

# Crop Mapping Using Machine Learning Algorithms and Dual-Polarized Indices Derived From Multi-Temporal Sentinel-1 Data

Seyed Hedayat Sheikhghaderi<sup>1</sup>, Mostafa Mahdavi<sup>2\*</sup>, Reyhaneh Modirzadeh<sup>2</sup>, Khalil Valizadeh Kamran<sup>2</sup>

1. Dep of Remote Sensing and Geographic Information Systems, Faculty of Geography, Kharazmi University, Tehran, Iran
2. Dep of Remote Sensing and Geographic Information Systems, Faculty of Planning and Environmental Sciences, University of Tabriz, Tabriz, Iran

\* Corresponding Author: mostafamahdavi842@gmail.com

## ABSTRACT

**Introduction:** In recent years, with increasing pressure on natural resources and the need for sustainable use of agricultural land, precision agriculture has gained growing importance as an efficient approach for smart resource management. One of the fundamental challenges in this field is the accurate identification of crop types and monitoring their growth stages at appropriate temporal and spatial scales. Remote sensing technology, particularly Synthetic Aperture Radar (SAR), enables the extraction of precise ground information under various weather conditions. Unlike optical data, which are highly dependent on illumination and often limited in cloudy regions, radar data such as Sentinel-1 imagery provide effective tools for agricultural monitoring with their all-weather, day-and-night imaging capability. In this context, the present study aims to investigate the potential of Sentinel-1 radar time series data and its VV and VH polarizations, along with derived polarimetric indices, for accurate crop classification in an agricultural area located in the suburbs of Mashhad. The main focus of this research is to evaluate the capability of different machine learning algorithms combined with radar data to enhance classification accuracy and achieve more precise crop identification.

**Materials and Methods:** For this study, Sentinel-1 radar time series data with VV and VH polarizations, covering the period from winter 2021 to spring 2022, were used. The study area includes agricultural lands in Mashhad County, characterized by a variety of crops such as wheat, chickpea, alfalfa, as well as non-cropland areas. Through radar data processing, four key polarimetric indices NRPB (Noise-to-Backscatter Ratio), DPDD (Dual-Polarization Difference), IDPDD (Integrated Dual-Polarization Differential), and VDDPI (Temporal Variation Index for VV and VH) were extracted and employed in combination with the original data for classification purposes.

Three powerful machine learning algorithms XGBoost, Random Forest (RF), and Support Vector Machine (SVM) were applied for crop classification. Training samples were collected for seven defined classes within the study area, and classification accuracy was evaluated using the error matrix, Kappa coefficient, and overall accuracy.

**Results and Discussion:** The results of modeling and classification, which were validated using field data associated with the coordinates of each plot, showed that the XGBoost and RF algorithms performed significantly better than the SVM algorithm. The overall accuracy and Kappa for the XGBoost model were 83.48% and 0.78, respectively, and for the RF model were 82.27% and 0.78, whereas the SVM algorithm achieved an overall accuracy and Kappa of 61.46% and 0.51. This performance difference is primarily attributed to the superior ability of tree-based algorithms to model complex and nonlinear relationships between features and classes.

Among the polarimetric indices, DPDD and IDPDD demonstrated distinct temporal behaviors during different crop growth stages, proving highly valuable for phenological crop discrimination. Crops such as alfalfa, chickpea, and wheat were classified with higher accuracy and less confusion by XGBoost and RF, whereas SVM struggled to separate classes with similar vegetation cover, leading to substantial overlaps between certain crop types. Among the polarimetric indices, DPDD and IDPDD demonstrated distinct temporal behaviors during different crop growth stages, proving highly valuable for phenological crop discrimination. Crops such as alfalfa, chickpea, and wheat were

classified with higher accuracy and less confusion by XGBoost and RF, whereas SVM struggled to separate classes with similar vegetation cover, leading to substantial overlaps between certain crop types.

**Conclusion:** This study clearly demonstrated that Sentinel-1 radar data particularly VV and VH polarizations combined with time-series derived polarimetric indices, hold strong potential for accurate crop classification. The integration of these data with advanced machine learning algorithms, especially XGBoost and RF, can provide reliable alternatives to traditional optical-based methods, particularly in cloudy regions or areas with limited access to optical data. Moreover, the findings, in line with similar international studies, highlight the importance and effectiveness of polarimetric indices as key tools for periodic crop monitoring. Utilizing these indices alongside time-series data represents a significant step toward optimizing agricultural land management, enhancing productivity, and promoting sustainable development in the agricultural sector. Consequently, the adoption of modern remote sensing technologies and machine learning will play a pivotal role in shaping the future of smart and sustainable agriculture.

**Keywords:** Sentinel-1, Machine Learning, Dual-Polarization Index, Crop Mapping, Google Earth Engine

## نقشه برداری محصولات زراعی با بهره‌گیری از الگوریتم‌های یادگیری ماشین و شاخص‌های دو پلاریزه دریافتی از داده‌های چند زمانه سنتینل-۱

سید هدایت شیخ قادری<sup>۱</sup>، مصطفی مهدوی فرد<sup>۲\*</sup>، ریحانه مدیرزاده<sup>۲</sup>، خلیل ولیزاده کامران<sup>۲</sup>

۱. گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه خوارزمی، تهران، ایران

۲. گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده برنامه‌ریزی و علوم محیطی، دانشگاه تبریز، تبریز، ایران

\*نویسنده عهده دار مکاتبات: mostafamahdavi842@gmail.com

### چکیده

**سابقه و هدف:** در سال‌های اخیر، با افزایش فشار بر منابع طبیعی و نیاز به بهره‌برداری پایدار از اراضی کشاورزی، اهمیت کشاورزی دقیق به‌عنوان رویکردی کارآمد برای مدیریت هوشمند منابع بیش‌ازپیش موردتوجه قرار گرفته است. یکی از چالش‌های اساسی در این حوزه، شناسایی دقیق نوع محصولات زراعی و پایش مراحل رشد آن‌ها در مقیاس‌های زمانی و مکانی مناسب است. فناوری سنجش‌ازدور، به‌ویژه رادار با روزه مصنوعی (SAR)، امکان استخراج اطلاعات دقیق از سطح زمین را در شرایط مختلف آب‌وهوایی فراهم می‌سازد. برخلاف داده‌های اپتیکی که وابسته به شرایط نوری و اغلب در مناطق ابری با محدودیت مواجه‌اند، داده‌های راداری از جمله تصاویر ماهواره سنتینل-۱، با قابلیت تصویربرداری شبانه‌روزی و عبور از پوشش ابری، ابزاری مؤثر برای پایش اراضی کشاورزی محسوب می‌شوند. در این راستا، پژوهش حاضر باهدف بررسی قابلیت داده‌های سری زمانی راداری سنتینل-۱ و قطبش‌های VV و VH به همراه شاخص‌های قطبشی مشتق‌شده از آن‌ها، در طبقه‌بندی دقیق محصولات زراعی در منطقه‌ای در حومه شهر مشهد انجام شده است. تمرکز اصلی این مطالعه بر روی ارزیابی توانایی الگوریتم‌های مختلف یادگیری ماشین در ترکیب با داده‌های راداری در جهت بهبود دقت طبقه‌بندی و شناسایی دقیق‌تر محصولات بوده است.

**مواد و روش‌ها:** برای انجام این تحقیق، داده‌های سری زمانی راداری سنتینل-۱ در دو قطبش VV و VH مربوط به دوره زمستان ۱۴۰۰ تا بهار ۱۴۰۱ مورد استفاده قرار گرفت. منطقه مورد مطالعه بخشی از اراضی کشاورزی در شهرستان مشهد است که با تنوع مناسبی از محصولات زراعی مانند گندم، نخود، یونجه و همچنین اراضی غیر زراعی مشخص می‌شود. با پردازش داده‌های راداری، چهار شاخص قطبشی مهم شامل NRPB (نسبت نویز به سیگنال پس پراکنش)، DPDD (تفاضل قطبش‌های دوبه‌دو)، IDPDD (یکپارچگی تفاضلی قطبشی) و VDDPI (شاخص تغییرات زمانی در داده‌های VV و VH) استخراج شدند که در ترکیب با داده‌های اصلی برای طبقه‌بندی مورد استفاده قرار گرفتند.

برای طبقه‌بندی محصولات، سه الگوریتم قدرتمند یادگیری ماشین شامل درخت تقویت‌گرایان (XGBoost)، جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM) به کار گرفته شد. داده‌های آموزشی برای هفت کلاس تعریف‌شده در منطقه جمع‌آوری گردید و صحت طبقه‌بندی از طریق ماتریس خطا، ضریب کاپا و دقت کلی مورد ارزیابی قرار گرفت.

**نتایج و بحث:** نتایج حاصل از مدل‌سازی و طبقه‌بندی، که بر اساس داده‌های میدانی مرتبط با مختصات هر قطعه زمین اعتبارسنجی شد، نشان داد که الگوریتم‌های XGBoost و RF به‌طور قابل‌توجهی عملکرد بهتری نسبت به الگوریتم SVM داشتند. دقت کلی و ضریب کاپا برای مدل XGBoost به ترتیب ۸۳.۴۸٪ و ۰.۷۸، برای مدل RF به ترتیب ۸۲.۲۷٪ و ۰.۷۸ گزارش شد، در حالی که الگوریتم SVM دقت کلی و ضریب کاپایی برابر با ۶۱.۴۶٪ و ۰.۵۱ ارائه داد. این اختلاف عملکرد عمدتاً ناشی از توانایی بالاتر الگوریتم‌های مبتنی بر درخت تصمیم در مدل‌سازی روابط پیچیده و غیرخطی بین ویژگی‌ها و کلاس‌ها است.

از میان شاخص‌های قطبشی، دو شاخص DPDD و IDPDD توانستند رفتار زمانی متفاوتی را در مراحل مختلف رشد گیاهان نشان دهند که این ویژگی برای تشخیص فنولوژیکی محصولات بسیار مفید بود. محصولاتی نظیر یونجه، نخود و گندم توسط الگوریتم‌های XGBoost و RF با دقت بالاتری طبقه‌بندی شدند و میزان اختلاط کمتری با سایر کلاس‌ها داشتند. در مقابل، الگوریتم SVM در تفکیک کلاس‌هایی با پوشش گیاهی مشابه، نظیر برخی محصولات زراعی نزدیک فنولوژی، عملکرد ضعیف‌تری داشت و هم‌پوشانی قابل‌توجهی بین کلاس‌ها مشاهده گردید.

**نتیجه‌گیری:** پژوهش حاضر به‌روشنی نشان داد که داده‌های راداری سنتینل-۱، به‌ویژه در دو قطبش VV و VH، در کنار شاخص‌های استخراج‌شده از سری‌های زمانی آن، قابلیت بالایی در طبقه‌بندی دقیق محصولات کشاورزی دارند. ترکیب این داده‌ها با الگوریتم‌های پیشرفته یادگیری ماشین به‌ویژه XGBoost و RF، می‌تواند بدون نیاز به داده‌های اپتیکال و با عملکردی قابل‌قبول، جایگزین مناسبی برای روش‌های سنتی در شرایط جوی نامناسب باشد. این موضوع به‌ویژه در مناطق ابری یا مناطقی که دسترسی به داده‌های نوری محدود است، اهمیت بیشتری می‌یابد.

همچنین، یافته‌های این تحقیق هم‌راستا با مطالعات مشابه بین‌المللی، بر اهمیت و اثربخشی شاخص‌های قطبشی به‌عنوان ابزارهایی کلیدی در پایش دوره‌ای رشد محصولات زراعی تأکید می‌کند. بهره‌گیری از این شاخص‌ها در کنار داده‌های سری زمانی می‌تواند گامی مؤثر در جهت بهینه‌سازی مدیریت اراضی کشاورزی، افزایش بهره‌وری و توسعه پایدار در بخش کشاورزی باشد. از این‌رو، استفاده از فناوری‌های نوین سنسورزودور و یادگیری ماشین، نقش برجسته‌ای در آینده کشاورزی هوشمند و پایدار ایفا خواهد کرد.

**واژگان کلیدی:** سنتینل-۱، یادگیری ماشین، شاخص دو پلاریزه، محصول زراعی، گوگل ارث انجین

## مقدمه

کشاورزی یکی از مهم‌ترین شیوه‌های بهره‌برداری از زمین در سطح جهانی به شمار می‌رود و همواره جایگاه برجسته‌ای در مطالعات علمی داشته است، به‌ویژه در عصری که جهان به‌سوی پایداری زیست‌محیطی در حال حرکت است (Sharma et al., 2024). این بخش از فعالیت‌های انسانی، نقشی اساسی در تأمین نیازهای تغذیه‌ای بشر و توسعه پایدار ایفا می‌کند (Zhang et al., 2024). در سال‌های اخیر، تغییرات اقلیمی، همراه با رشد سریع جمعیت و تخریب فزاینده محیط‌زیست، موجب شده است تا نیاز به اطلاعات به‌موقع و دقیق کشاورزی بیش‌ازپیش افزایش یابد (Kazemi Garajeh et al., 2023).

در این راستا، پایش وضعیت رشد گیاهان زراعی و ارزیابی عملکرد آن‌ها، از ارکان اصلی مدیریت بهینه در کشاورزی مدرن به شمار می‌آید. شناسایی نوع محصول، نخستین گام در ایجاد سامانه‌های مؤثر برای پایش و برآورد عملکرد زراعی است (Nagraj et al., 2016). با این حال، روش‌های سنتی برداشت اطلاعات میدانی، به دلیل بازدهی اقتصادی پایین و ویژگی‌های خاص کشاورزی همچون وسعت زیاد اراضی، ماهیت فصلی تولید و ناهمگنی شدید فضایی، توانایی تأمین داده‌های سالانه در مقیاس ملی یا منطقه‌ای را ندارند. از سوی دیگر، اطلاع از سطح زیر کشت هر محصول، مؤلفه‌ای کلیدی در برآورد تولید کل محصولات کشاورزی هر کشور محسوب می‌شود و نقش مؤثری در تنظیم بازارهای داخلی و بین‌المللی این محصولات دارد (Nagraj et al., 2016). در این میان، فناوری سنسورزودور به‌عنوان ابزاری کارآمد و عملی، توانسته است راه‌حلی مؤثر برای غلبه بر محدودیت‌های روش‌های سنتی ارائه دهد. این فناوری نه تنها در شناسایی نوع محصولات زراعی، بلکه در برآورد عملکرد آن‌ها نیز به‌طور گسترده مورد استفاده قرار گرفته است.

داده‌های سنجش‌ازدور با فراهم‌سازی اطلاعات مکانی-فضایی دقیق از سطح زمین، امکان ارزیابی منابع اراضی و پایش محیط‌زیست را در سطحی وسیع فراهم می‌کنند (Ajadi et al., 2021).

در گذشته، رویکردهای سنتی برای تولید نقشه‌های نوع محصول نظیر مصاحبه با کشاورزان و جوامع محلی معمولاً زمان‌بر، پرهزینه و وابسته به نیروی انسانی بودند (Mahdizadeh, Pott et al., 2021; Bégué et al., 2018; Jayne and Rashid., 2010; Özdoğan et al., 2025; Liu et al., 2025; Gharakhanlou et al., 2024). در مقابل، مروری بر پژوهش‌های انجام‌شده در چند دهه اخیر نشان می‌دهد که بیشتر مطالعات از داده‌های نوری چند طیفی ماهواره‌های Landsat و MODIS به‌منظور طبقه‌بندی محصولات بهره گرفته‌اند که دلیل اصلی آن در دسترس بودن تاریخی این داده‌ها بوده است (Ajadi et al., 2021). با این حال، چالش پوشش ابری سنگین در طول فصل رشد، موجب شده است تا دسترسی به تصاویر نوری با قدرت تفکیک مکانی و زمانی مناسب، محدود شود. در سال‌های اخیر، استفاده از داده‌های راداری با درجه مصنوعی (SAR) مورد توجه فراوان قرار گرفته است؛ چراکه این داده‌ها قابلیت نفوذ به ابر را داشته و در شرایط مختلف آب‌وهوایی قابل بهره‌برداری هستند (Liu et al., 2019).

در مناطق با پوشش ابری مکرر، داده‌های راداری سنتینل-۱ به دلیل توانایی تصویربرداری در تمام شرایط آب و هوایی، به‌ویژه در فصل‌های بارانی، ابزار مناسبی برای پیش‌بینی بهره‌وری و برنامه‌ریزی کشاورزی محسوب می‌شوند (Nasirzadehdizaji et al., 2019). در مقابل، داده‌های نوری مانند سنتینل-۲ و لندست-۸ به دلیل محدودیت نفوذ به ابر، کارایی محدودی در این شرایط دارند (Ulaby, 1975 و McNairn and Shang, 2016).

ماهواره سنتینل-۱، آمورتیتی از آژانس فضایی اروپا متشکل از دو ماهواره A و B است که تناوب بازدید ۶ روزه را فراهم می‌کند و امکان پایش رشد محصولات زراعی در مراحل حساس فنولوژیکی را مهیا می‌سازد. این سنجنده در حالت دو قطبی (dual-pol) فعالیت می‌کند؛ به این صورت که موج قطبیده عمودی ارسال شده و بازتاب آن در دو حالت VV و VH ثبت می‌شود. داده‌های حاصل شامل شدت پراکنش بازگشتی هستند که به پارامترهایی مانند رطوبت خاک و گیاه، ساختار گیاهی، زبری سطح و زاویه تابش حساس‌اند (Nagaraju et al., 2013; Ackermann et al., 2014 و Narvekar et al., 2015). همچنین، شدت سیگنال باز پراکنش با ویژگی‌های پوشش زمین و مراحل فنولوژیکی گیاهان مرتبط است و همین امر آن را به ابزاری کارآمد برای شناسایی و تفکیک انواع محصولات زراعی تبدیل می‌کند (Whelen and Siqueira, 2018; Mandal et al., 2018 و Arias et al., 2020). بر همین اساس، بهره‌گیری از این قطبش‌ها و ترکیب آن‌ها باهم در قالب شاخص‌های راداری می‌تواند در تحلیل دقیق‌تر این تفاوت‌ها مؤثر واقع شود.

در سال‌های اخیر، شاخص‌های پوشش گیاهی مبتنی بر داده‌های SAR، به‌ویژه از نوع دو قطبی، توسعه یافته‌اند تا برای شناسایی، تفکیک و پایش رشد محصولات مورد استفاده قرار گیرند (Engman and Chauhan, 1995; Choudhury and Tucker, 1987; Ulaby et al., 1996 و Jackson et al., 1999). این شاخص‌ها با استفاده از ویژگی‌های قطبشی باند C، کنتراست بین پوشش گیاهی و سایر اهداف را افزایش داده و تفسیر داده‌ها را ساده‌تر می‌کنند (Periasamy et al., 2018; Chang et al., 2018; Mandal et al., 2020 و de Freitas Bussinguer et al., 2024). در واقع شاخص‌های مبتنی بر قطبش دوگانه در داده‌های SAR، نقش کلیدی در ارزیابی‌های کشاورزی مانند پایش رشد، تنش‌های زراعی و پیش‌بینی عملکرد ایفا می‌کند (Bousbih; Bargiel, 2017; Nguyen et al., 2016; Kussul et al., 2016; Van Tricht et al., 2018).

با توجه به قابلیت‌های منحصربه‌فرد تصویربرداری سنجنده‌های راداری در تمام شرایط جوی، کاربرد این داده‌ها در پایش و ارزیابی محصولات زراعی، به‌ویژه در مناطق با پوشش ابری بالا، روزبه‌روز بیشتر مورد توجه قرار گرفته است. با این حال، بخش عمده‌ای از مطالعات گذشته عمدتاً بر ترکیب داده‌های راداری و اپتیکی تمرکز داشته‌اند و پژوهش‌هایی که صرفاً مبتنی بر داده‌های راداری باشند، همچنان محدود و نسبتاً معدود باقی مانده‌اند. این موضوع نشان می‌دهد که بررسی ظرفیت داده‌های راداری مستقل، به‌ویژه از نوع قطبش‌دار، در طبقه‌بندی و پایش محصولات کشاورزی، همچنان جای کار و توسعه فراوانی دارد. در این راستا، شاخص‌های متنوعی نیز از داده‌های راداری استخراج شده‌اند که می‌توانند اطلاعات معناداری درباره ساختار، رطوبت و وضعیت فنولوژیکی پوشش گیاهی ارائه دهند. در ادامه، برخی از مهم‌ترین پژوهش‌های انجام شده در این حوزه مرور می‌شوند.

Mahdavi et al (2020) با استفاده از داده‌های سری زمانی سنتینل-۱ و سنتینل-۲ به برآورد و تهیه نقشه یک‌ساله محصول برنج در شهرستان جویبار پرداختند. نتایج نشان داد که ترکیب داده‌های اپتیکی و راداری دقت بالایی در تهیه نقشه محصولات زراعی داشته و نقشه نهایی با دقت کلی ۹۷٪ و ضریب کاپای ۹۳٪ تهیه شد. در پژوهشی دیگر، Asadi and shamsoddini (2024) با به‌کارگیری سری زمانی داده‌های سنتینل-۱ و سنتینل-۲ در شمال غرب اردبیل و استفاده از الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان نشان دادند که باندهای لبه قرمز و شاخص‌های گیاهی نقش مهمی در بهبود تفکیک محصولات زراعی دارند و ترکیب داده‌های راداری و اپتیکی به صحت کلی ۸۴.۶۷٪ و کاپای ۸۲.۳۱٪ منجر می‌شود.

در همین راستا، Forkuor et al (2014) در شمال غربی بنین با ترکیب داده‌های اپتیکی چند زمانه RapidEye و راداری TerraSAR-X و استفاده از الگوریتم جنگل تصادفی نشان دادند که دقت طبقه‌بندی در مقایسه با داده‌های صرف اپتیکی ۱۰ تا ۱۵ درصد افزایش می‌یابد. همچنین، بررسی قطبش‌ها حاکی از عملکرد بهتر VV نسبت به VH در تفکیک محصولات و دستیابی به دقتی حدود ۷۵٪ بود. Van Tricht et al (2018) نیز در بلژیک داده‌های سنتینل-۱ و سنتینل-۲ را به صورت موزاییک‌های چندروزه ترکیب کرده و با طبقه‌بندی جنگل تصادفی به دقت کلی ۸۲٪ و کاپای ۷۷٪ دست یافتند که نشان‌دهنده مزیت ترکیب دو سنجنده نسبت به استفاده منفرد است.

در پژوهشی دیگر Dingle Robertson et al (2020) تجربه کانادا در استفاده از داده‌های راداری باند C همراه با داده‌های اپتیکی را برای نقشه‌برداری سرتاسری محصولات کشاورزی ارزیابی کرده و با ارزیابی سه نوع فیلتر نویز (سازگار، چند زمانه و چند وضوحی) نشان دادند که فیلتر چند وضوحی Touzi بهترین عملکرد را ارائه داده و اهمیت انتخاب روش پردازش داده را برجسته کردند. این نتایج برای طراحی سامانه‌های عملیاتی در مقیاس ملی مفید بوده و نقش مهم داده‌های SAR در پایش جهانی محصولات کشاورزی را برجسته می‌کند.

Yousefi and Kordi (2022) نیز در مطالعه‌ای که بر روی بخشی از حوزه آبخیز میان‌دوآب در شمال غرب ایران با ترکیب داده‌های اپتیکی، راداری و مدل ارتفاعی رقومی و استفاده از الگوریتم SVM گزارش کردند که این رویکرد دقت طبقه‌بندی محصولات زراعی شامل یونجه، گندم، چغندر قند، سیب و انگور را به‌طور معناداری در مقایسه با داده‌های تک‌سنجنده‌ای افزایش می‌دهد. به همین ترتیب، Yuan et al (2023) با معرفی روشی نوین مبتنی بر یادگیری تضاد متقابل نشان دادند که هم‌زمانی داده‌های اپتیکی و راداری در شبکه‌های یادگیری عمیق به بهبود دقت طبقه‌بندی محصولات کشاورزی، حتی در شرایط محدودیت داده‌های آموزشی، منجر می‌شود.

Maleki et al (2024) نیز با تمرکز بر آفتاب‌گردان، سویا و ذرت نشان دادند که ترکیب سری زمانی داده‌های اپتیکی سنتینل-۲ (باند‌های طیفی و شاخص‌های پوشش گیاهی)، داده‌های راداری سنتینل-۱ (ضرایب باز پراکنش و پارامترهای قطبشی) و ویژگی‌های فنولوژیکی استخراج‌شده از هر دو منبع و استفاده از الگوریتم‌های یادگیری ماشین به‌ویژه InceptionTime دقت بالایی در تفکیک محصولات ارائه می‌کند، هرچند ویژگی‌های قطبشی عملکرد ضعیف‌تری داشتند. در ادامه، Jensch et al (2025) در آلمان با ترکیب داده‌های میدانی، اپتیکی و راداری و استفاده از RF نشان دادند که پوشش داده‌های اپتیکی در پاییز و زمستان برای دقت طبقه‌بندی محصولات میان‌دوره‌ای ضروری است، درحالی‌که داده‌های SAR نقش مکمل و تقویت‌کننده ایفا می‌کنند. در همین راستا، Suwanlee et al (2025) در شمال شرق تایلند با ترکیب داده‌های چند سنجنده‌ای پریسما، سنتینل-۱، سنتینل-۲ و لندست-۹ و ۸ به‌کارگیری الگوریتم جنگل تصادفی گزارش کردند که ادغام چند منبعی نه‌تنها دقت بالایی در بهبود نقشه‌برداری محصولات داشته و با آمار رسمی اداره توسعه اراضی، همبستگی بالایی دارد، بلکه محدودیت داده‌های تک سنجنده‌ای را نیز برطرف می‌کند.

Usey and Chen (2019) در زیمبابوه با بهره‌گیری از سری زمانی سنتینل-۱ و مدل‌سازی فوریه نشان دادند که داده‌های راداری توانایی بالایی در شناسایی تغییرات جزئی الگوهای کشت و تناوب زراعی مزارع کوچک‌مقیاس دارد و طبقه‌بندی چند زمانه با جنگل تصادفی دقت‌های بالای ۹۹٪ و ۹۵٪ در مناطق مختلف به دست داد. این پژوهش، کارایی بالای داده‌های SAR در پایش سیستم‌های تک کشت، دو کشت و سه کشت در مزارع کوچک و بزرگ را تأیید کرد. به‌طور مشابه، Gella et al (2021) در هلند با داده‌های دو قطبشی سنتینل-۱ و تک قطبشی TerraSAR-X و روش‌های طبقه‌بندی مبتنی بر twDTW جهت طبقه‌بندی محصولات زراعی نشان دادند که ادغام داده‌ها و بهره‌گیری از شاخص‌های راداری Ratio، MRVI و DPSVI و همچنین تجزیه پلاریمتریک، دقت کلی را تا ۸۰.۶٪ افزایش می‌دهد.

Mishra et al (2023) در هند با استفاده از شاخص ترکیبی راداری مشتق‌شده از باندهای VH و VV تصاویر سنتینل-۱ و به‌کارگیری الگوریتم‌های RF و SVM توانستند محصولات فصل بارانی را با دقت بیش از ۹۳٪ طبقه‌بندی کنند و تأکید کردند که شاخص IDPDD حساسیت بالایی نسبت به محصولات با پراکندگی زیاد دارد. در پژوهشی دیگر، Sorokin et al (2024) با داده‌های راداری سنتینل-۱ و الگوریتم‌های یادگیری ماشین در روسیه نشان دادند که شاخص DpRVI از پایداری مکانی-زمانی بالاتری نسبت به سایر شاخص‌ها (VH/VV و RVI) برخوردار بوده و عملکردی قابل‌مقایسه با NDVI دارد و می‌تواند در شرایط ابری جایگزین مؤثری برای داده‌های اپتیکی و ابزاری مؤثر برای پایش رشد گیاهان و نقشه‌برداری کشاورزی باشد.

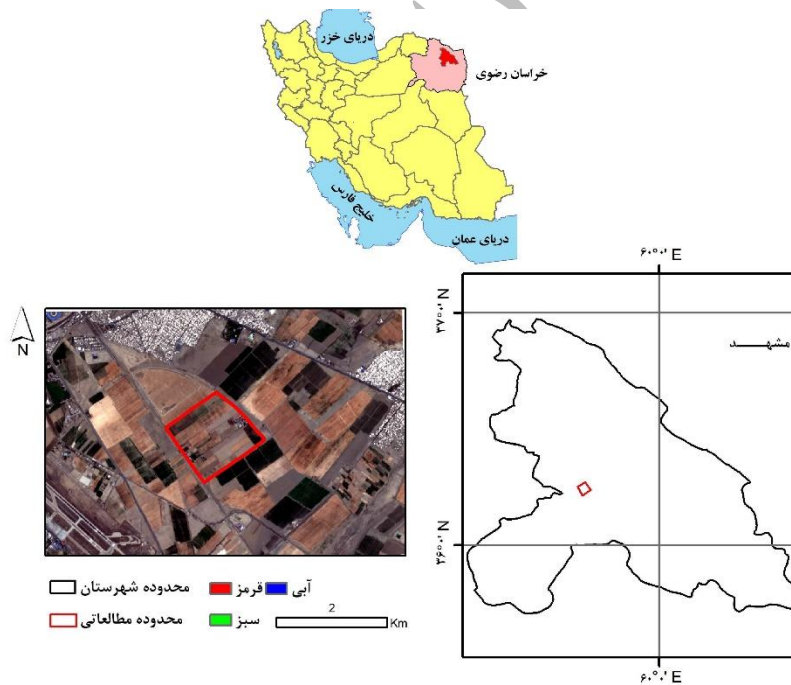
Niraimathi and Saravanan (2025) در هند با استفاده از پارامترهای دو قطبی سنتینل-۱ و الگوریتم RF نشان دادند که می‌توان مراحل فنولوژیک شالیزارها را با دقت بالایی پایش کرد. یافته‌های آن‌ها نشان داده روش‌های مبتنی بر تجزیه قطبی راداری و ترکیب آن‌ها با یادگیری ماشین را در پایش دقیق شالیزار، تفکیک آن با سایر پوشش‌های گیاهی و مدیریت بهینه منابع کشاورزی برجسته کرده است. به‌طور مشابه، Fikriyah et al (2025) در فیلیپین توانستند تفاوت بین برنج اصلی و راتون را در مراحل فنولوژیک حساس با استفاده چهار ویژگی مبتنی بر قطبش (VH و VV، نسبت VH/VV و RVI) مبتنی بر سری زمانی سنتینل-۱ و روش PLS-DA آشکار کنند. یافته‌های آن‌ها داد که استفاده از داده‌های سری زمانی سنتینل-۱ می‌تواند به تعیین بهترین دوره‌ها و ویژگی‌های SAR برای تفکیک برنج اصلی و راتون کمک کند و کاربرد بالقوه‌ای در نقشه‌برداری و برآورد تولید برنج مبتنی بر سنجنش‌ازدور داشته باشد.

همان‌گونه که در مطالعات پیشین اشاره شده است، تاکنون در ایران پژوهش‌های معدودی در زمینه بهره‌گیری از داده‌های راداری برای تفکیک و شناسایی محصولات زراعی انجام شده و بر اساس جست‌وجوهای صورت‌گرفته، مطالعه مشابهی یافت نشده است؛ از این‌رو،

هدف اصلی این پژوهش، استخراج و به کارگیری شاخص‌های نوین گیاهی و زراعی مبتنی بر داده‌های راداری سری زمانی سنتینل-۱ شامل نسبت‌های روش نرمال‌سازی بین‌باندی<sup>۱</sup> (NRPB)، فاصله قطری دوقطبی<sup>۲</sup> (DPDD)، فاصله قطری معکوس دوقطبی<sup>۳</sup> (IDPDD) و شاخص دوقطبی زدایی عمودی<sup>۴</sup> (VDDPI) و ترکیب آن‌ها به منظور تولید نقشه‌ای دقیق و جامع از محصولات زراعی در جنوب شرق شهرستان مشهد است. در این راستا، با اتخاذ رویکردی نوین و بهره‌گیری کامل از داده‌های راداری، تلاش شده است روشی ارائه شود که دقت بالاتری در شناسایی و تفکیک محصولات زراعی فراهم آورد و بتواند گامی مؤثر در توسعه فناوری‌های نوین نقشه‌برداری زراعی و ارتقاء مدیریت پایدار کشاورزی باشد.

## مواد و روش منطقه مورد مطالعه

منطقه مورد مطالعه در حومه شهر مشهد، در شمال شرق ایران واقع شده و در موقعیت جغرافیایی با طول ۵۹ درجه و ۴۰ دقیقه شرقی و عرض ۳۶ درجه و ۱۴ دقیقه شمالی قرار دارد. این محدوده که مساحتی در حدود ۱/۷۰ کیلومترمربع را در بر می‌گیرد (شکل ۱)، دارای پوشش زراعی متنوعی شامل گندم، جو، یونجه، زیره و نخود است. دلیل اصلی انتخاب این منطقه، تنوع بالای محصولات کشاورزی و فراهم بودن داده‌های میدانی معتبر بوده است.



شکل ۱. موقعیت جغرافیایی منطقه کشاورزی مورد مطالعه

در جدول ۱، زمان‌بندی کاشت هر یک از محصولات کشاورزی، بر اساس نقشه منطقه مورد مطالعه، ارائه شده است.

<sup>1</sup> Normalized Ratio Procedure between Bands

<sup>2</sup> Dual-Pol Diagonal Distance

<sup>3</sup> Inverse DualPol Diagonal Distance

<sup>4</sup> Vertical Dual DePolarization Index

جدول ۱. زمان کاشت محصولات

شماره	نوع محصول	تاریخ کاشت
۱	نخود (رقم هاشم)	اسفند ۱۴۰۰
۲	گندم پیشگام	پاییز ۱۴۰۰
۳	نخود پاییزه	پاییز ۱۴۰۰
۴	گیاه زیره	پاییز ۱۴۰۰
۵	جو	پاییز ۱۴۰۰
۶	یونجه	۱۳۹۹-۱۴۰۱

### معرفی، پیش‌پردازش و آماده‌سازی تصاویر سنتینل-۱

تصاویر سنتینل-۱ بخشی از مأموریت راداری برنامه کوپرنیک آژانس فضایی اروپا هستند که از سال ۲۰۱۴ با پرتاب ماهواره‌های A ۱ و B آغاز شد. این تصاویر با رادار SAR در باند C تهیه می‌شوند و قابلیت تصویربرداری در شب و روز و تحت هر شرایط آب‌وهوایی، حتی پوشش ابر و بارش را دارند. داده‌های سنتینل-۱ در مدهای مختلفی مانند IW، EW و SM ارائه می‌شوند که از میان آن‌ها مد IW مرتبط با محصولات GRD بیشترین کاربرد را دارد. وضوح واقعی این مد حدود ۵ متر در جهت برد و ۲۰ متر در جهت آزیموت است، اما پس از بازنمونه‌گیری، پیکسل‌ها با اندازه  $10 \times 10$  متر ارائه می‌شوند (European Space Agency [ESA]).

در این پژوهش، از میانگین شش ماهه سری زمانی مجموعه تصاویر متعلق به سنجنده راداری سنتینل-۱ با قطبش‌های VV و VH، طی بازه زمستان ۱۴۰۰ تا بهار ۱۴۰۱ (ژانویه تا ژوئن)، در محیط سامانه تحت وب گوگل ارث انجین، هم‌زمان با فصل کاشت و رشد گیاهان، بهره گرفته شده است. از آنجاکه تصاویر یادشده در این سامانه از تصحیحات هندسی و رادیومتریکی کامل برخوردارند، تنها برای کاهش نویز اسپیکل<sup>۵</sup> از فیلتر لی<sup>۶</sup> استفاده شده است (Lee et al., 1999 و همکاران). همچنین، به منظور حفظ وضوح و جلوگیری از کاهش جزئیات، اندازه فیلتر در ابعاد  $3 \times 3$  پیکسل در نظر گرفته شده است. در جدول ۲ مشخصات داده‌های مورد استفاده آورده شده است با این توضیح که در این مطالعه تنها به قطبش‌های VV و VH دسترسی وجود داشت و حالت‌های HH و HV در داده‌ها موجود نبودند؛ بنابراین جدول حاضر صرفاً شامل VV و VH است که ترکیب آن‌ها نیز اطلاعات مفیدی از ساختار پوشش گیاهی، سطح خاک و رطوبت فراهم می‌کند.

جدول ۲. مشخصات داده‌های مورد استفاده

ماهواره / سنجنده	بازه زمانی	باند	قطبش	تفکیک مکانی (متر)
Sentinel-1 SAR	۱۴۰۰-۱۴۰۱	C	فرستنده: عمودی، گیرنده: عمودی → VV فرستنده: عمودی، گیرنده: افقی → VH فرستنده: افقی، گیرنده: افقی → HH	$10 \times 10$

<sup>5</sup> Speckle noise

<sup>6</sup> Lee

		فرستنده: افقی، گیرنده: عمودی → HV	
		در مناطق غیر قطبی) VV + VH	
		(بیشتر در مناطق قطبی) HH + HV	

## محاسبه شاخص‌های راداری

در این منبع، شاخص پوشش گیاهی راداری بر اساس داده‌های دو قطبی<sup>7</sup> (SVIDP) که توسط Periasamy (2018) معرفی شده است، از باندهای دو قطبی VV و VH مشتق شده و شامل نسبت‌های روش نرمال‌سازی بین باندهای (NRPB)، فاصله قطری دو قطبی (DPDD)، فاصله قطری معکوس دو قطبی (IDPDD) و شاخص زدایی عمودی (VDDPI) است. این شاخص‌ها برای تفکیک مرزهای درون گیاهی در میان پیکسل‌های زراعی و کاهش هم‌پوشانی بین نمونه‌های آموزشی در داده‌های SAR سنجنده سنتینل-1 به کار گرفته شده است (Mishra et al., 2023).

### ۱. NRPB

این شاخص میزان تفاوت بین قطبش VV و VH را نرمال‌سازی کرده و می‌تواند برای تفکیک پوشش‌های گیاهی مختلف استفاده شود (رابطه ۱). شاخص NRPB با افزودن تعداد بیشتری از متغیرهای کمکی، دقت پیش‌بینی تغییرات پوشش گیاهی را در داده‌های SAR افزایش می‌دهد (Filgueiras et al., 2019).

رابطه (۱)

$$NRPB_{ij} = \frac{\sigma^0 v h_{ij} - \sigma^0 v v_{ij}}{\sigma^0 v h_{ij} + \sigma^0 v v_{ij}}$$

### ۲. DPDD

این شاخص از مجموع مقادیر بازپخش دو قطبش VV و VH استفاده کرده و میزان پراکنش را در یک منطقه مشخص بررسی می‌کند (رابطه ۲). در این محاسبه، مخرج برابر با  $\sqrt{2}$  در نظر گرفته شد تا فاصله‌ی قطری مطابق با مثلث  $45^\circ-45^\circ-90^\circ$  بر اساس قضیه فیثاغورس اندازه‌گیری شود (Periasamy, 2018).

رابطه (۲)

$$DPDD_{ij} = \frac{(\sigma^0 v h_{ij} + \sigma^0 v v_{ij})}{\sqrt{2}}$$

### ۳. IDPDD

<sup>7</sup> SAR Vegetation Index based on Dual Polarization

این شاخص با استفاده از حداکثر مقدار قطبش  $VV$ ، شدت پراکنش را نسبت به مقدار ماکزیمم تعیین می‌کند (Periasamy, 2018). در رابطه (۳) نحوه محاسبه شاخص IDPDD آورده شده است:

رابطه (۳)

$$IDPDD_{ij} = \frac{(\sigma^0 v_{V(Max)} + \sigma^0 v_{ij}) + \sigma^0 v_{h_{ij}}}{\sqrt{2}}$$

#### ۴. VDDPI

این شاخص همان‌طور که در رابطه (۴) نشان داده شده است برای شناسایی تراکم پوشش گیاهی بر اساس نسبت بازپخش قطبش  $VH$  و  $VV$  به کار می‌رود (Periasamy, 2018).

رابطه (۴)

$$VDDPI_{ij} = \frac{(\sigma^0 v_{h_{ij}} + \sigma^0 v_{ij})}{\sigma^0 v_{ij}}$$

#### روش‌شناسی پردازش و طبقه‌بندی محصولات زراعی با بهره‌گیری از داده‌های راداری ماهواره سنتینل-۱

پس از فراخوانی مجموعه تصاویر راداری سنتینل-۱ در سامانه GEE و محاسبه هر کدام از شاخص‌ها، سری‌های زمانی میانگین ماهانه هر یک از شاخص‌های راداری شامل  $IDPDD$ ،  $VDDPI$ ،  $DPDD$ ،  $NRPB$  و همچنین ترکیب قطبش‌های  $VH$  و  $VV$  برای ماه‌های ژانویه تا ژوئن استخراج شد و در ادامه تمامی این داده‌ها در یک دیتاست واحد، سازمان‌دهی شدند.

پس از آماده‌سازی داده‌های راداری، نمونه‌های آموزشی برای هر یک از کلاس‌های موردنظر استخراج گردید. این نمونه‌ها بر اساس داده‌های میدانی و با استفاده از مختصات هر قطعه زمین برداشت شدند تا با دقت بالا به الگوریتم‌های طبقه‌بندی معرفی شوند (جدول ۳).

جدول ۳. تعداد نمونه‌های آموزشی برای هر کلاس

شماره	نوع محصول	تعداد نمونه‌های تعلیمی
۱	نخود (رقم هاشم)	۴۰
۲	گندم پیشگام	۳۵
۳	نخود پاییزه	۲۰
۴	گیاه زیره	۲۰
۵	جو	۳۵
۶	یونجه	۲۰
۷	غیر کشت شده	۵۰

در ادامه، با استفاده از سه الگوریتم ماشین بردار پشتیبان<sup>۸</sup> (SVM)، جنگل تصادفی<sup>۹</sup> (RF) و درخت تقویت گرادیان<sup>۱۰</sup> (XGBoost)، پیاده‌سازی شده در سامانه گوگل ارث انجین، محصولات زراعی بر اساس ترکیب سری زمانی ۶ ماهه شاخص‌های راداری و قطبش‌های VV-VH طبقه‌بندی شدند. در ادامه هر یک از الگوریتم‌های طبقه‌بندی به صورت مختصر توضیح داده می‌شوند.

### ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM) یک الگوریتم یادگیری نظارت‌شده است که هم در مسائل طبقه‌بندی و هم در رگرسیون کاربرد دارد (Burgess, 1998). در این الگوریتم، داده‌ها به صورت نقاطی در یک فضای  $n$ -بعدی نمایش داده می‌شوند، به طوری که هر ویژگی داده یک مؤلفه از مختصات نقطه را مشخص می‌کند. هدف SVM یافتن یک ابر صفحه است که بتواند دسته‌های مختلف داده را از هم جدا کند. این الگوریتم به عنوان یک طبقه‌بند دودویی شناخته می‌شود و نخستین بار توسط Cortes and Vapnik (1995) معرفی شد. ماشین بردار پشتیبان از میان ابر صفحه‌های ممکن، صفحه‌ای را انتخاب می‌کند که بیشترین فاصله را از نزدیک‌ترین نقاط داده داشته باشد تا دقت جداسازی افزایش یابد. در شرایطی که داده‌ها به صورت خطی قابل جداسازی نباشند، دو رویکرد به کار گرفته می‌شود: «حاشیه نرم» که اجازه خطاهای جزئی در طبقه‌بندی را فراهم می‌کند تا مدل توانایی پیش‌بینی بهتری داشته باشد و «تابع کرنل» که با افزودن ابعاد جدید، داده‌های غیرخطی را به گونه‌ای تبدیل می‌کند که به صورت خطی قابل جداسازی شوند. به این ترتیب، روش SVM آماری و غیر پارامتریک محسوب می‌شود که انعطاف‌پذیری بالایی در مواجهه با داده‌های پیچیده دارد.

### جنگل تصادفی

جنگل تصادفی یک روش یادگیری ترکیبی و نظارت‌شده در یادگیری ماشین است که هم برای طبقه‌بندی و هم برای رگرسیون به کار می‌رود. اساس این الگوریتم بر ایجاد مجموعه‌ای از درختان تصمیم است که هر کدام به طور مستقل روی زیرمجموعه‌ای از داده‌ها آموزش داده می‌شوند و خروجی نهایی بر پایه رأی‌گیری اکثریت (در مسائل طبقه‌بندی) یا میانگین‌گیری (در مسائل رگرسیون) تعیین می‌شود. این الگوریتم نخست برای غلبه بر مشکل بیش‌برازش در درختان تصمیم معرفی شد و معمولاً عملکرد بهتری نسبت به یک درخت منفرد دارد، هر چند میزان این بهبود به ویژگی‌های داده وابسته است (Piryonesi and El-Diraby, 2020). جنگل تصادفی در دسته روش‌های نا پارامتریک قرار می‌گیرد و می‌تواند بدون نیاز به کاهش متغیرها، روابط و همبستگی‌ها را در داده‌ها آشکار سازد. این ویژگی موجب شده تا طی دو دهه اخیر به طور گسترده در داده‌کاوی، کشف الگوها و ساخت مدل‌های پیش‌بینی مورد استفاده قرار گیرد. سازوکار آن شامل انتخاب تصادفی نمونه‌ها از داده‌های آموزشی، ساخت درختان تصمیم برای هر زیرمجموعه و تکرار این فرآیند برای تعداد مشخصی از درختان است. سپس در مرحله پیش‌بینی، خروجی هر درخت محاسبه شده و بر اساس اکثریت آرا یا میانگین نتایج، دسته‌بندی یا پیش‌بینی نهایی انجام می‌شود. افزایش تعداد درختان معمولاً باعث افزایش دقت مدل شده و احتمال بیش‌برازش را کاهش می‌دهد.

### درخت تقویت گرادیان

الگوریتم تقویت گرادیان یکی از روش‌های قدرتمند یادگیری گروهی در یادگیری ماشین است که برای مسائل طبقه‌بندی و رگرسیون به کار می‌رود. این الگوریتم بر پایه ترکیب خطی مجموعه‌ای از مدل‌های ضعیف به صورت متوالی بنا شده و هدف آن ایجاد یک مدل

<sup>8</sup> Support vector machines

<sup>9</sup> Random Forest

<sup>10</sup> Gradient boosting

نهایی قوی تر است (Friedman, 2001 و Piryonesi and El-Diraby, 2020). در تقویت گرادیان، چندین کلاسه‌بند یا پیش‌بین ضعیف - معمولاً درخت تصمیم به‌طور پی‌درپی روی نسخه‌های اصلاح‌شده داده‌ها آموزش داده می‌شوند. هر مدل جدید خطاهای مدل قبلی را در نظر گرفته و تلاش می‌کند با استفاده از گرادیان نزولی، مقدار تابع ضرر را به حداقل برساند. به این ترتیب، خروجی مجموعه‌ای از مدل‌های ضعیف ترکیب می‌شود تا یک مدل جمعی با قدرت پیش‌بینی بالاتر شکل گیرد. کلاسه‌بند ضعیف در این روش مدلی است که تنها اندکی بهتر از یک حدس تصادفی عمل می‌کند، اما ترکیب آن‌ها موجب بهبود چشمگیر عملکرد می‌شود (Piryonesi and El-Diraby, 2020 and Hastie et al., 2009). ساختار کلی این الگوریتم شامل سه جزء اصلی است: یک تابع ضرر برای بهینه‌سازی، یک یادگیرنده ضعیف برای پیش‌بینی و یک مدل جمعی برای افزودن تدریجی یادگیرندگان جدید جهت کاهش خطا. به دلیل ماهیت ترتیبی این فرآیند، هر درخت تصمیم جدید بر اساس خطاهای درخت قبلی ساخته می‌شود و بدین ترتیب دقت مدل نهایی به‌طور مستمر افزایش می‌یابد.

پس از انجام طبقه‌بندی با هر یک از الگوریتم‌های یادگیری ماشین یادشده، نتایج به کمک مجموعه داده‌های میدانی ارزیابی شد. در این ارزیابی، از ماتریس خطا و معیارهای دقت کلی<sup>۱۱</sup> (OA)، ضریب کاپا<sup>۱۲</sup> (KC)، دقت کاربر<sup>۱۳</sup> (UA) و دقت تولیدکننده<sup>۱۴</sup> (PA) استفاده گردید (Jansen, 2015) تا عملکرد مدل‌های طبقه‌بندی موردسنجش قرار گیرد (جدول ۴). در ادامه توضیح هر کدام از این معیارها آورده شده است:

**ضریب کاپا:** ضریب کاپا میزان دقت را برعکس روش دقت کلی بر اساس تمامی پیکسل‌هایی که درست و غلط طبقه‌بندی شده‌اند، محاسبه می‌نماید. این فاکتور از اعتبار بالاتری در مقایسه با دقت کلی برای ارزیابی دقت نقشه طبقه‌بندی برخوردار است.

**دقت کلی:** این فاکتور دقت را بر اساس تعداد پیکسل‌هایی که به‌درستی طبقه‌بندی شده‌اند، محاسبه می‌کند. به عبارت دیگر تعداد پیکسل‌هایی که برای هریک از کلاس‌های مذکور به‌درستی طبقه‌بندی شده‌اند به‌تمامی تعداد پیکسل‌های چک شده تقسیم می‌شوند. **دقت کاربر:** عبارت است از احتمال قطعیت درست طبقه‌بندی شدن یک پیکسل.

**دقت تولیدکننده:** عبارت است از احتمال آنکه یک نمونه برداشت‌شده بر روی تصویر مرتبط با آن کلاس خاص است.

جدول ۴. پارامترهای ارزیابی دقت

معیارها	فرمول	منبع
ضریب کاپا	$KC = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})}$	
دقت کلی	$OA = \frac{1}{N} \sum P_{ii}$	(Jansen, 2015)
دقت کاربر	$UA = \frac{x_{ii}}{x_{+i}}$	
دقت تولیدکننده	$PA = \frac{x_{jj}}{x_{+j}}$	

<sup>11</sup> Overall Accuracy

<sup>12</sup> Kappa Coefficient

<sup>13</sup> User's Accuracy


<sup>14</sup> Producer's Accuracy

در مرحله بعد، چرخه فنولوژیکی هر یک از محصولات کشاورزی منطقه مورد مطالعه طی ماه‌های ژوئن تا ژانویه، بر اساس میانگین سری زمانی ماهانه قطبش‌های VV و VH و همچنین شاخص‌های راداری استخراج‌شده از تصاویر سنتینل-۱، مورد تحلیل قرار گرفته است. در این راستا، نواحی مشخصی از اراضی زراعی شامل یونجه، جو، نخود، گندم، زیره و نخود پاییزه به‌عنوان نمونه انتخاب شدند. سپس روند تغییرات زمانی هر یک از قطبش‌ها و شاخص‌ها در بازه‌ی مورد نظر ارزیابی شده و الگوهای فنولوژیکی محصولات زراعی از طریق نمودارهای سری زمانی تحلیل و مقایسه شدند.


## نتایج و بحث

نتایج نشان داد تصاویر راداری سنتینل-۱، به‌ویژه در ترکیب با شاخص‌های گیاهی راداری، توان بالایی در شناسایی و طبقه‌بندی محصولات زراعی دارند. برای این منظور از سه الگوریتم یادگیری ماشین شامل XGBoost، جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM) استفاده شد. طبقه‌بندی در قالب هفت کلاس زراعی (یونجه، جو، نخود، زیره، نخود پاییزه، گندم و اراضی غیر کشت‌شده) انجام گرفت. نقشه‌های حاصل (شکل‌های ۲، ۳ و ۴) نشان می‌دهند که XGBoost و RF دقت بالاتری در تفکیک کلاس‌ها نسبت به SVM دارند.


الگوریتم SVM تنها در شناسایی اراضی غیر کشت‌شده عملکرد قابل قبول داشت و در تفکیک محصولات با پوشش گیاهی مشابه ضعیف‌تر بود. در مقابل، XGBoost و RF توانستند تمامی کلاس‌های زراعی را با دقت مناسب استخراج کنند. این امر نشان می‌دهد که استفاده از الگوریتم‌های یادگیری ماشین RF و XGBoost برای طبقه‌بندی داده‌های راداری نسبت به SVM مناسب‌تر است.



شکل ۲. نتیجه طبقه‌بندی کننده XGBoost در منطقه مطالعاتی



شکل ۳. نتیجه طبقه‌بندی کننده RF در منطقه مطالعاتی



شکل ۴. نتیجه طبقه‌بندی کننده SVM در منطقه مطالعاتی

بر اساس نتایج کمی (جدول ۵، ۶ و ۷)، الگوریتم XGBoost با دقت کلی ۸۳/۴۸٪ و ضریب کاپا ۰/۷۸ بهترین عملکرد را داشت. الگوریتم RF نیز با دقت کلی ۸۲/۲۷٪ و ضریب کاپا مشابه، عملکردی نزدیک به XGBoost نشان داد. در مقابل، SVM تنها به دقت کلی ۶۱/۴۶٪ و ضریب کاپا ۰/۵۱ رسید. هرچند اختلاف میان XGBoost و RF اندک بود، اما هر دو الگوریتم برای طبقه‌بندی داده‌های راداری قابل اعتماد هستند. به‌طور خاص، در برخی کلاس‌ها RF دقت کاربر بیشتری نسبت به XGBoost داشت (یونجه ۸۸/۸۹٪، نخود ۸۲/۳۵٪ و نخود پاییزه ۶۳/۶۴٪). در مقابل دقت کاربر و دقت تولیدکننده SVM در تمامی کلاس‌ها پایین بود اما تنها دقت کاربر کلاس گندم برابر با ۱۰۰٪ تخمین شد. نتایج نشان می‌دهد که کلاس نخود پاییزه پایین‌ترین دقت تولیدکننده را در طبقه‌بندی SVM داشته است اما الگوریتم‌های XGBoost و RF به ترتیب با دقت تولیدکننده ۶۱/۷۶٪ و ۶۰/۰۰٪ عملکرد بهتری نسبت به SVM داشته‌اند. در نتایج طبقه‌بندی SVM تداخل زیادی در کلاس‌های زیره و مناطق غیر کشت‌شده و همچنین همپوشانی زیادی در سایر کلاس‌ها مشاهده شد، چراکه این الگوریتم یادگیری ماشین صرفاً یک تمیزدهنده مناسب بین خاک و آب است و به‌طور کلی عملکرد نامطلوبی در شناسایی و تفکیک پوشش گیاهی مانند محصولات زراعی دارد؛ بنابراین، درحالی‌که RF و XGBoost هر دو عملکرد مطلوبی در طبقه‌بندی محصولات کشاورزی از تصاویر SAR دارند، برتری نسبی XGBoost در شاخص‌های کلی دقت نشان می‌دهد که این الگوریتم می‌تواند گزینه‌ای مطمئن‌تر و کارآمدتر برای کاربردهای عملی در پایش کشاورزی باشد.

جدول ۵. ماتریس ابهام طبقه‌بندی کننده XGBoost - یادگیری ماشین

XGBOOST									
دقت کاربر	دقت تولید کننده	خاک	گندم	زیره	نخود پاییزه	نخود	جو	یونجه	کلاس طبقاتی
۸۲.۱۴	۸۵.۱۹	۴	۰	۰	۰	۱	۰	۲۳	یونجه
۹۷.۵۶	۸۶.۰۲	۰	۰	۲	۰	۰	۸۰	۰	جو
۸۰.۷۷	۷۳.۶۸	۱	۰	۱	۰	۴۲	۸	۰	نخود
۶۱.۷۶	۶۱.۷۶	۲	۰	۳	۲۱	۷	۱	۰	نخود پاییزه
۸۹.۱۳	۷۷.۳۶	۳	۰	۴۱	۱	۰	۰	۱	زیره
۱۰۰	۸۷.۷۲	۰	۵۰	۰	۰	۰	۰	۰	گندم
۷۵.۰۰	۹۲.۱۳	۱۱۷	۷	۶	۱۲	۷	۴	۳	خاک
۰.۷۸									ضریب کاپا
۸۳.۴۸									دقت کلی

جدول ۶. ماتریس ابهام طبقه‌بندی کننده RF- یادگیری ماشین

RF									
دقت کاربر	دقت تولید کننده	خاک	گندم	زیره	نخود پاییزه	نخود	جو	یونجه	کلاس طبقاتی
۸۸.۸۹	۸۸.۸۹	۳	۰	۰	۰	۰	۰	۲۴	یونجه
۹۷.۵۶	۸۶.۰۲	۰	۰	۱	۱	۰	۸۰	۰	جو
۸۲.۳۵	۷۳.۶۸	۰	۰	۲	۰	۴۲	۷	۰	نخود
۶۳.۶۴	۶۰.۰۰	۴	۲	۱	۲۱	۴	۱	۰	نخود پاییزه
۸۳.۶۷	۷۷.۳۶	۶	۰	۴۱	۱	۱	۰	۰	زیره
۹۵.۴۵	۸۷.۵۰	۲	۴۲	۰	۰	۰	۰	۰	گندم
۷۲.۷۳	۸۸.۱۹	۱۱۲	۴	۸	۱۲	۱۰	۵	۳	خاک
۰.۷۸									ضریب کاپا
۸۲.۲۷									دقت کلی



جدول ۷. ماتریس ابهام طبقه‌بندی کننده SVM- یادگیری ماشین

SVM									
دقت کاربر	دقت تولید کننده	خاک	گندم	زیره	نخود پاییزه	نخود	جو	یونجه	کلاس طبقاتی
۵۳.۸۵	۵۱.۸۵	۳	۰	۰	۱	۲	۶	۱۴	یونجه
۷۰.۰۰	۶۷.۷۴	۸	۰	۲	۱	۱۱	۶۳	۰	جو
۴۷.۰۶	۴۲.۱۱	۳	۰	۸	۰	۲۴	۱۱	۰	نخود
۴۴.۴۴	۱۱.۴۳	۴	۱	۳	۴	۰	۰	۰	نخود پاییزه
۶۲.۵۰	۳۷.۷۴	۷	۰	۲۰	۰	۳	۲	۱	زیره
۱۰۰	۸۶.۴۴	۰	۵۱	۰	۰	۰	۰	۰	گندم
۵۲.۶۳	۸۰.۰۰	۱۰۰	۷	۲۳	۲۴	۱۷	۱۱	۸	خاک

۰.۵۱	ضریب کاپا
۶۱.۴۶	دقت کلی

میانگین زمانی قطبش‌های VV و VH در شکل ۵ نشان داده شده است. از نظر زمانی (۲۲ ژانویه تا ۲۲ ژوئن) مشخصات طیفی محصولات زراعی در قطبش VH بیانگر آن است که در بازه زمانی بررسی شده، روندی نسبتاً صعودی را برای اغلب محصولات نشان می‌دهد. بر این اساس، جو در ماه می بیشترین افزایش را در قطبش VH تجربه کرده است، به طوری که مقدار بازتابندگی آن از ۲۳- دسی‌بل در آوریل به ۱۶- دسی‌بل در می رسیده است؛ این تغییر معادل بهبود ۱۶ دسی‌بل است که نشان‌دهنده‌ی افزایش چشمگیر نوسانات این قطبش در این ماه است. یونجه، گندم و زیره نیز در بازه مارس تا می روندی صعودی داشته‌اند، گرچه شدت تغییرات به اندازه جو نبوده است. نخود پاییزه پایین‌ترین مقادیر VH را در ماه‌های ژانویه و فوریه بترتیب با مقادیر بازتابندگی ۲۴- و ۲۶- داشته که بیانگر پایداری VH بیشتر در این ماه‌ها می‌باشد. در ماه ژوئن، اکثر محصولات کاهش نسبی در قطبش VH با مقدار ۲۳- داشته‌اند که نشان‌دهنده بازگشت به شرایط پایداری و سبزی‌نگی باشد.

مشخصات طیفی قطبش VV که نوسانات عمودی را نمایش می‌دهد، رفتار پویاتری از خود نشان داده است، بطوریکه جو در ماه می دارای بالاترین مقدار VV (حدود ۹.۵-) است که نشان می‌دهد نوسانات عمودی این محصول در این ماه بسیار افزایش یافته است. این می‌تواند ناشی از شرایط آب و هوایی خاص، رشد سریع یا مشکلاتی در تثبیت ریشه باشد. گندم و زیره نیز در ماه می افزایش مشخصی در VV داشته‌اند. در مقابل، نخود تغییرات محدودی در این قطبش نشان داده است که ممکن است به دلیل ساختار رشد آهسته‌تر یا ویژگی‌های خاص فیزیولوژیکی آن باشد. افت شدید VV برای جو در آوریل نیز قابل توجه است و ممکن است به پدیده‌هایی مانند خوابیدگی گیاه یا آسیب‌های محیطی بازگردد. به‌طور کلی هر دو قطبش VH و VV در ماه می برای بیشتر محصولات افزایش یافته‌اند که این موضوع در این منطقه عمدتاً ناشی از بارش‌های بهاره و ورود محصولات به مراحل رشد رویشی - زایشی (افزایش بیوماس و رطوبت گیاهی) است و بیانگر تغییرات فیزیولوژیکی و ساختاری گیاهان در این دوره است. در نقطه مقابل، ماه‌های ژانویه و فوریه کمترین نوسانات را ثبت کرده‌اند که نشان‌دهنده ثبات محیطی یا آغاز فصل رشد است؛ بنابراین، تحلیل تفاوت‌های رفتاری محصولات مختلف در قطبش‌های VH و VV نه تنها می‌تواند مبنای مناسبی برای مدیریت مزرعه باشد، بلکه در سطحی گسترده‌تر قابلیت آن را دارد که به‌عنوان شاخصی برای پایش سلامت گیاه، پیش‌بینی عملکرد و انتخاب گونه‌های مقاوم‌تر در برابر نوسانات اقلیمی به کار رود؛ موضوعی که به‌ویژه در مناطق نیمه‌خشک مانند مشهد که با تغییرپذیری بالای شرایط محیطی مواجه است، از اهمیت عملی و راهبردی بالایی برخوردار است.



شکل ۵. مقایسه میانگین توزیع زمانی قطبش‌ها برای هر محصول زراعی

شکل ۶، نتایج عملکرد زمانی شاخص‌های مورد استفاده برای محصولات زراعی را نشان می‌دهد. نتایج شاخص DPDD بیانگر آن است که این شاخص برای همه محصولات در بازه زمانی ژانویه تا مارس مقادیر منفی (از ۱۶- تا ۳۰-) داشته و در ماه‌های بعد (به‌ویژه می) روند افزایشی داشته است. بیشترین مقدار DPDD در ماه می با ۱۶- مربوط به محصول جو بوده که نشان‌دهنده بازتاب نسبتاً بیشتر از حد انتظار در آن دوره است. این تغییر در واقع بیانگر افزایش سطح پراکنش امواج راداری به دلیل تراکم بیشتر پوشش گیاهی و تغییرات ساختاری در مزرعه است که شاخص DPDD در این ماه به‌خوبی آن را آشکار کرده است.

شاخص IDPDD به دلیل اینکه محصولات زراعی بیشترین تفاوت را در قطبش‌های VV و VH دارند و همچنین حساس هستند امکان مقایسه دقیق‌تری بین محصولات زراعی مختلف را فراهم می‌کند. این شاخص نیز برای جو و یونجه روندی صعودی داشت که بیانگر افزایش تدریجی اختلاف بازتاب واقعی از مقدار پتانسیل است. در ماه ژوئن کاهش ناگهانی در اکثر محصولات دیده می‌شود که

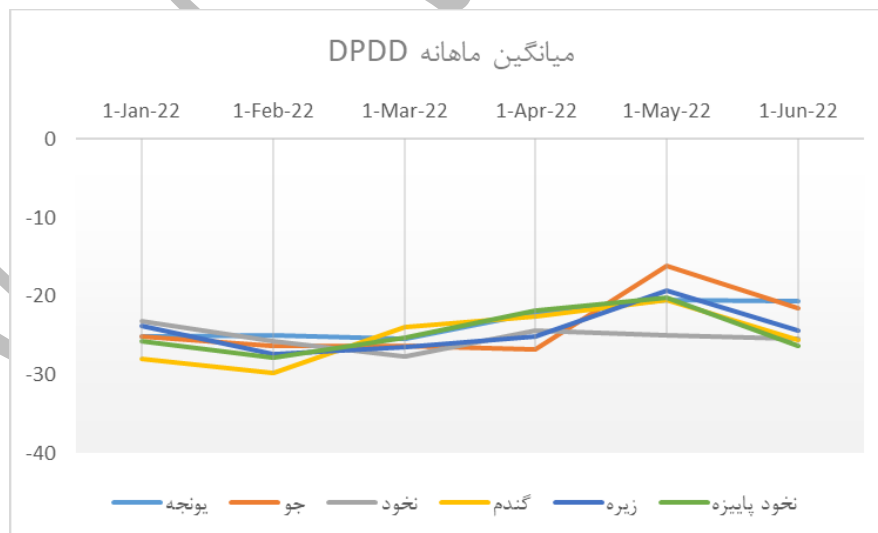
با توجه به زمان برداشت محصولات در منطقه (اواخر خرداد تا اوایل تیر) می‌تواند ناشی از برداشت محصول و کاهش پوشش گیاهی باشد.


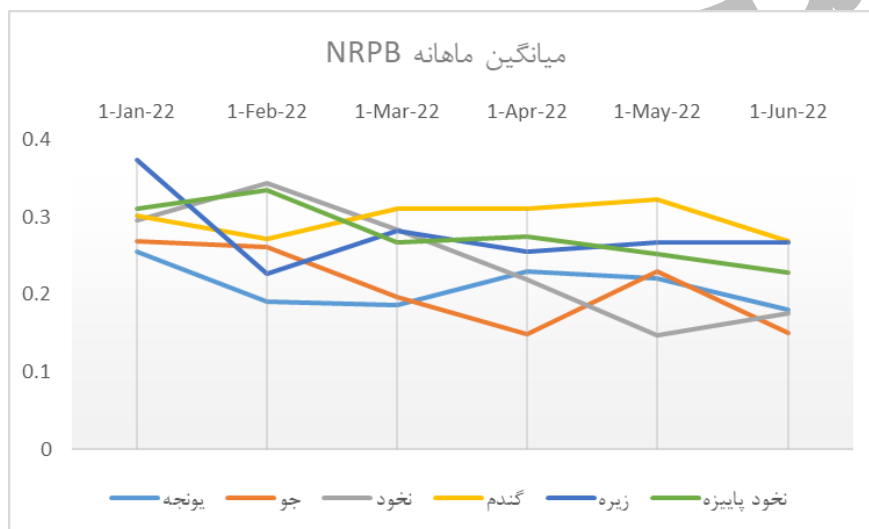

شاخص NRPB نوسانات کمی داشت و بیشتر در بازه ۰/۲ تا ۰/۳۵ باقی‌مانده است که نشان‌دهنده پایداری نسبی باز پراکنش در این بازه زمانی است. محصول زیره در ژانویه مقدار بالاتری داشته و در ادامه کاهش داشته که بیانگر ورود به فاز رشد یا پوشش گیاهی متراکم‌تر در آن زمان می‌باشد.

شاخص VDDPI برای بررسی پویایی زمانی در تغییرات باز پراکنش طراحی شده است. بیشترین مقدار این شاخص مربوط به یونجه در ژانویه (حدود ۳/۲) بوده که در ادامه کاهش یافته و از فوریه به بعد در مقدار تقریباً ثابت حدود ۲/۶ به حالت تعادل رسیده است. محصولات جو و نخود نوسانات بیشتری در این شاخص داشتند که احتمالاً به حساسیت بالاتر آن‌ها به شرایط محیطی مربوط است.

به‌طور کلی شاخص‌های DPDD و IDPDD روند رشد و تنش پوشش گیاهی را به‌خوبی در رادار نشان می‌دهند و نوسانات آن‌ها می‌تواند برای شناسایی دوره‌های اوج رشد یا فشار محیطی مفید باشد. شاخص NRPB به‌عنوان شاخصی پایدار عمل کرده است و می‌تواند برای تعیین مراحل مختلف رشد محصولات کاربردی باشد. شاخص VDDPI اطلاعات ارزشمندی درباره پویایی پوشش گیاهی ارائه می‌دهد و برای محصولات ناپایدار یا حساس (مانند نخود و جو) بینش دقیقی فراهم می‌آورد.

نتایج نشان داد شاخص‌های راداری می‌توانند ابزار مؤثری برای پایش رشد، زمان‌بندی برداشت و تشخیص استرس‌های محیطی محصولات باشند. پیشنهاد می‌شود در پژوهش‌های آینده این شاخص‌ها با داده‌های زمینی و در شرایط اقلیمی متنوع‌تر اعتبارسنجی شوند تا کاربرد عملی آن‌ها در مدیریت کشاورزی تقویت گردد.





شکل ۶. مقایسه میانگین توزیع زمانی شاخص‌های دو قطبی برای هر محصول زراعی

در این مطالعه، استفاده از داده‌های سنتینل-۱ در کنار شاخص‌های گیاهی استخراج‌شده از داده‌های راداری منجر به بهبود دقت الگوریتم‌های RF و XGBoost پیاده شده در پلتفرم گوگل ارث انجین به‌منظور تهیه نقشه‌های محصولات زراعی شد، درحالی‌که عملکرد الگوریتم SVM کاهش یافت. به‌طورکلی، با توجه به نتایج این پژوهش می‌توان نتیجه گرفت که کلاس‌های گندم و جو در اغلب الگوریتم‌ها با دقت بالاتری نسبت به سایر محصولات تفکیک‌شده‌اند؛ به‌طوری‌که دقت کاربر کلاس گندم در الگوریتم‌های XGBoost و SVM برابر با ۱۰۰٪ و در الگوریتم RF حدود ۹۵.۴۵٪ برآورد شد. همچنین برای کلاس جو، دقت کاربر در SVM برابر با ۷۰٪ و در الگوریتم‌های XGBoost و RF بیش از ۹۷٪ گزارش گردید. این نتایج نشان می‌دهد که میزان تداخل کلاسی در این دو گروه بسیار ناچیز بوده و قابلیت اعتماد بالایی در تفکیک آن‌ها وجود دارد. این امر می‌تواند به تفاوت در زمان کاشت و نیز ویژگی‌های فنولوژیکی متمایز این دو محصول که اغلب در مجاورت یکدیگر کشت می‌شوند، نسبت داده شود. از سوی دیگر، بیشترین هم‌پوشانی کلاسی مربوط به کلاس‌های گندم و زیره با کلاس اراضی غیر کشت‌شده بوده است. علت این ادغام نه‌تنها به زمان نسبتاً مشابه کاشت این محصولات مربوط است، بلکه به حضور پوشش‌های گیاهی پراکنده، درختان منفرد و بقایای محصولات کشاورزی سال‌های قبل که مجدداً رشد کرده‌اند نیز ارتباط دارد. بر این اساس پیشنهاد می‌شود در مطالعات آتی، تمرکز بر کلاس‌هایی مانند گندم و جو که پتانسیل تفکیک‌پذیری بالاتری در داده‌های راداری دارند، افزایش یابد و برای محصولاتی با هم‌پوشانی بالا (نظیر زیره) استفاده از داده‌های کمکی (مانند تصاویر نوری یا اطلاعات میدانی) مدنظر قرار گیرد تا دقت طبقه‌بندی ارتقا یابد.

پراکنش و بازتاب راداری از سطح پوشش‌های گیاهی وابسته به پارامترهایی نظیر ساختار گیاه، محتوای رطوبتی، زبری سطح و الگوی رشد آن در طول زمان است. در نتیجه، با تغییر میزان سبزی‌نگی و توسعه فنولوژیکی گیاه، پاسخ راداری آن نیز تغییر می‌کند. شاخص‌های راداری پوشش گیاهی که از ترکیب قطبش‌ها و ویژگی‌های بازتابی استخراج می‌شوند، می‌توانند این تغییرات زمانی را به‌خوبی نمایان کنند؛ بنابراین، بهره‌گیری از سری‌های زمانی شاخص‌های راداری می‌تواند به تفکیک مؤثر محصولات کشاورزی کمک کند؛ زیرا محصولات مختلف، به دلیل تفاوت در الگوی رشد، ساختار و رطوبت گیاهی، در دوره‌های زمانی خاص رفتار بازتابی متفاوتی از خود نشان می‌دهند. این موضوع استفاده از تصاویر راداری را به ابزاری توانمند در زمینه پایش و طبقه‌بندی محصولات کشاورزی، به‌ویژه در مناطقی با پوشش ابری زیاد، تبدیل کرده است. در همین راستا، حتی در شرایطی که زمان کاشت محصولات نسبتاً مشابه بوده است، ترکیب سری زمانی شاخص‌های راداری و داده‌های قطبش‌دار، در کنار بهره‌گیری از الگوریتم‌های پیشرفته یادگیری ماشین مانند جنگل تصادفی (RF) و درخت تقویت‌گرایان (XGBoost)، توانسته است تفکیک دقیق محصولات و تعیین مرز مزارع را با دقت بالایی امکان‌پذیر سازد. به‌طورکلی، الگوریتم‌های جنگل تصادفی و درخت تقویت‌گرایان، به دلیل ساختار درختی و انعطاف‌پذیری بالای خود، در این پژوهش عملکرد دقیق‌تری نسبت به الگوریتم ماشین بردار پشتیبان نشان دادند. با این حال، اگرچه در کل دقت الگوریتم ماشین بردار پشتیبان در تفکیک کلاس‌های زراعی پایین‌تر بود، اما در تفکیک و طبقه‌بندی کلاس‌های گندم و نخود عملکرد قابل‌قبولی از خود ارائه داد است.

این نتایج با یافته‌های (Mishra et al (2023 هم‌راستا بود، به‌طوری‌که آن‌ها نیز گزارش کردند ترکیب داده‌های سنتینل-۱ و شاخص‌های گیاهی راداری باعث ارتقای عملکرد الگوریتم RF نسبت به SVM می‌شود. با این حال، باید توجه داشت که در مطالعه حاضر منطقه موردبررسی تنها شامل اراضی زراعی بود، درحالی‌که در پژوهش (Mishra et al (2023 علاوه بر اراضی کشاورزی، کاربری‌های متنوعی همچون مناطق جنگلی، آبی و ساخته‌شده نیز طبقه‌بندی شدند که در واقع بیشتر تمرکز بر کاربری اراضی بوده است. در پژوهشی دیگر (Chen and Useya (2019 با به‌کارگیری داده‌های سری زمانی سنتینل-۱ و استفاده از الگوریتم طبقه‌بندی RF برای تهیه نقشه‌های تناوب زراعی، به دقتی بالاتر از ۹۵٪ دست یافتند. این یافته‌ها با نتایج مطالعه حاضر هم‌راستا هستند، چراکه در این تحقیق نیز داده‌های سری زمانی سنتینل-۱ به‌عنوان ورودی الگوریتم RF مورداستفاده قرار گرفت و عملکرد بالایی را در

طبقه‌بندی محصولات زراعی نشان داد. همچنین یافته‌ها نشان داد بهره‌گیری از شاخص‌های گیاهی راداری VDDPI، NRPB، IDPDD و DPDD باعث بهبود دقت الگوریتم یادگیری ماشین RF با دقت کلی ۸۲.۲۷٪ گردید، این عملکرد با پژوهش Dubrovin et al (2023) همخوانی و سازگاری دارد، این پژوهشگران خاطر نشان کردند که شاخص‌های گیاهی راداری DpRVI و RVI سنتینل-۱ باعث افزایش دقت کلی ۸۲.۰٪ الگوریتم RF می‌گردد. در تأیید نتایج به‌دست‌آمده، مطالعه Gella et al (2021) نیز نشان داده است که بهره‌گیری از داده‌های SAR امکان طبقه‌بندی دقیق محصولات کشاورزی را حتی در مناطقی با قطعات کوچک و پراکنده فراهم می‌سازد. در همین راستا نتایج پژوهش Asadi and shamsoddini (2024) مؤید یافته‌های مطالعه کنونی است و نشان می‌دهد که ترکیب شاخص‌های طیفی نوری با باندهای لبه قرمز سنتینل-۲ و داده‌های راداری سنتینل-۱ می‌تواند دقت الگوریتم‌های طبقه‌بندی RF و SVM را به‌طور قابل‌توجهی افزایش دهد. با این حال، تفاوت قابل‌توجهی میان دو مطالعه وجود دارد؛ به‌طوری‌که در پژوهش کنونی از تصاویر نوری و همچنین شاخص‌های گیاهی نوری استفاده نشده و صرفاً شاخص‌های گیاهی مبتنی بر داده‌های راداری به کار گرفته شده‌اند که سبب بهبود دقت گردیده است. همچنین مطالعه Maleki et al (2024) با وجود تفاوت‌هایی جزئی، در راستای یافته‌های پژوهش حاضر قرار دارد؛ به‌طوری‌که در آن تحقیق، الگوریتم XGBoost در طبقه‌بندی سه نوع محصول زراعی بر مبنای داده‌های سنتینل-۱ عملکرد بهتری نسبت به RF نشان داد. در مطالعه حاضر نیز الگوریتم XGBoost توانست در طبقه‌بندی گندم، نخود پاییزه و اراضی آیش، عملکرد بهتری نسبت به الگوریتم RF ارائه دهد. در یک مطالعه مشابه، از شاخص‌های راداری مانند شاخص راداری دو قطبشی (DpRVI)، شاخص پوشش گیاهی راداری (RVI) و نسبت قطبش عمودی-افقی به عمودی-عمودی (VH/VV) استفاده شد. نتایج نشان داد این شاخص‌ها، به‌ویژه DpRVI، در شرایط ابری عملکرد مناسبی دارند و الگوریتم‌های یادگیری ماشین مانند تحلیل ممیزی درجه دوم در طبقه‌بندی محصولات دقت قابل‌قبولی ارائه می‌دهند. این مطالعه نشان می‌دهد که شاخص DpRVI می‌تواند در شرایطی که استفاده از NDVI با محدودیت مواجه است، برای پایش مراحل فنولوژیکی رشد و تهیه نقشه‌های محصولات به کار رود (Sorokin et al., 2024).

این مطالعه باهدف نقشه‌برداری محصولات زراعی، از ترکیب داده‌های سری زمانی راداری و شاخص‌های گیاهی مبتنی بر رادار در منطقه‌ای کاملاً زراعی و فاقد کاربری‌های غیر مرتبط استفاده کرده است. یافته‌های پژوهش نشان می‌دهند که شاخص‌های راداری، به‌ویژه زمانی که همراه با داده‌های قطبش‌دار و الگوریتم‌های یادگیری ماشین مانند RF و XGBoost به کار گرفته شوند، قادرند مرز مزارع و انواع محصولات را با دقت بالایی تفکیک کنند. این عملکرد به‌ویژه در اراضی زراعی یکنواخت و پوشیده از محصولات همگن بیشتر نمود پیدا می‌کند، چراکه یکنواختی فضایی پوشش گیاهی باعث افزایش تمایز بازتاب راداری و بهبود نتایج طبقه‌بندی می‌شود. با این حال، از آنجا که شاخص‌های راداری عمدتاً به ویژگی‌های پوشش گیاهی وابسته‌اند، در تفکیک خاک و سایر سطوح فاقد پوشش گیاهی، به‌ویژه در مراحل ابتدایی رشد محصول یا در اراضی بایر، الگوریتم‌ها با چالش‌هایی مواجه می‌شوند. نتایج همچنین ضعف الگوریتم SVM را در طبقه‌بندی نواحی با تنوع پوشش گیاهی نمایان ساختند و در مجموع، بر ارزش‌افزوده داده‌های راداری مستقل در سنجش‌ازدور کشاورزی تأکید دارند.

## نتیجه‌گیری

در این پژوهش، با تمرکز بر داده‌های چند زمانه راداری سنتینل-۱ جمع‌آوری شده از زمستان ۱۴۰۰ تا بهار ۱۴۰۱ و با بهره‌گیری از شاخص‌های نوین گیاهی مبتنی بر دو قطبش VV و VH، امکان‌پذیری و کارایی نقشه‌برداری محصولات زراعی در منطقه‌ای یکنواخت و صرفاً زراعی مورد ارزیابی قرار گرفت. نتایج نشان داد که الگوریتم‌های یادگیری ماشین، به‌ویژه XGBoost و RF، توانستند دقت طبقه‌بندی محصولات زراعی را به ترتیب تا ۸۳.۴۸ و ۸۲.۲۷٪ افزایش دهند، در حالی که الگوریتم SVM با دقت ۶۱.۴۶٪ عملکرد نسبتاً

ضعیفی داشت. شاخص‌هایی مانند DPDD و IDPDD با نمایش روند رشد و تنش پوشش گیاهی، ابزار مؤثری برای تحلیل زمانی محصولات مختلف فراهم کردند. افزون بر این، با حذف داده‌های نوری و تمرکز صرف بر اطلاعات راداری شامل شاخص‌های مشتق شده از آن، این مطالعه نشان داد که حتی بدون دسترسی به داده‌های نوری، می‌توان به دقت‌های قابل قبول و بالای نقشه‌برداری محصولات زراعی دست یافت. این امر به‌ویژه در مناطق ابری یا با دسترسی محدود به داده‌های نوری، از اهمیت ویژه‌ای برخوردار است. نتایج همچنین هم‌راستا با مطالعات پیشین بین‌المللی بوده و قابلیت اطمینان روش به کاررفته را تأیید می‌کند.

در مجموع، پژوهش حاضر با ارائه یک رویکرد کارآمد مبتنی بر داده‌های راداری سنتینل-۱ و شاخص‌های گیاهی راداری، نه تنها توانسته است گامی مؤثر در جهت ارتقای دقت نقشه‌برداری محصولات زراعی بردارد، بلکه چشم‌انداز جدیدی را برای بهره‌برداری از فناوری رادار در کاربردهای کشاورزی هوشمند و مدیریت بهینه زمین‌های زراعی ارائه می‌دهد. با توجه به نتایج به دست آمده، پیشنهاد می‌شود از این روش و شاخص‌ها در مطالعات مشابه و همچنین در سایر کاربردهای کشاورزی و سنجش از دور به کار گرفته شود.

## منابع

- 1) Ackermann, N. 2014. Growing stock volume estimation in temperate forested areas using a fusion approach with SAR satellites imagery. **Springer**.
- 2) Ajadi, O. A., Barr, J., Liang, S. Z., Ferreira, R., Kumpatla, S. P., Patel, R., Swatantran, A. 2021. Large-scale crop type and crop area mapping across Brazil using synthetic aperture radar and optical imagery. **International Journal of Applied Earth Observation and Geoinformation**, 97, p. 102294. <https://doi.org/10.1016/j.jag.2020.102294>
- 3) Arias, M., Campo-Bescós, M. Á., Álvarez-Mozos, J. 2020. Crop classification based on temporal signatures of Sentinel-1 observations over Navarre province, Spain. **Remote Sensing**, 12(2), p. 278. <https://doi.org/10.3390/rs12020278>
- 4) Asadi, B. and shamsoddini, A. 2024. Crop Mapping Using a Combination of Sentinel-1 and 2 Images in Ardabil Province. **Iranian Journal of Remote Sensing and GIS**, 16(3), pp. 25-46. doi: 10.48308/gisj.2023.103095
- 5) Bargiel, D. 2017. A new method for crop classification combining time series of radar images and crop phenology information. **Remote sensing of environment**, 198, pp. 369-383. <https://doi.org/10.1016/j.rse.2017.06.022>
- 6) Bégué, A., Arvor, D., Bellon, B., Betbeder, J., De Abelleira, D., PD Ferraz, R., R. Verón, S. 2018. Remote sensing and cropping practices: A review. **Remote Sensing**, 10(1), p. 99. <https://doi.org/10.3390/rs10010099>
- 7) Behzadi, S., Kolbadinejad, M. 2019. Introducing a novel method to solve shortest path problems based on structure of network using genetic algorithm. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, 42, pp. 201-203. <https://doi.org/10.5194/isprs-archives-XLII-4-W18-201-2019>
- 8) Bousbih, S., Zribi, M., Lili-Chabaane, Z., Baghdadi, N., El Hajj, M., Gao, Q., Mougenot, B. 2017. Potential of Sentinel-1 radar data for the assessment of soil and cereal cover parameters. **Sensors**, 17(11), pp. 2617. <https://doi.org/10.3390/s17112617>
- 9) Burges, C. J. 1998. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, 2(2), pp. 121-167. <https://doi.org/10.1023/A:1009715923555>
- 10) Chang, J. G., Shoshany, M., Oh, Y. 2018. Polarimetric radar vegetation index for biomass estimation in desert fringe ecosystems. **IEEE Transactions on Geoscience and Remote Sensing**, 56(12), pp. 7102-7108. <https://doi.org/10.1109/TGRS.2018.2848285>

- 11) Choudhury, B. J., Tucker, C. J. 1987. Monitoring global vegetation using Nimbus-7 37 GHz Data Some empirical relations. **International Journal of Remote Sensing**, 8(7), pp. 1085-1090. <https://doi.org/10.1080/01431168708954754>
- 12) Cortes, C., Vapnik, V. 1995. Support-vector networks. **Machine learning**, 20, pp. 273-297. <https://doi.org/10.1007/BF00994018>
- 13) de Freitas Bussinguer, J., de Mello Baptista, G. M., Sano, E. E., Leal, F. A. 2024. Understanding the Spatio-Temporal Behavior of Sentinel-1 SAR Vegetation Indices Over the Brazilian Savanna. **IEEE Transactions on Geoscience and Remote Sensing**, 62, pp. 1-18. <https://doi.org/10.1109/TGRS.2024.3381468>
- 14) Dingle Robertson, L., Davidson, A., McNairn, H., Hosseini, M., Mitchell, S., De Abelleira, D., Cosh, M. H. 2020. Synthetic Aperture Radar (SAR) image processing for operational space-based agriculture mapping. **International Journal of Remote Sensing**, 41(18), pp. 7112-7144. <https://doi.org/10.1080/01431161.2020.1754494>
- 15) Dubrovin, K., Stepanov, A., Verkhoturov, A. 2023. Cropland mapping using sentinel-1 data in the southern part of the Russian far east. **Sensors**, 23(18), p. 7902. <https://doi.org/10.3390/s23187902>
- 16) Engman, E. T., & Chauhan, N. 1995. Status of microwave soil moisture measurements with remote sensing. **Remote Sensing of Environment**, 51(1), pp. 189-198. <https://doi.org/10.1109/IGARSS.1995.520316>
- 17) European Space Agency (ESA)
- 18) Fikriyah, V. N., Darvishzadeh, R., Laborte, A., Rathore, J., Nelson, A. 2025. Temporal backscatter characterisation of ratoon rice crops based on Sentinel-1 intensity data. **GIScience & Remote Sensing**, 62(1), p. 2455081. <https://doi.org/10.1080/15481603.2025.2455081>
- 19) 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), pp. 1441. <https://doi.org/10.3390/rs11121441>
- 20) Forkuor, G., Conrad, C., Thiel, M., Ullmann, T., Zoungrana, E. 2014. Integration of optical and Synthetic Aperture Radar imagery for improving crop mapping in Northwestern Benin, West Africa. **Remote sensing**, 6(7), pp. 6472-6499. <https://doi.org/10.3390/rs6076472>
- 21) Friedman, J. H. 2001. Greedy function approximation: a gradient boosting machine. **Annals of statistics**, pp. 1189-1232.
- 22) Gella, G. W., Bijker, W., Belgiu, M. 2021. Mapping crop types in complex farming areas using SAR imagery with dynamic time warping. **ISPRS journal of photogrammetry and remote sensing**, 175, pp. 171-183. <https://doi.org/10.3390/rs6076472>
- 23) Hastie, T., Tibshirani, R., Friedman, J., Hastie, T., Tibshirani, R., Friedman, J. 2009. Boosting and additive trees. **The elements of statistical learning: data mining, inference, and prediction**, pp. 337-387. [https://doi.org/10.1007/978-0-387-84858-7\\_10](https://doi.org/10.1007/978-0-387-84858-7_10)
- 24) Jackson, T. J., Le Vine, D. M., Hsu, A. Y., Oldak, A., Starks, P. J., Swift, C. T., Haken, M. 1999. Soil moisture mapping at regional scales using microwave radiometry: The Southern Great Plains Hydrology Experiment. **IEEE transactions on geoscience and remote sensing**, 37(5), pp. 2136-2151 <https://doi.org/10.1109/36.789610>
- 25) Jayne, T. S., Rashid, S. 2010. The Value of Accurate Crop Production Forecasts. <https://doi.org/10.22004/ag.econ.97032>
- 26) Jensch, K., Ghazaryan, G., Ernst, S., Hostert, P., Nendel, C. 2025. Integrating Landsat, Sentinel-2 and Sentinel-1 time series for mapping intermediate crops. **European Journal of Remote Sensing**, 58(1), p. 2507738. <https://doi.org/10.1080/22797254.2025.2507738>
- 27) Jensen, J. R. 1996. Introductory digital image processing: a remote sensing perspective.

- 28) Kazemi Garajeh, M., Salmani, B., Zare Naghadehi, S., Valipoori Goodarzi, H., & Khasraei, A. (2023). An integrated approach of remote sensing and geospatial analysis for modeling and predicting the impacts of climate change on food security. **Scientific Reports**, 13(1), p. 1057. <https://doi.org/10.1038/s41598-023-28244-5>
- 29) Kordi, F., Yousefi, H. 2022. Crop classification based on phenology information by using time series of optical and synthetic-aperture radar images. **Remote Sensing Applications: Society and Environment**, 27, 100812. <https://doi.org/10.1016/j.rsase.2022.100812>
- 30) Lee, J. S., Grunes, M. R., De Grandi, G. 1999. Polarimetric SAR speckle filtering and its implication for classification. **IEEE Transactions on Geoscience and remote sensing**, 37(5), pp. 2363-2373. <https://doi.org/10.1109/36.789635>
- 31) Liu, Y., Zhang, A., Zhao, X., Wang, Y., Hao, Y., Hu, P. 2025. Crop Mapping Using kNDVI-Enhanced Features from Sentinel Imagery and Hierarchical Feature Optimization Approach in GEE. **Remote Sensing**, 17(17), p. 3003. <https://doi.org/10.3390/rs17173003>
- 32) MahdaviFard, M., Sheikhghaderi, S. H., Moradi, N., Eivazi, A. 2020. Integration of Sentinel-2 and Sentinel-1 time-series data (radar and optical) using Google Earth Engine for mapping rice cultivated area (Case study: Juybar County). **The 1st International and 2nd National Conference on New Geomatics Technologies and Applications, Tabriz, Iran**. [<https://civilica.com/doc/1249699>](<https://civilica.com/doc/1249699>)
- 33) Mahdizadeh Gharakhanlou, N., Perez, L., Coallier, N. 2024. Mapping Crop Types for Beekeepers Using Sentinel-2 Satellite Image Time Series: Five Essential Crops in the Pollination Services. **Remote Sensing**, 16(22), p. 4225. <https://doi.org/10.3390/rs16224225>
- 34) Maleki, S., Baghdadi, N., Bazzi, H., Dantas, C. F., Ienco, D., Nasrallah, Y., Najem, S. 2024. Machine learning-based summer crops mapping using sentinel-1 and sentinel-2 images. **Remote Sensing**, 16(23), p. 4548. <https://doi.org/10.3390/rs16234548>
- 35) Mandal, D., Kumar, V., Bhattacharya, A., Rao, Y. S., Siqueira, P., Bera, S. 2018. Sen4Rice: A processing chain for differentiating early and late transplanted rice using time-series Sentinel-1 SAR data with Google Earth engine. **IEEE Geoscience and Remote Sensing Letters**, 15(12), pp. 1947-1951. <https://doi.org/10.1109/LGRS.2018.2865816>
- 36) Mandal, D., Kumar, V., Ratha, D., Dey, S., Bhattacharya, A., Lopez-Sanchez, J. M., Rao, Y. S. 2020. Dual polarimetric radar vegetation index for crop growth monitoring using sentinel-1 SAR data. **Remote Sensing of Environment**, pp. 247, 111954. <https://doi.org/10.1016/j.rse.2020.111954>
- 37) McNairn, H., Shang, J. 2016. A review of multitemporal synthetic aperture radar (SAR) for crop monitoring. **Multitemporal remote sensing: Methods and applications**, pp. 317-340. [https://doi.org/10.1007/978-3-319-47037-5\\_15](https://doi.org/10.1007/978-3-319-47037-5_15)
- 38) Mishra, D., Pathak, G., Singh, B. P., Mohit, Sihag, P., Rajeev, Singh, S. 2023. Crop classification by using dual-pol SAR vegetation indices derived from Sentinel-1 SAR-C data. **Environmental Monitoring and Assessment**, 195(1), p. 115. <https://doi.org/10.1007/s10661-022-10591-x>
- 39) Nagaraju, M. S. S., Venugopal, M. V., Rajankar, P., Laghate, P., Reddy, M. S., Joshi, A. K., Sharma, J. R. 2013. Modified Dubois model for estimating soil moisture with dual polarized SAR data. **J Indian Soc Remote Sens** (December 2013), 41(4), pp. 865-872. <https://doi.org/10.1007/s12524-013-0274-3>
- 40) Nagraj, G. M., Karegowda, A. G. 2016. Crop mapping using SAR imagery: An review. **International Journal of Advanced Research in Computer Science**, 7(7), pp. 47-52. <https://doi.org/10.26483/ijarcs.v7i7.2824>
- 41) Narvekar, P. S., Entekhabi, D., Kim, S. B., Njoku, E. G. 2015. Soil moisture retrieval using L-band radar observations. **IEEE Transactions on Geoscience and Remote Sensing**, 53(6), pp. 3492-3506. <https://doi.org/10.1109/TGRS.2014.2377714>

- 42) Nasirzadehdizaji, R., Balik Sanli, F., Cakir, Z., Sertel, E. 2019. Crop mapping improvement by combination of optical and SAR datasets. In 2019. **8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics)** (pp. 1-6). IEEE. <https://doi.org/10.1109/Agro-Geoinformatics.2019.8820604>
- 43) Nguyen, D. B., Gruber, A., Wagner, W. 2016. Mapping rice extent and cropping scheme in the Mekong Delta using Sentinel-1A data. **Remote Sensing Letters**, 7(12),pp. 1209-1218. <https://doi.org/10.1080/2150704X.2016.1225172>
- 44) Niraimathi, J., Saravanan, S. 2025. Mapping and monitoring paddy crops with sentinel-1 derived polarimetric parameters and machine learning. **Environment, Development and Sustainability**, pp. 1-27. <https://doi.org/10.1007/s10668-025-06448-1>
- 45) Özdoğan, M., Wang, S., Ghose, D., Fraga, E., Fernandes, A., Varela, G. 2025. Field-scale rice area and yield mapping in Sri Lanka with optical remote sensing and limited training data. **Remote Sensing**, 17(17), p. 3065. <https://doi.org/10.3390/rs17173065>
- 46) Periasamy, S. 2018. Significance of dual polarimetric synthetic aperture radar in biomass retrieval: An attempt on Sentinel-1. **Remote sensing of environment**, 217,pp. 537-549. <https://doi.org/10.1016/j.rse.2018.09.003>
- 47) Periasamy, S., Senthil, D., Shanmugam, R. S. 2018, November. A Modified Triangle with SAR Target Parameters for Soil Texture Categorization Mapping. In **Conference of the Arabian Journal of Geosciences** (pp. 97-99). Cham: Springer International Publishing. [https://doi.org/10.1007/978-3-030-01440-7\\_23](https://doi.org/10.1007/978-3-030-01440-7_23)
- 48) Piryonesi, S. M., El-Diraby, T. E. 2020. Data analytics in asset management: Cost-effective prediction of the pavement condition index. **Journal of infrastructure systems**, 26(1),p. 04019036. [https://doi.org/10.1061/\(ASCE\)0887-3801\(1998\)12:4\(249\)](https://doi.org/10.1061/(ASCE)0887-3801(1998)12:4(249)).
- 49) Piryonesi, S. M., El-Diraby, T. E. 2020. Role of data analytics in infrastructure asset management: Overcoming data size and quality problems. **Journal of Transportation Engineering, Part B: Pavements**, 146(2),p. 04020022. <https://doi.org/10.1061/JPEODX.0000175>
- 50) Pott, L. P., Amado, T. J. C., Schwalbert, R. A., Corassa, G. M., Ciampitti, I. A. 2021. Satellite-based data fusion crop type classification and mapping in Rio Grande do Sul, Brazil. **ISPRS Journal of Photogrammetry and Remote Sensing**, 176, pp. 196-210. <https://doi.org/10.1016/j.isprsjprs.2021.04.015>
- 51) Sharma, N., Bhattacharjee, S., Garg, R. D., Sharma, K., Salim, M. 2024. Sustainable management and agriculture resource technology system using remote sensing descriptors and IoT. **Geomatica**, 76(2),p. 100040. <https://doi.org/10.1016/j.geomat.2024.100040>
- 52) Sorokin, A., Stepanov, A., Dubrovin, K., Verkhoturov, A. 2024. Enhancement of Comparative Assessment Approaches for Synthetic Aperture Radar (SAR) Vegetation Indices for Crop Monitoring and Identification—Khabarovsk Territory (Russia) Case Study. **Remote Sensing**, 16(14),p. 2532. <https://doi.org/10.3390/rs16142532>
- 53) Suwanlee, S. R., Qaisrani, Z. N., Som-ard, J., Keawsomsee, S., Kasa, K., Nuthammachot, N., Sarvia, F. 2025. Integrating PRISMA hyperspectral data with Sentinel-1, Sentinel-2 and Landsat data for mapping crop types and land cover in northeast Thailand. **The Egyptian Journal of Remote Sensing and Space Sciences**, 28(2), pp.252-260. <https://doi.org/10.1016/j.ejrs.2025.04.005>.
- 54) Ulaby, F. 1975. Radar response to vegetation. **IEEE Transactions on Antennas and Propagation**, 23(1),pp. 36-45. <https://doi.org/10.1109/TAP.1975.1140999>
- 55) Ulaby, F. T., Dubois, P. C., Van Zyl, J. 1996. Radar mapping of surface soil moisture. **Journal of hydrology**, 184(1-2),pp. 57-84. [https://doi.org/10.1016/0022-1694\(95\)02968-0](https://doi.org/10.1016/0022-1694(95)02968-0)
- 56) Useya, J., Chen, S. 2019. Exploring the potential of mapping cropping patterns on smallholder scale croplands using Sentinel-1 SAR data. **Chinese Geographical Science**, 29(4),pp. 626-639. <https://doi.org/10.1007/s11769-019-1060-0>

- 57) Van Tricht, K., Gobin, A., Gilliams, S., Piccard, I. 2018. Synergistic use of radar Sentinel-1 and optical Sentinel-2 imagery for crop mapping: A case study for Belgium. **Remote Sensing**, 10(10),p. 1642. <https://doi.org/10.3390/rs10101642>
- 58) Whelen, T., Siqueira, P. 2018. Time-series classification of Sentinel-1 agricultural data over North Dakota. **Remote sensing letters**, 9(5),pp. 411-420. <https://doi.org/10.1080/2150704X.2018.1430393>
- 59) Yuan, Y., Lin, L., Zhou, Z. G., Jiang, H., Liu, Q. 2023. Bridging optical and SAR satellite image time series via contrastive feature extraction for crop classification. **ISPRS Journal of Photogrammetry and Remote Sensing**, 195,p. 222-232. <https://doi.org/10.1016/j.isprsjprs.2022.11.020>
- 60) Yun, S. H. A. O., Hasi, T. 2019. Research advances of SAR remote sensing for agriculture applications: A review. **Journal of integrative agriculture**, 18(3),pp. 506-525. [https://doi.org/10.1016/S2095-3119\(18\)62016-7](https://doi.org/10.1016/S2095-3119(18)62016-7)
- 61) Zhang, S., Zhang, L., Meng, Q., Wang, C., Ma, J., Li, H., Ma, K. 2024. Evaluating agricultural non-point source pollution with high-resolution remote sensing technology and SWAT model: A case study in Ningxia Yellow River Irrigation District, China. **Ecological Indicators**, 166, p.112578. <https://doi.org/10.1016/j.ecolind.2024.112578>