

Original Article



Crop Mapping Using a Combination of Sentinel-1 and 2 Images in Ardabil Province

Bahar Asadi¹ and Ali Shamsoddini^{2*}

Affiliation

1. Msc, Department of Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran
2. Associate professor, Department of Remote Sensing and GIS, Tarbiat Modares University, Tehran, Iran

ABSTRACT

Introduction: Identifying and mapping crops provides important information to agricultural lands management and cultivation area estimation of crops. Optical and radar images are valuable resources for classifying agricultural land. Features derived from optical images contain information about the reflectance signatures of various products, while radar images provides information about the structural characteristics and distribution mechanisms of products. The combination of these two sources can create a complementary dataset with a significant number of spectral, texture and polarized temporal features for the classification of agricultural land

Material and methods: This study aims to explore the significance of red edge bands for the segregation of crops such as wheat, barley, alfalfa, beans, broad beans, flax, corn, sugar beet and potatoes using the random forest method and support vector machine. To conduct the analysis, a time series of Sentinel-1 and 2 images 2019 in the northwest region of Ardabil was retrieved from the Google Earth Engine (GEE) platform. The study evaluates the effectiveness of spectral and temporal information, plant indices and backscatter information on the crop mapping by examining different combinations of bands. Through the random forest feature selection method, essential features are identified and utilized as inputs for both the random forest and support vector machine classifiers.

Results and discussion: The random forest provided the most favorable outcomes across all scenarios. The results revealed that incorporating red edge wavelengths and red edge-based vegetation indices proved more beneficial than other bands and vegetation indices for differentiating between barley, beans, broad beans, and flax. The most optimal outcome among various feature combinations was associated with the time series of spectral features from Sentinel-2 images combined with the time series of Sentinel-1 images, resulting in an overall accuracy of 84.67% and a kappa coefficient of 82.31%. Furthermore, the results demonstrated that red edge bands and red edge-based vegetation indices effectively distinguish between different types of crops

Conclusion: It is recommended to carefully consider the selection of specific spectral bands to achieve higher accuracy in separation of crops. It is important to highlight that combining radar and optical images consistently yields superior results compared to classification methods based on a single sensor, leading to increased classification information.

Keywords: Optical and radar image fusion; Crop mapping; Red edge bands; Red edge-based vegetation indices; Machine learning

Citation: Asadi, B., and Shamsoddini, A., Crop Mapping Using a Combination of Sentinel-1 and 2 Images in Ardabil Province, Iran J Remote Sens GIS. 16(3):25-46.





تفکیک محصولات زراعی با استفاده از ترکیب تصاویر

سنتینل-۱ و ۲ در استان اردبیل

بهار اسدی^۱ و علی شمس‌الدینی^{۲*}

سمت

۱. کارشناس ارشد گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی، دانشگاه تربیت مدرس، تهران، ایران
 ۲. دانشیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی، دانشگاه تربیت مدرس، تهران، ایران

چکیده

سابقه و هدف: شناسایی و نقشه کردن محصولات زراعی اطلاعات مهمی برای مدیریت زمین‌های کشاورزی و برآورد سطح زیر کشت محصولات زراعی فراهم می‌کند. تصاویر اپتیک و راداری، منابع ارزشمندی برای طبقه‌بندی زمین‌های کشاورزی است. ویژگی‌های مستخرج از تصاویر اپتیک حاوی اطلاعاتی در مورد امضای بازتابی محصولات مختلف است. در مقابل، یک تصویر راداری فراهم‌کننده اطلاعاتی در مورد خصوصیات ساختاری و سازوکارهای پراکنش محصولات است. ترکیب این دو منبع قادر به ایجاد یک مجموعه داده مکمل با تعداد چشمگیری از ویژگی‌های زمانی طیفی، بافت و قطبیده برای طبقه‌بندی زمین‌های کشاورزی است.

مواد و روش‌ها: این پژوهش به بررسی اهمیت باندهای لبه‌قرمز برای تفکیک محصولات زراعی شامل گندم، جو، یونجه، لوبیا، باقلا، کتان، ذرت، چغندر قند و سیب‌زمینی با استفاده از روش جنگل تصادفی و ماشین بردار پشتیبان می‌پردازد. بدین منظور سری زمانی تصاویر سنتینل-۱ و ۲ در سال ۲۰۱۹ از شمال غرب شهر اردبیل در پلتفرم ارت انجین فراخوانی شد. ترکیب‌های متفاوت باندها برای بررسی تأثیرات اطلاعات طیفی و زمانی، شاخص‌های گیاهی و اطلاعات بازپراکنش برای طبقه‌بندی محصولات بررسی شد. با استفاده از روش انتخاب ویژگی جنگل تصادفی ویژگی‌های مهم شناسایی و به‌عنوان ورودی الگوریتم جنگل تصادفی و ماشین بردار پشتیبان معرفی شدند.

نتایج و بحث: جنگل تصادفی برای تمامی سناریوها بهترین نتیجه را به دست آورد. نتایج نشان داد افزودن طول موج‌های لبه‌قرمز و شاخص‌های مشتق‌شده از آن باعث شد محصولاتی همچون جو، لوبیا، باقلا و کتان نسبت به سایر محصولات با صحت بالاتری تفکیک شود. بهترین نتیجه در میان ترکیبات مختلف ویژگی‌ها مربوط به تلفیق سری زمانی ویژگی‌های طیفی تصاویر سنتینل-۲ با سری زمانی تصاویر سنتینل-۱ بود. صحت کلی ۸۴/۶۷ درصد و ضریب کاپا ۸۲/۳۱ درصد به دست آمد. نتایج نشان داد باندهای لبه‌قرمز و شاخص‌های پوشش گیاهی مبتنی بر آن به‌تنهایی قابلیت جداسازی محصولات زراعی را از همدیگر دارند.

نتیجه‌گیری: پیشنهاد می‌شود برای دستیابی به صحت بالاتر در تفکیک محصولات زراعی انتخاب باندهای طیفی هدفمند مورد توجه قرار گیرد. ترکیبی از تصاویر راداری و اپتیک همیشه از روش طبقه‌بندی براساس تک‌سنجنده بهتر عمل می‌کند و به افزایش اطلاعات طبقه‌بندی منجر می‌شود.

واژه‌های کلیدی: تلفیق تصاویر اپتیک و رادار، نقشه‌بندی محصولات زراعی، باندهای لبه‌قرمز، شاخص‌های پوشش گیاهی لبه‌قرمز، یادگیری ماشین

استناد: اسدی، ب. و شمس‌الدینی، ع.، تفکیک محصولات زراعی با استفاده از ترکیب تصاویر سنتینل-۱ و ۲ در استان اردبیل، نشریه سنجش از دور و GIS ایران، سال ۱۶، شماره ۳، پاییز ۱۴۰۳: ۲۵-۴۶.



۱- مقدمه

مقدار زمین تحت پوشش محصولات مختلف در یک بازه زمانی خاص، به‌عنوان سطح زیر کشت شناخته می‌شود. سطح تولیدات کشاورزی عامل تعیین‌کننده‌ای است که بر اقتصاد کشاورزی نیز تأثیرگذار است (Aduvukha et al., 2021). پیمایش‌های زمینی و روش‌های ارزیابی برای تعیین نوع محصولات کاشته‌شده در یک منطقه اغلب ناکافی، گران و وقت‌گیر است و اطلاعات لازم برای کشاورزی دقیق را فراهم نمی‌کند (Bégué et al., 2018). سنجش‌ازدور اپتیک در سال‌های اخیر به‌طور گسترده‌ای در نقشه‌برداری مناطق کشاورزی و طبقه‌بندی محصولات زراعی استفاده شده است. سنجش‌ازدور با ارائه اطلاعات مکانی-زمانی برای نظارت بر پوشش گیاهی و تهیه نقشه نوع محصولات زراعی سیستم مؤثرتری برای مدیریت زمین‌های کشاورزی فراهم می‌کند (Filgueiras et al., 2019). بنابراین نقشه‌برداری از محصولات زراعی براساس داده‌های سنجش‌ازدور می‌تواند جایگزین مناسبی برای نقشه‌برداری زمینی باشد. تصاویر ماهواره‌ای مانند لندست و مادیس که در اغلب پژوهش‌های گذشته به کار رفته است قدرت تفکیک مکانی یا زمانی پایینی دارند (Gitelson et al., 1996). دستیابی به اطلاعات نوع کشت به‌دلیل فراهم نبودن تصاویر با قدرت تفکیک مکانی و زمانی بالا یکی از موضوعات چالش‌برانگیز در سنجش‌ازدور است. ویژگی‌های طیفی و زمانی اساسی‌ترین اطلاعات برای طبقه‌بندی محصولات زراعی با استفاده از سنجش‌ازدور هستند (Gitelson et al., 1996). از جمله عوامل دیگری که این امر را با چالش مواجه می‌کند شامل شباهت طیفی کلاس‌های زراعی و تفاوت در عوامل تأثیرگذار بر زراعت یک محصول است. مثلاً شرایط اقلیمی و محیطی متفاوت در زمان کشت و شرایط رشد برای یک نوع محصول می‌تواند در مکان‌های مختلف، متفاوت باشد و این مسئله به تغییر در شرایط فنولوژیکی آن محصول در شرایط زراعی مختلف منجر شود. این مسئله موجب می‌شود در بعضی

مراحل رشد، محصولات مشابه ویژگی‌های طیفی متفاوتی داشته باشند و به همین دلیل طبقه‌بندی در یک تاریخ خاص صحت طبقه‌بندی را محدود می‌سازد (Chong et al., 2021). به همین دلیل در کنار قدرت تفکیک مکانی و زمانی، قدرت تفکیک طیفی تصاویر مورد استفاده نیز در تشخیص نوع محصولات کشاورزی با استفاده از سنجش‌ازدور می‌تواند حائز اهمیت باشد.

با توجه به عوامل یادشده، تهیه نقشه نوع محصول در مقایسه با تهیه نقشه پوشش زمین^۱ می‌تواند با خطای بیشتری توأم باشد (Zhang et al., 2017). به‌منظور فائق آمدن بر این چالش‌ها لازم است تا تصاویر ماهواره‌ای مورد استفاده از قدرت تفکیک طیفی، مکانی و زمانی بالا برخوردار باشند تا به‌واسطه آن کوچک‌ترین تغییرات و تفاوت‌ها حتی در بازه‌های زمانی کوتاه‌مدت نیز قابل شناسایی باشند. در سال‌های اخیر، داده‌های مربوط به سنتینل-۲ به‌عنوان داده‌هایی مطرح می‌شوند که علاوه بر دارا بودن قدرت تفکیک زمانی مناسب، از نظر طیفی و مکانی نیز قدرت تفکیک مطلوبی را به‌منظور بررسی تیپ‌های مختلف گیاهان زراعی فراهم می‌آورد.

همچنین، تصویر مربوط به یک تاریخ خاص به‌تنهایی نمی‌تواند برای تعیین تیپ‌های مختلف گیاهان زراعی در یک منطقه مؤثر باشد و استفاده از تمامی سری زمانی تصاویر ممکن است بهترین عملکرد طبقه‌بندی را برای تفکیک محصولات کشاورزی به دنبال نداشته باشد (Pal et al., 2004, Tariq et al., 2022). با توجه به این مطلب، اگرچه اطلاعات زمانی به‌دلیل خواص فنولوژیکی منحصربه‌فرد محصولات مختلف، بااهمیت است، ولی استفاده از داده‌های مناسب برای تاریخ‌های مناسب در یک سری زمانی به‌منظور کسب نتایج بهتر، ضروری است؛ بنابراین ارزیابی اهمیت نسبی باندهای طیفی سنتینل-۲ برای طبقه‌بندی محصولات، به‌ویژه عملکرد داده‌های حاصل از باندهای لبه‌قرمز، به‌عنوان باندهایی که تاکنون در سنجنده‌های متداول گذشته مانند

1. Land Cover

درباره ویژگی‌های طیفی سه باند لبه‌قرمز تصاویر اپتیک این سنجنده و نیز شاخص‌های پوشش گیاهی که براساس این سه باند به دست می‌آیند، به‌منظور تفکیک محصولات کشاورزی انجام نشده است. لذا این مطالعه برای مشخص کردن اهمیت باندهای لبه‌قرمز سنتینل در طبقه‌بندی محصولات زراعی، با رویکردهای متفاوت و نیز تلفیق تصاویر اپتیک و رادار انجام می‌شود.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

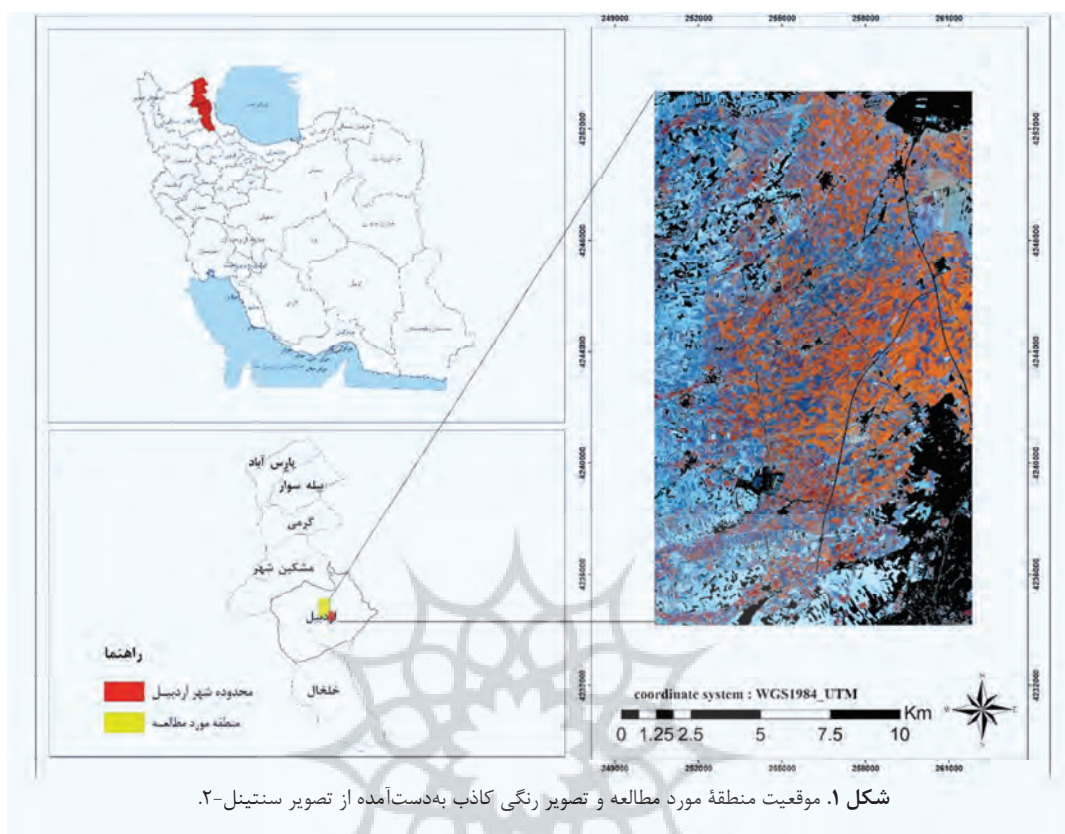
منطقه مورد مطالعه در ۳۸.۱۳ تا ۳۸.۲۳ درجه عرض شمالی و ۴۸.۱۶ تا ۴۸.۹ درجه طول شرقی و در شمال غرب ایران واقع شده است (شکل ۱). این منطقه در استان اردبیل قرار دارد و شامل اراضی دشت یامچی است. این اراضی در ارتفاع ۱۵۰۰ متری از سطح دریا در میان کوه‌های تالش و سیلان در شمال غرب فلات ایران قرار دارد و دارای زمستان سرد معتدل است. به دلیل شرایط آب‌وهوایی منطقه اراضی مورد مطالعه غالباً تک‌کشت‌اند. میانگین بارندگی سالیانه حدود ۳۱۷ میلی‌متر است.

با توجه به هدف این پژوهش، داده‌های نوع کشت مربوط به این ناحیه طی سال ۱۳۹۸ (۲۰۱۹) است. نمونه‌های زمینی شامل ۹ نوع محصول از جمله یونجه و اسپرس، گندم، جو، لوبیا، ذرت، باقلا، کتان، سیب‌زمینی و چغندر قند است که جزء محصولات غالب در دشت اردبیل هستند. موقعیت مزارع و نوع کشت آن‌ها با استفاده از GPS و نقشه‌برداری زمینی برداشت شد.

۲-۲- داده‌ها

جدول ۱ نشان‌دهنده ویژگی‌های تصاویر سنتینل-۲ است که در این پژوهش استفاده شد. با توجه به ویژگی‌های باندهای مختلف، باندهای ۱۰ متری و ۲۰ متری شامل باندهای ۲ تا ۷ و باندهای ۸ و ۸A و باندهای ۱۱ و ۱۲ به‌منظور انجام این مطالعه انتخاب

ندست و اسپات نبوده و کمتر بر روی آن‌ها مطالعه انجام شده، ضروری است. شاخص‌های استفاده‌شده بر مبنای ویژگی‌های لبه‌قرمز تحت تأثیر ویژگی‌های بیوشیمیایی گیاه همچون ساختار برگ، کلروفیل برگ و تاج پوشش گیاهی است و به‌خوبی قادر به تفکیک گیاهان زراعی از یکدیگر است (Zhong et al., 2014). از آنجاکه بازتاب طیفی محصولات تحت تأثیر وضعیت پوشش گیاهی نظیر میزان کلروفیل، رنگ‌دانه، تاج پوشش و محتوی آب برگ قرار دارند، اطلاعات مهمی برای تفکیک نوع محصول هستند (Zhang et al., 2017). ولی در کنار این خصوصیات، اطلاعات مربوط به ساختار فیزیکی گیاهان نیز می‌تواند در تعیین نوع محصول در کنار سایر ویژگی‌های طیفی مؤثر باشد. خصوصاً در مورد محصولاتی با چرخه فنولوژیکی مشابه، فقط استفاده از اطلاعات طیفی برای تمایز محصولات چالش‌برانگیز است و از آنجاکه تصاویر راداری، مانند داده‌های سنتینل-۱، حاوی اطلاعاتی در رابطه با ساختار پوشش گیاهی هستند، تلفیق تصاویر اپتیک و رادار می‌تواند مکمل یکدیگر باشد و به بهبود نتایج تفکیک محصولات کشاورزی کمک کند (Khosravi et al., 2019). برخی مطالعات نشان می‌دهد که استفاده از تصاویر راداری خصوصاً تصاویر با قطبش مخالف می‌تواند نتایج مطلوبی در تفکیک محصولات کشاورزی به‌دنبال داشته باشد (Ban et al., 2003, Skriver et al., 2011, Blickensdörfer et al., 2022). با توجه به مطالب بیان‌شده به‌دلیل تفاوت در مراحل رشد محصولات و متفاوت بودن ویژگی‌های طیفی محصولات مختلف در طول دوره رشد ترکیب‌های متفاوت ویژگی‌های سری زمانی تصاویر اپتیک و ضریب بازپراکنش راداری بررسی می‌شود تا قابلیت شاخص‌های مختلف و تأثیر آن‌ها در صحت طبقه‌بندی محصولات زراعی بررسی شود. اگرچه تاکنون مطالعات متعددی در زمینه تهیه نقشه نوع محصول کشاورزی از تصاویر چندزمانه سنجنده سنتینل-۲ و سنتینل-۱ انجام شده (Sun et al., 2020)، ولی مطالعه‌چندانی



پس از فراخوانی این تصاویر پیش‌پردازش‌های لازم، از جمله تبدیل تصاویر از سیگمانات به دسی‌بل و تصحیح اثر اسپیکل با استفاده از فیلتر تصحیح‌شده لی^۳ انجام شد. هرچند تصاویر سیگما نات برای استفاده کیفی کافی است، ولی برای استفاده کمی از داده‌های SAR تصاویر باید به دسی‌بل تبدیل شوند.

به‌منظور برداشت پیکسل‌های مورد نیاز برای استفاده به‌عنوان پیکسل‌های آموزشی و آزمایشی، ابتدا برای اجتناب از اختلاط طیفی مزارع با یکدیگر یک بافر برای مرز قطعات انتخاب شد. سپس خودهمبستگی تمامی کلاس‌های موجود برای سه دوره رشد محصولات مختلف با استفاده از واریوگرام بررسی شد و پس از به

شد و اندازه پیکسل‌های باندهای ۲۰ متری به ۱۰ متری با استفاده از روش addBands() موجود در گوگل ارت انجین^۱ تغییر یافت. به‌منظور انتخاب بازه زمانی مناسب برای این مطالعه، براساس اطلاعات فنولوژیکی محصولات کشاورزی که از تقویم زراعی و رسم سری زمانی NDVI شکل ۲ به دست آمد، تصاویر سری زمانی L2A، اخذشده در ۱۸ ژوئن تا ۱۸ سپتامبر برای منطقه مورد مطالعه در پلتفرم گوگل ارت انجین، فراخوانی شدند (تصاویر سنتینل-۲ در گوگل ارت انجین تصحیح اتمسفری و هندسی شده‌اند).

سنجنده Sentinel-1A در محدوده طول موج ماکروویو و باند C تصویربرداری می‌کند. این سنجنده در باند C راداری به تصویربرداری از سطح زمین می‌پردازد. سری زمانی تصاویر سنتینل-1 GRD^۲ از ۷ مه تا ۲۸ سپتامبر در پلتفرم ارت انجین فراخوانی شد.

1. Google Earth Engine
2. Ground Range Detected
3. Rfined Lee Filter

یکسان اتفاق نمی‌افتد. با در نظر گرفتن فواصل حداکثر، نمونه‌گیری تصادفی طبقه‌ای^۱ به‌منظور انتخاب پیکسل‌های آموزشی و آزمایشی استفاده شد. پیکسل‌ها به‌صورت تصادفی به ۳۰ درصد نمونه‌های آزمایشی و ۷۰ درصد نمونه‌های آموزشی تقسیم‌بندی شدند.

دست آوردن فواصل نمونه‌برداری برای هر محصول در دوره‌های رویشی مختلف، بیشترین فاصله تعیین شده برای هر محصول به‌منظور انتخاب پیکسل‌های مربوط به آن محصول استفاده شد (جدول ۲). نتایج نشان داد خودهمبستگی برای محصولات مختلف به‌صورت


جدول ۱. مشخصات طیفی و مکانی داده‌های سنجنده سنتینل-۲A

شماره باند	نام باند	میانگین طول موج نانومتر	توان تفکیک مکانی به متر
۱	هواویز ساحلی	۴۴۲.۷	۶۰
۲	آبی	۴۹۲.۴	۱۰
۳	سبز	۵۵۹.۸	۱۰
۴	قرمز	۶۶۴.۶	۱۰
۵	لبه‌قرمز پوشش گیاهی	۷۰۴.۱	۲۰
۶	لبه‌قرمز پوشش گیاهی	۷۴۰.۵	۲۰
۷	لبه‌قرمز پوشش گیاهی	۷۸۲.۸	۲۰
۸	مادون قرمز نزدیک	۸۳۲.۸	۱۰
۸A	مادون قرمز نزدیک کم‌پهنای	۸۶۴.۷	۲۰
۹	بخار آب	۹۴۵.۱	۶۰
۱۰	مادون قرمز موج کوتاه ابر سیروس	۱۳۷۳.۵	۶۰
۱۱	مادون قرمز موج کوتاه	۱۶۱۳.۷	۲۰
۱۲	مادون قرمز موج کوتاه	۲۲۰۲.۴	۲۰

جدول ۲. حداقل فاصله لازم برای انتخاب پیکسل‌ها در کلاس‌های زراعی مختلف در منطقه مورد مطالعه

کلاس‌های زراعی	فاصله نمونه‌ها به پیکسل
یونجه	۷
جو	۹
لوبیا	۹
ذرت	۶
باقلا	۹
کتان	۸
سیب‌زمینی	۱۳
چغندر قند	۷
گندم	۱۲

1. Stratified Random Sampling



شکل ۲. منحنی رفتار مقادیر NDVI برای هر محصول در زمان‌های مختلف

جدول ۳. تقویم زراعی کشت‌های مختلف

آبان	مهر	شهریور	مرداد	تیر	خرداد	اردیبهشت	فروردین	
			√					گندم
Δ			√					جو
	√		√		√		Δ	یونجه
		√					Δ	لوبیا
	√						Δ	ذرت
			√				Δ	باقلا
			√				Δ	کتان
		√					Δ	سیب زمینی
√	√						Δ	چغندر قند

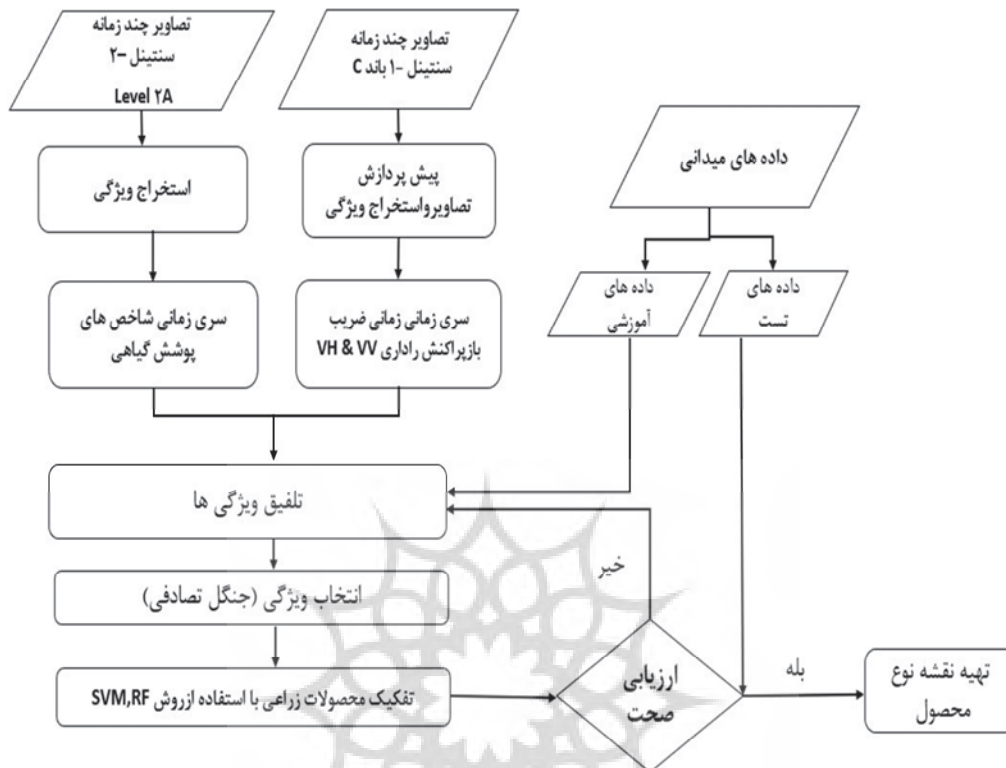
راهنما: کاشت: Δ، رویش: √، برداشت: √

۲-۳- روش کار

روش کلی انجام کار در شکل ۳ ارائه شده است. پس از دریافت داده‌ها و انجام پیش‌پردازش‌های لازم مانند کاهش اثر نویز اسپکل، ویژگی‌های لازم از سری زمانی تصاویر استخراج شد. در ادامه هر یک از مراحل کار تشریح می‌شود.

۲-۳-۱- استخراج ویژگی از تصاویر اپتیک

در مجموع ۲۷ شاخص پوشش گیاهی مبتنی بر باندهای مرئی، مادون قرمز و لبه قرمز محاسبه شد و سری زمانی باندهای ۱۰ و ۲۰ متری به‌عنوان ویژگی‌های ورودی تصاویر اپتیک برای طبقه‌بندی انتخاب شدند (جدول ۴).



شکل ۳. نمودار مفهومی و روند کلی انجام پژوهش

جدول ۴. ویژگی‌های مورد استفاده در پژوهش

۱. میانگین باندهای طیفی سری زمانی باندهای B2, B3, B4, B5, B6, B7, B8, B8A, B11 و B12

۲. سری زمانی شاخص‌های پوشش گیاهی شامل شاخص‌های

NDVI (Tucker 1979b), ReNDVI (Fernández et al., 2016), MSRre (Chen et al., 1996), MCARI (Daughtry et al., 2000), IRECI (Frampton et al., 2013), TVI (Khosravi et al., 2018), Ndre1 (Gitelson et al., 1994), NDSAVI (Qi et al., 2002), NDRI (Gelder et al., 2009), NDWI (Sun et al., 2020)

مجموعاً شامل ۱۹۲ ویژگی

ویژگی‌های به‌دست‌آمده از

تصاویر سنتینل-۲

۱. ضریب باز پراکنش راداری VV (ارسال و دریافت در پلاریزاسیون عمودی)، (ارسال در پلاریزاسیون

عمودی و دریافت در پلاریزاسیون افقی) VH

ویژگی‌های به‌دست‌آمده از

تصاویر SAR

۲. نسبت بین باز پراکنش VV/VH, NRPB مجموعاً شامل ۴۸ ویژگی

۲-۳-۲- استخراج ویژگی از تصاویر رادار

ویژگی‌های به‌دست‌آمده از تصاویر SAR شامل سری زمانی بازپراکنش VV, VH است. رابطه (۱) نسبت بین این دو بازپراکنش VV/VH را نشان می‌دهد. رابطه (۲) شاخص NRPB^۱ را نشان می‌دهد که یک شاخص طیفی است و از ترکیب بازپراکنش‌های VV و VH به دست می‌آید (Filgueiras et al., 2019).

$$\text{رابطه (۱)} \quad \text{Intensity_VV/VH_ratio} = \frac{\text{intVV}}{\text{intVH}}$$

$$\text{رابطه (۲)} \quad \text{NRPB} = \frac{\text{intVH} - \text{intVV}}{\text{intVH} + \text{intVV}}$$

پس از اینکه سری زمانی بازپراکنش‌های VV, VH، نسبت بین این دو و شاخص NRPB محاسبه شد. پس از انتخاب ویژگی تنها سری زمانی بازپراکنش VV و VH در شناسایی و طبقه‌بندی محصولات زراعی مؤثر واقع شد.

۲-۳-۳- الگوریتم روش جنگل تصادفی RF

الگوریتم جنگل تصادفی جزو طبقه‌بندی‌کننده‌های گروه است که اساساً به این معنی است که آن‌ها از چندین درخت تصمیم‌گیری استفاده می‌کنند. الگوریتم جنگل تصادفی یک نوع مدرن از درخت پایه هستند که شامل انبوهی از درخت‌های طبقه‌بندی و رگرسیونی می‌شوند (Breiman, 2001). در واقع الگوریتم جنگل تصادفی مبتنی بر دسته‌ای از درخت‌های تصمیم است که براساس میانگین‌گیری از نتایج حاصل از تمامی درخت‌های تصمیم، پیش‌بینی را انجام می‌دهد. درختان تصادفی بردار ورودی را گرفته، آن را با هر درخت در جنگل طبقه‌بندی می‌کنند و خروجی، برچسب‌های کلاسی هستند که با رأی اکثریت درختان ساخته می‌شود (Rodriguez et al., 2012). RF هر پیکسل را به کلاسی اختصاص می‌دهد که بیشترین تعداد آرا را از مجموعه درختان به دست آورده است. در RF دو مرحله اصلی وجود دارد:

۱- انتخاب تصادفی نمونه‌ها با استفاده از فتاوری نمونه‌گیری Bootstrapping تعداد مشخصی از نمونه‌ها را از مجموعه داده اصلی به‌طور تصادفی انتخاب می‌کند، تا یک مجموعه آموزش جدید ایجاد کند.

۲- انتخاب تصادفی ویژگی‌ها، این دو فرایند تصادفی باعث می‌شود از overfitting جلوگیری شود (Rodriguez et al., 2012).

همچنین این روش قابلیت زیادی برای نویزها و outlierها دارد. بنابراین، هنگام استفاده از جنگل تصادفی، باید دو پارامتر تنظیم شود. یکی تعداد طبقه‌بندی‌کننده‌های پایه (درختان) و دیگری تعداد ویژگی‌هایی که باید به‌طور تصادفی در هر گره انتخاب شوند (Breiman, 2001). پارامترهایی که در این طبقه‌بندی‌کننده لازم است بهینه شود تعداد درختان و تعداد ویژگی است که با استفاده از روش اعتبارسنجی متقابل، تعداد درختان با استفاده از تحلیل داده‌های خارج از جعبه به دست آمد و تعداد ویژگی در این الگوریتم معمولاً با استفاده از جذر ویژگی‌ها به دست آمد (Belgiu et al., 2018).

۲-۳-۴- الگوریتم طبقه‌بندی ماشین بردار پشتیبان SVM
الگوریتم طبقه‌بندی ماشین بردار پشتیبان SVM یکی از روش‌های الگوریتم‌های یادگیری نظارت‌شده است. مبنای اصلی این روش بر دسته‌بندی خطی داده‌ها و با در نظر گرفتن حاشیه اطمینان^۲ است و اساساً یک جداکننده دودویی محسوب می‌شود (Pal et al., 2004). نتایج تحقیقات قبلی نشان داده است استفاده از کرنل RBF^۳ برای طبقه‌بندی عملکرد بهتری دارد (Huang et al., 2004). در این پژوهش از کرنل RBF استفاده شد و هنگام استفاده از این کرنل دو پارامتر^۴ C و گاما^۵ بهینه می‌شود. برای تعیین پارامتر بهینه از این دو ترکیب از روش جست‌وجوی شبکه‌ای^۶ استفاده شد که دلیل استفاده از این روش زمان محاسباتی کمتر این روش برای یافتن بهترین ترکیب پارامترهای C و گاما

1. Normalized Ratio Procedure between Bands
2. Margin
3. Radial Basis Function
4. Cost
5. Gamma
6. Grid Search

۶-۳-۲- ارزیابی صحت طبقه‌بندی

برای جلوگیری از بیش‌برازش^۳ ویژگی‌های استفاده‌شده برای طبقه‌بندی با روش‌های یادگیری ماشین استفاده شد که از روش اعتبارسنجی متقابل^۴ برای بهینه‌سازی پارامترهای طبقه‌بندی استفاده می‌کند. برای ارزیابی عملکرد طبقه‌بندی‌کننده شاخص‌های مختلفی از قبیل صحت کلی، ضریب کاپا، صحت کاربر^۵، صحت تولیدکننده^۶ و F1-Score استفاده می‌شود. برای محاسبه این معیارها اولین قدم ایجاد ماتریس خطا^۷ است. برای هر کلاس صحت تولیدکننده و کاربر و F1-Score محاسبه شد. صحت کلی^۸ را که در واقع نوعی ارزیابی خوش‌بینانه از صحت است ارزیابی می‌کند. مقدار ضریب کاپا^۹ صحت طبقه‌بندی را نسبت به یک طبقه‌بندی کاملاً تصادفی محاسبه می‌کند، معیار F1-Score به‌عنوان میانگین هارمونیک صحت تولیدکننده و صحت کاربر معنی‌دارتر از ضریب کاپا و صحت کلی است و طبق رابطه زیر محاسبه می‌شود. در ادامه رابطه ریاضی مربوط به رابطه بالا آورده شده است (Zhang et al., 2017).

$$F1 - Score = 2 * \frac{\text{Producer's Accuracy} * \text{User's Accuracy}}{\text{Producer's Accuracy} + \text{User's Accuracy}}$$

رابطه (۳)

۳- نتایج و بحث

در این مطالعه ترکیب ویژگی‌های مختلفی که از تصاویر رادار و اپتیک به دست آمد، به‌منظور مقایسه ویژگی‌های مختلف و اثر آن‌ها بر صحت طبقه‌بندی بررسی شد. براساس یافته‌ها و تحلیل نتایج انتخاب ویژگی و اهمیت ویژگی‌ها نتایج تحقیق به شرح زیر است. با توجه به

نسبت به سایر روش‌هاست، C ضریب پنالتی است که تعیین می‌کند مدل چقدر اجازه خطا دارد. در واقع C بزرگ‌تر همیشه نتیجه بهتری در آموزش به دست می‌آورد، اما مدل تولیدشده خطر بیش‌برازشی^۱ دارد که به کاهش تعمیم طبقه‌بندی منجر می‌شود. هرچه C کوچک‌تر در نظر گرفته شود طبقه‌بندی‌نشده‌ها^۲ بیشتر می‌شود (Feng et al., 2019).

۵-۳-۲- انتخاب ویژگی با استفاده از روش RF

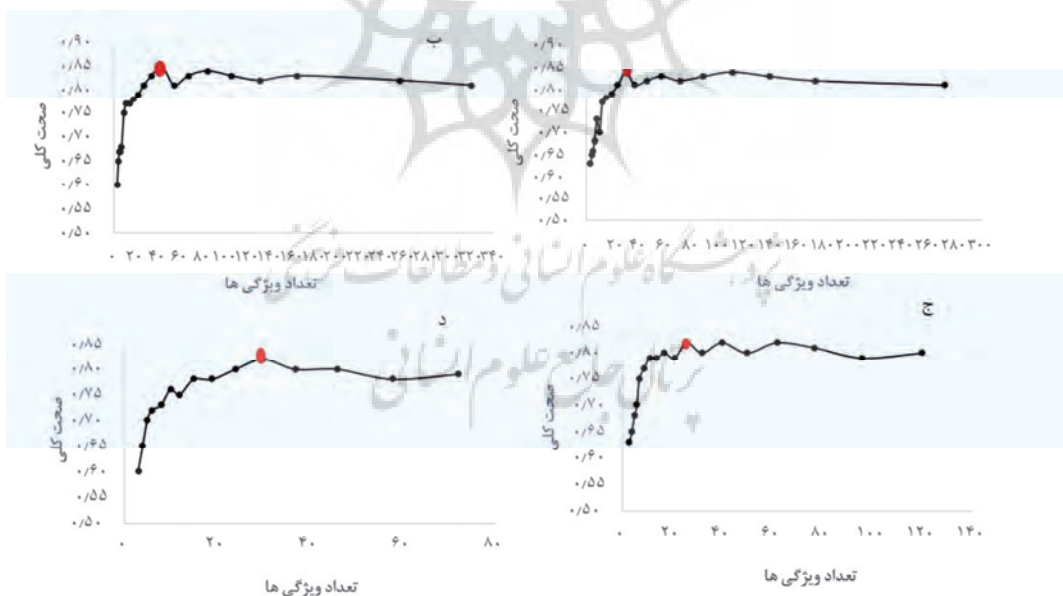
تهیه نقشه نوع کشت با استفاده از داده‌های چندزمانه سنتینل-۱ و ۲ باعث افزایش ابعاد ویژگی می‌شود، برای مقابله با ابعاد ویژگی‌های ورودی روش انتخاب ویژگی RF انتخاب شد. انتخاب ویژگی مرحله‌ای اساسی در طبقه‌بندی است که با حذف ویژگی‌های اضافی ممکن است عملکرد طبقه‌بندی افزایش یابد. با توجه به بزرگی ابعاد ویژگی‌های ورودی، از روش انتخاب ویژگی جنگل تصادفی به‌منظور کاهش ابعاد داده‌های ورودی استفاده شد (Shamsoddini et al., 2013). برای این منظور پس از تشکیل درختان و ساخت مدل در گام بعدی با استفاده از داده‌های خارج از جعبه که حدود یک‌سوم داده‌های انتخابی است و بررسی تأثیر تک‌تک متغیرها در تمام درختان و نتایجی که متغیر مورد نظر قبل از حضور و بعد از حضور در کاهش میانگین خطا در طبقه‌بندی ایجاد می‌کنند، متغیرهایی که بیشترین تأثیر را در کاهش میانگین خطا دارند به‌عنوان متغیرهای مهم انتخاب می‌شوند. در مرحله بعدی متغیرهای کم‌اهمیت حذف می‌شوند. حذف متغیرهای کم‌اهمیت به‌صورت مرحله‌ای است، یعنی در هر مرحله با حذف ویژگی‌های کم‌اهمیت، RF با بقیه متغیرها انجام می‌شود و میزان خطای مدل محاسبه می‌شود و این مرحله تا رسیدن به سه ویژگی ادامه می‌یابد. در نتیجه ویژگی‌ها براساس اهمیت آن‌ها رتبه‌بندی می‌شوند (James et al., 2013).

1. Overfitting
2. Unclassify
3. Overfitting
4. k-fold_cross_validation
5. User's Accuracy
6. Producer's Accuracy
7. Confusion Matrix
8. Overall Accuracy
9. Kappa Coefficient

شاخص‌های پوشش گیاهی ذکر شده خود از عملیات ریاضی‌ای به دست می‌آیند که بر روی باندهای مادون قرمز نزدیک، مادون قرمز نزدیک کم‌پهنا، مادون قرمز موج کوتاه، باندهای لبه قرمز و باند قرمز پیاده می‌شوند و بیانگر اهمیت باندهای ذکر شده در شناسایی محصولات زراعی هستند. به‌طور کلی نتایج نشان‌دهنده اهمیت باندهای لبه قرمز در تفکیک محصولات زراعی است. سپس بازپراکنش VH، VV در درجه دوم اهمیت قرار دارد. در ارزیابی باندهای لبه قرمز تصاویر سنتینل-۲ با سایر باندها در تمامی سناریوها باندهای لبه قرمز بیشترین اهمیت را داشتند.


شکل ۶ نتایج ارزیابی کمی را که از ماتریس ابهام به دست آمد، نشان می‌دهد، طبقه‌بندی کننده جنگل تصادفی برای تمامی نه سناریو بالاترین صحت طبقه‌بندی را به دست آورد، در حالی که صحت به دست آمده از طبقه‌بندی کننده SVM برای تمام سناریوها صحت به دست آمده کمتر از جنگل تصادفی بود.

مقایسه صحت کلی مطابق با شکل ۴ در حالت تلفیق رادار و اپتیک که بالاترین دقت را به دست آورد تعداد ۴۳ ویژگی از ۳۲۰ ویژگی با استفاده از روش جنگل تصادفی به‌عنوان مهم‌ترین ویژگی‌های تأثیرگذار در تفکیک محصولات زراعی در این روش انتخاب شدند. شکل ۵ نتایج اهمیت ویژگی‌ها را نشان می‌دهد که این تعداد ویژگی دارای بیشترین صحت کلی نسبت به بقیه حالت‌ها بوده است. شکل ۵ اهمیت ویژگی‌ها را بر اساس شاخص جینی^۱ نشان می‌دهد، اهمیت جینی بالاتر نشان می‌دهد ویژگی مورد نظر نقش مهم‌تری در طبقه‌بندی دارد، در حالی که جینی پایین‌تر اهمیت کمتری در طبقه‌بندی دارد. مطابق با این روش پراهمیت‌ترین ویژگی‌ها در تفکیک محصولات زراعی در تلفیق تصاویر اپتیک و رادار شامل ویژگی‌های طیفی به‌ترتیب NDVIre2n، PVR، B6، B8، LSWI، NDSVI، TVI شاخص‌های پوشش گیاهی در مقایسه با باندهای طیفی در تفکیک محصولات زراعی اهمیت بیشتری دارند.

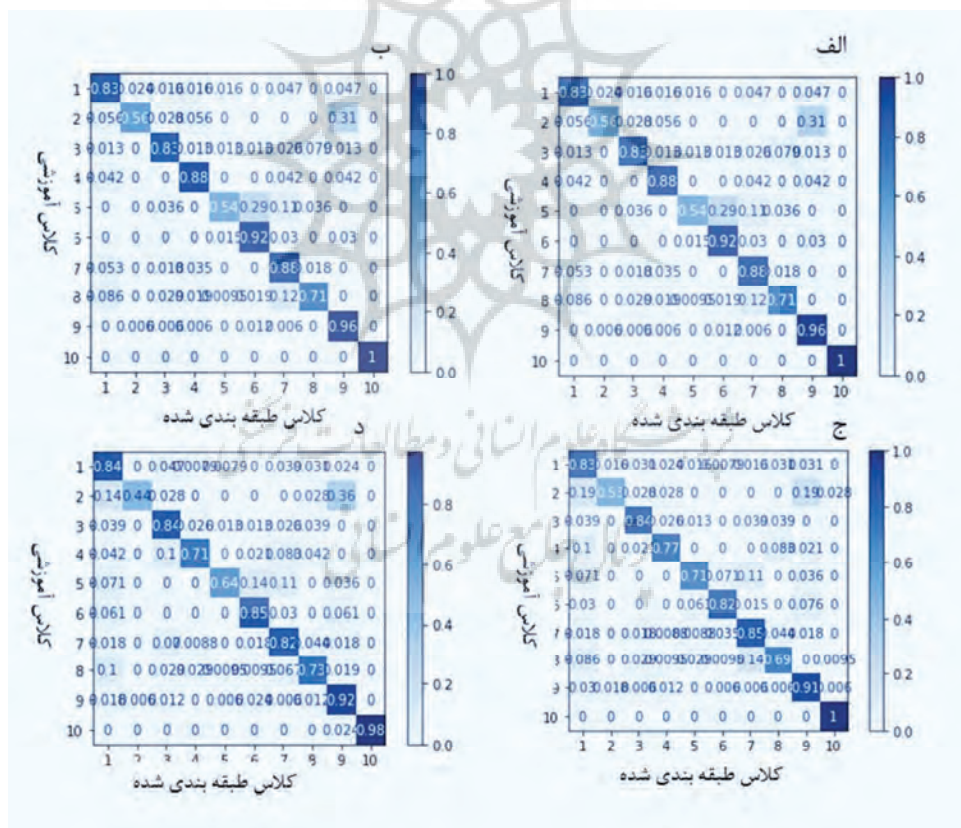


شکل ۴. نتایج انتخاب ویژگی (الف) ترکیب سنتینل-۱ و سنتینل-۲، (ب) ویژگی‌های طیفی به دست آمده از سنتینل-۲، (ج) سنتینل-۱ و فقط شاخص‌ها و باندهای لبه قرمز سنتینل-۲، (د) سنتینل-۲ فقط شاخص‌ها و باندهای لبه قرمز سنتینل-۲ با استفاده از روش RF

1. Gini Importance



شکل ۵. نتایج اهمیت ویژگی‌ها در ترکیب ویژگی‌های تصاویر سنتینل-۱ و سنتینل-۲ با استفاده از روش RF



شکل ۶. ماتریس ابهام حاصل از: الف) ترکیب سنتینل-۱ و سنتینل-۲، ب) ویژگی‌های طیفی به‌دست‌آمده از سنتینل-۲، ج) سنتینل-۱ و فقط شاخص‌ها و باندهای لبه‌قرمز سنتینل-۲، د) سنتینل-۲ فقط شاخص‌ها و باندهای لبه‌قرمز سنتینل-۲ با استفاده از روش RF

جدول ۵. مقایسه نتایج F1_Score حاصل از طبقه‌بندی در هریک از کلاس‌های زراعی به روش RF

گندم	چغندر قند	سیب‌زمینی	کتان	باقلا	ذرت	لوبیا	جو	یونجه	مجموعه ویژگی‌ها
۰.۸۹	۰.۷۶	۰.۸۱	۰.۸۳	۰.۶۳	۰.۷۶	۰.۸۳	۰.۵۹	۰.۸۰	فقط باندهای اصلی سنتینل-۲
۰.۸۹	۰.۸۲	۰.۷۹	۰.۸۴	۰.۶۳	۰.۷۶	۰.۸۴	۰.۵۹	۰.۸۴	شاخص‌های طیفی سنتینل-۲
۰.۹۰	۰.۸۴	۰.۸۷	۰.۸۵	۰.۷۹	۰.۷۵	۰.۷۷	۰.۶۰	۰.۸۶	باندهای اصلی و شاخص‌های طیفی سنتینل-۲
۰.۸۹	۰.۷۷	۰.۸۱	۰.۸۳	۰.۷۲	۰.۷۶	۰.۷۸	۰.۶۰	۰.۸۰	فقط شاخص‌ها و باندهای لبه‌قرمز سنتینل-۲
۰.۹۱	۰.۷۷	۰.۸۳	۰.۸۰	۰.۶۴	۰.۷۶	۰.۷۴	۰.۵۳	۰.۸۱	بدون شاخص‌ها و باندهای لبه‌قرمز سنتینل-۲
۰.۷۴	۰.۷۲	۰.۷۰	۰.۶۱	۰.۵۰	۰.۶۹	۰.۶۱	۰.۲۴	۰.۶۸	سنتینل-۱
۰.۸۹	۰.۷۷	۰.۸۰	۰.۸۵	۰.۷۵	۰.۷۰	۰.۷۶	۰.۶۱	۰.۸۰	تلفیق سنتینل-۱ با سنتینل-۲ بدون شاخص‌ها و باندهای لبه‌قرمز
۰.۹۰	۰.۷۴	۰.۸۲	۰.۸۴	۰.۶۸	۰.۷۸	۰.۸۴	۰.۶۳	۰.۷۹	تلفیق سنتینل-۱ با سنتینل-۲ فقط شاخص‌ها و باندهای لبه‌قرمز
۰.۹۱	۰.۸۴	۰.۸۶	۰.۸۳	۰.۶۸	۰.۷۵	۰.۸۷	۰.۶۱	۰.۸۳	سنتینل-۱ و سنتینل-۲

جدول ۶. مقایسه صحت روش‌های طبقه‌بندی با ترکیب‌های مختلف از باندهای سنتینل-۱ و ۲ به روش SVM و RF

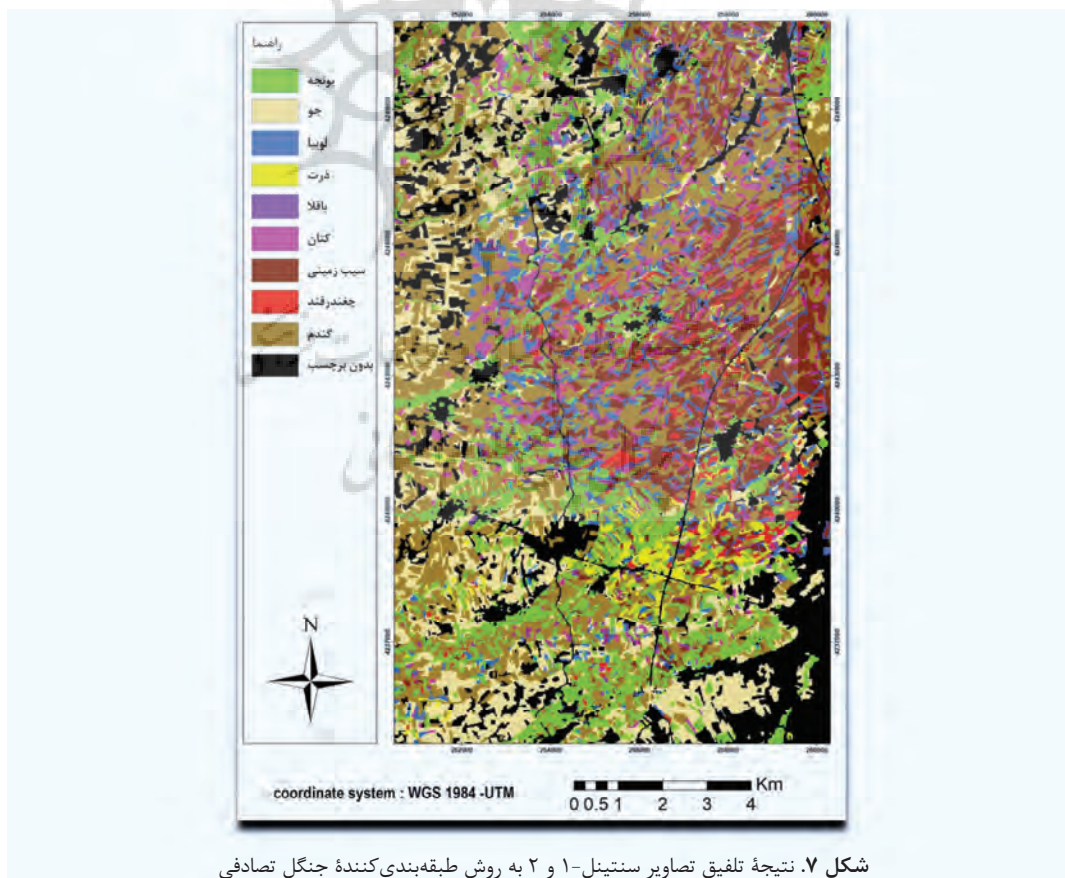
مجموعه ویژگی‌ها	RF			SVM		
	OA	kappa	F1-score	OA	kappa	F1-score
فقط باندهای اصلی سنتینل-۲	۸۱.۴۵	۷۸.۵۶	۰.۸۱	۸۱.۳۳	۷۸.۶۷	۰.۸۱
شاخص‌های طیفی سنتینل-۲	۸۲.۶۹	۸۰.۰۷	۰.۸۳	۸۲.۴۴	۷۹.۹۴	۰.۸۲
باندهای اصلی و شاخص‌های طیفی سنتینل-۲	۸۴.۴۳	۸۲.۰۷	۰.۸۴	۸۲.۵۰	۰.۸۰	۰.۸۲
فقط شاخص‌ها و باندهای لبه‌قرمز سنتینل-۲	۸۱.۵۸	۷۸.۷۴	۰.۸۲	۰.۸۲	۰.۸۰	۰.۸۲
بدون شاخص‌ها و باندهای لبه‌قرمز سنتینل-۲	۸۰.۸۴	۷۷.۷۸	۰.۸۱	۰.۷۸	۰.۷۵	۰.۷۸
سنتینل-۱	۶۷.۸۶	۶۲.۷۶	۰.۶۸	۰.۷۰	۰.۶۵	۰.۷۰
تلفیق سنتینل-۱ با سنتینل-۲ بدون شاخص‌ها و باندهای لبه‌قرمز	۸۱.۰۸	۷۸.۰۷	۰.۸۱	۸۰.۹۶	۷۸.۲۸	۰.۸۱
تلفیق سنتینل-۱ با سنتینل-۲ فقط شاخص‌ها و باندهای لبه‌قرمز	۸۱.۸۲	۷۹.۰۸	۰.۸۲	۸۲.۴۴	۷۹.۹۵	۰.۸۲
سنتینل-۱ و سنتینل-۲	۸۴.۶۷	۸۲.۳۱	۰.۸۵	۸۲.۹۴	۸۰.۰۴	۰.۸۳

همان‌طور که جدول ۵ و ۶ نشان می‌دهد بهترین نتیجه مربوط به تلفیق تصاویر اپتیک و رادار به روش جنگل تصادفی با صحت کلی ۰/۸۵ درصد و ضریب کاپای ۰/۸۲ درصد است. در همه سناریوها به غیر از جو و باقلا بقیه کلاس‌ها به خوبی از همدیگر تفکیک شدند. جو به دلیل مشابهت طیفی بالا و دوره فنولوژیک مشابهی که با گندم دارد (Wilson et al., 2014)، به‌طور میانگین با صحت ۰.۶۰ درصد تفکیک شد. نتایج نشان داد با افزودن باندهای لبه‌قرمز محصولات چون جو، باقلا و لوبیا بهتر تفکیک می‌شوند. با بررسی‌های

میدانی مشاهده شد که باقلا کمترین مساحت کشت در بین کشت‌های دیگر دارد که این امر باعث می‌شود که نمونه آموزشی کمتر و به صحت کمتر نسبت به سایر محصولات تفکیک منجر شود (Zhang et al., 2020). نتایج انتخاب ویژگی در شکل ۴ نشان داد که انتخاب ویژگی به روش جنگل تصادفی در تمامی نه سناریو دو تا سه درصد باعث افزایش صحت طبقه‌بندی نسبت به طبقه‌بندی با تمام ویژگی‌ها می‌شود. انتخاب معقول باندهای طیفی و شاخص‌های پوشش گیاهی در صحت تفکیک محصولات زراعی مهم است، طول موج‌های

۰.۷۷٪، ۰.۷۶٪، ۰.۷۲٪، ۰.۷۱٪، ۰.۶۹٪ با بازپراکنش VH، VV بهتر از سایر کلاس‌ها تفکیک شدند و شاخص NRPB و نسبت بین VH، VV در تفکیک محصولات زراعی مؤثر واقع نشد. نتایج نشان داد استفاده از شاخص‌های پوشش گیاهی در تفکیک محصولات زراعی نتایج دقیق‌تری در مقایسه با طبقه‌بندی فقط با سری زمانی باندهای اصلی به دست می‌آوردند. به‌خصوص شاخص‌های NDVIre2n، TVI، LSWI، NDSVI، TCARI، PVR در تفکیک محصول مؤثرتر عمل کردند. تصاویر سنتینل-۱ به‌تنهایی دقت مطلوبی نداشت، با اضافه کردن سه باند لیه‌قرمز و شاخص پوشش گیاهی مبتنی بر آن NDre، CIre، MSRre که فقط از سه باند لیه‌قرمز استفاده می‌کنند صحت طبقه‌بندی محصولاتی همچون جو، لوبیا، باقلا و کتان افزایش می‌یابد. شکل ۷ نقشه نوع محصول به‌دست‌آمده از تلفیق تصاویر

لیه‌قرمز، به‌خصوص باند B6 و طول موج مادون‌قرمز نزدیک B8 و مادون‌قرمز نزدیک کم‌پهنای B8A در شناسایی محصولات مؤثرتر از باندهای دیگر هستند. شکل ۶ نتایج اهمیت ویژگی‌ها را در روش جنگل تصادفی نشان می‌دهد. شاخص‌های B5، B6، B7، TVI، TCARI، B5، NDVIre2n، PVR و B8 به‌ترتیب مؤثرتر از سایر باندهای طیفی و شاخص‌های طیفی در تفکیک محصول در اغلب سناریوها عمل می‌کنند. از تاریخ‌های انتخاب‌شده تاریخ ۱۸ ژوئیه اهمیت بیشتری داشته است که می‌توان چنین نتیجه گرفت که تصاویر اوج رشد محصولات زراعی برای تفکیک نوع محصول اهمیت بیشتری دارند. در میان ویژگی‌های تصاویر سنتینل-۱ فقط بازپراکنش VH، VV در شناسایی محصولات زراعی مؤثر واقع شد. فقط محصولات گندم، چغندر، سیب‌زمینی، یونجه و ذرت به‌ترتیب با صحت



شکل ۷. نتیجه تلفیق تصاویر سنتینل-۱ و ۲ به روش طبقه‌بندی‌کننده جنگل تصادفی

عمدتاً عمودی دارند که مسلماً چنین محصولاتی روی پلاریزاسیون VV نسبت به پلاریزاسیون HH تأثیر بیشتری خواهند که سبب می‌شود تضعیف نیز در این کانال بیشتر باشد. این امر می‌تواند سبب تفکیک مناسب محصولات دانه‌ای و یا دیگر کلاس‌های مشابه شود (Brisco et al., 1998). به‌طور کلی، هریک از پلاریزاسیون‌ها در موقعیتی خاص مفیدند و اطلاعات ارزشمندی در اختیارمان می‌گذارند. علاوه بر پارامترهای سنجنده که تأثیر زیادی در پاسخ دریافتی از گیاه دارند، ساختار گیاه، ویژگی‌های دی‌الکتریک تاج پوشش، تراکم گیاه و جهت کشت نیز در نوع و شدت بازپراکنش مؤثرند (Liu et al., 2012). شکل کلی یا هندسه محصول در تعیین ویژگی‌های بازپراکنش تأثیرگذار است. به‌طور کلی، محصولات پهن‌برگ مانند ذرت و چغندر در مراحل اولیه رشد خود در باندهای C و X دارای میزان بازپراکنش زیادی خواهند بود، اما به‌علت تأثیر اشباع‌شدگی، میزان بازپراکنش آن‌ها در باقی دوره رشدشان تغییر کمی دارد. در مقابل محصولات دانه‌ای مانند گندم و جو دارای تغییرات زمانی بسیار پویا در بازپراکنش راداری در سراسر دوره رشد خود هستند، هر چند عوامل محیطی (مثلاً رطوبت زیاد خاک پس از بارش سنگین باران) اغتشاشاتی را در میزان بازپراکنش ایجاد می‌کنند (Brisco et al., 1998). البته شایان ذکر است که ویژگی‌های ساختاری محصولات و میزان آب آنها در دوره فنولوژیکی محصول تغییر می‌کند (Feng et al., 2019). برای سایر کلاس‌های موجود طبقه‌بندی محصولات تنها براساس تصاویر سنتینل-۱ در منطقه مورد مطالعه نتیجه مطلوبی نداشت که می‌تواند به دلایل زیر باشد:

۱- شدت بازپراکنش راداری بسته به تاج پوشش محصول متفاوت است، اما زاویه برخورد رادار و رطوبت سطح زمین خاک بر شدت بازپراکنش راداری اثر می‌گذارد، بنابراین محصولات با تاج پوشش مشابه و ظاهر مشابه به تمایز سخت‌تر محصولات منجر می‌شود (Orynbaikyzy et al., 2019).

سنتینل-۱ و ۲ با طبقه‌بندی‌کننده جنگل تصادفی را نشان می‌دهد. اراضی شمال غرب شهر اردبیل دارای زمین‌های مسطح و خاک حاصلخیز است که برای کشت انواع گیاهان زراعی مناسب است. از میان محصولات گندم و جو بیشترین سطح زیر کشت را به خود اختصاص داده‌اند. کشت سیب‌زمینی در رتبه دوم قرار دارد. بقیه کشت‌ها به‌صورت پراکنده توزیع یافته‌اند و تنوع کشت روستای اردی بیشتر از سایر روستاهاست. کمترین درصد سطح کشت مربوط به کشت باقلاست که عمدتاً در روستای باروق کشت می‌شود.

نتایج در تمام سناریوها نشان‌دهنده کارایی طبقه‌بندی‌کننده RF در تفکیک نوع محصولات زراعی است. جنگل تصادفی روش بسیار مفیدی برای از بین بردن افزونگی داده‌ها در یک سری زمانی و به حداکثر رساندن صحت طبقه‌بندی با حداقل ورودی تصویر است (Nitze et al., 2015). این روش علاوه بر دارا بودن سرعت بالا در آموزش و طبقه‌بندی، برای طبقه‌بندی ویژگی‌های با ابعاد بالا قوی عمل می‌کند (Joelsson et al., 2005). الگوریتم RF سرعت بالاتری در آموزش دارد، دچار بیش‌برازش نمی‌شود و هنگامی که ابعاد ویژگی بالا باشد قوی‌تر عمل می‌کند (Kang et al., 2021). برخی محققان دریافته‌اند که خودهمبستگی مکانی صحت طبقه‌بندی را تحت تأثیر قرار می‌دهد (Stehman et al., 2019). با بررسی خودهمبستگی مکانی در محصولات زراعی منطقه مورد مطالعه در سه دوره رویشی مشخص شد خودهمبستگی مکانی برای هر محصول با محصول دیگر متفاوت است. اولین تأثیر خودهمبستگی مکانی این است که صحت طبقه‌بندی را تحت تأثیر قرار می‌دهد. همبستگی مکانی مثبت خطای استاندارد برای نمونه‌برداری افزایش می‌دهد، زیرا پیکسل‌های نزدیک به هم شباهت بیشتری به یکدیگر دارند (Stehman et al., 2019). با طبقه‌بندی محصولات فقط براساس تصاویر سنتینل-۱ محصولات گندم، چغندر، سیب‌زمینی، یونجه و ذرت بهتر از سایر کلاس‌ها تفکیک شدند. در کشاورزی، محصولات دانه‌ای مانند گندم و جو توجیه

با منطقه‌ای باشد که محصولاتی مشابه این منطقه دارد، ویژگی‌های مطلوب متفاوت خواهد بود (Zhang et al., 2021). در این پژوهش شاخص‌هایی در تفکیک محصولات زراعی مؤثرتر عمل کردند که از طول موج‌های لبه‌قرمز، مادون قرمز نزدیک و مادون قرمز نزدیک کم‌پهنای و مادون قرمز موج کوتاه بهره می‌برند. به‌طور کلی طول موج‌های لبه‌قرمز، مادون قرمز نزدیک، مادون قرمز نزدیک کم‌پهنای و مادون قرمز موج کوتاه در طبقه‌بندی محصولات زراعی مفید واقع شدند. در بین این باندها باند لبه‌قرمز B6 و مادون قرمز نزدیک B8 و B8A مادون قرمز موج کوتاه باند B11 مهم‌ترین هستند. در کل باندهای لبه‌قرمز عملکرد بهتری نسبت به طول موج‌های مرئی دارند. این عمدتاً به دلیل بهتر بودن طول موج‌های لبه‌قرمز در گرفتن اطلاعات بیوشیمیایی گیاهان زراعی است (Zhang et al., 2020).

محتوای کلروفیل برگ، ساختار گیاه، تاج پوشش و محتوای آب برگ گیاهان از عوامل اصلی شناسایی نوع محصولاند (Sun et al., 2019). باند اول لبه‌قرمز B5 در مقایسه با دو باند دیگر لبه‌قرمز بیشتر تحت تأثیر محتوای کلروفیل برگ‌های گیاه قرار دارد، در همین حال بسیاری از محصولات در مراحل میانی و اوج رشد و ثمردهی از غلظت بالای کلروفیل برگ برخوردارند. باندهای سبز و قرمز در کلروفیل‌های بالا اشباع می‌شوند که کاربرد باندهای سبز و قرمز در طبقه‌بندی نوع محصول را محدود می‌کند. در مقایسه با باندهای ذکر شده باند 6 سنتینل-۲ با حساسیت بیشتر به غلظت کلروفیل اطلاعات ضروری برای طبقه‌بندی محصول ارائه می‌دهد (Gitelson et al., 1996). تصاویر سنتینل-۲ به دلیل سری زمانی متراکمی که فراهم می‌آورند، از توان تفکیک زمانی پنج روز در استوا و سه روز در عرض‌های میانی برخوردارند تصاویر سنتینل-۲ امکان ثبت دوره‌های کوتاه فنولوژیکی گیاهان را به‌خوبی فراهم می‌آورند در نتیجه اطلاعات دقیقی از مراحل رویش گیاه ثبت می‌شود که در تفکیک گیاهان زراعی بسیار اهمیت دارند (Veloso et al., 2017).

۲- اسپیکل در تصاویر رادار تنوع درون کلاسی را افزایش می‌دهد و جدایی‌پذیری بین کلاس‌های مختلف را پایین می‌آورد، هرچند که اسپیکل به‌شدت وابسته به ویژگی‌های سطح است و نویز نیست. از طرف دیگر اسپیکل آماره‌ها و توزیع ارزش پیکسل‌ها در فضای ویژگی تحت تأثیر قرار می‌دهد، به‌طوری‌که واریانس هر کلاس و کوواریانس بین کلاس‌ها افزایش پیدا می‌کند، این تأثیر جدایی‌پذیری بین کلاس‌ها را از همدیگر افزایش می‌دهد و ممکن است خطای طبقه‌بندی را افزایش دهد (Tavakkoli et al., 2012).

۳- زاویه برخورد استفاده‌شده تفاوت کمی برای تمایز برخی گونه‌های زراعی فراهم می‌کند. بنابراین به دلیل محدود بودن زاویه دید و مدار داده‌های رادار تنها استفاده از داده‌های رادار برای طبقه‌بندی نوع محصول به‌خصوص زمانی که تنوع کشت بالاست کافی نباشد (Ban, 2003). هرچه زاویه دید رادار نسبت به منطقه مورد مطالعه در تصاویر اخذشده بیشتر باشد دقت بالاتری در تفکیک محصول به دست می‌آید.

در تفکیک محصولات زراعی در این تحقیق شاخص‌های معمول پوشش گیاهی نظیر EVI, MSAVI2, RNDVI, IRECI, NDWI, SR, NDVI, در شناسایی محصولات زراعی مؤثر واقع نشدند. به‌طور مثال شاخص NDVI که از تفاوت افزایش بازتاب بین طول موج قرمز و مادون قرمز نزدیک بهره می‌گیرد، ثابت شده است که یک راه مؤثر برای تشخیص محصولات مختلف است. با وجود این برخی محصولات مراحل فنولوژیکی منحصربه‌فردی را نشان می‌دهند که متمایز از سایر محصولات است، به این معنی که NDVI که به‌صورت گسترده برای شناسایی محصولات استفاده می‌شود، ممکن است ویژگی مطلوب برای شناسایی محصولات دیگر نباشد (Zhang et al., 2020). همچنین محققان دریافته‌اند که ویژگی‌های مطلوب برای تفکیک محصولات زراعی وقتی نوع کشته‌ای منطقه مورد مطالعه متفاوت است، اگر توزیع مکانی کشت‌ها متفاوت

۵- نتیجه‌گیری

در این پژوهش دو طبقه‌بندی‌کننده جنگل تصادفی و ماشین بردار پشتیبان با ترکیب ویژگی‌های مختلف باندهای سنتینل-۲ و سنتینل-۱ در تفکیک محصول بررسی شد. نتایج این مطالعه را به صورت زیر می‌توان خلاصه کرد:

- طبقه‌بندی‌کننده جنگل تصادفی برای تمامی سناریوها بالاترین صحت طبقه‌بندی را به دست آورد.
- نتایج نشان داد خودهمبستگی برای محصولات مختلف در فواصل یکسان اتفاق نمی‌افتد و حداقل فاصله بین دو پیکسل برای هر کلاس زراعی متفاوت با کلاس دیگر به دست آمد.
- باندهای لبه‌قرمز و شاخص‌های پوشش گیاهی مبتنی بر آن به‌تنهایی قابلیت جداسازی محصولات زراعی از هم را دارند. به‌دنبال آن باند مادون‌قرمز نزدیک و مادون‌قرمز موج کوتاه و همچنین استفاده از باندهای لبه‌قرمز در کنار سایر باندهای سنتینل-۲ و سنتینل-۱ به افزایش صحت طبقه‌بندی کمک می‌کند.
- شاخص‌های پوشش گیاهی لبه‌قرمز از بااهمیت‌ترین ویژگی‌ها در تفکیک و شناسایی محصولات زراعی همچون جو، باقلا، لوبیا و کتان است.
- با توجه به بررسی‌ای که از تلفیق تصاویر سنتینل-۱ و ۲ در این تحقیق انجام شد می‌توان نتیجه‌گیری کرد که اگر تصاویر سنجش‌ازدور برای منطقه مورد مطالعه در دسترس باشد با توجه به اینکه محصولات زراعی با تصاویر اپتیک هم با صحت قابل قبولی قابل تفکیک‌اند و ترکیب ویژگی‌های اپتیک و رادار به ایجاد ابعاد بالای ویژگی‌ها منجر می‌شود که می‌تواند برای یادگیری ماشین چالش ایجاد کند. با توجه به آنچه گفته شد تلفیق تصاویر اپتیک و رادار با توجه به نوع محصولات مورد بررسی باید در نظر گرفته شود.
- یافته‌های این مطالعه کاربرد مهمی در انتخاب باندهای طیفی هدفمند برای دستیابی به صحت بالاتر در تفکیک محصولات زراعی دارد.

۶- منابع

- Aduvukha, G. R., Abdel-Rahman, E. M., Sichangi, A. W., Makokha, G. O., Landmann, T., Mudereri, B. T., ... & Dubois, T. (2021). Cropping Pattern Mapping in an Agro-Natural Heterogeneous Landscape Using Sentinel-2 and Sentinel-1 Satellite D atasets. *Agriculture*, 11(6), 530.
<https://doi.org/10.3390/agriculture11060530>
- Ban, Y. (2003). Synergy of multitemporal ERS-1 SAR and Landsat TM data for classification of agricultural crops. *Canadian Journal of Remote Sensing*, 29(4), 518-526.
<https://doi.org/10.5589/m03-014>
- Blickensdörfer, L., Schwieder, M., Pflugmacher, D., Nendel, C., Erasmi, S., & Hostert, P. (2022). Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany. *Remote sensing of environment*, 269, 112831.
<https://doi.org/10.1016/j.rse.2021.112831>
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Brisco, B. (1998). "Agricultural Application With Radar" Principles and Application of Imaging RADAR:381-406.
- Bégué, A., Arvor, D., Bellón, B., Betbeder, J., Abelleira, D. D., Ferraz, R. P. D., ... & Verón, S. R. Remote Sensing and Cropping Practices: A Review. *Remote Sens*, 2018, 10 (1), 99.
- Bolton, D. K., & Friedl, M. A. (2013). Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. *Agricultural and Forest Meteorology*, 173, 74-84.
<https://doi.org/10.1016/j.agrformet.2013.01.007>
- Belgiu, M., & Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote sensing of environment*, 204, 509-523.
<https://doi.org/10.1016/j.rse.2017.10.005>
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote sensing of environment*, 37(1), 35-46.
[https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)

- Chong, L. U. O., LIU, H. J., LU, L. P., LIU, Z. R., KONG, F. C., & ZHANG, X. L. (2021). Monthly composites from Sentinel-1 and Sentinel-2 images for regional major crop mapping with Google Earth Engine. *Journal of Integrative Agriculture*, 20(7), 1944-1957. [https://doi.org/10.1016/S2095-3119\(20\)63329-9](https://doi.org/10.1016/S2095-3119(20)63329-9)
- Conese, C., & Maselli, F. (1991). Use of multitemporal information to improve the classification performance of TM scenes in complex terrain. *ISPRS Journal of Photogrammetry and Remote Sensing*, 46(4), 187-197. [https://doi.org/10.1016/0924-2716\(91\)90052-W](https://doi.org/10.1016/0924-2716(91)90052-W)
- Clerici, N., Valbuena Calderón, C. A., & Posada, J. M. (2017). Fusion of Sentinel-1A and Sentinel-2A data for land cover mapping: a case study in the lower Magdalena region, Colombia. *Journal of Maps*, 13(2), 718-726. <https://doi.org/10.1080/17445647.2017.1372316>
- Dash, J., & Curran, P. J. (2004). The MERIS terrestrial chlorophyll index.
- Feng, S., Zhao, J., Liu, T., Zhang, H., Zhang, Z., & Guo, X. (2019). Crop type identification and mapping using machine learning algorithms and sentinel-2 time series data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(9), 3295-3306. <https://doi.org/10.1109/JSTARS.2019.2922469>
- Filgueiras, R., Mantovani, E. C., Althoff, D., Fernandes Filho, E. I., & Cunha, F. F. D. (2019). Crop NDVI monitoring based on sentinel 1. *Remote Sensing*, 11(12), 1441. <https://doi.org/10.3390/rs11121441>
- Gao, F., Anderson, M. C., Zhang, X., Yang, Z., Alfieri, J. G., Kustas, W. P., ... & Prueger, J. H. (2017). Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. *Remote Sensing of Environment*, 188, 9-25. <https://doi.org/10.1016/j.rse.2016.11.004>
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, 58(3), 289-298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Haboudane, D., Miller, J. R., Pattey, E., Zarco-Tejada, P. J., & Strachan, I. B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote sensing of environment*, 90(3), 337-352. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Huang, Z., Chen, H., Hsu, C. J., Chen, W. H., & Wu, S. (2004). Credit rating analysis with support vector machines and neural networks: a market comparative study. *Decision support systems*, 37(4), 543-558. [https://doi.org/10.1016/S0167-9236\(03\)00086-1](https://doi.org/10.1016/S0167-9236(03)00086-1)
- Immitzer, M., Vuolo, F., & Atzberger, C. (2016). First experience with Sentinel-2 data for crop and tree species classifications in central Europe. *Remote sensing*, 8(3), 166. <https://doi.org/10.3390/rs8030166>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning* (Vol. 112, p. 18). New York: Springer
- Jia, K., Li, Q., Tian, Y., Wu, B., Zhang, F., & Meng, J. (2012). Crop classification using multi-configuration SAR data in the North China Plain. *International Journal of Remote Sensing*, 33(1), 170-183. <https://doi.org/10.1080/01431161.2011.587844>
- Joelsson, S. R., Benediktsson, J. A., & Sveinsson, J. R. (2005, July). Random forest classifiers for hyperspectral data. In *Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005. IGARSS'05.* (Vol. 1, pp. 4-pp). IEEE. <https://doi.org/10.1109/IGARSS.2005.1526129>
- Kang, Y., Meng, Q., Liu, M., Zou, Y., & Wang, X. (2021). Crop Classification Based on Red Edge Features Analysis of GF-6 WFV Data. *Sensors*, 21(13), 4328. <https://doi.org/10.3390/s21134328>
- Kim, H. O., & Yeom, J. M. (2014). Effect of red-edge and texture features for object-based paddy rice crop classification using RapidEye

- multi-spectral satellite image data. *International Journal of Remote Sensing*, 35(19), 7046-7068.
<https://doi.org/10.1080/01431161.2014.965285>
- Kobayashi, N., Tani, H., Wang, X., & Sonobe, R. (2020). Crop classification using spectral indices derived from Sentinel-2A imagery. *Journal of Information and Telecommunication*, 4(1), 67-90.
<https://doi.org/10.1080/24751839.2019.1694765>
- Khosravi, I., & Alavipanah, S. K. (2019). A random forest-based framework for crop mapping using temporal, spectral, textural and polarimetric observations. *International Journal of Remote Sensing*, 40(18), 7221-7251.
<https://doi.org/10.1080/01431161.2019.1601285>
- [26] Khosravi, I., Safari, A., & Homayouni, S. (2018). MSMD: maximum separability and minimum dependency feature selection for cropland classification from optical and radar data. *International Journal of Remote Sensing*, 39(8), 2159-2176.
<https://doi.org/10.1080/01431161.2018.1425564>
- Liu, C., Shang, J., Vachon, P. W., & McNairn, H. (2012). Multiyear crop monitoring using polarimetric RADARSAT-2 data. *IEEE Transactions on Geoscience and Remote Sensing*, 51(4), 2227-2240.
<https://doi.org/10.1109/TGRS.2012.2208649>
- Liu, Y., Wang, X., & Qian, J. (2021). Crop distribution extraction based on Sentinel data. In *E3S Web of Conferences* (Vol. 252, p. 02081). EDP Sciences.
<https://doi.org/10.1051/e3sconf/202125202081>
- Nitze, I., Barrett, B., & Cawkwell, F. (2015). Temporal optimisation of image acquisition for land cover classification with Random Forest and MODIS time-series. *International Journal of Applied Earth Observation and Geoinformation*, 34, 136-146.
<https://doi.org/10.1016/j.jag.2014.08.001>
- 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/10.1080/01431161.2019.1569791>
- Pal, M., & Mather, P. M. (2004). Assessment of the effectiveness of support vector machines for hyperspectral data. *Future generation computer systems*, 20(7), 1215-1225.
<https://doi.org/10.1016/j.future.2003.11.011>
- Qiong, H. U., WU, W. B., Qian, S. O. N. G., Miao, L. U., Di, C. H. E. N., YU, Q. Y., & TANG, H. J. (2017). How do temporal and spectral features matter in crop classification in Heilongjiang Province, China?. *Journal of integrative agriculture*, 16(2), 324-336.
[https://doi.org/10.1016/S2095-3119\(15\)61321-1](https://doi.org/10.1016/S2095-3119(15)61321-1)
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sanchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93-104.
<https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- Shamsoddini, A., J. C. Trinder, and R. Turner. 2013. "Non-Linear Methods for Inferring Lidar Metrics Using SPOT-5 Textural Data." *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences II-5/W2*: 259-264.
 doi:10.5194/isprsannals-II-5-W2-259-2013. <https://doi.org/10.5194/isprsannals-II-5-W2-259-2013>, 2013.
- Skriver, H., Mattia, F., Satalino, G., Balenzano, A., Pauwels, V. R., Verhoest, N. E., & Davidson, M. (2011). Crop classification using short-revisit multitemporal SAR data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(2), 423-431.
<https://doi.org/10.1109/JSTARS.2011.2106198>
- 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.
<https://doi.org/10.3390/s19102401>
- Sun, L., Chen, J., Guo, S., Deng, X., & Han, Y.

- (2020). Integration of Time Series Sentinel-1 and Sentinel-2 Imagery for Crop Type Mapping over Oasis Agricultural Areas. *Remote Sensing*, 12(1), 158. <https://doi.org/10.3390/rs12010158>
- Shamsoddini, A., & Raval, S. (2018). Mapping red edge-based vegetation health indicators using Landsat TM data for Australian native vegetation cover. *Earth Science Informatics*, 11(4), 545-552. <https://doi.org/10.1080/01431160701281056>
- Stehman, S. V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote sensing of Environment*, 62(1), 77-89. [https://doi.org/10.1016/S0034-4257\(97\)00083-7](https://doi.org/10.1016/S0034-4257(97)00083-7)
- Stehman, S. V., & Foody, G. M. (2019). Key issues in rigorous accuracy assessment of land cover products. *Remote Sensing of Environment*, 231, 111199. <https://doi.org/10.1016/j.rse.2019.05.018>
- Sonobe, R., Yamaya, Y., Tani, H., Wang, X., Kobayashi, N., & Mochizuki, K. I. (2018). Crop classification from Sentinel-2-derived vegetation indices using ensemble learning. *Journal of Applied Remote Sensing*, 12(2), 026019. <https://doi.org/10.1117/1.JRS.12.026019>
- Schuster, C., Förster, M., & Kleinschmit, B. (2012). Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. *International Journal of Remote Sensing*, 33(17), 5583-5599. <https://doi.org/10.1080/01431161.2012.666812>
- Tariq, A., Yan, J., Gagnon, A. S., Riaz Khan, M., & Mumtaz, F. (2022). Mapping of cropland, cropping patterns and crop types by combining optical remote sensing images with decision tree classifier and random forest. *Geo-spatial Information Science*, 1-19. <https://doi.org/10.1080/10095020.2022.2100287>
- Tavakkoli, M. (2011). Multi-Temporal Classification of Crops Using ENVISAT ASAR Data (Doctoral dissertation, Ph. D. Dissertation, Leibniz University of Hannover). DOI:10.4236/ijg.2014.52021
- Tscharntke, T., Clough, Y., Wanger, T. C., Jackson, L., Motzke, I., Perfecto, I., ... & Whitbread, A. (2012). Global food security, biodiversity conservation and the future of agricultural intensification. *Biological Conservation*, 151(1), 53-59. <https://doi.org/10.1016/j.biocon.2012.01.068>
- Wilson, J. H., Zhang, C., & Kovacs, J. M. (2014). Separating crop species in northeastern Ontario using hyperspectral data. *Remote Sensing*, 6(2), 925-945. <https://doi.org/10.3390/rs6020925>
- Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J. F., & Ceschia, E. (2017). Understanding the temporal behaviour of crops using Sentinel-1 and Sentinel-2-like data for agricultural applications. *Remote sensing of environment*, 199, 415-426. <https://doi.org/10.1016/j.rse.2017.07.015>
- Yilmaz, M. T., Hunt Jr, E. R., & Jackson, T. J. (2008). Remote sensing of vegetation water content from equivalent water thickness using satellite imagery. *Remote Sensing of Environment*, 112(5), 2514-2522. <https://doi.org/10.1016/j.rse.2007.11.014>
- 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. <https://doi.org/10.3390/rs12244052>
- Zandsalimi, Z., Sima, S., & Mousivand, A. (2021). Evaluating the Performance of Global Land Cover Maps in Agricultural Land Delineation (Case Study: Lake Urmia Basin). *Iranian Journal of Soil and Water Research*, 52(3), 795-810. <https://dx.doi.org/10.22059/ijswr.2021.315097.668828>
- Zhong, L., Gong, P., & Biging, G. S. (2014). Efficient corn and soybean mapping with temporal extendability: A multi-year experiment using Landsat imagery. *Remote Sensing of Environment*, 140, 1-13. <https://doi.org/10.1016/j.rse.2013.08.023>
- Zhang, T., Su, J., Liu, C., Chen, W. H., Liu, H., & Liu, G. (2017, September). Band selection in Sentinel-2 satellite for agriculture

- applications. In *2017 23rd International Conference on Automation and Computing (ICAC)* (pp. 1-6). IEEE.
<https://doi.org/10.23919/ICAC.2017.8081990>
- Zhang, H., Kang, J., Xu, X., & Zhang, L. (2020). Accessing the temporal and spectral features in crop type mapping using multi-temporal Sentinel-2 imagery: A case study of Yi'an County, Heilongjiang province, China. *Computers and Electronics in Agriculture*, *176*, 105618.
<https://doi.org/10.1016/j.compag.2020.105618>
- Zhang, L., Gong, Z. N., Wang, Q. W., Jin, D. D., & Wang, X. (2019). Wetland mapping of Yellow River Delta wetlands based on multi-feature optimization of Sentinel-2 images. *J. Remote Sens*, *23*, 313-326.
<https://doi.org/10.1016/j.scitotenv.2021.147061>
- Zhang, H., Wang, Y., Shang, J., Liu, M., & Li, Q. (2021). Investigating the impact of classification features and classifiers on crop mapping performance in heterogeneous agricultural landscapes. *International Journal of Applied Earth Observation and Geoinformation*, *102*, 102388.
<https://doi.org/10.1016/j.jag.2021.102388>

