

تولید و ارزیابی نقشه‌های کاربری اراضی و نوع محصول با استفاده از تصاویر ماهواره‌ای و مدل‌های داده‌محور مبتنی بر یادگیری در دشت ایسین استان هرمزگان (مقاله پژوهشی)

۱- فاطمه خیری، دانش‌آموخته کارشناسی ارشد، گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران.

۲- علیرضا نفرزادگان^{*}، دانشیار، گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران.

a.r.nafarzadegan@hormozgan.ac.ir

۳- رسول مهدوی، دانشیار، گروه مهندسی منابع طبیعی، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران.

دریافت: ۱۴۰۵/۰۲/۲۴

پذیرش: ۱۴۰۵/۰۶/۰۵

چکیده

هدف این پژوهش ارزیابی عملکرد مدل‌های یادگیری ماشین در تهیه نقشه‌های کاربری اراضی و شناسایی نوع محصول زراعی و همچنین تحلیل تغییرات کاربری اراضی طی دوره ۲۰۱۴ تا ۲۰۲۴ در دشت ایسین استان هرمزگان بود. این دشت به دلیل برخورداری از منابع آب شیرین و خاک حاصلخیز، از دیرباز یکی از مناطق مهم کشاورزی استان محسوب می‌شود. در بازدید میدانی از منطقه مورد مطالعه، ۸۹۸ نقطه واقعیت زمینی برای تهیه نقشه کاربری اراضی شامل باغات (انبه، لیمو و نخيلات)، اراضی زراعی، آیش، شوره‌زار و ساخت‌وساز انسانی و ۵۱۳ نقطه برای نقشه نوع محصول شامل بادمجان، فلفل دلمه‌ای، باغات و شوره‌زار جمع‌آوری شد. تصاویر ماهواره‌ای لندست ۸ برای تهیه نقشه کاربری اراضی و سنتینل ۲ برای شناسایی محصولات زراعی به کار گرفته شد و شاخص‌های طیفی برای افزایش دقت تفکیک کاربری‌ها و محصولات زراعی محاسبه شدند. به منظور انتخاب ویژگی‌های مؤثر، از هم‌خطی‌چندگانه و الگوریتم بروتا استفاده شد. سپس، مدل‌های جنگل تصادفی و ماشین بردار پشتیبان به کار گرفته شدند و نتایج نشان داد مدل ماشین بردار پشتیبان در دسته‌بندی کاربری اراضی دقت بیشتری دارد؛ به طوری که در سال ۲۰۲۴، دقت کلی آن در داده‌های آزمون ۸۷/۴۵ درصد و ضریب کاپا ۸۳/۶۴ بود، در حالی که در شناسایی محصولات زراعی، مدل جنگل تصادفی با دقت کلی ۸۹/۲۹ درصد و ضریب کاپا ۸۴/۵۹ در داده‌های آزمون عملکرد برتری داشت. در بررسی تغییرات کاربری اراضی طی دوره ۱۰ ساله، سطح باغات، اراضی زراعی و آیش کاهش یافت و شوره‌زار و مناطق ساخت‌وساز انسانی افزایش پیدا کرد. این تغییرات حاصل عوامل طبیعی و انسانی است؛ به طوری که کاهش بارش، تداوم خشکسالی و افت منابع آب زیرزمینی موجب افزایش شوره‌زار و کاهش اراضی زراعی و باغی شده است. افزایش هزینه‌های تولید کشاورزی، نزدیکی دشت ایسین به شهر بندرعباس و گسترش ساخت‌وساز نیز در تغییر الگوی کاربری اراضی نقش داشته‌اند. در مجموع، نتایج بیانگر اثربخشی بالای الگوریتم‌های یادگیری ماشین در تهیه نقشه‌های دقیق و کاربردی کاربری اراضی و نوع محصولات زراعی است.

واژگان کلیدی: دسته‌بندی نظارت‌شده، سنجش از دور، سنتینل-۲، شاخص‌های طیفی، لندست ۸، یادگیری ماشین.

مقدمه

زمانی گوناگون [۱] از سوی دیگر، انجام فعالیت‌های پایشی همزمان در این دو بخش را لازم می‌کند. تولید نقشه‌های دقیق و به‌روز با حداقل هزینه و زمان، به منظور ارزیابی وضعیت و دستیابی به الگوی توسعه

اهمیت پایش کاربری اراضی به عنوان یکی از پیش‌زمینه‌های مدیریت پایدار منابع طبیعی از یک سو و نقش بسزای کشاورزی به عنوان یک فعالیت تولیدی سنتی در رشد و توسعه کشورها در دوره‌های

پایدار، به‌ویژه در دشت‌های عمدتاً کشاورزی کشور، از جمله این فعالیت‌هاست. یکی از موضوعات اساسی در ارزیابی وضعیت دشت‌ها، علاوه بر ارزیابی تغییرات زمانی کاربری اراضی، پایش فعالیت‌های کشاورزی از طریق دسترسی به نقشه به‌روز نوع محصول یا تخمین سطح زیرکشت محصولات به‌منظور برآورد میزان تولید (به‌ویژه برای محصولات استراتژیک) است. برخورداری از چنین اطلاعاتی، امکان تدوین سیاست‌های مدیریتی و اجرایی مؤثر و منطقی را در سطوح کوتاه‌مدت و بلندمدت بخش کشاورزی [۲۴] و منابع طبیعی برای هر دشت را فراهم می‌سازد.

در این میان، فناوری سنجش از دور و تصاویر ماهواره‌ای با قدرت تفکیک مکانی، زمانی و طیفی مناسب، به ابزاری منحصربه‌فرد برای تولید این دسته از نقشه‌ها و نیز برنامه‌ریزی بهینه‌تر در زمینه الگوی کشت تبدیل شده‌اند [۸]. بر این اساس، با بهره‌گیری از ترکیب داده‌های ماهواره‌ای و به‌کارگیری الگوریتم‌های یادگیری ماشین از طریق دسته‌بندی نظارت‌شده، می‌توان به تولید نقشه‌های دقیق کاربری اراضی و همچنین نوع محصولات زراعی پرداخت. در این پژوهش به‌منظور دسته‌بندی نظارت‌شده از دو الگوریتم جنگل تصادفی^۱ و ماشین بردار پشتیبان^۲ استفاده گردید که در پژوهش‌های مرتبط با منابع طبیعی نیز پرکاربرد هستند. در طی دو دهه اخیر، شاخص‌های پوشش گیاهی در مطالعات منابع طبیعی، از مقیاس‌های کوچک تا وسیع، کاربرد گسترده‌ای یافته‌اند و همچنین بررسی روند تغییرات پوشش گیاهی با این شاخص‌ها، به یکی از مسائل مهم در مدیریت و کنترل پوشش گیاهی و پایش وضعیت اراضی تبدیل شده‌اند [۱۱]. بنابراین پژوهش‌های زیادی نشان‌دهنده نقش مهم کاربردهای سنجش از دور در بررسی تغییرات پوشش گیاهی و نوع گیاهان هستند. برای مثال، Niculescu و Xie (۲۰۲۲) به‌منظور نقشه‌برداری دو محصول گندم و جو در منطقه شمالی فرانسه، از داده‌های سنتینل-۲ و

روش‌های دسته‌بندی سلسله‌مراتبی و استخراج مستقیم استفاده شد و نتایج به‌دست آمده نشان داد که روش دسته‌بندی سلسله‌مراتبی با دقت کلی ۹۳٪ بوده است. Singh و همکاران (۲۰۲۲) در تحقیقی از الگوریتم یادگیری عمیق و جنگل تصادفی با استفاده از تصاویر ماهواره سنتینل-۲ برای تهیه نقشه انواع کاربری اراضی کشاورزی در بخشی از ایالت پنجاب هند به مساحت ۴۴۳ هکتار استفاده کردند. محصولات عمده فصل زمستان شامل گندم، برسيم، خردل و سایر پوشش‌های گیاهی مورد ارزیابی قرار گرفتند. نتایج نشان داد که یادگیری عمیق با دقت کلی ۹۷/۸٪ نسبت به جنگل تصادفی با دقت کلی ۹۶/۲٪ از دقت بالاتری برخوردار است. این تحقیق به‌ویژه برای تفکیک و شناسایی محصولات خردل و برسيم بسیار مفید واقع شده است.

YI و همکاران (۲۰۲۰) برای تولید نقشه محصولات کشاورزی در حوضه آبریز شی‌یانگ واقع در شمال غربی چین، از داده‌های چندزمانه ماهواره سنتینل-۲ در فصل رشد سال ۲۰۱۹ بهره بردند که منجر به دستیابی به دقت کلی ۹۴٪ شد، متوسط بارش سالانه در این حوضه ۱۵۰ تا ۲۵۰ میلی‌متر و تبخیر سالانه ۱۳۰۰ تا ۲۵۰۰ میلی‌متر است که نشان‌دهنده اقلیم خشک این منطقه می‌باشد. علاوه بر این، نقشه‌ای نسبتاً دقیق از محصولات کشاورزی را می‌توان تنها تا اواخر ژوئیه تولید کرد و این روش قابلیت انتقال به سایر مناطق خشک با ساختار مشابه را نیز دارا است. در ایران نیز رشیدی و جعفری (۱۴۰۳) برای تهیه نقشه‌های پوشش زمین منطقه، شامل ۱۵۷۸۲/۶ هکتار از شهرستان مریوان در منطقه رویشی زاگرس از الگوریتم‌های دسته‌بندی از جمله ماشین بردار پشتیبان، شبکه عصبی، حداکثر احتمال و سایر روش‌ها با استفاده از داده‌های ماهواره‌ای سنتینل-۲ استفاده کردند. این تحقیق با ارزیابی ۲۰ الگوریتم مختلف دسته‌بندی، تحلیل جامعی از عملکرد الگوریتم‌ها در پردازش تصاویر ماهواره‌ای سنتینل ارائه داد که می‌تواند به مقایسه دقیق‌تر با سایر تحقیقات مشابه کمک کند. خسروی (۱۴۰۳) در

¹ Random Forest (RF)

² Support Vector Machine (SVM)

۱۰ ساله (۲۰۱۴ تا ۲۰۲۴) مورد تجزیه و تحلیل قرار خواهد گرفت.


روش تحقیق

منطقه مورد مطالعه

دشت ایسین در فاصله حدود ۲۴ کیلومتری شمال غرب شهر بندرعباس در استان هرمزگان واقع شده است. این دشت در مختصات جغرافیایی $27^{\circ} 14'$ تا $26^{\circ} 26'$ عرض شمالی و $56^{\circ} 1'$ تا $56^{\circ} 21'$ طول شرقی واقع شده و ارتفاع آن بین ۱۲۰ متر در دامنه گوه گنو تا ۶۰ متر در خط القعر دشت از سطح دریا متغیر می‌باشد. مساحت آبخوان ایسین نیز حدود $101/48$ کیلومتر مربع است. میانگین بارندگی بلندمدت منطقه در بازه زمانی سال‌های ۱۳۷۳ تا ۱۴۰۲ برابر با $179/5$ میلی‌متر در سال گزارش شده است. دشت ایسین از گذشته‌های دور به دلیل برخورداری از منابع آب شیرین و خاک حاصلخیز، یکی از قطب‌های کشاورزی استان هرمزگان محسوب می‌شود. از جمله محصولات عمده این منطقه می‌توان به خرما، لیموشیرین، سبزیجات و صیفی‌جات به‌ویژه گوجه‌فرنگی، بادمجان و خیارسبز اشاره کرد (شکل ۱).

یکی از مطالعات خود، با بهره‌گیری از تصاویر ماهواره‌ای لندست ۸ و استفاده از مجموعه‌ای از الگوریتم‌های پیشرفته یادگیری ماشین، چارچوبی جهت تولید نقشه نوع محصولات کشاورزی در منطقه مرودشت استان فارس ارائه داد. یافته‌ها نشان داد که الگوریتم‌های تحلیل انحراف زمانی پویا و جنگل تصادفی در مقایسه با سایر روش‌ها دقت بالاتری داشته‌اند و دقت کلی نقشه‌برداری نوع محصول را بین ۱۰ تا ۱۲ درصد بهبود داده‌اند. حاجی‌الیاسی و همکاران (۱۴۰۳) در تحقیقی به‌منظور بررسی تغییرات کاربری اراضی در حوضه آبخیز تالاب انزلی از ترکیب الگوریتم SAM^3 و جنگل تصادفی به تجزیه و تحلیل تصاویر سنتینل-۲ در طی سال‌های ۲۰۱۹ تا ۲۰۲۳ پرداخته‌اند. نتایج نشان داد که در طی ۵ سال، بیشترین تغییرات در کاربری‌های پهنه آب (کاهش)، تالاب (افزایش) و مناطق انسان‌ساخت مشاهده شده و دقت کلی مدل‌سازی بیش از ۸۷ درصد بود و دقت دسته‌بندی در کاربری پهنه آب بیش از ۹۰ درصد به‌دست آمد. محرمی (۱۴۰۱) در پژوهش خود با هدف تهیه نقشه پوشش اراضی شهری شهر تبریز از داده‌های ماهواره‌ای سنتینل-۲ و الگوریتم یادگیری شامل جنگل تصادفی و یادگیری عمیق مبتنی بر شبکه عصبی استفاده شد. به‌طور کلی، هر دو الگوریتم عملکرد مناسبی در استخراج نقشه پوشش اراضی شهری داشتند، اما الگوریتم یادگیری عمیق با دقت کلی $95/2$ آن را به گزینه‌ای مؤثرتر در این مطالعه تبدیل کرده است. در این پژوهش تلاش خواهد شد با استفاده از بازدیدهای میدانی و جمع‌آوری نقاط واقعیت زمینی مربوط به کاربری‌های اراضی مختلف و نوع محصولات کشاورزی و با بهره‌گیری از تصاویر ماهواره‌ای لندست ۸، سنتینل-۲ و به کارگیری الگوریتم‌های یادگیری ماشین، نقشه کاربری اراضی و نقشه پراکنش انواع محصولات کشاورزی در دشت ایسین استان هرمزگان تهیه شود. همچنین تغییرات کاربری اراضی در این دشت مهم نیز در بازه زمانی

³ Spectral Angle Mapper (SAM)



شکل ۱- موقعیت جغرافیایی دشت ایسین در استان هرمزگان و ایران

جمع‌آوری اطلاعات

داده‌ها، میزان تغییرات سطح هر نوع (دسته) کاربری اراضی بر حسب هکتار محاسبه گردید. برای محاسبه مساحت از تعداد پیکسل‌ها، باید از اندازه هر پیکسل در تصاویر ماهواره‌ای استفاده شود [۹] (معادله ۱). تصاویر ماهواره لندست ۸ برای استخراج نقشه کاربری اراضی و بررسی تغییرات آن، از پایگاه داده سازمان زمین‌شناسی آمریکا (USGS) دریافت گردیدند. برای هر سال، تصویری با کمترین میزان ابر و بهترین کیفیت دیداری انتخاب شد. این داده‌ها به‌منظور تحلیل وضعیت مزارع کشاورزی و شناسایی دقیق آن استفاده گردیدند. همچنین برای تهیه نقشه نوع محصول کشاورزی در دشت ایسین، تصاویر ماهواره‌ای Sentinel2 (MSI) متعلق به سازمان فضایی اروپا از سایت Open Access Hub دریافت شدند.

$$A_{ha} = \frac{N \times S^2}{10000}$$


رابطه (۱):

A : مساحت (ha)

N : تعداد پیکسل‌ها

S : اندازه تفکیک مکانی پیکسل (m)

بازدیدهای میدانی و سنجش از دور، به‌عنوان دو منبع اصلی برای دستیابی به اطلاعات کاربری اراضی و کشاورزی، نقش بسیار مهمی دارند [۱۹]. جهت تهیه نقشه کاربری و محصولات، از تصاویری استفاده شد که شامل داده‌های مربوط به فصل رشد محصولات کشاورزی در سال زراعی جاری بودند (شکل ۲). این تصاویر، مطابق با تاریخ برداشت نقاط واقعیت زمینی بودند و اطلاعات مهمی از وضعیت پوشش گیاهی و کشاورزی منطقه در آن زمان ارائه دادند. در این پژوهش، به‌منظور تهیه نقشه کاربری اراضی، در مجموع ۸۹۸ نقطه واقعیت زمینی از دسته‌های باغات، اراضی زراعی، اراضی آیش، ساخت‌وساز انسانی و شوره‌زار برداشت شد (جدول ۱). همچنین برای تهیه نقشه نوع محصولات، ۵۱۳ نقطه واقعیت زمینی شامل دسته‌های بادمجان، فلفل دلمه‌ای، باغات و شوره‌زار جمع‌آوری و مورد استفاده قرار گرفت (جدول ۲). برای بررسی تغییرات در بازه زمانی ۲۰۲۴-۲۰۱۴، از تصاویر ماهواره لندست ۸ استفاده شد. براساس این



شکل ۲- نقاط واقعیت زمینی جمع‌آوری شده در بازدید میدانی برای کاربری‌های اراضی

جدول ۱- تعداد نقاط واقعیت زمینی برای هر کاربری

نوع کاربری	تعداد نقاط
باغات	۱۵۶
زراعت	۳۰۴
ساخت و ساز انسانی	۲۱۰
اراضی آیش	۱۲۴
شوره‌زار	۱۰۴
جمع نقاط	۸۹۸

جدول ۲- تعداد نقاط واقعیت زمینی برای هر محصول زراعی

نوع محصول	تعداد نقاط
بادمجان	۱۷۸
باغات	۱۵۵
فلفل دلمه‌ای	۴۲
شوره‌زار	۱۳۸
جمع نقاط	۵۱۳

شاخص‌های طیفی

کاربرد گسترده شاخص‌های طیفی در زمینه‌هایی همچون شناسایی و پایش تغییرات کاربری اراضی و پوشش گیاهی، کشاورزی دقیق، پایش خشکسالی، مدیریت منابع آبی و ارزیابی آسیب‌های ناشی از آتش‌سوزی، نشان‌دهنده اهمیت بالای این ابزار در مطالعات محیط‌زیستی و برنامه‌ریزی‌های مدیریتی

است [۲۱]. برای تقویت توان تفکیک کاربری‌های مختلف اراضی و استخراج ویژگی‌های کلیدی پوشش سطح زمین، پنج شاخص طیفی اصلی از تصاویر لندست ۸ محاسبه شد، محاسبه این شاخص‌ها با هدف افزایش دقت دسته‌بندی و تمایز بهتر میان کاربری‌های زراعی، مرتعی، آبی و شهری صورت گرفت. به‌ویژه، استفاده از BSI امکان تفکیک دقیق‌تر

نواحی بدون پوشش گیاهی را فراهم کرده و به بهبود صحت نقشه کاربری اراضی دشت ایسین کمک نمود (جدول ۳).

جدول ۳- شاخص‌های طیفی محاسبه شده به عنوان ورودی مدل‌های تشخیص نوع کاربری و نوع محصول			
نام شاخص	مخفف	رابطه	منبع اصلی
Normalized Difference Water Index	NDWI	$NDWI = \frac{(Green - NIR)}{(Green + NIR)}$	۱۹۹۶, McFeeters
Normalized Difference Vegetation Index	NDVI	$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$	Rouse و همکاران، ۱۹۷۳
Enhanced Vegetation Index	EVI	$EVI = 2.5 \times \frac{(NIR - RED)}{(NIR + 6 \times RED - 7.5 \times BLUE) + 1}$	Huete و همکاران، ۲۰۰۲
Normalized Difference Built-Up Index	NDBI	$NDBI = \frac{(SWIR - NIR)}{(SWIR + NIR)}$	Zha و همکاران، ۲۰۰۳
Bare Soil Index	BSI	$BSI = \frac{(SWIR + RED) - (NIR + Blue)}{(SWIR + RED) + (NIR + Blue)}$	Diek و همکاران، ۲۰۱۷

انتخاب متغیرها

برای بهبود عملکرد مدل‌های یادگیری ماشین و کاهش پیچیدگی داده‌ها، از فرآیند انتخاب ویژگی‌ها^۴ استفاده شد. این مرحله به منظور شناسایی و حذف ویژگی‌های (متغیرهای مستقل) غیرضروری و افزایشی که ممکن است منجر به کاهش دقت مدل شوند، انجام گردید. برای شناسایی وابستگی میان ویژگی‌ها و جلوگیری از همبستگی بالا که ممکن بود موجب کاهش کارایی مدل‌ها شود، از دو روش اصلی استفاده گردید که به منظور کاهش هم‌پوشانی داده‌ها و جلوگیری از بیش‌برازش، از آزمون هم‌خطی چندگانه با استفاده از شاخص‌های VIF و حد قابل تحمل^۵ استفاده شد. به صورتی که ویژگی‌های با مقادیر VIF بزرگتر از ۱۰ و حد قابل تحمل کمتر از ۰/۱۱ حذف گردید [۴]. سپس الگوریتم Boruta برای انتخاب ویژگی‌های مؤثر به کار گرفته شد و ویژگی‌های تایید شده در مرحله هم‌خطی چندگانه به این الگوریتم معرفی گردیدند و نتایج نشان داد که همه این

ویژگی‌ها مهم و معنادار تشخیص داده شدند. بدین ترتیب، Boruta نتایج آزمون هم‌خطی را تایید کرده و همان ویژگی‌ها را به عنوان ترکیب ورودی منتخب برای مدل معرفی نمود. الگوریتم Boruta مبتنی بر جنگل تصادفی بوده و با ایجاد نسخه‌های تصادفی از متغیرهای اصلی (متغیرهای سایه)^۶، اهمیت هر ویژگی را در مقایسه با بیشینه اهمیت ویژگی‌های تصادفی ارزیابی می‌کند. به کارگیری هم‌زمان این روش‌ها در مطالعات منابع طبیعی رویکردی مؤثر شناخته شده است، به گونه‌ای که این ترکیب با حذف متغیرهای غیرمؤثر و کاهش هم‌پوشانی اطلاعاتی، نقش مهمی در بهبود دقت دسته‌بندی و افزایش پایداری مدل‌های پیش‌بینی دارد [۷].

الگوریتم‌های یادگیری ماشین

به منظور دسته‌بندی مکانی کاربری‌های مختلف اراضی و نوع محصولات زراعی، دو الگوریتم یادگیری ماشین پرکاربرد یعنی جنگل تصادفی و ماشین بردار پشتیبان به کار گرفته شد. ابتدا مجموعه داده آموزش شامل

^۴ Feature Selection

^۵ Tolerance

^۶ Shadow Features

می‌دهند. دقت مثبت و دقت منفی نیز احتمال صحت پیش‌بینی‌های مثبت و منفی را بیان می‌کنند و شیوع، سهم واقعی هر دسته در داده‌های واقعیت زمینی را مشخص می‌کند. نرخ شناسایی نسبت نمونه‌های به‌درستی شناسایی شده به کل نمونه‌ها را نشان می‌دهد و نرخ شیوع شناسایی نیز سهم نمونه‌های پیش‌بینی شده به‌عنوان یک دسته در کل نمونه‌ها را مشخص می‌کند [۲]. در نهایت، خروجی هر دو الگوریتم شامل نقشه‌های دسته‌بندی شده کاربری اراضی و نوع محصولات زراعی تولید گردید.

نتایج

نقشه کاربری اراضی با استفاده از یادگیری

ماشین در بازه زمانی ۲۰۱۴-۲۰۲۴

برای تهیه نقشه کاربری اراضی دشت ایسین از دو الگوریتم یادگیری ماشین از جمله ماشین بردار پشتیبان و جنگل تصادفی استفاده شد. این الگوریتم‌ها به دلیل پرکاربرد بودن و توانایی بالای خود در دسته‌بندی داده‌های پیچیده و پراکنده، انتخاب گردیدند. متغیرهای مستقل شامل مقادیر باندهای طیفی مختلف ماهواره لندست ۸ و مجموعه‌ای از شاخص‌های طیفی مرتبط با پوشش گیاهی، خاک لخت و سطوح ساخته شده بودند. باندهای مورد بررسی شامل طیف‌های مرئی، فروسرخ نزدیک، فروسرخ با طول موج کوتاه و همچنین باند حرارتی می‌شدند. در گام نخست، به منظور کاهش هم‌پوشانی داده‌ها و جلوگیری از بیش‌برازش، آزمون هم‌خطی‌چندگانه انجام شد. براساس نتایج این آزمون، باندهای B10 و B5، شاخص‌های NDVI و NDBI به‌عنوان ویژگی‌های مؤثر انتخاب گردیدند (جدول ۵). در ادامه، الگوریتم Boruta به کار گرفته شد و ویژگی‌های تاییده شده در مرحله هم‌خطی چندگانه به این الگوریتم معرفی گردیدند. نتایج نشان داد که همه این ویژگی‌ها مهم بوده و بدین ترتیب نتایج حاصل از هم‌خطی چندگانه تایید گردید و باندهای B10 و B5، شاخص‌های NDVI و NDBI به‌عنوان ورودی نهایی به مدل معرفی شدند. (شکل ۳). در این

۷۰٪ نقاط واقعیت زمینی در اختیار هر دو مدل قرار گرفت. الگوریتم جنگل تصادفی بر مبنای ایجاد تعداد زیادی درخت تصمیم مستقل عمل می‌کند؛ هر درخت با نمونه‌گیری تصادفی از داده‌ها و ویژگی‌ها آموزش می‌بیند و نتیجه نهایی از طریق رأی‌گیری اکثریت درخت‌ها تعیین می‌شود. این رویکرد باعث افزایش پایداری مدل و کاهش احتمال بیش‌برازش می‌شود [۱۲]. ماشین بردار پشتیبان از طریق یافتن صفحه جداساز بهینه که بیشترین فاصله را تا نزدیک‌ترین نقاط هر دسته حفظ کند، داده‌ها را دسته‌بندی می‌کند [۵]. در این پژوهش برای مدل‌سازی روابط غیرخطی، از تابع کرنل شعاعی (RBF^7) استفاده شد و مقادیر بهینه فرایارامترهای نرم‌سازی (C) و عرض کرنل (γ) از طریق اعتبار سنجی متقابل ۵ بخشی^۸ در مرحله آزمون برآورد شد. مدل‌های آموزش دیده روی ۳۰٪ داده‌های باقی‌مانده با استفاده از مجموعه‌ای از شاخص‌های مبتنی بر ماتریس خطا شامل دقت کلی^۹، ضریب کاپا^{۱۰}، دقت متوازن^{۱۱}، حساسیت^{۱۲}، ویژگی^{۱۳}، دقت مثبت^{۱۴}، دقت منفی^{۱۵} و شیوع^{۱۶}، نرخ شناسایی^{۱۷} و نرخ شیوع شناسایی^{۱۸} مورد ارزیابی قرار گرفت (جدول ۴). دقت کلی نسبت نمونه‌هایی که به درستی دسته‌بندی شده به کل نمونه‌ها را نشان می‌دهد، درحالی‌که ضریب کاپا میزان توافق دسته‌بندی با داده‌های واقعیت زمینی را با حذف اثر شانس بیان می‌کند. دقت متوازن میانگین حساسیت و ویژگی بوده و برای ارزیابی عملکرد مدل در داده‌های نامتوازن کاربرد دارد. حساسیت و ویژگی به ترتیب توانایی مدل در شناسایی صحیح نمونه‌های مثبت و منفی را نشان

⁷ Radial Basis Function

⁸ 5-fold cross validation

⁹ Overall Accuracy

¹⁰ Kappa Coefficient

¹¹ Balanced Accuracy

¹² Sensitivity

¹³ Specificity

¹⁴ Positive Predictive Value

¹⁵ Negative Predictive Value

¹⁶ Prevalence

¹⁷ Detection Rate

¹⁸ Detection Prevalence

مطالعه، ۸۹۸ نقطه واقعیت زمینی از پنج کلاس باغات، اراضی زراعی، ساخت‌وساز انسانی، اراضی آیش و شوره‌زار برداشت شد. این نقاط با هدف پوشش مناسب تمامی کلاس‌های موجود در منطقه انتخاب گردیدند و سپس برای آموزش مدل و اعتبارسنجی نتایج مورد استفاده قرار گرفتند. ابتدا، عملکرد مدل‌ها براساس معیارهای دقت کلی و ضریب کاپا بررسی شده، سپس ماتریس سردرگمی به‌منظور نمایش میزان دسته‌بندی صحیح و نادرست هر یک از دسته‌های کاربری اراضی مورد استفاده قرار گرفت. در ادامه، عملکرد مدل‌ها با استفاده از معیارهای ارزیابی شامل حساسیت، ویژگی، دقت مثبت، دقت منفی، شیوع، نرخ شناسایی، شیوع شناسایی و دقت متوازن مورد بررسی قرار می‌گیرد.


جدول ۴- معیارهای عملکردی مورد استفاده در ارزیابی مدل‌های یادگیری ماشین

معیار عملکردی	رابطه	دامنه تغییرات
دقت کلی	$Overall Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$	[۰,۱]
ضریب کاپا	$Kappa Coefficient = \frac{(P_o - P_e)}{(1 - P_e)}$	[-۱,۱]
دقت متوازن	$Balanced Accuracy = \frac{TPR+TNR}{2}$	[۰,۱]
حساسیت	$Sensitivity = \frac{TP}{TP+FN}$	[۰,۱]
ویژگی	$Specificity = \frac{TN}{TN+FP}$	[۰,۱]
دقت مثبت	$Positive Predictive Value = \frac{TP}{TP+FP}$	[۰,۱]
دقت منفی	$Negative Predictive Value = \frac{TN}{TN+FN}$	[۰,۱]
شیوع	$Prevalence = \frac{TP+FN}{TP+FP+TN+FN}$	[۰,۱]
نرخ شناسایی	$Detection Rate = \frac{TP}{TP+FP+TN+FN}$	[۰,۱]
شیوع شناسایی	$Detection Prevalence = \frac{TP+FP}{TP+FP+TN+FN}$	[۰,۱]

TP: True Positives (مثبت‌های درست) FP: False Positives (منفی‌های نادرست)
 TN: True Negatives (منفی‌های درست) FN: False Negatives (مثبت‌های نادرست)
 TPR: True Positives Rate (نرخ حساسیت) TNR: True Negatives Rate (نرخ اختصاصی)

جدول ۵ - ویژگی‌های انتخاب‌شده بعد از حذف گام به گام براساس آزمون هم‌خطی چندگانه

باند	حد مجاز (قابل تحمل) Tolerance	عامل تورم واریانس VIF
B10	۰/۵۷۷	۱/۷۳۴
B5	۰/۷۸۴	۱/۲۷۵
NDVI	۰/۱۳۰	۷/۶۸۱
NDBI	۰/۱۱۹	۸/۳۹۱



شکل ۳ - انتخاب ویژگی با استفاده از الگوریتم Boruta برای شناسایی نوع کاربری اراضی

جدول ۶ - ارزیابی عملکرد مدل ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) در مراحل آموزش و آزمایش در سال ۲۰۲۴ و ۲۰۱۴.

سال	مدل	آموزش		آزمایش	
		دقت کلی	ضریب کاپا	دقت کلی	ضریب کاپا
۲۰۲۴	SVM	۸۸/۷۵	۸۵/۲۷	۸۷/۴۵	۸۳/۶۴
	RF	۸۵/۰۵	۸۰/۴۷	۸۱/۹۲	۷۶/۲۷
۲۰۱۴	SVM	۷۹/۷۴	۷۳/۱۳	۷۴/۱۷	۶۵/۹۲
	RF	۷۷/۱۷	۶۹/۴۸	۶۴/۹۴	۵۲/۹۱

براساس داده‌های جدول ۶ عملکرد دو مدل ماشین بردار پشتیبان و جنگل تصادفی در دسته‌بندی انواع کاربری اراضی در سال ۲۰۱۴ و ۲۰۲۴ مورد بررسی قرار گرفته است. برای سال ۲۰۲۴، نقاط نمونه‌برداری با استفاده از دستگاه GPS برداشت شد. اما به دلیل عدم دسترسی به داده برای سال ۲۰۱۴، موقعیت همان نقاط در سامانه گوگل ارث انجین شناسایی و داده‌های ماهواره‌ای مربوط به آن سال استخراج گردید و سپس برای مقایسه با داده‌های ۲۰۲۴ مورد استفاده قرار گرفت. مدل ماشین بردار پشتیبان در سال ۲۰۲۴ در مرحله آموزش، دقت کلی ۸۸/۷۵ درصد و ضریب کاپا ۸۵/۲۷ را کسب کرده که نشان‌دهنده توان قابل توجه این مدل در یادگیری و تطابق با داده‌های آموزشی است. همچنین در سال ۲۰۱۴ نیز مدل ماشین بردار پشتیبان با دقت کلی

۷۹/۷۴ و ضریب کاپای ۷۳/۱۳ توانست ساختار داده‌های آموزشی را با دقت قابل قبولی انجام دهد. در مرحله آزمایش در سال ۲۰۲۴ نیز مدل ماشین بردار پشتیبان با دقت کلی ۸۷/۴۵ درصد و ضریب کاپا ۸۳/۶۴ را به دست آورده و در مرحله آزمایش در سال ۲۰۱۴ مدل ماشین بردار پشتیبان دقت کلی ۷۴/۱۷ و ضریب کاپای ۶۵/۹۲ را کسب کرد. این کاهش اندک نسبت به مرحله آموزش، کاملاً طبیعی بوده و نشان‌دهنده عملکرد نسبتاً پایدار مدل در مواجهه با داده‌های مستقل آزمایش است. در مجموع، مدل ماشین بردار پشتیبان در هر دو مرحله آموزش و آزمایش، دقت و ثبات بیشتری از خود نشان داده و به عنوان گزینه مناسب‌تر برای دسته‌بندی کاربری اراضی در سال‌های ۲۰۲۴ و ۲۰۱۴ معرفی می‌شود. در جدول ۷، تعداد نمونه‌های صحیح شناسایی شده

براساس ماتریس سردرگمی مدل ماشین بردار پشتیبان در سال‌های ۲۰۱۴ و ۲۰۲۴ ارائه شده است. همچنین، در جدول ۸، ارزیابی عملکرد این مدل در سال‌های مذکور با استفاده از معیارهای مختلف به‌منظور بررسی دقیق‌تر نتایج دسته‌بندی کاربری‌های اراضی ارائه شده است.

جدول ۷- تعداد نمونه‌های صحیح کلاس‌های کاربری اراضی براساس ماتریس سردرگمی در سال‌های ۲۰۱۴ و ۲۰۲۴

کلاس کاربری	۲۰۱۴	۲۰۲۴
باغات	۳۳	۳۷
زراعت	۷۸	۸۳
اراضی آیش	۱۴	۲۷
ساخت و ساز انسانی	۴۸	۵۸
شوره‌زار	۲۸	۳۲

تعداد نمونه‌های صحیح در دسته ساخت و ساز انسانی از ۴۸ به ۵۸ نمونه، در دسته زراعت از ۷۸ به ۸۳ نمونه، در دسته باغات از ۳۳ به ۳۷ نمونه و در دسته شوره‌زار از ۲۸ به ۳۲ نمونه رسید. این نتایج بیانگر بهبود عملکرد مدل در شناسایی صحیح دسته‌های مختلف کاربری اراضی بوده و نشان می‌دهد که مدل ماشین بردار پشتیبان در سال ۲۰۲۴ نسبت به سال ۲۰۱۴ توانایی بیشتری در تفکیک دسته‌های کاربری اراضی داشته است.


براساس جدول ۷، تعداد نمونه‌های صحیح شناسایی شده توسط مدل ماشین بردار پشتیبان برای دسته‌های مختلف کاربری اراضی در سال‌های ۲۰۱۴ و ۲۰۲۴ مورد مقایسه قرار گرفت. نتایج نشان می‌دهد که تعداد نمونه‌های صحیح در تمامی دسته‌های کاربری در سال ۲۰۲۴ نسبت به سال ۲۰۱۴ افزایش یافته است. بیشترین افزایش مربوط به دسته اراضی آیش بود، به‌طوری‌که تعداد نمونه‌های صحیح این دسته از ۱۴ به ۲۷ نمونه افزایش یافت. همچنین،

جدول ۸ - معیارهای ارزیابی عملکرد مدل ماشین بردار پشتیبان در شناسایی نوع کاربری اراضی در سال‌های ۲۰۱۴ و ۲۰۲۴

معیار عملکردی	باغات	زراعت	اراضی آیش	ساخت و ساز انسانی	شوره‌زار
سال	۲۰۱۴	۲۰۲۴	۲۰۱۴	۲۰۲۴	۲۰۱۴
حساسیت	۷۱/۷۴	۸۰/۴۳	۸۴/۷۸	۹۰/۲۲	۳۶/۸۴
ویژگی	۹۸/۲۲	۹۶/۸۹	۸۰/۴۵	۹۲/۷۴	۹۸/۷۱
دقت مثبت	۸۹/۱۹	۸۴/۰۹	۶۹/۰۳	۸۶/۴۶	۸۲/۳۵
دقت منفی	۹۴/۴۴	۹۶/۰۴	۹۱/۱۴	۹۴/۸۶	۹۰/۵۵
شیوع	۱۶/۹۷	۱۶/۹۷	۳۳/۹۵	۳۳/۹۵	۱۴/۰۲
نرخ شناسایی	۱۲/۱۸	۱۳/۶۵	۲۸/۷۸	۳۰/۶۳	۵/۱۷
شیوع شناسایی	۱۳/۶۵	۱۶/۲۴	۴۱/۷۰	۳۵/۴۲	۶/۲۷
دقت متوازن	۸۴/۹۸	۸۸/۶۶	۸۲/۶۱	۹۱/۴۸	۶۷/۷۸

مثبت مربوط به دسته اراضی آیش ۱۰۰ درصد و بیشترین دقت منفی مربوط به دسته شوره‌زار ۱۰۰ درصد است. بررسی معیار دقت متوازن نیز نشان می‌دهد که عملکرد مدل در تمامی دسته‌ها در سال ۲۰۲۴ نسبت به سال ۲۰۱۴ بهبود یافته است. بیشترین مقدار این معیار مربوط به دسته شوره‌زار ۹۷/۹۱ درصد و ساخت و ساز انسانی ۹۵/۰۷ درصد و کمترین مقدار آن مربوط به دسته اراضی آیش ۸۵/۵۳ درصد است که با وجود این، نسبت به سال ۲۰۱۴ افزایش قابل توجهی داشته است. به‌طور کلی، نتایج حاصل از معیارهای ارزیابی بیانگر آن است که مدل ماشین بردار پشتیبان در سال ۲۰۲۴ نسبت به سال ۲۰۱۴ از دقت و قابلیت تفکیک بالاتری در شناسایی دسته‌های مختلف کاربری اراضی برخوردار بوده است. علاوه بر این، تفاوت عملکرد مدل در دو سال مورد بررسی می‌تواند علاوه بر تعداد نمونه‌ها، تحت تأثیر نحوه توزیع نمونه‌های آموزش و آزمون و میزان نزدیکی ویژگی‌های آن‌ها نیز باشد که این امر بر توانایی تعمیم مدل و دقت دسته‌بندی تأثیرگذار است.

براساس جدول ۸، مقایسه معیارهای ارزیابی عملکرد مدل ماشین بردار پشتیبان در سال‌های ۲۰۲۴ و ۲۰۱۴ نشان می‌دهد که عملکرد مدل در اغلب دسته‌های کاربری اراضی در سال ۲۰۲۴ بهبود یافته است. معیار حساسیت که بیانگر توانایی مدل در شناسایی صحیح نمونه‌های هر دسته است، در تمامی دسته‌ها افزایش یافته و بیشترین مقدار آن مربوط به دسته شوره‌زار ۱۰۰ درصد و ساخت و ساز انسانی ۹۲/۰۶ درصد است. همچنین، حساسیت دسته اراضی آیش از ۳۶/۸۴ درصد در سال ۲۰۱۴ به ۷۱/۰۵ درصد در سال ۲۰۲۴ افزایش یافته که بیانگر بهبود قابل توجه مدل در شناسایی این دسته است. معیار ویژگی نیز برای تمامی دسته‌ها مقادیر بالایی را نشان می‌دهد و در سال ۲۰۲۴ برای دسته اراضی آیش به ۱۰۰ درصد رسیده است که نشان می‌دهد نمونه‌های سایر دسته‌ها به‌ندرت به اشتباه در این دسته قرار گرفته‌اند. همچنین، معیارهای دقت مثبت و دقت منفی در اغلب دسته‌ها نسبت به سال ۲۰۱۴ افزایش یافته‌اند که بیانگر بهبود قابلیت مدل در پیش‌بینی صحیح نمونه‌های مثبت و منفی است. بیشترین دقت



شکل ۴- نقشه‌های تغییرات کاربری اراضی تولیدشده توسط مدل ماشین بردار پشتیبان برای سال ۲۰۱۴ و ۲۰۲۴

آیش نیز کاهش ۸۰۸/۸۳ هکتاری را تجربه کرده‌اند و از ۲۱۳۵/۱۶ هکتار به ۱۳۲۶/۳۳ هکتار کاهش یافته‌اند.

در مقابل، کاربری ساخت‌وساز انسانی طی این دوره با افزایشی برابر با ۴۲۱/۸۳ هکتار از ۱۷۵۳/۳۸ هکتار به ۲۱۷۵/۲۱ هکتار رسیده که نشان‌دهنده رشد شهرنشینی، توسعه مناطق مسکونی یا گسترش زیرساخت‌ها در منطقه است. بیشترین تغییر نیز مربوط به شوره‌زار است که با افزایشی برابر با ۷۱۶۵/۷۱ هکتار، از ۵۰۱۱/۸۳ هکتار به ۲۱۵۳/۸۸ هکتار افزایش یافته‌اند. در مجموع، نتایج بیانگر کاهش فضاهای تولیدی و کشاورزی و گسترش فضاهای شوره‌زار و ساخت‌وساز در منطقه هستند که می‌تواند زنگ خطری برای مدیریت منابع طبیعی و برنامه‌ریزی کاربری زمین در آینده باشد.

جهت بررسی تغییرات کاربری اراضی در بازه زمانی مذکور، پیکسل‌های مربوط به هر نوع کاربری در سال‌های ۲۰۱۴ و ۲۰۲۴ استخراج شدند. با توجه به جدول ۹، تغییرات کاربری اراضی طی دوره زمانی ده‌ساله بین سال‌های ۲۰۱۴ تا ۲۰۲۴، حاصل از دسته‌بندی تصاویر ماهواره‌ای و مقایسه پیکسل‌های هم‌ارز مکانی، نشان‌دهنده تحولات قابل‌توجهی در توزیع کاربری‌های مختلف در منطقه مورد مطالعه است. نتایج حاکی از کاهش محسوس در سطح باغات، اراضی زراعی و اراضی آیش است. سطح باغات از ۴۳۵/۶۹ هکتار در سال ۲۰۱۴ به ۲۱۳/۴۸ هکتار در سال ۲۰۲۴ کاهش یافته و معادل ۲۲۲/۲۱ هکتار از این نوع کاربری کاسته شده است. اراضی زراعی با کاهش ۱۵۴۴/۶۷ هکتار، معادل ۴۰/۵۸ درصد کاهش، از ۳۸۱۰/۴۲ هکتار در سال ۲۰۱۴ به ۲۲۶۵/۷۵ هکتار در سال ۲۰۲۴ رسیده است. اراضی

جدول ۹- تغییرات کاربری اراضی در بازه زمانی ۲۰۱۴ تا ۲۰۲۴ براساس نتایج دسته‌بندی مدل ماشین بردار پشتیبان

نام دسته	سال ۲۰۱۴ (هکتار)	سال ۲۰۲۴ (هکتار)	تغییرات (هکتار)
باغات	۴۳۵/۶۹	۲۱۳/۴۸	-۲۲۲/۲۱
اراضی زراعی	۳۸۱۰/۴۲	۲۲۶۵/۷۵	-۱۵۴۴/۶۷
اراضی آیش	۲۱۳۵/۱۶	۱۳۲۶/۳۳	-۸۰۸/۸۳
ساخت و ساز انسانی	۱۷۵۳/۳۸	۲۱۷۵/۲۱	۴۲۱/۸۳
شوره‌زار	۵۰۱۱/۸۳	۷۱۶۵/۷۱	۲۱۵۳/۸۸
مجموع مساحت	۱۳۱۴۶/۴۸		


تهیه نقشه نوع محصولات زراعی

با هدف تهیه نقشه محصولات عمده کشاورزی سال ۲۰۲۴ در دشت ایسین واقع در استان هرمزگان، در بازدید صحرایی از منطقه ۵۱۳ نقطه واقعیت زمینی جهت بررسی و تهیه نقشه نوع محصول برداشت گردید، و همچنین از تصاویر ماهواره‌ای سنتینل ۲ به همراه الگوریتم‌های یادگیری ماشین بهره گرفته شد. شناسایی صحیح و دقیق پراکنش محصولات کشاورزی در مقیاس منطقه‌ای، از جمله نیازهای اساسی در مدیریت بهینه منابع طبیعی، برنامه‌ریزی

کشاورزی، و افزایش بهره‌وری در اراضی زراعی محسوب می‌شود. برای آموزش مدل‌ها، از ۷۰ درصد نقاط برداشت‌شده در بازدیدهای میدانی استفاده گردید، درحالی‌که ۳۰ درصد باقی‌مانده به منظور آزمون و ارزیابی مستقل مدل‌ها نگه‌داشته شد. با هدف سنجش عملکرد الگوریتم‌ها، از معیارهای ارزیابی دقت کلی و ضریب کاپا استفاده گردید. این معیارها به تفکیک برای هر دسته محصول و نیز در سطح کلی مدل محاسبه شدند. در گام نخست به‌منظور انتخاب ویژگی‌های مؤثر ابتدا

گردیدند. نتایج نشان داد که همه این ویژگی‌ها مهم بوده (شکل ۵) و بدین ترتیب نتایج حاصل از هم‌خطی چندگانه تایید گردید و به‌عنوان ورودی نهایی به مدل معرفی شدند. این فرآیند موجب بهبود عملکرد مدل، افزایش دقت نهایی دسته‌بندی و ساده‌تر شدن ساختار آن گردید.

هم‌خطی چندگانه انجام شد براساس نتایج این آزمون ترکیب انتخاب شده از شاخص‌های طیفی NDVI و BSI به همراه دو باند (B2 و B7) از ماهواره سنتینل-۲ بود (جدول ۱۰). در ادامه، الگوریتم Boruta به‌کار گرفته شد و ویژگی‌های تایید شده در مرحله هم‌خطی چندگانه به این الگوریتم معرفی



شکل ۵ - ویژگی‌های منتخب به‌عنوان ورودی مدل براساس الگوریتم Boruta برای شناسایی نوع محصول زراعی

جدول ۱۰- آماره‌های هم‌خطی چندگانه برای باندها و شاخص‌های طیفی منتخب به‌منظور تولید نقشه نوع محصول

عامل تورم واریانس	حد مجاز (قابل تحمل)	باند
VIF	Tolerance	
۴/۸۵۸	۰/۲۰۶	NDVI_1
۷/۲۶۳	۰/۱۳۸	NDVI_5
۶/۲۹۸	۰/۱۵۹	BSI_1
۶/۱۸۵	۰/۱۶۲	BSI_2
۳/۴۷۱	۰/۲۸۸	BSI_3
۴/۴۱۶	۰/۲۲۶	BSI_4
۵/۵۱۱	۰/۱۸۱	BSI_5
۴/۶۱۸	۰/۲۱۷	B2_Nov.1
۲/۳۶۷	۰/۴۲۳	B7_Dec.4


جدول ۱۱- بررسی کارایی مدل ماشین بردار پشتیبان و جنگل تصادفی در تولید نقشه نوع محصول

آموزش		آزمایش	
مدل ۲۰۲۴		ضرب کاپا	دقت کلی
ضرب کاپا	دقت کلی	ضرب کاپا	دقت کلی

۸۲/۴۶	۸۳/۷۱	۷۹/۱۷	۸۵/۵۸	SVM
۸۴/۵۹	۸۹/۲۹	۸۷	۹۰/۹۱	RF

همچنین در مرحله آزمایش نیز جنگل تصادفی با دقت کلی ۸۹/۲۹ و ضریب کاپا ۸۴/۵۹ نسبت به الگوریتم ماشین بردار پشتیبان با دقت کلی ۸۳/۷۱ درصد و ضریب کاپا ۸۲/۴۶ نتایج مطلوب‌تری را به دست آورد. بنابراین، اگرچه هر دو الگوریتم دقت مناسبی در دسته‌بندی محصولات زراعی داشتند، نتایج بیانگر برتری نسبی الگوریتم جنگل تصادفی از نظر دقت و پایداری عملکرد است و این مدل را به گزینه مناسب‌تری برای تهیه نقشه محصولات زراعی در منطقه مورد مطالعه تبدیل کرده است. در ادامه، ماتریس سردرگمی (جدول ۱۲) و معیار عملکردی (جدول ۱۳) مربوط به عملکرد هر یک از مدل‌ها به‌منظور بررسی دقیق‌تر نتایج ارائه می‌گردد.

در جدول ۱۱، عملکرد دو الگوریتم ماشین بردار پشتیبان و جنگل تصادفی در دسته‌بندی محصولات زراعی سال ۲۰۲۴ براساس دو معیار دقت کلی و ضریب کاپا مورد ارزیابی قرار گرفت. نتایج نشان داد که هر دو الگوریتم از عملکرد قابل قبولی در مرحله آموزش و آزمون برخوردار بوده و توانسته‌اند محصولات زراعی را با دقت مناسبی دسته‌بندی کنند (شکل ۶). با این حال، الگوریتم جنگل تصادفی در هر دو مرحله، مقادیر بالاتری از دقت کلی و ضریب کاپا را نسبت به ماشین بردار پشتیبان به دست آورد. به‌طوری‌که در مرحله آموزش، الگوریتم جنگل تصادفی با دقت کلی ۹۱/۹۰ درصد و ضریب کاپا ۸۷، عملکرد بهتری نسبت به ماشین بردار پشتیبان با دقت کلی ۸۵/۵۸ درصد و ضریب کاپا ۷۹/۱۷ داشته و



شکل ۶ - نقشه‌های نوع محصول تولید شده با استفاده از دو الگوریتم یادگیری ماشین جنگل تصادفی و ماشین بردار پشتیبان

جدول ۱۲ - بررسی ماتریس سردرگمی مدل جنگل تصادفی برای تولید نقشه نوع محصول

واقعیت	پیش‌بینی			
	باغات	بادمجان	شوره‌زار	فلفل دلمه
باغات	۴۷	۱	۰	۰

بادمجان	۱	۴۶	۵	۲
شوره‌زار	۰	۰	۲۵	۰
فلفل دلمه	۰	۴	۲	۷

عملکرد را در بین دسته‌های مورد بررسی نشان داده است. در مقابل، در دسته فلفل دلمه‌ای، از مجموع ۱۳ نمونه واقعی، ۷ نمونه به‌درستی شناسایی شده و ۶ نمونه در سایر دسته‌ها دسته‌بندی شده‌اند که نشان‌دهنده عملکرد ضعیف‌تر مدل در شناسایی این دسته نسبت به سایر دسته‌های مورد بررسی است. به‌طور کلی، نتایج ماتریس سردرگمی نشان می‌دهد که مدل جنگل تصادفی در شناسایی دسته‌های باغات، بادمجان و شوره‌زار عملکرد مطلوبی داشته، درحالی‌که بیشترین خطای دسته‌بندی مربوط به دسته فلفل دلمه‌ای بوده است.

نتایج حاصل از جدول ۱۲ نشان می‌دهد که مدل جنگل تصادفی در شناسایی دسته‌های مختلف نوع محصول عملکرد مناسبی داشته است. در دسته باغات، از مجموع ۴۸ نمونه واقعی، ۴۷ نمونه به‌درستی شناسایی شده و تنها یک نمونه به اشتباه در دسته بادمجان قرار گرفته است که بیانگر دقت بالای مدل در شناسایی این دسته است. در دسته بادمجان نیز ۴۶ نمونه به‌درستی دسته‌بندی شده‌اند، درحالی‌که ۸ نمونه در سایر دسته‌ها قرار گرفته‌اند. دسته شوره‌زار با شناسایی صحیح تمامی ۲۵ نمونه واقعی و بدون هیچ‌گونه خطای دسته‌بندی، بهترین

جدول ۱۳ - بررسی معیارهای عملکردی مدل جنگل تصادفی در تهیه نقشه نوع محصول

معیار عملکردی	باغات	بادمجان	شوره‌زار	فلفل دلمه
حساسیت	۹۷/۹۲	۸۵/۱۹	۱۰۰	۵۳/۸۵
ویژگی	۹۸/۹۱	۹۴/۱۹	۹۳/۹۱	۹۸/۴۳
دقت مثبت	۹۷/۹۲	۹۰/۲۰	۷۸/۱۲	۷۷/۷۸
دقت منفی	۹۸/۹۱	۹۱/۰۱	۱۰۰	۹۵/۴۲
شیوع	۳۴/۲۹	۳۸/۵۷	۱۷/۸۶	۲۹/۹
نرخ شناسایی	۵۷/۳۳	۸۶/۳۲	۸۶/۱۷	۵۰
شیوع شناسایی	۳۴/۲۹	۳۶/۴۳	۲۲/۸۶	۶/۴۳
دقت متوازن	۹۸/۴۱	۸۹/۶۹	۹۶/۹۶	۷۶/۱۴

مثبت پایین ۷۸/۱۲ درصد نشان می‌دهد که تعدادی از نمونه‌های سایر دسته‌ها به اشتباه در این گروه دسته‌بندی شده‌اند. با این حال، ویژگی بالا و دقت منفی کامل، عملکرد مناسب مدل را در تفکیک این دسته از دیگر طبقات تأیید می‌کند. برای دسته فلفل دلمه‌ای نیز حساسیت ۵۳/۸۵ درصد و دقت مثبت ۷۷/۷۸ درصد به‌دست آمده است. با وجود آن‌که مدل در شناسایی تمام نمونه‌های این دسته موفق نبوده، ولی نتایج به‌دست‌آمده قابل قبول ارزیابی می‌شود، به‌ویژه با توجه به سهم نسبتاً کم این دسته در کل

نتایج به‌دست‌آمده از جدول ۱۳ بیانگر عملکرد متفاوت جنگل تصادفی در شناسایی دسته‌های مختلف است. در دسته باغات، مدل دقت بالایی داشته و با حساسیت و ویژگی نزدیک به ۹۸ درصد، توانسته این دسته را با اطمینان خوبی تشخیص دهد. دقت مثبت و منفی نیز در همین محدوده قرار داشته و بیانگر توانایی مناسب مدل در تفکیک این دسته نسبت به سایر دسته‌ها است. در مورد شوره‌زار، حساسیت کامل حاصل شده، که نشان‌دهنده شناسایی کامل نمونه‌های این دسته است. اما دقت

داده‌ها. در مجموع، مدل جنگل تصادفی به‌ویژه در تفکیک دسته باغات و شوره‌زار عملکرد مطلوبی از خود نشان داده است.

بحث و نتیجه‌گیری

این پژوهش با هدف تهیه نقشه کاربری اراضی و شناسایی نوع محصولات زراعی دشت ایسین در استان هرمزگان، با بهره‌گیری از الگوریتم‌های یادگیری ماشین و داده‌های ماهواره‌ای انجام شد. در گام نخست، به‌منظور دسته‌بندی دقیق کاربری‌های اراضی و بررسی تغییرات آن‌ها در بازه زمانی ۲۰۱۴ تا ۲۰۲۴، تصاویر ماهواره‌ای لندست ۸ مورد استفاده قرار گرفتند. دسته‌بندی کاربری‌ها شامل پنج دسته اصلی شامل ساخت‌وساز انسانی، شوره‌زار، اراضی آیش، اراضی زراعی و باغات بود. برای انجام دسته‌بندی، دو الگوریتم پرکاربرد یادگیری ماشین یعنی ماشین بردار پشتیبان و جنگل تصادفی انتخاب و اجرا شدند. به‌منظور ارتقاء دقت مدل‌ها، علاوه بر باندهای طیفی لندست، شاخص‌های مهم طیفی مانند NDVI، NDBI، NDWI، EVI و BSI محاسبه و به‌عنوان ورودی مدل‌ها مورد استفاده قرار گرفتند. همچنین به‌منظور کاهش هم‌پوشانی داده‌ها و جلوگیری از بیش‌برازش، از آزمون هم‌خطی‌چندگانه با استفاده از شاخص‌های VIF و حد قابل تحمل استفاده شد. سپس با به‌کارگیری الگوریتم Boruta، ویژگی‌های مؤثر برای مدل‌سازی نهایی انتخاب شدند. این رویکرد در مطالعات منابع طبیعی و سنجش‌ازدور به‌عنوان روش مؤثر در بهبود دقت و پایداری مدل‌ها گزارش شده است [۴]. در تهیه نقشه کاربری اراضی، نتایج حاصل از اجرای مدل‌ها نشان داد که الگوریتم ماشین بردار پشتیبان در هر دو سال ۲۰۱۴ و ۲۰۲۴ عملکرد بهتری نسبت به الگوریتم جنگل تصادفی داشته است. در سال ۲۰۲۴، ماشین بردار پشتیبان در مرحله آزمون با دقت کلی ۸۷/۴۵ درصد و ضریب کاپای ۸۳/۶۴، نسبت به جنگل تصادفی با دقت کلی ۸۱/۹۲ درصد و ضریب کاپای ۷۶/۲۷، دقت بیشتری در دسته‌بندی کاربری اراضی نشان داد. همچنین در

مرحله آموزش نیز با دقت کلی ۸۸/۷۵ درصد و ضریب کاپای ۸۵/۲۷، در مقایسه با جنگل تصادفی با دقت کلی ۸۵/۰۵ درصد و ضریب کاپای ۸۰/۴۷، عملکرد مطلوب‌تری داشت. در سال ۲۰۱۴ نیز روند مشابهی مشاهده شد؛ به‌طوری‌که ماشین بردار پشتیبان در مرحله آزمون با دقت کلی ۷۴/۱۷ درصد و ضریب کاپای ۶۵/۹۲، در مقایسه با جنگل تصادفی با دقت کلی ۶۴/۹۴ درصد و ضریب کاپای ۵۲/۹۱، و در مرحله آموزش با دقت کلی ۷۹/۷۴ درصد و ضریب کاپای ۷۳/۱۳، در مقایسه با دقت کلی ۷۷/۱۷ درصد و ضریب کاپای ۶۹/۴۸ برای جنگل تصادفی، نتایج دقیق‌تری ارائه کرد. این نتایج نشان می‌دهد که الگوریتم ماشین بردار پشتیبان در تهیه نقشه کاربری اراضی از قابلیت تفکیک و دقت بالاتری برخوردار بوده است. همچنین تغییرات کاربری در بازه ده‌ساله مورد بررسی نشان داد که میزان ساخت‌وسازهای انسانی و شوره‌زارها افزایش یافته و در مقابل، کاهش قابل توجهی در کاربری‌های مرتبط با فعالیت‌های کشاورزی مشاهده شده است که با توجه به پژوهش صالحی و همکاران (۱۴۰۴) این امر می‌تواند ترکیبی از عوامل اقلیمی و انسانی می‌باشد. در بُعد اقلیمی، شرایطی همچون کاهش بارش‌های مؤثر و تداوم خشکسالی‌ها موجب کاهش منابع آب و افت سطح آب‌های زیرزمینی شده است. با توجه به وابستگی بالای دشت ایسین به منابع آب زیرزمینی، بیلان منفی این دشت و افت کمی و کیفی آبخوان آن در سال‌های اخیر نقش مهمی در کاهش توان تولید کشاورزی و افت سطح زیر کشت داشته است. در بُعد انسانی نیز عواملی مانند افزایش تقاضا در سال‌های گذشته، افزایش هزینه‌های تولید، نزدیکی به شهر بندرعباس و گسترش ساخت‌وساز و توسعه شهری، در تشدید این روند مؤثر بوده‌اند. در مجموع، تلفیق عوامل اقلیمی و انسانی منجر به تغییر ساختار کاربری اراضی و تغییر الگوی بهره‌برداری از زمین در منطقه شده است [۱۷]. روندی که نشان‌دهنده گسترش سکونتگاه‌ها و افزایش فشار بر اراضی کشاورزی است. در همین راستا، حاجی‌الیاسی و همکاران (۱۴۰۳) نیز

با بررسی تغییرات کاربری اراضی در حوضه آبخیز تالاب انزلی طی دوره زمانی ۲۰۱۹ تا ۲۰۲۳ و استفاده از تصاویر سنتینل-۲ و الگوریتم‌های یادگیری ماشین، افزایش مناطق انسان‌ساخت و تغییر در برخی کاربری‌های طبیعی را گزارش کردند، مشاهده افزایش مناطق انسان‌ساخت در هر دو پژوهش، نقش فعالیت‌های انسانی در تغییر ساختار کاربری اراضی را تأیید می‌کند، همچنین دقت کلی بیش از ۸۷ درصد در این مطالعه و در پژوهش حاضر، نشان‌دهنده قابلیت مناسب الگوریتم‌های یادگیری ماشین در استخراج اطلاعات کاربری اراضی از تصاویر ماهواره‌ای است. در بخش دوم پژوهش، تمرکز بر تهیه نقشه نوع محصولات زراعی در فصل رشد بود. محصولات عمده شناسایی شده شامل فلفل دلمه‌ای و بادمجان بودند که در اراضی کشاورزی منطقه کشت می‌شدند. با استفاده از همان الگوریتم‌های یادگیری ماشین بردار پشتیبان و جنگل تصادفی، فرآیند دسته‌بندی نوع محصولات زراعی انجام شد. در این مرحله الگوریتم جنگل تصادفی در داده‌های آزمون با دقت کلی ۸۹/۲۹ درصد و ضریب کاپای ۸۴/۵۹ و در داده‌های آموزش با دقت کلی ۹۰/۹۱ درصد و ضریب کاپای ۸۷، عملکرد بهتری نسبت به الگوریتم ماشین بردار پشتیبان با دقت کلی ۸۳/۷۱ درصد و ضریب کاپای ۸۲/۴۶ در داده‌های آزمون و دقت کلی ۸۵/۵۸ درصد و ضریب کاپای ۷۹/۱۷ در داده‌های آموزش نشان داد. این نتایج بیانگر توانایی بیشتر الگوریتم جنگل تصادفی در تهیه نقشه نوع محصولات زراعی است. نتایج این پژوهش با یافته‌های خسروی (۱۴۰۳) در منطقه مرودشت استان فارس همخوانی دارد. در آن مطالعه، عملکرد الگوریتم‌های مختلف یادگیری ماشین شامل جنگل تصادفی، جنگل دورانی، ماشین بردار پشتیبان و تحلیل انحراف زمانی پویا در تهیه نقشه نوع محصولات کشاورزی با استفاده از سری زمانی تصاویر لندست ۸ مقایسه شد، نتایج نشان داد که الگوریتم جنگل تصادفی و تحلیل انحراف زمانی پویا نسبت به سایر روش‌ها عملکرد بهتری داشته و موجب افزایش ۱۰ تا ۱۲ درصدی دقت کلی

نقشه‌برداری محصولات شدند. در پژوهش حاضر نیز برتری الگوریتم جنگل تصادفی نسبت به ماشین بردار پشتیبان بر اساس معیارهای دقت کلی، ضریب کاپا و عملکرد مدل در داده‌های آموزش و آزمون تأیید شد، همچنین Singh و همکاران (۲۰۲۲) با مقایسه الگوریتم‌های جنگل تصادفی و یادگیری عمیق، دقت کلی ۹۶ و ۹۷ درصد را گزارش کردند که نشان‌دهنده عملکرد مطلوب هر دو الگوریتم در شناسایی محصولات کشاورزی است. اگرچه در آن پژوهش، یادگیری عمیق دقت بالاتری نسبت به جنگل تصادفی داشت، اما در پژوهش حاضر جنگل تصادفی نسبت به ماشین بردار پشتیبان عملکرد بهتری نشان داد. این تفاوت‌ها بیانگر آن است که برتری یک الگوریتم، مطلق نیست و به عواملی مانند نوع داده‌های ماهواره‌ای، تعداد نمونه‌های آموزشی، تنوع محصولات، ویژگی‌های طیفی و شرایط منطقه مطالعه وابسته است. از این رو، برتری جنگل تصادفی در پژوهش حاضر را می‌توان ناشی از توانایی این الگوریتم در مدیریت روابط غیرخطی بین متغیرهای طیفی و کاهش حساسیت به نویز داده‌ها دانست که موجب افزایش دقت تفکیک محصولات زراعی شده است. در مجموع، نتایج این تحقیق نشان داد که ترکیب بازدیدهای میدانی، تصاویر ماهواره‌ای و شاخص‌های طیفی حاصل از آنها با الگوریتم‌های یادگیری ماشین می‌تواند ابزاری کارآمد برای پایش تغییرات کاربری اراضی و شناسایی دقیق محصولات کشاورزی با حداقل هزینه و زمان باشد. همچنین انتخاب صحیح ویژگی‌ها و کاهش پیچیدگی داده‌ها نقش مهمی در افزایش دقت مدل‌ها ایفا می‌کند. یافته‌های این مطالعه می‌تواند به‌عنوان مبنایی برای مدیریت منابع طبیعی، برنامه‌ریزی کاربری اراضی و پایش وضعیت اراضی کشاورزی و باغات به‌ویژه در دشت‌های مناطق خشک و نیمه خشک مثل استان هرمزگان مورد استفاده قرار گیرد.

پیشنهادهات

یکی از چالش‌های اصلی در فرآیند برداشت نقاط واقعیت زمینی، الگوی کشت غالب منطقه بود که بیشترین سطح زیر کشت را بادمجان تشکیل می‌داد. این الگو عمدتاً ناشی از توصیه‌های سازمان جهاد کشاورزی به کشاورزان بوده است. همچنین ساختار زمین‌ها به صورت کاملاً یکپارچه و منظم تفکیک نشده بود، به گونه‌ای که در برخی موارد در میان زمین وسیع بادمجان، قطعات کوچکی با کشت متفاوت (مانند گوجه‌فرنگی) مشاهده می‌شد که فرآیند نمونه‌برداری و تفکیک کاربری را با دشواری مواجه ساخت. برای افزایش دقت و قابلیت تعمیم مدل‌ها، توصیه می‌شود در پژوهش‌های بعدی تنوع محصولات مورد مطالعه افزایش یابد و داده‌های مربوط به محصولات متنوع‌تری جمع‌آوری شود. این امر به مدل‌ها کمک می‌کند تا الگوهای متفاوت عملکرد محصول را بهتر شناسایی کنند، همچنین جمع‌آوری داده‌های بیشتر و در بازه‌های زمانی طولانی‌تر می‌تواند

کیفیت آموزش مدل‌ها را بهبود بخشد و از مشکلات ناشی از کمبود داده‌ها جلوگیری کند. همچنین، پیشنهاد می‌شود در مطالعات آینده، علاوه بر افزایش تعداد نقاط واقعیت زمینی و تنوع محصولات مورد بررسی، از تصاویر چندزمانه در مراحل مختلف رشد گیاه و ترکیب‌های متنوع‌تری از باندها و شاخص‌های طیفی استفاده شود تا قابلیت تفکیک محصولات با رفتار طیفی مشابه افزایش یابد. همچنین، بررسی تأثیر روش‌های مختلف انتخاب ویژگی و بهینه‌سازی پارامترهای الگوریتم‌های یادگیری ماشین، متناسب با ویژگی‌های منطقه مورد مطالعه، می‌تواند ضمن افزایش دقت و پایداری مدل‌ها، به انتخاب مناسب‌ترین الگوریتم برای تهیه نقشه‌های کاربری اراضی و شناسایی محصولات زراعی کمک کند و با ساخت یک پایگاه داده ملی یا منطقه‌ای با داده‌های دقیق و استاندارد از محصولات مختلف کشاورزی می‌تواند نقش مهمی در پیشرفت پژوهش‌های مرتبط با کشاورزی هوشمند ایفا کند.

References

- [1]. Byerlee, D., Janvry, A., Sadoulet, E., Townsend, R. & Klytchnikova, I. (2008). Agriculture for Development. World Bank Washington ,DC ,pp: 2. doi: 10.1596/978-0-8213-6807-7
- [2]. Congalton, R. G., & Green, K. (2019). Assessing the accuracy of remotely sensed data: principles and practices. CRC press. doi: 10.1201/9780429052729
- [3]. Diek, S., Fornallaz, F., Schaepman, M. E., & De Jong, R. (2017). Barest pixel composite for agricultural areas using landsat time series. *Remote Sensing*, 9(12), 1245. doi: 10.3390/rs9121245
- [4]. Ebrahimi-Khusfi, Z., Nafarzadegan, A. R., & Dargahian, F. (2021). Predicting the number of dusty days around the desert wetlands in southeastern Iran using feature selection and machine learning techniques. *Ecological Indicators*, 125, 107499. doi: 10.1016/j.ecolind.2021.107499
- [5]. Gómez, C., White, J. C., & Wulder, M. A. (2016). Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of photogrammetry and Remote Sensing*, 116, 55-72. doi: 10.1016/j.isprsjprs.2016.03.008
- [6]. Haji Elyasi, A., Nasseri, M., & Badiei, P. (2024). Assessment of Land Use Changes Based on the Integration of Machine Learning Method and Spectral Angle Mapper Algorithm Using Training Samples Migration: A Case Study of Anzali Wetland Basin. *Physical Geography Research*, 56(4), 39-56. doi: 10.22059/jphgr.2025.384462.1007848 (in Farsi).
- [7]. Han, X., Ye, H., Zhang, Y., Nie, C., & Wen, F. (2024). Study on the method of vineyard information extraction based on spectral and texture features of GF-6 satellite imagery. *Agronomy*, 14(11), 2542. doi: 10.3390/agronomy14112542
- [8]. Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote sensing of environment*, 83(1-2), 195-213. doi: 10.1016/S0034-4257(02)00096-2
- [9]. Jensen, J. R. (1996). Introductory digital image processing: a remote sensing perspective.

- [10]. Khalfi, J., & Davarpanah, G. R. (2006). Estimating the area and preparing a map of the lands under rainfed wheat cultivation using GIS and remote sensing in the Zanzan-Rood watershed. (in Farsi).
- [11]. Khosravi, I. (2024). Crop Mapping from Landsat-8 Images Time Series Using Machine-Learning Methods (Case Study: Marvdasht in Fars Province). *Geography and Environmental Planning*, 35(2), 45-66. doi: 10.22108/gep.2024.138615.1601 (in Farsi).
- [12]. Li, Y., Wang, W., Wang, G., & Tan, Q. (2022). Actual evapotranspiration estimation over the Tuojiang River Basin based on a hybrid CNN-RF model. *Journal of Hydrology*, 610, 127788. doi: 10.1016/j.jhydrol.2022.127788
- [13]. McFeeters, S. K. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425-1432. doi: 10.1080/01431169608948714
- [14]. Moharmi, M., & Nisani, S. N. (1401/2022). Comparing the performance of partitioning and random forest methods in urban land cover classification (Case study: Tabriz city). (in Farsi).
- [15]. Rashidi, F., & Jafari, A. (2014). Investigating the efficiency of supervised algorithms in land cover mapping using Sentinel 2 images in the Zagros forest habitat. *Iranian Forest Journal*, 16(1), 25-36. doi: 10.22034/ijf.2023.328404.1849 (in Farsi).
- [16]. Rouse, J. W., Hass, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. *Proceedings of the third ERTS symposium*, NASA SP-351, pp. 309-317.
- [17]. Salehi, M., Mahdavi Najaf Abadi, R., Rezai, M., Nafarzadegan, A. R., & Ghorbani, M. (2025). Prediction of the Aquifer Status in the Isin-Bandar Abbas Plain Using a System Dynamics Model. *Journal of Arid Biome*, 15(1), 103-119. (in Farsi). doi: 10.29252/aridbiom.2026.3996
- [18]. Singh, G., Singh, S., Sethi, G., & Sood, V. (2022). Deep learning in the mapping of agricultural land use using Sentinel-2 satellite data. *Geographies*, 2(4), 691-700. doi: 10.3390/geographies2040042
- [19]. Sun, C., Bian, Y., Zhou, T., & Pan, J. (2019). Using of multi-source and multi-temporal remote sensing data improves crop-type mapping in the subtropical agriculture region. *Sensors*, 19(10), 2401. doi: 10.3390/s19102401
- [20]. Xie, G., & Niculescu, S. (2022). Mapping Crop Types Using Sentinel-2 Data Machine Learning and Monitoring Crop Phenology with Sentinel-1 Backscatter Time Series in Pays de Brest, Brittany, France. *Remote Sensing*, 14(18), 4437. doi: 10.3390/rs14184437
- [21]. Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017(1), 1353691. doi: 10.1155/2017/1353691
- [22]. Yi, Z., Jia, L., & Chen, Q. (2020). Crop classification using multi-temporal Sentinel-2 data in the Shiyang River Basin of China. *Remote Sensing*, 12(24), 4052. doi: 10.3390/rs12244052
- [23]. Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International journal of remote sensing*, 24(3), 583-594. doi: 10.1080/01431160304987
- [24]. Zhu, L., Radeloff, V. C., & Ives, A. R. (2017). Improving the mapping of crop types in the Midwestern US by fusing Landsat and MODIS satellite data. *International journal of applied earth observation and geoinformation*, 58, 1-11. doi: 10.1016/j.jag.2017.01.012

Production and Evaluation of Land Use and Crop Type Maps using Satellite Imagery and Data-Driven Learning-Based Models in the Isin Plain, Hormozgan Province (Research Paper)

1 -Fatemeh Kheiri, M.Sc. Graduate, Department of Natural Resources Engineering, Faculty of Agriculture and Natural Resources, University of Hormozgan, Bandar Abbas, Iran.

2 -Alireza Nafarzadegan*, Associate Professor, Department of Natural Resources Engineering, Faculty of Agriculture and Natural Resources, University of Hormozgan, Bandar Abbas, Iran.

a.r.nafarzadegan@hormozgan.ac.ir

3- Rasoul Mahdavi, Associate Professor, Department of Natural Resources Engineering, Faculty of Agriculture and Natural Resources, University of Hormozgan, Bandar Abbas, Iran.

Received: 14 May. 2026

Accepted: 27 Aug. 2026

Abstract

The aim of this study was to evaluate the performance of machine learning models in producing land use maps and identifying crop types, as well as to analyze land use changes during the 2014–2024 period in the Isin Plain, Hormozgan Province, Iran. Owing to its abundant freshwater resources and fertile soils, the Isin Plain has long been recognized as one of the major agricultural regions of the province. During field surveys, 898 ground truth points were collected for land use mapping, including orchards (mango, lemon, and date palm), croplands, fallow lands, barren lands, and built-up areas. In addition, 513 ground truth points were collected for crop type mapping, including eggplant, bell pepper, orchards, and barren lands. Landsat 8 imagery was used for land use mapping, while Sentinel-2 imagery was employed for crop type identification. Spectral vegetation indices were calculated to improve the discrimination accuracy of land use classes and crop types. Multicollinearity analysis and the Boruta algorithm were applied for feature selection. Random Forest (RF) and Support Vector Machine (SVM) algorithms were used for classification. The results showed that the SVM model achieved higher accuracy in land use classification (Overall Accuracy 87.48% and Kappa 83.64% in 2024) , whereas the RF model outperformed SVM in crop type classification (Overall Accuracy 89.29% and Kappa 84.59%). During the 10-year period, orchard, cropland, and fallow areas decreased, whereas barren lands and built-up areas increased. These changes resulted from the combined effects of natural and human factors. Reduced precipitation, prolonged drought, and declining groundwater resources led to the reduction of agricultural lands and orchards and the expansion of barren lands. In addition, increasing production costs, the proximity of the Isin Plain to Bandar Abbas, and urban expansion contributed to land use changes. Overall, the results demonstrate the high effectiveness of machine learning algorithms in producing accurate and practical land use and crop type maps.

Keywords: Landsat 8, Machine Learning, Remote sensing, Sentinel 2, Spectral indices, Supervised classification.