0.988	0.0101	0.0072	0.886

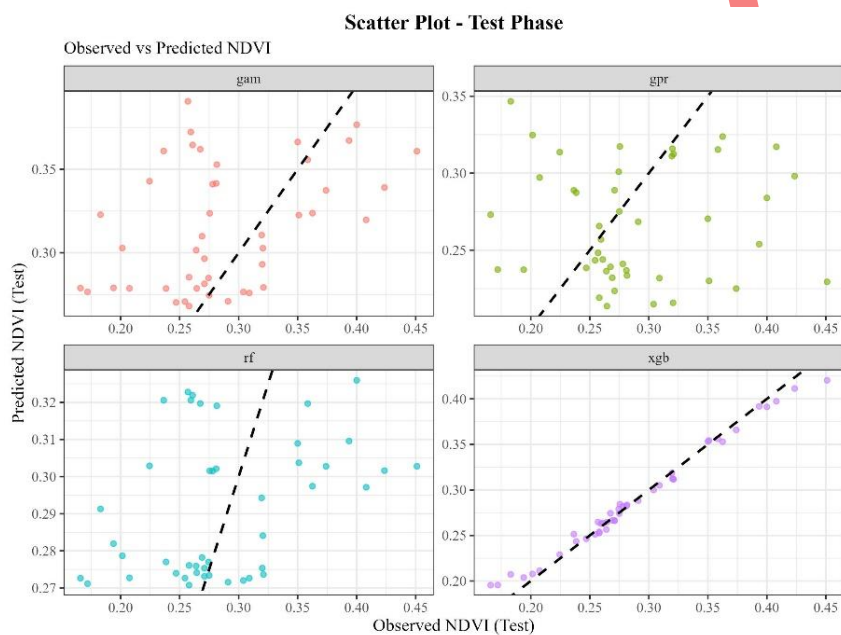
در مقابل، سه مدل دیگر (GPR, GAM, RF) با افت عملکرد شدیدی مواجه شدند. ضریب تبیین (R^2) برای هر سه مدل به کمتر از ۰/۲ کاهش یافت که نشان‌دهنده عدم توانایی آن‌ها در پیش‌بینی داده‌های جدید است. به طور خاص، مدل GPR که در نقطه اول بهترین عملکرد را داشت، در این نقطه با ثبت KGE منفی (۰/۰۹۱-)، ضعیف‌ترین نتیجه را کسب کرد. مقدار منفی KGE نشان می‌دهد که پیش‌بینی این مدل حتی از میانگین داده‌های مشاهداتی نیز عملکرد ضعیف‌تری دارد. این نتایج نشان‌دهنده وقوع پدیده بیش‌برازش شدید برای مدل‌های GPR, GAM و RF در این نقطه است.

نمودار تیلور (شکل ۱۰) دلیل این شکست را به زیبایی به تصویر می‌کشد. نقطه مربوط به مدل XGBoost با همبستگی بسیار بالا (نزدیک به ۰/۹۹) و انحراف معیار نزدیک به داده‌های مشاهداتی، در موقعیت بسیار خوبی قرار دارد.

در مقابل، نقاط مربوط به مدل‌های GPR, GAM و RF همگی در گوشه پایین سمت چپ نمودار و بسیار نزدیک به مبدأ تجمع کرده‌اند. این موقعیت نشان‌دهنده دو ضعف عمده است: ۱) همبستگی بسیار پایین با داده‌های مشاهداتی (کمتر از ۰/۴) و

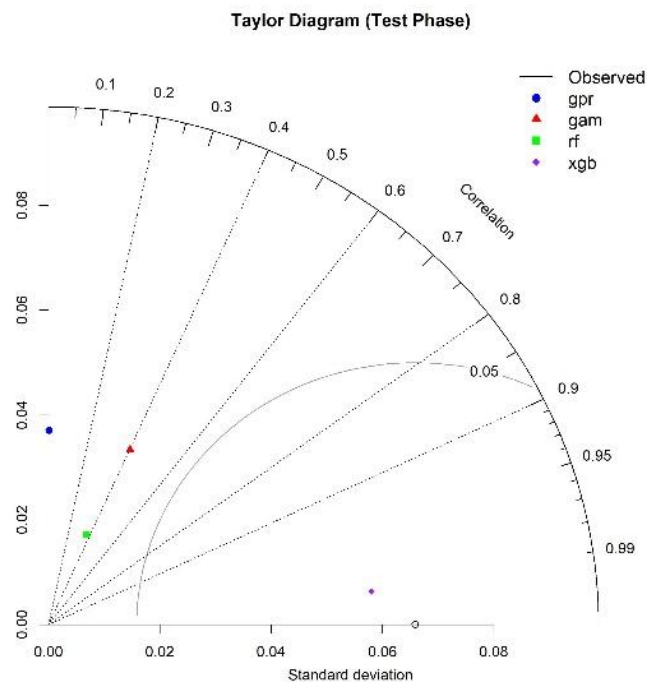
۲) ناتوانی شدید در بازتولید دامنه نوسانات واقعی NDVI. همان‌طور که از محور انحراف معیار مشخص است، این سه مدل پراکندگی (واریانس) داده‌ها را به شدت کمتر از حد واقعی برآورد کرده‌اند که نشان‌دهنده یک ضعف ساختاری در مواجهه با دینامیک داده‌های این نقطه است. نمودارهای پراکنش (شکل ۹) نیز این یافته را با نمایش ابری از نقاط بی‌شکل برای این سه مدل تأیید می‌کند.

انتخاب مدل بهینه برای نقطه دوم: با توجه به برتری قاطع در تمامی معیارهای کمی و کیفی و همچنین پایداری عملکرد در هر دو فاز آموزش و آزمون، مدل تقویت‌گرایان شدید (XGBoost) به‌عنوان تنها مدل قابل اتکا و مدل بهینه برای شبیه‌سازی و پیش‌بینی NDVI در نقطه شماره دو انتخاب گردید.



شکل ۹. نمودار پراکنش مقادیر NDVI مشاهداتی در مقابل پیش‌بینی‌شده توسط مدل‌ها در مرحله آزمون برای نقطه دوم.

Fig 9. Scatter plots observed versus predicted NDVI values by the models during the test phase for Point 2.



شکل ۱۰. نمودار تیلور برای مقایسه عملکرد مدل‌ها در مرحله آزمون برای نقطه دوم.

Fig 10. Taylor diagram comparing the performance of the models at Point 2 during the test phase.

پیش‌بینی آینده NDVI برای نقطه اول تحت سناریوی SSP3-7.0

پس از انتخاب مدل GPR به‌عنوان مدل بهینه برای نقطه اول، از این مدل برای پیش‌بینی سری زمانی شاخص NDVI از سال ۲۰۱۹ تا ۲۱۰۰ تحت سناریوی بدبینانه تغییر اقلیم (SSP3-7.0) استفاده شد. نتایج این پیش‌بینی به‌صورت سری زمانی در شکل (۱۱) و مقادیر خلاصه آماری آن در جدول (۵) ارائه شده است.

جدول ۵. مقایسه میانگین NDVI در دوره‌های زمانی آینده با دوره مبنای تاریخی برای نقطه اول

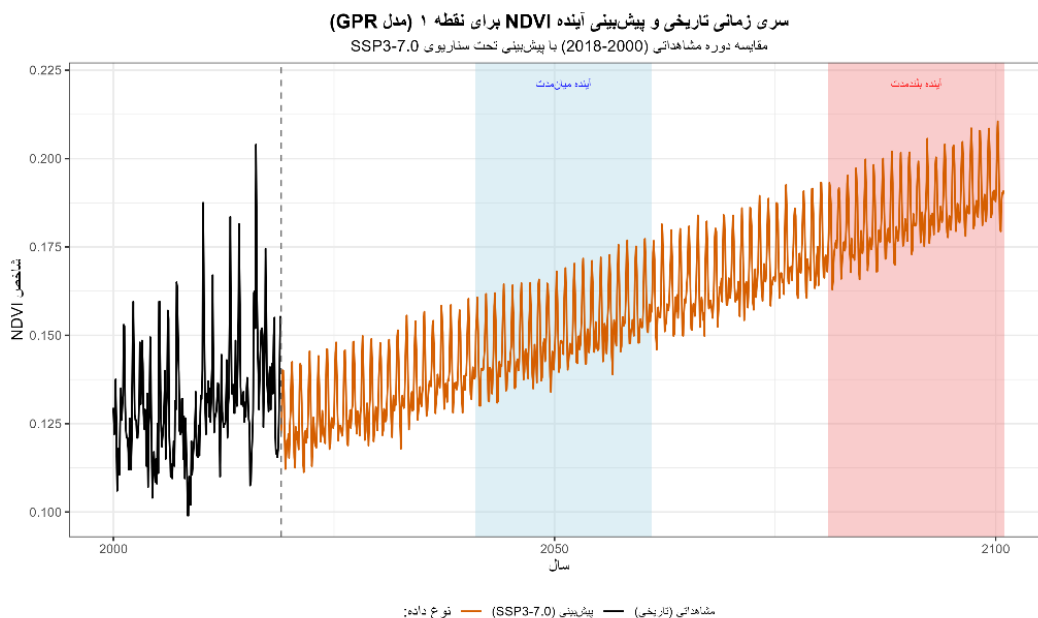
Table 5. Comparison of mean NDVI in future time periods with the historical baseline period for Point 1

درصد تغییر نسبت به دوره مبنای Change vs. Baseline (%)	میانگین سالانه NDVI Annual Mean NDVI	دوره زمانی Time Period
	0.131	مبنای (۲۰۱۸-۲۰۰۰) Baseline (2000-2018)
+13.0%	0.148	آینده میان‌مدت (۲۰۶۰-۲۰۴۱) Mid-term Future (2041-2060)
+42.0%	0.186	آینده بلندمدت (۲۱۰۰-۲۰۸۱) Long-term Future (2081-2100)

نتایج پیش‌بینی برای نقطه اول، یک روند افزایشی واضح و قابل توجه در مقادیر NDVI تا پایان قرن را آشکار می‌سازد. همان‌طور که در شکل (۱۱) مشاهده می‌شود، پس از یک دوره نوسانات نسبتاً پایدار تاریخی، مدل پیش‌بینی می‌کند که پوشش گیاهی از حدود سال ۲۰۴۰ به بعد وارد یک فاز رشد پایدار شود.

این روند افزایشی در نتایج کمی جدول (۵) نیز تأیید می‌شود. میانگین سالانه NDVI از مقدار ۰/۱۳۱ در دوره مبنای، به ۰/۱۴۸ در دوره میان‌مدت (۲۰۶۰-۲۰۴۱) افزایش می‌یابد که نشان‌دهنده رشدی معادل ۱۳ درصد است. با توجه به حساسیت بالای اکوسیستم‌های خشک به نوسانات خرد، بررسی‌های آماری آزمون t-test مقایسه میانگین‌ها نشان داد که این میزان افزایش از نظر آماری معنی‌دار است ($p < 0.05$). این روند رشد در دهه‌های پایانی قرن شدت گرفته و میانگین NDVI در دوره بلندمدت (۲۱۰۰-۲۰۸۱) به ۰/۱۸۶ می‌رسد که بیانگر یک افزایش چشمگیر و معنی‌دار ۴۲ درصدی نسبت به دوره تاریخی است. این

یافته که تحت یک سناریوی گرمایش شدید، پوشش گیاهی روندی صعودی از خود نشان می‌دهد، بسیار حائز اهمیت است و نشان می‌دهد که ممکن است عوامل دیگری فراتر از دما، مانند اثر لقاح دی‌اکسید کربن (CO2 Fertilization Effect) یا تغییر در الگوهای بارش فصلی پیش‌بینی‌شده توسط مدل GFDL-ESM4، نقش محرک اصلی را در پویایی آینده پوشش گیاهی این منطقه ایفا کنند.



شکل ۱۱. سری زمانی NDVI مشاهداتی (۲۰۱۸-۲۰۰۰) و پیش‌بینی‌شده (۲۰۱۹-۲۱۰۰) برای نقطه اول با استفاده از مدل GPR تحت سناریوی SSP3-7.0.

Fig 11. Time series of observed (2000-2018) and predicted (2019-2100) NDVI for Point 1 using the GPR model under the SSP3-7.0 scenario

پیش‌بینی آینده NDVI برای نقطه دوم تحت سناریوی SSP3-7.0

برای نقطه دوم، مدل XGBoost که در مرحله آموزش و اعتبارسنجی بهترین عملکرد را نشان داده بود، جهت پیش‌بینی سری زمانی NDVI تا پایان قرن ۲۱ تحت سناریوی SSP3-7.0 به کار گرفته شد. روند تغییرات زمانی در شکل (۱۲) ترسیم شده و خلاصه آماری مقایسه دوره‌ها در جدول (۶) ارائه گردیده است.

جدول ۶. مقایسه میانگین NDVI در دوره‌های زمانی آینده با دوره مبنای تاریخی برای نقطه دوم.

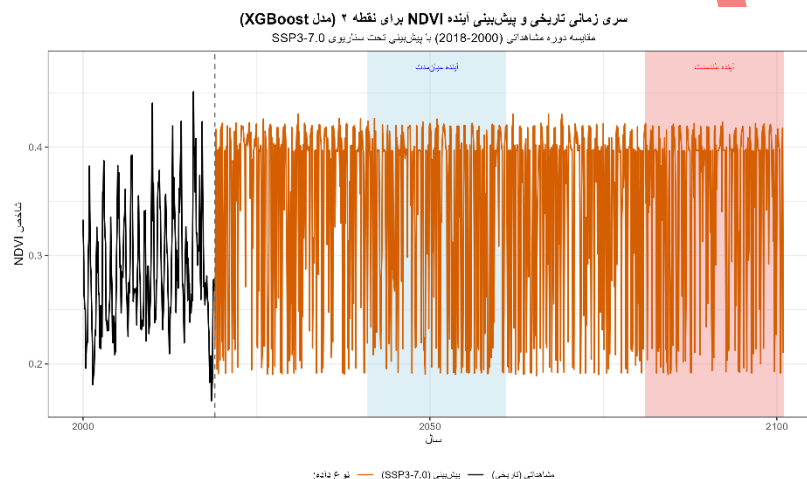
Table 6. Comparison of mean NDVI in future time periods with the historical baseline period for Point 2.

درصد تغییر نسبت به دوره مبنا Change vs. Baseline (%)	میانگین سالانه NDVI Annual Mean NDVI	دوره زمانی Time Period
-	0.292	مبنا (۲۰۱۸-۲۰۰۰) Baseline (2000-2018)
+10.9%	0.324	آینده میان‌مدت (۲۰۶۰-۲۰۴۱) Mid-term Future (2041-2060)
+10.9%	0.324	آینده بلندمدت (۲۱۰۰-۲۰۸۱) Long-term Future (2081-2100)

تحلیل بصری شکل (۱۲) نشان می‌دهد که مدل XGBoost توانسته است نوسانات فصلی حاکم بر منطقه را به خوبی شناسایی و برای آینده شبیه‌سازی کند. برخلاف نقطه اول که یک روند صعودی پرشتاب را تجربه کرد، نقطه دوم رفتاری مبتنی بر پایداری و تاب‌آوری از خود نشان می‌دهد.

همان‌طور که در جدول (۶) مشاهده می‌شود، میانگین NDVI از مقدار ۰/۲۹۲ در دوره تاریخی، با افزایشی ملایم (حدود ۱۰/۹ درصد) به ۰/۳۲۴ در دوره میان‌مدت می‌رسد. نکته کلیدی اینجاست که این شاخص در دوره بلندمدت (۲۰۸۱-۲۱۰۰) ثابت باقی می‌ماند و رشد بیشتری نمی‌کند.

این یافته‌ها بیانگر آن است که اکوسیستم در نقطه دوم، توانایی سازگاری با شرایط اقلیمی سناریوی SSP3-7.0 را دارد و دچار تخریب نمی‌شود، اما به دلیل محدودیت‌های اکولوژیکی یا محیطی، به یک تعادل جدید رسیده و ظرفیت افزایش تراکم پوشش گیاهی فراتر از این حد را ندارد. نوسانات منظم و تکرارشونده در بخش پیش‌بینی نشان می‌دهد که چرخه‌های فنولوژیک گیاهان (فصل رشد و فصل خواب) در آینده نیز با قدرت ادامه خواهند یافت.



شکل ۱۲. سری زمانی NDVI مشاهداتی (۲۰۰۰-۲۰۱۸) و پیش‌بینی شده (۲۰۱۹-۲۱۰۰) برای نقطه دوم با استفاده از مدل XGBoost تحت سناریوی SSP3-7.0.

Fig 11. Time series of observed (2000-2018) and predicted (2019-2100) NDVI for Point 2 using the model under the SSP3-7.0 scenario XGBoost

این پژوهش با هدف ارزیابی قابلیت مدل‌های یادگیری ماشین در پیش‌بینی آینده پوشش گیاهی استان هرمزگان تحت شدیدترین سناریوی تغییر اقلیم (SSP3-7.0) انجام شد. نتایج حاصله حاوی نکات فنی و اکولوژیکی قابل توجهی است که در سه محور اصلی قابل بحث هستند: عملکرد الگوریتم‌ها، نقش متغیرهای اقلیمی، و ناهمگونی در پاسخ‌های آینده اکوسیستم.

۱- ارزیابی عملکرد و برتری مدل‌های غیرخطی یافته‌های این تحقیق نشان داد که مدل‌های رگرسیون فرآیند گاوسی (GPR) و تقویت‌گرادیان شدید (XGBoost) عملکردی به مراتب برتر نسبت به مدل‌های افزودنی تعمیم‌یافته (GAM) و جنگل تصادفی (RF) دارند. برتری GPR در نقطه اول را می‌توان به ماهیت بیزی و قابلیت هسته‌های آن در مدل‌سازی روابط هموار و پیوسته نسبت داد که برای داده‌های با نوسانات کمتر، بسیار کارآمد است (Williams, 2006 & Rasmussen). از سوی دیگر، عملکرد خیره‌کننده XGBoost در نقطه دوم و پایداری آن در هر دو مرحله آموزش و آزمون، ناشی از مکانیزم "تقویت" (Boosting) است که به مدل اجازه می‌دهد تا خطاهای سیستماتیک را مرحله به مرحله اصلاح کرده و الگوهای پیچیده فصلی را بهتر شناسایی کند (Guertin, 2016 & Chen). شکست مدل RF در مرحله آزمون (بیش‌برازش شدید)، به ویژه در نقطه اول، تأییدی بر این نکته است که اگرچه جنگل تصادفی مدلی قدرتمند است، اما در مواجهه با داده‌های سری زمانی که دارای روندها یا الگوهای خاص خارج از دامنه آموزش هستند، ممکن است دچار خطا شود. این در حالی است که XGBoost با استفاده از تکنیک‌های منظم‌سازی تعبیه شده در ساختار خود، توانسته است از بیش‌برازش جلوگیری کرده و تعمیم‌پذیری بالایی ارائه دهد.

دلیل عملکرد ضعیف‌تر مدل‌های رندوم فارست (RF) و GAM در مقایسه با XGBoost را می‌توان در ساختار الگوریتمی آن‌ها و ماهیت نوسانی داده‌های NDVI جستجو کرد. در مدل RF، با وجود کسب ضریب همبستگی و R^2 بالا در مرحله آموزش، شاخص ترکیبی KGE به دلیل کم‌برآورد کردن شدید انحراف معیار داده‌ها افت قابل توجهی داشت (همان‌طور که در نمودارهای تیلور مشاهده شد). از آنجایی که الگوریتم RF مبتنی بر روش تجمیع (Bagging) و میانگین‌گیری از پیش‌بینی‌های درختان

متعدد است، این فرآیند ذاتاً منجر به هموارسازی (Smoothing) مقادیر فرین (بیکهای بالا و پایین NDVI) می‌شود. در نتیجه، این مدل توانایی بازتولید دامنه کامل نوسانات اکولوژیکی را ندارد. از سوی دیگر، مدل GAM با وجود قابلیت تفسیرپذیری بالا به دلیل ساختار نیمه پارامتریک و توابع هموارساز (Smoothing splines)، در مواجهه با تعاملات پیچیده و غیرخطی اقلیم-پوشش گیاهی در نقطه دوم، دچار پدیده بیش‌برازش (Overfitting) شدید گردید و نتوانست یادگیری خود را به داده‌های آزمون تعمیم دهد. این نتایج نشان می‌دهد که برای شبیه‌سازی دقیق دینامیک‌های پیچیده NDVI، الگوریتم‌های مبتنی بر تقویت گرادیان (مانند XGBoost) که به صورت متوالی خطاهای درختان قبلی را اصلاح می‌کنند و قابلیت کنترل پیچیدگی (Regularization) بهتری دارند، نسبت به روش‌های مبتنی بر Bagging (مثل RF) یا توابع هموارساز (GAM) ارجحیت دارند.

۲- مکانیزم‌های کنترل‌کننده اقلیمی تحلیل اهمیت متغیرها (شکل ۳) و نمودارهای همبستگی (شکل ۲) نشان داد که "دما" مهم‌ترین عامل محدودکننده و کنترل‌کننده پوشش گیاهی در منطقه است. رابطه منحنی‌شکل مشاهده شده بین دما و NDVI بیانگر وجود یک آستانه حرارتی بهینه برای فتوسنتز است. در اکوسیستم‌های گرمسیری و نیمه‌گرمسیری مانند هرمرگان، افزایش دما تا یک حد مشخص می‌تواند باعث تحریک رشد شود، اما فراتر از آن منجر به بسته شدن روزنه‌ها برای جلوگیری از اتلاف آب و توقف فتوسنتز می‌گردد (Sun et al., 2023). شناسایی این رابطه غیرخطی توضیح می‌دهد که چرا مدل‌های خطی یا نیمه‌خطی ساده (مانند GAM در برخی موارد) نمی‌توانند با دقت بالا رفتار اکوسیستم را شبیه‌سازی کنند.

۳- واگرایی در آینده پوشش گیاهی: تاب‌آوری در برابر انبساط یکی از مهم‌ترین یافته‌های این پژوهش، تفاوت آشکار در سرنوشت آینده پوشش گیاهی بین دو نقطه مورد مطالعه است. در نقطه اول (داخلی/کوهستانی)، پیش‌بینی‌ها نشان‌دهنده افزایش چشمگیر ۴۲ درصدی NDVI تا پایان قرن است. این پدیده را می‌توان با فرضیه "اثر لقاح دی‌اکسید کربن" (CO₂ Fertilization Effect) توضیح داد. تحت سناریوی SSP3-7.0، غلظت CO₂ جو به شدت افزایش می‌یابد که می‌تواند کارایی مصرف آب در گیاهان را بهبود بخشیده و نرخ فتوسنتز را افزایش دهد، به ویژه در مناطقی که محدودیت آب عامل اصلی است (Piao et al., 2020; Zhu et al., 2016). همچنین، گرمایش جهانی ممکن است فصل رشد را در مناطق مرتفع‌تر یا سردتر استان طولانی‌تر کرده و فرصت بیشتری برای زیست‌توده فراهم کند. با این وجود، باید تأکید کرد که پیش‌بینی افزایش مستمر NDVI بر پایه "اثر لقاح دی‌اکسید کربن" دارای عدم قطعیت‌های قابل توجهی است. اگرچه غلظت بالای CO₂ می‌تواند از طریق افزایش راندمان مصرف آب (WUE) و تحریک فتوسنتز به سبز شدن کمک کند، اما این روند افزایشی نامحدود نخواهد بود. مطالعات اخیر نشان می‌دهند که اثر مثبت لقاح CO₂ به شدت توسط محدودیت عناصر غذایی خاک، به ویژه نیتروژن و فسفر، کنترل می‌شود (Peñuelas et al., 2013). علاوه بر این، همزمان با افزایش دما، کمبود فشار بخار اتمسفر (VPD) نیز افزایش می‌یابد که می‌تواند منجر به بسته شدن روزنه‌ها، کاهش فتوسنتز و بروز تنش خشکی در گیاهان شود (Yuan et al., 2019). بنابراین، در سناریوهای بدبینانه مانند SSP3-7.0، احتمال می‌رود که اثرات منفی ناشی از تنش‌های حرارتی مکرر و افزایش تبخیر و تعرق، اثرات مثبت لقاح CO₂ را در دهه‌های آینده خنثی کند؛ موضوعی که در تثبیت یا حتی کاهش روند رشد در برخی نقاط مورد مطالعه (مانند نقطه دوم) قابل مشاهده است.

در مقابل، نقطه دوم (ساحلی/جنوبی) رفتاری مبنی بر پایداری و ثبات (+۱۰.۹٪ و سپس توقف رشد) نشان داد. این منطقه احتمالاً به "ظرفیت برد اکولوژیکی (Ecological Carrying Capacity)" (خود نزدیک شده است) به عنوان مثال -Del Monte (2014); Luna et al., 2004; Xia et al., 2014) مفهوم ظرفیت برد در اکولوژی گیاهی نشان‌دهنده حداکثر زیست‌توده‌ای است که یک محیط می‌تواند با توجه به محدودیت‌های منابع (مانند آب و مواد مغذی) پشتیبانی کند. در این مناطق که دما و رطوبت هم‌اکنون نیز بالاست، اثرات مثبت افزایش CO₂ احتمالاً توسط اثرات منفی تنش گرمایی شدید خنثی می‌شود. ثبات مشاهده شده در نیمه دوم قرن ۲۱ نشان‌دهنده تاب‌آوری اکوسیستم است؛ به این معنا که گونه‌های گیاهی منطقه (احتمالاً گونه‌های سازگار با شوری و گرما مانند کهور یا حرا) توانسته‌اند خود را با شرایط جدید وفق دهند، اما محدودیت‌های فیزیولوژیک اجازه افزایش تراکم بیشتر را نمی‌دهد. پیش‌بینی واگرایی در پاسخ اکولوژیکی دو نقطه مورد مطالعه (رشد پیوسته و شدید در نقطه اول در مقابل رشد ملایم و سپس رسیدن به پایداری در نقطه دوم) ضرورت توجه به مکانیزم‌های محلی خاک و خرد-اقلیم را برجسته می‌سازد. دلیل این تفاوت را می‌توان در ویژگی‌های ذاتی هر رویشگاه جستجو کرد. در نقطه اول، شرایط مساعدتر خاک [مثلاً: عمق بیشتر خاک، بافت لومی تر یا ظرفیت نگهداری آب بالاتر] و قرارگیری در خرد-اقلیمی با تنش‌های تبخیری کمتر، به پوشش

گیاهی اجازه می‌دهد تا از اثر لقای CO_2 در آینده حداکثر بهره را ببرد و روند سبزی‌نگی را تداوم بخشد. در مقابل، رفتار مجانبی و رسیدن به آستانه پایداری در نقطه دوم، می‌تواند ناشی از محدودیت‌های بستر خاک [مثلاً: خاک‌های کم‌عمق‌تر، فرسایش یافته یا با درصد ماسه بالاتر] و نوع رویش گیاهی آن باشد. در چنین شرایطی، سیستم اکولوژیک سریع‌تر به ظرفیت برد (Carrying Capacity) خود می‌رسد و افزایش تبخیر و تعرق پتانسیل ناشی از گرمایش جهانی تحت سناریوی SSP3-7.0، اثرات مثبت افزایش کربن را خنثی کرده و مانع از رشد بیشتر گیاه می‌گردد.

یکی از یافته‌های تامل‌برانگیز این پژوهش، پیش‌بینی رشد ۴۲ درصدی NDVI برای نقطه اول تحت سناریوی بدبینانه SSP3-7.0 است. برای درک صحیح این رقم، توجه به مقادیر مطلق ضروری است؛ میانگین NDVI این منطقه از ۰/۱۳۱ در دوره مبنا به ۰/۱۸۶ در پایان قرن می‌رسد. این افزایش مطلق اندک (۰/۰۵۵) به دلیل ساختار چولگی به راست و سطح پایه بسیار پایین پوشش گیاهی، از نظر ریاضی رشدی ۴۲ درصدی را نشان می‌دهد. از منظر اکولوژیک، این پاسخ غیرخطی که در ادبیات علمی به عنوان پدیده سبز شدن مناطق خشک شناخته می‌شود، لزوماً ناشی از بهبود شرایط عمومی اقلیم نیست. بلکه بر اساس متغیرهای ورودی مدل، ناشی از تغییر در توزیع فصلی رطوبت نسبی و دما است که پنجره‌های رشد کوتاه اما موثری را ایجاد می‌کند. علاوه بر این، مطالعات جهانی (Piao et al., 2015) نشان می‌دهند که افزایش غلظت دی‌اکسید کربن در سناریوهای انتشار بالا، با ایجاد «اثر لقای CO_2 »، کارایی مصرف آب گیاهان خشک‌زی را بهبود می‌بخشد. با این حال، از آنجا که مدل‌های یادگیری ماشین توسعه‌یافته در این پژوهش مبتنی بر داده هستند، تفکیک دقیق سهم اثر CO_2 از تغییرات دما و رطوبت نیازمند استفاده از مدل‌های فرآیند محور در مطالعات آتی است.

نتیجه‌گیری

این مطالعه با هدف پیش‌بینی اثرات تغییر اقلیم بر پویایی پوشش گیاهی در استان هرمزگان، رویکردی نوین مبتنی بر مقایسه الگوریتم‌های پیشرفته یادگیری ماشین را ارائه داد. نتایج حاصله منجر به استخراج نتایج کلیدی زیر گردید:

برتری مدل‌های یادگیری ماشین: نتایج نشان داد که الگوریتم‌های XGBoost و GPR با غلبه بر محدودیت‌های روش‌های کلاسیک، ابزارهایی بسیار دقیق برای مدل‌سازی روابط غیرخطی پیچیده در اکوسیستم‌های خشک هستند. به طور خاص، مدل XGBoost به‌عنوان پایدارترین مدل با کمترین ریسک بیش‌برازش شناسایی شد.

نقش کلیدی دما: رژیم حرارتی به‌عنوان اصلی‌ترین پیش‌رسان تغییرات NDVI در منطقه شناسایی شد. پاسخ غیرخطی پوشش گیاهی به دما نشان می‌دهد که مدل‌سازی‌های آینده باید حتماً آستانه‌های تحمل حرارتی گونه‌ها را در نظر بگیرند.

ناهمگونی مکانی در پاسخ به تغییر اقلیم: برخلاف تصور رایج که تغییر اقلیم لزوماً منجر به بیابان‌زایی یکنواخت می‌شود، این پژوهش نشان داد که پاسخ اکوسیستم‌ها به شدت وابسته به مکان است. در حالی که بخش‌های داخلی استان پتانسیل سبز شدن و افزایش زیست‌توده را تحت سناریوی افزایش CO_2 (Chen et al., 2019; Zhu et al., 2016) دارند، مناطق ساحلی و جنوبی به یک وضعیت تعادل جدید و پایدار می‌رسند که ناشی از رسیدن به آستانه ظرفیت برد اکولوژیکی منطقه است.

با توجه به ناهمگونی بارز در پاسخ‌های اکولوژیک نقاط مورد مطالعه، تدوین یک سیاست مدیریتی یکنواخت برای کل منطقه فاقد کارایی بوده و اتخاذ راهبردهای کاملاً مکان‌محور ضرورت دارد. در نقطه نخست که بر اساس پیش‌بینی‌ها از پتانسیل بالای سبز شدن و افزایش چشمگیر حدود ۴۲ درصدی NDVI برخوردار است، رویکرد مدیریتی باید بر توسعه پایدار پوشش گیاهی و بهره‌برداری مسئولانه استوار باشد. این منطقه ظرفیت مناسبی برای اجرای برنامه‌های ترسیب کربن و توسعه سامانه‌های تلفیقی مانند جنگل-کشاورزی دارد و می‌توان با احداث سامانه‌های پخش سیلاب و تغذیه مصنوعی آبخوان‌ها شرایط رطوبتی لازم را برای پشتیبانی از این رشد طبیعی فراهم ساخت. علاوه بر این، پایش مداوم برای کنترل گونه‌های مهاجم ضروری است تا از بروز اختلال در روند ترمیم طبیعی جلوگیری شود.

در نقطه دوم که رشد محدود و رسیدن زودهنگام به آستانه پایداری اکوسیستم (افزایش تنها ۱۰/۹ درصدی NDVI) نشان‌دهنده شکنندگی و نزدیک شدن به ظرفیت برد زیست‌محیطی است، رویکرد مدیریت باید بر محافظت سخت‌گیرانه و افزایش تاب‌آوری اکوسیستم متمرکز باشد. اقداماتی نظیر اجرای قرق و کنترل شدید چرای دام برای کاهش فشار بر پوشش گیاهی، به‌کارگیری سامانه‌های خردبوم‌شناختی جمع‌آوری بارش مانند هلالی‌های آبیگر جهت حفظ رطوبت خاک، و در صورت ضرورت احیاء، کاشت

گونه‌های بومی فوق‌مقاوم به خشکی و شوری نظیر *Prosopis*، *Acacia* و گونه‌های سازگار *Ziziphus*، می‌تواند توان اکوسیستم را برای تحمل تنش‌های ناشی از افزایش دما و تبخیر و تعرق در آینده تقویت کند. این رویکرد تفکیکی و مکان‌محور، امکان مدیریت کارآمد هر رویشگاه را بر اساس قابلیت‌ها و محدودیت‌های واقعی آن فراهم می‌سازد.

این پژوهش اگرچه چارچوبی مقاوم برای پیش‌بینی اثرات تغییر اقلیم بر NDVI باتکیه بر الگوریتم‌های پیشرفته یادگیری ماشین ارائه می‌دهد، اما دارای محدودیت‌هایی است که می‌تواند مسیر تحقیقات آینده را روشن‌تر سازد. نخست آنکه ماهیت نقطه‌محور مطالعه، اگرچه برای مقایسه دقیق مدل‌های محاسباتی سنگین و فهم رفتارهای اکولوژیک واگرا ضروری بود، تعمیم‌پذیری فضایی نتایج را در مقیاس کل هرمزگان محدود می‌کند و استفاده از پردازش‌های ابری و مدل‌سازی پیکسل‌مبنا در آینده می‌تواند این کاستی را رفع کند. همچنین به دلیل محدودیت داده‌های ماهواره‌ای پیوسته، دوره آموزش مدل به سال‌های ۲۰۰۰ تا ۲۰۱۸ محدود شد و برخی متغیرها مانند بارش، به دلیل عدم قطعیت زیاد، از ورودی‌ها حذف گردید؛ از این‌رو بهره‌گیری از تأخیرهای زمانی اقلیمی یک تا سه‌ماهه در مدل‌های آتی توصیه می‌شود. افزون بر این، پیش‌بینی‌ها تنها تحت سناریوی SSP3-7.0 انجام شده و دامنه کامل عدم قطعیت‌ها را بازنمایی نمی‌کند، بنابراین شبیه‌سازی تحت سناریوهای متنوع‌تری مانند SSP2-4.5 ضروری است. نهایتاً مدل‌ها تنها پاسخ اقلیمی بالقوه پوشش گیاهی را نمایش می‌دهند و عوامل انسانی همچون چرای مفرط و تغییر کاربری می‌توانند این پتانسیل را تضعیف یا خنثی کنند؛ لذا ترکیب این چارچوب با مدل‌های پویایی کاربری اراضی و تحلیل تفکیکی سهم محرک‌ها (مانند تفکیک نقش دما و CO₂) می‌تواند تصویر دقیق‌تر و واقع‌بینانه‌تری از آینده NDVI ارائه دهد.

منابع

- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32. <https://doi.org/10.3390/land13040533>
- Chen, C., Park, T., Wang, X., Piao, S., Xu, B., Chaturvedi, R. K., ... & Myneni, R. B. (2019). China and India lead in the greening of the world through land-use management. *Nature Sustainability*, 2(2), 122-129. <https://doi.org/10.1038/s41893-019-0220-7>.
- Chen, T. (2016). XGBoost: a scalable tree boosting system. *Cornell University*.
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared, is more informative than SMAPE, MAE, MAPE, MSE, and RMSE in regression analysis evaluation. *PeerJ Computer Science* 7:e623 <https://doi.org/10.7717/peerj-cs.623>
- Dawidowicz, J., & Buczyński, R. (2025). Comparison of the effectiveness of artificial neural networks and elastic net regression in surface runoff modeling. *Water*, 17(3), 405. <https://doi.org/10.3390/w17030405>
- Dehghanisani, G. & Bashi-Azghadi, S.N. (2025). An overview of different perspectives on climate change: analysis and comparison. *Journal of Drought and Climate Change Research (JDCCR)*, 3 (Spatial Issue), 137-156. <https://doi.org/10.22077/jdcr.2025.9047.1124>.
- Del Monte-Luna, P., Brook, B. W., Zetina-Rejón, M. J., & Cruz-Escalona, V. H. (2004). The carrying capacity of ecosystems. *Global Ecology and Biogeography*, 13(6), 485-495. <https://doi.org/10.1111/j.1466-822X.2004.00131.x>.
- Hastie, T. (2009). The elements of statistical learning: data mining, inference, and prediction.
- Hastie, T. J. (2017). Generalized additive models. *Statistical models in S*, 249-307.
- Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J.,... & Thépaut, J. N. (2020). The ERA5 global reanalysis. *Quarterly journal of the royal meteorological society*, 146(730), 1999-2049. <https://doi.org/10.1002/qj.3803>.
- Kazemi, M., Nafarzadegan, A. R., & Mohammadi, F. (2020). Investigation of the relationship between maximum dust and climatic variables using remote sensing data (Case study: Hormozgan province). *Iranian Journal of Range & Desert Research*, 27(4). <https://doi.org/10.22092/IJRDR.2020.123154>
- Kling, H., Fuchs, M., & Paulin, M. (2012). Runoff conditions in the upper Danube basin under an ensemble of climate change scenarios. *Journal of Hydrology*, 424, 264-277. <https://doi.org/10.1016/j.jhydrol.2012.01.011>.

- Lange, S. (2019). Trend-preserving bias adjustment and statistical downscaling with ISIMIP3BASD (v1. 0). *Geoscientific Model Development*, 12(7), 3055-3070. <https://doi.org/10.5194/gmd-12-3055-2019>.
- Li, A., Yin, S., Li, N., & Shi, C. (2025). Comprehensive analysis of the driving forces behind NDVI variability in China under climate change conditions and future scenario projections. *Atmosphere*, 16(6), 738. <https://doi.org/10.3390/atmos16060738>
- Li, C., Yu, Y., Sun, L., He, J., Zhang, H., Lu, Y., Guo, Z., Zhang, L., Malik, I., Wistuba, M., & Yu, R. (2025). The response of NDVI to climate change in the lowest and hottest basins in China. *Atmosphere*, 16(7), 778. <https://doi.org/10.3390/atmos16070778>
- Li, X., Wang, Y., Zhao, Y., Zhai, J., Liu, Y., Han, S., & Liu, K. (2024). Research on the impact of climate change and human activities on the NDVI of arid areas—a case study of the Shiyang River basin. *Land*, 13(4), 533. <https://doi.org/10.3390/land13040533>
- Liu, Y., Tian, J., Liu, R., & Ding, L. (2021). Influences of climate change and human activities on NDVI changes in China. *Remote Sensing*, 13(21), 4326. <https://doi.org/10.3390/rs13214326>.
- Ma, Y., Zuo, L., Gao, J., Liu, Q., & Liu, L. (2021). Comparing four types of methods for karst NDVI prediction based on machine learning. *Atmosphere*, 12(10), 1341. <https://doi.org/10.3390/atmos12101341>
- Mohammadi, M. (2026). Using machine learning to improve precipitation estimation by ERA5 data at meteorological stations in West Azerbaijan Province. *Journal of Drought and Climate Change Research (JDCR)*, 3 (Spatial Issue), 37-56. <https://doi.org/10.22077/jdcr.2025.9231.1137>.
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900. <https://doi.org/10.3390/land13040533>
- Nguyen, K. A., Seeboonruang, U., & Chen, W. (2023). Projected climate change effects on global vegetation growth: a machine learning approach. *Environments*, 10(12), 204. <https://doi.org/10.3390/environments10120204>
- Otieno, L. A., Otieno, T. A., Rotich, B., Löhr, K., & Kipkulei, H. K. (2025). Integrating remote sensing and machine learning to evaluate environmental drivers of post-fire vegetation recovery in the Mount Kenya forest. *Discover Geoscience*, 3(1), 81. <https://doi.org/10.1007/s44288-025-00196-5>
- Otieno, T. A., Otieno, L. A., Rotich, B., Löhr, K., & Kipkulei, H. K. (2025). Modeling climate change impacts and predicting future vulnerability in the Mount Kenya forest ecosystem using remote sensing and machine learning. *Environmental Monitoring and Assessment*, 197(6), 631. <https://doi.org/10.1007/s10661-025-14089-0>
- Pato, M., Moradi, S., & Henareh, J. (2025). Investigating the effects of climate change and dust storms on the health and sustainability of the Zagros forest ecosystem. *Journal of Drought and Climate Change Research (JDCR)*, 3 (Special Issue), 1-16. <https://doi.org/10.22077/jdcr.2025.9043.1126>.
- Peñuelas, J., et al. (2013). Evidence of the current impact of climate change on life: a walk from genes to the biosphere. *Global Change Biology*, 19(8), 2303-2338. <https://doi.org/10.1111/gcb.12143>
- Phan, P., Chen, N., Xu, L., Dao, D. M., & Dang, D. (2021). NDVI variation and yield prediction in growing season: a case study with tea in Tanuyen, Vietnam. *Atmosphere*, 12(8), 962. <https://doi.org/10.3390/atmos12080962>
- Piao, S., Yin, G., Tan, J., Cheng, L., Huang, M., Li, Y.,... & Wang, Y. (2015). Detection and attribution of vegetation greening trend in China over the last 30 years. *Global change biology*, 21(4), 1601-1609. <https://doi.org/10.1111/gcb.12795>.
- Rasmussen, C. E., & Williams, C. K. I. (2006). Gaussian processes for machine learning. The MIT Press.
- Riahi, K., Van Vuuren, D. P., Kriegler, E., Edmonds, J., O'neill, B. C., Fujimori, S.,... & Tavoni, M. (2017). The shared socioeconomic pathways and their energy, land use, and greenhouse gas emissions implications: An overview. *Global environmental change*, 42, 153-168. <https://doi.org/10.1016/j.gloenvcha.2016.05.009>.
- Salehnia, N., Byun, E., Ahn, J., & Kumari, K. (2025). Continuous gap-filled atmospheric N2O record for the past 800,000 years using machine learning techniques. *npj Climate and Atmospheric Science*, 8(1), 263. <https://doi.org/10.1038/s41612-025-01153-2>

- Shamsaei, N., Mahdavi, R., Khoorani, A., and Gholami, H. (2025). Investigating the impact of land surface temperature, evaporation, transpiration, and rainfall on changes in vegetation cover in Hormozgan province. *Geography*, 22(83), 91-121. <https://doi.org/10.22034/jiga.2025.2036593.1319>
- Sharifi, O., Behroozeh, S., & Behroozeh, S. (2025). Soil Parameters Under Varying Land Use Types in-Spatiotemporal Trends of Climatic Southern Iran. *Spanish Journal of Soil Science*, 15, 14806. <https://doi.org/10.3389/sjss.2025.14806>.
- Sun, M., Gong, A., Zhao, X., Liu, N., Si, L., & Zhao, S. (2023). Reconstruction of a monthly 1 km NDVI time series product in China using random forest methodology. *Remote Sensing*, 15(13), 3353. <https://doi.org/10.3390/rs15133353>
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, 106(D7), 7183-7192. <https://doi.org/10.1029/2000JD900719>
- Tobore, A. O., Nkwunonwo, U. C., Abdussalaam, S. A., Oyerinde, G., Samson, V. M., Adeoba, A. Q.,... & Adelana, A. O. (2025). Random forest algorithm and remote sensing techniques for wetland soil organic carbon prediction towards environmental sustainability. *Discover Environment*, 3(1), 222. <https://doi.org/10.1007/s44274-025-00410-8>
- Verrelst, J., Muñoz, J., Alonso, L., Delegido, J., Rivera, J. P., Camps-Valls, G., & Moreno, J. (2012). Machine learning regression algorithms for biophysical parameter retrieval: Opportunities for Sentinel-2 and -3. *Remote Sensing of Environment*, 118, 127-139. <https://doi.org/10.1016/j.rse.2011.11.002>
- Wagle, P., Danala, G., Donner, C., Xiao, X., Moffet, C., Gunter, S. A.,... & Ebert, D. S. (2024). Modeling time series of vegetation indices in tallgrass prairie using machine learning and deep learning algorithms. *Ecological Informatics*, 84, 102917. <https://doi.org/10.1016/j.ecoinf.2024.102917>
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research*, 30(1), 79-82. <https://doi.org/10.3354/cr030079>
- Wood, S. N. (2017). Generalized Additive Models: An Introduction with R (2nd ed.). *Chapman and Hall/CRC*.
- Xia, J., Niu, S., Ciais, P., Janssens, I. A., Chen, J., Ammann, C., ... & Luo, Y. (2014). Joint control of terrestrial gross primary productivity by plant phenology and physiology. *Proceedings of the National Academy of Sciences*, 111(21), 7673-7678. <https://doi.org/10.1073/pnas.1413090112>
- Yuan, W., et al. (2019). Increased atmospheric vapor pressure deficit reduces global vegetation growth. *Science Advances*, 5(8), eaax1396. <https://doi.org/10.1126/sciadv.aax1396>
- Zhu, Z., Piao, S., Myneni, R. B., Dong, M., Zeng, Z., Canadell, J. G., ... & Zeng, N. (2016). Greening of the Earth and its drivers. *Nature Climate Change*, 6(8), 791-795.

