

تفکیک اراضی کشاورزی استان خوزستان بر اساس نوع سیستم کشت با استفاده از داده‌های سنجش از دوری و مدل جنگل تصادفی

اسماعیل عبدالی^۱، آرمین مقیمی^{۲*}، محمدجواد ولدانزوج^۳

^۱ کارشناسی ارشد، گروه فتوگرامتری و سنجش از دور، دانشکده ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران.
e.abdalli@email.kntu.ac.ir

^۲ استادیار، گروه فتوگرامتری و سنجش از دور، دانشکده ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران.
moghimii@kntu.ac.ir

^۳ استاد، گروه فتوگرامتری و سنجش از دور، دانشکده ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران.
valadanzouj@kntu.ac.ir

(دریافت: تیر ۱۴۰۴، تصویب: شهریور ۱۴۰۴)

چکیده

شناسایی دقیق و به‌موقع نوع سیستم‌های کشت در اراضی کشاورزی، یکی از چالش‌های اساسی در پژوهش‌های کشاورزی نوین محسوب می‌شود. این تحقیق با هدف تفکیک اراضی زیر کشت گندم و جو در بخشی از استان خوزستان طی سال‌های ۱۴۰۱ تا ۱۴۰۲، آن‌ها را در سه گروه «آبی»، «دیم» و «سایر کاربری‌ها» (نظیر زمین بایر، مناطق شهری و ...) طبقه‌بندی کرده و چارچوبی نوآورانه مبتنی بر داده‌های چندزمانه سنجش‌از‌دور و مدل‌های یادگیری ماشین ارائه می‌دهد. در این مطالعه، داده‌های ماهواره‌ای Sentinel-1، Sentinel-2، Landsat-8 و SRTM به‌صورت تلفیقی به‌کار گرفته شده‌اند تا ابعاد مختلف پوشش زمین از منظر ساختاری، زمانی و مکانی تحلیل شوند. همچنین مجموعه‌ای از شاخص‌های اختصاصی فنولوژیکی، بر اساس تفاوت‌های زمانی و طیفی میان کلاس‌های کشت طراحی شده است. نتایج نشان داد که این شاخص‌ها به‌تنهایی عملکرد مناسبی داشته‌اند؛ به‌طوری‌که، دقت کلی ۸۴/۳۱ درصد و ضریب کاپای ۰/۷۵ را ثبت کرده‌اند؛ مقادیری که نسبت به سایر ترکیب‌های ساده‌تر، نتایج دقیق‌تری ارائه می‌کنند. با این حال، ترکیب همین شاخص‌های فنولوژیکی با سایر ویژگی‌های زمانی، طیفی، راداری، حرارتی و توپوگرافی، منجر به بهبود چشم‌گیر عملکرد مدل شده و دقت کلی ۹۱/۵۷ درصد و ضریب کاپای ۰/۸۷ حاصل شده است. در این راستا، مدل جنگل تصادفی (Random Forest) به‌عنوان روش طبقه‌بندی اصلی مورد استفاده قرار گرفته است. یافته‌ها نشان می‌دهد که شاخص‌های فنولوژیکی، به‌ویژه در باندهای حساس مانند RED و NIR، نقش کلیدی در افزایش دقت طبقه‌بندی دارند و ترکیب آن‌ها با سایر داده‌های سنجش‌از‌دور می‌تواند تفکیک پوشش‌های مشابه را به‌مراتب بهبود بخشد. این مطالعه بر اهمیت طراحی شاخص‌های زمانی مبتنی بر داده تأکید می‌کند.

واژگان کلیدی: سنجش از دور، شاخص‌های فنولوژیکی، سیستم‌های کشت، طبقه‌بندی، یادگیری ماشین

* نویسنده رابط

۱- مقدمه

طبقه‌بندی دقیق و به‌موقع اراضی کشاورزی بر اساس نوع سیستم کشت، از مسائل بنیادی در مطالعات کشاورزی مدرن است. نقشه‌برداری به‌روز محصولات برای تضمین امنیت غذایی و مدیریت مؤثر مزارع اهمیت بالایی دارد [۱]. در بسیاری از مناطق جهان، به‌ویژه اقلیم‌های نیمه‌خشک و خشک، زمین‌های کشاورزی عمدتاً به دو گروه کشت دیم (وابسته به بارش) و کشت آبی (با منابع تکمیلی آب) تقسیم می‌شوند. گرچه این تمایز ساده به نظر می‌رسد، اما تعیین دقیق مرز میان این دو نوع کشت در مقیاس وسیع، به دلیل عوامل متعددی مانند تنوع اقلیمی و مدیریت مزرعه‌ای، چالش‌برانگیز است [۲]. در مناطقی مانند استان خوزستان، که دارای تنوع شرایط اقلیمی و مدیریتی است، شناسایی خودکار نوع کشت برای برنامه‌ریزی دقیق و حمایت هدفمند از کشاورزان اهمیتی فزاینده یافته است [۳]. بسیاری از تصمیمات حاکمیتی، از تخصیص منابع تا پایش تغییرات کاربری زمین، به داده‌های مکانی دقیق درباره نوع سیستم کشت نیاز دارند [۴]. روش‌های سنتی مانند بازدیدهای میدانی و آمارگیری محلی، زمان‌بر، پرهزینه و اغلب فاقد پوشش مکانی و زمانی کافی‌اند. در این میان، سنجش از دور (RS)^۱ به‌عنوان روشی نوین، امکان تولید نقشه‌های دقیق و به‌روز از الگوهای کشت در مقیاس وسیع را فراهم کرده است [۵].

در اغلب کاربردهای سنجش‌از‌دور، به‌ویژه در مطالعات کشاورزی، عمده داده‌های مورد استفاده شامل داده‌های اپتیک (نوری) و داده‌های راداری فعال، از جمله رادار با روزنه مصنوعی (SAR)^۲ هستند [۶]. داده‌های نوری به دلیل توانایی بالا در ثبت ویژگی‌های طیفی و فنولوژی گیاهان، کاربرد گسترده‌ای در مطالعات نقشه‌برداری محصولات کشاورزی دارند [۷]؛ از جمله داده‌های MODIS [۸]، Landsat [۹] و Sentinel-2 [۷, ۱۰]. داده‌های SAR مانند Sentinel-1 [۱۱]، نیز به دلیل عدم وابستگی به شرایط جوی و نور، امکان تصویربرداری در هر شرایط آب‌وهوایی را فراهم می‌کنند و نسبت به ویژگی‌های سطحی نظیر رطوبت گیاه، ساختار فیزیکی، خاک و زبری حساس‌اند [۱۲, ۱۳]. پژوهش‌های بسیاری به‌کارگیری ترکیبی داده‌های نوری و SAR چندزمانه را برای بهره‌گیری از مزایای هر دو منبع توصیه کرده‌اند

[۱۴, ۱۵]؛ زیرا این ترکیب امکان درک دقیق‌تر تحولات فنولوژیکی و ساختاری گیاهان و بهبود دقت طبقه‌بندی را فراهم می‌سازد.

یکی از چالش‌های مهم در تمایز کشت دیم و آبی، شباهت‌های طیفی این دو در بسیاری از مراحل رشد است. در مراحل اولیه، تفاوت بازتاب طیفی ممکن است ناچیز باشد [۱۶]. همچنین، نوع خاک، گیاه، تاریخ کاشت و شیوه مدیریت، بر الگوی بازتاب تأثیر گذاشته و تشخیص صرفاً بر اساس تصاویر تک‌زمانه یا شاخص‌های عمومی پوشش گیاهی را دشوار می‌کند. این امر لزوم چارچوب‌هایی را نشان می‌دهد که با استفاده از داده‌های زمانی، مکانی و چندمنظوره و مدل‌های پیشرفته، تفاوت‌های جزئی را آشکار کنند [۱۷, ۱۸]. مدل‌های یادگیری ماشین، به‌ویژه در ترکیب با داده‌های چندزمانه، قابلیت بالایی در شناسایی الگوهای پیچیده دارند [۱۸]. مدل‌هایی مانند جنگل تصادفی (RF)^۳، شبکه‌های عصبی (ANN)^۴ و ماشین بردار پشتیبان (SVM)^۵، با ساختارهای غیرخطی و توانایی پردازش داده‌های چندلایه، ویژگی‌هایی را استخراج می‌کنند که تفسیر آن برای انسان دشوار است [۱۹]. این روش‌ها، به‌ویژه در شرایط کمبود داده میدانی، می‌توانند جایگزین مناسبی برای روش‌های سنتی باشند.

با وجود مزایا، به‌کارگیری رویکردهای چندزمانه و چندمنبعی با چالش‌هایی نظیر حجم بالای داده و نیاز به روش‌های پردازش پیشرفته همراه است [۲۰]. با این حال، بستر GEE^۶ تا حد زیادی این محدودیت‌ها را برطرف کرده و موجب گسترش کاربردهای سنجش‌از‌دور و یادگیری ماشین شده است [۲۱]. این بستر در حوزه‌هایی همچون مدیریت منابع آب [۲۲]، پایش تغییرات پوشش زمین [۲۳]، طبقه‌بندی پوشش زمین [۲۴] و نظارت بر آفات [۲۵] مورد استفاده قرار گرفته است.

این پژوهش چارچوبی نوین برای تفکیک اراضی گندم و جو بخشی از استان خوزستان به سه دسته‌ی دیم، آبی و سایر (شامل کاربری‌های کشاورزی دیگر، زمین بایر و مناطق شهری) در بازه زمانی ۱۴۰۱-۱۴۰۲ ارائه می‌دهد. چارچوب پیشنهادی بر ترکیب داده‌های چندزمانه ماهواره‌های Sentinel-1/2 و Landsat و مدل RF استوار است [۲۶]. علاوه

۴ Artificial Neural Network
۵ Support Vector Machine
۶ Google Earth Engine

۱ Remote Sensing
۲ Synthetic Aperture Radar
۳ Random Forests

بر شاخص‌های متداولی چون 1NDVI ، 2EVI و 3NDWI ، مجموعه‌ای از شاخص‌های فنولوژیکی زمانی طراحی شده تا تفاوت عملکردی میان کشت دیم و آبی در طول فصل رشد آشکار شود. در سیستم‌های آبی معمولاً پوشش گیاهی یکنواخت‌تر و پایدارتر است، در حالی که در کشت دیم، رشد وابسته به بارندگی بوده و ممکن است ناپیوسته یا همراه با افت ناگهانی باشد [۱،۲۷]. تحلیل چندزمانه می‌تواند این تفاوت‌ها را بهتر آشکار کند.

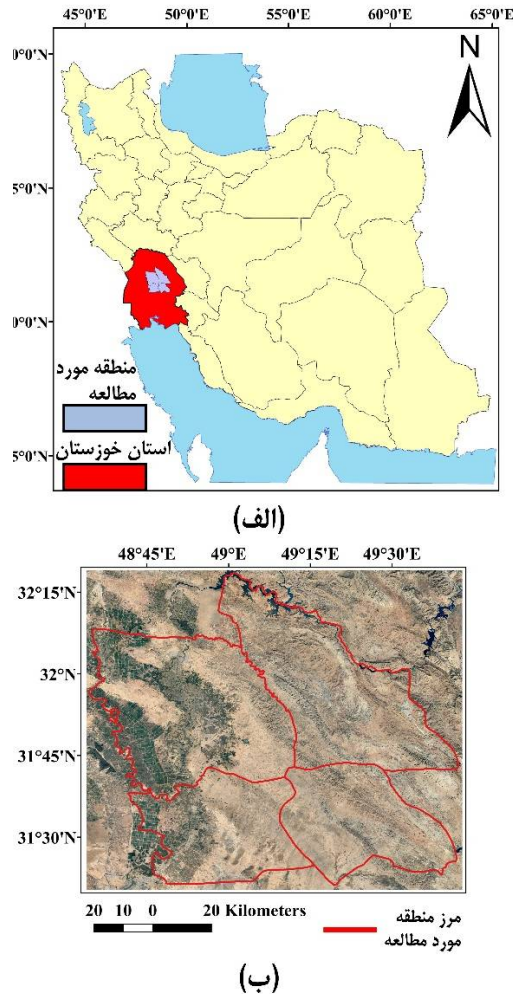
در فرآیند طبقه‌بندی، داده‌های طیفی و راداری همراه با لایه‌های کمکی مانند مدل ارتفاع رقومی (DEM) و شیب زمین به کار گرفته شدند تا اثر ویژگی‌های فیزیکی زمین بر نوع کشت در نظر گرفته شود [۲۸،۲۹]. مدل RF به دلیل انعطاف‌پذیری و توانایی کنترل بیش‌برازش، به‌عنوان طبقه‌بندی‌کننده اصلی در این پژوهش انتخاب شد [۳۰]. مطالعات متعدد کارایی بالای این مدل را نسبت به سایر مدل‌ها نشان داده‌اند [۳۱،۳۲]. مدل با داده‌های آموزشی معتبر (شامل مشاهدات میدانی و منابع مرجع) آموزش داده شد و سپس برای کل منطقه اعمال گردید. دقت آن نیز با استفاده از ماتریس ابهام، دقت کلی و ضریب کاپا ارزیابی گردید.

۲- منطقه مورد مطالعه و داده‌ها

در این بخش به معرفی منطقه مورد مطالعه و منابع داده‌ای استفاده شده شامل تصاویر ماهواره‌ای RS و داده‌های واقعیت زمینی پرداخته می‌شود.

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه شامل چهار شهرستان مسجدسلیمان، هفتکل، باوی و شوشتر در استان خوزستان واقع در جنوب‌غربی ایران است. این نواحی که در بخش‌های شمالی و مرکزی استان قرار دارند، از نظر شرایط اقلیمی، توپوگرافی و الگوی بهره‌برداری از اراضی، تنوع قابل توجهی را نشان می‌دهند و نمونه‌ای مناسب از انواع مختلف سیستم‌های کشاورزی در استان محسوب می‌شوند. شکل ۱ موقعیت جغرافیایی این مناطق را نشان می‌دهد.



شکل ۱- منطقه مورد مطالعه: (الف) کشور ایران و (ب) موقعیت جغرافیایی منطقه مورد مطالعه

شهرستان‌های مسجدسلیمان و هفتکل عمدتاً دارای اراضی کوهپایه‌ای با توپوگرافی نسبتاً ناهموار هستند. در این مناطق، محدودیت‌های منابع آب و شیب زمین باعث شده که بخش قابل توجهی از زمین‌های کشاورزی به صورت دیم مورد استفاده قرار گیرند. وابستگی به بارش‌های طبیعی در این نواحی، تفاوت‌های قابل توجهی در پوشش گیاهی و وضعیت رشد در مقایسه با مناطق دارای آبیاری ایجاد کرده است. در مقابل، شهرستان‌های باوی و شوشتر عمدتاً در نواحی دشتی قرار داشته و با دسترسی مستقیم به منابع آبی مانند رودخانه‌ی کارون، شرایط مساعدی برای کشاورزی آبی دارند. به‌ویژه در شوشتر، وجود شبکه‌های گسترده آبیاری امکان توسعه گسترده اراضی کشاورزی را فراهم کرده است. از نظر اقلیمی، این مناطق دارای آب‌وهوای گرم و نیمه‌خشک

3 Normalized Difference Water Index
 4 Digital Elevation Model

1 Normalized Difference Vegetatin Index
 2 Enhanced Vegettion Index

مطالعه، باندهای حرارتی TIRS با وضوح مکانی حدود ۱۰۰ متر، به منظور استخراج دمای واقعی سطح زمین استفاده گردید، چرا که سایر باندهای طیفی از Sentinel-2 تأمین شده‌اند. داده‌های راداری از مأموریت Sentinel-1، نخستین پروژه برنامه کوپرنیکوس، تهیه شد. این مأموریت شامل دو ماهواره یکسان (Sentinel-1A) و (Sentinel-1B) با چرخه تکرار ۱۲ روزه است [۳۷]. از آنجا که داده‌های Sentinel-1B در زمان انجام این تحقیق در دسترس نبود، تحلیل‌ها تنها بر اساس داده‌های Sentinel-1A انجام شد. داده‌های باند C با دو قطبش VV و VH در حالت IW^۳ و وضوح مکانی ۱۰ متر، به صورت محصول GRD^۴ از GEE دریافت و پس از حذف نویز حرارتی، کالیبراسیون رادیومتری و تصحیح هندسی آماده‌سازی شدند.

به‌عنوان داده جانبی، از مدل ارتفاع رقومی SRTM با وضوح مکانی ۳۰ متر استفاده گردید [۳۸]. این داده‌ها که توسط ناسا و سازمان فضایی ملی آمریکا در سال ۲۰۰۰ تهیه شده‌اند، امکان استخراج ویژگی‌های توپوگرافی از جمله ارتفاع و شیب را فراهم می‌کنند. مشخصات کلی منابع داده مورد استفاده در این پژوهش، شامل نوع، سنجنده، وضوح مکانی، بازه زمانی و پارامترهای استخراج‌شده، در جدول ۱ ارائه شده است.

جدول ۱- مشخصات منابع داده ماهواره‌ای مورد استفاده در این تحقیق

منبع داده	نوع	سنجنده / ماهواره	وضوح مکانی	بازه زمانی	پارامترها
Sentinel-2	نوری	MSI	۱۰-۲۰ متر	مهر تا تیر ۱۴۰۲	بازتاب طیفی
Landsat-8	حرارتی	TIRS	۱۰۰ متر	مهر تا تیر ۱۴۰۲	دمای سطح
Sentinel-1	راداری	C-Band (VV/VH)	۱۰ متر	مهر تا تیر ۱۴۰۲	بازتاب راداری
SRTM	توپوگرافی	DEM	۳۰ متر	ثابت	ارتفاع، شیب

۲-۲-۲- مجموعه داده واقعیت زمینی

علاوه بر داده‌های سنجنش از دور، در این پژوهش از داده‌های واقعیت زمینی (GT^۵) به منظور آموزش و ارزیابی مدل RF استفاده شده است. این داده‌ها توسط پژوهشگاه فضایی ایران تهیه شده و به صورت یک Shapefile نقطه‌ای

هستند. تابستان‌ها بسیار گرم و خشک بوده و دمای هوا در برخی روزها از ۵۰ درجه سانتی‌گراد نیز فراتر می‌رود. بارش سالانه عمدتاً در فصل زمستان و اوایل بهار رخ می‌دهد و بین ۲۵۰ تا ۳۰۰ میلی‌متر متغیر است [۳۳]. این شرایط اقلیمی در کنار ناهمواری‌های زمین، موجب شکل‌گیری الگوهای مکانی و زمانی متنوع در رشد پوشش گیاهی شده که شناسایی و تحلیل آن‌ها از طریق داده‌های سنجنش از دور را امکان‌پذیر می‌سازد. با توجه به وجود هر دو نوع سیستم آبی و دیم در این منطقه و تفاوت‌های محسوس در الگوهای بازتاب طیفی، محدوده‌ی انتخاب‌شده بستر مناسبی برای بررسی و به‌کارگیری شاخص‌های فنولوژیکی در فرآیند طبقه‌بندی اراضی کشاورزی فراهم کرده است.

۲-۲-۲- داده‌های مورد استفاده

داده‌های مورد استفاده در این تحقیق شامل مجموعه داده‌های سنجنش از دور و مجموعه داده واقعیت زمینی می‌باشد که در ادامه به معرفی آن‌ها پرداخته می‌شود.

۲-۲-۱- مجموعه داده سنجنش از دور

در این پژوهش، از داده‌های چندمنبعی شامل تصاویر نوری، حرارتی، راداری و توپوگرافی، برای اواخر مهرماه ۱۴۰۱ تا اواخر تیر ماه ۱۴۰۲ استفاده شده است. تصاویر نوری از مأموریت Sentinel-2 متعلق به آژانس فضایی اروپا تهیه شد که شامل سه ماهواره Sentinel-2A، Sentinel-2B و Sentinel-2C است. در زمان انجام این تحقیق داده‌های Sentinel-2C در دسترس نبود، بنابراین تنها داده‌های دو ماهواره اول استفاده گردید [۳۴]. این ماهواره‌ها با حسگر MSI^۱ و ۱۳ باند طیفی، وضوح مکانی ۱۰، ۲۰ و ۶۰ متر و پوشش ۲۹۰ کیلومتر را ارائه می‌دهند [۳۵]. در این پژوهش از داده‌های سطح A2 (تصحیح‌شده جوی، رادیومتری و هندسی) به منظور استخراج شاخص‌های طیفی استفاده شد. برای محاسبه دمای سطح زمین (LST^۲)، داده‌های حرارتی ماهواره Landsat-8 به‌کار گرفته شد. این مأموریت که توسط ناسا و سازمان زمین‌شناسی ایالات متحده مدیریت می‌شود، مجهز به حسگر OLI برای داده‌های چندطیفی و حسگر TIRS برای باندهای حرارتی است [۳۶]. در این

۴ Ground Range Detected

۵ Ground Truth

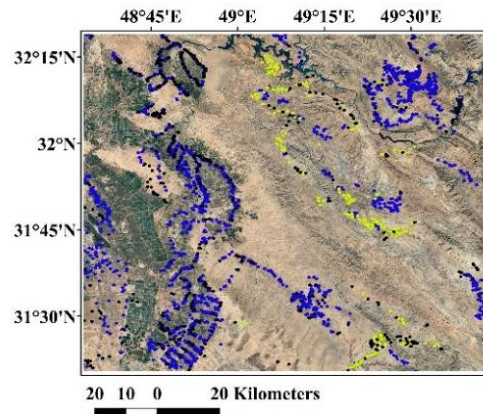
۱ Multi Spectral Instrument

۲ Land Surface Temperature

۳ Interferometric Wide

برای کل استان خوزستان که در آذر ماه سال ۱۴۰۱ جمع‌آوری شده است، در اختیار قرار گرفته‌اند.

(الف)



(ب)



شکل ۲- توزیع مکانی نمونه‌های واقعیت زمینی: (الف) آموزشی و (ب) ارزیابی

شکل ۲ توزیع مکانی نمونه‌های آموزشی و ارزیابی را در منطقه‌ی مورد مطالعه نمایش می‌دهد. هر نمونه به صورت یک نقطه در مرکز زمین‌های کشاورزی تعریف شده است و دارای برچسب نوع محصول و کاربری می‌باشد. اگرچه در نسخه‌ی اولیه داده‌ها کلاس‌بندی متنوعی وجود داشت، اما برای اهداف این پژوهش، تمام نمونه‌ها به سه کلاس کلی گندم و جو دیم، گندم و جو آبی و سایر (که شامل اراضی بایر و شهری و سایر طبقات کشاورزی است) بازتعریف و ساده‌سازی شدند و از این پس با آبی، دیم و سایر به آن‌ها ارجاع می‌شود. این داده‌ها پس از واردسازی به بستر GEE،

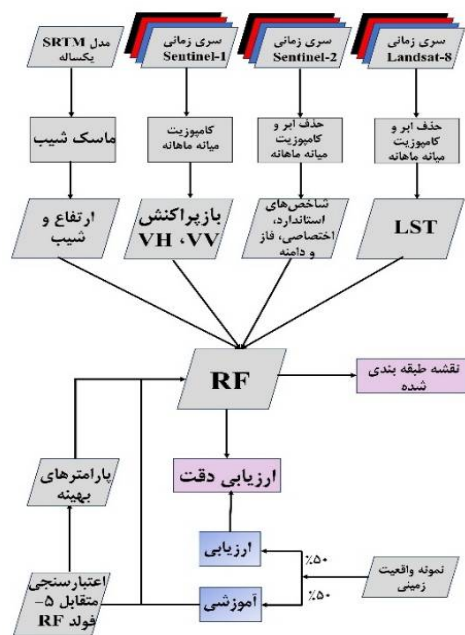
به صورت تصادفی به دو بخش تقسیم شدند؛ ۵۰ درصد از نمونه‌ها برای آموزش مدل و ۵۰ درصد باقی‌مانده برای ارزیابی عملکرد مدل مورد استفاده قرار گرفتند. تعداد نمونه‌های آموزشی و ارزیابی در جدول ۲ ارائه شده است.

جدول ۲- تعداد نمونه‌های آموزشی و ارزیابی به ازای هر کلاس

نام کلاس	آموزشی	ارزیابی	مجموع
آبی	۱۳۸۰	۱۳۹۹	۲۷۷۹
دیم	۹۲۰	۹۳۳	۱۸۵۳
سایر	۷۶۷	۷۷۹	۱۵۴۶
مجموع	۳۰۶۷	۳۱۱۱	۶۱۷۸

۳- روش پژوهش

در این بخش روش‌شناسی این پژوهش معرفی می‌شود. طرح کلی روش پیشنهادی را می‌توان در شکل ۳ مشاهده کرد.



شکل ۳- روندنمای مراحل انجام تحقیق

این قسمت شامل چهار مرحله اصلی است: (۱) پیش‌پردازش، (۲) استخراج ویژگی‌ها، (۳) آموزش مدل و تنظیم پارامترها، (۴) ارزیابی دقت. هر یک از مراحل در بخش‌های بعد به طور کامل توضیح داده شده‌است.

۳-۱- پیش‌پردازش

در این پژوهش، داده‌های ماهواره‌ای Sentinel-1 و Sentinel-2 و Landsat-8 برای دوره ۲۰ اکتبر ۲۰۲۱ تا ۲۰

ژوئیه ۲۰۲۲ (۲۸ مهر ۱۴۰۱ تا ۲۹ تیر ۱۴۰۲) استفاده شد. بازه زمانی کمتر از یک سال به دو دلیل انتخاب شد: کاهش بار پردازشی در محیط GEE و حذف دوره‌های کم‌ارزش تحلیلی مانند اواخر تابستان که پوشش گیاهی حداقلی و نویز بالا دارند [39]. برای Sentinel-2، ابتدا تصاویر با پوشش ابری کمتر از ۱۰٪ فیلتر شدند. سپس با استفاده از لایه‌های کمکی (محصول) احتمال ابر، احتمال برف، و طبقه‌بندی سطح صحنه (SCL) پیکسل‌های ابر، سایه ابر و برف حذف گردید تا فقط پیکسل‌های پاک باقی بماند.

در Sentinel-1، فقط بازپراکنش هر دو باند VV و VH که (که در GEE کالیبره شده و به صورت (σ^0) ارائه می‌شود) استفاده شد. داده‌ها از گذرهای مختلف ترکیب زمانی شدند تا یکنواختی مکانی و تداوم زمانی بهبود یابد.

برای Landsat-8، داده‌های حرارتی سنجنده TIRS جهت محاسبه دمای سطح زمین (LST) به کار رفت. این محاسبه با ماژول آماده sofiaermida انجام شد که شامل مراحل استاندارد حذف ابر و پیش‌پردازش داخلی است [۴۰]. به‌منظور کنترل اثرات توپوگرافی، از مدل ارتفاع رقومی SRTM با تفکیک مکانی ۳۰ متر استفاده شد. شیب محاسبه و مناطق با شیب بیش از ۱۰٪ حذف شدند، زیرا چنین نواحی نه‌تنها دقت داده‌ها را به‌دلیل تغییر زاویه تابش و بازتاب کاهش می‌دهند، بلکه به‌علت رواناب سریع و خشکی خاک احتمال کشت در آن‌ها پایین است [۱۰]. تمامی لایه‌های مکانی با بازنمونه‌برداری به تفکیک ۳۰ متر هم‌تراز شدند تا سازگاری مکانی بین منابع داده تضمین شود. حذف پیکسل‌های ابری و شیب‌دار باعث ایجاد شکاف در برخی تصاویر شد؛ بنابراین، برای اطمینان از پوشش کامل منطقه و کاهش نویز، از کامپوزیت میانه ماهانه استفاده گردید. این روش که کارایی آن در مطالعات مشابه اثبات شده [۲۵]، هم شکاف‌های مکانی را پر کرده و هم نویزهای طیفی در داده‌های نوری و لکه‌های نویزی در داده‌های SAR را کاهش داده است.

۳-۲- استخراج ویژگی‌ها

در این پژوهش، برای طبقه‌بندی پوشش زمین، مجموعه‌ای از ویژگی‌های طیفی، زمانی، راداری، حرارتی و توپوگرافی از داده‌های Sentinel-1، Sentinel-2، Landsat-8 و مدل ارتفاع رقومی SRTM استخراج شد. هدف، افزایش دقت و بهبود تمایز میان کلاس‌های زراعت آبی، دیم، اراضی بایر و سایر پوشش‌ها بود. ابتدا سه شاخص رایج پوشش

گیاهی NDVI، EVI و NDWI از Sentinel-2 محاسبه گردید. NDVI برای تشخیص سبزی‌نگی و EVI برای کاهش اثرات خاک و جو به کار رفت، در حالی که NDWI حساس به رطوبت پوشش گیاهی و آب است. سپس برای تحلیل تغییرات فصلی NDVI، مدل هارمونیک مرتبه اول اجرا شد تا دو ویژگی دامنه (شدت نوسانات سبزی‌نگی) و فاز (زمان اوج رشد) استخراج شود. این متغیرها نقش مهمی در تفکیک اراضی کشاورزی فصلی دارند. ویژگی‌های راداری از Sentinel-1 شامل پلاریزاسیون‌های VV (حساس به بازتاب سطحی) و VH (حساس به ساختار پوشش گیاهی) استخراج شدند که به‌ویژه در شرایط ابری مکمل داده‌های نوری هستند. از SRTM، دو متغیر ارتفاع و شیب محاسبه شد که در تشخیص محدودیت‌های توپوگرافی مؤثرند. برای بخش حرارتی، داده‌های LST از Landsat-8 با استفاده از ماژول sofiaermida تولید گردید. این ویژگی، در تفکیک کشت‌های تابستانه و زمستانه بر اساس تفاوت دمای سطح زمین کاربرد دارد.

به‌منظور افزایش قدرت جداسازی کلاس‌ها، شاخص‌های فنولوژیکی جدید بر پایه تغییرات بازتاب در باندهای Sentinel-2 طراحی شد که نوآوری این تحقیق به شما می‌رود. ابتدا میانگین بازتاب پیکسل‌های آموزشی هر کلاس (۵۰ نمونه‌ها) به‌صورت ماهانه محاسبه شد و سری زمانی ۹ ماهه برای هر باند به دست آمد. سپس برای هر جفت ماه (۳۶ حالت)، شیب تغییر بازتاب در هر کلاس محاسبه شد. انحراف معیار شیب‌ها میان کلاس‌ها معیار تمایز بود و جفت ماه با بیشترین این انحراف به‌عنوان بازه بهینه انتخاب گردید. اختلاف میانگین بازتاب کلاس‌ها بین این دو ماه به‌عنوان شاخص فنولوژیکی آن باند تعریف شد.

مجموعه نهایی ویژگی‌ها شامل متغیرهای چندزمانه، شاخص‌های استاندارد، دامنه و فاز، ویژگی‌های راداری و حرارتی، توپوگرافی، و شاخص‌های فنولوژیکی بود. برای ارزیابی اثر این متغیرها در مدل RF، چهار ترکیب ویژگی (FC) تعریف گردید که در جدول ۳ آمده است.

جدول ۳- مجموعه ویژگی‌های مختلف برای ارزیابی در این مطالعه

توضیحات	مجموعه ویژگی (FC)
شاخص‌های استاندارد، فاز و دامنه	FC ₁
شاخص‌های فنولوژیکی	FC ₂
ارتفاع، شیب، LST، VV، VH	FC ₃
تمام ویژگی‌ها	FC ₄

۳-۳- آموزش مدل و تنظیم پارامترها

برای انجام طبقه‌بندی پوشش زمین در منطقه‌ی مورد مطالعه، از مدل RF به‌عنوان یکی از روش‌های غیرپارامتریک و قدرتمند یادگیری ماشین بهره گرفته شد. این مدل به دلیل عملکرد بالا، توانایی مدیریت حجم زیاد داده‌ها و قابلیت مقابله با هم‌خطی بین ویژگی‌ها، در بسیاری از مطالعات سنجش از دور به‌ویژه برای طبقه‌بندی پوشش زمین مورد استفاده قرار می‌گیرد. به‌منظور تعیین بهترین ترکیب پارامترهای مدل و جلوگیری از بیش‌برازش^۱، از تکنیک اعتبارسنجی متقابل پنج‌تایی^۲ (K=5) در چارچوب یک جستجوی شبکه‌ای^۳ استفاده شد (جدول ۴). در این روش، داده‌های آموزشی به پنج زیرمجموعه تقسیم شدند و در هر تکرار، چهار زیرمجموعه برای آموزش و یکی برای ارزیابی مدل به‌کار رفت. این فرایند برای تمام ترکیب‌های ممکن از پارامترهای مشخص‌شده انجام شد و در نهایت، ترکیبی از سه پارامتر اصلی مدل شامل تعداد درخت‌ها (NT^۴)، حداکثر عمق (MD^۵) و حداقل تعداد نمونه‌های تقسیم (MSS^۶) که بالاترین میانگین دقت طبقه‌بندی را در میان تکرارها نشان می‌داد، به‌عنوان تنظیم نهایی انتخاب شد. با استفاده از این ساختار بهینه، مدل نهایی بر روی کل داده‌های آموزشی آموزش داده شد.

جدول ۴- فضای جستجوی شبکه‌ای جهت بهینه کردن مدل

پارامتر	فضای جستجوی شبکه‌ای
NT	[۱۰، ۵۰، ۱۰۰، ۲۰۰، ۳۰۰]
MD	[۱-۱۰، فاصله، ۲]
MSS	[۲-۱۰، فاصله، ۲]
پارامتر	فضای جستجوی شبکه‌ای

لازم به ذکر است که، در مرحله آموزش کلیه ویژگی‌های استخراج‌شده به مدل معرفی شدند. این ویژگی‌ها شامل شاخص‌های استاندارد پوشش گیاهی نظیر NDVI، EVI، NDWI، مجموعه‌ای از شاخص‌های فنولوژیکی طراحی‌شده بر پایه‌ی رفتار زمانی باندهای Sentinel-2، متغیرهای راداری مانند VV و VH، فاز و دامنه حاصل از مدل هارمونیک سری زمانی NDVI، و داده‌های توپوگرافی مانند ارتفاع و شیب

بودند. این تنوع در ویژگی‌ها به مدل امکان داد تا الگوهای پیچیده و پویای پوشش زمین را در ابعاد مختلف (طیفی، زمانی، مکانی) درک کند.

۳-۴- ارزیابی دقت

برای دستیابی به دقت طبقه‌بندی حاصل از مدل، از ماتریس ابهام^۷ به‌عنوان ابزار اصلی تحلیل عملکرد استفاده شد. این ماتریس امکان مقایسه بین کلاس‌های پیش‌بینی‌شده توسط مدل و مقادیر واقعی موجود در داده‌های مرجع را فراهم می‌کند. شکل ۴ یک نمونه از ماتریس ابهام با تعداد n طبقه را نشان می‌دهد.

	j = 1	j = 2	...	j = n
i = 1	a_{11}	a_{12}	...	a_{1n}
i = 2	a_{21}	a_{22}	...	a_{2n}
⋮	⋮	⋮	⋮	⋮
i = n	a_{n1}	a_{n1}	...	a_{nn}

برچسب پیش‌بینی شده

شکل ۴- نمونه‌ای از ماتریس ابهام

$$OA = \frac{\sum_{i=1}^n a_{ii}}{\sum_{i=1}^n \sum_{j=1}^n a_{ij}} \quad (1)$$

$$Kappa = \frac{M \sum_{i=1}^n \sum_{j=1}^n a_{ij} - \sum_{i=1}^n \sum_{j=1}^n a_{i1} a_{1j}}{M^2 - \sum_{i=1}^n \sum_{j=1}^n a_{i1} a_{1j}} \quad (2)$$

$$PA = \frac{a_{ii}}{\sum_{j=1}^n a_{ij}} \quad (3)$$

$$UA = \frac{a_{jj}}{\sum_{i=1}^n a_{ij}} \quad (4)$$

از دل این ماتریس، مجموعه‌ای از شاخص‌های آماری استخراج می‌شود که شامل دقت کلی (OA^۸)، ضریب

۵ Maximum Depth

۶ Minimum Sample Split

۷ Confusion Matrix

۸ Overall Accuracy

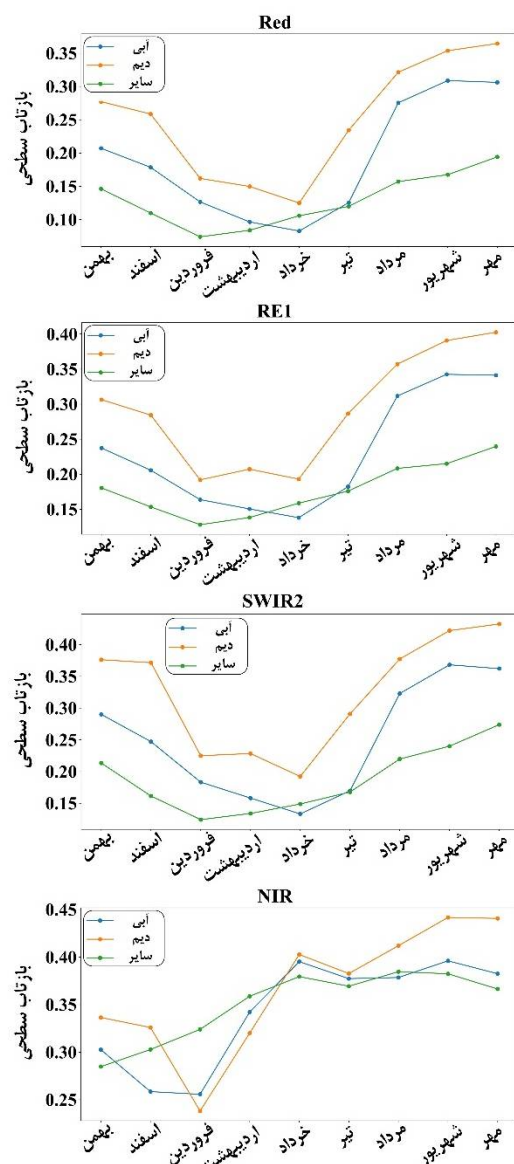
۱ Overfitting

۲ K-fold Cross Validation

۳ Grid Search

۴ Number of Trees

به سلامت و تراکم گیاهی در دوره میانی رشد برجسته می‌سازد.



شکل ۵- مثال‌هایی از سری زمانی میانگین پیکسل‌های آموزشی در ۴ باند مختلف

در باند SWIR2 بیشترین تفکیک در بازه اسفند تا اردیبهشت (ماه‌های ۲ و ۵) رخ داده است ($\sigma = 0/0682$). SWIR2 به رطوبت گیاه و خاک حساس است و رفتار متفاوت کلاس‌ها در این بازه ممکن است ناشی از شروع فعالیت رویشی در زمین‌های دیم پس از بارش‌های زمستانه و هم‌زمان، افزایش کنترل‌شده رطوبت در مزارع آبی باشد. در

کاپا^۱ (Kappa)، دقت تولیدکننده^۲ (PA) و دقت کاربر^۳ (UA) برای هر کلاس بودند. دقت کلی میزان صحت کلی مدل در تفکیک همه کلاس‌ها را نشان می‌دهد، در حالی که ضریب کاپا میزان توافق بین نتایج پیش‌بینی‌شده و واقعی را با در نظر گرفتن شانس محاسبه می‌کند. دقت تولیدکننده به احتمال صحیح شناسایی یک کلاس خاص از دید مرجع اشاره دارد و دقت کاربر نشان‌دهنده صحت پیش‌بینی مدل برای هر کلاس از دید کاربر نهایی است. همچنین روابط (۱-۴) فرمول معیارهای مشتق شده از این ماتریس که در آن i بیانگر برچسب واقعی و j بیانگر برچسب پیش‌بینی شده است. A_{ij} تعداد پیکسل‌هایی است که متعلق به طبقه i هستند اما در طبقه j طبقه‌بندی شده‌اند. n و m به ترتیب بیانگر تعداد کلاس‌ها و تعداد کل نمونه‌های ارزیابی هستند.

۴- نتایج و بحث

۴-۱- استخراج شاخص‌های فنولوژیکی

شکل ۵ تغییرات بازتاب در چهار باند نمونه از سنجنده Sentinel-2 را برای سه کلاس کاربری «آبی»، «دیم» و «سایر» در یک دوره ۹ ماهه از بهمن تا مهر نشان می‌دهند. مقادیر عددی در هر نقطه، میانگین بازتاب پیکسل‌های آموزشی در ترکیب میانه آن ماه را بیان می‌کند. این چهار نمودار به‌عنوان نمونه‌هایی از میان کلیه باندهای بررسی‌شده انتخاب شده‌اند؛ اطلاعات کامل سایر باندها در جدول ۵ ارائه شده است. تحلیل این نمودارها نه تنها بیانگر تفاوت میانگین بازتاب میان کلاس‌هاست، بلکه نشان‌دهنده رفتارهای فنولوژیکی متمایز آن‌ها در بازه‌های زمانی خاص نیز می‌باشد. چنین رفتارهایی مبنای ساخت شاخص‌های فنولوژیکی برای هر باند قرار گرفته‌اند که می‌توانند در افزایش توان تفکیک مدل‌های طبقه‌بندی مورد استفاده قرار گیرند.

در شکل ۵ باند Red، بازه اردیبهشت تا مرداد (ماه‌های ۵ و ۸) با بیشترین تمایز طیفی میان کلاس‌ها همراه بوده است ($\sigma = 0/0782$) این بازه هم‌زمان با اوج رشد پوشش گیاهی و شروع خشکی تدریجی خاک در اراضی دیم است، که موجب افزایش شدید بازتاب در کلاس دیم و روند یکنواخت‌تر در کلاس آبی شده است. این تفاوت در شیب بازتاب، اهمیت باند Red را در تشخیص تفاوت‌های مربوط

^۳ User's Accuracy

^۱ Kappa Coefficient

^۲ Producer's Accuracy

نتیجه، این باند برای تشخیص نوع کشت در مراحل ابتدایی رشد از ارزش بالایی برخوردار است.

جدول ۵- جفت ماه‌های منتخب به ازای هر باند

نام باند	ماه‌های منتخب	انحراف معیار (σ)
Blue	خرداد و شهریور	۰/۰۳۷۶
Green	خرداد و شهریور	۰/۰۴۶۴
Red	خرداد و شهریور	۰/۰۷۸۲
RE1	خرداد و شهریور	۰/۰۶۸۳
RE2	فروردین و مهر	۰/۰۶۰۴
RE3	فروردین و مهر	۰/۰۶۳۱
NIR	فروردین و مهر	۰/۰۶۵۴
RE4	فروردین و مهر	۰/۰۶۴۰
SWIR1	خرداد و شهریور	۰/۰۶۱۲
SWIR2	اسفند و خرداد	۰/۰۶۸۶

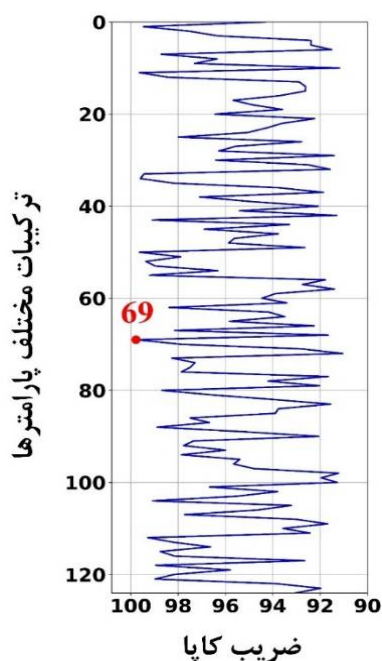
در باند RE1، که از باندهای حساس به ساختار گیاهی و فعالیت کلروفیل است، تمایز واضحی میان کلاس‌ها در بازه اردیبهشت تا مرداد (۵ و ۸) مشاهده می‌شود ($\sigma = ۰/۰۶۸۳$). افزایش ناگهانی بازتاب کلاس دیم در این بازه نشان می‌دهد که رشد آن عمدتاً وابسته به شرایط مساعد بهاره بوده و شروع دوره زوال نیز زودتر اتفاق می‌افتد. در مقابل، مزارع آبی به دلیل پایداری منابع آبی، رشد منظم‌تری دارند. این تمایز می‌تواند برای مدل‌های تفکیک نوع کشت بر اساس روند رشد بسیار مؤثر باشد. در باند NIR نیز بازه فروردین تا شهریور (ماه‌های ۳ و ۹) بیشترین اختلاف را میان کلاس‌ها ایجاد کرده است ($\sigma = ۰/۰۶۵۴$) کاهش و سپس افزایش بازتاب کلاس دیم در این باند بازتابی از دوره استرس آبی و آغاز بازسازی پوشش گیاهی است، در حالی که کلاس آبی روند یکنواخت‌تری دارد. از آنجا که NIR با محتوای زیست‌توده و وضعیت سبزینه گیاه ارتباط نزدیکی دارد، این باند در تشخیص پوشش‌های گیاهی تحت فشار یا در حال بازیابی بسیار کاربردی است.

نکته قابل توجه آن است که در اکثر باندها، بازه زمانی اسفند تا شهریور (ماه‌های ۲ تا ۶ یا بیشتر) به‌طور مکرر به‌عنوان بازه منتخب ظاهر شده است. این مسئله بیانگر آن است که عمده تفاوت‌های طیفی میان کلاس‌های کاربری در همین بازه زمانی اتفاق می‌افتد؛ یعنی دوره‌ای که در آن رشد گیاه، دسترسی به منابع آبی، و تفاوت‌های مدیریتی بیشترین

تأثیر را بر بازتاب دارند. در مجموع، تحلیل‌های صورت‌گرفته نشان می‌دهند که انتخاب جفت‌ماه‌های مناسب برای هر باند و طراحی شاخص‌های فنولوژیکی مبتنی بر آن، نقش مؤثری در افزایش دقت طبقه‌بندی زمین‌های کشاورزی ایفا می‌کند.

۴-۲- آموزش مدل و تنظیم پارامترها

فرآیند آموزش مدل RF با استفاده از اعتبارسنجی مقاطع پنج‌تایی و جستجوی شبکه‌ای برای یافتن ترکیب بهینه‌ای از پارامترها انجام شد. شکل ۶ تغییرات ضریب کاپا را در ترکیب‌های مختلف پارامترهای مدل نمایش می‌دهد. محور افقی نمایانگر ترکیب‌های گوناگون سه پارامتر اصلی مدل شامل NT، MD و MSS است. محور عمودی نیز مقدار ضریب کاپا به دست آمده از هر ترکیب را نشان می‌دهد. بر اساس این نمودار، ترکیب شماره ۶۹ بالاترین مقدار ضریب کاپا برابر با ۰/۹۹ را ارائه داده است، که پارامترهای NT، MD و MSS برای آن به ترتیب ۲۰۰، ۶ و ۸ بود. این ترکیب به‌عنوان ساختار بهینه مدل انتخاب شد. همان‌طور که در نمودار قابل مشاهده است، ترکیب‌هایی با درخت‌های بسیار عمیق یا تعداد اندک درخت‌ها معمولاً با کاهش دقت همراه بوده‌اند. این کاهش دقت را می‌توان به بیش‌برازش در ساختارهای پیچیده و کاهش توان تعمیم در ساختارهای ساده نسبت داد.



شکل ۳- دقت ترکیب‌های مختلف از پارامترهای مدل


نکته حائز اهمیت دیگر، تفاوت محسوس در دقت بین ترکیب‌های برتر و ضعیف است که در برخی موارد بیش از ۰/۸ در مقدار کاپا گزارش شده است. این اختلاف نشان می‌دهد که تنظیم دقیق پارامترها در مسائل طبقه‌بندی با داده‌های پیچیده و چندمنبعی امری ضروری است، و تکیه بر تنظیمات پیش‌فرض می‌تواند منجر به نتایج ضعیف‌تری شود. در مجموع، مدل RF پس از بهینه‌سازی پارامترها عملکرد بسیار رضایت‌بخشی از خود نشان داد. ساختار نهایی مدل از نظر دقت و پایداری در تکرارهای مختلف آموزش قابل اعتماد بوده و در ادامه پژوهش، برای تحلیل اهمیت ویژگی‌ها و ارزیابی مدل مورد استفاده قرار گرفت.

۴-۳- اهمیت ویژگی‌ها

شکل ۷ میزان اهمیت نسبی ویژگی‌های ورودی مدل RF را بر اساس شاخص کاهش ناخالصی جینی^۱ نشان می‌دهد. بر مبنای نتایج حاصل، مجموعه‌ای از ویژگی‌های طیفی فنولوژیکی، شاخص‌های عمومی پوشش گیاهی، و متغیرهای مرتبط با شرایط فنولوژیکی، راداری و توپوگرافی در فرایند طبقه‌بندی مورد استفاده قرار گرفته‌اند. با این حال، درجه اهمیت آن‌ها در بهبود عملکرد مدل یکسان نبوده است. بالاترین میزان اهمیت به شاخص فنولوژیکی Red-I با مقدار ۰/۱۶۸ تعلق دارد که بیانگر نقش کلیدی این باند در تفکیک پوشش گیاهی هدف است. این موضوع توسط نتایج جدول ۵ نیز پشتیبانی می‌شود، چراکه انحراف معیار این باند بالاترین (۰/۰۷۸۲) بود. پس از آن، شاخص NDVI با مقدار ۰/۱۴۳، شاخص SWIR2-I با ۰/۱۱۶، و شاخص RE1-I با ۰/۱۰۳ به ترتیب در رتبه‌های دوم تا چهارم قرار گرفته‌اند. ویژگی LST نیز با مقدار ۰/۰۸۶ در جایگاه پنجم قرار دارد. این روند نشان می‌دهد که شاخص‌های فنولوژیکی مبتنی بر باندهای منتخب، به‌ویژه در بخش‌های قرمز و مادون‌قرمز نزدیک، نسبت به بسیاری از شاخص‌های عمومی و متغیرهای غیرطیفی عملکرد دقیق‌تری داشته‌اند. همچنین شاخص‌های عمومی سبزی‌نگی مانند NDVI و EVI نیز همچنان در میان ویژگی‌های مؤثر مدل دیده می‌شوند که نقش آن‌ها در ارزیابی پوشش گیاهی را تأیید می‌کند.

مطالعه حاضر نشان می‌دهد که شاخص‌های فنولوژیکی طراحی‌شده بر پایه تفاوت‌های زمانی در بازتاب طیفی

کلاس‌ها، سهم قابل توجهی در تبیین ساختار داده داشته‌اند. پنج شاخص فنولوژیکی شامل RE1-I، Red-I، NIR-I، SWIR2-I و RE4-I در بین ده ویژگی برتر قرار گرفته‌اند و مجموع اهمیت آن‌ها به حدود ۰/۴۶۴ می‌رسد. این امر نشان می‌دهد که نزدیک به نیمی از توان تفکیکی مدل از طریق این گروه از شاخص‌ها حاصل شده است؛ شاخص‌هایی که معمولاً در مطالعات سنتی نادیده گرفته می‌شوند ولی با هدف‌گذاری مناسب می‌توانند به‌عنوان مکملی قدرتمند در کنار شاخص‌های عمومی ایفای نقش کنند. در این پژوهش، NDVI دامنه و فاز آن در مجموع بیش از ۰/۲۲۱ از اهمیت مدل را به خود اختصاص داده‌اند که تأکیدی بر نقش مؤثر ویژگی‌های زمانی در تحلیل تمایز فنولوژیکی میان کشت‌های آبی و دیم دارد.



شکل ۷- نمودار اهمیت نسبی ویژگی‌های مدل براساس شاخص کاهش ناخالصی جینی

در نقطه مقابل، متغیرهای راداری VH و VV با مقادیر ۰/۰۱۴ و ۰/۰۱۰ متغیرهای توپوگرافی مانند ارتفاع (۰/۰۰۴) و شیب (۰/۰۰۳) از اهمیت کمتری برخوردار بوده‌اند. این امر احتمالاً ناشی از ضعف سیگنال‌های راداری در تفکیک پوشش‌های گیاهی متراکم و یا یکنواختی نسبی توپوگرافی در منطقه مطالعه‌شده است، به‌ویژه با توجه به اعمال ماسک اولیه برای حذف نواحی با شیب یا ارتفاع بالا. در مجموع، نتایج حاصل از تحلیل اهمیت ویژگی‌ها بیانگر آن است که بهره‌گیری ترکیبی از شاخص‌های فنولوژیکی مبتنی بر باندهای طیفی خاص و شاخص‌های عمومی متداول می‌تواند به عملکرد بهینه مدل‌های طبقه‌بندی منجر شود. این یافته‌ها بر لزوم طراحی هدفمند و داده‌محور شاخص‌های زمانی تأکید

^۱ Mean Decrease in Gini Impurity

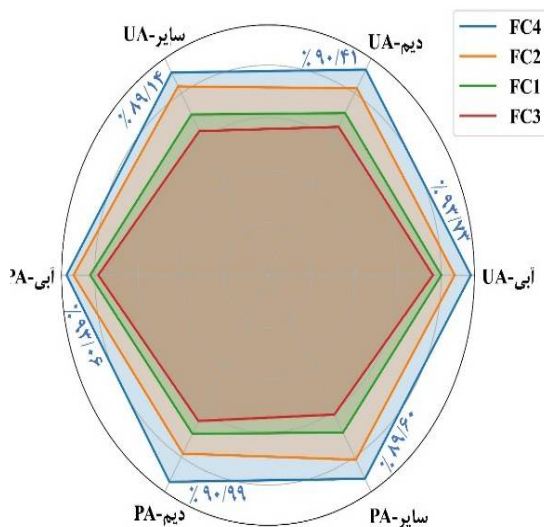
دارند؛ به‌ویژه در شرایطی که هدف، تمایز الگوهای کشت و رشد در اراضی زراعی باشد. استفاده از رویکردهای ترکیبی می‌تواند محدودیت‌های هر کدام از گروه‌های شاخص را جبران کرده و دقت مدل‌های یادگیری ماشین را به‌طور معناداری افزایش دهد.

۴-۴- ارزیابی مجموعه ویژگی‌ها

بررسی نتایج حاصل از ماتریس‌های ابهام (شکل ۸) نشان داد که ترکیب ویژگی‌های FC4، شامل داده‌های طیفی، فنولوژیکی، شاخص‌های فنولوژیکی، راداری، دمای سطح زمین و توپوگرافی، بالاترین عملکرد را در میان سایر ترکیب‌ها داشته است. این ترکیب با ثبت دقت کلی ۹۱/۵۷ درصد و ضریب کاپا ۰/۸۷، نشان‌دهنده بالاترین سطح انطباق با داده‌های مرجع است. ترکیب داده‌های مکمل در FC4 موجب بهبود قابل توجه در تفکیک کلاس‌ها، به‌ویژه در نواحی مرزی و مختلط شده و خروجی طبقه‌بندی از انسجام فضایی بالایی برخوردار است.

کاپا ۰/۷۵۶ عملکرد نسبتاً مناسبی، به‌ویژه در کلاس دیم، داشته است. FC1 و FC3 به‌ترتیب با دقت‌های ۷۵/۲۱ درصد و ۶۹/۸۸ درصد و ضرایب کاپا ۰/۶۱۵ و ۰/۵۳ عملکرد ضعیف‌تری ارائه داده‌اند؛ به‌ویژه FC3 که به‌دلیل فقدان داده‌های طیفی و فنولوژیکی، توان تفکیک پوشش‌های گیاهی مشابه را نداشته است.

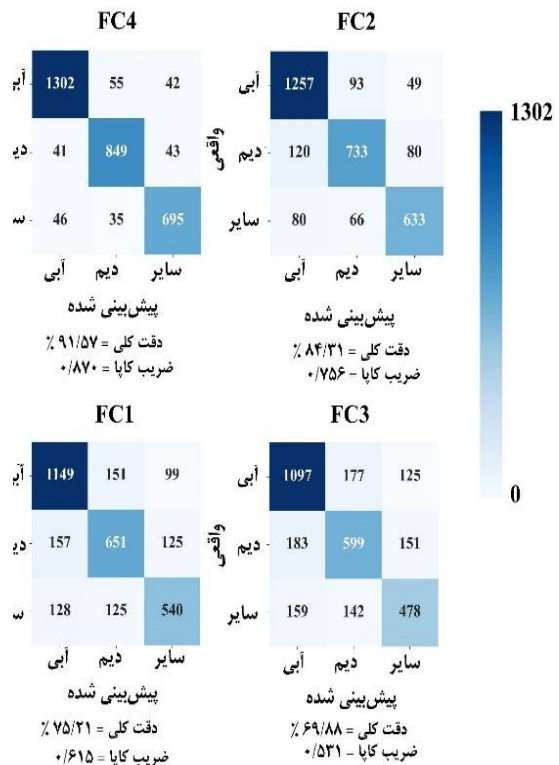
نمودار دقت تولیدکننده (PA) و دقت کاربر (UA) (شکل ۹) تفاوت‌های عملکرد میان ترکیب‌های مختلف را به‌وضوح نمایش می‌دهد.



شکل ۹- دقت تولید کننده (PA) و دقت کاربر (UA) چهار مجموعه ویژگی مذکور

در FC4، برای کلاس آبی، دقت تولیدکننده ۹۳/۷۳ درصد و دقت کاربر ۹۰/۴۱ درصد ثبت شده است، که نسبت به سایر ترکیب‌ها بالاترین مقادیر را نشان می‌دهد. در FC1، همین مقادیر به‌ترتیب ۸۰/۱۲ درصد و ۷۱/۳۰ درصد بوده‌اند، که نشان‌دهنده نرخ خطای بالاتر در طبقه‌بندی این کلاس است. همچنین برای کلاس دیم، FC4 دقت تولیدکننده ۹۳/۰۶ درصد و دقت کاربر ۹۰/۹۹ درصد را به‌دست آورده، در حالی که این مقادیر در FC3 به‌ترتیب ۷۸/۴۱ درصد و ۶۴/۲۰ درصد گزارش شده‌اند. این اختلاف فاحش، تأثیر مستقیم به‌کارگیری شاخص‌های مکمل و داده‌های چندمنبعی را در افزایش صحت و کاهش خطاهای طبقه‌بندی نشان می‌دهد.

نقشه طبقه‌بندی نهایی (شکل ۱۰) نیز این یافته‌ها را از منظر بصری تأیید می‌کند. در نقشه حاصل از ترکیب FC4، مرز میان کلاس‌ها به‌ویژه در مناطق کشت دیم و آبی،



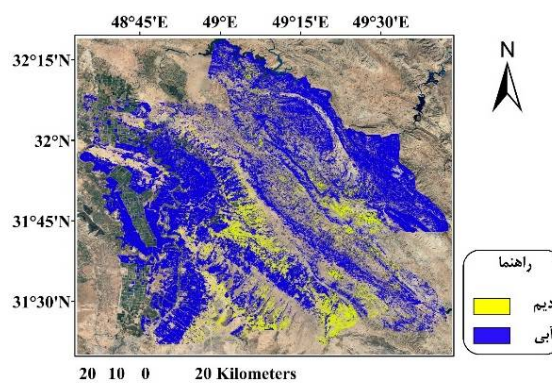
شکل ۸- ماتریس ابهام چهار مجموعه ویژگی مذکور به همراه دقت‌های آن‌ها

در مقابل، FC2 که صرفاً بر شاخص‌های فنولوژیکی Sentinel-2 تکیه دارد، با دقت کلی ۸۴/۳۱ درصد و ضریب

۵- نتیجه گیری

پژوهش حاضر چارچوبی نوین برای طبقه بندی اراضی کشاورزی بر اساس نوع سیستم کشت ارائه داد که با بهره گیری از داده های چندزمانه و چندمنبع سنجش از دور و مدل های یادگیری ماشین توسعه یافته است. طراحی و به کارگیری شاخص های فنولوژیکی فنولوژیکی، که بر مبنای تفاوت های زمانی در رفتار طیفی کشت های آبی و دیم شکل گرفته اند، نقش مهمی در بهبود دقت تفکیک این دو نوع کشت ایفا کردند. در مقایسه با ترکیب های ساده تر، این شاخص ها دقت بالاتری ایجاد کردند، اما زمانی که با سایر داده های سنجش از دور نظیر شاخص های استاندارد، اطلاعات راداری، دمای سطح زمین و پارامترهای توپوگرافی ترکیب شدند، کارایی مدل به طور چشمگیری افزایش یافت. این تلفیق منجر به افزایش انسجام مکانی طبقه بندی، کاهش پراکندگی خطا در مرز کلاس ها، و افزایش قابلیت اطمینان در نواحی با پوشش پیچیده یا متغیر شد. از این منظر، می توان نتیجه گرفت که هم افزایی داده های متنوع، به ویژه زمانی که با طراحی هدفمند ویژگی ها همراه باشد، می تواند به طبقه بندی دقیق تر سیستم های زراعی در مقیاس های وسیع کمک کند. رویکرد ارائه شده، نه تنها امکان پایش موثرتر اراضی کشاورزی را فراهم می کند، بلکه بستری مناسب برای تصمیم گیری های مدیریتی و سیاست گذاری در حوزه منابع طبیعی و کشاورزی فراهم می سازد. در ادامه مسیر، بهره گیری از مدل های یادگیری عمیق، شبکه های عصبی و استفاده از داده های دارای تفکیک زمانی و مکانی بالا، می تواند پایداری، دقت و تعمیم پذیری مدل را در شرایط متنوع اقلیمی و زراعی به صورت محسوسی ارتقاء بخشد.

به صورت واضح ترسیم شده است و پراکندگی فضایی طبقات با دقت بالا منعکس شده است. ترکیب هم زمان داده های ساختاری، طیفی و زمانی باعث شده تا حتی نواحی با پوشش های پیچیده نیز با صحت بیشتری شناسایی شوند. این موضوع نشان می دهد که بهره گیری از تنوع داده ها نه تنها دقت مدل را افزایش داده، بلکه تفسیرپذیری نتایج را نیز برای تحلیل های کاربردی تسهیل کرده است.



شکل ۱۰- نقشه طبقه بندی نهایی

در نهایت، بررسی نقشه طبقه بندی نهایی مبتنی بر FC4 (شکل ۱۰) نشان می دهد که این ترکیب توانسته است الگوهای فضایی کشاورزی را با دقت بالایی بازنمایی کند. مرز بین کلاس ها شفاف و پیوسته است و پراکندگی های اشتباه در کلاس های مختلط یا حاشیه های به حداقل رسیده اند. این امر به خصوص در مناطق با ترکیب الگوهای کشت آبی و دیم، که به دلیل تداخل زمانی در داده ها مستعد اشتباه هستند، اهمیت بیشتری دارد. همچنین، پوشش سایر کلاس ها که معمولاً با چالش های بیشتری در طبقه بندی روبه رو هستند، در FC4 با انسجام بهتری تفکیک شده اند، هر چند در این کلاس همچنان نوساناتی در دقت باقی مانده که قابل انتظار است.

مراجع

- [۱] K. M. Chandrasekharan, C. Subasinghe, and A. Hailelassie, *Mapping irrigated and rainfed agriculture in Ethiopia (2015-2016) using remote sensing methods*. International Water Management Institute (IWMI), 2021.
- [۲] L. Zhang, K. Zhang, X. Zhu, H. Chen, and W. Wang, "Integrating remote sensing, irrigation suitability and statistical data for irrigated cropland mapping over mainland China," *Journal of Hydrology*, vol. 613, p. 128413, 2022.
- [۳] K. S. Mpakairi, T. Dube, M. Sibanda, and O. Mutanga, "Fine-scale characterization of irrigated and rainfed croplands at national scale using multi-source data, random forest, and deep learning algorithms," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 204, pp. 117-130, 2023.
- [۴] Z. Gao, D. Guo, D. Ryu, and A. W. Western, "Enhancing the accuracy and temporal transferability of irrigated cropping field classification using optical remote sensing imagery," *Remote Sensing*, vol. 14, no. 4, p. 997, 2022.

- [۵] E. Abdali, M. J. Valadan Zoej, A. Taheri Dehkordi, and E. Ghaderpour, "A parallel-cascaded ensemble of machine learning models for crop type classification in Google Earth Engine using multi-temporal sentinel-1/2 and landsat-8/9 remote sensing data," *Remote Sensing*, vol. 16, no. 1, p. 127, 2023.
- [۶] L. Zhu, J. Suomalainen, J. Liu, J. Hyypä, H. Kaartinen, and H. Haggren, "A review: Remote sensing sensors," *Multi-purposeful application of geospatial data*, vol. 19, pp. 19-42, 2018.
- [۷] L. Ghayour *et al.*, "Performance evaluation of Sentinel-2 and Landsat 8 OLI data for land cover/use classification using a comparison between machine learning algorithms," *Remote Sensing*, vol. 13, no. 7, p. 1349, 2021.
- [۸] J. Li, B. Zhang, and X. Huang, "A hierarchical category structure based convolutional recurrent neural network (HCS-ConvRNN) for Land-Cover classification using dense MODIS Time-Series data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 108, p. 102744, 2022.
- [۹] P. Dash, S. L. Sanders, P. Parajuli, and Y. Ouyang, "Improving the accuracy of land use and land cover classification of Landsat data in an agricultural watershed," *Remote Sensing*, vol. 15, no. 16, p. 4020, 2023.
- [۱۰] H. Rakuasa, "Classification of Sentinel-2A Satellite Image for Ternate City land cover using Random Forest Classification in SAGA GIS Software," *DNS-DIGITAL NEXUS SYSTEMATIC JOURNAL*, vol. 1, no. 1, pp. 34-36, 2025.
- [۱۱] A. Qadir, S. Skakun, N. Kussul, A. Shelestov, and I. Becker-Reshef, "A generalized model for mapping sunflower areas using Sentinel-1 SAR data ", *Remote Sensing of Environment*, vol. 306, p. 114132, 2024.
- [۱۲] S. a. Ibrahim and H. Balzter, "Evaluating Flood Damage to Paddy Rice Fields Using PlanetScope and Sentinel-1 Data in North-Western Nigeria: Towards Potential Climate Adaptation Strategies ", *Remote Sensing*, vol. 16, no. 19, p. 3657, 2024.
- [۱۳] F. Bioresita, T. S. F. Larastika, M. Taufik, and N. Hayati, "Integration of Texture and PCA Information from Sentinel-1 SAR Data for Land Cover-Analysis using Random Forest Classifier Method in Sidoarjo Regency, Indonesia," in *Forum Geografi*, 2025, vol. 39, no. 1, pp. 38-52 .
- [۱۴] M. Vizzari, G. Lesti, and S. Acharki, "Crop classification in Google Earth Engine: leveraging Sentinel-1, Sentinel-2, European CAP data, and object-based machine-learning approaches," *Geo-spatial Information Science*, pp. 1-16, 2024.
- [۱۵] C. Eisfelder *et al.*, "Cropland and Crop Type Classification with Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine for Agricultural Monitoring in Ethiopia," *Remote Sensing*, vol. 16, no. 5, p. 866, 2024.
- [۱۶] H. Xing *et al.*, "Mapping irrigated, rainfed and paddy croplands from time-series Sentinel-2 images by integrating pixel-based classification and image segmentation on Google Earth Engine," *Geocarto International*, vol. 37, no. 1, pp. 13291-13310, 2022.
- [۱۷] A. K. Sharma *et al.*, "Identifying seasonal groundwater-irrigated cropland using multi-source NDVI time-series images," *Remote sensing*, vol. 13, no. 10, p. 1960, 2021.
- [۱۸] E. Erdanaev, M. Kappas, and D. Wyss, "The Identification of Irrigated Crop Types Using Support Vector Machine, Random Forest and Maximum Likelihood Classification Methods with Sentinel-2 Data in 2018: Tashkent Province, Uzbekistan," *International Journal of Geoinformatics*, vol. 18, no. 2, 2022.
- [۱۹] M. Alami Machichi *et al.*, "Crop mapping using supervised machine learning and deep learning: A systematic literature review," *International Journal of Remote Sensing*, vol. 44, no. 8, pp. 2717-2753, 2023.
- [۲۰] H. Tamiminia, B. Salehi, M. Mahdianpari, L. Quackenbush, S. Adeli, and B. Brisco, "Google Earth Engine for geo-big data applications: A meta-analysis and systematic review," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 164, pp. 152-170, 2020.
- [۲۱] Z. Zhao *et al.*, "Comparison of three machine learning algorithms using Google Earth Engine for land use land cover classification," *Rangeland ecology & management*, vol. 92, pp. 129-137, 2024.
- [۲۲] M. Kazemi Garajeh, F. Haji, M. Tohidfar, A. Sadeqi, R. Ahmadi, and N. Kariminejad, "Spatiotemporal monitoring of climate change impacts on water resources using an integrated approach of remote sensing and Google Earth Engine," *Scientific reports*, vol. 14, no. 1, p. 5469, 2024.

- [۲۳] C. B. Pande, "Land use/land cover and change detection mapping in Rahuri watershed area (MS), India using the google earth engine and machine learning approach," *Geocarto International*, vol. 37, no. 26, pp. 13860-13880, 2022.
- [۲۴] A. Amindin, N. Siamian, N. Kariminejad, J. J. Clague, and H. R. Pourghasemi, "An integrated GEE and machine learning framework for detecting ecological stability under land use/land cover changes," *Global Ecology and Conservation*, vol. 53, p. e03010, 2024.
- [۲۵] J. Zhi *et al.*, "Rapid Large-Scale Monitoring of Pine Wilt Disease Using Sentinel-1/2 Images in GEE," *Forests*, vol. 16, no. 6, p. 981, 2025.
- [۲۶] A. Liepa *et al.*, "Harmonized NDVI time-series from Landsat and Sentinel-2 reveal phenological patterns of diverse, small-scale cropping systems in East Africa," *Remote Sensing Applications: Society and Environment*, vol. 35, p. 101230, 2024.
- [۲۷] E. Heller *et al.*, "Mapping crop types, irrigated areas, and cropping intensities in heterogeneous landscapes of Southern India using multi-temporal medium-resolution imagery," *Photogrammetric Engineering & Remote Sensing*, vol. 78, no. 8, pp. 815-827, 2012.
- [۲۸] E. S. Ibrahim, P. Rufin, L. Nill, B. Kamali, C. Nendel, and P. Hostert, "Mapping crop types and cropping systems in Nigeria with Sentinel-2 imagery," *Remote sensing*, vol. 13, no. 17, p. 3523, 2021.
- [۲۹] N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, "Deep learning classification of land cover and crop types using remote sensing data," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 5, pp. 778-782, 2017.
- [۳۰] L. Breiman, "Random forests ", *Machine learning*, vol. 45, pp. 5-32, 2001.
- [۳۱] H. Deng, W. Zhang, X. Zheng, and H. Zhang, "Crop classification combining object-oriented method and random forest model using unmanned aerial vehicle (UAV) multispectral image," *Agriculture*, vol. 14, no. 4 ,p. 548, 2024.
- [۳۲] A. Orynbaikyzy, U. Gessner, and C. Conrad, "Spatial transferability of random forest models for crop type classification using Sentinel-1 and Sentinel-2," *Remote Sensing*, vol. 14, no. 6, p. 1493, 2022.
- [۳۳] I. Baronian, R. Borna, K. Jafarpour Ghalehtemouri, M. Zohoorian, J. Morshedi, and M. A. Khaliji, "Unveiling the thermal impact of land cover transformations in Khuzestan province through MODIS satellite remote sensing products," *Paddy and Water Environment*, vol. 22, no. 4, pp. 503.۲۰۲۴ ,۰۲۰-
- [۳۴] H. Zhao, S. Duan, J. Liu, L. Sun, and L. Reymondin, "Evaluation of five deep learning models for crop type mapping using sentinel-2 time series images with missing information," *Remote Sensing*, vol. 13, no. 14, p. 2790, 2021.
- [۳۵] L. Liu *et al.*, "Mapping cropping intensity in China using time series Landsat and Sentinel-2 images and Google Earth Engine," *Remote Sensing of Environment*, vol. 239, p. 111624, 2020.
- [۳۶] F. Rahimi-Ajdadi, "Land suitability assessment for second cropping in terms of low temperature stresses using Landsat TIRS sensor," *Computers and Electronics in Agriculture*, vol. 200, p. 107205, 2022.
- [۳۷] P. Potin *et al.*, "Sentinel-1 mission status," in *Proceedings of EUSAR 2016: 11th European conference on synthetic aperture radar*, 2016: VDE, pp. 1-6 .
- [۳۸] L. Yang, X. Meng, and X. Zhang, "SRTM DEM and its application advances," *International Journal of Remote Sensing*, vol. 32, no. 14, pp. 3875-3896, 2011.
- [۳۹] Q. Li, J. Tian, and Q. Tian, "Deep learning application for crop classification via multi-temporal remote sensing images," *Agriculture*, vol. 13, no. 4, p. 906, 2023.
- [۴۰] S. L. Ermida, P. Soares, V. Mantas, F.-M. Göttsche, and I. F. Trigo, "Google earth engine open-source code for land surface temperature estimation from the landsat series," *Remote Sensing*, vol. 12, no. 9, p. 1471, 2020.