Pixel-Level Classification of Healthy and Stressed Citrus Leaves Using UAV Multispectral Images and Machine Learning Techniques

طبقه‌بندی پیکسلی برگ‌های سالم و تنش‌دار مرکبات با استفاده از تصاویر چندطیفی پهپاد و تکنیک‌های یادگیری ماشین

چکیده: با توجه به رشد فزاینده جمعیت و اهمیت محصولات کشاورزی در تأمین امنیت غذایی، تشخیص سریع و دقیق تنش‌های گیاهی، به‌ویژه در محصولات باغی مانند مرکبات، اهمیتی دوچندان یافته است. توسعه پهپادها و سنجنده‌های چندطیفی، امکان پایش غیرتماسی، سریع و با دقت بالای سلامت گیاه را فراهم ساخته و زمینه استفاده از روش‌های نوین تحلیل داده را فراهم کرده اند.در این پژوهش، داده‌های چندطیفی درختان مرکبات محوطه دانشگاه صنعتی نوشیروانی بابل با استفاده از پهپاد فانتوم ٤ پرو چندطیفی گردآوری شد. پس از تولید عکس‌نقشه(Orthomosaic)، استخراج ١٦٠٠٠ نمونه برچسب‌خورده (سالم و دچار تنش) انجام گرفت. در این مطالعه تفکیک عمومی نمونه‌های سالم و تنش‌دار انجام شده و هدف، شناسایی عامل یا نوع خاص تنش نبوده است .به‌منظور ارزیابی عملکرد مدل‌ها با کنترل وابستگی مکانی نمونه‌ها، تقسیم‌بندی داده‌ها و اعتبارسنجی بر اساس شناسه درخت انجام شد. سه سناریوی تحلیلی طراحی شدند: در سناریوی اول، عملکرد ده الگوریتم یادگیری ماشین با استفاده از باندهای طیفی خام و شاخص‌های گیاهی اولیه بررسی شد؛ در سناریوی دوم، عملکرد مدل‌ها با استفاده از مجموعه‌های ویژگی شامل شاخص‌های گیاهی منتخب، باندهای خام و ترکیب آن‌ها، همراه با تنظیم ابرپارامترها و اعتبارسنجی متقاطع گروهی تودرتو ارزیابی شد؛ و در سناریوی سوم، عملکرد ٢٠ ترکیب از روش‌های Soft Voting و Stacking با استفاده از اعتبارسنجی متقاطع گروهی تودرتو مورد مقایسه قرار گرفت. نتایج سناریوی اول نشان داد که رگرسیون لجستیک با F١–macro برابر با ٨٦/٥٢٪ بهترین عملکرد را بر اساس این معیار به دست آورد. در سناریوی دوم، بیشترین F١–macro در مجموعه شاخص‌های گیاهی به رگرسیون لجستیک با مقدار ٨٦/٧٤٪ و در مجموعه ویژگی ترکیبی به درخت تصمیم با مقدار ٨٦/٧١٪ تعلق داشت. در سناریوی سوم، ترکیب Soft Voting مبتنی بر جنگل تصادفی و رگرسیون لجستیک (VOTE_rf+lr) با میانگین F١–macro برابر با ٨٧/٠٠٪ و انحراف معیار آن ٤/٤٠ واحد درصد، همراه با میانگین دقت ٩١/١٣٪، بهترین عملکرد را میان ترکیب‌های بررسی‌شده ارائه کرد. همچنین، میانگین زمان محاسباتی این ترکیب در هر Fold برابر با ١٠/٠٤ ثانیه بود. در ارزیابی نهایی، ترکیب منتخب بر روی مجموعه آزمون مستقل شامل ١٠٢٠ نمونه پیکسلی متعلق به چهار درخت دیده‌نشده، به دقت کلی ٩٥،٢٠٪، مقدار F١–macroبرابر با ٩٣،٨٨٪ و مقدار ROC–AUC برابر با ٠،٩٨٩٠ دست یافت. در مجموع، نتایج نشان می‌دهد که ترکیب داده‌های چندطیفی پهپادی با الگوریتم‌های یادگیری ماشین و روش‌های Ensemble می‌تواند برای تفکیک پیکسلی نمونه‌های دارای ظاهر

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

سالم و تنش‌دار در مجموعه داده مورد مطالعه مناسب باشد؛ با این حال، تعمیم نتایج به سایر باغ‌ها و شرایط محیطی نیازمند ارزیابی مستقل است.

کلمات کلیدی: پایش تنش گیاهی، مرکبات، پهپاد، تصاویر چندطیفی، شاخص‌های گیاهی، یادگیری ماشین، مدیریت هوشمند باغ

چکیده انگلیسی:

Given the importance of agricultural production in ensuring food security, monitoring plant health and identifying visible signs of stress in orchard crops, including citrus, are essential. The development of unmanned aerial vehicles (UAVs) and multispectral sensors has enabled rapid, non-contact monitoring of vegetation and facilitated the application of machine learning methods for plant assessment. In this study, multispectral images of citrus trees located on the campus of Babol Noshirvani University of Technology were acquired using a DJI P4 Multispectral UAV. Following orthomosaic generation, 16,000 pixel-level samples, including 8,000 healthy-looking and 8,000 visibly stressed samples, were extracted and labeled. The objective was to distinguish between generally healthy-looking and visibly stressed samples rather than identify a specific stress factor or type. To account for spatial dependence among samples, data partitioning and model evaluation were performed based on tree identifiers. Three analytical scenarios were designed. Scenario 1 evaluated ten machine learning algorithms using raw spectral bands and initially selected vegetation indices. Scenario 2 assessed model performance using vegetation-index-only, spectral-band-only, and combined feature sets, together with hyperparameter tuning and nested group cross-validation. Scenario 3 evaluated twenty ensemble combinations based on Soft Voting and Stacking using nested group cross-validation. In Scenario 1, Logistic Regression achieved the highest F1-score of 86.52%. In Scenario 2, the highest F1-scores were obtained by Logistic Regression using vegetation indices only (86.74%) and Decision Tree using the combined feature set (86.71%). In Scenario 3, the Soft Voting combination of Random Forest and Logistic Regression (VOTE_rf+lr) achieved the highest mean F1-score of 87.00% (D = 4.40 percentage points), with a mean accuracy of 91.13%. On the tree-level held-out test set, consisting of 1,020 pixel samples from four previously unseen trees, the selected ensemble achieved an overall accuracy of 95.20%, a macro-F1 score of 93.88%, and a ROC-AUC of 0.9890. Overall, the findings indicate that integrating UAV multispectral data with machine learning and ensemble methods can provide a suitable approach for pixel-level discrimination between healthy-looking and visibly stressed samples within the studied dataset. Nevertheless, further independent evaluations involving more trees, orchards, and environmental conditions are required to assess the generalizability of the results.

Keywords: Plant Stress Classification, Citrus, Drone (UAV), Multispectral Images, Vegetation Indices, Machine Learning, Smart Orchard Management

۱- مقدمه

مرکبات با نام علمی Citrus و متعلق به خانواده روتاسه، از مهم‌ترین محصولات باغی در سطح جهان به شمار می‌روند و به‌طور گسترده در مناطق مختلف دنیا کشت می‌شوند. این خانواده نه‌تنها بزرگ‌ترین گروه محصولات باغی تجاری جهان را تشکیل می‌دهد، بلکه به دلیل دارا بودن ترکیبات مفید درمانی و غنای بالای فیبر غذایی، نقش مهمی در تأمین نیازهای تغذیه‌ای و حفظ سلامت انسان ایفا می‌کند (Sanofer, ۲۰۱٤). بر اساس گزارش (Taghizadeh-Alisaraei et al., ۲۰۱۷)، تولید مرکبات ایران در سال ۲۰۱٤ بالغ بر ٤.۳۲ میلیون تن بوده است. در میان استان‌های کشور، مازندران با تولید حدود ۱.۹۱ میلیون تن در رتبه نخست قرار داشته و پس از آن استان‌های فارس با ۱.۱۲ میلیون تن و کرمان با ۰.۵۷ میلیون تن قرار داشته‌اند. پس از این استان‌ها، هرمزگان، گیلان، گلستان و خوزستان از دیگر مناطق مهم تولیدکننده مرکبات کشور بوده‌اند.

با توجه به اهمیت این محصول، تنش‌های محیطی می‌توانند عملکرد آن را تحت تأثیر قرار دهند. این میوه‌ها را نمی‌توان به دلیل فساد پس از برداشت برای مدت طولانی در شرایط عادی نگهداری کرد؛ امری که باعث خسارات اقتصادی سنگین تا ۳۰ درصد از کل تولید می‌شود و در کشورهای توسعه‌نیافته می‌تواند تا۵۰ درصد نیز برسد.(Richa et al., ۲۰۲۳) ازاین‌رو، شناسایی و مدیریت به‌موقع تنش‌های محیطی مانند تنش گرمایی، خشکی، بیماری‌ها و آفات، برای پایداری و مدیریت تولید ضروری است. از میان عوامل اقلیمی تأثیرگذار بر کشت مرکبات، دما نقش تعیین‌کننده‌ای دارد. صفر فیزیولوژیک مرکبات حدود ۱۲/۵ درجه سانتی‌گراد و دامنه مناسب برای رشد آن تا ۳۲ درجه سانتی‌گراد گزارش شده است. افزایش دما و پدیده گرمایش جهانی یکی از چالش‌های اصلی بخش کشاورزی به شمار می‌رود. با توجه به اینکه مرکبات در گروه گیاهان با متابولیسم C3 قرار می‌گیرند، حساسیت و آسیب‌پذیری بالاتری نسبت به تنش گرمایی دارند (Allen & Vu, ۲۰۰۹; Fotuhi-Qazvini & Fatahi-Moghadam, ۲۰۱۰; Mann et al., ۲۰۱۱; Nouhi et al., ۲۰۱۲). افزایش دما به مقادیری فراتر از حد آستانه و طی دوره زمانی مشخص، می‌تواند خسارات جبران‌ناپذیری در رشد و عملکرد گیاه ایجاد کند. به‌طور معمول، افزایش ۱۰ تا ۱۵ درجه سانتی‌گراد نسبت به دمای مطلوب، منجر به بروز تنش یا شوک گرمایی در گیاه می‌شود. اگرچه گیاهان در شرایط رطوبتی مناسب می‌توانند از طریق افزایش تعرق تا حدی خنک شوند، اما در شرایط کمبود رطوبت نسبی، اثرات منفی تنش گرمایی تشدید خواهد شد(Ahmadi & Mirhaji, ۲۰۱۲). افزون بر این، افزایش دما باعث شدت یافتن تنش‌های نظیر گرما، خشکسالی، بیماری‌ها و آفات می‌شود. ترکیب این تنش‌ها، در صورت عدم مدیریت و واکنش سریع، می‌تواند موجب کاهش جدی بهره‌وری محصولات کشاورزی گردد (Gomiero et al., ۲۰۱۱; Govender et al., ۲۰۰۹). هرچند در این پژوهش، این عوامل به‌صورت مجزا مورد تشخیص یا طبقه‌بندی قرار نگرفته‌اند و تمرکز مطالعه بر تفکیک کلی نمونه‌های سالم و دارای تنش بر اساس ویژگی‌های طیفی است. در این راستا، وضعیت نمونه‌ها بر اساس علائم ظاهری قابل مشاهده در برگ‌ها در دو گروه کلی سالم و تنش‌دار طبقه‌بندی شد. نمونه ای از برگ‌های دارای تنش درختان مرکبات و آسیب‌های آن در شکل ۱ نشان داده شده است.

مقاله در نوبت انتشار
نسخه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »



شکل ۱. نمونه‌ای از برگ‌های دارای تنش در درختان مرکبات؛ خطوط قرمز محدوده برگ‌های دارای تنش را نشان می‌دهند.

برای تشخیص بیماری‌ها و تنش‌ها در درختان، روش‌های مختلفی به‌کار گرفته می‌شود. یکی از متداول‌ترین این روش‌ها، بازدید میدانی و بررسی بصری درختان توسط کارشناسان است؛ روشی که به شدت به تجربه و مهارت فرد متخصص وابسته است(Keremane et al., ۲۰۱۵). نرخ کشف درختان آلوده در روش‌های مختلف پیمایش بصری، تنها حدود ٤٧ تا ٦١ درصد گزارش شده است (Futch et al., ۲۰۰۹). علاوه بر این، نمونه‌برداری دستی از برگ‌ها و تشخیص آلودگی فرآیندی زمان‌بر و پرهزینه بوده و در مقیاس‌های بزرگ کارایی لازم را ندارد؛ به‌طوری‌که تکمیل نمونه‌برداری ممکن است ماه‌ها به طول انجامد و در این فاصله، میزان آلودگی می‌تواند افزایش یابد(Garcia-Ruiz et al., ۲۰۱۳).

به‌کارگیری فناوری پرنده هدایت پذیر از راه دور (پهپاد) (UAV)[1] یکی از راهکارهای نوین و کارآمد برای تشخیص بیماری‌ها و تنش‌های گیاهی به‌شمار می‌رود. این فناوری با ترکیب اطلاعات مکانی و طیفی حاصل از تصویربرداری و تکنیک‌های طیف‌سنجی، امکان تشخیص دقیق‌تر وضعیت سبزینگی و سلامت درختان مرکبات را فراهم می‌سازد و از مزیت‌های هر دو روش بهره می‌برد (Garcia-Ruiz et al., ۲۰۱۳; Mishra et al., ۲۰۱۱; Sarkar et al., ۲۰۱٦).

در تصویربرداری کشاورزی، سنجنده‌ها و ابزارهای متعددی برای پایش محصولات مورد استفاده قرار می‌گیرند؛ از جمله سنجنده‌های نور مرئی، چندطیفی، دما و رطوبت. تغییرات بازتاب طول‌موج‌های مختلف یا نسبت آن‌ها در اثر بیماری‌ها و تنش‌های گیاهی رخ می‌دهد و این ویژگی، امکان تشخیص سریع‌تر، دقیق‌تر و پیش از بروز علائم ظاهری را فراهم می‌سازد. به‌کارگیری سنجنده‌های چندطیفی در کنار الگوریتم‌های یادگیری ماشین، می‌تواند فرایند تشخیص و ارزیابی سلامت گیاهان را به میزان قابل توجهی تسریع و تسهیل کند.

[1] Unmanned Aerial Vehicle

در ایران، به‌ویژه در استان مازندران، پژوهش‌های کاربردی در زمینه پایش سلامت محصولات باغی با استفاده از پهپادهای چندطیفی هنوز محدود است. انجام مطالعات گسترده‌تر در این حوزه می‌تواند نقش مهمی در بهبود مدیریت باغات و افزایش بهره‌وری ایفا کند.

در این پژوهش، ابتدا مطالعات پیشین و مقالات مرتبط با پایش تنش گیاهی مبتنی بر تصاویر چندطیفی و الگوریتم‌های یادگیری ماشین مرور و تحلیل شده و نقاط قوت و خلأهای موجود مشخص گردیده است. سپس روش پیشنهادی شامل معرفی منطقه مطالعه، جمع‌آوری داده‌ها، فرایند برچسب‌گذاری، استخراج شاخص‌های گیاهی و مدل‌سازی با الگوریتم‌های منتخب تشریح شده است. در بخش چهارم، نتایج و تحلیل عملکرد مدل‌ها ارائه شده و در نهایت، بخش پنجم به نتیجه‌گیری و پیشنهادهای آینده اختصاص یافته است.

اهداف اصلی این پژوهش شامل توسعه و ارزیابی یک چارچوب کارآمد یادگیری ماشین برای تفکیک نمونه‌های سالم و تنش‌دار مرکبات‌بر اساس تصاویر چندطیفی اخذ شده توسط پهپاد، مقایسه و ارزیابی عملکرد الگوریتم‌های مختلف یادگیری ماشین در سه سناریوی طراحی‌شده، بررسی اثر همبستگی و افزونگی ویژگی‌های استخراج‌شده بر عملکرد مدل‌های طبقه‌بندی، و ارزیابی عملکرد روش‌های ترکیبی نظیر Voting و Stacking از نظر دقت و کارایی محاسباتی است.

۲- مرور ادبیات

در سال‌های اخیر، با توسعه پهپادها و دسترسی گسترده‌تر متخصصان به سنجنده‌های چندطیفی مقرون‌به‌صرفه، کاربرد این فناوری‌ها در کشاورزی رشد چشمگیری داشته است. با توجه به اهمیت روزافزون امنیت غذایی، استفاده از تصویربرداری چندطیفی می‌تواند نقشی کلیدی در مدیریت، پایش و تشخیص زودهنگام بیماری‌ها و تنش‌های گیاهی ایفا کند. ترکیب این سنجنده‌ها با الگوریتم‌های یادگیری ماشین نیز امکان شناسایی سریع‌تر و دقیق‌تر عوامل بیماری‌زا را فراهم کرده و به دلیل اثربخشی بالا، توجه پژوهشگران و فعالان حوزه کشاورزی را به خود جلب کرده است.

در مطالعه (Miraki et al., ۲۰۲۲)، آشکارسازی درختان پرتقال و تشخیص تنش گیاهی بر اساس داده‌های طیفی اخذشده از پهپاد با دو هدف مورد بررسی قرار گرفته است: نخست، ارزیابی توانایی داده‌های پهپادی در شناسایی درختان و دوم، سنجش میزان سلامت مرکبات. نتایج طبقه‌بندی این پژوهش نشان داد که درختان دارای تنش با دقت کلی ٦٩٪ قابل تشخیص هستند.

در مطالعه دیگر(Ampatzidis & Partel, ۲۰۱۹)، یک سیستم نوین، خودکار و کم‌هزینه مبتنی بر پهپاد، تصویربرداری چندطیفی و هوش مصنوعی (یادگیری عمیق) برای ارزیابی سریع صفات فنوتیپی درختان مرکبات معرفی می‌کند. این روش قادر است با دقت بسیار بالا (بیش از ۹۹ درصد) درختان و فضاهای خالی باغ را شمارش و مکان‌یابی کرده و ویژگی‌هایی نظیر اندازه تاج و شاخص سلامت را ارزیابی کند؛ از این رو جایگزینی بسیار کارآمد و مقرون‌به‌صرفه برای روش‌های سنتیِ پرزحمت و زمان‌برِ اصلاح نباتات به شمار می‌رود.

در یک پژوهش دیگر(Woolfson, 2024)، به بررسی کارایی ترکیب تصاویر چندطیفیِ پهپادها و الگوریتم‌های یادگیری عمیق (مدلResNet-101) برای تشخیص زودهنگام بیماریِ مخرب «پوسیدگی ریشه» در باغ‌های لیمو پرداخته است. نتایج نشان می‌دهد که این سیستم هوشمند قادر است با دقت ۸۰ درصد درختان بیمار را از سالم تفکیک کند؛ لذا استفاده از این فناوری

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

می‌تواند به عنوان ابزاری کارآمد برای مدیریت سریع، جلوگیری از گسترش بیماری‌ها و حفظ کیفیت محصولات باغی مورد استفاده قرار گیرد.

در مطالعه دیگر(Matusevicius e de Castro & Bolfe, 2023) مروری نشان می‌دهد که ترکیب سنجش از دور (پهپادهای مجهز به حسگرهای چندطیفی و ابرطیفی) با الگوریتم‌های یادگیری ماشین و یادگیری عمیق، روشی بسیار کارآمد برای تشخیص بیماری‌های مخرب مرکبات مانند «گرینینگ» است. با وجود دقت بالای این مدل‌ها در شناسایی درختان بیمار با استفاده از داده‌های مکانیِ دقیق و باندهای طیفی خاص (مثلRed-Edge)، تشخیص زودهنگام بیماری پیش از بروز علائم ظاهری، همچنان یک چالش علمی است و نیازمند تحقیقات بیشتر می‌باشد.

در مطالعه دیگر(Peres & Cancelliere, 2021) ، نتایج این مطالعه نشان داد که برخی شاخص‌های گیاهی، از جمله NDVI، GNDVI و SIPI2، می‌توانند برای بررسی تفاوت‌های وضعیت پوشش گیاهی در باغ‌های مرکبات مفید باشند.با شناسایی دقیق مناطقی از باغ که دچار کمبود یا مازاد آبیاری هستند، این فناوری می‌تواند بهینه‌سازی مصرف آب و ارتقای بهره‌وری سیستم‌های آبیاری را، به‌خصوص در مناطق نیمه‌خشک، به همراه داشته باشد.

در پژوهشی دیگر (Futch et al., ۲۰۰۹)، عملکرد بازرسی بصری برای شناسایی درختان آلوده به HLB را بررسی کردند و محدودیت تشخیص چشمی و وابستگی آن به شرایط و تجربه بازرسان را نشان دادند. نرخ شناسایی گزارش‌شده در مطالعات مرتبط حدود ٤٧ تا ٦١ درصد بوده است.

در مطالعه‌ای دیگر (Lan et al., ۲۰۲۰)، برای جمع‌آوری تصاویر چندطیفی (باندهای سبز، قرمز و مادون قرمز نزدیک) از باغ‌های مرکبات، از دوربین چندطیفی تجاری ADC-lite نصب‌شده بر روی پهپاد DJI M100 استفاده شد. پس از دریافت داده‌ها، تحلیل مؤلفه‌های اصلی[1] (PCA) برای فشرده‌سازی و استخراج ویژگی‌های بالقوه مورد استفاده قرار گرفت. سپس چندین الگوریتم یادگیری ماشین شامل مدل ماشین بردار پشتیبان[2]،k–نزدیک‌ترین همسایه،[3] رگرسیون لجستیک[4] ، بیز ساده و روش‌های یادگیری جمعی با یکدیگر مقایسه شدند. نتایج نشان داد که ویژگی‌های فشرده‌سازی‌شده حاصل ازPCA همراه با شاخص‌های گیاهی[5] و مقادیر اصلی باندها[6] در تمامی مدل‌ها عملکردی با دقت بالا ارائه دادند.

در پژوهشی دیگر، (DadrasJavan et al., ۲۰۱۹) از تصاویر چندطیفی کم‌ارتفاع حاصل از پهپاد در پنج باند شامل آبی، سبز، قرمز، لبه قرمز و مادون‌قرمز نزدیک و مجموعه‌ای از شاخص‌های گیاهی برای شناسایی بیماری سبزینگی مرکبات استفاده کردند. با استفاده از ماشین بردار پشتیبان، دقت کلی ۸۱/۷۵٪ بر اساس نمونه‌های کنترل گزارش شد که بیانگر ظرفیت تصاویر چندطیفی کم‌ارتفاع برای شناسایی سریع درختان آلوده به بیماری سبزینگی بود.

از تصویربرداری فراطیفی[7] برای تشخیص بیماری هوانگ‌لونگ‌بینگ مرکبات در (Li et al., ۲۰۱٤) استفاده شده است. در این پژوهش، روشی به نام نگاشت زاویه طیفی توسعه‌یافته[8] (ESAM) معرفی شد. ابتدا نویزهای طیفی با استفاده از فیلتر Savitzky–

[1] PCA (Principal Component Analysis)
[2] Support Vector Machine (SVM)
[3] K-Nearest Neighbors (K-NN)
[4] Logistic Regression (LR)
[5] Vegetation Indices
[6] Digital Number
[7] Hyperspectral
[8] ESAM (Extended Spectral Angle Mapper)

مقاله در نوت انسار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

Golay حذف گردید، سپس تاج درختان با روش ماشین بردار پشتیبان‌جداسازی شد و نمونه‌های خالص (سالم و آلوده) استخراج گردید. در ادامه، با بهره‌گیری از نگاشت زاویه طیفی و تحلیل موقعیت لبه قرمز، نواحی آلوده شناسایی شدند. روش ESAM با دقت ۸۶٪ عملکرد بهتری نسبت به روش‌های دیگر ارائه داد و پتانسیل بالای داده‌های فراطیفی را برای تشخیص بیماری سندروم HLB[1] تأیید نمود.

در پژوهشی دیگر (Moriya et al., ۲۰۲۱)، توانایی تشخیص بیماری گموز مرکبات[2] که توسط قارچ .Phytophthora spp ایجاد می‌شود، با استفاده از تصاویر فراطیفی و چندطیفی بررسی شد. تصاویر فراطیفی شامل ۲۵ باند در محدوده ۵۰۰ تا ۸۴۰ نانومتر بودند و در کنار آن‌ها، تصاویر چندطیفی شبیه‌سازی‌شده با ۳ باند مورد تحلیل قرار گرفتند. نتایج نشان داد که داده‌های فراطیفی به سبب جزئیات طیفی دقیق‌تر، عملکرد بهتری در تشخیص بیماری گموز ارائه می‌دهند. میزان دقت نقشه‌های سلامت ۰/۷۹ برای داده‌های چندطیفی و ۰/۹۴ برای داده‌های فراطیفی گزارش شد.

در (Deng et al., ۲۰۲۰)، به منظور تشخیص سریع اثرات بیماری هوانگ‌لونگ‌بینگ در باغ‌های وسیع، از سنجش از دور فراطیفی مبتنی بر پهپاد استفاده شد. تصاویر با دوربین Cubert S185 نصب‌شده روی پهپاد DJI Matrice 600 Pro ثبت و داده‌ها با طیف‌سنج ASD Handheld2 اعتبارسنجی شد. سپس با الگوریتم ژنتیک، باندهای کلیدی برای تشخیص بیماری استخراج گردید. مدل‌های تشخیص مبتنی بر ادغام ویژگی‌ها و شبکه عصبی خودرمزگذار تودرتو[3] (SAE) به دقت‌های ۹۹/۳۳٪ برای آموزش و ۹۹/۷۲٪ برای اعتبارسنجی دست یافتند. نتایج میدانی نشان داد که این مدل قادر است مبتلایان به HLB را به‌طور دقیق شناسایی کرده و توزیع بیماری را در سطح گسترده مشخص کند.

در مطالعه‌ای دیگر (Weng et al., ۲۰۱۸)، با استفاده از تصویربرداری فراطیفی و تحلیل متابولیسم کربوهیدرات‌ها، روشی مؤثر برای شناسایی بیماری HLB ارائه شد. یافته‌ها نشان داد که ساکارز در برگ‌های آلوده به هوانگ‌لونگ‌بینگ نسبت به سایر قندها تجمع بیشتری دارد، در حالی که برگ‌های دچار کمبود تغذیه‌ای روند معکوسی نشان می‌دهند. ویژگی‌های طیفی و بافتی استخراج‌شده از طول موج‌های بهینه و تصاویر حاصل از مؤلفه‌های اصلی، ارتباط معناداری با نشانه‌های بیماری داشتند. دقت طبقه‌بندی برگ‌های سالم، آلوده و دارای کمبود تغذیه به ترتیب ۹۰/۲٪، ۹۶٪ و ۹۲/۶٪ (برای فصل‌های مختلف) گزارش شد. علاوه بر این، صحت مدل در گونه‌های مختلف مرکبات با استفاده از انتقال مدل تأیید شد و دقت کلی ۹۳/۵٪ به دست آمد.

در (Qin et al., ۲۰۰۹)، با هدف توسعه یک روش تصویربرداری ابرطیفی برای تشخیص ضایعات شانکر در میوه‌های مرکبات، یک سامانه تصویربرداری بازتابی در محدوده ۴۵۰ تا ۹۳۰ نانومتر طراحی شد. در این آزمایش، نمونه‌های مختلفی از گریپ‌فروت‌های آلوده به شانکر، پوست سالم و سایر شرایط پوستی شامل لکه چربی، آسیب حشرات، ملانوز و زخم باد مورد استفاده قرار گرفتند. روش طبقه‌بندی مبتنی بر واگرایی اطلاعات طیفی[4] (SID) که بر ارزیابی شباهت طیف‌ها نسبت به طیف مرجع شانکر استوار بود، برای تفکیک این شرایط اعمال شد. دقت کلی ۹۶/۲٪ با مقدار آستانه ۰/۰۰۸ برای SID حاصل شد.

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

[1] Huanglongbing
[2] Citrus gummosis
[3] Stacked Autoencoder
[4] Spectral Information Divergence (SID)

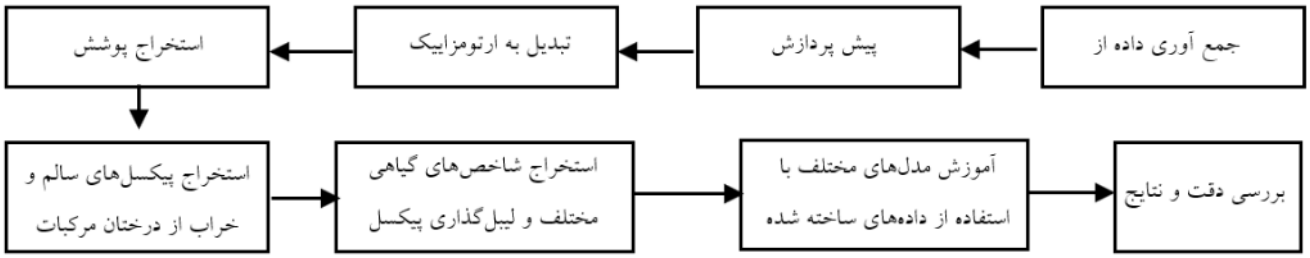
در مجموع، با وجود مطالعات متعدد در حوزه تشخیص تنش‌ها و بیماری‌های مرکبات، همچنان نیاز به بررسی جامع‌تر برای مقایسه عملکرد مدل‌های یادگیری ماشین و ارزیابی کارایی سنجنده‌های چندطیفی وجود دارد. چنین مقایسه‌ای می‌تواند درک دقیق‌تری از مزایا و محدودیت‌های روش‌های موجود ارائه دهد و مسیر تحقیقات آینده را روشن‌تر سازد.

با وجود مطالعات متعدد در زمینه استفاده از تصاویر چندطیفی و الگوریتم‌های یادگیری ماشین برای پایش سلامت و بیماری‌های مرکبات، بخش قابل‌توجهی از تحقیقات بر تشخیص یک بیماری یا تنش مشخص متمرکز بوده‌اند، در حالی که بررسی تفکیک عمومی وضعیت سالم و تنش‌دار درختان مرکبات با استفاده از ویژگی‌های طیفی و شاخص‌های گیاهی همچنان نیازمند ارزیابی‌های جامع‌تر است. همچنین، اگرچه مقایسه الگوریتم‌های مختلف یادگیری ماشین و استفاده از روش‌های Ensemble در برخی مطالعات پیشین گزارش شده است، بررسی هم‌زمان اثر کاهش افزونگی ویژگی‌ها، انتخاب مدل، ترکیب مدل‌ها و هزینه محاسباتی در قالب یک چارچوب یکپارچه برای داده‌های چندطیفی UAV مرکبات کمتر مورد توجه قرار گرفته است.

بر این اساس، در پژوهش حاضر یک چارچوب سه‌مرحله‌ای برای ارزیابی تفکیک نمونه‌های سالم و تنش‌دار مرکبات ارائه می‌شود که در آن ابتدا عملکرد چندین الگوریتم یادگیری ماشین مقایسه شده، سپس اثر کاهش همبستگی و افزونگی ویژگی‌ها بر عملکرد مدل‌ها ارزیابی می‌شود و در ادامه عملکرد مدل‌های منتخب با استفاده از روش‌های Voting و Stacking بررسی می‌گردد.

۳- چارچوب پژوهش و روش‌شناسی تفکیک پیکسلی نمونه‌های سالم و دارای تنش

به منظور ارزیابی دقیق وضعیت سلامت و پایش میزان تنش در باغات مرکبات، یک چارچوب عملیاتی مبتنی بر سنجش از دور و یادگیری ماشین طراحی گردید. فرآیند کلی این پژوهش، مطابق با آنچه در شکل ۲ ترسیم شده است، از هشت مرحله کلیدی تشکیل شده که با جمع‌آوری داده‌های تصویری توسط پرنده‌های بدون سرنشین آغاز می‌گردد. پس از انجام عملیات پیش‌پردازش و تولید نقشه ارتوموزاییک، ساختار تاج درختان از پس‌زمینه تفکیک شده و بر اساس شاخص‌های طیفی، پیکسل‌های سالم و دارای تنش استخراج می‌شوند. در نهایت، با استخراج شاخص‌های گیاهی و برچسب‌گذاری داده‌ها، مدل‌های مختلف یادگیری ماشین آموزش دیده و کارایی آن‌ها در تفکیک پیکسلی نمونه‌های سالم و دارای علائم ظاهری تنش مورد ارزیابی قرار می‌گیرد.



شکل ۲. بلوک دیاگرام مراحل انجام کار جهت بررسی تفکیک پیکسلی نمونه‌های سالم و دارای علائم ظاهری تنش بوسیله آموزش مدل‌های یادگیری ماشین مختلف

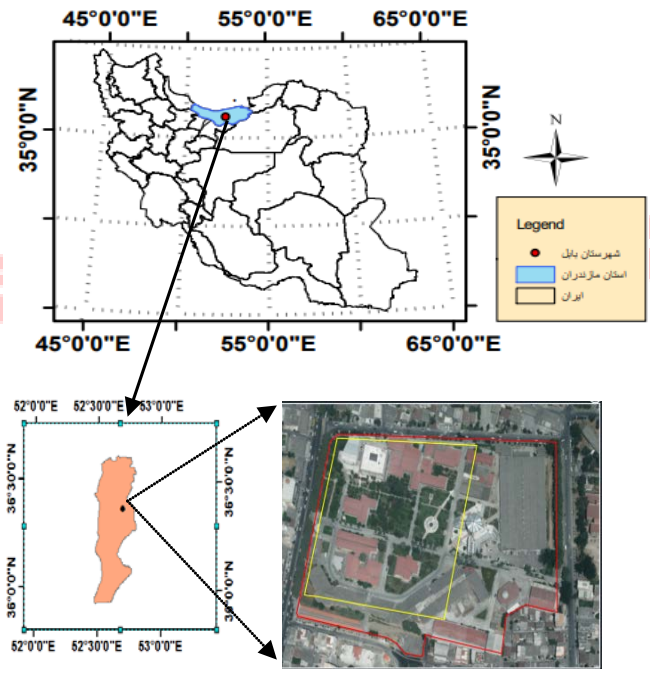
۳-۱- منطقه مورد مطالعه و داده‌ها

در این مطالعه، محوطه دانشگاه صنعتی نوشیروانی بابل واقع در استان مازندران به دلیل وجود تعداد قابل‌توجهی درخت مرکبات به‌عنوان منطقه مورد مطالعه انتخاب شد (شکل ۳). از پهپاد فانتوم ٤ پرو چندطیفی با قابلیت تصویربرداری رنگی و چندطیفی (آبی، سبز، قرمز، لبه قرمز و مادون قرمز نزدیک) برای تصویربرداری منطقه مورد مطالعه استفاده شد (شکل ٤).

تصویربرداری از منطقه مورد مطالعه در آبان ۱۳۹۹ و در حدود ساعت ۱۱ و در شرایط آسمان آفتابی انجام شد. ارتفاع پرواز پهپاد ٦۰ متر در نظر گرفته شد و تصاویر با تفکیک مکانی (GSD) حدود سه سانتی‌متر اخذ شدند. میزان همپوشانی طولی و عرضی تصاویر به‌ترتیب ۷۰ و ٦۰ درصد بود. به‌منظور ثبت تغییرات تابش خورشیدی در طول فرآیند تصویربرداری، از حسگر طیفی نور خورشید (Downwelling Light Sensor; DLS) نصب‌شده بر روی پهپاد DJI P٤ Multispectral استفاده شد. داده‌های این حسگر همراه با تصاویر چندطیفی در فراداده تصاویر ثبت شدند و در فرآیند کالیبراسیون بازتابندگی در نرم‌افزار Agisoft Metashape مورد استفاده قرار گرفتند. در این پژوهش، تصحیح رادیومتریک بر مبنای داده‌های حسگر DLS انجام شد و از پنل بازتابندگی مرجع استفاده نشد. استفاده از اطلاعات ثبت‌شده توسط این حسگر به جبران تغییرات تابش فرودی خورشید در طول تصویربرداری و بهبود سازگاری رادیومتریک داده‌های چندطیفی کمک می‌کند.

تعداد ۹۰ تصویر شامل پنج باند طیفی از کل منطقه مورد مطالعه اخذ و پردازش‌های فتوگرامتری با استفاده از نرم‌افزار Agisoft Metashape در حالت پردازشی Medium انجام شد. عکس‌نقشه حاصل از پردازش تصاویر، با دقت هندسی حدود ۱۰ سانتی‌متر، به‌عنوان پایه برای محاسبه شاخص‌های گیاهی و تحلیل‌های مکانی مورد استفاده قرار گرفت.

مقاله در نوبت انتشار
نسریه علمی پژوهشی
« اطلاعات ... (سپهر) »



شکل ۳. موقعیت جغرافیایی دانشگاه صنعتی نوشیروانی بابل جهت تفکیک پیکسلی نمونه‌های سالم و دارای علائم ظاهری تنش





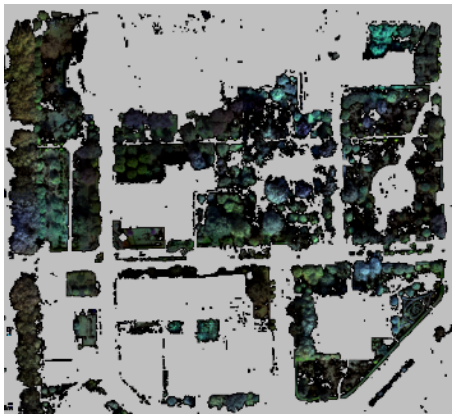
شکل ٤. پهپاد DJI P4 Multispectral و باند های دوربین چندطیفی مورد استفاده در این پهپاد جهت تفکیک پیکسلی نمونه‌های سالم و دارای علائم ظاهری تنش

عکس نقشه حاصل از پردازش تصاویر به‌عنوان پایه‌ای برای محاسبه شاخص‌های گیاهی و تحلیل‌های مکانی مورد استفاده قرار گرفت. برای سهولت در پردازش‌های بعدی ابتدا پوشش گیاهی با استفاده از شاخص NDVI از ساختمان‌ها و سایر مناطق غیرگیاهی تفکیک شدند(شکل ۵).

مقاله در نوبت انتشار



(الف)



(ج)

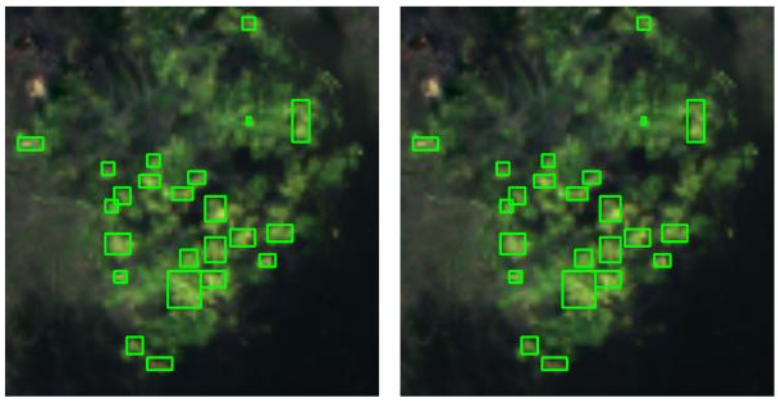


(ب)

شکل ۵. الف) عکس‌نقشه منطقه مورد مطالعه – محوطه دانشگاه صنعتی نوشیروانی بابل ب) استخراج شاخص NDVI مربوط به کل تصویر عکس‌نقشه شده ج) استخراج پوشش گیاهی از تصویر عکس‌نقشه و حذف ساختمان‌ها و پوشش‌های غیر گیاهی

در این تحقیق، نمونه‌های گیاهی بر اساس بررسی بصری تصاویر چندطیفی و شناسایی علائم ظاهری قابل مشاهده در برگ‌ها به دو گروه سالم و تنش‌دار تقسیم و به‌صورت دستی برچسب‌گذاری شدند. نمونه‌های دارای ظاهر طبیعی و فاقد علائم قابل مشاهده تغییر رنگ یا آسیب برگ، در گروه سالم و نمونه‌های دارای علائم ظاهری غیرطبیعی در گروه تنش‌دار قرار گرفتند. ارزیابی بصری و فرآیند برچسب‌گذاری توسط فردی باتجربه در زمینه درختان مرکبات انجام شد. همچنین، بازدید میدانی از منطقه مورد مطالعه در همان روز تصویربرداری، با هدف بررسی وضعیت ظاهری پوشش گیاهی و پشتیبانی از تفسیر نمونه‌های مشاهده‌شده در تصاویر صورت گرفت.

با استفاده از عکس‌نقشه، در مجموع ۱۶۰۰۰ نمونه پیکسلی شامل ۸۰۰۰ نمونه سالم و ۸۰۰۰ نمونه دارای علائم ظاهری تنش استخراج و برچسب‌گذاری شد (شکل ٦). نمونه‌های انتخاب‌شده عمدتاً از بخش‌های برگ‌پوش تاج درختان استخراج شدند و نواحی آشکار غیرگیاهی خارج از محدوده تاج، مانند ساختمان‌ها و سایر پس‌زمینه‌های غیرگیاهی، وارد مجموعه نمونه‌ها نشدند. همچنین، هنگام انتخاب نمونه‌های پیکسلی، تا حد امکان از بخش‌های سایه‌دار تاج درختان اجتناب شد. با توجه به وضوح مکانی تصاویر و ناهمگنی طبیعی ساختار تاج، احتمال حضور تعداد بسیار محدودی پیکسل مختلط یا شامل اجزای غیربرگی به‌طور کامل قابل رد نیست؛ با این حال، نمونه‌برداری با تمرکز بر نواحی برگ‌پوش انجام شد.



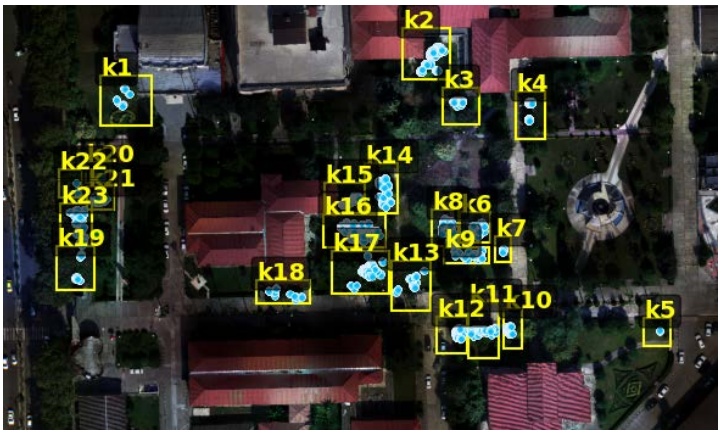
شکل ٦. نمونه پیکسل‌های برچسب‌گذاری شده در تصویر

لازم به ذکر است که شاخص NDVI صرفاً برای تفکیک اولیه پوشش گیاهی از عوارض غیرگیاهی و حذف پس‌زمینه‌هایی مانند ساختمان‌ها مورد استفاده قرار گرفت و در تعیین برچسب کلاس‌های سالم و تنش‌دار نقشی نداشت. تعیین کلاس هر نمونه صرفاً بر اساس بررسی بصری علائم قابل مشاهده در برگ‌ها انجام شد. همچنین، برای تأیید برچسب‌ها از آزمون‌های آزمایشگاهی یا اندازه‌گیری‌های فیزیولوژیک، مانند اندازه‌گیری میزان کلروفیل یا پتانسیل آب برگ، استفاده نشد. بنابراین، برچسب‌های مورد استفاده بیانگر وضعیت ظاهری نمونه‌ها هستند و لزوماً نشان‌دهنده یک علت فیزیولوژیک یا بیماری‌شناختی مشخص نیستند.

نمونه‌های برچسب‌گذاری‌شده به‌صورت لکه‌ای و پراکنده از بخش‌های مختلف پوشش گیاهی و از درختان مختلف انتخاب شدند تا نمونه‌برداری صرفاً به یک ناحیه یا یک تاج درخت محدود نباشد. در مرحله تکمیلی پژوهش، به‌منظور بررسی تأثیر وابستگی مکانی نمونه‌ها بر عملکرد مدل‌های طبقه‌بندی، ساختار مکانی داده‌ها در سطح درخت نیز مورد بررسی قرار گرفت. برای این

مقاله در نوبت انتشار
نشر
« اطلاعات جغرافیایی (سپهر) »

منظور، درختان مرکبات موجود در منطقه مورد مطالعه به‌صورت مجزا شناسایی شدند و پیکسل‌های برچسب‌گذاری‌شده مربوط به هر درخت به شناسه مکانی مستقل اختصاص یافتند. تقسیم بندی پیکسل های هر درخت در شکل۷ قابل مشاهده است. سپس، مجموعه داده بر اساس شناسه درخت‌ها به دو بخش آموزش و آزمون تقسیم شد؛ به‌گونه‌ای که هیچ‌یک از درختان موجود در مجموعه آموزش در مجموعه آزمون حضور نداشته باشند.



شکل ۷. تقسیم‌بندی پیکسل‌ها بر اساس شناسه درخت

در مجموع، نمونه‌های پیکسلی برچسب‌گذاری‌شده به ۲۰ درخت مرکبات مستقل تعلق داشتند. برای کنترل وابستگی مکانی، محدوده مکانی هر درخت به‌صورت مستقل شناسایی و شناسه یکتایی (tree_id) به آن اختصاص داده شد. سپس تمامی نمونه‌های پیکسلی واقع در محدوده هر درخت با همان شناسه گروه‌بندی شدند. این شناسه‌ها در مراحل تقسیم داده‌ها، اعتبارسنجی متقاطع گروهی و تشکیل مجموعه آزمون مستقل مورد استفاده قرار گرفتند.

در این روش، برخلاف تقسیم تصادفی پیکسلی که نمونه‌های یک درخت می‌توانند هم‌زمان در مجموعه‌های آموزش و ارزیابی قرار گیرند، جداسازی بر اساس واحد درخت انجام شد. بنابراین، تمامی پیکسل‌های متعلق به هر درخت صرفاً در یکی از دو مجموعه قرار گرفتند. این رویکرد امکان ارزیابی عملکرد مدل را بر روی درخت‌هایی فراهم می‌کند که در فرآیند آموزش حضور نداشته‌اند و می‌تواند تصویر واقع‌بینانه‌تری از توانایی مدل در تعمیم به درخت‌های مستقل ارائه دهد.

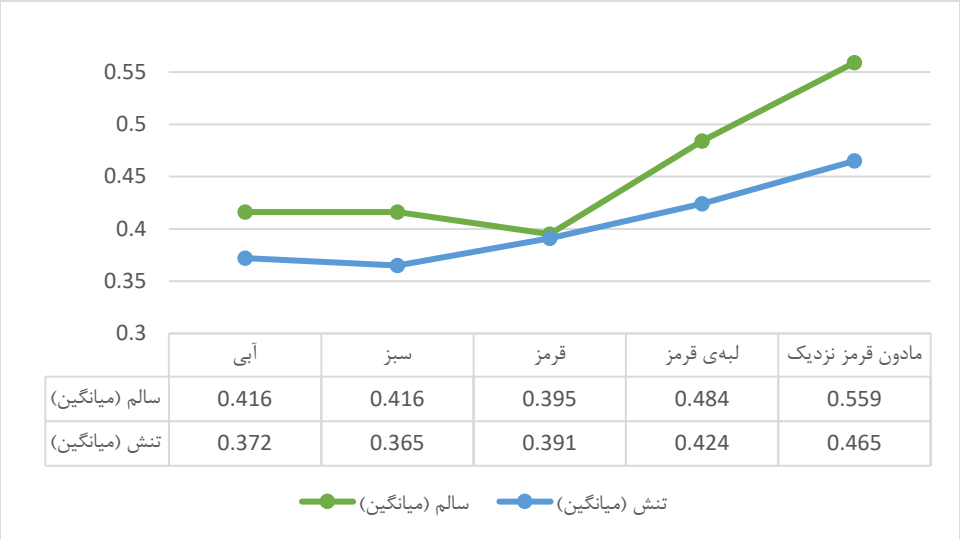
۳-۲- بررسی مقادیر داده‌های طیفی نمونه‌ها

بررسی مقادیر میانگین داده‌های طیفی نمونه‌ها (پس از نرمال‌سازی مقادیر در بازه صفر تا یک) نشان داد که بازتاب برگ‌های سالم در باندهای سبز، آبی، مادون قرمز نزدیک (NIR)[1] و لبه قرمز (Red Edge)[2] بیشتر از برگ‌های دارای تنش است، در حالی که در باند قرمز تفاوت قابل توجهی مشاهده نشد که می‌تواند ناشی از جذب بالای نور توسط گیاهان سالم و ناسالم باشد.

[1] Near-Infrared
[2] Red Edge

نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

علاوه بر این، در باندهای مادون قرمز نزدیک و لبه قرمز اختلاف بازتاب بین نمونه‌های سالم و تنش‌دار بیشتر بود، که نشان‌دهنده ساختار داخلی برگ‌های سالم و بازتاب بالاتر آن‌ها در این باندهاست. در این مطالعه، باند NIR بیشترین اختلاف را بین نمونه‌های سالم و تنش‌دار نشان داد، که می‌تواند با تفاوت در ساختار داخلی و ویژگی‌های بافتی برگ‌ها مرتبط باشد. این اطلاعات در شکل ۸ آورده شده است.



	آبی	سبز	قرمز	لبه‌ی قرمز	مادون قرمز نزدیک
سالم (میانگین)	0.416	0.416	0.395	0.484	0.559
تنش (میانگین)	0.372	0.365	0.391	0.424	0.465

شکل ۸. میزان میانگین نرمالایز شده هر باند پیکسل‌های برچسب گذاری شده

مقاله
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

۳-۳- سناریوهای طراحی‌شده برای ارزیابی مدل‌ها

به منظور ارزیابی عملکرد مدل‌های مختلف و بررسی تأثیر نوع داده‌های ورودی بر دقت نتایج، سه سناریوی آموزشی طراحی شد:

- سناریو ۱: عملکرد الگوریتم‌های مختلف یادگیری ماشین با استفاده از باندهای طیفی خام و شاخص‌های گیاهی اولیه به‌عنوان مبنای ارزیابی بررسی شد.
- سناریو ۲: بهینه‌سازی نمایش ویژگی‌ها و تنظیم مدل‌ها، محاسبه و تحلیل مجموعه گسترده‌تری از شاخص‌های گیاهی، بررسی افزونگی و همبستگی ویژگی‌ها، رتبه‌بندی و انتخاب ویژگی‌ها بر اساس تحلیل SHAP و مقایسه مجموعه‌های مختلف ورودی در کنار تنظیم ابرپارامترها انجام گرفت.
- سناریو ۳: بررسی ظرفیت روش‌های ترکیبی در ارتقای عملکرد طبقه‌بندی و دستیابی به توازن مناسب میان کیفیت پیش‌بینی و هزینه محاسباتی، ترکیب‌های مختلف Soft Voting و Stacking ارزیابی شدند. بنابراین، این سه سناریو جنبه‌های مکمل و مراحل با پیچیدگی روش‌شناختی فزاینده را در توسعه و ارزیابی چارچوب پیشنهادی پوشش می‌دهند.

تقسیم داده‌ها، پیش‌پردازش و روش اعتبارسنجی

در این پژوهش، واحد تحلیل و پیش‌بینی نمونه‌های پیکسلی بود؛ با این حال، به‌منظور کنترل وابستگی مکانی میان پیکسل‌های متعلق به یک درخت، واحد تقسیم‌بندی داده‌ها در فرآیند اعتبارسنجی، شناسه درخت (tree_id) در نظر گرفته شد. به این ترتیب، تمامی نمونه‌های پیکسلی متعلق به هر درخت در یک گروه قرار گرفتند و از حضور هم‌زمان نمونه‌های یک درخت در مجموعه‌های آموزش و ارزیابی هر Fold جلوگیری شد. در سناریوهای اول و دوم، اعتبارسنجی بر اساس گروه‌بندی درخت‌ها انجام شد. در سناریوی سوم نیز ابتدا درخت‌ها به دو مجموعه Dev و Hold-out تقسیم شدند و سپس اعتبارسنجی متقاطع گروهی تودرتو بر روی مجموعه Dev اجرا گردید.

در سناریوی اول، از روش ۵-Fold Group Cross-Validation با استفاده از شناسه درخت (tree_id) به‌عنوان متغیر گروه‌بندی استفاده شد. در این روش، تمام نمونه‌های پیکسلی متعلق به هر درخت به‌عنوان یک گروه در نظر گرفته شدند؛ به‌گونه‌ای که نمونه‌های مربوط به یک درخت به‌طور هم‌زمان در مجموعه‌های آموزش و ارزیابی یک Fold قرار نگرفتند. در هر تکرار، چهار Fold برای آموزش مدل و Fold باقی‌مانده برای ارزیابی آن استفاده شد. این فرآیند در پنج تکرار انجام گرفت و عملکرد هر مدل بر اساس میانگین و انحراف معیار معیارهای ارزیابی حاصل از پنج Fold گزارش گردید.

در سناریوی دوم، به‌منظور تنظیم ابرپارامترها و ارزیابی عملکرد مدل‌ها، از روش Nested Group Cross-Validation استفاده شد. در این روش، پنج Fold بیرونی برای ارزیابی عملکرد مدل‌ها و سه Fold داخلی برای تنظیم ابرپارامترها با استفاده از Grid Search در نظر گرفته شد. در هر تکرار، تقسیم‌بندی در هر دو سطح بیرونی و داخلی بر اساس شناسه درخت (tree_id) انجام شد؛ بنابراین، نمونه‌های متعلق به یک درخت در Foldهای آموزش و ارزیابی یک مرحله مشترک قرار نگرفتند. داده‌های Fold بیرونی صرفاً برای ارزیابی مدل بهینه‌شده استفاده شدند و در فرآیند تنظیم ابرپارامترها دخالت نداشتند. محدوده ابرپارامترهای مورد بررسی و معیار انتخاب بهترین ترکیب پارامترها در بخش مربوط به سناریوی دوم و جدول ۱۰ ارائه شده است.

در سناریوی سوم، به‌منظور جلوگیری از دخالت مجموعه آزمون نهایی در فرآیند انتخاب ترکیب Ensemble، شناسه‌های یکتای ۲۰ درخت موجود به‌صورت تصادفی و با استفاده از مقدار ثابت random_state=۴۲ به دو مجموعه Dev و Hold-out تقسیم شدند. در این تقسیم‌بندی، ۱۶ درخت (۸۰ درصد شناسه‌های درخت) به مجموعه Dev و چهار درخت باقی‌مانده (۲۰ درصد شناسه‌های درخت) به مجموعه Hold-out اختصاص یافتند. با توجه به تعداد نمونه‌های متعلق به هر درخت، تعداد نمونه‌های پیکسلی این دو مجموعه به‌ترتیب برابر با ۱۴۹۸۰ و ۱۰۲۰ بود. بنابراین، نسبت تعداد نمونه‌های پیکسلی در دو مجموعه الزاماً معادل نسبت تقسیم شناسه‌های درخت نبود. از آنجا که تقسیم‌بندی بر اساس شناسه درخت انجام شد، تمامی نمونه‌های پیکسلی متعلق به هر درخت صرفاً در یکی از این دو مجموعه قرار گرفتند و هیچ‌یک از درخت‌های مجموعه Hold-out در مجموعه Dev حضور نداشتند. مجموعه Hold-out در تمام مراحل تنظیم ابرپارامترها، ارزیابی ترکیب‌ها، مقایسه عملکرد و انتخاب ترکیب نهایی کنار گذاشته شد و تنها پس از تکمیل این مراحل برای ارزیابی نهایی مدل منتخب مورد استفاده قرار گرفت.

بر روی مجموعه Dev، برای هر یک از ۲۰ ترکیب Ensemble، روش Nested Group Cross-Validation شامل پنج Fold بیرونی و سه Fold داخلی اجرا شد. در هر Fold بیرونی، داده‌های آموزشی با استفاده از شناسه درخت به سه Fold داخلی تقسیم شدند و Grid Search بر اساس معیار F۱-macro انجام گرفت. سپس مدل بهینه‌شده روی Fold بیرونی ارزیابی شد و عملکرد آن با استفاده از معیارهای F۱-macro، Accuracy، Balanced Accuracy، Kappa و ROC-AUC ثبت گردید. در نهایت، میانگین و انحراف معیار F۱-macro حاصل از پنج Fold بیرونی برای هر ترکیب محاسبه شد و ترکیبی که بالاترین

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

میانگین F۱–macro را داشت، به‌عنوان ترکیب منتخب در نظر گرفته شد. پس از انتخاب ترکیب نهایی، مدل با استفاده از کل مجموعه Dev و تنظیم ابرپارامترها از طریق اعتبارسنجی گروهی سه Fold آموزش داده شد و در نهایت، عملکرد آن یک‌بار روی مجموعه Hold–out ارزیابی گردید.همچنین، عملیات پیش‌پردازش و تبدیل ویژگی‌ها در قالب Pipeline انجام شد تا مراحل استانداردسازی و سایر تبدیل‌های مورد استفاده، در هر Fold تنها با استفاده از داده‌های آموزشی همان Fold برازش شوند. به‌منظور حفظ استقلال مجموعه آزمون نهایی، چهار درخت اختصاص‌یافته به مجموعه Hold–out در هیچ‌یک از مراحل انتخاب ویژگی‌ها، شامل محاسبه همبستگی میان شاخص‌های گیاهی، تعیین هفت شاخص منتخب و تحلیل اهمیت ویژگی‌ها با استفاده از SHAP، دخالت داده نشدند. این مراحل صرفاً با استفاده از داده‌های مجموعه Dev انجام گرفتند. در نتیجه، اطلاعات مربوط به چهار درخت مجموعه Hold–out در فرآیند انتخاب ویژگی‌ها، تنظیم ابرپارامترها و انتخاب مدل نهایی مورد استفاده قرار نگرفت و این مجموعه تنها پس از تکمیل مراحل مذکور برای ارزیابی نهایی مدل منتخب به کار گرفته شد.

به‌منظور یکسان‌سازی مقیاس ویژگی‌های ورودی و جلوگیری از تأثیر تفاوت دامنه مقادیر بر عملکرد الگوریتم‌های حساس به مقیاس، از استانداردسازی Z–score با استفاده از StandardScaler استفاده شد. در این روش، مقدار هر ویژگی با کم کردن میانگین آن ویژگی و تقسیم نتیجه بر انحراف معیار همان ویژگی استانداردسازی شد. این عملیات در داخل Pipeline قرار گرفت؛ بنابراین، میانگین و انحراف معیار هر ویژگی در هر Fold صرفاً از داده‌های آموزشی همان Fold محاسبه و سپس برای تبدیل داده‌های ارزیابی همان Fold به کار گرفته شد. این فرآیند به‌ویژه برای الگوریتم‌هایی مانند ماشین بردار پشتیبان، K–نزدیک‌ترین همسایه، رگرسیون لجستیک و پرسپترون چندلایه اهمیت دارد.

محیط سخت‌افزاری اجرای آزمایش‌ها

آزمایش‌های محاسباتی این پژوهش بر روی سامانه‌ای مجهز به پردازنده Intel Core i۵–۱۰۲۱۰U با فرکانس ۱.٦۰ GHz، حافظه RAM برابر با ٤ GB و کارت گرافیک NVIDIA GeForce MX۱۳۰ با حافظه ۲ GB انجام شد. آموزش و ارزیابی مدل‌های یادگیری ماشین با استفاده از پردازنده مرکزی (CPU) و پردازش موازی انجام گرفت و کارت گرافیک در فرایند آموزش مدل‌های مورد استفاده در این پژوهش به‌کار گرفته نشد. زمان‌های محاسباتی گزارش‌شده در این پژوهش مربوط به اجرای مدل‌ها در همین محیط سخت‌افزاری است.

۳–۳–۱– سناریو ۱ : ارزیابی مدل‌ها با استفاده از باندهای طیفی خام و شاخص‌های گیاهی اولیه

در سناریو ۱ از شاخص‌های گیاهی مختلف برای ارزیابی سلامت و تراکم پوشش گیاهی استفاده شد، از جمله:

- NDVI[1]: شاخص نرمال‌شده پوشش گیاهی که تراکم و سلامت گیاهان را نشان می‌دهد.
- MCARI1[2]: شاخص جذب کلروفیل اصلاح‌شده، برای برآورد میزان کلروفیل برگ و حساس به ساختار برگ.
- SIPI[3]: شاخص رنگدانه‌ای بدون حساسیت به ساختار برگ، برای ارزیابی نسبت کاروتنوئید به کلروفیل.

[1] Normalized Difference Vegetation Index
[2] Modified Chlorophyll Absorption in Reflectance Index 1
[3] Structure Insensitive Pigment Index

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

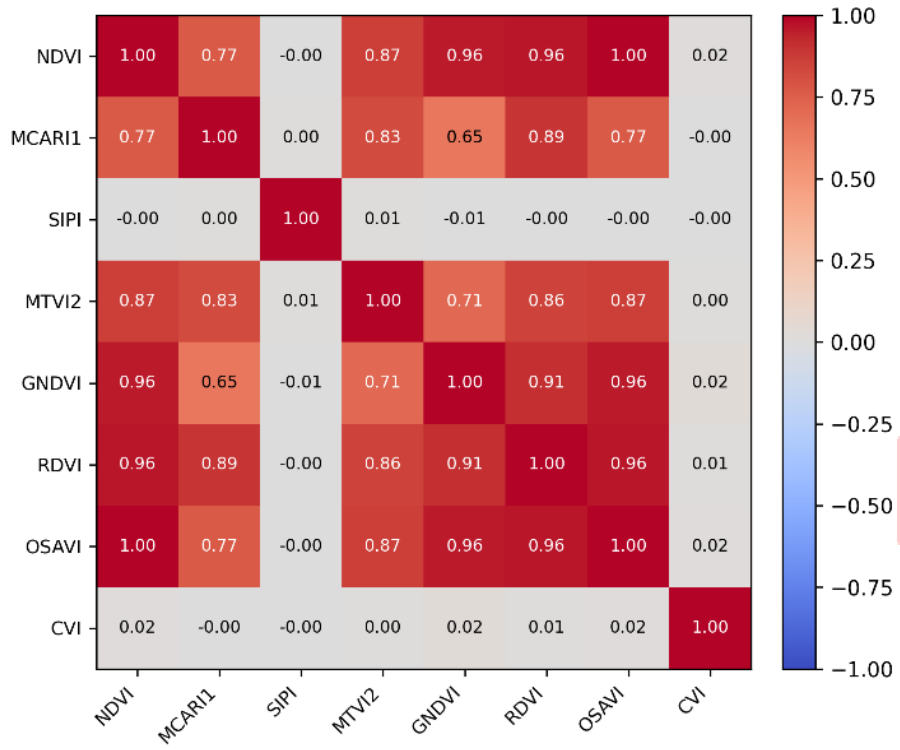
- MTVI2[1]: شاخص مثلثی اصلاح‌شده که تغییرات کلروفیل در تراکم بالا را بهتر منعکس می‌کند.
- GNDVI[2]: نسخه سبز NDVI با حساسیت بالاتر به میزان کلروفیل.
- RDVI[3]: شاخص پوشش گیاهی نرمال‌شده با کاهش نویز زمین، مناسب برای مناطق با پوشش گیاهی کم تا متوسط.
- OSAVI[4]: شاخص اصلاح‌شده برای تأثیر خاک، مناسب برای مناطق با پوشش گیاهی کم.
- CVI[5]: شاخص ترکیبی که مقدار کلروفیل و تراکم گیاه را به‌صورت همزمان نشان می‌دهد.

فرمول‌های شاخص‌های مذکور به همراه روابط در جدول ۱ ارائه شده است. همچنین، ماتریس همبستگی بین شاخص‌های گیاهی برای بررسی میزان وابستگی و تکرار اطلاعات میان متغیرها ارائه شد. همان‌طور که در شکل ۹ مشاهده می‌شود، برخی از شاخص‌های طیفی دارای همبستگی بالایی با یکدیگر هستند که نشان‌دهنده وجود اطلاعات مشترک و تداخل طیفی میان آن‌ها است. این همبستگی بالا می‌تواند باعث افزونگی داده‌ها در فرآیند آموزش مدل شود و ضرورت انتخاب شاخص‌های مستقل‌تر و با همبستگی پایین‌تر را برجسته می‌سازد.

جدول ۱. مشخصات شاخص‌های گیاهی مورد استفاده برای آموزش مدل‌های یادگیری ماشین

شماره	شاخص	روابط	منابع
۱	NDVI	(NIR - Red) / (NIR + Red)	Rouse Jr et al. (1973)
۲	MCARI1	1.2[2.5*(NIR - Red) – 1.3 * (NIR - Green)]	Haboudane et al. (2004)
۳	SIPI	(NIR - Blue) / (NIR - Red)	Pen Uelas et al. (1995)
٤	MTVI2	$(1.5 \times [1.2 \times (NIR - Green) - 2.5 \times (Red - Green)]) / \sqrt{((2 \times NIR + 1)^2 - (6 \times NIR - 5 \times \sqrt{Red}) - 0.5)}$	Haboudane et al. (2004)
٥	GNDVI	(NIR - Green) / (NIR + Green)	Gitelson et al. (1996)
٦	RDVI	(NIR - Red) / √(NIR + Red)	Roujean and Breon (1995)
۷	OSAVI	(1 + 0.16) * (NIR - Red) / (NIR + Red + 0.16)	Rondeaux et al., (1996)
۸	CVI	(NIR*Red) / $Green^2$	Hare & Walthall, (1998)

[1] Modified Triangular Vegetation Index 2
[2] Green Normalized Difference Vegetation Index
[3] Renormalized Difference Vegetation Index
[4] Optimized Soil-Adjusted Vegetation Index
[5] Chlorophyll Vegetation Index



شکل ۹. میزان همبستگی شاخص‌های مختلف گیاهی بدست آمده از باندهای مختلف پیکسل‌های برچسب‌گذاری شده در سناریو اول

برای آموزش مدل‌ها، از زبان برنامه‌نویسی پایتون در محیط Jupyter Notebook استفاده شد. مقادیر و شاخص‌های برچسب‌گذاری شده با مدل‌های مختلف آموزش داده شدند. در سناریو ۱، به منظور بررسی و مقایسه عملکرد مدل‌ها، از چندین الگوریتم پایه و پیشرفته استفاده شد که مشخصات آن‌ها در جدول ۲ ارائه شده است. همچنین هایپرپارامترهای هر مدل در جدول ۳ گزارش شد. روال پیشنهادی در این سناریو شامل بخش‌های اصلی از ورودی، پیش‌پردازش، استخراج ویژگی‌ها، آموزش مدل، ارزیابی و خروجی می‌باشد. شبه کد سناریو ۱ که در الگوریتم ۱ نشان داده شده است شامل مدل‌های یادگیری ماشین با استفاده از باندهای خام و شاخص‌های گیاهی اولیه آموزش داده شدند و مراحل از بارگذاری داده‌ها، تولید عکس‌نقشه، استخراج نمونه‌ها، محاسبه ویژگی‌ها، آموزش مدل و ارزیابی آن تا تولید خروجی دنبال شده است.

جدول ۲. مشخصات مدل‌های یادگیری ماشین جهت آموزش داده‌ها

شماره	نام الگوریتم	مرجع	سال (میلادی)
۱	جنگل تصادفی	Breiman, L.	۲۰۰۱
۲	درخت تصمیم	Breiman, L., et al.	۱۹۸۶
۳	XGBoost	Chen, T., & Guestrin, C.	۲۰۱۶
٤	پرسپترون چند لایه	Rosenblatt, F.	۱۹۵۸
٥	ماشین بردار پشتیبان	Cortes, C., & Vapnik, V.	۱۹۹۵

مقاله
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

۶	AdaBoost	Freund, Y., & Schapire, R. E.	۱۹۹۶
۷	K- نزدیکترین همسایه	Cover, T., & Hart, P.	۱۹۶۷
۸	بیز ساده	John, G. H., & Langley, P.	۱۹۹۵
۹	رگرسیون لجستیک	Cox, D. R.	۱۹۵۸
۱۰	Gradient Boosting	Friedman, J. H.	۱۹۹۹

جدول ۳. هایپر پارامترهای مدل‌های اموزش داده شده در سناریوی اول

مدل	هایپرپارامترها
جنگل تصادفی	random_state=42, n_jobs=-1, n_estimators=100, max_depth=None, min_samples_split=2, min_samples_leaf=1, max_features='sqrt', criterion='gini', bootstrap=True
درخت تصمیم	random_state=42,criterion='gini', max_depth=None, min_samples_split=2, min_samples_leaf=1, ccp_alpha=0.0
XGBoost	eval_metric='logloss', use_label_encoder=False, random_state=42, n_jobs=-1, n_estimators=100, max_depth=6, learning_rate=0.3, subsample=1.0, colsample_bytree=1.0, reg_lambda=1.0, reg_alpha=0.0
پرسپترون چند لایه	max_iter=1000, random_state=42, hidden_layer_sizes=(100,), activation='relu', solver='adam', alpha=0.0001, learning_rate_init=0.001, batch_size='auto'
ماشین بردار پشتیبان	random_state=42, probability=True, C=1.0, kernel='rbf', gamma='scale', tol=1e-3
AdaBoost	random_state=42, n_estimators=50, learning_rate=1.0, algorithm='SAMME.R'
K-نزدیکترین همسایه	n_neighbors=5, weights='uniform', metric='minkowski', p=2
بیز ساده	GaussianNB با var_smoothing=1e-9
رگرسیون لجستیک	max_iter=1000, random_state=42, C=1.0, penalty='l2', solver='lbfgs', tol=1e-4
Gradient Boosting	random_state=42, n_estimators=100, learning_rate=0.1, max_depth=3, subsample=1.0, min_samples_split=2, min_samples_leaf=1

الگوریتم ۱: آموزش مدل با ویژگی‌های اولیه

ورودی: تصاویر چندطیفی، برچسب‌ها

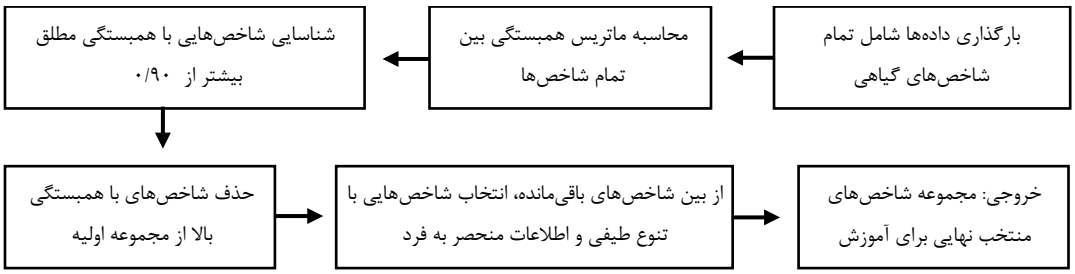
خروجی: مدل آموزش‌دیده، دقت

۱.بارگذاری تصاویر چندطیفی و برچسب‌ها
۲.تولید عکس‌نقشه از تصاویر
۳.استخراج نمونه‌ها (پیکسل‌ها یا نواحی) و برچسب‌گذاری
٤.محاسبه شاخص‌های گیاهی اولیه NDVI، GNDVI، OSAVI و...
۵.ایجاد مجموعه ویژگی‌ها شامل باندهای خام و شاخص‌ها
٦.ایجاد تقسیم‌بندی ۵-Fold Group Cross-Validation با استفاده از شناسه درخت (tree_id) به‌عنوان متغیر گروه‌بندی، به‌گونه‌ای که نمونه‌های متعلق به هر درخت صرفاً در یکی از مجموعه‌های آموزش یا ارزیابی هر Fold قرار گیرند.
۷.انتخاب الگوریتم یادگیری ماشین (درخت تصمیم، جنگل تصادفی و غیره)
۸.آموزش مدل در هر Fold با استفاده از داده‌های آموزشی همان Fold
۹.ارزیابی مدل روی Fold ارزیابی
۱۰.محاسبه میانگین معیارهای عملکرد در پنج Fold
۱۱. بازگرداندن مدل و معیارهای عملکرد

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

۳-۲-۲- سناریو ۲ : بهینه‌سازی مجموعه ویژگی‌ها و تنظیم مدل‌های یادگیری ماشین

در سناریوی دوم، به‌منظور بررسی تأثیر ساختار مجموعه ویژگی‌ها بر عملکرد مدل‌های طبقه‌بندی، ابتدا شاخص‌های گیاهی متعددی از پنج باند طیفی اصلی شامل آبی، سبز، قرمز، لبه قرمز و مادون قرمز نزدیک محاسبه شدند. سپس با استفاده از تحلیل همبستگی و فرآیند انتخاب ویژگی، هفت شاخص گیاهی منتخب تعیین شدند. در ادامه، عملکرد مدل‌ها در سه ساختار ورودی مستقل شامل مجموعه شاخص‌های گیاهی منتخب (indices_only)، مجموعه پنج باند طیفی خام (bands_only) و مجموعه ترکیبی شامل باندهای خام و شاخص‌های منتخب (combined) ارزیابی شد. بدین ترتیب، امکان مقایسه عملکرد اطلاعات حاصل از شاخص‌های گیاهی، باندهای اولیه و ترکیب این دو نوع ویژگی فراهم گردید. مراحل این فرآیند در شکل ۱۰ قابل مشاهده است.

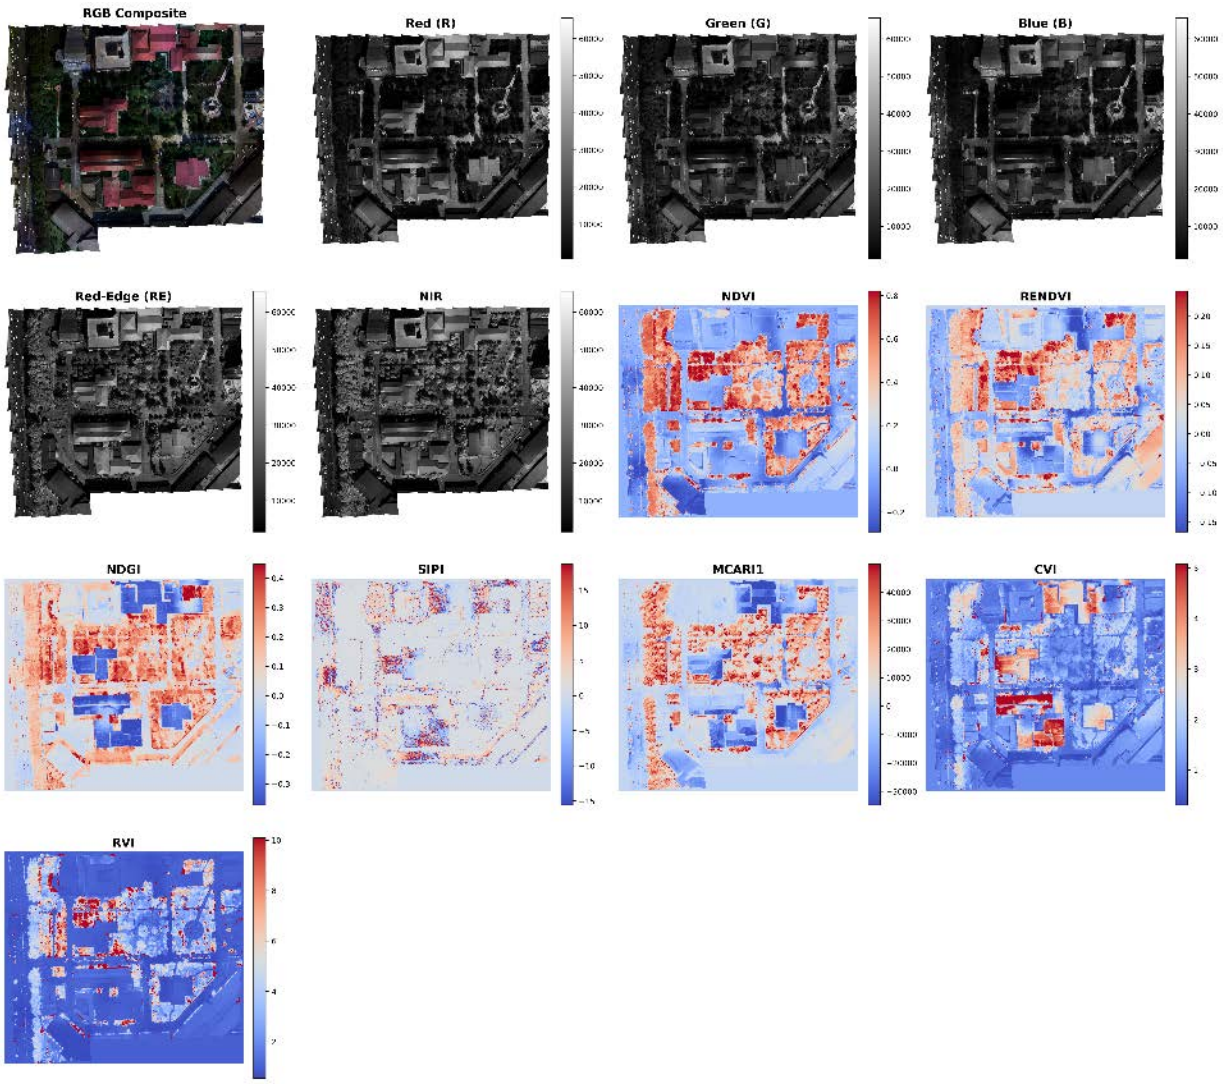


شکل ۱۰. بلوک دیاگرام مراحل انتخاب شاخص‌های گیاهی موثر با همبستگی پایین

در سناریو دوم ابتدا از ۱٤ شاخص طیفی برای ارزیابی پوشش گیاهی استفاده شد. شاخص‌ها و کاربردهای آن‌ها عبارتند از: NDVI برای تشخیص سلامت گیاه و پوشش سبز (Rouse Jr et al. 1973) ، MCARI1 برای کاهش اثرات خاک و برآورد حجم توده گیاهی (Haboudane et al., 2004)، و SIPI برای ارزیابی نسبت کلروفیل به کاروتنوئیدها به کار گرفته شد (Peñuelas et al., 1995)، به منظور بهبود حساسیت به پوشش سبز، GNDVI به کار رفت(Gitelson et al., 1996) ، RDVI برای افزایش دقت در مناطق با پوشش گیاهی کم (Roujean & Breon, 1995)، OSAVI برای کاهش تأثیر خاک (Rondeaux et al., 1996)، CVI برای برآورد ترکیبات زیستی گیاه (Hare & Walthall, 1998)، IPVI برای محاسبه نسبت گیاه به خاک، DVI و GDVI برای مقایسه تفاوت‌های طیفی مادون قرمز نزدیک با قرمز یا سبز، NDGI برای تمایز پوشش سبز، RVI و SR برای نسبت‌بندی ساده باندهای مادون قرمز نزدیک و قرمز، و در نهایت RENDVI برای تشخیص بهتر ویژگی‌های برگ و سلامت گیاه (Haboudane et al., 2004). این شاخص‌ها به عنوان ورودی‌های اصلی تحلیل طیفی و ارزیابی سلامت پوشش گیاهی مورد استفاده قرار گرفتند.

در این سناریو، هدف کاهش همبستگی بین شاخص‌های گیاهی و شناسایی مجموعه‌ای از ویژگی‌های مؤثر و غیرتکراری برای آموزش مدل‌ها بود. برای این منظور، پس از فرآیند انتخاب ویژگی‌ها تنها شاخص‌های NDVI، RENDVI، NDGI، SIPI، MCARI۱، CVI و RVI به‌عنوان ویژگی‌های مؤثر و غیرتکراری برای آموزش مدل‌ها انتخاب شدند. باندهای رنگی و شاخص‌های منتخب در شکل ۱۱ نشان داده شده‌اند.

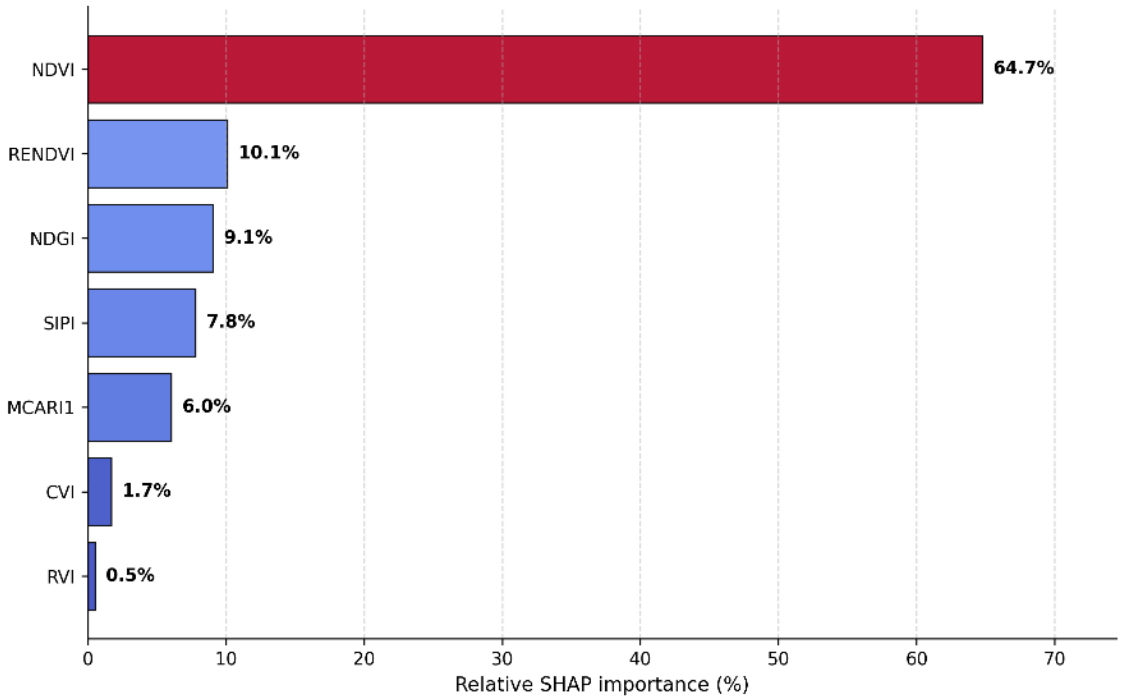
مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی(سپهر)»



شکل ۱۱. باندهای رنگی و شاخص‌های منتخب محاسبه شده

برای بررسی تفسیرپذیری ویژگی‌های منتخب، از تحلیل SHAP (SHapley Additive exPlanations) مبتنی بر TreeExplainer در مدل‌های درخت تصادفی و XGBoost استفاده شد. این تحلیل سهم هر شاخص را در پیش‌بینی مدل به‌صورت مقدار SHAP میانگین قدرمطلق (mean |SHAP|) مشخص می‌کند. نتایج این تحلیل برای هفت شاخص منتخب (NDVI، RENDVI، NDGI، SIPI، MCARI۱، CVI و RVI) در شکل ۱۲ نمایش داده شده است.

« اطلاعات جهرافیایی (سپهر) »



شکل ۱۲. اهمیت نسبی شاخص‌های منتخب بر اساس تحلیل SHAP (سناریو ۲)

همان‌طور که در شکل ۱۲ مشاهده می‌شود، توزیع اهمیت SHAP به‌صورت نامتقارن و متمرکز است: NDVI به‌تنهایی حدود ۶۵٪ از اهمیت کل را به خود اختصاص داده. چهار شاخص اول به‌تنهایی ۹۱.۷٪ از اهمیت تجمعی را پوشش می‌دهند که نشان‌دهنده‌ی تمرکز اطلاعات تشخیصی در ترکیب باندهای قرمز، مادون‌قرمز نزدیک، red-edge و سبز است.

اهمیت بالای NDVI را می‌توان با حساسیت آن به تفاوت بازتابش در ناحیه‌ی قرمز و مادون‌قرمز نزدیک مرتبط دانست. ناحیه‌ی قرمز تحت تأثیر جذب رنگیزه‌های فتوسنتزی، به‌ویژه کلروفیل، قرار دارد، در حالی که بازتابش در ناحیه‌ی مادون‌قرمز نزدیک با ویژگی‌های ساختاری و بافت داخلی برگ ارتباط دارد. از این‌رو، تغییرات ناشی از تنش در وضعیت رنگیزه‌ها و ویژگی‌های ساختاری برگ می‌تواند الگوی بازتابش این دو ناحیه را تغییر داده و در نتیجه مقدار NDVI را تحت تأثیر قرار دهد. با این حال، NDVI در سطوح بالای سبزینگی و در شرایط تنش‌های شدید دچار اشباع می‌شود و همین محدودیت، حضور شاخص‌های تکمیلی را در مجموعه‌ی منتخب ضروری می‌سازد.

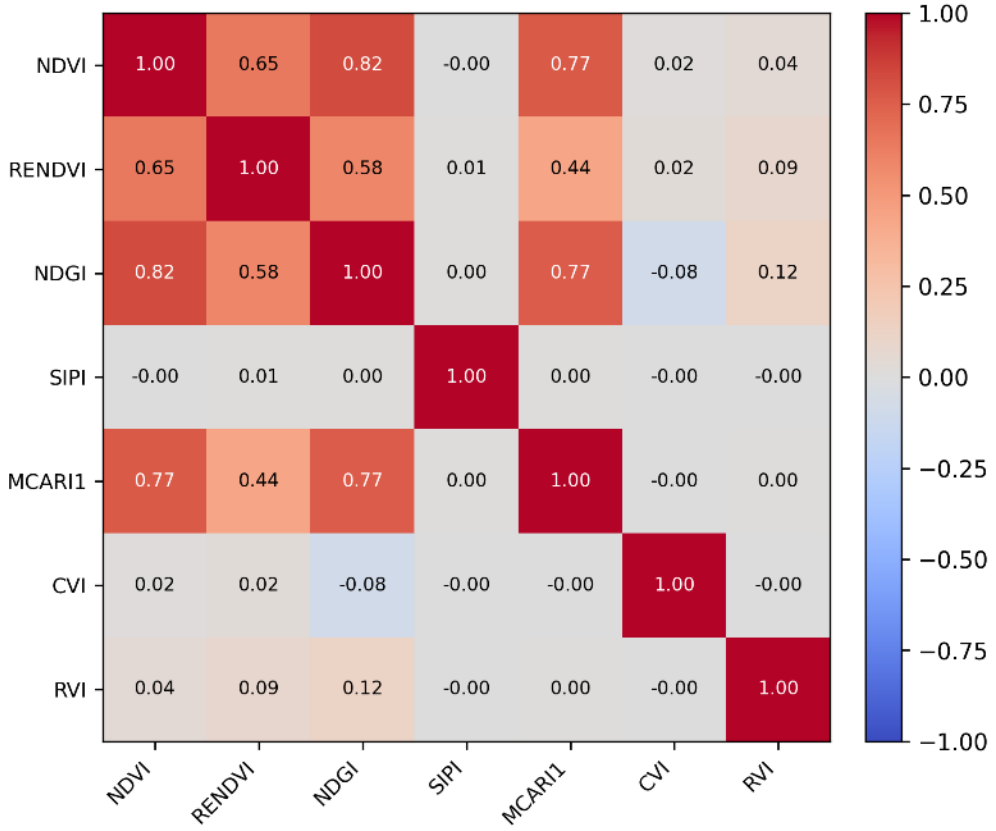
حضور RENDVI در رتبه‌ی دوم (۱۰.۱٪) را می‌توان به حساسیت این شاخص به ناحیه‌ی red-edge (حدود ۷۰۰–۷۴۰ نانومتر) نسبت داد که به‌عنوان ناحیه‌ی انتقالی بین جذب کلروفیل و پراکندگی مزوفیل شناخته می‌شود. برخلاف NDVI، RENDVI در سطوح بالای شاخص سطح برگ و کلروفیل دیرتر اشباع می‌شود و بنابراین در تشخیص تنش‌های خفیف و مراحل اولیه‌ی تنش، اطلاعات مکملی فراهم می‌کند. اهمیت بالای RENDVI نشان می‌دهد که بخش قابل‌توجهی از سیگنال تشخیصی مدل، مستقل از NDVI و از ناحیه‌ی red-edge تأمین می‌شود.

از این منظر، نتایج SHAP نشان می‌دهد که مزیت اصلی استفاده از داده‌های چندطیفی در این مطالعه، فراهم‌کردن اطلاعات طیفی متنوع برای استخراج ویژگی‌هایی است که نسبت به تغییرات قابل مشاهده در وضعیت برگ حساس هستند. قرار گرفتن NDVI، RENDVI، NDGI و SIPI در میان مهم‌ترین ویژگی‌ها، این موضوع را تقویت می‌کند که اطلاعات حاصل از ترکیب باندهای

مختلف طیفی (قرمز، مادون‌قرمز نزدیک، red-edge، سبز و آبی) می‌توانند در تفکیک نمونه‌های سالم و تنش‌دار نقش مؤثری داشته باشند. توزیع نامتقارن اهمیت SHAP نیز نشان می‌دهد که اطلاعات تشخیصی عمدتاً در باندهای قرمز و مادون‌قرمز نزدیک متمرکز است، اما شاخص‌های مکمل (RENDVI، NDGI، SIPI و MCARI۱) بخش قابل‌توجهی از سیگنال مکمل را تأمین می‌کنند که صرفاً با NDVI قابل استخراج نیست. با این حال، از آنجا که هدف مطالعه شناسایی عمومی وضعیت سالم و تنش‌دار بوده است، این الگو به نوع یا عامل مشخصی از تنش (خشکی، شوری، بیماری یا آفت) نسبت داده نمی‌شود و تفسیر آن باید در چارچوب عمومی تنش گیاهی صورت گیرد.

در ادامه، میزان همبستگی با استفاده از شاخص جدید محاسبه شد که نتایج آن در شکل ۱۳ ارائه شده است. پس از انتخاب شاخص‌های مناسب، داده‌های آموزشی با استفاده از مدل‌های پایه شامل جنگل تصادفی[1]، XGBoost، ماشین بردار پشتیبان، رگرسیون لجستیک[2] ودرخت تصمیم[3] آموزش داده شدند.

مقاله در نوبت انتشار



شکل ۱۳. میزان همبستگی شاخص‌های مختلف گیاهی در سناریو دوم

[1] Random Forest
[2] Logistic Regression
[3] Decision Tree

همچنین، در سناریوی دوم، به‌منظور تنظیم ابرپارامترهای مدل‌ها، در هر Fold بیرونی از Grid Search در Fold های داخلی استفاده شد. محدوده جست‌وجوی ابرپارامترها برای هر الگوریتم از پیش تعیین شد و بهترین ترکیب پارامترها بر اساس مقدار F۱ انتخاب گردید. جزئیات ابرپارامترهای بررسی‌شده برای هر یک از مدل‌های مورد استفاده در جدول ٤ ارائه شده است.

جدول ٤. هایپر پارامترهای مدل های اموزش داده شده در سناریوی دوم

مدل	هایپرپارامتر	مقادیر
XGBoost	n_estimators	٤٠٠، ٦٠٠
	max_depth	٤، ٦، ٨
	learning_rate	٠/٠٥، ١
	subsample	٠/٨١، ١
	colsample_bytree	٠/٨، ١
	reg_lambda	١، ٥
جنگل تصادفی	n_estimators	٣٠٠، ٥٠٠
	max_depth	١٠، ٢٠، None
	min_samples_leaf	١، ٣، ٥
دسته‌بند بردار پشتیبان	C	٠/٥، ١، ٢
	kernel	linear، rbf
	gamma	auto، scale
رگرسیون لجستیک	C	٠/٥، ١، ٢
	penalty	١٢
درخت تصمیم	max_depth	٦، ٨، ١٠، ١٢، None
	min_samples_leaf	١، ٣، ٥، ١٠
	min_samples_split	٢، ٥، ١٠
	ccp_alpha	٠/٠، ٠/٠٠٠٥، ٠/٠٠١، ٠/٠٠٥

در شبه کد سناریو ۲، که در الگوریتم ۲ ارائه شده است، مجموعه ویژگی‌ها با کاهش همبستگی بهینه شد و مدل‌ها با این مجموعه بهینه آموزش داده شدند تا دقت و پایداری پیش‌بینی افزایش یابد.

الگوریتم ۲: آموزش مدل با ویژگی‌های بهینه

ورودی: مجموعه ویژگی‌ها، برچسب‌ها

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

خروجی: مدل آموزش‌دیده، دقت و پایداری

۱. دریافت مجموعه ویژگی‌های اولیه از سناریو ۱
۲. تحلیل همبستگی بین ویژگی‌ها
۳. حذف ویژگی‌های با همبستگی بالا
٤. تشکیل مجموعه ویژگی بهینه با همبستگی پایین
٥. ایجاد Nested Group Cross-Validation شامل پنج Fold بیرونی و سه Fold داخلی، با گروه‌بندی بر اساس شناسه درخت (tree_id).
٦. تنظیم ابرپارامترهای مدل با استفاده از Grid Search در Foldهای داخلی
۷. آموزش مدل بهینه با داده‌های آموزشی هر Fold بیرونی
۸. ارزیابی مدل بهینه روی داده‌های ارزیابی Fold بیرونی
۹. محاسبه معیارهای عملکرد و تجمیع نتایج Foldهای بیرونی
۱۰. بازگرداندن مدل آموزش‌دیده بهینه و معیارها

۲-۲-۳- سناریو سوم: ترکیب مدل‌ها برای بهبود دقت

در سناریوی ۳، به‌منظور بررسی امکان بهبود عملکرد از طریق ترکیب مدل‌ها، از دو روش Voting و Stacking استفاده شد. پنج مدل پایه شامل ماشین بردار پشتیبان، XGBoost، جنگل تصادفی، رگرسیون لجستیک و درخت تصمیم در نظر گرفته شدند و ترکیب‌های مختلفی از آن‌ها مورد ارزیابی قرار گرفت.

در روش Stacking، پیش‌بینی‌های مدل‌های پایه با استفاده از سازوکار اعتبارسنجی متقاطع داخلی به‌صورت Out-of-Fold تولید و برای آموزش Meta-learner از نوع رگرسیون لجستیک استفاده شدند.

در روش Soft Voting نیز احتمال‌های پیش‌بینی مدل‌های پایه با یکدیگر ترکیب و نتیجه نهایی بر اساس میانگین وزن‌دار احتمال‌ها تعیین شد.

در شبه‌کد سناریو ۳، ترکیب‌های مختلف مدل‌های پایه با استفاده از روش‌های Voting و Stacking ایجاد و و با استفاده از Nested Cross-Validation ارزیابی شدند. عملکرد ترکیب‌ها بر اساس معیارهای ارزیابی مقایسه و ترکیب منتخب بر مبنای میانگین F۱-macro حاصل از Foldهای بیرونی تعیین شد.

الگوریتم ۳: ترکیب مدل‌ها برای افزایش دقت

ورودی: مجموعه ویژگی‌های منتخب، برچسب‌ها و پنج مدل پایه
خروجی: نتایج ارزیابی ترکیب‌هایEnsembleو ترکیب منتخب و عملکرد نهایی آن

مقاله در نوبت انتشار
نسخه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

۱. شناسه‌های یکتای ۲۰ درخت موجود با استفاده از مقدار ثابت random_state=۴۲ به‌صورت تصادفی مرتب شده و بر اساس شناسه درخت به دو مجموعه Dev شامل ۱۶ درخت و Hold-out شامل چهار درخت تقسیم شدند. این تقسیم‌بندی در سطح درخت انجام شد و لایه‌بندی جداگانه‌ای بر اساس برچسب کلاس صورت نگرفت.

۲. کنار گذاشتن Hold-out Test از تمام مراحل تنظیم، مقایسه و انتخاب ترکیب‌ها.

۳. تعریف پنج مدل پایه شامل جنگل تصادفی، XGBoost، ماشین بردار پشتیبان، رگرسیون لجستیک و درخت تصمیم.

٤. تولید تمام ۱۰ ترکیب دوتایی برای Soft Voting.

۵. تولید تمام ۱۰ ترکیب سه‌تایی برای Stacking.

٦. ایجاد Nested Cross-Validation با ۵ Fold بیرونی و ۳ Fold داخلی روی بخش Dev.

۷. برای هر Fold بیرونی:

- تقسیم داده‌های آموزشی به سه Fold داخلی.
- اجرای Grid Search برای هر ترکیب بر اساس F۱.
- در Soft Voting، بررسی وزن‌های (۱،۱)، (۲،۱) و (۱،۲).
- در Stacking، بررسی مقادیر C برابر ۰/۱، ۱ و ۱۰ برای Meta-learner.
- تولید پیش‌بینی‌های Out-of-Fold مدل‌های پایه با CV داخلی سه‌Fold در Stacking.
- آموزش ترکیب بهینه روی داده‌های آموزشی Fold بیرونی.
- ارزیابی بر روی Fold بیرونی و ثبت معیارهای عملکرد و زمان محاسباتی.

۸. محاسبه میانگین و انحراف معیار F۱ در پنج Fold برای هر ترکیب.

۹. انتخاب ترکیبی که بالاترین میانگین F۱ را در بخش Dev کسب کرده است.

۱۰. آموزش مجدد ترکیب منتخب روی کل بخش Dev با Grid Search.

۱۱. ارزیابی نهایی ترکیب منتخب، بدون هیچ تنظیم مجدد، روی Hold-out Test.

۱۲. ثبت و گزارش معیارهای عملکرد نهایی.

٤- نتایج روش پیشنهادی و بحث

در این پژوهش، به منظور مقایسه عملکرد مدل‌ها در شرایط مختلف، سه سناریوی آموزشی پیاده‌سازی شد. در سناریوی اول، از داده‌های خام شامل باندهای اولیه و شاخص‌های گیاهی انتخاب‌شده به‌صورت تصادفی استفاده شد تا عملکرد پایه مدل‌ها ارزیابی گردد. سناریوی دوم شامل آموزش مدل‌ها با ویژگی‌هایی بود که همبستگی کمتری نسبت به هم داشتند (نسبت به سناریوی اول)، تا اثر حذف ویژگی‌های با همبستگی بالا بر بهبود دقت مشخص شود. در سناریوی سوم، مدل‌های منتخب با استفاده از روش‌های Stacking و Votingترکیب شدند تا امکان افزایش دقت و پایداری پیش‌بینی‌ها بررسی شود. نتایج سناریوهای مختلف به‌صورت منظم در متن زیر مورد تحلیل و ارزیابی عملکرد قرار گرفتند.

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

٤-١- بررسی نتایج سناریو اول

در این بخش، نتایج مدل‌های مختلف یادگیری ماشین برای تفکیک نمونه‌های سالم و تنش‌دار در سطح پیکسل در سناریوی اول بررسی شد. برای هر مدل، معیارهای عملکرد شامل دقت[1]، ضریب کاپا[2]، مساحت زیر منحنی AUC[3] و F1-Score به‌عنوان پارامترهای ارزیابی در نظر گرفته شدند. مقادیر این معیارها در **جدول ۵** بررسی شده.

جدول ۵. نتایج عملکرد و زمان محاسباتی مدل‌ها در سناریوی اول

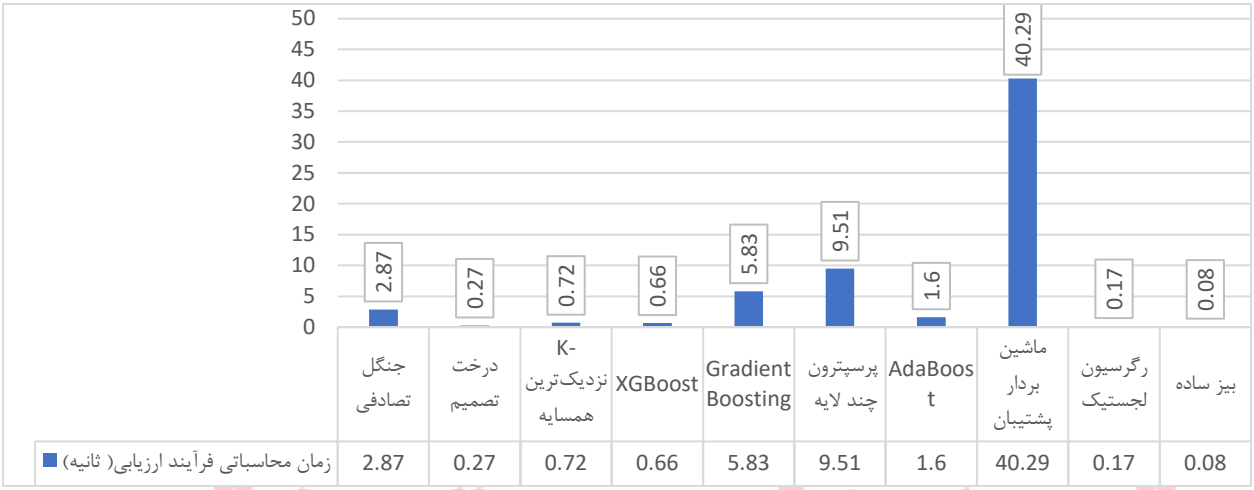
مدل	Accuracy (میانگین ± انحراف معیار)	F1 (میانگین ± انحراف معیار)	AUC	Kappa	زمان محاسباتی فرآیند ارزیابی (ثانیه)
جنگل تصادفی	۹۰/۰۵± ۵/۰۹	۸٤/۷٦ ± ۸/۰۱	۹۲/۸۳	۰.٦۹٦۲	۲/۸۷
درخت تصمیم	۸٦/۸۷± ٦/۰۸	۸۰/۹۱ ± ۹/۳۵	۸۳/۰۱	۰/٦۲۰۲	۰/۲۷
K- نزدیکترین همسایه	۹۰/٤۹± ٤/۹۹	۸۵/۵۰ ± ۷/٦۹	۹۱/٦۸	۰/۷۱۰۹	۰/۷۲
XGBoost	۹۰/۷۷± ٤/۷۲	۸۵/٦۳ ± ۷/۸۳	۹۳/٦۰	۰/۷۱۳۵	۰/٦٦
Gradient Boosting	۹۱/۳٤± ٤/۵۳	۸٦/۲۵ ± ۷/۸۳	۹٤/۳٤	۰/۷۲٦۰	۵/۸۳
پرسپترون چند لایه[4]	۹۱/۲٤± ٤/٦۵	۸٦/۲٤ ± ۷/۵۹	۹٤/۷۰	۰/۷۲۵۸	۹/۵۱
AdaBoost	۹۱/۵٤± ٤/۳۱	۸٦/۲٦ ± ۷/۹۰	۹۳/۲۵	۰/۷۲٦۹	۱/٦۰
ماشین بردار پشتیبان	۹۱/٤۳± ٤/٤٤	۸٦/۲۵ ± ۷/۷۵	۹۲/۵۵	۰/۷۲٦۹	٤۰/۲۹
رگرسیون لجستیک	۹۱/٤۵± ٤/۳۲	۸٦/۵۲ ± ۷/۵۲	۹٤/٦۳	۰/۷۳۱۳	۰/۱۷
بیز ساده	۹۰/۲٦± ٤/۹۸	۸۳/۹۱ ± ۸/۹۹	۹۳/٦۰	۰/٦۷۹۸	۰/۰۸

زمان محاسباتی مدل‌ها به‌عنوان یکی از معیارهای مهم در ارزیابی کارایی الگوریتم‌های یادگیری ماشین، در این پژوهش اندازه‌گیری و مقایسه شد. نتایج نشان داد که مدل بیز ساده (Naive Bayes) با زمان اجرای ۰/۰۸ ثانیه، سریع‌ترین الگوریتم در میان مدل‌های مورد بررسی بود. پس از آن، رگرسیون لجستیک و درخت تصمیم به‌ترتیب با زمان‌های ۰/۱۷ و ۰/۲۷ ثانیه قرار گرفتند. سرعت بالای این مدل‌ها را می‌توان به ساختار محاسباتی نسبتاً ساده و هزینه پردازشی پایین آن‌ها نسبت داد. در مقابل، ماشین بردار پشتیبان (SVC) با زمان اجرای ٤۰/۲۹ ثانیه، بیشترین زمان محاسباتی را به خود اختصاص داد. همچنین، پرسپترون چندلایه (MLP) با

[1] Accuracy
[2] Kappa
[3] Area Under the Curve
[4] Multi-Layer Perceptron

زمان ۹/۵۱ ثانیه، دومین مدل زمان‌بر در این مقایسه بود. این تفاوت در زمان اجرا را می‌توان با توجه به پیچیدگی محاسباتی الگوریتم‌ها، فرآیند بهینه‌سازی پارامترها و ماهیت محاسباتی هر مدل توضیح داد.

از میان روش‌های تقویتی (Boosting)، الگوریتم XGBoost با زمان اجرای ۰/٦٦ ثانیه و AdaBoost با ۱/٦۰ ثانیه، زمان محاسباتی نسبتاً پایینی داشتند. همچنین، جنگل تصادفی با زمان اجرای ۲/۸۷ ثانیه، در مقایسه با مدل‌های پیچیده‌تری مانند SVC و MLP، از سرعت مناسبی برخوردار بود. این نتایج نشان می‌دهد که تفاوت قابل‌توجهی میان الگوریتم‌ها از نظر هزینه محاسباتی وجود دارد و انتخاب مدل مناسب باید با در نظر گرفتن هم‌زمان کیفیت طبقه‌بندی و زمان اجرا صورت گیرد.



شکل ١٤. میزان زمان محاسباتی صرف شده(ثانیه) در سناریو اول

از نظر دقت طبقه‌بندی، نتایج نشان داد که AdaBoost با مقدار میانگین ۹۱/٥٤ ، بالاترین Accuracy را در میان مدل‌های بررسی‌شده به دست آورد. پس از آن، رگرسیون لجستیک با ۹۱/٤٥، ماشین بردار پشتیبان با ۹۱/٤۳ و Gradient Boosting با ۹۱/۳٤ عملکرد نزدیکی داشتند. همچنین، بررسی معیار F۱-Score نشان داد که رگرسیون لجستیک با مقدار ۸٦/٥۲ بهترین عملکرد را ثبت کرده است. این مدل علاوه بر کسب بالاترین F۱-Score، مقدار Kappa برابر با ۰.۷۳۱۳ را نیز به دست آورد که بالاترین مقدار در میان الگوریتم‌های مورد بررسی بود. از سوی دیگر، پرسپترون چندلایه با مقدار AUC برابر با ۹٤/۷۰ ، بهترین توانایی تفکیک دو کلاس را بر اساس این معیار نشان داد.

در مقابل، جنگل تصادفی با Accuracy برابر با ۹۰/۰٥ و F۱-Score برابر با ۸٤/۷٦ ، عملکرد نسبتاً مناسبی داشت، اما در مقایسه با مدل‌هایی نظیر رگرسیون لجستیک، AdaBoost و MLP، مقادیر پایین‌تری را ثبت کرد. درخت تصمیم نیز با Accuracy برابر با ۸٦/۸۷ و F۱-Score برابر با ۸۰/۹۱ ، ضعیف‌ترین عملکرد را از نظر این دو معیار داشت. همچنین، مدل بیز ساده با وجود برخورداری از کمترین زمان اجرا، مقدار F۱-Score برابر با ۸۳/۹۱ را ثبت کرد که نشان‌دهنده تفاوت میان سرعت محاسباتی و کیفیت طبقه‌بندی در این الگوریتم است.

در مجموع، نتایج سناریوی اول نشان می‌دهد که هیچ‌یک از الگوریتم‌ها در تمامی معیارهای ارزیابی برتری مطلق ندارند. رگرسیون لجستیک با برخورداری از بالاترین F۱-Score و Kappa، مقدار AUC نزدیک به بهترین نتیجه و زمان اجرای بسیار پایین، عملکرد متوازنی ارائه داد. همچنین، AdaBoost از نظر Accuracy و MLP از نظر AUC بهترین نتایج را کسب کردند؛ با این

نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

حال، زمان اجرای بیشتر MLP باید در انتخاب آن مورد توجه قرار گیرد. بنابراین، انتخاب الگوریتم مناسب برای تفکیک پیکسلی نمونه‌های سالم و تنش‌دار، به اولویت پژوهش میان کیفیت طبقه‌بندی، توانایی تفکیک کلاس‌ها و هزینه محاسباتی وابسته است.

٤-٢- بررسی نتایج سناریو دوم

در این سناریو، نتایج مدل‌های مختلف بر اساس سه مجموعه ویژگی مختلف، یعنی شاخص‌ها تنها (indices_only)، باندها تنها (bands_only)، و ترکیب (combined) مورد ارزیابی قرار گرفت. مدل‌ها شامل XGBoost، جنگل تصادفی، دسته‌بند بردار پشتیبان، رگرسیون لجستیک، و درخت تصمیم هستند. در ادامه به بررسی نتایج هر مدل برای هر مجموعه ویژگی در جدول ٦، ٧ و ٨ پرداخته می‌شود.

جدول ٦. نتایج مدل‌ها برای مجموعه شاخص‌ها به صورت مجزا در سناریو دوم

مدل	Accuracy (میانگین ± انحراف معیار)	F1 (میانگین ± انحراف معیار)	AUC	Kappa	زمان محاسباتی فرآیند ارزیابی (ثانیه)
XGBoost	٩١/٣١ ± ٤/٢٦	٨٥/٧٩ ± ٨/٠٨	٪ ٩٤/٧٢	٠/٧١٦٥	٦٥٢/٧٩
جنگل تصادفی	٩١/٦٦ ± ٤/٠٦	٨٦/٣٢ ± ٧/٩١	٪ ٩٤/٥٢	٠/٧٢٦٩	٧٤٢/٤٦
ماشین بردار پشتیبان	٩١/١٤ ± ٤/٥٠	٨٥/١٩ ± ٩/٢٨	٪ ٩٢/١٠	٠/٧٠٤٢	٣٧٨/١١
رگرسیون لجستیک	٩١/٦٤ ± ٤/١٦	٨٦/٧٤ ± ٧/٣٣	٪ ٩٣/٨٨	٠/٧٣٥٧	٠/٥٧
درخت تصمیم	٩١/٥٨ ± ٤/٠٤	٨٥/٨٤ ± ٩/١٦	٪ ٩٢/٥٩	٠/٧١٨٠	٧٥/١٨

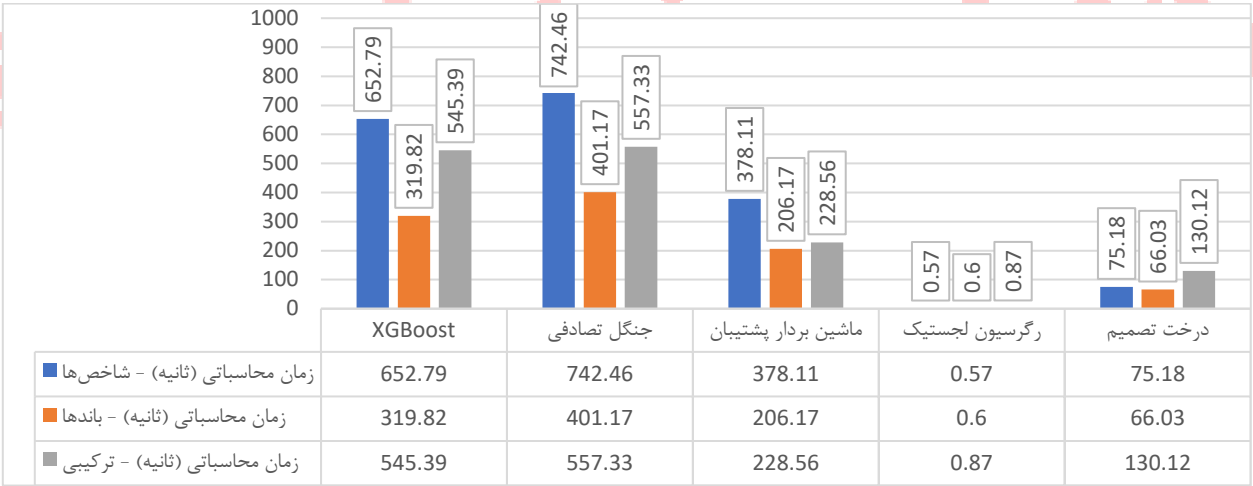
جدول ٧. نتایج مدل‌ها برای مجموعه باندها تنها در سناریو دوم

مدل	Accuracy (میانگین ± انحراف معیار)	F1 (میانگین ± انحراف معیار)	AUC	Kappa	زمان محاسباتی فرآیند ارزیابی (ثانیه)
XGBoost	٩٠/٨١ ± ٥/٠٧	٨٥/٧٣ ± ٧/٣٩	٪ ٩٣/٨٣	٠/٧١٥٠	٣١٩/٨٢
جنگل تصادفی	٩١/١٦ ± ٤/٦٧	٨٦/٠٢ ± ٧/٥٦	٪ ٩٤/٤٥	٠/٧٢١٠	٤٠١/١٧
ماشین بردار پشتیبان	٩١/٩٨ ± ٣/٩٧	٨٦/٦٨ ± ٧/٧١	٪ ٩٤/٥٣	٠/٧٣٤٢	٢٠٦/١٧
رگرسیون لجستیک	٩١/٦٢ ± ٤/٢١	٨٦/٠٨ ± ٧/٩٤	٪ ٩٤/٥٣	٠/٧٢٢٥	٠/٦٠
درخت تصمیم	٩٠/٥٤ ± ٤/٩١	٨٤/٩٨ ± ٧/٥٦	٪ ٩٠/٦٥	٠/٧٠١٣	٦٦/٠٣

جدول ۸. نتایج مدل‌ها برای مجموعه ترکیبی در سناریو دوم

مدل	Accuracy (میانگین ± انحراف معیار)	F1 (میانگین ± انحراف معیار)	AUC	Kappa	زمان محاسباتی فرآیند ارزیابی (ثانیه)
XGBoost	۹۱/۱٤ ± ٤/۱۲	۸٥/٥٦ ± ۸/۱٤	٪ ۹٤/۳۹	۰/۷۱۱۷	٥٤٥/۳۹
جنگل تصادفی	۹۱/٦٤ ± ٤/۲٥	۸٦/۳٦ ± ۷/٦۱	٪ ۹٤/٦۰	۰/۷۲۷۷	٥٥۷/۳۳
ماشین بردار پشتیبان	۹۰/۹٥ ± ٤/۷٤	۸۳/۸٤ ± ۱۱/۱٦	٪ ۹۲/۲٤	۰/٦۷۷۳	۲۲۸/٥٦
رگرسیون لجستیک	۹۱/۲٤ ± ٤/٤٥	۸٥/۰۹ ± ۹/۱۹	٪ ۹۲/۸٦	۰/۷۰۲۳	۰/۸۷
درخت تصمیم	۹۲/۰۷ ± ۳/۹٦	۸٦/۷۱ ± ۷/۹۷	٪ ۹۳/۱۸	۰/۷۳٥۳	۱۳۰/۱۲

همچنین، زمان محاسباتی مدل‌ها در شکل ۱٥ ارائه شده است. زمان گزارش‌شده بیانگر مدت اجرای فرآیند ارزیابی هر مدل در سناریوی دوم است که در سه مجموعه ویژگی شامل شاخص‌های گیاهی، باندهای طیفی خام و ترکیب هر دو مورد اندازه‌گیری و مقایسه شده است. نتایج نشان داد که رگرسیون لجستیک در هر سه حالت، با زمان‌های ۰/٥۷، ۰/٦۰ و ۰/۸۷ ثانیه، سریع‌ترین الگوریتم در میان مدل‌های مورد بررسی بوده است. در مقابل، جنگل تصادفی در مجموعه شاخص‌های گیاهی و مجموعه باندهای طیفی، به‌ترتیب با زمان‌های ۷٤۲/٤٦ و ٤۰۱/۱۷ ثانیه، بیشترین زمان محاسباتی را داشته است؛ درحالی‌که در مجموعه ویژگی ترکیبی، با زمان ٥٥۷/۳۳ ثانیه بیشترین زمان اجرا را به خود اختصاص داده است. همچنین، زمان اجرای ماشین بردار پشتیبان در هر سه مجموعه ویژگی نسبتاً بالا بوده و به‌ترتیب ۳۷۸/۱۱ ، ۲۰٦/۱۷ و ۲۲۸/٥٦ ثانیه ثبت شده است. این نتایج نشان می‌دهد که نوع و تعداد ویژگی‌های ورودی و همچنین ساختار محاسباتی الگوریتم‌ها بر زمان اجرای آن‌ها تأثیرگذار است. بنابراین، زمان محاسباتی در کنار معیارهای عملکرد طبقه‌بندی، می‌تواند مبنای مهمی برای انتخاب مدل مناسب، به‌ویژه در کاربردهای مقیاس بزرگ و پردازش مجموعه‌داده‌های حجیم، باشد.



شکل ۱٥. میزان زمان محاسباتی مدل‌ها در سناریو دوم (ثانیه)

٤-٢-١- مقایسه همبستگی ویژگی‌ها در سناریو اول و سناریو دوم

برای مقایسه وابستگی ویژگی‌ها در سناریو ۱ و ۲، میانگین مقادیر ماتریس همبستگی (بالاتر از قطر اصلی) محاسبه و به‌صورت نرمال‌شده مقایسه شد. فرمول نرمال‌سازی به‌صورت زیر است:

$$S_{\text{normalized}} = \frac{S_{\text{sum}}}{n} \quad (۱)$$

که در آن S_{sum} مجموع مقادیر مطلق بالای قطر اصلی ماتریس همبستگی است و n تعداد زوج‌های ویژگی است. این مقدار برای سناریو۱ مقدار ۰/٤٦٦ و برای سناریو۲ مقدار ۰/۲۱۰ را محاسبه شد، که نشان‌دهنده کاهش وابستگی کلی میان ویژگی‌های انتخاب‌شده در سناریوی دوم است.

با این حال، از آنجا که در سناریوی دوم علاوه بر تغییر مجموعه ویژگی‌ها، از Nested Cross-Validation و Grid Search برای تنظیم ابرپارامترها نیز استفاده شد، تغییرات عملکرد مدل‌ها را نمی‌توان صرفاً به کاهش همبستگی ویژگی‌ها نسبت داد. بنابراین، نتایج سناریوی دوم نشان‌دهنده اثر کلی استفاده از مجموعه ویژگی‌های با افزونگی کمتر همراه با فرآیند بهینه‌تر تنظیم و ارزیابی مدل‌ها است.

جدول ۹. مقایسه عملکرد مدل‌های مشابه با استفاده از مجموعه ویژگی ترکیبی سناریوی دوم و مجموعه ویژگی اولیه سناریوی اول

مدل	زمان محاسباتی فرآیند ارزیابی_ سناریو اول (ثانیه)	زمان محاسباتی فرآیند ارزیابی _ سناریو دوم (ثانیه)	دقت(درصد) _ سناریو اول	دقت(درصد) _ سناریو دوم	اختلاف دقت (درصد)
جنگل تصادفی	۲/۸۷	٥٥٧/۳۳	۹۰/۰٥	۹۱/٦٤	+۱/٥۹
درخت تصمیم	۰/۲۷	۱۳۰/۱۲	۸٦/۸۷	۹۲/۰۷	+٥/۲۰
XGBoost	۰/٦٦	٥٤٥/۳۹	۹۰/۷۷	۹۱/۱٤	+۰/۳۷
ماشین بردار پشتیبان	٤۰/۲۹	۲۲۸/٥٦	۹۱/٤۳	۹۰/۹٥	−۰/٤۸
رگرسیون لجستیک	۰/۱۷	۰/۸۷	۹۱/٤٥	۹۱/۲٤	−۰/۲۱

همان‌طور که در جدول ۹ مشاهده می‌شود، زمان محاسباتی مدل‌های مشابه در سناریوی دوم نسبت به سناریوی اول افزایش یافته است. این افزایش زمان عمدتاً به دلیل تفاوت در ساختار فرآیند اعتبارسنجی و تنظیم ابرپارامترها در دو سناریو است. در سناریوی اول، مدل‌ها با استفاده از اعتبارسنجی متقاطع پنج Foldی گروهی (۵-Fold Group Cross-Validation) و بر اساس شناسه

مقاله در نوبت انتشار
نشریه علمی پژوهشی
«اطلاعات جغرافیایی (سپهر)»

درخت ارزیابی شدند؛ درحالی‌که در سناریوی دوم از اعتبارسنجی متقاطع گروهی تودرتو (Nested Group Cross-Validation)، شامل پنج Fold بیرونی و سه Fold داخلی، به همراه Grid Search برای تنظیم ابرپارامترها استفاده شد. در نتیجه، تعداد دفعات آموزش و ارزیابی مدل‌ها در سناریوی دوم افزایش یافت و موجب افزایش هزینه محاسباتی فرآیند شد. بنابراین، زمان‌های گزارش‌شده در دو سناریو باید به‌عنوان هزینه محاسباتی فرآیندهای ارزیابی با ساختارهای متفاوت تفسیر شوند.

٤-٣- بررسی نتایج سناریو سوم: ترکیب مدل‌های منتخب با روش‌های Ensemble

در سناریوی سوم، پنج مدل پایه شامل جنگل تصادفی، XGBoost، ماشین بردار پشتیبان، رگرسیون لجستیک و درخت تصمیم به‌عنوان اجزای Ensemble در نظر گرفته شدند. ۲۰ترکیبEnsemble شامل ۱۰ ترکیب Soft Voting دوتایی و ۱۰ ترکیب Stackingسه‌تایی مورد ارزیابی قرار گرفتند. تمامی ترکیب‌ها به‌صورت از پیش تعریف‌شده و مستقل از نتایج عملکرد ایجاد شدند. ارزیابی ترکیب‌ها بر روی بخش Dev با استفاده ازNested Cross-Validation شامل پنج Fold بیرونی و سهFold داخلی انجام شد و مجموعه Hold-out شامل ۱۰۲۰ نمونه پیکسلی متعلق به چهار درخت مستقل بود که در تمام مراحل تنظیم ابرپارامترها، ارزیابی ترکیب‌ها، مقایسه عملکرد و انتخاب ترکیب نهایی کنار گذاشته شد. این مجموعه تنها پس از تکمیل فرآیند انتخاب و آموزش مدل نهایی برای ارزیابی مستقل مورد استفاده قرار گرفت. مجموعه Hold-out در تمام مراحل ارزیابی، تنظیم ابرپارامترها و انتخاب ترکیب برتر کنار گذاشته شد و صرفاً پس از نهایی‌شدن ترکیب منتخب، برای ارزیابی نهایی آن روی درخت‌های دیده‌نشده مورد استفاده قرار گرفت.

نتایج ارزیابی ۲۰ ترکیب Ensemble در بخش Dev نشان داد که عملکرد این ترکیب‌ها از نظر میانگین Macro-F۱ متفاوت است. بر این اساس، ترکیب‌ها بر مبنای میانگین Macro-F1 حاصل از پنج Fold بیرونی رتبه‌بندی شدند و پنج ترکیب دارای بالاترین عملکرد انتخاب شدند. نتایج مربوط به این ترکیب‌ها، شامل میانگین و انحراف معیار Macro-F۱، میانگین دقت و زمان محاسباتی فرآیند ارزیابی، در جدول ۱۰ ارائه شده است.

جدول ۱۰. پنج ترکیب برتر Ensemble بر اساس میانگین F۱ در اعتبارسنجی متقاطع گروهی تودرتو

رتبه	ترکیبEnsemble	میانگینMacro-F1 ± انحراف معیار	Acc_mean	AUC	میانگین زمان محاسباتی در هر Fold(ثانیه)
۱	VOTE_rf+lr	٨٧/٠٠ ± ٤/٤٠	٩١/١٣	٠/٩٥٣	١٠/٠٤
۲	STACK_svc+lr+dt	٨٦/٨٦ ± ٣/٨٩	٩٠/٩٩	٠/٩٤٦	٣٥/٠٦
۳	STACK_rf+svc+lr	٨٦/٨٢ ± ٤/٠٥	٩٠/٩٧	٠/٩٥٢	٥٦/٢٠
٤	STACK_rf+svc+dt	٨٦/٧١ ± ٤/١٣	٩٠/٨٦	٠/٩٥٢	٥٦/٣٦
٥	STACK_rf+lr+dt	٨٦/٦٩ ± ٣/٩٧	٩٠/٨٩	٠/٩٥٢	٣٠/٢٠

مقاله در نوبت انتشار
نشریه علمی پژوهشی

پس از انتخاب ترکیب VOTE_rf+lr بر اساس نتایج اعتبارسنجی متقاطع گروهی تودرتو روی مجموعه Dev، این ترکیب با استفاده از کل مجموعه Dev و تنظیم ابرپارامترها از طریق اعتبارسنجی گروهی سهFold آموزش مجدد یافت و سپس یک‌بار و بدون هیچ تنظیم مجددی روی مجموعه Hold-out ارزیابی شد. مجموعه Hold-out شامل ۱۰۲۰ نمونه پیکسلی متعلق به چهار درخت بود که در هیچ یک از مراحل انتخاب ویژگی، تنظیم ابرپارامترها، مقایسه ترکیب‌ها و انتخاب مدل نهایی حضور نداشتند. مدل منتخب روی این مجموعه به دقت کلی ۹۵/۲۰٪، Precision-macro برابر با ۹۶/۵۵٪، Recall-macro برابر با ۹۱/۹۲٪، F۱-macro برابر با ۹۳/۸۸٪، Balanced Accuracy برابر با ۹۱/۹۲٪، ضریب کاپای کوهن برابر با ۰/۸۷۷۹ و ROC-AUC برابر با ۰/۹۸۹۰ دست یافت. ماتریس ابهام این ارزیابی در جدول ۱۱ ارائه شده است.

جدول ۱۱. ماتریس ابهام ترکیب منتخب VOTE_rf+lr روی مجموعه آزمون مستقل (۱۰۲۰ نمونه پیکسلی از چهار درخت دیده‌نشده)

نمونه واقعی	نمونه پیش‌بینی‌شده		
	سالم	تنش‌دار	مجموع
سالم	۷۲۲	۲	۷۲٤
تنش‌دار	٤۷	۲٤۹	۲۹٦
مجموع	۷٦۹	۲۵۱	۱۰۲۰

همان‌طور که در جدول ۱۱ مشاهده می‌شود، بیشترین سهم خطا مربوط به نمونه‌های تنش‌دار بود که به‌اشتباه سالم پیش‌بینی شدند (٤۷ نمونه از ۲۹٦ نمونه، معادل ۱۵/۸۸٪)، در حالی که تنها دو نمونه از ۷۲٤ نمونه سالم (معادل ۰/۲۸٪) به‌اشتباه تنش‌دار تشخیص داده شد. این الگوی نامتقارن نشان می‌دهد که مدل منتخب در حفظ نمونه‌های سالم محافظه‌کارانه‌تر عمل کرده و در مواردی نمونه‌های دارای علائم ظاهری تنش را با ظاهر سالم اشتباه گرفته است. با توجه به اینکه هدف این پژوهش تفکیک عمومی وضعیت ظاهری نمونه‌ها بوده است، این الگوی خطا در چارچوب تفکیک «ظاهر سالم» از «ظاهر تنش‌دار» تفسیر می‌شود و به نوع یا شدت مشخصی از تنش نسبت داده نمی‌شود.

بررسی ساختار پنج ترکیب برتر نشان داد که مدل‌های جنگل تصادفی (RF) و رگرسیون لجستیک (LR) بیشترین تکرار را در میان ترکیب‌های منتخب داشته‌اند. همچنین، چهار مورد از پنج ترکیب برتر بر اساس روش Stacking و یک ترکیب بر اساس روش Soft Voting ایجاد شده‌اند. با وجود این، این فراوانی به‌تنهایی برای نتیجه‌گیری درباره برتری عمومی یک روش ترکیبی یا عملکرد مستقل مدل‌های پایه کافی نیست. از نظر عملکرد، ترکیب Soft Voting مبتنی بر RF و LR با میانگین F۱ برابر با ۰/۸۷ و انحراف معیار ۰/۰٤۳۹ ، رتبه نخست را به دست آورد. این ترکیب همچنین با میانگین زمان محاسباتی ۱۰/۰٤ ثانیه در هر Fold، کمترین زمان اجرا را در میان پنج ترکیب برتر داشت. در مقابل، ترکیب‌های مبتنی بر Stacking با وجود دستیابی به مقادیر

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

Macro-F1 نزدیک به ترکیب نخست، زمان محاسباتی بیشتری نیاز داشتند. در مجموع، نتایج نشان می‌دهد که در چارچوب داده‌ها و روش ارزیابی این پژوهش، ترکیب RF و LR با روش Soft Voting توانسته است توازن مناسب‌تری میان عملکرد طبقه‌بندی و هزینه محاسباتی برقرار کند.

۵- نتیجه‌گیری

در این پژوهش، امکان تفکیک پیکسلی نمونه‌های سالم و دارای علائم ظاهری تنش در درختان مرکبات با استفاده از تصاویر چندطیفی پهپاد و الگوریتم‌های یادگیری ماشین مورد بررسی قرار گرفت. به این منظور، تعداد ۱۶۰۰۰ نمونه پیکسلی شامل ۸۰۰۰ نمونه سالم و ۸۰۰۰ نمونه دارای علائم ظاهری تنش استخراج و برچسب‌گذاری شد. با توجه به احتمال وابستگی مکانی نمونه‌های متعلق به یک درخت، در فرآیند ارزیابی مدل‌ها از تقسیم‌بندی گروهی بر اساس شناسه درخت استفاده شد تا عملکرد مدل‌ها بر روی درخت‌هایی ارزیابی شود که در فرآیند آموزش آن‌ها حضور نداشته‌اند. همچنین، به‌منظور بررسی جنبه‌های مختلف عملکرد طبقه‌بندی، سه سناریوی مستقل شامل مقایسه الگوریتم‌های یادگیری ماشین، ارزیابی مجموعه‌های ویژگی و ترکیب مدل‌های منتخب طراحی و اجرا گردید.

در سناریوی اول، عملکرد ده الگوریتم یادگیری ماشین با استفاده از باندهای طیفی خام و شاخص‌های گیاهی اولیه مقایسه شد. نتایج نشان داد که رگرسیون لجستیک با مقدار F1 برابر با ۸۶/۵۲٪ و ضریب کاپای ۰/۷۳۱۳، بهترین عملکرد را بر اساس این دو معیار ارائه کرد. از سوی دیگر، الگوریتم AdaBoost با دقت کلی ۹۱/۵۴٪ و پرسپترون چندلایه با مقدار AUC برابر با ۹۴/۷۰٪، به‌ترتیب بهترین نتایج را از نظر دقت کلی و توانایی تفکیک دو کلاس به دست آوردند. این نتایج نشان می‌دهد که برتری الگوریتم‌ها به معیار ارزیابی وابسته است و هیچ‌یک از مدل‌ها در تمامی معیارهای بررسی‌شده برتری مطلق نداشتند.

در سناریوی دوم، تأثیر استفاده از مجموعه‌های ویژگی با ساختار متفاوت، شامل شاخص‌های گیاهی منتخب، باندهای طیفی خام و مجموعه ترکیبی، بر عملکرد مدل‌ها بررسی شد. نتایج نشان داد که در مجموعه شاخص‌های گیاهی، رگرسیون لجستیک با F1 برابر با ۸۶/۷۴٪ بهترین عملکرد را داشت. در مجموعه باندهای طیفی خام، ماشین بردار پشتیبان با F1 برابر با ۸۶/۶۸٪ و دقت ۹۱/۹۸ ٪ عملکرد مطلوبی ارائه کرد؛ درحالی‌که در مجموعه ویژگی ترکیبی، درخت تصمیم با F1 برابر با ۸۶/۷۱٪ و دقت ۹۲/۰۷٪ بهترین نتایج را به دست آورد. همچنین، مقدار شاخص نرمال‌شده وابستگی ویژگی‌ها از ۰/۴۶۶ در سناریوی اول به ۰/۲۱۰ در سناریوی دوم کاهش یافت که نشان‌دهنده کاهش افزونگی میان ویژگی‌های منتخب بر اساس معیار محاسبه‌شده در این پژوهش است. با این حال، با توجه به تفاوت هم‌زمان مجموعه ویژگی‌ها و فرآیند تنظیم و ارزیابی مدل‌ها در دو سناریو، تغییرات عملکرد را نمی‌توان صرفاً به کاهش همبستگی ویژگی‌ها نسبت داد.

در سناریوی سوم، به‌منظور بررسی تأثیر ترکیب مدل‌های پایه بر عملکرد طبقه‌بندی، تعداد ۲۰ ترکیب Ensemble شامل ۱۰ ترکیب دوتایی Soft Voting و ۱۰ ترکیب سه‌تایی Stacking ارزیابی شدند. بر اساس نتایج اعتبارسنجی متقاطع گروهی تودرتو، ترکیب Soft Voting مبتنی بر جنگل تصادفی و رگرسیون لجستیک (VOTE_rf+lr) با میانگین F1 برابر با ۸۷/۰۰٪ و انحراف معیار ۰/۰۴۳۹ واحد درصد، رتبه نخست را در میان ترکیب‌های بررسی‌شده کسب کرد. میانگین دقت این ترکیب برابر با ۹۱/۱۳٪ و میانگین زمان محاسباتی آن در هر Fold برابر با ۱۰/۰۴ ثانیه بود. این نتایج نشان داد که ترکیب مدل‌های پایه با روش Soft

مقاله در نوبت انتشار
نسخه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

Voting در مجموعه داده مورد مطالعه توانسته است توازن مناسبی میان عملکرد طبقه‌بندی و هزینه محاسباتی ایجاد کند. با این وجود، اختلاف عملکرد این ترکیب با برخی ترکیب‌های برتر دیگر محدود بوده و برای اثبات برتری آماری آن به تحلیل‌های تکمیلی نیاز است.

در مرحله نهایی، ترکیب منتخبVOTE_rf+lr پس از تنظیم ابرپارامترها و آموزش مجدد با استفاده از کل مجموعهDev، بر روی مجموعه آزمون مستقل ارزیابی شد. این مجموعه شامل ۱۰۲۰ نمونه پیکسلی متعلق به چهار درخت بود که در فرآیند آموزش و اعتبارسنجی مدل حضور نداشتند. نتایج نشان داد که مدل نهایی به دقت کلی ۹۵/۲۰٪، مقدار Precision–macro برابر با ۹۶/۵۵٪، مقدار Recall–macro برابر با ۹۱/۹۲٪ و مقدار F۱ برابر با ۹۳/۸۸٪ دست یافت. همچنین، مقدارBalanced Accuracyبرابر با ۹۱/۹۲٪، ضریب کاپای کوهن برابر با ۰/۸۷۷۹ و مقدارROC–AUCبرابر با ۰/۹۸۹۰ به دست آمد. این نتایج بیانگر عملکرد مناسب ترکیب منتخب در تفکیک نمونه‌های پیکسلی متعلق به درخت‌های خارج از مجموعه آموزش است. همچنین ماتریس ابهام این ارزیابی نشان داد که بیشترین سهم خطا مربوط به نمونه‌های تنش‌دار است که به‌اشتباه سالم پیش‌بینی شده‌اند (۴۷ نمونه)، در حالی که تنها دو نمونه سالم به‌اشتباه تنش‌دار تشخیص داده شد.

در مجموع، یافته‌های این پژوهش نشان داد که استفاده از تصاویر چندطیفی پهپادی در کنار الگوریتم‌های یادگیری ماشین و روش‌های ترکیبی، ظرفیت مناسبی برای تفکیک پیکسلی نمونه‌های دارای ظاهر سالم و تنش‌دار در مجموعه داده مورد مطالعه دارد. همچنین، نتایج نشان داد که انتخاب ویژگی‌ها و نوع الگوریتم طبقه‌بندی بر عملکرد نهایی تأثیرگذار است و استفاده از روش‌های ترکیبی لزوماً در تمام شرایط به بهبود چشمگیر عملکرد منجر نمی‌شود. از آنجا که برچسب‌گذاری نمونه‌ها در این پژوهش بر اساس علائم ظاهری برگ‌ها انجام شده و عامل یا نوع فیزیولوژیک تنش به‌صورت مستقل تأیید نشده است، نتایج باید در چارچوب تفکیک عمومی وضعیت ظاهری نمونه‌ها تفسیر شوند. افزون بر این، با وجود انجام ارزیابی مستقل بر روی درخت‌های دیده‌نشده، مجموعه Hold–out تنها شامل چهار درخت بود. بنابراین، تعداد محدود واحدهای مکانی مستقل در ارزیابی نهایی، در کنار محدود بودن منطقه مطالعاتی و دوره تصویربرداری، تعمیم نتایج به سایر باغ‌ها و شرایط محیطی را با محدودیت مواجه می‌کند.

پیشنهادات

با توجه به اینکه داده‌های این پژوهش از یک محدوده مکانی و در یک دوره تصویربرداری جمع‌آوری شده‌اند و مجموعه آزمون مستقل نیز تنها شامل چهار درخت بوده است، پیشنهاد می‌شود در مطالعات آینده عملکرد مدل‌ها با استفاده از تعداد بیشتری از درخت‌های مستقل، باغ‌های مختلف، مناطق جغرافیایی متفاوت و دوره‌های زمانی متعدد ارزیابی شود. همچنین، استفاده از تقسیم‌بندی بلوک‌های مکانی مستقل در کنار جداسازی درخت‌محور می‌تواند امکان بررسی دقیق‌تر تأثیر فاصله مکانی و وابستگی فضایی بر قابلیت تعمیم مدل‌ها را فراهم سازد.

از سوی دیگر، با توجه به اینکه برچسب‌گذاری نمونه‌ها در پژوهش حاضر بر اساس علائم ظاهری برگ‌ها انجام شده است، استفاده از داده‌های مرجع مستقل، آزمون‌های آزمایشگاهی و اندازه‌گیری‌های فیزیولوژیک گیاه می‌تواند به افزایش اعتبار برچسب‌ها و بررسی ارتباط ویژگی‌های طیفی با وضعیت واقعی سلامت گیاه کمک کند. همچنین، استفاده از داده‌های چندزمانه، تصاویر حرارتی و اطلاعات تکمیلی محیطی می‌تواند امکان بررسی تغییرات وضعیت سلامت در طول زمان و ارزیابی عملکرد مدل‌ها

مقاله در نوبت انتشار
نشریه علمی پژوهشی
« اطلاعات جغرافیایی (سپهر) »

تحت شرایط مختلف محیطی را فراهم سازد. در نهایت، توسعه مدل‌هایی برای تفکیک انواع مشخص تنش و بیماری، با استفاده از نمونه‌های دارای برچسب مرجع معتبر، می‌تواند مسیر تحقیقات آینده را به سمت تشخیص تخصصی‌تر و کاربردی‌تر در مدیریت باغات مرکبات هدایت کند.

مراجع

Ahmadi, M., & Mirhaji, H. (2012). Evaluation of Thermal Stress Effects on Corn (Case Study: Qazvin Province). *Advanced Environmental Sciences, 9* .(۳)

Allen, L. H., & Vu, J. C. (2009). Carbon dioxide and high temperature effects on growth of young orange trees in a humid, subtropical environment. *Agricultural and Forest Meteorology, 149*(5), 820-830 .

Ampatzidis, Y., & Partel, V. (2019). UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. *Remote Sensing, 11*(4), 410 .

DadrasJavan, F., Samadzadegan, F., Seyed Pourazar, S. H., & Fazeli, H. (2019). UAV-based multispectral imagery for fast Citrus Greening detection. *Journal of Plant Diseases and Protection, 126*(4), 307-318 .

Deng, X., Zhu, Z., Yang, J ,.Zheng, Z., Huang, Z., Yin, X., Wei, S., & Lan, Y. (2020). Detection of Citrus Huanglongbing Based on Multi-Input Neural Network Model of UAV Hyperspectral Remote Sensing. *Remote Sensing, 12*(17), 2678. https://www.mdpi.com/2072-4292/12/17/2678

Fotuhi-Qazvini, R., & Fatahi-Moghadam, J. (2010). Citrus growing in Iran / Third Edition. *University of Guilan Press, 1389* .(۱)

Futch, S., Weingarten, S., & Irey, M. (2009). Determining HLB infection levels using multiple survey methods in Florida citrus .

Garcia-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013, 2013/02/01/). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture, 91*, 106-11 .۵ https://doi.org/https://doi.org/10.1016/j.compag.2012.12.002

Gomiero, T., Pimentel, D., & Paoletti, M. G. (2011, 2011/01/01). Environmental Impact of Different Agricultural Management Practices: Conventional vs. Organic Agriculture. *Critical Reviews in Plant Sciences, 30*(1-2), 95-124. https://doi.org/10.1080/07352689.2011.554355

مقاله در نوبت انتشار
نشریه علمی پژوهشی
«اطلاعات جغرافیایی (سپهر)»

Govender, M., Govender, P., Weiersbye, I., Witkowski, E., & Ahmed, F. (2009). Review of commonly used remote sensing and ground-based technologies to measure plant water stress. *Water Sa, 35* .(۵)

Keremane, M. L., Ramadugu, C., Rodriguez, E., Kubota, R., Shibata, S., Hall, D. G., Roose, M. L., Jenkins, D., & Lee, R. F. (2015, 2015/02/01/). A rapid field detection system for citrus huanglongbing associated 'Candidatus Liberibacter asiaticus' from the psyllid vector, Diaphorina citri Kuwayama and its implications in disease management. *Crop Protection, 68*, 41-48. https://doi.org/https://doi.org/10.1016/j.cropro.2014.10.026

Lan, Y., Huang, Z., Deng, X., Zhu, Z., Huang, H., Zheng, Z., Lian, B., Zeng, G., & Tong, Z. (2020, 2020/04/01/). Comparison of machine learning methods for citrus greening detection on UAV multispectral images. *Computers and Electronics in Agriculture, 171*, 105234. https://doi.org/https://doi.org/10.1016/j.compag.2020.105234

Li, H., Lee, W. S., Wang, K., Ehsani, R., & Yang, C. (2014, 2014/04/01). 'Extended spectral angle mapping (ESAM)' for citrus greening disease detection using airborne hyperspectral imaging. *Precision Agriculture, 15*(2), 162-183. https://doi.org/10.1007/s11119-013-9325-6

Mann, K. K., Schmann, A. W., & Spann, T. M. (2011). Response of citrus to exogenously applied salicylate compounds during abiotic and biotic stress. Proceedings of the Florida State Horticultural Society ,

Matusevicius e de Castro, V. H. P., Taya Cristo, & Bolfe, É. L. (2023). Disease detection in citrus crops using optical and thermal remote sensing: a literature review. *Eng. Agric, 31*, 140-157 .

Miraki, M., Sohrabi, H., & Fatehi, P. (2022). Citrus trees identification and trees stress detection based on spectral data. derived from UAVs. *Journal of Reserch in Horticultural Science, 1*(1), 27-40. https://doi.org/10.22092/rhsj.2022.127815

Mishra, A., Karimi, D., Ehsani, R., & Albrigo, L. G. (2011, 2011/11/01/). Evaluation of an active optical sensor for detection of Huanglongbing (HLB) disease. *Biosystems Engineering, 110*(3), 302-309. https://doi.org/https://doi.org/10.1016/j.biosystemseng.2011.09.003

Moriya, É. A. S., Imai, N. N., Tommaselli, A. M. G., Berveglieri, A., Santos, G. H., Soares, M. A., Marino, M., & Reis, T. T. (2021, 2021/09/01/). Detection and mapping of trees infected with citrus gummosis using UAV hyperspectral data. *Computers and Electronics in Agriculture, 188*, 106298. https://doi.org/https//:doi.org/10.1016/j.compag.2021.106298

Nouhi, K., Fattahi, E., & Fateh, S. (2012). Effect of Heat Stress on Citrus Yield in Southern Iran .

Peres, D. J., & Cancelliere, A. (2021). Analysis of multi-spectral images acquired by UAVs to monitor water stress of citrus orchards in Sicily, Italy. World Environmental and Water Resources Congress 2021 ,

Qin, J., Burks, T. F., Ritenour, M. A., & Bonn, W. G. (2009, 2009/07/01/). Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. *Journal of Food Engineering, 93*(2), 183-191. https://doi.org/https://doi.org/10.1016/j.jfoodeng.2009.01.014

Richa, R., Kohli, D., Vishwakarma, D., Mishra, A., Kabdal, B., Kothakota, A., Richa, S., Sirohi, R., Kumar, R., & Naik, B .(۲۰۲۳) .Citrus fruit: Classification, value addition, nutritional and medicinal values, and relation with pandemic and hidden hunger. *Journal of Agriculture and Food Research, 14*, 100718 .

Sanofer, A. A. (2014). Role of citrus fruits in health. *Journal of Pharmaceutical Sciences and Research, 6*(2), 121 .

Sarkar, S. K., Das, J., Ehsani, R., & Kumar, V. (2016, 16-21 May 2016). Towards autonomous phytopathology: Outcomes and challenges of citrus greening disease detection through close-range remote sensing ۲۰۱۶ .IEEE International Conference on Robotics and Automation (ICRA) ,

Taghizadeh-Alisaraei, A., Hosseini, S. H., Ghobadian, B., & Motevali, A. (2017). Biofuel production from citrus wastes: A feasibility study in Iran. *Renewable and Sustainable Energy Reviews, 69*, 1100-1112 .

Weng, H., Lv, J., Cen, H., He, M., Zeng, Y., Hua, S., Li, H., Meng, Y., Fang, H., & He, Y. (2018, 2018/12/01/). Hyperspectral reflectance imaging combined with carbohydrate metabolism analysis for diagnosis of citrus Huanglongbing in different seasons and cultivars. *Sensors and Actuators B: Chemical, 275*, 50-60. https://doi.org/https://doi.org/10.1016/j.snb.2018.08.020

Woolfson, L. (2024). *Detecting Disease in Citrus Trees using Multispectral UAV Data and Deep Learning Algorithm* University of the Witwatersrand, Johannesburg (South Africa) .[

مقاله در نوبت انتشار
نشریه علمی پژوهشی
«اطلاعات جغرافیایی (سپهر)»