



Mapping date-palm plantations using random forest classification and multi-temporal data in the Maroon–Jarahi sub-basin, Khuzestan, Iran

Masoud Soltani^{1✉} | Bahareh Bahmanabadi² | Ali Mokhtaran³

1. Corresponding Author, Department of Water Science and Engineering, Faculty of Agriculture and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: msoltani@eng.ikiu.ac.ir
2. Department of Water Science and Engineering, Faculty of Agriculture and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: b.bahmanabadi@gmail.com
3. Agricultural Engineering Research Department, Khuzestan Agricultural and Natural Resources Research and Education Center (AREEO), Ahwaz, Iran. E-mail: alimokhtaran@gmail.com

Article Info

Article type:

Research Article

Article history:

Received 24 January 2026

Received in revised form

11 April 2026

Accepted 26 April 2026

Published online 22 August 2026

Keywords:

Classification

Date palm

Maroon–Jarahi sub-basin

Random Forest

Sentinel

ABSTRACT

Accurate Monitoring of date-palm plantations and reliable estimation of cultivated area are essential for water-resource management, agricultural planning and regional policy making in arid and semi-arid regions, specially in south-west of Iran. This research utilized multi-temporal, Sentinel-2, and radar, Sentinel-1 imageries and supervised classification based on random forest, to present accurate and applicable map of date-palms plantations in Maroon-Jarahi sub-basin. To address this, Sentinel-2 optical and Sentinel-1 radar time series were derieved and processed, then together with Spectral, Radar, thermal indices and collected field reference samples during the 2022-2024 agricultural seasons were applied to training process of random forest model. Classification was run based on 36 inputs including, main bands, Spectral, Radar, and thermal indices. Accuracy assessment of the Model according to independent sample test displayed that The Random Forest classifier yielded very high performance due to, overall accuracy=95%, kappa coefficient=0.94, and precision, recall and F1-score were approximately 0.99. furthermore, mapped date-palm area closely matched reference inventories, the actual area was 26197.55 ha while the mapped area was 21764.55 ha for the Random Forest result, thus approximately +1% over-estimation was derieved. The results showed that, The integration of multi-temporal and thermal indicators within a Random Forest classification framework provides an efficient, reliable and scalable method to map date-palm plantations in arid and semi-arid basins. Practically, the proposed workflow can be a validated approach for water resource management, Orchards' health monitoring and agricultural planning in reginal and national scales.

Cite this article: Soltani, M., Bahmanabadi, B., & Mokhtaran, A. (2026). Mapping date-palm plantations using random forest classification and multi-temporal data in the Maroon-Jarahi sub-basin, Khuzestan, Iran. *Journal of Water and Irrigation Management*, 16 (2), 371-391. DOI: <https://doi.org/10.22059/jwim.2026.409960.1284>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2026.409960.1284>

Publisher: University of Tehran Press.



نقشه گیاهی نخلستان های خرما با بهره گیری از طبقه بندی جنگل تصادفی و داده های چندزمانه در زیر حوضه مارون - جراحی خوزستان

مسعود سلطانی^۱ | بهاره بهمن آبادی^۲ | علی مختاران^۳

۱. نویسنده مسئول، گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین المللی امام خمینی (ره)، قزوین، ایران. رایانامه: msoltani@eng.ikiu.ac.ir
۲. گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین المللی امام خمینی (ره)، قزوین، ایران. رایانامه: b.bahmanabadi@alumni.ut.ac.ir
۳. بخش تحقیقات فنی و مهندسی کشاورزی، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی خوزستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اهواز، ایران. رایانامه: alimokhtaran@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۴/۱۱/۰۴ تاریخ بازنگری: ۱۴۰۵/۰۱/۲۲ تاریخ پذیرش: ۱۴۰۵/۰۲/۰۶ تاریخ انتشار: ۱۴۰۵/۰۵/۳۱ کلیدواژه ها: جنگل تصادفی خرما زیرحوضه مارون-جراحی سنتینل طبقه بندی	پایش دقیق نخلستان های خرما و برآورد سطح زیرکشت آن ها در مناطق خشک و نیمه خشک، به ویژه در جنوب غرب ایران، به منظور مدیریت منابع آب، برنامه ریزی زراعی و تصمیم سازی های منطقه ای اهمیت ویژه ای دارد. این پژوهش با هدف تهیه نقشه ای دقیق و کارآمد از نخلستان های زیرحوضه مارون-جراحی خوزستان، از ترکیب داده های چندزمانه سنتینل-۲ و راداری، سنتینل-۱ و طبقه بندی نظارت شده مبتنی بر مدل جنگل تصادفی بهره گرفت. برای این منظور، تصاویر اپتیک، راداری و حرارتی در دوره های ۱۴۰۰ تا ۱۴۰۳ استخراج و پس از تصحیح، ترکیب زمانی و محاسبه شاخص های طیفی، راداری و حرارتی، همراه با نمونه های میدانی گردآوری شده، در فرایند آموزش مدل به کار گرفته شدند. طبقه بندی بر پایه ۳۶ متغیر ورودی شامل باندهای اصلی، شاخص های طیفی و شاخص های راداری و دمایی انجام شد. ارزیابی دقت مدل با استفاده از داده های مستقل آزمون نشان داد که روش پیشنهادی از عملکرد بسیار مطلوبی برخوردار است، به گونه ای که صحت کلی ۹۵ درصد، ضریب کاپای ۰/۹۴ و مقادیر Precision، Recall و F1-score برای کلاس نخلستان همگی در محدوده ۰/۹۹ به دست آمد. نتایج برآورد سطح زیرکشت نشان داد که مقدار واقعی ۱۹۷۵۵/۲۶ هکتار و مقدار برآوردی ۲۱۷۶۴/۵۵ هکتار بوده که تنها بیانگر بیش برآوردی حدود یک درصد است. یافته ها حاکی از آن است که استفاده همزمان از ویژگی های طیفی، ساختاری و حرارتی در کنار مدل جنگل تصادفی، چارچوبی کارآمد، پایدار و قابل تعمیم برای شناسایی نخلستان ها فراهم می آورد. این رویکرد می تواند مبنایی معتبر برای مدیریت منابع آب، پایش سلامت باغات و برنامه ریزی کشاورزی در مقیاس های منطقه ای و ملی ارائه دهد.

استناد: سلطانی، مسعود؛ بهمن آبادی، بهاره و مختاران، علی (۱۴۰۵). نقشه گیاهی نخلستان های خرما با بهره گیری از طبقه بندی جنگل تصادفی و داده های چندزمانه در زیر حوضه مارون - جراحی خوزستان. نشریه مدیریت آب و آبیاری، ۱۶ (۲)، ۳۷۱-۳۹۱.
DOI: <https://doi.org/10.22059/jwim.2026.409960.1284>



۱. مقدمه

خرما یکی محصولات راهبردی مناطق گرمسیری و خشک جهان بویژه ایران به شمار می رود و نقش برجسته ای در امنیت غذایی، اشتغال و توسعه اقتصادی نواحی جنوبی کشور، به ویژه استان خوزستان، دارد. تولید انبوه خرما علاوه بر تأمین نیاز غذایی داخلی، با ایجاد فرصت های شغلی در کشت، فرآوری و صادرات محصول، ارزش افزوده ای اقتصادی قابل توجهی را برای کشاورزان و اقتصاد منطقه به همراه دارد (Al-Karmadi & Okoh, 2024). طبق آمار فائو، ایران با تولید حدود ۹۰۰ هزار تن خرما در سال (حدود ۱۴ درصد تولید جهانی) و بیش از ۱۸۵ هزار هکتار اراضی باغی تحت کشت خرما، همواره پس از مصر و گاهی هم زمان با آن، در رتبه دوم یا اول تولید جهانی جای دارد (Koshteh & Kamalian, 2004). علاوه بر جنبه اقتصادی، نخل خرما از نظر بوم شناختی نیز در تثبیت خاک های بیابانی و کویری نقش داشته و به دلیل مقاومتش به شرایط خشکی و شوری، پوشش گیاهی مناسبی در اقلیم خشک فراهم می آورد (Chao & Krueger, 2007). با توجه به اهمیت اقتصادی و محیط زیستی، پایش مستمر وضعیت و سطح زیرکشت نخلستان ها از اولویت های تحقیقات کشاورزی است.

روش های مرسوم برآورد سطح زیرکشت نخل خرما که بیش تر مبتنی بر آماربرداری های میدانی، سرشماری سنتی یا پرسشنامه های محلی است، علاوه بر هزینه بالا و زمان بردون، دقت مکانی پایینی دارد و اطلاعات آن به روز نیست (Rahnama et al., 2019). چنین روش هایی معمولاً پس از زمان طولانی از برداشت اطلاعات، گزارش می شوند و توانایی پوشش دقیق الگوهای مکانی در مناطق وسیع را ندارند (Mc & Nadaf, 2025). با توسعه فناوری های سنجش از دور، پایش اراضی کشاورزی به شکلی بی سابقه کارتر و دقیق تر شده است. مطالعات متعدد نشان داده اند که سنجش از دور می تواند به طور خودکار و سریع تغییرات کاربری و سلامت گیاهی را در مناطق گسترده فراهم آورد (Bagheri et al., 2020; Khanal et al., 2024). در پژوهش Li و همکاران (۲۰۲۵)، نشان داده شد که سنجش از دور یک «رویکرد کارآمد» برای پایش اراضی کشاورزی گسترده است که امکان ارزیابی سریع کاربری اراضی و سلامت گیاهی را فراهم می آورد (Li et al., 2025). این خصیصه، به ویژه در مدیریت منابع آب و خاک و برنامه ریزی کشاورزی منطقه ای، دارای اهمیت ویژه ای است. لذا استفاده از داده های ماهواره ای به جای روش های سنتی، علاوه بر پیوستگی مکانی و تکرارپذیری زمانی بالا، هزینه ها را نیز کاهش می دهد و امکان برنامه ریزی کارآمدتری را فراهم می سازد. هم چنین مطالعات داخلی و بین المللی متعددی به کاربرد سنجش از دور برای شناسایی نخل خرما و سایر درختان میوه پرداخته اند. برخی از پژوهش ها از تصاویر ماهواره های چندطیفی نظیر لندست یا سنتینل-۲ از شاخص های پوشش گیاهی رایج مانند NDVI، EVI و SAVI سود برده اند تا بین درختان خرما و پوشش های گیاهی دیگر تفکیک قائل شوند (Li et al., 2025). برای نمونه، مطالعات انجام شده در امارات متحده عربی نشان داده اند که مقادیر NDVI بین ۰/۱۸ تا ۰/۴۵ برای تفکیک تاج نخل خرما از سایر پوشش ها مفید است، هم چنین در این تحقیق، با استفاده از تصاویر لندست-۸ و تقسیم بندی شی محور، دقت کلی ۹۴/۵ درصد را در نقشه برداری نخلستان های خرما در امارات به دست آورده اند، این نتایج حاکی از آن است که حتی تصاویر با وضوح مکانی متوسط (۳۰ متر) در ترکیب با تکنیک های پیشرفته طبقه بندی می توانند به نقشه های دقیق نخیلات منجر شوند (Issa et al., 2020).

در بحث طبقه بندی و برآورد سطح زیرکشت محصولات کشاورزی، کیفیت و پیوستگی زمانی و مکانی تصاویر حائز اهمیت می باشد. دو سنجنده پرکاربرد برای پایش پوشش های گیاهی و کاربری اراضی، سنجنده های سنتینل-۱ (رادار) و سنتینل-۲ (اپتیکی) هستند. سنتینل-۲، دارای ۱۳ باند طیفی (شامل نواحی مرئی، نزدیک مادون قرمز و باندهای لبه قرمز) با تفکیک مکانی ۱۰ تا ۶۰ متر است و بازدید مکرر پنج روزه دارد که امکان رصد پویا را فراهم می کند (Saini & Ghosh, 2020).

(2018). ماهیت چندطیفی و تفکیک بالایی سنتینل-۲، آن را به ابزاری مناسب برای محاسبه شاخص‌های پوشش گیاهی و شناسایی گونه‌های گیاهی مختلف تبدیل کرده است (Jiang et al., 2025). در مقابل، سنجنده سنتینل-۱ با فناوری رادار (SAR) قادر است در هر شرایط آب‌وهوایی و با وضوح مکانی بالا (۱۰ متر) پوشش گیاهی را پایش کند (Sharif et al., 2022). بنابراین، استفاده هم‌زمان از سنتینل-۲ برای اطلاعات طیفی و سنتینل-۱ برای قابلیت نفوذ به ابرها و درون‌داد انرژی، پتانسیل بالایی در شناسایی دقیق پوشش نخیلات و سنجش تغییرات زمانی آن‌ها دارد (Luo et al., 2025).

در سال‌های اخیر، مدل‌های یادگیری ماشین نقش بسیار مهمی در طبقه‌بندی تصاویر سنجش از دور یافته‌اند. از جمله این مدل‌ها، جنگل تصادفی به دلیل ویژگی‌های برجسته‌ای مانند توانایی کار بر روی مجموعه داده‌های بزرگ، قابلیت رفع نویز، عدم نیاز به پیش‌فرض‌های پارامتری و امکان تعیین اهمیت ویژگی‌ها، محبوبیت یافته است (Ghodsi et al., 2021; Kazanskiy et al., 2025). مدل جنگل تصادفی به عنوان یک مدل طبقه‌بندی، در بسیاری از مطالعات سنجش از دور به کار رفته است. این مدل با ایجاد مجموعه‌ای از درخت‌های تصمیم‌گیری و تجمیع آرای آن‌ها، دقت بالایی در شناسایی کلاس‌های کاربری زمین به دست می‌دهد. در پژوهش Mohammadpour و همکاران (۲۰۲۲)، به منظور تهیه نقشه پوشش گیاهی منطقه لوسائ پرتغال، از جنگل تصادفی استفاده کردند و یادآور شدند که «جنگل تصادفی یکی از محبوب‌ترین مدل‌های نظارت‌شده است که بیش‌ترین دقت میانگین را (۸۵/۸۱ درصد) در مقایسه با سایر روش‌ها نشان داده است. هم‌چنین در مطالعه‌ای بر روی ارزیابی پارامتر تبخیر و تعرق مرجع با داده‌های سنجش از دور، نشان داده شد که مدل جنگل تصادفی نسبت به سایر مدل‌ها از دقت بالاتری برخوردار بود. مطالعه حاضر نشان داد که مدل جنگل تصادفی می‌تواند یک مدل مطمئن و نسبتاً دقیق برای پیش‌بینی ETo با استفاده از داده‌های سنجش از دوری برای مناطق فاقد آمار باشد (Azizi mobaser et al., 2025). بررسی پژوهش‌های پیشین نشان می‌دهد که مطالعات اندکی به‌طور ویژه بر پایش نخل خرما در زیر حوضه مارون-جراحی (واقع در جنوب غربی ایران) متمرکز شده‌اند. عمده پژوهش‌های مرتبط با این زیرحوضه بر مسایل هیدرولوژیکی و مدل‌سازی جریان آب تمرکز داشته‌اند. برای مثال، شفیعی و همکاران (۲۰۱۸) با استفاده از تصاویر TM و ETM ماهواره Landsat تغییرات کاربری اراضی زیرحوضه مارون را در بازه زمانی ۱۹۸۰ تا ۲۰۱۰ با مدل SWAT شبیه‌سازی کردند (Shafiei et al., 2018).

هم‌چنین، تاکنون در این منطقه از تصاویر سنتینل و مدل‌های یادگیری ماشین برای تفکیک دقیق نخلستان‌ها استفاده نشده است. بنابراین، به دلیل فقدان مدل‌های به‌روز برای طبقه‌بندی چندزمانه و خودکار نخلستان‌های خرما در این اقلیم خشک و نیمه‌خشک، این خلأ، به‌ویژه با توجه به اهمیت اقتصادی نخل خرما در استان‌های جنوبی کشور (مانند خوزستان) قابل توجه است. بررسی داده‌های قبلی نشان می‌دهد که بهره‌گیری از سنجنده‌های جدید و مدل‌های دقیق می‌تواند اطلاعات مؤثرتری از پراکنش مکانی نخلستان‌ها فراهم آورد.

مطالعه حاضر با هدف رفع خلأ موجود در پایش دقیق و روزآمد نخلستان‌های خرما در مناطق خشک و نیمه‌خشک، یک چارچوب نوین مبتنی بر پردازش ابری ارائه می‌دهد که بر ادغام هم‌زمان داده‌های چندمنبعی و چندزمانه استوار است. در این رویکرد، داده‌های اپتیک سنتینل-۲، داده‌های راداری سنتینل-۱ و مجموعه‌ای گسترده از شاخص‌های طیفی، راداری و حرارتی به‌صورت یکپارچه ترکیب شده‌اند تا امکان بازنمایی هم‌زمان ویژگی‌های طیفی، ساختاری و بافتی پوشش گیاهی فراهم شود. چنین ساختاری، نسبت به روش‌های تک‌منبعی یا مبتنی بر تصاویر منفرد، توانایی بیش‌تری در تفکیک و شناسایی الگوهای رشد نخلستان‌ها دارد و به‌ویژه برای کار در محیط‌های گرم و خشک که پوشش گیاهی از نظر طیفی پیچیدگی بالایی دارد، مناسب است. در این چارچوب، یکی از جامع‌ترین مجموعه متغیرهای پیشنهادی توسعه یافته که مشتمل بر ۳۶ ویژگی استخراج‌شده از داده‌های اپتیک، راداری و حرارتی است و به عنوان مبنای مدل طبقه‌بندی به کار می‌رود.

پلتفرم گوگل ارث انجین^۱ در این پژوهش برای استخراج، پالایش و پردازش سری های زمانی تصاویر چندسنسوری مورد استفاده قرار گرفته است و سپس فرایند طبقه بندی به کمک مدل جنگل تصادفی در محیط گوگل کولب انجام شده است. ترکیب شاخص های پوشش گیاهی با باندهای چندطیفی و اطلاعات ساختاری استخراج شده از داده های راداری، توانایی مدل را در تبیین تغییرات مکانی-زمانی نخل خرما در طول فصل رشد. افزایش می دهد و در عین حال اثر پوشش ابر را در داده های اپتیک کاهش می دهد. بهره گیری از زیرساخت های محاسبات ابری امکان پردازش کارآمد داده های حجیم چندساله را فراهم کرده و مسیر استفاده از این روش را برای پژوهش گرانی با منابع محدود نیز هموار می سازد. در نهایت، این رویکرد یک سامانه عملیاتی و قابل تعمیم برای تهیه نقشه پوشش گیاهی باغات خرما ارائه می کند که می تواند مبنایی قابل اتکا برای برنامه ریزی های زراعی، مدیریت منابع آب و تصمیم سازی های مرتبط با توسعه پایدار کشاورزی در جنوب غرب ایران باشد. این چارچوب با تأکید بر ادغام داده های چندطیفی، راداری و حرارتی، پاسخی مؤثر به نیازهای جدید پایش کشاورزی و جایگزینی مناسب برای روش های سنتی مبتنی بر برداشت میدانی محسوب می شود.

۲. روش شناسی پژوهش

۲.۱. منطقه مورد مطالعه

محدوده مورد مطالعه زیرحوضه آبخیز رودخانه مارون در جنوب غرب ایران و در محدوده جغرافیایی ۵۰ درجه و ۰۵ دقیقه تا ۵۱ درجه و ۱۱ دقیقه طول شرقی و ۳۰ درجه و ۳۹ دقیقه و ۳۱ درجه و ۲۱ دقیقه عرض جغرافیایی شمالی واقع شده است که دارای مساحتی حدود ۲۷۵۰ کیلومتر مربع و حداکثر ارتفاع در این حوضه ۳۴۸۳ متر و حداقل ارتفاع ۳۶۴ متر در نزدیکی سد مارون می باشد (Sharifi paichoon *et al.*, 2019; Zalaki Badili *et al.*, 2013). براساس طبقه بندی اقلیمی کوپن (Köppen, 1884)، این حوضه در ناحیه خشک قرار دارد. همچنین، حداقل، میانگین و حداکثر دمای سالانه به ترتیب برابر با ۶-، ۲۲/۸ و ۵۳/۳ درجه سانتی گراد بوده و میانگین بارش سالانه نیز ۶۴۶/۵۱ میلی متر گزارش شده است (Adib *et al.*, 2023; Adib *et al.*, 2021). در شکل (۱)، موقعیت جغرافیایی منطقه مورد مطالعه و کاربری اراضی منطقه نشان داده شده است.




Figure 1. Location of case study area and Landuse-Landcover

۲.۲. تصاویر ماهواره‌ای

در این مطالعه به منظور تهیه نقشه کشت، از تلفیق تصاویر اپتیک سنتینل-۲ و داده‌های راداری سنتینل-۱^۲ در طی دوره‌های ۱۴۰۰ تا ۱۴۰۳ استفاده شد. این مجموعه به‌دلیلی قدرت تفکیک مکانی ۱۰ متری و پیوستگی زمانی پنج روزه و دسترسی رایگان به داده‌ها، مناسب برای مطالعات کشاورزی به‌شمار می‌رود (Phiri et al., 2020; Torres et al., 2012). داده‌های سنتینل-۲ از نوع بازتابش سطحی^۳، محصول سطح بازتاب تصحیح‌شده جوی^۴ و داده‌های سنتینل-۱ از نوع (GRD)^۵ در مد تصویربرداری IW^۶ و مسیر نزولی^۷ انتخاب گردیدند. بازه زمانی تصاویر در دوره حداکثر رشد و بیش‌ترین تاج پوشش تعیین و فیلتر ابری کمتر از ۱۰ درصد برای تصاویر اپتیک اعمال شد تا کیفیت مکانی و طیفی داده‌ها بهبود یابد. تصاویر سنتینل-۲ پس از تصحیح جوی، با استفاده از روش ترکیب میانه^۸ به یک تصویر نماینده از دوره رشد محصولات تبدیل شدند. سپس داده‌های راداری سنتینل-۱ در قطبش‌های VV و VH به‌صورت میانگین محاسبه و برای استخراج ویژگی‌های ساختاری و رطوبتی گیاهان به کار گرفته شد. برای افزایش دقت شناسایی پوشش گیاهی، نسبت VV/VH نیز محاسبه گردید (Dobrinic et al., 2021; Felegari et al., 2021).

۳.۲. محاسبه شاخص‌های طیفی و راداری

به‌منظور تفکیک بین کلاس‌های مختلف زراعی و باغی و سطوح غیر زراعی شاخص‌های طیفی متداول و حساس به طول موج‌های مختلف در این پژوهش به کار گرفته شد. همچنین، داده‌های راداری سنتینل-۱ با قدرت نفوذ بالا به ساختار تاج گیاه و حساسیت به رطوبت سطحی، مکمل مناسبی برای داده‌های اپتیک محسوب می‌شوند. در جدول (۱)، ویژگی‌های هر شاخص نشان داده شده است.

Table 1. Spectral Indices introduction

Reference	Application	Equation	Spectral Indices
(Rokni & Musa, 2019)	Measuring the greenness and density of crops	$(\text{NIR}-\text{RED})/(\text{NIR}+\text{RED})$	NDVI
(Nițu et al., 2025)	A version of NDVI that uses red band instead of green band to measure its sensitivity to chlorophyll	$(\text{NIR}-\text{Green})/(\text{NIR}+\text{Green})$	GNDVI
(Ovakoglou et al., 2018)	For measuring the greenness of vegetation cover. It is more sensitive in region with denser vegetation cover and decrease effects of saturation	$2.5 * ((\text{NIR} - \text{RED}) / (\text{NIR} + 6 * \text{RED} - 7.5 * \text{BLUE} + 1))$	EVI
(Rondeaux et al., 1996)	It is applicable in region with scattered vegetation cover and able to refine soil adjustment	$((\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED} + 0.5)) * 1.5$	SAVI
(Steven, 1998)	More stability with reducing the sensitivity to the soil	$((\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED} + 0.16)) * 1.16$	OSAVI
(Jackson et al., 2004)	With differentiating water boundaries from other classes able to detect water boundaries and vegetation moisture, since water has high reflectance in green band and decline in NIR band	$(\text{Green}-\text{NIR})/(\text{Green}+\text{NIR})$	NDWI
(Chandrasekar et al., 2010)	It is sensitive to matter and changes in leaves. Low LSWI reveals water tension in crops	$(\text{NIR}-\text{SWIR1})/(\text{NIR}+\text{SWIR1})$	LSWI
(Gamal et al., 2020)	Focused on the sensitivity to the detailed changes in leaves density and crop growth and in Agricultural intelligent monitoring, able to detect crop's stress	$(\text{Rededge3}-\text{Rededge1})/(\text{Rededge3}+\text{Rededge1})$	MRENDVI
(Dash et al., 2010)	Estimates chlorophyll	$(\text{Rededge2} - \text{Rededge1}) / ((\text{Rededge1} - \text{RED}) + 1e-10)$	MTCI
(Nițu et al., 2025)	Relative to NDVI It is more applicable in cloudy and dusty atmosphere, Able to detect vegetation cover in polluted weather	$\text{NIR}-(\text{RED}-\gamma(\text{BLUE}-\text{RED}))/\text{NIR}+(\text{RED}-\gamma(\text{BLUE}-\text{RED}))$ $\gamma=1.7$	ARVI
(Nițu et al., 2025)	Physical quantity, per each area unity, measures one side of leaves	$3.618 * \text{EVI} - 0.118$	LAI
(Baugh & Groeneveld, 2006)	Works as a nonlinear measurements index for greenness	NIR/RED	RVI
(Wang et al., 2019)	Measures the amount of crop Chlorophyll and Nitrogen, specially in median and final stage of growth that Chlorophyll is high, has better sensitivity	$(\text{Rededge}-\text{NIR})/(\text{Rededge}+\text{NIR})$	NDRE

Continued table 1. Spectral Indices introduction

Reference	Application	Equation	Spectral Indices
(Cui <i>et al.</i> , 2019)	Measures Chlorophyll content	$(RED - BLUE) / RED$	CI
(Mao <i>et al.</i> , 2003)	Uses different visible bands to assert the different colours of vegetation cover	$18.78745 + 0.44 * RED - 0.88 * GREEN + 0.385 * BLUE$	CIVE
(Louhaichi <i>et al.</i> , 2001)	High sensitivity of this index to leaves' characteristics, make it more applicable to estimate chlorophyll	$(2 * GREEN - RED - BLUE) / (2 * GREEN + RED + BLUE)$	GLI
(Bendig <i>et al.</i> , 2015)	Used for comparing vegetation covers in different variety and texture conditions.	$(GREEN^2 - RED^2) / (GREEN^2 + RED^2)$	MGRVI
(Yang <i>et al.</i> , 2008)	Gives information about the photosynthesis and leaves health	$(GREEN - RED) / (GREEN + RED)$	MPRI
(McNaim & Protz, 2014)	Used for measuring chlorophyll	$128 * ((GREEN - RED) / (GREEN + RED) + 1)$	NDI
(Bendig <i>et al.</i> , 2015)	Revised and generalized version of MRGVI	$(GREEN^2 - RED * BLUE) / (GREEN^2 + RED * BLUE)$	RGBVI
(Gitelson <i>et al.</i> , 2002)	To separate crop class from other classes	$(GREEN - RED) / (GREEN + RED - BLUE)$	VARI
(Woebbecke <i>et al.</i> , 1995)	By using green, blue, and red bands helps to separate vegetation cover from background	$(GREEN - BLUE) / (RED - GREEN)$	WI
Reference	Application	Equation	Relative Indices
(Yang <i>et al.</i> , 2022)	Investigating chlorophyll changes and nitrogen condition in crop	$NIR / (RED + 1e-10)$	SR
(Taha <i>et al.</i> , 2024)	Estimating chlorophyll and nitrogen in crop	$GREEN / (NIR + 1e-10)$	Green-Ratio
(Carracelas <i>et al.</i> , 2024)	Assessing crop health and investigating the effects of tension on chlorophyll and nitrogen changes in crop	$RE1 / (RE2 + 1e-10)$	Re-ratio
Reference	Application	Equation	Radar Indices
(Vreugdenhil <i>et al.</i> , 2018)	Supplementary index in region with high cloudiness that optical sensing have error and disorder	VV	VV
(Vreugdenhil <i>et al.</i> , 2018)	To monitor vegetation cover growth, specifically in the periods that biomass is enhancing	VH	VH
(Vreugdenhil <i>et al.</i> , 2018)	To differentiate cultivation methods or monitoring phenology stages	VV/VH	VV-VH-Ratio
Reference	Application	Equation	Thermal Indices
(Chen <i>et al.</i> , 2024)	Displaying land surface temperature for detecting cities/agricultural hot/cold regions	Mean Land surface Temperature in period of time	Mean LST
(Mohamed <i>et al.</i> , 2020)	Identifying hot regions and potential areas for thermal tension	Maximum Land surface Temperature	Max LST
(Vani <i>et al.</i> , 2018)	Identifying cold regions	Minimum Land surface Temperature	Min LST
(Abderrazak <i>et al.</i> , 2002)	Estimation of soil moisture and dryness tension	$TVDI = (Mean_LST - Min_LST) / (Max_LST - Min_LST)$	TVDI
(Zheng <i>et al.</i> , 2024)	Displaying vegetation's thermal condition and relative soil moisture	$VTI = (Mean_LST - Min_LST) / (Max_LST - Min_LST)$	VTI
(Aliabad <i>et al.</i> , 2024; Yin <i>et al.</i> , 2014)	Evaluating thermal capacity and day and night temperature change, Detecting regions with high thermal exchange	$DeltaT = MODIS_Day_C - MODIS_Night_C$	Delta T (MODIS day-night)

۴.۲. داده های میدانی

در سال های زراعی ۱۴۰۰ تا ۱۴۰۳ و در راستای اجرای مأموریت نقشه برداری اراضی، داده های میدانی مربوط به مزارع واقع در شهرستان های زیرحوضه مارون-جراحی در استان خوزستان توسط تیم های مهندسی و پژوهشگران جهاد کشاورزی استان، با همکاری مالکان و کشاورزان محلی، جمع آوری شد. مختصات نخلستان های خرما شناسایی شده در این بازدیدهای میدانی توسط کارشناسان در جدول (۲) ارائه شده است.

Table 2. General characteristics of pilots

Region	Crop Class	Y	X
Ramshir	Date-Palm	3416588	340511
Shadegan		3396840	278971
Mahshahr Port		3406409	333194

داده های نمونه آموزشی^۹ برای کلاس خرما و کلاس های پس زمینه مانند خاک و آب از طریق برداشت میدانی و تفسیر بصری تصاویر گوگل ارث تهیه و در قالب فایل های CSV وارد محیط گوگل ارث انجین^{۱۰} گردید. برای انجام

طبقه‌بندی نظارت‌شده محصولات کشاورزی، نمونه‌های آموزشی و آزمون از داده‌های میدانی انتخاب شدند. نمونه‌های آموزشی تنها برای ساخت مدل اولیه طبقه‌بندی مورد استفاده قرار گرفتند، درحالی‌که نمونه‌های آزمون برای ارزیابی دقت، صحت و قابلیت اعتماد روش‌های طبقه‌بندی به کار رفتند. در این مطالعه، ۷۰ درصد از داده‌های میدانی به صورت تصادفی انتخاب و به عنوان داده‌های آموزشی مورد استفاده قرار گرفت و بخش باقی‌مانده برای آزمون اختصاص یافت. جزئیات مربوط به تعداد نمونه‌های آموزشی هر کلاس محصول در جدول (۳) ارائه شده است. داده‌ها به صورت تصادفی به دو بخش آموزشی (۷۰ درصد) و ارزیابی (۳۰ درصد) تقسیم شدند. طبقه‌بندی براساس ۳۶ باند و شاخص شامل باندهای اصلی سنتینل-۲، شاخص‌های طیفی محاسبه‌شده، سه باند راداری (VH، VV و VV/VH Ratio) و شاخص‌های حرارتی انجام گرفت.

Table 3. Train and test

Crop Class	Date
Total Samples	949
Training Samples	665

۵.۲. مدل طبقه‌بندی

روش‌های طبقه‌بندی تجمیعی^{۱۱} از جمله رویکردهای پیشرفته در یادگیری ماشین هستند که به جای استفاده از یک کلاس منفرد، مجموعه‌ای از کلاس‌ها را به کار می‌گیرند و نتیجه نهایی را براساس رأی‌گیری میان خروجی‌های آن‌ها تعیین می‌کنند. این روش‌ها در سال‌های اخیر به دلیل دقت بالا و پایداری نتایج، جایگاه ویژه‌ای در تحلیل داده‌های سنجش از دور یافته‌اند. از میان مهم‌ترین روش‌های تجمیعی می‌توان به بگینگ^{۱۲}، بوستینگ^{۱۳} و جنگل تصادفی اشاره کرد (Jafarzadeh *et al.*, 2021; Zhang *et al.*, 2022). در روش بگینگ، از مجموعه داده آموزشی، چندین نمونه تصادفی با جایگذاری برداشت می‌شود و برای هر یک از این نمونه‌ها، یک درخت تصمیم به طور مستقل ساخته می‌شود. سپس، پیش‌بینی نهایی با رأی اکثریت درخت‌ها تعیین می‌گردد. این روش سبب کاهش واریانس مدل می‌شود و در برابر نوسانات داده‌ها عملکرد پایدارتری دارد (Liaw & Wiener, 2002). در روش بوستینگ، فرایند آموزش به صورت تکراری انجام می‌شود. در هر تکرار، وزن نمونه‌هایی که در مرحله قبل به درستی طبقه‌بندی نشده‌اند افزایش می‌یابد تا در مراحل بعدی اهمیت بیش‌تری پیدا کنند. این سازوکار باعث کاهش هم‌زمان بایاس و واریانس مدل می‌شود و در بسیاری از موارد دقت بالاتری نسبت به بگینگ دارد، هرچند که سرعت اجرای آن کم‌تر بوده و نسبت به نویز داده‌ها حساس‌تر است (Gislason *et al.*, 2006).

۵.۲.۱. مدل جنگل تصادفی

مدل جنگل تصادفی، نسخه‌ای پیشرفته از بگینگ است که عنصر تصادفی‌سازی در انتخاب ویژگی‌ها را نیز وارد فرایند یادگیری می‌کند (Breiman, 2001). در این روش، در هر گره از درخت، به جای جست‌وجوی بهترین تقسیم میان تمام متغیرها، تنها از میان یک زیرمجموعه تصادفی از متغیرها بهترین تقسیم انتخاب می‌شود. برای ساخت هر درخت، نمونه‌ای تصادفی با جایگذاری از داده‌های آموزشی انتخاب شده و درخت بدون هرس^{۱۴} با استفاده از انتخاب تصادفی ویژگی‌ها رشد می‌کند (Archer & Kimes, 2008; Breiman, 2001). به کارگیری این روش موجب شده که جنگل تصادفی در مقایسه با بسیاری از مدل‌های متداول مانند تحلیل تشخیصی، ماشین‌های بردار پشتیبان و شبکه‌های عصبی، از دقت بالاتری برخوردار باشد (Cutler *et al.*, 2007; Liaw & Wiener, 2002). افزون بر این، جنگل تصادفی از سرعت

بالای محاسباتی برخوردار است، به طوریکه در برابر بیش برآزش مقاومت داشته و امکان ساخت تعداد دلخواهی درخت را برای کاربر فراهم می کند (Cutler et al., 2007).

در اجرای مدل جنگل تصادفی، تعیین دو پارامتر اولیه: تعداد درخت ها (N) و (m) تعداد متغیرهایی که در هر گره برای انتخاب بهترین تقسیم در نظر گرفته می شوند، ضروری است. معمولاً از ۲/۳ داده های آموزشی برای ساخت مدل و از ۱/۳ باقی مانده، موسوم به داده های خارج از نمونه^{۱۵}، برای برآورد خطای مدل استفاده می شود. برای هر نمونه بوت استرپ، یک درخت بدون هرس ساخته می شود که در هر گره آن، m متغیر به صورت تصادفی انتخاب شده و بهترین تقسیم از میان آن ها انجام می گیرد. انتخاب تعداد مناسب متغیرها از اهمیت زیادی برخوردار است، زیرا باید میان کاهش همبستگی درخت ها و افزایش قدرت پیش بینی تعادل برقرار شود (Horning, 2010). براساس پیشنهاد بریمن (۲۰۰۲)، انتخاب تعداد متغیرها برابر با جذر تعداد کل متغیرها ($\sqrt{M}$) معمولاً نتایج بهینه ای به همراه دارد (Breiman, 2002).

جنگل تصادفی برای ساخت درخت ها از مدل درخت تصمیم طبقه بندی و رگرسیون کارت^{۱۶} استفاده می کند (Breiman, 2002). در این مدل، تقسیم در هر گره براساس معیارهایی مانند شاخص جینی^{۱۷} انجام می شود. بهره گیری از چنین رویکردی موجب افزایش دقت طبقه بندی، کاهش خطای مدل و پایداری نتایج در داده های پیچیده و ناهمگون می شود.

۲.۶. ارزیابی صحت مدل های یادگیری ماشین در طبقه بندی تصاویر

۲.۶.۱. صحت کلی

صحت کلی یکی از شاخص های استاندارد برای ارزیابی دقت طبقه بندی است و نشان می دهد چه درصدی از کل نمونه ها به درستی طبقه بندی شده اند. این شاخص با جمع مقادیر قطر اصلی ماتریس درهم ریختگی تقسیم بر تعداد کل نمونه ها محاسبه می شود (Aziz et al., 2024). صحت کلی به صورت رابطه (۱)، تعریف می شود.

$$\text{Overall Accuracy} = \frac{N_{\text{Correct}}}{N_{\text{total}}} \quad (\text{رابطه ۱})$$

که در آن، N_{Correct} تعداد نمونه های درستی است که به درستی طبقه بندی شده اند، N_{total} کل تعداد نمونه ها است.

۲.۶.۲. ماتریس درهم ریختگی^{۱۸}

ماتریس درهم ریختگی، ماتریسی است که تعداد نمونه های پیش بینی شده برای هر کلاس را در مقابل مقادیر واقعی آن ها نمایش می دهد. در این ماتریس، معمولاً سطرها نشان دهنده کلاس های پیش بینی شده و ستون ها نمایانگر کلاس های واقعی هستند، و مقادیر سلول های قطر اصلی (i,i) تعداد نمونه هایی را نشان می دهند که به درستی طبقه بندی شده اند (Nicolau et al., 2024). به دلیل الگوی خطاها در این ماتریس امکان شناسایی کلاس هایی که اغلب با یکدیگر اشتباه گرفته شده اند را فراهم می کند (Feizizadeh et al., 2022a). ساختار کلی ماتریس درهم ریختگی به صورت رابطه (۲)، تعریف می شود:

$$\text{Confusion Matrix} = \begin{bmatrix} \text{False Positive (FP)} & \text{True Positive (TP)} \\ \text{True Negative (TN)} & \text{False Negative (FN)} \end{bmatrix} \quad (\text{رابطه ۲})$$

که در آن:

True Positive (TP): تعداد نمونه هایی که به درستی به کلاس مورد نظر اختصاص یافته اند.

False Positive (FP): تعداد نمونه هایی که به نادرست به کلاس مثبت اختصاص یافته اند.

False Negative (FN): تعداد نمونه هایی که متعلق به کلاس هدف بوده اند، اما توسط مدل شناسایی نشده اند.

True Negative (TN): تعداد نمونه هایی که به درستی به کلاس نادرست طبقه بندی شده اند.

۳.۶.۲ Precision

دقت معیاری برای سنجش توانایی مدل در پیش‌بینی درست نمونه‌های مثبت است و نشان می‌دهد از میان نمونه‌هایی که مدل به‌عنوان متعلق به یک کلاس خاص پیش‌بینی کرده است، چه نسبتی واقعاً به آن کلاس تعلق دارند (Foody, 2023).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (\text{رابطه ۳})$$

۴.۶.۲ Recall

توانایی مدل در شناسایی نمونه‌های واقعی یک کلاس را نشان می‌دهد و بیان می‌کند چه درصدی از نمونه‌های متعلق به کلاس هدف، توسط مدل به درستی تشخیص داده شده‌اند:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (\text{رابطه ۴})$$

که در آن، FN تعداد نمونه‌هایی است که به کلاس هدف تعلق داشته‌اند اما توسط مدل شناسایی نشده‌اند (Foody, 2023).

۵.۶.۲ F1-Score

برای ارزیابی جامع‌تر عملکرد مدل، شاخص F1-Score نیز محاسبه شد که میانگین هارمونیک دقت و بازیابی است. دقت بیانگر درصد نمونه‌های مثبت پیش‌بینی‌شده که واقعاً مثبت بودند و بازیابی نسبت نمونه‌های واقعی مثبت شناسایی‌شده توسط مدل را نشان می‌دهد (Zheng et al., 2024).

معیار F1-Score به‌صورت میانگین هارمونیک دقت و بازیابی تعریف می‌شود:

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{رابطه ۵})$$

۶.۶.۲ ضریب کاپا^{۱۹}

ضریب کاپا معیاری آماری است که میزان توافق بین نتایج طبقه‌بندی و داده‌های مرجع را اندازه‌گیری می‌کند و اثر توافق تصادفی را کاهش می‌دهد (Feizizadeh et al., 2022b). مقدار کاپا بین -۱ و +۱ نوسان می‌کند، به‌گونه‌ای که $\kappa=1$ نشان‌دهنده توافق کامل، $\kappa=0$ نشان‌دهنده توافق معادل با شانسی و مقادیر منفی نشان‌دهنده توافق کمتر از شانسی است.

$$\text{Kappa} = \frac{P_0 - P_e}{1 - P_e} \quad (\text{رابطه ۶})$$

طبق رابطه (۶)، در آن:

P_0 : برابر است با تعداد نمونه‌های به‌درستی طبقه‌بندی‌شده تقسیم بر کل تعداد نمونه‌ها؛

P_e : برابر است با مجموع حاصل‌ضرب‌های تعداد واقعی نمونه‌ها و تعداد پیش‌بینی‌شده در هر دسته، تقسیم بر مجذور کل تعداد نمونه‌ها (Zhan et al., 2024).

۳. یافته‌های پژوهش و بحث

۳.۱. بررسی عملکرد شاخص‌های گیاهی، طیفی و راداری در تشخیص نخلستان‌های خرما

شکل (۲)، ارزیابی اهمیت شاخص‌ها برای شناسایی نخلستان‌های خرما، نتایج حاصل از سه گروه شاخص‌های راداری، طیفی و حرارتی نشان می‌دهد که هر یک از این منابع اطلاعاتی نقش ویژه و در عین حال مکملی در بهبود فرایند طبقه‌بندی ایفا می‌کنند. این هم‌افزایی میان ویژگی‌های ساختاری، زیستی و فیزیولوژیک سبب شده است که مدل نهایی

از دقت و پایداری بالایی برخوردار باشد. لازم به توضیح است که مبنای تعیین اهمیت شاخص‌ها، خروجی بخش featureImportance در تابع explain() مدل جنگل تصادفی در گوگل ارث انجین است. این مقادیر بیانگر سهم هر ویژگی در کاهش خطای شاخه‌بندی در درخت‌ها بوده و پس از محاسبه، به درصد نرمال‌سازی شده‌اند. بنابراین محدوده اهمیت در تمام نمودارها به صورت صفر تا ۱۰۰ درصد تعریف می‌شود. هرچه عدد ارائه‌شده برای یک شاخص بالاتر باشد، نقش آن در بهبود عملکرد مدل بیش‌تر است. در شکل (۲) محور افقی دارای واحد نیست و تنها شماره‌گذاری شاخص‌های مختلف به ترتیب ورود در مدل است و صفر به عنوان اولین شاخص به صورت خودکار اختصاص یافته است. تفاوت دامنه محور عمودی میان سه نمودار نیز ناشی از تفاوت میزان اهمیت نسبی هر گروه و تعداد شاخص‌های داخل آن است، زیرا هر گروه به صورت جداگانه نرمال‌سازی شده و دامنه تغییرات آن مستقل از گروه دیگر است.




Figure 2. The Importance of the spectral, radar, and thermal indicator groups in identifying date palm plantations

۳.۱.۱. شاخص‌های راداری

تحلیل ویژگی‌های راداری سنتینل-۱ نشان داد که این دسته در مجموع حدود ۳۵ درصد از اثرگذاری کل مدل را شامل می‌شود. در میان این ویژگی‌ها، قطبش VH بیش‌ترین سهم را داشته و به‌تنهایی حدود ۲۰ درصد از اثر کلی مدل و بیش از ۶۰ درصد از کل سهم رادار را تشکیل داده است. حساسیت بالای باند VH به ساختار عمودی، زبری سطح و رطوبت اندام‌های گیاهی سبب شده است که این باند عملکرد ممتاز و پایداری در تشخیص تاج و سامانه ساختاری نخل‌ها را داشته باشد. باند VV سهمی در حدود ۱۰ درصد دارد و نسبت VV/VH نقش محدودتری (کم‌تر از ۵ درصد) نشان داده که این نسبت بیش‌تر برای سطوح بدون پوشش یا خاکی مناسب است و برای پوشش‌های درختی و متراکم مانند نخلستان کارایی کم‌تری دارد. در مطالعه‌ای که به‌منظور نقشه‌برداری درختان نخل در مزارع پالم در گابن، آفریقا انجام

شد، نتایج نشان داد که باند VH به دلیل پراکندگی حجمی ناشی از تاج پالم اهمیت زیادی دارد و می‌تواند در تفکیک پالم از جنگل یا سایر پوشش‌ها مورداستفاده قرار گیرد (Ballester-Berman & Rastoll-Gimenez, 2021). همچنین در پژوهش دیگری در کرواسی، گزارش شد که باند VH به‌تنهایی قادر است طبقه‌بندی پوشش گیاهی را با دقت بالا انجام دهد. این شواهد تأیید می‌کنند که اطلاعات ساختاری نهفته در قطبش VH ابزار مؤثری برای شناسایی نخل‌هاست.

۳.۱.۲. شاخص‌های طیفی

شاخص‌های طیفی با سهمی نزدیک به ۵۰ درصد، مهم‌ترین نقش را در مدل ایفا کرده‌اند. ترکیب باندهای اصلی و شاخص‌های گیاهی حساسیت بالایی به ویژگی‌های زیستی و فیزیولوژیکی نخل‌ها نشان داده است. باندهای B11 (SWIR1)، B4، B3 و B2 در مجموع حدود ۲۵ درصد از اثرگذاری را شامل شده‌اند. اهمیت بالای این باندها به دلیل واکنش قوی آن‌ها به رطوبت، کلروفیل و تشخیص سایه‌های سنگین تاج از پس‌زمینه خاک است. باندهای Red-Edge (شامل B5، B6 و B7) نیز حدود ۱۰ درصد سهم داشته‌اند و به دلیل حساسیت بالا به غلظت کلروفیل و پایداری سبزینه عملکرد مطلوبی در تشخیص نخل‌ها از سایر پوشش‌ها ارائه کرده‌اند.

از سوی دیگر، ترکیب شاخص‌هایی مانند EVI، ARVI، WWI، NDWI و GREEN_RATIO جمعاً حدود ۱۵ درصد از اثرگذاری کل را تشکیل داده است و توانسته‌اند رطوبت برگ، وضعیت کلروفیل و تراکم عمودی تاج را به‌خوبی منعکس کنند. در مقابل، شاخص‌هایی چون SAVI، VARI، GLI و MRENDVI سهم کم‌تر از ۵ درصد داشته‌اند و برای پوشش‌های درختی، کارایی محدودتری نشان داده‌اند. این نتایج در مطالعات دیگر نیز تأیید شده‌اند؛ مثلاً در پژوهشی درباره نقشه‌برداری پالم بتل (betel palm) در جزیره هاینان (Hainan)، مدل ترکیبی سنتینل ۲/۱ از باند B11، باندهای Red-Edge و شاخص‌هایی مانند EVI و NDMI استفاده شده است و به دقت بالایی در تفکیک درختان نخل رسیده است (Luo et al., 2025). همچنین در پژوهشی دیگر، در مرداب‌های بزرگ آمانزول (GAP) در کشور غنا نشان داد که باند SWIR1 (همان B11) بیش از سایر شاخص‌های طیفی اهمیت دارد، زیرا منعکس‌کننده رطوبت و خصوصیات ساختاری گیاهی است (Amoakoh et al., 2024).

۳.۱.۳. شاخص‌های حرارتی

شاخص‌های حرارتی حدود ۱۵ درصد از اثرگذاری کل مدل را به خود اختصاص داده‌اند. اگرچه سهم آن‌ها کم‌تر از دو دسته دیگر است، اما نقش آن‌ها هدفمند، تکمیلی و بسیار مؤثر بوده است. شاخص DeltaT مهم‌ترین ویژگی این بخش بوده و حدود ۸ درصد از اثر کلی مدل و بیش از ۵۰ درصد از سهم حرارتی را شامل شده است. این شاخص با بازتاب تفاوت دمای روز و شب، اثر تبخیر-تعرق بالا، سایه‌اندازی تاج و ظرفیت حرارتی ویژه نخل‌ها را نمایان می‌کند. اهمیت بالای DeltaT با نتایج پژوهش انجام‌شده در جنوب سوماترا، اندونزی مطابقت دارد، نتایج نشان داد که دمای سطح در مزارع نخل در مقایسه با کشت‌های دیگر متفاوت است، که ناشی از ظرفیت تبخیر، سایه تاج و خصوصیات حرارتی نخل‌هاست (Putra & Kusratmoko, 2021). همچنین در مطالعه دیگری، همبستگی دینامیک زمانی بین شاخص سطح برگ (LAI) و LST نشان داده شد که تغییرات LAI (در دوره رشد گیاه) تأثیر معناداری بر الگوی دمایی دارد (Ahmed et al., 2024). شاخص‌های VTI و Mean_LST نیز مجموعاً حدود ۵ درصد سهم داشته‌اند و الگوهای پایدار حرارتی نخلستان‌ها را آشکار کرده‌اند. در مقابل، شاخص‌هایی مانند Max_LST و TVDI سهم بسیار اندکی (کم‌تر از ۲ درصد) داشته‌اند، زیرا این شاخص‌ها بیش‌تر برای پایش خشک‌سالی و تشخیص سطوح بدون پوشش مناسب‌اند و در شناسایی

پوشش‌های دائمی با تبخیر- تعرق فعال، مانند خرما، عملکرد کم‌تری دارند. مقایسه سه دسته نشان می‌دهد که داده‌های طیفی با پوشش ۵۰ درصد مهم‌ترین منبع اطلاعاتی برای شناسایی نخل‌ها بوده‌اند، رادار با ۳۵ درصد نقش ساختاری و مکمل اساسی ایفا کرده است و حرارتی با ۱۵ درصد بیش‌ترین کمک را در تمایز فیزیولوژیک و حرارتی محصول داشته است. این ترکیب سه‌گانه، یک مدل مستحکم و چندمنبعی برای شناسایی دقیق نخلستان‌ها فراهم می‌آورد.

۲.۳. بررسی دقت مدل جنگل تصادفی در شناسایی نخلستان‌ها و برآورد سطح زیر کشت

در این مطالعه مدل جنگل تصادفی برای طبقه‌بندی کاربری زمین بر مبنای تصاویر ماهواره‌ای به‌منظور شناسایی نخلستان‌های خرما به‌کار گرفته شد. برای ارزیابی عملکرد مدل از معیارهای صحت کلی و ضریب کاپا، precision، Recall، F1-Score استفاده شد. در بررسی دقیق عملکرد مدل، تمرکز اصلی بر کلاس نخلستان خرما بود. ماتریس درهم‌ریختگی (شکل ۳) نشان داد درصد زیادی از پیکسل‌های نخلستان با دقت بالا شناسایی شده‌اند.

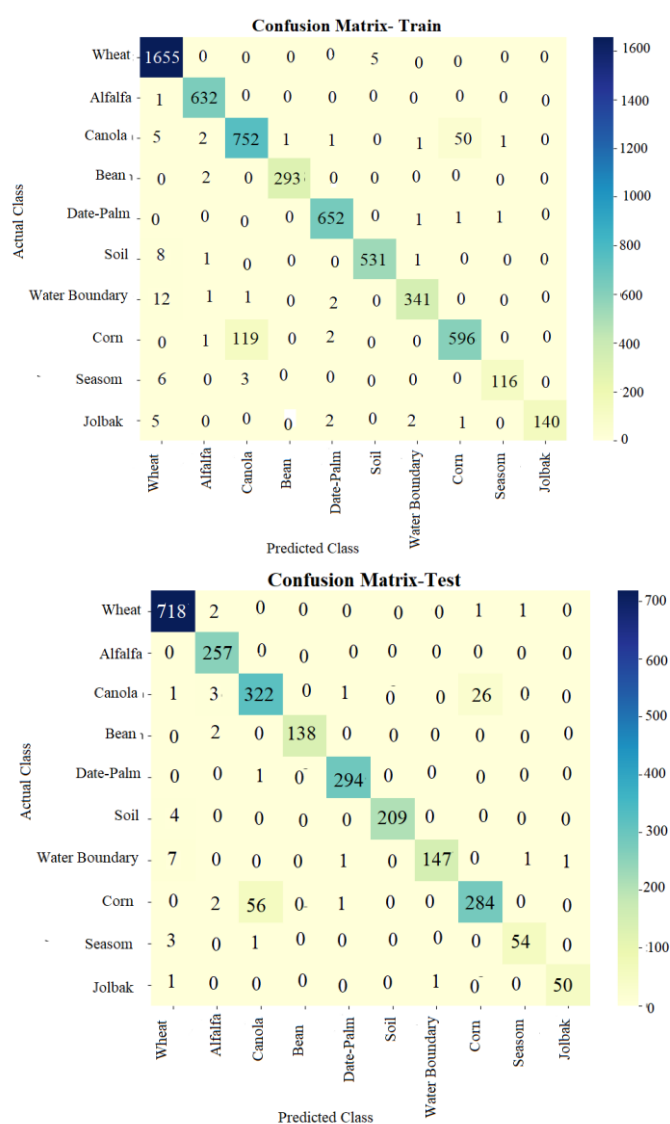


Figure 3. The confusion matrix of the training and test data for the reference date-palm pixels

بر این اساس، مدل جنگل تصادفی توانست نخلستان‌های خرما را به‌خوبی از سایر پوشش‌ها (مانند باغ‌ها یا پوشش‌های گیاهی دیگر) تفکیک کند، هرچند برخی تشابه‌های طیفی بین نخل و گونه‌های گیاهی مشابه چالش‌برانگیز بود. در داده‌های آموزشی، از مجموع ۶۵۵ نمونه مربوط به کلاس خرما، تعداد ۶۵۲ نمونه به‌درستی شناسایی شده و تنها سه نمونه با سایر کلاس‌های گیاهی (نظیر خاک یا ذرت) اشتباه گرفته شده است. این نتیجه دلالت بر دقت تولیدکننده‌ای در حدود ۹۹ درصد دارد، به این معنا که تقریباً تمام پیکسل‌های واقعی نخلستان توسط مدل به‌درستی شناسایی شده‌اند. در داده‌های آزمون نیز، ۲۹۴ نمونه از ۲۹۶ نمونه خرما به‌درستی طبقه‌بندی شده‌اند (دقت تولیدکننده ۹۹ درصد) و تنها دو نمونه در هم‌پوشانی طیفی با سایر کلاس‌ها قرار گرفته‌اند. این پایداری بین داده‌های آموزش و آزمون، بیانگر تعمیم‌پذیری بالای مدل و نبود بیش‌برازش است (Belgiu & Drăguț, 2016; Breiman, 2001). این نتایج با نتایج پژوهش‌های انجام‌شده نیز منطبق است؛ برای مثال فرناندز و همکاران (۲۰۲) دریافتند جنگل تصادفی صحت کلی ۸۵ درصد و ضریب کاپای ۰/۸۲ در شناسایی درختان خرما (تحت تصاویر پهباد) داشته است (Tagle Casapia et al., 2020). به‌همین ترتیب، داهی و همکاران (۲۰۲۱) در مطالعه‌ای در امارات برای نقشه‌برداری نخلستان‌های پراکنده به دقت کلی تا ۹۴/۵ درصد و ضریب کاپای ۰/۸۸ رسیدند (Dahy et al., 2021). نتایج نشان داد که مدل جنگل تصادفی در تفکیک نخلستان‌های خرما از سایر کاربری‌ها در منطقه نیمه‌خشک زیرحوضه مارون-جراحی عملکردی بسیار مطلوب دارد. در داده‌های آموزشی، مدل توانست تقریباً تمامی پیکسل‌های مربوط به کلاس خرما را به‌درستی شناسایی کند، به‌طوری‌که نرخ شناسایی صحیح به بیش از ۰/۹۸ رسید و میزان خطاهای تداخلی با سایر کلاس‌ها، بسیار ناچیز بود. این امر نشان‌دهنده توان بالای مدل در بهره‌گیری از تفاوت‌های ظریف طیفی میان تاج نخل و سایر گونه‌های گیاهی است؛ تفاوت‌هایی که به‌ویژه در باندهای NIR و SWIR و شاخص‌های گیاهی ترکیبی (مانند NDVI و OSAVI) نمود می‌یابند. در چنین مناطقی که الگوهای کشت متراکم و تغییرات فصلی شدید است، پایداری این دقت نشان می‌دهد مدل نه‌تنها دچار بیش‌برازش نشده بلکه ساختار تصادفی آن توانسته تعادل مناسبی میان دقت و تعمیم‌پذیری برقرار کند.

در این پژوهش، مطابق جدول (۴)، عملکرد مدل جنگل تصادفی در شناسایی نخلستان‌ها نسبت به سایر کلاس‌های کاربری-پوشش زمین به‌طور چشم‌گیری بالاتر بوده است. نتایج حاصل از داده‌های آزمون نشان می‌دهد که صحت کلی مدل در طبقه‌بندی نهایی ۹۵ درصد و ضریب کاپا ۰/۹۴ بود که بیانگر سطح توافق بسیار بالا و قابل اتکا میان نتایج مدل و واقعیت زمینی است. به‌ویژه برای کلاس نخلستان (dates)، شاخص‌های ارزیابی شامل Precision، Recall و F1-score همگی در حدود ۰/۹۹ قرار گرفتند که نشان‌دهنده توانایی بسیار بالای مدل در شناسایی صحیح نخلستان‌ها و حداقل بودن موارد طبقه‌بندی اشتباه نسبت به سایر کلاس‌هاست. این موضوع به‌خوبی بیانگر تمایزپذیری مناسب ویژگی‌های طیفی و راداری نخلستان‌ها در تصاویر سنتینل و هم‌چنین کارایی بالای مجموعه شاخص‌های مورد استفاده است. همین الگو در داده‌های آموزش نیز مشاهده می‌شود، به‌طوری‌که صحت کلی و ضریب کاپا هر دو ۰/۹۵ بوده و مقادیر Precision، Recall و F1-score برای نخلستان‌ها به‌ترتیب ۰/۹۹-۰/۹۸ به‌دست آمد. پایداری این مقادیر بین داده‌های آموزش و آزمون نشان می‌دهد که مدل دچار بیش‌برازش نشده و توانایی تعمیم آن برای مناطق مشابه بسیار مطلوب است. مطالعه Orynbaikyzy و همکاران (۲۰۱۹) تأکید کرده است که ترکیب شاخص‌های گیاهی مانند NDVI، EVI و SAVI با داده‌های راداری در مدل جنگل تصادفی می‌تواند صحت طبقه‌بندی محصولات زراعی را به‌طور قابل‌توجهی افزایش دهد (Orynbaikyzy et al., 2019). در مجموع، می‌توان نتیجه گرفت که مدل جنگل تصادفی، با توجه به دقت بسیار بالا در تفکیک نخلستان‌ها نسبت به سایر کلاس‌ها، گزینه‌ای قابل اعتماد برای نقشه‌برداری و پایش مکانی-زمانی نخلستان‌ها در مقیاس‌های حوضه‌ای و منطقه‌ای به‌شمار می‌آید.

Table 4. Accuracy results of the machine learning models in identifying date-palm plantations

ML Model	Train					Test				
	Precision	Recall	F1-score	Overall Accuracy	Kappa Coefficient	Precision	Recall	F1-score	Overall Accuracy	Kappa Coefficient
Random Forest	0.98	0.99	0.99	0.95	0.95	0.99	0.99	0.99	0.95	0.94

مطابق جدول (۵)، نتایج برآورد سطح زیرکشت نخل خرما در حوضه مارون-جراحی نشان داد که مدل جنگل تصادفی توانسته است سطح نخلستان ها را با دقت مطلوبی تخمین بزند. مقدار واقعی سطح نخلستان ها ۱۹۷۵۵/۲۶ هکتار و مقدار برآوردی ۲۱۷۶۴/۵۵ هکتار به دست آمد که منجر به بایاس ± 0.101 (معادل بیش برآوردی حدود ۱ درصد) شد. این مقدار خطا در مقیاس حوضه نشان دهنده دقت بالا و قابلیت اعتماد مدل در شناسایی نواحی نخل کاری است. بیش برآوردی اندک مدل احتمالاً ناشی از تداخل طیفی نخل با سایر باغات، سایه تاج پوش در تصاویر اپتیک، و یا توزیع غیریکنواخت نمونه های آموزشی بود. با این حال، عملکرد مدل در سطح حوضه بسیار رضایت بخش ارزیابی می شود. در شکل (۵)، جانمایی مزارع توسط مدل جنگل تصادفی نمایش داده شده است.

Table 5. Comparison of the estimated cultivated area based on machine learning models with the actual value

Area estimation	Date	Bias
Actual Area	19755.26	
Random Forest	21764.553	0.101




Figure 4. Spatial distribution of date palm plantations in the Maroon-Jarahi Basin based on the Random Forest model

۴. نتیجه گیری

یافته های این پژوهش نشان داد که ترکیب داده های چندزمانه سنتینل-۱ و سنتینل-۲ در کنار مدل جنگل تصادفی، چارچوبی کارآمد و قابل اعتماد برای شناسایی نخلستان های خرما و برآورد سطح زیرکشت آن ها در مناطق خشک و نیمه خشک فراهم می کند. برتری مدل جنگل تصادفی، که با صحت کلی ۹۵ درصد و ضریب کاپای ۰/۹۴ همراه بود، در کنار نقش مکمل شاخص های طیفی، راداری و حرارتی بیانگر آن است که پایش نخیلات مبتنی بر داده های سنجنش از دور

می‌تواند جایگزینی دقیق‌تر، مقرون‌به‌صرفه‌تر و به‌روزتر نسبت به روش‌های سنتی برداشت میدانی باشد. با وجود چالش‌هایی همچون توزیع نامتوازن داده‌های آموزشی و میزان اندک بیش‌برآورد در کلاس خرما، نتایج پژوهش نشان‌دهنده پتانسیل بالای این رویکرد برای به‌کارگیری در برنامه‌های مدیریت آب، تخصیص بهینه نهاده‌های کشاورزی، پایش سلامت باغات و توسعه‌ی سامانه‌های هشدار زود هنگام خشک‌سالی است. در سطح سیاست‌گذاری نیز، تولید نقشه‌های دقیق و روزآمد از پراکنش مکانی نخلستان‌ها می‌تواند ابزاری مؤثر برای تصمیم‌سازی در حوزه‌هایی نظیر مدیریت منابع آب مارون-جراحی، برنامه‌ریزی کشت جایگزین، نظارت بر توسعه نامتوازن اراضی باغی و حمایت هدفمند از کشاورزان فراهم کند. از این‌رو، تداوم بهره‌گیری از داده‌های چندمنبعی و گسترش این مدل به مقیاس‌های وسیع‌تر (استانی یا ملی) می‌تواند مسیر توسعه کشاورزی هوشمند و مدیریت پایدار منابع در نواحی جنوبی کشور را هموار سازد. به‌طور کلی، عملکرد مدل جنگل تصادفی در این مطالعه تأکیدی است بر قابلیت بالای این مدل برای تحلیل داده‌های پیچیده سنجش‌ازدور کشاورزی، به‌ویژه در محصولات دائمی مانند خرما که از تاج پوشش متراکم، بازتاب طیفی ویژه و ساختار عمودی متمایز برخوردار هستند. از آنجایی که جنگل تصادفی مبتنی بر مجموعه‌ای از درخت‌های تصمیم مستقل عمل می‌کند، حساسیت آن به نویز طیفی، ناهمگنی درون‌کلاسی و محدودیت‌های هندسی معمولاً کمتر از سایر مدل‌های متداول نظیر SVM یا ANN است. بنابراین می‌توان نتیجه گرفت که استفاده از این مدل برای پایش و برآورد سطح زیرکشت نخلستان‌ها در مناطق خشک ایران، از دقت، پایداری و قابلیت تعمیم بالایی برخوردار است و توانایی لازم برای فراهم‌سازی مبنایی علمی در سیاست‌گذاری منابع آب و برنامه‌ریزی کشاورزی در زیرحوضه مارون-جراحی را داراست.

۵. پی‌نوشت‌ها

1. Google Earth Engine (GEE)
2. SAR
3. Surface Reflectance
4. COPENICUS/S2_SR_HARMONIZED
5. Ground Range Detected
6. Interferometric Wide Swath
7. Descending
8. Median Composite
9. Training Samples
10. Google Earth Engine
11. Ensemble Classification Methods
12. Bagging
13. Boosting
14. Un-pruned
15. Out-of-Bag or OOB
16. CART
17. GINI Index
18. Confusion Matrix
19. Kappa coefficient

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Abderrazak, B., Asalhi, H., & Teillet, P. M. (2002). Transformed difference vegetation index (TDVI) for vegetation cover mapping Geoscience and remote sensing Symposium, IGRASS'02.2002. *IEEE International*, (5). <https://doi.org/10.1109/IGARSS.2002.1026867>
- Adib, A., Haidari, B., Lotfirad, M., & Sasani, H. (2023). Evaluating climatic change effects on EC and runoff in the near future (2020–2059) and far future (2060–2099) in arid and semi-arid watersheds. *Applied Water Science*, 13(6), 122. <https://doi.org/10.1007/s13201-023-01926-1>
- Adib, A., Kisi, O., Khoramgah, S., Gafouri, H. R., Liaghat, A., Lotfirad, M., & Moayyeri, N. (2021). A new approach for suspended sediment load calculation based on generated flow discharge considering climate change. *Water Supply*, 21(5), 2400-2413. <https://doi.org/10.2166/ws.2021.069>
- Ahmed, A. Y., Ali, A. M., & Ahmed, N. (2024). Temporal dynamics of leaf area index and land surface temperature correlation using Sentinel-2 and Landsat OLI data. *Environmental Systems Research*, 13(1), 43. <https://doi.org/10.1186/s40068-024-00371-6>
- Al-Karmadi, A., & Okoh, A. I. (2024). An overview of date (*Phoenix dactylifera*) fruits as an important global food resource. *Foods*, 13(7), 1024.
- Aliabad, F. A., Zare, M., Malamiri, H. G., Pouriyeh, A., Shahabi, H., Ghaderpour, E., & Mazzanti, P. (2024). Reconstructing daytime and nighttime MODIS land surface temperature in desert areas using multi-channel singular spectrum analysis. *Ecological Informatics*, 83, 102830. <https://doi.org/https://doi.org/10.1016/j.ecoinf.2024.102830>
- Amoakoh, A. O., Aplin, P., Rodríguez-Veiga, P., Moses, C., Alonso, C. P., Cortés, J. A., ... Nortey, D. D. N. (2024). Predictive Modelling of Land Cover Changes in the Greater Amanzule Peatlands Using Multi-Source Remote Sensing and Machine Learning Techniques. *Remote Sensing*, 16(21), 4013.
- Archer, K. J., & Kimes, R. V. (2008). Empirical characterization of random forest variable importance measures. *Computational statistics & data analysis*, 52(4), 2249-2260.
- Aziz, G., Minallah, N., Saeed, A., Frnda, J., & Khan, W. (2024). Remote sensing based forest cover classification using machine learning. *Scientific Reports*, 14(1), 69. <https://doi.org/10.1038/s41598-023-50863-1>
- Azizi mobaser, J., Rasoulzadeh, A., & Akbari majd, A. (2025). Assessment of Machine Learning and Remote Sensing in Quantifying Reference Evapotranspiration. *Water and Irrigation Management*, 15(1), 180-205. <https://doi.org/10.22059/jwim.2025.383457.1182>. (In Persian).
- Bagheri, N., Sabzevari, A., & Rajabipour, A. (2024). Monitoring and classification of crops with satellite remote sensing technology. *Agricultural Engineering*, 47(3), 337-356. <https://doi.org/10.22055/agen.2024.46785.1723>. (In Persian).
- Ballester-Berman, J. D., & Rastoll-Gimenez, M. (2021). Sensitivity Analysis of Sentinel-1 Backscatter to Oil Palm Plantations at Pluriannual Scale: A Case Study in Gabon, Africa. *Remote Sensing*, 2075, 11(3). <https://www.mdpi.com/2072-4292/13/11/2075>
- Baugh, W., & Groeneveld, D. (2006). Broadband vegetation index performance evaluated for a low-cover environment. *International Journal of Remote Sensing*, 27(21), 4715-4730.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, 114, 24-31.
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., ... Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79-87. <https://doi.org/https://doi.org/10.1016/j.jag.2015.02.012>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, L. (2002). Manual on setting up, using, and understanding random forests v3. 1. *Statistics Department University of California Berkeley, CA, USA*, 1(58), 3-42.
- Carracelas, G., Ballester, C., Marchesi, C., Roel, A., & Hornbuckle, J. (2024). Assessing Drone-Based Remote Sensing Indices for Monitoring Rice Nitrogen Plant Status Under Different Irrigation Techniques. *Agronomy*, 14(12), 2976. <https://www.mdpi.com/2073-4395/14/12/2976>
- Chandrasekar, K., Sesha Sai, M. V. R., Roy, P. S., & Dwevedi, R. S. (2010). Land Surface Water Index (LSWI) response to rainfall and NDVI using the MODIS Vegetation Index product. *International Journal of Remote Sensing*, 31(15), 3987-4005. <https://doi.org/10.1080/01431160802575653>

- Chao, C. T., & Krueger, R. R. (2007). The date palm (*Phoenix dactylifera* L.): overview of biology, uses, and cultivation. *HortScience*, 42(5), 1077-1082.
- Chen, C., Li, Y., Wang, X., Luo, X., Li, Y., Cheng, Y., & Zhu, Z. (2024). Biophysical effects of croplands on land surface temperature. *Nature Communications*, 15(1), 10901. <https://doi.org/10.1038/s41467-024-55319-2>
- Cui, B., Zhao, Q., Huang, W., Song, X., Ye, H., & Zhou, X. (2019). A New Integrated Vegetation Index for the Estimation of Winter Wheat Leaf Chlorophyll Content. *Remote Sensing*, 11(8), 974. <https://www.mdpi.com/2072-4292/11/8/974>
- Cutler, D. R., Edwards Jr, T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random forests for classification in ecology. *Ecology*, 88(11), 2783-2792.
- Dahy, B., Issa, S., & Saleous, N. (2021). Detecting and mapping mature, medium, and young age date palms in the arid lands of Abu Dhabi, using hierarchical integrated approach (HIA). *Remote Sensing Applications: Society and Environment*, 23, 100584.
- Dash, J., Curran, P., Tallis, M., Llewellyn, G., Taylor, G., & Snoeij, P. (2010). Validating the MERIS Terrestrial Chlorophyll Index (MTCI) with ground chlorophyll content data at MERIS spatial resolution. *International Journal of Remote Sensing*, 31(20), 5513-5532.
- Dobrić, D., Gašparović, M., & Medak, D. (2021). Sentinel-1 and 2 time-series for vegetation mapping using random forest classification :A case study of Northern Croatia. *Remote Sensing*, 13(12), 2321.
- Feizizadeh, B., Darabi, S., Blaschke, T., & Lakes, T. (2022a). QADI as a New Method and Alternative to Kappa for Accuracy Assessment of Remote Sensing-Based Image Classification. *Sensors*, 12(2), 2.
- Feizizadeh, B., Darabi, S., Blaschke, T., & Lakes, T. (2022b). QADI as a New Method and Alternative to Kappa for Accuracy Assessment of Remote Sensing-Based Image Classification. *Sensors*, 22(12), 4506. <https://www.mdpi.com/1424-8220/22/12/4506>
- Felegari, S., Sharifi, A., Moravej, K., Amin, M., Golchin, A., Muzirafuti, A., ... Zhao, N. (2021). Integration of sentinel 1 and sentinel 2 satellite images for crop mapping. *Applied Sciences*, 11(21), 10104.
- Foody, G. M. (2023). Challenges in the real world use of classification accuracy metrics: From recall and precision to the Matthews correlation coefficient. *Plos one*, 18(10), e0291908.
- Gamal, E., Khder, G., Morsy, A., El-Sayed, M., Hashim, A., & Saleh, H. (2020). Hyperspectral indices for discriminating plant diversity in Wadi AL-Afreet, Egypt. *Plant Archives*, 20 (Supplement 2), 3361-3371.
- Ghodsi, Z., Kheirkhah Zarkesh, M. M., & Ghermezcheshmeh, B. (2021). Comparison of Accuracy Between Support Vector Machine and Random Forest Classifiers for Land Use and Crop Mapping Using Multi-Temporal Sentinel-2 Images. *Iranian Journal of Remote Sensing and GIS*, 12(4), 73-92. <https://doi.org/10.52547/gisj.12.4.73>. (In Persian).
- Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern recognition letters*, 27(4), 294-300.
- Gitelson, A., Kaufman, Y., Stark, R., & Rundquist, D. (2002). Novel Algorithms for Remote Estimation of Vegetation Fraction. *Remote sensing of environment*, 80, 76-87. [https://doi.org/10.1016/S0039-00289\(01\)4257-4](https://doi.org/10.1016/S0039-00289(01)4257-4)
- Horning, N. (2010). Random Forests: An algorithm for image classification and generation of continuous fields data sets. Proceedings of the International Conference on Geoinformatics for Spatial Infrastructure Development in Earth and Allied Sciences, Osaka, Japan.
- Issa, S., Dahy, B., & Saleous, N. (2020). Accurate mapping of date palms at different age-stages for the purpose of estimating their biomass. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, V-461, 2020-3-467 <https://doi.org/10.5194/isprs-annals-V-3-2020-461-2020>
- Jackson, T. J., Chen, D., Cosh, M., Li, F., Anderson, M., Walthall, C., ... Hunt, E. R. (2004). Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote sensing of environment*, 92(4), 475-482.
- Jafarzadeh, H., Mahdianpari, M., Gill, E., Mohammadimanesh, F., & Homayouni, S. (2021). Bagging and Boosting Ensemble Classifiers for Classification of Multispectral, Hyperspectral and PolSAR Data: A Comparative Evaluation. *Remote Sensing*, 13(21), 4405. <https://www.mdpi.com/2072-4292/13/21/4405>
- Jiang, Y., Li, X., Peng, L., Li, C., & Song, T. (2025). Assessing the potential of multi-seasonal Sentinel-2 satellite imagery combined with airborne LiDAR for urban tree species identification. *Scientific Reports*, 15(1), 25107. <https://doi.org/10.1038/s41598-025-10971-6>

- Kazanskiy, N., Khabibullin, R., Nikonorov, A., & Khonina, S. (2025). A Comprehensive Review of Remote Sensing and Artificial Intelligence Integration: Advances, Applications, and Challenges. *Sensors*, 25(19), 5965. <https://www.mdpi.com/1424-8220/25/19/5965>
- Khanal, S., KC, K., Fulton, J. P., Shearer, S., & Ozkan, E. (2020). Remote Sensing in Agriculture—Accomplishments, Limitations, and Opportunities. *Remote Sensing*, 12(22), 3783. <https://www.mdpi.com/2072-4292/12/22/3783>
- Köppen, W. (1884). Die Wärmezonen der Erde, nach der Dauer der heissen, gemässigten und kalten Zeit und nach der Wirkung der Wärme auf die organische Welt betrachtet.
- Koshteh, K., & Kamalian, A. (2004). Dates marketing & exporting challenges in Iran. *XV International Symposium on Horticultural Economics and Management*, 655.
- Li, C., Chen, B., Wang, X., Ong-Abdullah, M., Wu, Z., Lan, G., ... Kou, W. (2025). Integrating Multi-Temporal Landsat and Sentinel Data for Enhanced Oil Palm Plantation Mapping and Age Estimation in Malaysia. *Remote Sensing*, 17(16), 2908. <https://www.mdpi.com/2072-4292/17/16/2908>
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.
- Louhaichi, M., Borman, M. M., & Johnson, D. E. (2001). Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. *Geocarto International*, 65-70, 16.
- Luo, H., Dai, S., Hu, Y., Zheng, Q., Yu, X., Chen, B., Li, Y., Wang, C., & Li, H. (2025). Integrating Knowledge-Based and Machine Learning for Betel Palm Mapping on Hainan Island Using Sentinel-1/2 and Google Earth Engine. *Plants*, 14(17), 2696. <https://www.mdpi.com/2223-7747/14/17/2696>
- Mao, W., Wang, Y., & Wang, Y. (2003). Real-time detection of between-row weeds using machine vision. In *2003 ASAE Annual Meeting* (p. 1). American Society of Agricultural and Biological Engineers. <https://elibrary.asabe.org/abstract.asp?aid=15381&t=5>
- Mc, G., & Nadaf, S. A. (2025). Digital soil mapping :Revolutionizing precision agriculture. *International Journal of Advanced Biochemistry Research*, 9, 1212-1225. <https://doi.org/10.33545/26174693.2025.v9.i6n.4742>
- McNairn, H., & Protz, R. (2014). Mapping Corn Field Residue Cover on Agricultural Fields in Oxford County, Ontario, Using Thematic Ma. *Canadian Journal of Remote Sensing*, 19. <https://doi.org/10.1080/07038992.1993.10874543>
- Mohamed, E. S., Ali, A., El-Shirbeny, M., Abutaleb, K., & Shaddad, S. M. (2020). Mapping soil moisture and their correlation with crop pattern using remotely sensed data in arid region. *The Egyptian Journal of Remote Sensing and Space Science*, 23(3), 347-353. <https://doi.org/https://doi.org/10.1016/j.ejrs.2019.04.003>
- Mohammadpour, P., Viegas, D. X., & Viegas, C. (2022). Vegetation Mapping with Random Forest Using Sentinel 2 and GLCM Texture Feature—A Case Study for Lousã Region, Portugal. *Remote Sensing*, 14(18), 4585. <https://www.mdpi.com/2072-4292/14/18/4585>
- Nicolau, A. P., Dyson, K., Saah, D., & Clinton, N. (2024). Accuracy Assessment: Quantifying Classification Quality. In J. A. Cardille, M. A. Crowley, D. Saah, & N. E. Clinton (Eds.), *Cloud-Based Remote Sensing with Google Earth Engine: Fundamentals and Applications*. 135-145. Springer International Publishing. https://doi.org/10.1007/978-3-031-26588-4_7
- Nițu, A., Florea, C., Ivanovici, M., & Racoviteanu, A. (2025). NDVI and Beyond: Vegetation Indices as Features for Crop Recognition and Segmentation in Hyperspectral Data. *Sensors*, 25(12), 3817. <https://www.mdpi.com/1424-8220/25/12/3817>
- Orynbaikyzy, A., Gessner, U., & Conrad, C. (2019). Crop type classification using a combination of optical and radar remote sensing data: a review. *International Journal of Remote Sensing*, 40(17), 6553-6595. <https://doi.org/10.1080/1431161.2019.1569791/>
- Ovakoglou, G., Alexandridis, T. K., Clevers, J. G., Cherif, I., Kasampalis, D. A., Navrozidis, I., ... Beltran, J. S. (2018). Spatial enhancement of Modis leaf area index using regression analysis with Landsat vegetation index. *IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium*.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*, 12(14), 2291.
- Putra, I., & Kusratmoko, E. (2021). Comparative Analysis of Land Surface Temperature between Oil Palm Plantations and Rice Paddies in Southern Sumatra Island. *Jurnal Geografi Lingkungan Tropik (Journal of Geography of Tropical Environments)*, 8(1), 5.

- Rahnama, S., Maharlooei, M., Rostami, M., & Maghsoudi, H. (2019). Determining the best classification algorithm in order to estimate the area under date palm cultivation using Landsat 8 satellite imagery. (In Persian).
- Rokni, K., & Musa, T. A. (2019). Normalized difference vegetation change index: A technique for detecting vegetation changes using Landsat imagery. *Catena*, 178, 59-63.
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote sensing of environment*, 55(2), 95-107. [https://doi.org/10.1016/0034-4257\(95\)00186-7](https://doi.org/10.1016/0034-4257(95)00186-7)
- Saini, R., & Ghosh, S. K. (2018). Crop classification on single date sentinel-2 imagery using random forest and support vector machine. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 683-688.
- Shafiei, K., Porhemmat, J., Sedghi, H., & Hosseini, M. (2018). Investigation the effect of land use changes on the quantity of water resources using remote sensing data and SWAT model (Case study: Maroon basin-southwest of Iran). *Journal of Water and Soil Resources Conservation*, 3(7), 71-87. <http://sanad.iau.ir/fa/Article/828894>. (In Persian).
- Sharif, M., Attarchi, S., & Kakroodi, A. (2022). Investigating the phenology changes of three plant species in different ecosystems using radar and optical data. *Physical Geography Research*, 54(1), 111-133. <https://doi.org/10.22059/jphgr.2022.334134.1007658>
- Sharifi paichoon, M., Omidvar, K., & Motazaker, K. (2019). Assessment of flooding using cluster analysis and multivariable regression methods with emphasis on hydro geomorphological parameters (Case study: Maroon catchment). *Journal of Natural Environmental Hazards*, 8(21), 75-92. <https://doi.org/10.22111/jneh.2018.22519.1336> [In Persian]
- Steven, M. D. (1998). The Sensitivity of the OSAVI Vegetation Index to Observational Parameters. *Remote sensing of environment*, 63(1), 49-60. [https://doi.org/10.1016/S0034-4257\(97\)00114-4](https://doi.org/10.1016/S0034-4257(97)00114-4)
- Tagle Casapia, X., Falen, L., Bartholomeus, H., Cárdenas, R., Flores, G., Herold, M., ... Baker, T. R. (2020). Identifying and Quantifying the Abundance of Economically Important Palms in Tropical Moist Forest Using UAV Imagery. *Remote Sensing*, 12(1), 9. <https://www.mdpi.com/2072-4292/12/1/9>
- Taha, M. F., Mao, H., Wang, Y., ElManawy, A. I., Elmasry, G., Wu, L., ... Qiu, Z. (2024). High-throughput analysis of leaf chlorophyll content in aquaponically grown lettuce using hyperspectral reflectance and RGB images. *Plants*, 13(3), 392.
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., ... Brown, M. (2012). GMES Sentinel-1 mission. *Remote sensing of environment*, 120, 9-24.
- Vani, V., Kummamuru, P., & Mandla, V. (2018). Agriculture drought analysis using remote sensing based on NDVI-LST feature space. *Indian Journal of Ecology*, 45, 6-10.
- Vreugdenhil, M., Wagner, W., Bauer-Marschallinger, B., Pfeil, I., Teubner, I., Rüdiger, C., & Strauss, P. (2018). Sensitivity of Sentinel-1 Backscatter to Vegetation Dynamics: An Austrian Case Study. *Remote Sensing*, 10(9), 1396. <https://www.mdpi.com/2072-4292/10/9/1396>
- Wang, K., Huggins, D. R., & Tao, H. (2019). Rapid mapping of winter wheat yield, protein, and nitrogen uptake using remote and proximal sensing. *International Journal of Applied Earth Observation and Geoinformation*, 82010921. <https://doi.org/10.1016/j.jag.2019.101921>
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259-269. <https://doi.org/10.13031/2013.27838>
- Yang, H., Ming, B., Nie, C., Xue, B., Xin, J., Lu, X., ... Li, S. (2022). Maize Canopy and Leaf Chlorophyll Content Assessment from Leaf Spectral Reflectance: Estimation and Uncertainty Analysis across Growth Stages and Vertical Distribution. *Remote Sensing*, 14(9), 2115. <https://www.mdpi.com/2072-4292/14/9/2115>
- Yang, Z., Willis, P., & Mueller, R. (2008). Impact of Band-Ratio Enhanced AWIFS Image on Crop Classification Accuracy. Proceeding of the Pecora 17 Remote Sensing Symposium, November 16-20 2008, Denver, CO.
- Yin, H., Pflugmacher, D., Kennedy, R. E., Sulla-Menashe, D., & Hostert, P. (2014). Mapping annual land use and land cover changes using MODIS time series. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(8), 3421-3427. <https://doi.org/10.119/JSTAR.2014.2348411>

- Zalaki Badili, N., Sayyad, G., Hemadi, K., Akhavan, S., & Abdi, A. (2013). Simulation of Runoff on Murun Dam Watershed (Idanak) using by. *Agricultural Engineering*, 35(2), 25-36. https://agrieng.scu.ac.ir/article_10005_c2d28605122e959337e2fccd68c9b385.pdf [In Persian]
- Zhang ,Y., Liu, J., & Shen, W. (2022). A Review of Ensemble Learning Algorithms Used in Remote Sensing Applications. *Applied Sciences*, 12(17), 8654. <https://www.mdpi.com/2076-3417/12/17/8654>
- Zheng, J., Ren, J., Liu, H., Tao, Z., Zou, B., Zheng, X., ... Feng, Z. (2024). Parcel-Based Mapping Framework of Corn Harvest Progress by Combining Optical and Radar Remote Sensing Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 12787-12796. <https://doi.org/10.1109/JSTARS.2024.3427127>
- Zheng, Y., Dong, W., ZhipingYang, Lu, Y., Zhang, X., Dong, Y., & Sun, F. (2024). A new attention-based deep metric model for crop type mapping in complex agricultural landscapes using multisource remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 134, 104204. <https://doi.org/https://doi.org/10.1016/j.jag.2024.104204>