

Original Article



Evaluating the Efficiency of InSAR Coherence in Crop Type Mapping Using Machine Learning

Fatemeh Amiri, Ali Shamsoddini^{*}, Mohamad Sharifkia**Affiliation**

Dep. of Remote Sensing and GIS, Faculty of Humanities, Tarbiat Modares University, Tehran, Iran

ABSTRACT

Introduction: The optimal use of agricultural land is a key concern for authorities due to agriculture's significant role in job creation, foreign exchange earnings, ensuring food security, and reducing reliance on imports. Gathering information about the spatial distribution and cultivated areas of various crops can enhance their efficient usage. One effective method for obtaining this information is through satellite imagery. Remote sensing technology, with its ability to provide high-resolution images and extensive spatial and temporal coverage, has become a dominant approach for crop type mapping. One of the remote sensing data that has recently received attention in the field of crop type mapping is the interferometric coherence images of synthetic aperture radar (InSAR). The sensitivity of these images to crop's structure, making them valuable for monitoring and mapping crop types. In global literature, InSAR coherence images have been widely used in research related to agricultural products. However, in Iran, the use of coherence data for monitoring phenology and distinguishing different crops has not received much attention, despite its unique capabilities. Therefore, evaluating the efficiency of coherence data and its potential for adopting optimal agricultural management policies in Iran can be highly beneficial.

Methodology: The main objective of this study is to evaluate the efficiency of machine learning-based InSAR coherence data for crop type mapping. To achieve this, a one-year time series of Synthetic Aperture Radar (SAR) data was compiled from Sentinel-1 phase information for the 2019 crop year, for the Ardabil plain, located to the west and northwest of Ardabil city. A network of SAR image pairs with short spatial and temporal baselines was created to produce coherence data. Field data were collected from 1,358 fields containing various crops. To avoid mixed pixels, a 10-meter buffer was established around the edges of each crop field. A total of 156,026 pixels from the coherence images were sampled and randomly divided into three groups: training (70%), validation (15%), and test (15%). To select the appropriate time interval for using coherence images, the phenological response of the crops to the InSAR coherence was analyzed. During the time interval, the phenological signals of the studied crops were compared with the signals of the built-up areas and bare soil to ensure that they were not mixed. Consequently, the multi-temporal InSAR coherence values in the selected time interval were used as input to the Support Vector Machine (SVM) classifier with different kernels to distinguish and identify the type of crops.

Result: The study of the coherence time series values in the selected control areas revealed distinct differences in the coherence behavior of various crops when compared to one another, as well as in comparison to both built-up and bare soil areas. The InSAR coherence data match well with the main phenological stages of the crops. Among the different SVM kernels tested, the radial basis function (RBF) kernel achieved the highest overall accuracy of 59.69% during the validation phase, utilizing various combinations of the parameters c and γ . In the testing phase, the crop type map produced using the SVM classifier with the RBF kernel reached an overall accuracy of 60.6%. This model performed best in identifying wheat and least effectively in identifying alfalfa. User accuracy was notably higher for wheat and potato plants, while it was lower for corn, broad bean, and alfalfa.

Conclusion: Coherence images offer valuable insights for identifying and classifying crops in Iran. Leveraging machine learning techniques can enhance the utility of coherence data in monitoring and categorizing different crop types. Several factors influence the effectiveness of coherence images and the performance of classification algorithms, including the number of training samples available for each crop, the number of coherence features, the use of complementary data, sensor parallax (spatial baseline), topographical features (slope and aspect), the temporal resolution, and the classification algorithm. These characteristics should be carefully considered to optimize the analysis.

Keywords: Crop type mapping, Support vector machine (SVM), Interferometric synthetic aperture radar (InSAR), Coherence, Sentinel-1.

Citation:

Amiri, F., Shamsoddini, A., Sharifkia, M., Evaluating the Efficiency of InSAR Coherence in Crop Type Mapping Using Machine Learning, Iran J Remote Sens GIS. 17(4): 133-160.

* Corresponding Author: ali.shamsoddini@modares.ac.ir
DOI: <https://doi.org/10.48308/gisj.2025.238522.1249>

Received: 2025.01.25

Accepted: 2025.05.24



Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license <https://creativecommons.org/licenses/by/4.0/>.



ارزیابی کارایی همدوسی تداخل سنجی راداری به منظور تعیین نوع کشت اراضی کشاورزی با استفاده از یادگیری ماشین

فاطمه امیری، علی شمس الدینی^{*}، محمد شریفی کیا

سمت

گروه سنجش از دور و سیستم اطلاعات
جغرافیایی، دانشکده علوم انسانی،
دانشگاه تربیت مدرس، تهران، ایران

چکیده

مقدمه: استفاده بهینه از زمین‌های کشاورزی یکی از دغدغه‌های مسئولان است زیرا کشاورزی از نظر اشتغال‌زایی، ارزآوری، تأمین امنیت غذایی کشور و وابستگی کمتر به ارز خارجی دارای اهمیت بسیار است. به دست آوردن اطلاعات درباره الگوی توزیع مکانی و سطح زیرکشت محصولات زراعی می‌تواند به استفاده کارآمد از آن‌ها کمک کند. ازجمله روش‌های مناسب به‌منظور حصول اطلاعات درمورد سطح زیرکشت محصولات زراعی، بهره‌گیری از تصاویر ماهواره‌ای است. حوزه سنجش از دور، با امکان ارائه تصاویر دارای قدرت تفکیک‌های مناسب و همچنین پوشش مکانی و زمانی وسیع، به رویکردی غالب برای استخراج سطح زیرکشت و پایش محصولات زراعی تبدیل شده است. یکی از داده‌های سنجش‌ازدوری که اخیراً در حوزه نقشه‌برداری نوع محصول زراعی مورد توجه قرار گرفته، تصاویر همدوسی تداخل‌سنجی رادار دریچه مصنوعی است که به دلیل حساسیت بالا به ساختار محصولات زراعی، به نظارت و نقشه‌برداری آن‌ها کمک بسیاری می‌کند. در منابع جهانی، تصاویر همدوسی InSAR کاربردی گسترده در تحقیقات مرتبط با محصولات زراعی داشته است. این درحالی است که در ایران، بهره‌گیری از داده‌های همدوسی برای پایش فنولوژی و تفکیک محصولات زراعی گوناگون، به‌رغم توانایی‌های منحصره‌فرد آن، چندان مورد توجه قرار نگرفته است. ازاین‌رو ارزیابی کارایی داده‌های همدوسی و قابلیت‌های آن‌ها برای اتخاذ سیاست‌های مدیریت کشاورزی بهینه در ایران می‌تواند بسیار کارساز باشد.

روش‌شناسی: هدف اصلی مطالعه حاضر ارزیابی کارایی داده‌های همدوسی مبتنی بر یادگیری ماشین، به‌منظور نقشه‌برداری نوع محصول زراعی است. بدین‌منظور سری زمانی یک‌ساله‌ای متعلق به سال زراعی ۱۳۹۸ (۲۰۱۹ میلادی)، از داده‌های همدوسی دارای اطلاعات فاز ماهواره سنتینل-۱، درمورد بخشی از اراضی دشت اردبیل واقع در غرب و شمال‌غرب شهر اردبیل، تهیه شد. در این راستا زنجیره‌ای از جفت تصاویر راداری، با خط‌مبنای مکانی و زمانی کوتاه، برای تولید داده‌های همدوسی به کار رفت. داده‌های میدانی از ۱۳۵۸ قطعه‌زمین با محصولات متفاوت برداشت شد. در مرز قطعات زراعی، حریمی دهمتری برای جلوگیری از پیکسل‌های مخلوط در نظر گرفته شد. درمجموع، ۱۵۶۰۲۶ پیکسل از تصاویر همدوسی، برای نمونه، برداشت و به‌صورت تصادفی به سه دسته آموزشی (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمایشی (۱۵٪) تقسیم شد. به‌منظور انتخاب بازه زمانی مناسب برای استفاده از تصاویر همدوسی، پاسخ فنولوژیکی محصولات به همدوسی تحلیل شد. در بازه زمانی انتخابی، سیگنال‌های فنولوژیکی محصولات مورد بررسی، با سیگنال‌های مناطق شاهد ساخته‌شده و خاک لخت، مقایسه شد تا درمورد اختلاط نیافتن آن‌ها اطمینان به دست آید. بدین‌ترتیب داده‌های همدوسی چندزمانه در بازه انتخابی، به‌منزله ورودی طبقه‌بندی‌کننده ماشین بردار پشتیبان با کرنل‌های متفاوت، برای تفکیک و شناسایی نوع محصولات زراعی استفاده شدند.

نتایج: بررسی مقادیر سری زمانی همدوسی، در مناطق شاهد انتخابی، حاکی از تمایز رفتار همدوسی محصولات زراعی متفاوت، درمقایسه با هم و نیز درمقایسه با مناطق ساخته‌شده و خاک لخت است. براین‌اساس داده‌های همدوسی انطباق خوبی با مراحل فنولوژیکی اصلی محصولات زراعی نشان می‌دهند. از میان کرنل‌های گوناگون طبقه‌بندی‌کننده ماشین بردار پشتیبان، کرنل تابع پایه شعاعی بیشترین میزان صحت کلی برابر با ۵۹/۶۹٪ با ترکیب متفاوتی از پارامترهای C و گاما در مرحله اعتبارسنجی نشان داد. صحت کلی نقشه نوع محصول زراعی تولیدشده با استفاده از طبقه‌بندی‌کننده ماشین بردار پشتیبان و کرنل تابع پایه شعاعی، در مرحله آزمایش، برابر با ۶۰/۶٪ است که بهترین عملکرد را در شناسایی گندم و بدترین را درمورد یونجه داشته است. صحت کاربر، برای گیاهان گندم و سیب‌زمینی، بالاتر و برای گیاهان ذرت، باقلا و یونجه، پایین‌تر است.

جمع‌بندی: به‌طور کلی، می‌توان گفت تصاویر همدوسی اطلاعات ارزشمندی به‌منظور شناسایی و تفکیک محصولات زراعی در ایران ارائه می‌دهند. استفاده از قابلیت‌های یادگیری ماشین می‌تواند، در پایش و تفکیک انواع محصولات زراعی، به داده‌های همدوسی کمک کند. در این راستا، عواملی همچون تعداد نمونه‌های آموزشی هر محصول، تعداد ویژگی‌های همدوسی، استفاده از داده‌های مکمل، اختلاف‌منظر سنجنده (خط‌مبنای مکانی)، ویژگی‌های توپوگرافیکی (شیب و جهت)، فاصله زمانی بین تصاویر رادار و نوع الگوریتم طبقه‌بندی تصویر، کارایی تصاویر همدوسی و طبقه‌بندی‌کننده را تحت تأثیر قرار می‌دهند که باید مورد توجه قرار گیرند.

واژه‌های کلیدی: نقشه‌برداری نوع محصول زراعی، ماشین بردار پشتیبان، تداخل‌سنجی راداری، همدوسی، سنتینل-۱.

استناد:

امیری، ف.، شمس‌الدینی، ع.، شریفی کیا، م.، ارزیابی کارایی همدوسی تداخل‌سنجی راداری به‌منظور تعیین نوع کشت اراضی کشاورزی با استفاده از یادگیری ماشین، نشریه سنجش از دور و GIS ایران، سال ۱۷، شماره ۴، زمستان ۱۴۰۴: ۱۳۳-۱۶۰.

دریافت: ۱۴۰۳/۱۱/۰۶

پذیرش: ۱۴۰۴/۰۳/۰۳



Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license <https://creativecommons.org/licenses/by/4.0/>.

* نویسنده عهده‌دار مکاتبات: ali.shamsoddini@modares.ac.ir
شناسه دیجیتال مقالات: 10.48308/gisj.2025.238522.1249

۱- مقدمه

کشاورزی نقش مهمی در حفظ بقای انسان دارد (Liu et al., 2023) و در مقایسه با سایر بخش‌های اقتصادی، از نظر اشتغال‌زایی، ارزآوری، تأمین امنیت غذایی کشور و وابستگی کمتر به ارز خارجی دارای اهمیت چشمگیری است (Akbari et al., 2003). بر همین اساس استفاده بهینه از زمین‌های کشاورزی یکی از دغدغه‌های مسئولان است. به دست آوردن اطلاعات درباره الگوی توزیع مکانی و سطح زیرکشت محصولات زراعی می‌تواند به نظارت و مدیریت پایدار منابع کشاورزی (Li et al., 2022) و استفاده کارآمد از آن‌ها کمک کند (Abiyat et al., 2022).

از جمله روش‌های مناسب، کم‌هزینه و سریع برای حصول اطلاعات در مورد سطح زیرکشت محصولات زراعی، بهره‌گیری از تصاویر ماهواره‌ای است (Alizadeh et al., 2018). همگام با پیشرفت‌های روزافزون در حوزه سنجش از دور با امکان ارائه تصاویر دارای قدرت تفکیک‌های فضایی، زمانی، طیفی و رادیومتریکی مناسب و همچنین پوشش مکانی و زمانی وسیع، نقشه‌برداری نوع محصول زراعی مبتنی بر تصاویر ماهواره‌ای به رویکردی غالب برای استخراج سطح زیرکشت و پایش محصولات زراعی تبدیل شده است (Azzari & Lobell., 2017). از داده‌های سنجش از دوری رایج مورد استفاده در این زمینه می‌توان به مجموعه داده‌های اپتیک، بازپراکنش راداری و لیدار اشاره کرد. یکی دیگر از داده‌هایی که اخیراً در حوزه نقشه‌برداری نوع محصول زراعی مورد توجه قرار گرفته، تصاویر همدوسی^۱ تداخل‌سنجی رادار دریاچه مصنوعی (InSAR)^۲ است که به دلیل حساسیت بالا به ساختار محصولات زراعی، کمک بسیاری به نظارت و نقشه‌برداری آن‌ها می‌کند (Zhao et al., 2024). در تکنیک InSAR، اختلاف فاز بین جفت تصاویر متعلق به زمان‌های متفاوت در قالب تداخل‌نگاشت^۳ اندازه‌گیری می‌شود و سپس این اختلاف فاز به تغییر فاصله بین سنجنده و هدف و یا جابه‌جایی سطح زمین

نسبت داده می‌شود (Crosetto et al., 2002). تغییرات همدوسی بین جفت تصاویر رادار دریاچه مصنوعی (SAR)^۴ ناشی از تغییرپذیری زمانی پدیده‌های سطح زمین است و از این‌رو می‌تواند اطلاعات ارزشمندی را به منظور شناسایی و طبقه‌بندی پوشش‌های متفاوت زمین، در اختیار قرار دهد (Mestre-Quereda et al., 2020).

در زمینه بهره‌گیری از تصاویر همدوسی، در حوزه نقشه‌برداری نوع محصول زراعی، مطالعات بسیاری انجام شده است. جو^۵ و همکاران (۲۰۱۷) تأثیر استفاده تلفیقی از داده‌های اپتیک لندست-۸ و همدوسی سنتینل-۱ را در صحت طبقه‌بندی محصول گندم زمستانه، در مناطق کشاورزی شهری در جنوب چین، ارزیابی کردند و برای این کار، از طبقه‌بندی‌کننده‌های جنگل تصادفی (RF)^۶ و ماشین بردار پشتیبان (SVM)^۷ بهره گرفتند. نتایج پژوهش آن‌ها نشان داد، در شرایط آب‌وهوایی نامساعد که تصاویر اپتیک مناسب در دسترس نباشند، می‌توان داده‌های همدوسی سنتینل-۱ را جایگزین کرد. همچنین دریافتند که در مجموع، طبقه‌بندی‌کننده SVM به لحاظ صحت کلی، ضریب کاپا^۸ و سرعت اجرا، عملکردی بهتر از RF داشته است. مستره-کردا^۹ و همکاران (۲۰۲۰) بر اهمیت بهره‌گیری از داده‌های همدوسی، برای افزایش صحت نقشه‌برداری نوع محصول زراعی در اسپانیا، تأکید داشتند. نتایج بررسی‌های آن‌ها نشان داد که صحت کلی طبقه‌بندی نظارت‌شده جنگل تصادفی برای این مجموعه داده، در قطبش VV با قدرت تفکیک زمانی دوازده روزه، برابر با ۷۳/۸٪ است. در مطالعه جیکوب^{۱۰} و همکاران (۲۰۲۰)، کارایی داده‌های همدوسی

1. Coherence
2. Interferometric Synthetic Aperture Radar
3. Interferogram
4. Synthetic Aperture Radar
5. Zhou
6. Random Forest
7. Support Vector Machine
8. Kappa Coefficient
9. Mestre-Quereda
10. Jacob

بسیاری بر توانایی چشمگیر الگوریتم طبقه‌بندی SVM، به‌منزله روش نظارت‌شده‌ای مبتنی بر یادگیری ماشین، تأکید داشته‌اند (Zhou et al., 2017; Jamali., 2020; Navale & Haldar., 2019).

با مرور مطالعات پیشین، می‌توان دریافت که در منابع جهانی، تصاویر همدوسی InSAR کاربردی گسترده در تحقیقات مرتبط با محصولات زراعی داشته‌اند (Sonobe et al., 2015; Zhou et al., 2017; Mestres-Quereda et al., 2020). این مجموعه داده هم در تفکیک انواع گوناگون محصولات و بررسی مراحل فنولوژیکی (Pandit et al., 2021) آن‌ها تأثیر داشته و هم در تلفیق با سایر داده‌ها، مانند داده‌های اپتیک و بازپراکنش (Engdahl and Hyypä, 2003; Parihar et al., 2014; Olesk et al., 2016; Khalil, 2018; Sica et al., 2019; Jacob et al., 2020)، نتایج مطلوبی به دست داده است. علاوه بر این، به‌منظور افزایش صحت و کارایی نتایج، روش‌های گوناگون یادگیری ماشین و یادگیری عمیق نیز، مبتنی بر این مجموعه داده‌ها، به کار رفته است. این درحالی است که در ایران، با وجود بهره‌گیری از داده‌های InSAR در حوزه‌هایی مانند طبقه‌بندی پوشش زمین (Soleimani et al., 2021) و ارزیابی فرسایش خاک (Ebrahimzadeh et al., 2023)، استفاده از داده‌های همدوسی برای پایش فنولوژی و تفکیک محصولات زراعی گوناگون، به‌رغم توانمندی‌های منحصربه‌فرد آن، مورد توجه قرار نگرفته است. با توجه به اینکه ایران دارای تنوع اقلیمی است و الگوهای مکانی کشت نواحی گوناگون کشور، در اراضی زیرکشت محصولات زراعی متنوع، اغلب سنتی و ناهمگن و کوچک‌مساحت‌اند، بررسی دقیق کارایی این داده‌ها در تفکیک انواع محصولات زراعی، ضروری به نظر می‌رسد. ارزیابی توانمندی داده‌های همدوسی InSAR، در مطالعه فنولوژی محصولات زراعی،

تداخل‌سنجی سنتینل-۱ به‌منظور نقشه‌برداری پوشش زمین بررسی شد. آن‌ها دریافتند که صحت کلی طبقه‌بندی نظارت‌شده مبتنی بر RF برای این مجموعه داده در قطبش VH+VV، با قدرت تفکیک زمانی دوازده‌روزه، برابر با ۷۰٪ است. مطالعات نصیری‌زاده دیزجی^۱ و همکاران (۲۰۲۱) و ویارویا-کارپیو^۲ و همکاران (۲۰۲۲) نیز مؤید انطباق خوب داده‌های سری زمانی همدوسی با مراحل فنولوژیکی اصلی محصولات زراعی است. پاندیت^۳ و همکاران (۲۰۲۱) از محصولات همدوسی برای پایش مراحل فنولوژیکی، تعیین کل مدت زمان کشت و تخمین تاریخ کاشت و برداشت درمورد محصول Bengal-gram استفاده کردند. نتایج این مطالعه نشان داد که تحلیل سری زمانی همدوسی، درباره مراحل رشد محصول، اطلاعات مورد اعتمادی می‌دهد و این رویکرد می‌تواند در پایش سایر محصولات نیز استفاده شود. هوبر^۴ و همکاران (۲۰۲۳)، در مطالعه‌ای، تصاویر همدوسی InSAR را به‌منزله شاخصی برای پایش فعالیت‌های کشاورزی (مانند کاشت، جوانه‌زنی، برداشت و خاک‌ورزی)، با در نظر گرفتن شرایط آب‌وهوایی (برف، باران، یخبندان)، به کار بردند. یافته‌های این مطالعه تأکید دارد تصاویر همدوسی شاخصی مطمئن برای پایش فعالیت‌های گوناگون کشاورزی، با شرایط جوّی متفاوت‌اند. جائو^۵ و همکاران (۲۰۲۴) توانمندی همدوسی سری زمانی سنتینل-۱ را به‌منزله ابزاری کارآمد برای نقشه‌برداری از محصولات اصلی، در مناطق مهم تولیدکننده غلات در چین، معرفی کردند. با بررسی مطالعات گذشته، در کل می‌توان نتیجه گرفت که طی سال‌های اخیر، استفاده از داده‌های همدوسی InSAR به‌منظور نقشه‌برداری محصولات زراعی، مورد توجه قرار گرفته و نتایج مطالعات مذکور گواه توانایی این مجموعه داده، در پایش وضعیت محصولات زراعی و شناسایی آن‌هاست. در این زمینه، ازمنظر روش طبقه‌بندی نیز طیف وسیعی از رویکردهای طبقه‌بندی نظارت‌شده و نظارت‌نشده به کار رفته است (Senanayake et al., 2020) و مطالعات

1. Nasirzadehdizaji
2. Villarroja-Carpio
3. Pandit
4. Huber
5. Zhao


داده‌های همدوسی چندزمانه InSAR استفاده شده است. بدین‌منظور سری زمانی یک‌ساله‌ای، متعلق به سال زراعی ۱۳۹۸ (۲۰۱۹ میلادی)، از داده‌های SAR دارای اطلاعات فاز ماهواره سنتینل-۱ تهیه شد که مختص بخشی از اراضی دشت اردبیل، واقع در غرب و شمال‌غرب شهر اردبیل بود. در ادامه، شبکه‌ای از جفت تصاویر SAR با خط‌مبناهای مکانی و زمانی کوتاه، برای پردازش InSAR و تولید داده‌های همدوسی تشکیل داده شد. بدین‌ترتیب داده‌های همدوسی چندزمانه تولیدشده به‌منزله ورودی الگوریتم طبقه‌بندی‌کننده SVM و با کرنل‌های متفاوت، در تفکیک و شناسایی نوع محصولات زراعی استفاده شدند. فرایند آموزش طبقه‌بندی‌کننده SVM و در نهایت، ارزیابی صحت نقشه نوع محصول زراعی مبتنی بر هر کرنل با استفاده از داده‌های زمینی، درباره نوع محصولات زراعی، انجام شده است. شکل ۱ ساختار کلی فرایند این مطالعه را نمایش می‌دهد.

اطلاعات مفیدی برای اجرای رویکردهای نقشه‌برداری نوع محصول زراعی در اختیار می‌گذارد که این نکته مهم، با توجه به ضرورت و اهمیت دسترسی به نقشه‌های تفکیک نوع محصول مورد اطمینان، راه را برای اتخاذ سیاست‌های مدیریت کشاورزی بهینه در ایران هموار می‌سازد.

براین‌اساس مطالعه حاضر با هدف ارزیابی توانایی‌های داده‌های همدوسی InSAR سنتینل-۱، به‌منظور نقشه‌برداری نوع محصولات زراعی با استفاده از الگوریتم SVM، در بخشی از اراضی کشاورزی دشت اردبیل انجام می‌شود. در طبقه‌بندی‌کننده SVM برای تفکیک داده‌ها در فضای ویژگی، کرنل‌های متفاوتی به کار گرفته می‌شود. از آنجاکه نوع تابع کرنل می‌تواند نتایج طبقه‌بندی را تحت تأثیر قرار دهد، در این مطالعه، توانمندی کرنل‌های متفاوت SVM نیز ارزیابی می‌شود.

۲- مواد و روش‌ها

در این مطالعه، برای تهیه نقشه محصولات زراعی، از



شکل ۱. ساختار کلی رویکرد نقشه‌برداری نوع محصول زراعی، با استفاده از داده‌های سری زمانی همدوسی InSAR ماهواره سنتینل-۱


۱-۲- منطقه مورد مطالعه

مطابق شکل ۲، منطقه مورد مطالعه (مستطیل قرمز) شامل بخشی از اراضی کشاورزی دشت اردبیل، واقع در غرب و شمال غرب شهر اردبیل است که در محدوده جغرافیایی بین ۴۸ درجه و ۹ دقیقه و ۲۸ ثانیه تا ۴۸ درجه و ۱۵ دقیقه و ۳۱ ثانیه طول شرقی و ۳۸ درجه و ۱۲ دقیقه تا ۳۸ درجه و ۲۲ دقیقه و ۵۸ ثانیه عرض شمالی قرار دارد و مساحت تقریبی آن ۱۷۸/۷۳ کیلومترمربع (معادل ۱۷۸۷۳ هکتار) است. متناسب با هدف پژوهش، در زمینه ارزیابی قابلیت داده‌های InSAR برای شناسایی و تفکیک محصولات زراعی، این محدوده از نظر تنوع محصولات زراعی، شرایط مناسبی دارد زیرا ارتفاعات، به صورت حلقه‌ای گرداگرد دشت اردبیل، آن را دربر گرفته و از طرفی، دشتی آبرفتی به‌منزله پست‌ترین سطح توپوگرافی، در مرکز آن واقع شده است (Ezzati et al., 2017). این نکته، به‌علاوه

بارندگی تجمعی سالیانه حدود ۳۰۰ میلی‌متر (Meteorological Yearbook of Ardabil Province, 2021)، منطقه مورد مطالعه را به‌طور طبیعی برای فعالیت‌های کشاورزی مناسب کرده است.

۲-۲- داده‌های ماهواره سنتینل-۱

برای محاسبه همدوسی InSAR مبتنی بر داده‌های سنتینل-۱، غالباً از تصاویر SLC^۱ برداشت‌شده در حالت تصویربرداری IW^۲ استفاده می‌شود. محصول IW دارای عرض برداشت^۳ ۲۵۰ کیلومتر، قدرت تفکیک فضایی ۵ متر (در راستای برد مایل) در ۲۰ متر (در راستای آزمون) و قدرت تفکیک زمانی دوازده‌روزه به‌صورت Single Look است. در حالت تصویربرداری IW، از طریق تکنیک مشاهده زمین با اسکن‌های پیش‌رونده^۴، تصویر در قالب سه زیرنوار IW1 (حداقل زاویه فرودی) تا IW3 (حداکثر زاویه فرودی) برداشت



شکل ۲. موقعیت منطقه مورد مطالعه (مستطیل قرمز) در دشت اردبیل

1. Single Look Complex
2. Interferometric Wide Swath
3. Swath Width
4. Terrain Observation with Progressive Scans SAR (TOPSAR)

$$\hat{\gamma} = \frac{E\{S_1 S_2^*\}}{\sqrt{E\{S_1 S_1^*\} \cdot E\{S_2 S_2^*\}}} \quad \text{رابطه (۱)}$$

در این معادله، $E\{0\}$ عملگر امید ریاضی^۵ است و S_1 و S_2 بیانگر دو تصویر پیچیده^۶ و ثبت‌هندسی شده^۷ SAR^۸ هستند. در راستای اهداف عملی و با این فرض که سیگنال‌های S_1 و S_2 رفتار تصادفی دارند، عملگر مورد نظر با میانگین مکانی مجموعه‌ای از پیکسل‌های داخل یک پنجره^۹ جایگزین می‌شود (Touzi et al., 1999). از این‌رو رابطه (۱) به صورت رابطه (۲) بیان می‌شود.

$$\gamma = \frac{\frac{1}{L} \sum_{i=1}^L S_1 S_2^*}{\sqrt{\frac{1}{L} \left(\sum_{i=1}^L S_1 S_1^* \right) \cdot \frac{1}{L} \left(\sum_{i=1}^L S_2 S_2^* \right)}} \quad (L > 1) \quad \text{رابطه (۲)}$$

در رابطه (۲)، L تعداد نمونه‌های موجود در یک پنجره است. دامنه تغییرات مقادیر γ ، در این معادله، بین ۰ و ۱ قرار دارد. مقادیر کم γ بیانگر همدوسی پایین و مقادیر بالای آن نشان‌دهنده همدوسی بالاست. در تصاویر همدوسی، مناطق ساخته شده و بدون تغییر معمولاً مقادیر بالایی دارند؛ در مقابل، مناطقی نظیر پوشش گیاهی و پهنه‌های آبی که در طول زمان به شدت پویا هستند و تغییرات زیادی دارند، دارای مقادیر همدوسی به مراتب پایین‌تری‌اند (Holzer & Galloway, 2005). به‌طور کلی، مراحل پردازش InSAR در این مطالعه، به‌منظور تولید تصاویر همدوسی چندزمانه، این‌گونه است:

- دانلود سری زمانی یک‌ساله‌ای (از اکتبر ۲۰۱۸ تا نوامبر ۲۰۱۹) از تصاویر SAR-SLC، دارای اطلاعات فاز ماهواره سنتینل-۱A (حالت تصویربرداری IW) پوشش‌دهنده منطقه مورد مطالعه؛

می‌شود. هریک از زیرنوارها از تعدادی Burst تشکیل شده است و در نهایت، هریک از این Burstها به صورت تصویری مجزا پردازش می‌شود. تصاویر برداشت شده از طریق حالت IW، پس از اعمال پردازش‌هایی در قالب محصولات سطح یک SLC، در دو قطبش VV و VH ارائه می‌شوند که مقادیر فاز و دامنه را در برمی‌گیرند و برای اهداف InSAR مناسب‌اند (Soleimani et al., 2021).

در این مطالعه، سری زمانی یک‌ساله‌ای (پوشش‌دهنده سال زراعی ۲۰۱۹) از طریق سایت مرکز دسترسی آزاد کوپرنیک سازمان فضایی اروپا^۱ بارگیری شد. این مجموعه شامل ۳۲ تصویر SAR ماهواره سنتینل-۱A، مربوط به شماره برش^۲ ۱۸، مسیر^۳ ۱۰۱ و گذر صعودی/بالارو^۴ در بازه زمانی ۱۵ اکتبر ۲۰۱۸ تا ۱۰ نوامبر ۲۰۱۹ می‌شد.

در اینجا با توجه به موقعیت منطقه مورد مطالعه، تصاویر مربوط به زیرنوار IW2 برای پردازش InSAR مد نظر قرار گرفت تا بدین ترتیب حجم و زمان محاسبات کاهش یابد. مطالعات گذشته درباره بهره‌گیری از اطلاعات همدوسی InSAR به منظور نقشه‌برداری نوع محصول زراعی، بر کارایی مؤثرتر تصاویر مربوط به قطبش VV، در زمینه تفکیک محصولات زراعی، تأکید داشته‌اند (Mestre-Quereda et al., 2020). براین اساس، در مطالعه حاضر نیز، باندهای راداری با قطبش VV در سری زمانی تصاویر، به منظور پردازش استفاده شدند.

۳-۲- تکنیک InSAR و محاسبه همدوسی

تکنیک InSAR از فناوری‌های سنجش‌ازدوری و مبتنی بر تلفیق داده‌های SAR اخذ شده از یک منطقه در زمان‌های متفاوت است. تصاویر تکراری SAR را می‌توان برای تشخیص تغییرات ایجاد شده در سطح زمین، مانند حرکت یا تغییر ارتفاع، به کار برد (Soleimani et al., 2021). این تصاویر اغلب در ارزیابی کیفیت تداخل‌نگاشت تولید شده به کار می‌روند و به صورت رابطه (۱) نشان داده می‌شود.

1. European Space Agency Copernicus Open Access Hub (<https://scihub.copernicus.eu/>)
2. Slice Number
3. Track
4. Ascending
5. Expectation Operator
6. Complex
7. Co-Registered
8. Kernel

- انتخاب زوج تصاویر مبنا^۱ و پیرو^۲ به صورت زنجیره‌وار
(با تفکیک زمانی دوازده‌روزه و حداکثر طول خط‌مبنای مکانی ۲۰۰ متر)، به منظور محاسبه سری زمانی همدوسی InSAR (جدول ۱ و شکل ۳):

جدول ۱. شبکه زوج تصاویر انتخابی به صورت زنجیره‌وار (تفکیک زمانی دوازده‌روزه، به منظور محاسبه سری زمانی همدوسی InSAR با استفاده از تصاویر گذر صعودی ماهواره سنتینل-۱A در شماره برش ۱۸، مسیر ۱۰۱ و قطبش VV (تعداد تصاویر مورد استفاده: ۳۲؛ تعداد تصاویر همدوسی تولیدشده: ۳۱)

شماره زوج تصویر	بازه زمانی	خط‌مبنای مکانی (متر)	شماره زوج تصویر	بازه زمانی	خط‌مبنای مکانی (متر)
۱	۲۰۱۸/۱۰/۱۵ تا ۲۰۱۸/۱۰/۲۷	-۱۲۵/۸۹	۱۷	۲۰۱۹/۰۴/۲۵ تا ۲۰۱۹/۰۵/۰۷	-۱۹۶/۹۷
۲	۲۰۱۸/۱۰/۲۷ تا ۲۰۱۸/۱۱/۰۸	-۸۱/۸۴	۱۸	۲۰۱۹/۰۵/۰۷ تا ۲۰۱۹/۰۵/۱۹	-۳۲/۸۶
۳	۲۰۱۸/۱۱/۰۸ تا ۲۰۱۸/۱۱/۲۰	-۴۹/۴	۱۹	۲۰۱۹/۰۵/۱۹ تا ۲۰۱۹/۰۵/۳۱	-۵۹/۱۸
۴	۲۰۱۸/۱۱/۲۰ تا ۲۰۱۸/۱۲/۰۲	-۲۷/۲۷	۲۰	۲۰۱۹/۰۵/۳۱ تا ۲۰۱۹/۰۶/۱۲	-۱۰۲/۹۸
۵	۲۰۱۸/۱۲/۰۲ تا ۲۰۱۸/۱۲/۱۴	۹/۶۶	۲۱	۲۰۱۹/۰۶/۱۲ تا ۲۰۱۹/۰۶/۲۴	-۹۵/۸۱
۶	۲۰۱۸/۱۲/۱۴ تا ۲۰۱۸/۱۲/۲۶	-۶۳/۲۳	۲۲	۲۰۱۹/۰۶/۲۴ تا ۲۰۱۹/۰۷/۰۶	۳۹/۵۹
۷	۲۰۱۸/۱۲/۲۶ تا ۲۰۱۹/۰۱/۰۷	-۱۰۷/۶۲	۲۳	۲۰۱۹/۰۷/۰۶ تا ۲۰۱۹/۰۷/۱۸	۱۰/۲۷
۸	۲۰۱۹/۰۱/۰۷ تا ۲۰۱۹/۰۱/۱۹	-۳۲/۸۸	۲۴	۲۰۱۹/۰۷/۱۸ تا ۲۰۱۹/۰۷/۳۰	۱۶/۴۹
۹	۲۰۱۹/۰۱/۱۹ تا ۲۰۱۹/۰۱/۳۱	-۲۰/۸۴	۲۵	۲۰۱۹/۰۷/۳۰ تا ۲۰۱۹/۰۸/۱۱	۱۱۹/۶۴
۱۰	۲۰۱۹/۰۱/۳۱ تا ۲۰۱۹/۰۲/۱۲	-۳۳/۹۷	۲۶	۲۰۱۹/۰۸/۱۱ تا ۲۰۱۹/۰۸/۲۳	۱۹/۷۳
۱۱	۲۰۱۹/۰۲/۱۲ تا ۲۰۱۹/۰۲/۲۴	-۴۲/۱۸	۲۷	۲۰۱۹/۰۸/۲۳ تا ۲۰۱۹/۰۹/۰۴	-۴۴/۱۴
۱۲	۲۰۱۹/۰۲/۲۴ تا ۲۰۱۹/۰۳/۰۸	۱۸/۲۱	۲۸	۲۰۱۹/۰۹/۰۴ تا ۲۰۱۹/۰۹/۱۶	-۹۴/۳۸
۱۳	۲۰۱۹/۰۳/۰۸ تا ۲۰۱۹/۰۳/۲۰	-۵۳/۷۱	۲۹	۲۰۱۹/۰۹/۱۶ تا ۲۰۱۹/۰۹/۲۸	-۳۲/۳۲
۱۴	۲۰۱۹/۰۳/۲۰ تا ۲۰۱۹/۰۴/۰۱	-۵۵/۸۳	۳۰	۲۰۱۹/۰۹/۲۸ تا ۲۰۱۹/۱۰/۱۰	-۴۷/۵۷
۱۵	۲۰۱۹/۰۴/۰۱ تا ۲۰۱۹/۰۴/۱۳	۱۲/۴۵	۳۱	۲۰۱۹/۱۰/۱۰ تا ۲۰۱۹/۱۰/۲۲	-۳۷/۴۲
۱۶	۲۰۱۹/۰۴/۱۳ تا ۲۰۱۹/۰۴/۲۵	-۱۰۶/۷۷			

1. Master

2. Slave


ارتفاعی رقومی (DEM)^۲ ماهواره SRTM، با قدرت تفکیک فضایی ۳۰ متر و تهیه پشته^۳ از آن‌ها (Back-Geocoding)؛

(۵) اعمال شاخص تنوع طیفی بهبودیافته (ESD)^۴ به منظور ارتقای کیفیت تصاویر همدوسی در هنگام ادغام Burstها (Enhanced-Spectral-Diversity)؛


(۶) محاسبه همدوسی InSAR بین تصاویر مینا و پیرو، با استفاده از رابطه (۲) و انجام دادن عملیات multi-looking برای کاهش نویز اسپکل^۵ و تولید پیکسل‌های مربعی شکل از طریق تعریف کرنل با ابعاد ۱۰ پیکسل، در راستای

• ساخت مدل گراف در نرم‌افزار SNAP، به منظور اتوماتیک‌سازی مراحل پردازش زوج تصاویر SAR (شکل ۴):

- (۱) فراخوانی تصاویر مینا و پیرو (Read)؛
- (۲) جداسازی IW-2 پوشش‌دهنده منطقه مورد مطالعه، به منظور کاهش حجم و زمان پردازش (TOPSAR-Split)؛
- (۳) بارگیری و اضافه کردن داده‌های مداری دقیق متناظر با تصاویر مینا و پیرو (Apply-Orbit-File)؛
- (۴) ثبت هندسی ۱ تصویر پیرو براساس تصویر مینا، با استفاده از داده‌های مداری دقیق و مدل



شکل ۳. تغییرات خط‌مبنای مکانی زوج تصاویر مورد استفاده برای پردازش سری زمانی تصاویر همدوسی InSAR در بازه زمانی ۲۰۱۸/۱۰/۱۵ تا ۲۰۱۹/۱۰/۲۲ ناشی از حرکات مداری ماهواره سنتینل-۱A در گذر صعودی. هر نقطه در نمودار بیانگر یک زوج تصویر SAR است که با شماره‌های ۱ تا ۳۱ نمایش داده شده‌اند (بازه زمانی مربوط به زوج تصاویر در جدول ۱ بیان شده است)



شکل ۴. مدل گراف ساخته‌شده در نرم‌افزار SNAP، به منظور اتوماتیک‌سازی مراحل پردازش جفت تصاویر راداری ماهواره سنتینل-۱A برای محاسبه سری زمانی تصاویر همدوسی InSAR

1. Coregistration
2. Digital Elevation Model
3. Stack
4. Enhanced Spectral Diversity
5. Speckle

ماشین، حریمی ده‌متری برای مرز قطعات زراعی در نظر گرفته می‌شود (از مرز قطعات به سمت داخل) تا از وجود پیکسل‌های مخلوط، در نمونه‌های به دست آمده از مزارع هم‌جوار شامل محصولات زراعی ناهمسان، در تصاویر همدوسی جلوگیری شود. درمورد مزارع هم‌جوار شامل محصولات زراعی همسان، حریم نام‌برده در نظر گرفته نمی‌شود. سپس درمجموع، ۱۵۶۰۲۶ پیکسل از تصاویر همدوسی، به منزله نمونه، از قطعات زراعی متفاوت برداشت و به صورت تصادفی به سه دسته، شامل نمونه‌های آموزشی (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمایشی (۱۵٪) تفکیک می‌شود (جدول ۲).

برای نقشه‌برداری نوع محصول زراعی با استفاده از رویکردهای طبقه‌بندی تصاویر ماهواره‌ای، آگاهی از تقویم زراعی منطقه ضرورت دارد. تقویم زراعی نتیجه تجربیات کشاورزان، در طول زمان و منبعی مورد استناد برای آگاهی از زمان کاشت و رویش و برداشت هر محصول است و در این مطالعه، با بهره‌گیری از دانش کشاورزان محلی به دست آمد. در شکل ۶، تقویم زراعی محصولات مورد بررسی ارائه شده است.

۲-۵- انتخاب ویژگی و بررسی پاسخ فنولوژیکی

محصولات زراعی به همدوسی InSAR

از آنجاکه ممکن است تمامی تصاویر همدوسی چندزمانه تولیدشده دربردارنده اطلاعاتی ارزشمند در زمینه تفکیک محصولات زراعی نباشند، انتخاب بازه زمانی مناسب برای استفاده از این تصاویر در الگوریتم‌های طبقه‌بندی‌کننده ضرورت می‌یابد تا حجم پردازش کاهش پیدا کند. بدین منظور، مقادیر میانگین همدوسی محصولات زراعی متفاوت در سری زمانی یک‌ساله، برای تولید نمودار چرخه فنولوژی آن‌ها، استخراج می‌شود. به منظور پرهیز از خطاهای احتمالی مانند اختلاط مزارع هم‌جوار و همچنین پیکسل‌های مخلوط،

فاصله مایل $3 \times$ پیکسل در راستای آزیموت، براساس فاصله پیکسل‌های^۱ تصویر در دو راستای فاصله مایل (۲/۳۲ متر) و آزیموت (۱۳/۹۳ متر) راداری (Coherence)؛

۷) ادغام Burstها در تصویر همدوسی محاسبه‌شده به منظور ایجاد تصویر یکنواخت، با استفاده از داده‌های خروجی مراحل ۵ و ۶ (TOPSAR-Deburst)؛

۸) زمین مرجع کردن^۲ و انتقال تصاویر همدوسی تولیدشده براساس مختصات فاصله مایل و آزیموت راداری به مختصات جغرافیایی زمینی، با استفاده از DEM، به منظور تولید تصاویر با اندازه پیکسل مربعی تقریباً ۱۲/۸۲ متر (Terrain-Correction)؛

۹) خروجی گرفتن از تصاویر همدوسی تولیدشده در فرمت‌های رایج (مانند geotiff و hdr) به منظور استفاده در نرم‌افزارهای پردازش تصویر (Write).


• برش زدن منطقه مورد مطالعه از تصاویر همدوسی چندزمانه InSAR محاسبه‌شده، برای استفاده در الگوریتم‌های طبقه‌بندی‌کننده، به منزله ویژگی یا متغیر ورودی.

۲-۴- داده‌های میدانی نوع محصول زراعی

در راستای هدف مطالعه حاضر، محدوده قطعات مزارع زیرکشت انواع محصولات زراعی غالب در منطقه مورد مطالعه که با استفاده از نقشه‌برداری میدانی برداشت شده است، متعلق به سال زراعی ۱۳۹۸ (۲۰۱۹ میلادی)، به دست آمد (شکل ۵). درمجموع، ۱۳۵۸ قطعه زمین زراعی با حداکثر، میانگین و حداقل مساحت، به ترتیب ۱۳، ۱ و ۰/۱ هکتار استفاده شد. در این قطعات زراعی، نه محصول غالب و متنوع در منطقه شامل یونجه، جو، لوبیا، ذرت، باقلا، کتان، سیب‌زمینی، چغندر قند و گندم کشت می‌شود. به منظور برداشت نمونه‌های آموزشی و اعتبارسنجی و آزمایش، برای اجرای روش طبقه‌بندی تصویر مبتنی بر یادگیری

1. Pixel Spacing

2. Geocoding




شکل ۵. توزیع مکانی قطعات مزارع در منطقه مورد مطالعه؛ به کاررفته با هدف دریافت نمونه‌های آموزشی، اعتبارسنجی و آزمایشی

در نهایت، با در نظر گرفتن تقویم زراعی منطقه (شکل ۶)، بازه زمانی مناسب برای ورود تصاویر همدوسی به‌منزله ویژگی به الگوریتم طبقه‌بندی‌کننده، انتخاب می‌شود.

در قطعات زراعی مربوط به محصولات گوناگون، پلی‌گون‌های مستطیلی دربرگیرنده چندین پیکسل به‌منزله نمونه، از وسط قطعات لحاظ می‌شوند.

جدول ۲. تعداد نمونه‌های آموزشی (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمایشی (۱۵٪) به تفکیک محصولات زراعی متفاوت

کلاس زراعی	آموزش	اعتبارسنجی	آزمایش	جمع کل
پونجه	۱۳۲۶۹	۲۸۴۳	۲۸۴۳	۱۸۹۵۶
جو	۴۹۹۷	۱۰۷۱	۱۰۷۱	۷۱۳۹
لوبیا	۱۰۶۳۹	۲۲۸۰	۲۲۸۰	۱۵۱۹۹
ذرت	۴۰۷۵	۸۷۳	۸۷۳	۵۸۲۲
باقلا	۳۸۶۲	۸۲۸	۸۲۸	۵۵۱۷
کتان	۹۴۳۳	۲۰۲۱	۲۰۲۱	۱۳۴۷۶
سیب‌زمینی	۲۲۱۲۱	۴۷۴۰	۴۷۴۰	۳۱۶۰۲
چغندر قند	۱۱۸۹۶	۲۵۴۹	۲۵۴۹	۱۶۹۹۴
گندم	۲۸۹۲۴	۶۱۹۸	۶۱۹۸	۴۱۳۲۰
جمع کل	۱۰۹۲۱۸	۲۳۴۰۴	۲۳۴۰۴	۱۵۶۰۲۶



شکل ۶. تقویم زراعی محصولات مورد بررسی در منطقه مورد مطالعه

بالاتر انتقال می‌یابند؛ این مسئله بهبود فرایند تفکیک‌پذیری را در پی دارد و ابرصفحه جداکننده نیز در آن فضا تعیین می‌شود (Ren et al., 2018). جزئیات بیشتر در مورد مبانی ریاضی این طبقه‌بندی‌کننده را می‌توان در پژوهش جو و بلومبرگ^۱ (۲۰۰۲) یافت.

در مورد طبقه‌بندی‌کننده SVM، تعیین نوع کرنل و پارامترهای c (هزینه)^۲ و گاما^۳ در عملکرد مدل تأثیرگذارند. در اینجا، رویکرد جست‌وجوی شبکه‌ای^۴ مبتنی بر اعتبارسنجی متقابل^۵، برای یافتن بهترین ترکیب پارامترهای c و گاما به کار می‌رود. بهره‌گیری از تکنیک اعتبارسنجی متقابل سبب جلوگیری از ایجاد مشکل بیش‌برازش^۶ مدل می‌شود (Lin et al., 2008). در روش جست‌وجوی شبکه‌ای، مقادیر بهینه ترکیب پارامترهای c و گاما، براساس تعیین مقدار حداقل (کران پایین)، مقدار حداکثر (کران بالا) و تعداد مراحل یا سطوح در دامنه عددی مشخصی، یافته می‌شوند. دامنه عددی دقیقی برای مقادیر پارامترهای c و گاما وجود ندارد. باین‌حال، چنانچه دامنه وسیع‌تری در نظر گرفته شود، احتمال اینکه روش جست‌وجوی شبکه‌ای بتواند بهترین مقدار را برای پارامترهای ترکیبی بیابد، بیشتر می‌شود (Syarif et al., 2016). ازدیگرسو برای تعیین توالی گام‌های تغییر مقادیر پارامترها در دامنه عددی مورد نظر، مقیاس‌های گوناگونی همچون خطی و لگاریتمی به کار می‌رود. همان‌طور که مطالعات پیشین تأکید کرده‌اند، در نظر گرفتن تغییرات نمایی در توالی مقادیر پارامترها، مبتنی بر مقیاسی لگاریتمی، مناسب‌تر است (Hsu et al., 2003). براین‌اساس دامنه عددی نسبتاً وسیعی، از ۰/۱ تا ۱۰۰، در ده سطح با مقیاس لگاریتمی، به منظور اجرای روش جست‌وجوی شبکه‌ای در نظر گرفته می‌شود. با استفاده از تکنیک

در حالت ایدئال، چنانچه حرکات جابه‌جایی زمین برآثر زلزله، فرونشست و زمین‌لغزش رخ نداده باشد، انتظار می‌رود مناطق ساخته‌شده در گذر زمان، سیگنال‌های فاز و به تبع آن، رفتار همدوسی راداری نسبتاً ثابتی داشته باشند. ازدیگرسو انتظار این است که محصولات زراعی، در مراحل ابتدایی فصل رویش، رفتار همدوسی مشابه با خاک لخت داشته باشند (همدوسی نسبتاً بالا) و با آغاز رویش و متراکم شدن آن‌ها، مقدار همدوسی کاهش یابد. در پایان فصل رشد و هنگام برداشت محصولات نیز قاعداً افزایش مقادیر همدوسی و بار دیگر میل به رفتار همانند خاک لخت را می‌توان در مزارع انتظار داشت. براین‌اساس، برای کسب اطمینان از پاسخ فنولوژیکی محصولات زراعی به داده‌های همدوسی InSAR و همچنین مطمئن بودن این داده‌ها در بازه زمانی انتخابی، رفتار همدوسی آن‌ها در قیاس با مناطق ساخته‌شده و خاک لخت، بررسی می‌شود. محدوده‌های شاهد انتخابی بدین منظور، شامل منطقه ساخته‌شده (سقف سالن‌های یک مرغداری، واقع در شمال شرق منطقه مورد مطالعه)، خاک لخت (زمینی بایر و بدون پوشش گیاهی، در مجاورت کارخانه لاستیک‌سازی گلدستون در نواحی غربی منطقه مورد مطالعه) و قطعه‌های برداشت‌شده از مزارع به تفکیک محصولات است (شکل ۷). سپس مقادیر آماره میانگین همدوسی در محدوده‌های شاهد، به صورت سری زمانی، استخراج و مبنای بررسی قرار می‌گیرد.

۲-۶- طبقه‌بندی تصویر

SVM نظریه‌ای در زمینه یادگیری آماری است و اغلب برای مسائل طبقه‌بندی استفاده می‌شود زیرا هدف اصلی این الگوریتم پیدا کردن بیشترین فاصله میان دو طبقه/کلاس و در نتیجه، افزایش صحت طبقه‌بندی است (Vapnik, 1995). الگوریتم SVM یک طبقه‌بندی‌کننده نرم محسوب می‌شود و توانایی غلبه بر مشکل توزیع غیرخطی داده‌ها را دارد. در این حالت، با بهره‌گیری از توابع کرنل، داده‌ها به فضایی با ابعاد

1. Zhu & Blumberg
2. Cost
3. Gamma
4. Grid Search
5. Cross Validation
6. Overfitting




خاک لخت



منطقه ساخته شده



مزرعه لوبیا



مزرعه جو



مزرعه یونجه



مزرعه کتان



مزرعه باقلا



مزرعه ذرت



مزرعه گندم



مزرعه چغندرقد



مزرعه سیب زمینی

شکل ۷. محدوده‌های شاهد انتخابی (پلی گون قرمز) از منطقه مورد مطالعه، به منظور بررسی پاسخ فنولوژیکی محصولات زراعی به همدوسی InSAR

در این مطالعه، صحت کلی^۶ و ضریب کاپای به‌دست‌آمده از ماتریس خطا، به‌منزله معیارهای ارزیابی عملکرد کلی طبقه‌بندی، و صحت کاربر^۷ و صحت تولیدکننده^۸ نیز به‌منظور ارزیابی عملکرد مدل در کلاس‌های متفاوت به کار می‌رود.


۳- نتایج

۳-۱- انتخاب بازه زمانی مناسب برای انتخاب ویژگی مطابق شکل ۸، بازه زمانی ۲۰ مارس تا ۱۰ اکتبر ۲۰۱۹ (۲۹ اسفند ۱۳۹۷-۱۸ مهر ۱۳۹۸) برای تعیین نوع محصولات زراعی در منطقه مورد مطالعه، مد نظر قرار گرفت. این بازه انتخابی پوشش‌دهنده تمامی محصولات زراعی، از نظر زمان رویش تا برداشت است. طبق جدول ۱، در این بازه زمانی هفده تصویر همدوسی استفاده می‌شود که شامل زوج تصاویر شماره ۱۴ تا ۳۰ هستند.

اعتبارسنجی متقابل به‌ازای مقادیر متفاوت پارامترهای c و γ ، ابتدا داده‌ها به k زیرمجموعه تقسیم می‌شوند (در بیشتر مطالعات، $k=10$). سپس طی فرایندی جایگشتی، n زیرمجموعه برای آموزش و یک زیرمجموعه برای اعتبارسنجی مدل استفاده می‌شود (Syarif et al., 2016). بدین ترتیب میانگین صحت کلی در تکرارهای متوالی اعتبارسنجی متقابل، برای ارزیابی نتایج و انتخاب پارامترهای بهینه، به کار می‌رود. این فرایند به‌تفکیک کرنل‌های گوناگون SVM، شامل خطی^۱، چندجمله‌ای^۲، تابع پایه شعاعی (RBF)^۳ و سیگموئید^۴ انجام می‌شود.

۲-۷- ارزیابی صحت

ماتریس خطا^۵ یکی از روش‌های استاندارد در ارزیابی عملکرد و صحت مدل‌های طبقه‌بندی است. این ماتریس براساس رابطه بین نمونه‌های کنترل زمینی و تصویر طبقه‌بندی‌شده محاسبه می‌شود (Stehman et al., 2007).



شکل ۸. مقادیر میانگین همدوسی به‌تفکیک نمونه‌های محصولات زراعی متفاوت در منطقه مورد مطالعه، طی بازه زمانی ۱۵ اکتبر ۲۰۱۸ (۲۳ مهر ۱۳۹۷) تا ۱۰ اکتبر ۲۰۱۹ (۱۸ مهر ۱۳۹۸)


1. Linear
2. Polynomial
3. Radial Basis Function
4. Sigmoid
5. Confusion Matrix
6. Overall Accuracy
7. User's Accuracy
8. Producer's Accuracy

برای کسب اطمینان از پاسخ فنولوژیکی محصولات زراعی مبتنی بر همدوسی InSAR، رفتار همدوسی آن‌ها در قیاس با رفتار مناطق ساخته‌شده و خاک لخت در محدوده‌های شاهد (شکل ۷)، طی بازه زمانی انتخابی، بررسی شد. به دلیل تنوع محصولات زراعی از لحاظ دوره‌های کاشت و رویش و برداشت، برای استخراج فنولوژی مبتنی بر تصاویر چندزمانه همدوسی و تحلیل پذیرتر کردن اطلاعات، محصولات براساس دوره رویش تا برداشت و مطابق با جدول ۳، به چهار دسته تفکیک شدند. در ادامه، رفتار فنولوژیکی محصولات در قیاس با سیگنال‌های به‌دست‌آمده از مناطق


ساخته‌شده و خاک لخت، طی دوره‌های رویش تا برداشت، استخراج شد (شکل‌های ۹ تا ۱۲). همان‌طور که نتایج نشان می‌دهد، در بازه زمانی انتخابی، سیگنال‌های فنولوژیکی محصولات مورد بررسی با سیگنال‌های مناطق ساخته‌شده و خاک لخت اختلاطی ندارند. افزون‌براین، روند تغییرات زمانی سیگنال‌های همدوسی محصولات زراعی متفاوت در پاسخ به تغییرات فنولوژیکی آن‌ها، الگوی نسبتاً متفاوتی نشان می‌دهد. این نکته مهم حاکی از کارایی و مطمئن بودن داده‌های همدوسی InSAR برای استفاده در الگوریتم طبقه‌بندی نوع محصول زراعی است.

جدول ۳. دسته‌بندی محصولات زراعی براساس زمان رویش و برداشت، به‌منظور سهولت بررسی پاسخ فنولوژیکی به همدوسی InSAR


دسته	نام محصول	زمان کشت	زمان رویش	زمان برداشت	از رویش تا برداشت - تعداد ماه
۱	جو			نیمه اول مرداد	اول فروردین تا آخر مرداد (نیمه دوم مارس تا نیمه دوم اوت) - پنج ماه
	گندم	نیمه اول آبان	نیمه اول فروردین	نیمه دوم مرداد	
	کتان	نیمه اول فروردین	نیمه اول اردیبهشت	نیمه دوم مرداد	اول اردیبهشت تا آخر شهریور (نیمه دوم آوریل تا نیمه دوم سپتامبر) - پنج ماه
	لوبیا	نیمه دوم فروردین	نیمه دوم اردیبهشت	نیمه اول شهریور	
۲	باقلا	نیمه دوم فروردین	نیمه اول خرداد	نیمه اول مرداد	
	سیب‌زمینی	نیمه دوم فروردین	نیمه اول خرداد	نیمه دوم شهریور	
	چغندر قند	نیمه دوم فروردین	نیمه دوم اردیبهشت	نیمه دوم مهر تا نیمه اول آبان	نیمه دوم اردیبهشت تا نیمه اول آبان (نیمه اول مه تا نیمه اول نوامبر) - شش ماه
	ذرت	نیمه دوم فروردین تا نیمه اول خرداد	نیمه اول تیر	مهر	
۳	یونجه	فروردین	نیمه دوم اردیبهشت	- نیمه دوم خرداد تا نیمه اول مهر - نیمه دوم مرداد تا نیمه اول مهر - نیمه اول اکتبر - پنج ماه	




شکل ۹. مقادیر میانگین هم‌دوسی InSAR در محدوده‌های شاهد انتخابی از منطقه ساخته‌شده، خاک لخت و مزارع جو و گندم (دسته‌بندی ۱ در جدول ۳)



شکل ۱۰. مقادیر میانگین هم‌دوسی InSAR در محدوده‌های شاهد انتخابی از منطقه ساخته‌شده، خاک لخت و مزارع لوبیا، باقلا، کتان و سیب‌زمینی (دسته‌بندی ۲ در جدول ۳)



شکل ۱۱. مقادیر میانگین هم‌دوسی InSAR در محدوده‌های شاهد انتخابی از منطقه ساخته‌شده، خاک لخت و مزارع ذرت و چغندر (دسته‌بندی ۳ در جدول ۳)



شکل ۱۲. مقادیر میانگین همدوسی InSAR در محدوده‌های شاهد انتخابی از منطقه ساخته شده، خاک لخت و مزرعه پونجه (دسته‌بندی ۴ در جدول ۳)

۲-۳- تفکیک نوع محصول زراعی مبتنی بر همدوسی InSAR

۱-۲-۳- بهینه‌سازی پارامترهای طبقه‌بندی‌کننده SVM و انتخاب کرنل

درمورد طبقه‌بندی‌کننده SVM، ترکیب متفاوت پارامترهای c و γ ، به تفکیک کرنل‌های گوناگون، در قالب مرحله اعتبارسنجی بررسی شد. بدین ترتیب برای هر یک از کرنل‌های SVM، ترکیب بهینه پارامترها که بیشترین میزان صحت کلی را به دست داده‌اند، در جدول ۴ آمده است. کرنل خطی فاقد پارامتر γ است؛ به همین دلیل فرایند جست‌وجوی شبکه‌ای برای آن به صورت تک‌بعدی انجام شده است. همان‌طور که نتایج نشان می‌دهد، کرنل تابع پایه شعاعی بیشترین میزان صحت کلی را با ترکیب متفاوتی از پارامترهای c و γ به دست داده است. بدین ترتیب، برای اجرای نهایی طبقه‌بندی‌کننده SVM در مرحله آزمایش، از کرنل RBF مبتنی بر ضرایب بهینه مشخص شده در جدول ۴ استفاده شد.

۲-۲-۳- ارزیابی عملکرد نقشه نوع محصول زراعی


در اینجا، نتایج اجرای الگوریتم طبقه‌بندی‌کننده SVM با استفاده از ویژگی‌های انتخابی (زوج تصاویر همدوسی شماره ۱۴ تا ۳۰ در جدول ۱) و پارامترهای بهینه مطرح شده است. برای ارزیابی صحت نقشه نوع محصول تولیدشده، از نمونه‌های آزمایشی بهره گرفته شد. شایان ذکر است که این نمونه‌ها در هیچ یک از مراحل مدل‌سازی، اعتبارسنجی و بهینه‌سازی پارامترها استفاده نشده‌اند. در جدول ۵، آماره‌های ارزیابی صحت نقشه نوع محصول تولیدشده، با استفاده از طبقه‌بندی‌کننده SVM بیان شده است. با به کارگیری ویژگی‌های همدوسی و براساس ضرایب و کرنل بهینه، این الگوریتم صحت کلی ۶۰٫۶٪ را نشان می‌دهد که بهترین عملکرد را در شناسایی گندم و بدترین را درمورد پونجه داشته است (جدول ۵). شکل ۱۳ نقشه نوع محصول تولیدشده را نمایش می‌دهد.

جدول ۴. ترکیب بهینه پارامترهای c و γ در کرنل‌های متفاوت (سطر تیره بیانگر بیشترین صحت و به تبع آن، بهترین ترکیب پارامترها و کرنل است)

نوع کرنل	پارامترهای بهینه		صحت کلی (%)
	γ	c	
خطی	---	۱۲٫۹۲	۵۷٫۲۰
چندجمله‌ای	۰٫۰۷	۴٫۶۴	۵۸٫۳۵
تابع پایه شعاعی	۰٫۲۱	۴٫۶۴	۵۹٫۶۹
سیگموئید	۰٫۰۱	۱۲٫۹۲	۵۲٫۲۰

جدول ۵. نتایج نقشه‌برداری نوع محصول زراعی با استفاده از طبقه‌بندی کننده SVM

کلاس‌های زراعی	خطای Omission (%)	صحت تولیدکننده (%)	خطای Commission (%)	صحت کاربر (%)
یونجه	۲۷٫۴	۷۲٫۶	۵۷	۴۳
جو	۱۰٫۶	۸۹٫۴	۵۷٫۶	۴۲٫۴
لوبیا	۲۹٫۳	۷۰٫۷	۵۱٫۵	۴۸٫۵
ذرت	۴٫۱	۹۵٫۹	۶۴٫۹	۳۵٫۱
باقلا	۳٫۶	۹۶٫۴	۶۳٫۹	۳۶٫۱
کتان	۲۵٫۴	۷۴٫۶	۵۱٫۵	۴۸٫۵
سیب‌زمینی	۴۸٫۳	۵۱٫۷	۲۸٫۷	۷۱٫۳
چغندر	۳۰٫۳	۶۹٫۷	۵۱٫۲	۴۸٫۸
گندم	۴۴٫۶	۵۵٫۴	۱۶	۸۴
صحت کلی (%)	۶۰٫۶			
ضریب کاپا (%)	۵۱٫۲			



شکل ۱۳. نقشه نوع محصول تولیدشده با الگوریتم طبقه‌بندی کننده SVM. کرنل RBF

۴- بحث

۴-۱- بررسی پاسخ فنولوژیکی محصولات زراعی

مبتنی بر همدوسی InSAR

شکل ۸ مقادیر میانگین همدوسی، به تفکیک نمونه‌های محصولات زراعی متفاوت را در منطقه مورد مطالعه، طی بازه زمانی ۱۵ اکتبر ۲۰۱۸ (۲۳ مهر ۱۳۹۷) تا ۱۰ اکتبر ۲۰۱۹ (۱۸ مهر ۱۳۹۸) نشان می‌دهد. طبق این شکل، در پایان (سمت راست نمودار) و آغاز (سمت چپ نمودار) سال زراعی، محصولات مورد بررسی، به ترتیب با کاهش و افزایش همدوسی مواجه بوده‌اند. افزایش همدوسی محصولات به دلیل نزدیک شدن به پایان دوره رشد، کاهش تغییرات فیزیکی و رسیدن به مرحله برداشت اتفاق افتاده است. در ادامه، کاهش و سپس افزایش همدوسی را می‌توان به برداشت محصولات و بایر بودن خاک مزارع نسبت داد. براین اساس بازه زمانی ۲۰ مارس تا ۱۰ اکتبر ۲۰۱۹ (۲۹ اسفند ۱۳۹۷ تا ۱۸ مهر ۱۳۹۸)، به منزله بازه زمانی مورد بررسی برای تعیین نوع محصولات زراعی با استفاده از داده‌های همدوسی InSAR در منطقه مورد مطالعه، مناسب تشخیص داده شده است. در بازه زمانی انتخابی، حداکثر تفکیک‌پذیری محصولات زراعی متفاوت مبتنی بر همدوسی چندزمانه InSAR مشاهده می‌شود. مطالعات اسدی و شمس‌الدینی^۱ (۲۰۲۴a, b) نیز در همین منطقه، با استفاده از داده‌های بازپراکنش راداری ماهواره سنتینل-۱، به شناسایی و تفکیک محصولات گوناگون شامل یونجه، گندم، جو، لوبیا، ذرت، باقلا، کتان، سیب‌زمینی و چغندر قند پرداخته است. این پژوهش نیز، زمان مناسب برای بررسی محصولات نام‌برده را براساس اطلاعات فنولوژیکی استخراج‌شده از تقویم زراعی منطقه و رسم سری زمانی NDVI^۲ تعیین کرده است. براساس نتایج این مطالعه، بازه زمانی مناسب برای بررسی محصولات از ۷ مه ۲۰۱۹ تا ۲۸ سپتامبر ۲۰۱۹ (۱۷ اردیبهشت ۱۳۹۸ تا ۶ مهر ۱۳۹۸) مشخص شده که به بازه زمانی انتخابی در پژوهش حاضر بسیار نزدیک است. بر همین اساس

می‌توان اذعان داشت که این مشابهت نتایج مطالعه حاضر درباره انتخاب بازه زمانی مناسب مبتنی بر همدوسی InSAR را برای مطالعه رفتار فنولوژیکی محصولات زراعی، تأیید می‌کند. تفاوت تقریبی پنجاه‌روزه، بین زمان آغاز دوره فنولوژیکی، در مطالعات اسدی و شمس‌الدینی (۲۰۲۴a, b) با تحقیق حاضر را می‌توان به تفاوت امکانات داده‌های همدوسی InSAR و داده‌های چندطیفی اپتیک نسبت داد. داده‌های همدوسی InSAR به دلیل حساسیت بالا به تغییرات فیزیکی سطح زمین، در قیاس با داده‌های بازپراکنش راداری و همچنین اپتیک، می‌توانند در تشخیص مراحل ابتدایی رشد گیاه و جوانه‌زنی، عملکرد بهتری داشته باشند (Nasirzadehdizaji, 2021).

مقایسه پاسخ فنولوژیکی محصولات زراعی مبتنی بر همدوسی InSAR (جدول ۳ و شکل‌های ۹ تا ۱۲)، با رفتار مناطق ساخته‌شده و خاک لخت در محدوده‌های شاهد (شکل ۷)، بر کارایی داده‌های همدوسی برای استفاده در الگوریتم طبقه‌بندی کننده صحنه می‌گذارد. طبق نتایج پژوهش جاثو و همکاران (۲۰۲۴)، میانگین مقادیر همدوسی InSAR برای محصولات برنج و ذرت در دوره‌های شخم‌زنی و کاشت، تحت تأثیر سیگنال‌های حاصل از خاک لخت، افزایش می‌یابد. پس از اتمام مراحل اولیه و آغاز مرحله رشد، امواج فاز راداری با گیاهان در تعامل قرار می‌گیرند و با ایجاد تغییرات فیزیکی و هندسی در برگ‌ها، سبب کاهش مقادیر همدوسی می‌شوند. در نهایت، با پایان دوره رشد و هم‌زمان با فرایند برداشت، امواج فاز راداری بار دیگر تحت تأثیر سیگنال‌های ناشی از خاک لخت قرار می‌گیرند و مقادیر همدوسی افزایش می‌یابد. براین اساس، با پایش تغییرات مقادیر همدوسی و انجام دادن ارزیابی‌های مناسب از مراحل کاشت و رشد و برداشت، می‌توان تأثیر عوامل مزاحم، مانند خاک لخت

1. Asadi & Shamsoddini

2. Normalized Difference Vegetation Index

بهتری داشته است (Forudikhor et al., 2010). نتایج مطالعات کاوزوگلو و کولکسن^۲ (۲۰۰۹) نیز نشان می‌دهد که طبقه‌بندی‌کننده SVM، با استفاده از کرنل RBF، صحت کلی بهتری دارد. خسروی^۳ (۲۰۲۴) نیز در مطالعه خود از کرنل RBF بهره برده و اذعان کرده است که این تابع از رایج‌ترین توابع کرنل در حوزه طبقه‌بندی داده‌های سنجش از دور است. انتخاب تابع کرنل SVM به نوع و ماهیت داده‌ها و مسئله بستگی دارد. عملکرد کرنل RBF در مسائل پیچیده بهتر است. هنگامی که در مورد نوع داده‌ها و ماهیت آن‌ها شناختی وجود ندارد و توزیع داده‌ها غیرخطی است، این تابع مقادیر بهینه را به خود اختصاص می‌دهد (Forudikhor et al., 2010).

۴-۳- کارایی تصاویر همدوسی و طبقه‌بندی‌کننده SVM و عوامل مؤثر در آن‌ها

نتایج مدل‌سازی با استفاده از ویژگی‌های انتخاب‌شده و پارامترهای بهینه، در مرحله آزمایش عملکرد مدل، در جدول ۵ آمده است. صحت کلی مدل‌سازی ۶۰/۶ است. مدل بهترین عملکرد را در شناسایی گندم و بدترین را در مورد یونجه داشته است. در این مطالعه، از تصاویر قطبش VV بهره گرفته‌ایم. احتمالاً ساختار عمودی گیاه گندم در این مسئله بی‌تأثیر نبوده و توانسته است، با موج ارسالی رادار در حالت عمودی، برهم‌کنش بیشتری نشان دهد (Villarroya-Carpio et al., 2022). دلیل عملکرد بهتر مدل در شناسایی گندم را می‌توان ناشی از این مورد دانست.

مطابق جدول ۵، صحت کاربر در مورد گیاهان گندم یا سیب‌زمینی، بیشتر و در مورد گیاهان ذرت و باقلا و یونجه، کمتر است. این مسئله ممکن است ناشی از تعداد نمونه‌های آموزشی هر محصول باشد. همان‌طور که در جدول ۲ آمده است، تعداد نمونه‌های آموزشی

و مناطق ساخته‌شده را شناسایی و از داده‌ها حذف کرد. در مطالعه حاضر نیز، نتایج کنترل رفتار فنولوژیکی چهار دسته از محصولات زراعی (جدول ۳) در قیاس با سیگنال‌های به‌دست‌آمده از مناطق ساخته‌شده و خاک لخت طی دوره‌های رویش تا برداشت محصولات (شکل‌های ۹ تا ۱۲)، نشان داد که منطقه ساخته‌شده دارای سیگنال نسبتاً ثابتی است و بین مقادیر همدوسی و مراحل فنولوژی محصولات زراعی در قیاس با خاک لخت نیز همبستگی خوبی وجود دارد. رفتار همدوسی در ابتدای دوره رشد، در مورد تمامی محصولات زراعی، نزدیک به رفتار خاک لخت است و با رویش و تکامل محصول و رسیدن به مرحله اوج رشد، تفاوت رفتار آن‌ها به حد اکثر می‌رسد. در پایان فصل رشد نیز رفتار همدوسی محصولات گوناگون به رفتار خاک لخت متمایل شده است. طبق شکل ۱۲، الگوی نوسانی در رفتار همدوسی یونجه به علت برداشت‌های متوالی و رویش مجدد این محصول است که به ترتیب، سبب افزایش و سپس کاهش مقادیر همدوسی شده است. در همین راستا نتایج مطالعات ویاو-کارپیو و همکاران (۲۰۲۲)، نصیری‌زاده دیزجی (۲۰۲۱)، بوسکی‌یر^۱ و همکاران (۲۰۲۰) و مستره-کیردا و همکاران (۲۰۲۰) نیز مؤید آن است که در مراحل رویشی اصلی محصولات زراعی، میزان همدوسی در بخش‌های گوناگون منطقه کمتر شده است و با نزدیک شدن به پایان فصل رشد و بایر شدن قطعات زراعی، شاهد افزایش میزان همدوسی هستیم.

۴-۲- انتخاب کرنل برای طبقه‌بندی‌کننده SVM

براساس نتایج ارائه‌شده در جدول ۴، کرنل تابع پایه شعاعی بیشترین میزان صحت کلی را با ترکیب متفاوت پارامترهای c و گاما، به دست داده و صحت کلی به‌دست‌آمده از این کرنل ۵۹/۶۹٪ است. کرنل سیگموئید، با ۵۳/۷۰٪ صحت کلی، کمترین میزان صحت کلی را داشته است. در کاربردهای مرتبط با طبقه‌بندی تصاویر ماهواره‌ای، کرنل RBF معمولاً نتایج

1. Busquier
2. Kavzoglu & Colkesen
3. Khosravi

درمورد گیاهان گندم و سیب‌زمینی، بیشتر و درمورد گیاهان ذرت و باقلا و یونجه، کمتر است. براین اساس می‌توان نتیجه گرفت که تعداد نمونه‌های آموزشی در عملکرد مدل تأثیر می‌گذارد و بیشتر بودن آن‌ها می‌تواند به بهبود صحت طبقه‌بندی بینجامد. در همین زمینه، همان‌طور که فو^۱ و همکاران (۲۰۲۳) در پی بررسی تأثیرات نمونه‌های آموزشی در صحت نقشه‌برداری نوع محصول، با الگوریتم‌های یادگیری ماشین بیان کرده‌اند، با افزایش تعداد نمونه‌های گندم، صحت نقشه‌برداری آن محصول بهبود می‌یابد. این مسئله را می‌توان یکی از دلایل پائین بودن صحت کلی طبقه‌بندی ویژگی‌های همدوسی نیز دانست. عملکرد ضعیف مدل، در کلاس‌هایی که نمونه‌های آموزشی کم بوده، به کاهش میزان صحت کلی مدل نیز منجر شده است.

یکی دیگر از دلایل احتمالی دربارهٔ پایین بودن صحت کلی طبقه‌بندی ویژگی‌های همدوسی را می‌توان اندک بودن تعداد آن‌ها برشمرد. در این مطالعه، به‌منظور ارزیابی کارایی تصاویر همدوسی چندزمانه InSAR، صرفاً از داده‌های SAR ماهواره سنتینل-۱A، مربوط به گذر صعودی و قطبش VV استفاده شد و از این راه، هفده ویژگی تولید شد. چنانچه از داده‌های قطبش VH و همچنین گذر نزولی نیز بهره گرفته شود، می‌توان تعداد ویژگی‌های استخراج‌شده را به حدوداً سه‌وینیم برابر (تا ۶۸ ویژگی) افزایش داد. به‌طبع، فرایند انتخاب ویژگی از بین ۶۸ مورد، در قیاس با فقط هفده ویژگی، می‌تواند اطلاعات بیشتر و مهم‌تری برای واردسازی به طبقه‌بندی‌کننده، به دست دهد. امهرت^۲ و همکاران (۲۰۲۲) نیز، در مطالعه‌ای با هدف نقشه‌برداری محصولات زراعی از طریق تکنیک تداخل‌سنجی راداری، تأکید داشته‌اند که بهره‌گیری ترکیبی از داده‌های SAR مربوط به قطبش‌های VV و VH سبب بهبود نتایج طبقه‌بندی می‌شود. البته اشاره به این نکته نیز الزامی است که بهره‌گیری از داده‌های SAR مربوط به قطبش‌های VV و VH و گذرهای صعودی و نزولی، حجم و زمان پردازش‌های InSAR را

حداقل تا چهاربرابر افزایش می‌دهد. علاوه‌براین، در مطالعه حاضر، تصاویر همدوسی از داده‌های SAR با تفکیک زمانی دوازده‌روزه تولید شده‌اند؛ به‌منظور افزایش تعداد ویژگی‌ها می‌توان از فاصله‌های زمانی طولانی‌تر، مانند ۲۴ و ۳۶ روزه نیز، استفاده کرد. البته باید در نظر داشت که افزایش فاصله زمانی بین تصاویر متوالی می‌تواند سبب غالب شدن تأثیرات ناشی از پویایی شرایط جوی بر ناهمبستگی زمانی فاز شود و بدین ترتیب، نتوان اطلاعات چندانی درمورد تغییرات فنولوژیکی محصولات زراعی به دست آورد. با آگاهی از این نکته و همچنین طبق دیدگاه‌های مستره- کِردا و همکاران (۲۰۲۰) در زمینه نقشه‌برداری نوع محصولات زراعی، چنانچه داده‌های سنتینل-۱A و B با تفکیک زمانی شش‌روزه در دسترس باشد، با ترکیب‌های شش، دوازده و حداکثر هجده‌روزه می‌توان تعداد ویژگی‌های بیشتری را به‌منظور طبقه‌بندی محصولات زراعی تولید کرد.

از آنجاکه داده‌های همدوسی بر مبنای تصاویر فاز رادار محاسبه می‌شوند، به ویژگی‌های فیزیکی پدیده‌ها حساس‌اند. بدین ترتیب ممکن است برخی محصولات زراعی گوناگون که دارای ویژگی‌های هندسی و فیزیکی مشابه‌اند، رفتار همدوسی مشابهی نشان دهند که این نکته مهم تفکیک آن‌ها را با مشکل مواجه می‌کند. بنابراین ضرورت بهره‌گیری از مجموعه داده‌های مکمل، در کنار این داده‌ها، احساس می‌شود. نتایج مطالعات مستره- کِردا و همکاران (۲۰۲۰)، جیکوب و همکاران (۲۰۲۰) و جو و همکاران (۲۰۱۷) نیز مؤید این مسئله است. داده‌های اپتیک از جمله مجموعه داده‌هایی هستند که می‌توان بدین‌منظور به کار برد. داده‌های چندطیفی اپتیک با دسترسی رایگان، به‌دلیل حساسیت در برابر ویژگی‌های شیمیایی عوارض، از طریق اندازه‌گیری رفتار طیفی آن‌ها اطلاعات ارزشمندی درمورد محصولات زراعی گوناگون به دست می‌دهند.

1. Fu

2. Amherdt

توسعه یافته‌اند که در زمینه‌های گوناگون، به‌ویژه نقشه‌برداری نوع محصول زراعی، کاربردی گسترده داشته‌اند؛ بنابراین توصیه می‌شود، برای افزایش صحت نقشه‌برداری محصولات زراعی، از روش‌های نوین به‌صورت مکمل بهره گرفته شود. نتایج مطالعات جیکوب و همکاران (۲۰۲۰) و اسدی و شمس‌الدینی (۲۰۲۴a, b) نیز مؤید استفاده مکمل از روش‌های نوین و افزایش صحت نقشه‌برداری محصولات زراعی است.

۵- نتیجه‌گیری

مطالعه پیش رو با هدف ارزیابی کارایی داده‌های همدوسی تداخل‌سنجی راداری، برای نقشه‌برداری نوع محصول زراعی مبتنی بر روش‌های یادگیری ماشین در دشت اردبیل، انجام شده است. بدین‌منظور از مجموعه زمانی یک‌ساله‌ای (۱۳۹۷-۱۳۹۸) شامل ۳۲ تصویر SAR از ماهواره سنیتل-۱A، برای تولید تصاویر همدوسی چندزمانه، استفاده شده است. با به‌کارگیری داده‌های میدانی نوع محصول زراعی در منطقه مورد مطالعه، شامل یونجه، جو، لوبیا، ذرت، باقلا، کتان، سیب‌زمینی، چغندر قند و گندم، مقادیر میانگین همدوسی این محصولات در قطعات مزارع گوناگون مرتبط با آن‌ها در سری زمانی محاسبه شد؛ هدف از این کار استخراج نمودار چرخه فنولوژی این محصولات بود. بازه زمانی ۲۰ مارس تا ۱۰ اکتبر ۲۰۱۹ (۲۹ اسفند ۱۳۹۷ تا ۱۸ مهر ۱۳۹۸)، که تمامی مراحل رشد تا برداشت محصولات زراعی مورد بررسی را پوشش می‌دهد، به‌منزله دوره زمانی مناسب برای ارزیابی امکانات داده‌های همدوسی InSAR انتخاب شد. این بازه زمانی شامل هفته تصویر همدوسی است که امکان تفکیک دقیق‌تر محصولات زراعی و بررسی رفتار فنولوژیکی آن‌ها را فراهم می‌کند. در ادامه، برای حصول اطمینان از ارتباط مقادیر همدوسی InSAR با مراحل فنولوژیکی محصولات زراعی مورد بررسی، رفتار زمانی سیگنال‌های همدوسی مربوط به هریک از محصولات زراعی نام‌برده، در قیاس با سیگنال‌های مناطق ساخته‌شده و خاک لخت

این اطلاعات در شناسایی و تفکیک آن‌ها بسیار کارآمد است و می‌تواند، در کنار تصاویر همدوسی InSAR، به افزایش صحت تفکیک محصولات زراعی کمک کند. درباره سایر مجموعه داده‌ها، مطالعات گذشته مانند پژوهش‌های مستره- کِردا و همکاران (۲۰۲۰)، ویارویا- کارپیو و همکاران (۲۰۲۲)، نصیری‌زاده دیزجی و همکاران (۲۰۲۱) بر کارایی داده‌های بازپراکنش راداری در قطبش‌های متفاوت، با هدف شناسایی محصولات زراعی، تأکید داشته‌اند. از این‌رو انتظار می‌رود تلفیق ویژگی‌های مستخرج از همدوسی InSAR و بازپراکنش راداری، در قطبش‌های گوناگون و گذرهای نزولی و صعودی، صحت طبقه‌بندی را تا حدی ارتقا دهد.

عواملی همچون اختلاف‌منظر سنجنده (خط‌مبنای مکانی)، توپوگرافی زمین (شیب و جهت) و فاصله زمانی بین تصاویر رادار در میزان اطلاعات قابل‌استخراج از داده‌های همدوسی مؤثر است. براین‌اساس ممکن است محصولات زراعی یکسان، در نواحی متفاوت، رفتار همدوسی متفاوتی داشته باشند که دقیقاً از ویژگی‌های فیزیکی آن‌ها ناشی نشود و درواقع، در یکی از عوامل نام‌برده منشأ داشته باشد. این مسئله، به‌طور کلی، به عملکرد تصادفی داده‌های همدوسی در شرایط محیطی متفاوت اشاره دارد که ممکن است ناشی از تفاوت در مناطق گوناگون، به‌علت تأثیرات ناهمبستگی مکانی و زمانی باشد. به‌منظور رفع این مسئله، توسعه شاخص‌های مبتنی بر سری زمانی تصاویر همدوسی InSAR که بتواند اطلاعاتی تکمیلی در زمینه این چالش به طبقه‌بندی‌کننده وارد کند، چه‌بسا راهگشا باشد (Ebrahimzadeh et al., 2023).

نوع و کارایی الگوریتم طبقه‌بندی تصویر نیز می‌تواند در میزان صحت نتایج نقش داشته باشد. طبقه‌بندی‌کننده SVM که در این مطالعه استفاده شد، از مرسوم‌ترین و پرکاربردترین روش‌های مبتنی بر یادگیری ماشین در زمینه نقشه‌برداری نوع محصول زراعی به‌شمار می‌رود. با این حال امروزه رویکردهای کارآمد و جدیدتری، مبتنی بر یادگیری عمیق نیز،

توجهی در اختیار قرار می‌دهند. بررسی مطالعات داخلی و خارجی پیشین در حوزه‌های مشابه، به‌ویژه نقشه‌برداری پوشش زمین، نشان می‌دهد که با افزایش تعداد نمونه‌های آموزشی، افزایش تعداد ویژگی‌های مبتنی بر همدوسی، بهره‌گیری از داده‌های مکمل مانند بازپراکنش راداری و اپتیک و همچنین به‌کارگیری روش‌های یادگیری عمیق به‌صورت مستقل و گروهی، می‌توان صحت نقشه‌برداری محصولات زراعی را بهبود بخشید.

۶- منابع

- Abiyat, M., Abiyat, M. & Abiyat, M., 2022, **Evaluation of Efficiency between Classification Methods and Spectral Indices in Cropped Area Estimation of Shush County**, Water and Soil, 36(4), PP. 493-509, <https://doi.org/10.22067/jsw.2022.76746.1167> (Persian).
- Akbary, N., Sameti, M. & Hadyan, V., 2003, **The Impact of Public Expenditures on Agriculture Value Added**, Eqtesad-e Keshavarzi va Towse'e, 11(1-2), PP. 137-166, <https://sid.ir/paper/24163/fa> (Persian).
- Alizadeh, P., Kamkar, B., Shataee, S. & Kazemi Posht Masari, H., 2018, **Estimation of Changes in Land Area under Wheat and Soybean Cultivation Using Satellite Images Classification Techniques in West of Golestan Province**, Applied Field Crops Research, 31(3), PP. 41-61, <https://doi.org/10.22092/aj.2018.121231.1268> (Persian).
- Amherdt, S., Di Leo, N.C., Pereira, A., Cornero, C. & Pacino, M.C., 2022, **Assessment of Interferometric Coherence Contribution to Corn and Soybean Mapping with Sentinel-1 Data Time Series**, Geocarto International, 28(1), PP. 1-22, <https://doi.org/10.1080/10106049.2022.2144472>.
- Asadi, B. & Shamsoddini, A., 2024a, **Crop Mapping through a Hybrid Machine Learning and Deep Learning Method**, Remote Sensing Applications: Society and Environment, 33, P. 101090, <https://doi.org/10.1016/j.rsase.2023.101090>.
- Asadi, B. & Shamsoddini, A., 2024b, **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, <https://doi.org/10.48308/gisj.2023.103095> (Persian).

در چندین مزرعه شاهد، ارزیابی شد. در نهایت، تصاویر همدوسی طی بازه زمانی انتخابی به‌منزله ویژگی‌های ورودی برای کالیبراسیون طبقه‌بندی‌کننده ماشین بردار پشتیبان با کرنل‌های متفاوت به کار رفت تا توانمندی‌های این مجموعه داده، در شناسایی و تفکیک محصولات زراعی، ارزیابی شود. در مجموع، یافته‌های این پژوهش را می‌توان بدین صورت خلاصه کرد:

- بررسی مقادیر سری زمانی همدوسی، در مناطق شاهد انتخابی، حاکی از تمایز رفتار همدوسی محصولات زراعی متفاوت، در مقایسه با هم و نیز در قیاس با مناطق ساخته‌شده و خاک لخت است. براین اساس، داده‌های همدوسی InSAR انطباق خوبی با مراحل فنولوژیکی اصلی محصولات زراعی نشان می‌دهند که این نکته مهم بر کارآمدی این داده‌ها، برای پایش وضعیت محصولات و شناسایی آن‌ها، تأکید دارد.

- از میان کرنل‌های متفاوت SVM، کرنل تابع پایه شعاعی با $59/69\%$ ، بیشترین میزان صحت کلی را با ترکیب بهینه‌ای از پارامترهای c و گاما در مرحله اعتبارسنجی فراهم کرد.

- صحت کلی نقشه نوع محصول زراعی تولیدشده با استفاده از طبقه‌بندی‌کننده SVM و کرنل RBF در مرحله آزمایش، برابر با $60/6\%$ است که بهترین عملکرد را در شناسایی گندم و ضعیف‌ترین عملکرد را در مورد یونجه داشته است.

هدف اصلی مطالعه حاضر ارزیابی پاسخ فنولوژیکی محصولات زراعی غالب در شرایط اقلیمی ایران، برپایه همدوسی InSAR است تا کارایی این مجموعه داده درک شود و مسیر به‌کارگیری آن، در منابع رویکردهای نقشه‌برداری نوع محصول زراعی و تفکیک سطح زیرکشت اراضی، با هدف مدیریت بهینه کشاورزی در کشور، هموار گردد. همان‌طور که نتایج نشان داد، داده‌های همدوسی InSAR در فرایند طبقه‌بندی تصویر، صحت کلی بیش از 60% را دربرداشتند و بدین ترتیب در مجموع، در زمینه مطالعه رفتار فنولوژیکی محصولات زراعی گوناگون و همچنین نقشه‌برداری آن‌ها، اطلاعات مفید و شایان

- Azzari, G. & Lobell, D.B., 2017, **Landsat-Based Classification in the Cloud: An Opportunity for a Paradigm Shift in Land Cover Monitoring**, Remote Sensing of Environment, Big Remotely Sensed Data: Tools, Applications and Experiences, 202, PP. 64-74, <https://doi.org/10.1016/j.rse.2017.05.025>.
- Busquier, M., Lopez-Sanchez, J.M., Mestre-Quereda, A., Navarro, E., González-Dugo, M.P. & Mateos, L., 2020, **Exploring TanDEM-X Interferometric Products for Crop-Type Mapping**, Remote Sensing, 12(11), P. 1774.
- Crosetto, M., Tscherning, C.C., Crippa, B. & Castillo, M., 2002, **Subsidence Monitoring Using SAR Interferometry: Reduction of the Atmospheric Effects Using Stochastic Filtering**, Geophysical Research Letters, 29(9), PP. 26-29, <https://doi.org/10.1029/2001GL013544>.
- Ebrahimzadeh, S., Soleimani, M., Atarchi, S., Saadat Novin, M. & Shabaniyan, H., 2023, **Detection of Areas with Severely Eroded Soils Using Sentinel-1 Interferometric SAR Coherence (Study Area: Khuzestan Province)**, jgit, 11(3), PP. 59-84, <http://dx.doi.org/10.61186/jgit.11.3.59> (Persian).
- Engdahl, M.E. & Hyypä, J.M., 2003, **Land-Cover Classification Using Multitemporal ERS-1/2 InSAR Data**, IEEE Transactions on Geoscience and Remote Sensing, 41(7), PP. 1620-1628.
- Engdahl, M.E., Borgeaud, M. & Rast, M., 2001, **The Use of ERS-1/2 Tandem Interferometric Coherence in the Estimation of Agricultural Crop Heights**, IEEE Transactions on Geoscience and Remote Sensing, 39(8), PP. 1799-1806, <https://doi.org/10.1109/36.942558>.
- Khalil, R.Z., 2018, **InSAR Coherence-Based Land Cover Classification of Okara, Pakistan**, The Egyptian Journal of Remote Sensing and Space Science, 21, PP. S23-S28.
- Ezzati, H., Pourbayramian, S. & Sarvoghmet, M., 2017, **The Effect of Yamchi Dam on Increasing the Groundwater Level of the Ardabil Plain Aquifer**, 10th National Geology Conference of Payam Noor University, <https://civilica.com/doc/621832> (Persian).
- Forudikhor, A., Sanei, M. & Ajdari Moghadam, M., 2010, **Comparison of Adaptive Neural Fuzzy Inference System (ANFIS) and Support Vector Machine (SVM) in Estimating Discharge Coefficient of Sharp-Edged Spillways**, Iranian Journal of Irrigation and Drainage, 11(5), PP. 772-784, <https://civilica.com/doc/1210864> (Persian).
- Fu, Y., Shen, R., Song, C., Dong, J., Han, W., Ye, T. & Yuan, W., 2023, **Exploring the Effects of Training Samples on the Accuracy of Crop Mapping with Machine Learning Algorithm**, Science of Remote Sensing, 7, P. 100081, <https://doi.org/10.1016/j.srs.2023.100081>.
- Holzer, T.L. & Galloway, D.L., 2005, **Impacts of Land Subsidence Caused by Withdrawal of Underground Fluids in the United States**, Publication of an Organization other than USGS, Geological Society of America, [https://doi.org/10.1130/2005.4016\(08\)](https://doi.org/10.1130/2005.4016(08)).
- Hsu, C.W., Chang, C.C. & Lin, C.J., 2003, **A Practical Guide to Support Vector Classification**, https://www.researchgate.net/publication/2926909_A_Practical_Guide_to_Support_Vector_Classification_Chih-Wei_Hsu_Chih-Chung_Chang_and_Chih-Jen_Lin.
- Huang, J., Ma, H., Sedano, F., Lewis, P., Liang, S., Wu, Q., ... & Zhu, D., 2019, **Evaluation of Regional Estimates of Winter Wheat Yield by Assimilating Three Remotely Sensed Reflectance Datasets into the Coupled WOFOST-PROSAIL Model**, European Journal of Agronomy, 102, PP. 1-13.
- Huber, M., Kumar, V., Steele-Dunne, S.C. & Rommen, B., 2023, **Sentinel-1 InSAR Coherence as an Indicator of Monitor Farming Activities**, IGARSS 2023-2023 IEEE International Geoscience and Remote Sensing Symposium (PP. 429-432), IEEE, <https://doi.org/10.1109/IGARSS52108.2023.10281522>.
- Jacob, A.W., Vicente-Guijalba, F., Lopez-Martinez, C., Lopez-Sanchez, J.M., Litzinger, M., Kristen, H., ... & Engdahl, M.E., 2020, **Sentinel-1 InSAR Coherence for Land Cover Mapping: A Comparison of Multiple Feature-Based Classifiers**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, PP. 535-552, <https://doi.org/10.1109/JSTARS.2019.2958847>.
- Jamali, A., 2020, **Sentinel-1 Image Classification Using Machine Learning Algorithms Based on the Support Vector**

- Machine and Random Forest**, Int. J. Geoinformatics, 16(2).
- Jensen, J.R., 1996, **Introductory Digital Image Processing: A Remote Sensing Perspective**, (No. Ed. 2), Prentice-Hall Inc.
- Kavzoglu, T. & Colkesen, I., 2009, **A Kernel Functions Analysis for Support Vector Machines for Land Cover Classification**, International Journal of Applied Earth Observation and Geoinformation, 11(5), PP. 352-359, <https://doi.org/10.1016/j.jag.2009.06.002>.
- Khosravi, I., 2024, **Crop Mapping from Landsat-8 Images Time Series Using Machine-Learning Methods (Case Study: Marvdasht in Fars Province)**, Geography and Environmental Planning, 35(2), PP. 45-66, <https://doi.org/10.22108/gep.2024.138615.1601> . (Persian).
- Li, G., Cui, J., Han, W., Zhang, H., Huang, S., Chen, H. & Ao, J., 2022, **Crop Type Mapping Using Time-Series Sentinel-2 Imagery and U-Net in Early Growth Periods in the Hetao Irrigation District in China**, Computers and Electronics in Agriculture, 203, P. 107478, <https://doi.org/10.1016/j.compag.2022.107478>.
- Lin, S.W., Ying, K.C., Chen, S.C. & Lee, Z.J., 2008, **Particle swarm optimization for parameter determination and feature selection of support vector machines**, Expert Systems with Applications, 35(4), PP. 1817-1824, <http://dx.doi.org/10.1016/j.eswa.2007.08.088>.
- Liu, X., Xie, S., Yang, J., Sun, L., Liu, L., Zhang, Q. & Yang, C., 2023, **Comparisons between Temporal Statistical Metrics, Time Series Stacks and Phenological Features Derived from NASA Harmonized Landsat Sentinel-2 Data for Crop Type Mapping**, Computers and Electronics in Agriculture, 211, P. 108015, <http://dx.doi.org/10.1016/j.compag.2023.108015>.
- Mestre-Quereda, A., Lopez-Sanchez, J.M., Vicente-Guijalba, F., Jacob, A.W. & Engdahl, M.E., 2020, **Time-Series of Sentinel-1 Interferometric Coherence and Backscatter for Crop-Type Mapping**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, PP. 4070-4084, <http://dx.doi.org/10.1109/JSTARS.2020.3008096>.
- Meteorological Yearbook of Ardabil Province**, 2021, Ardabil Province Meteorological Organization (Persian).
- Nasirzadehdizaji, R., Cakir, Z., Sanli, F.B., Abdikan, S., Pepe, A. & Calo, F., 2021, **Sentinel-1 Interferometric Coherence and Backscattering Analysis for Crop Monitoring**, Computers and Electronics in Agriculture, 185, P. 106118, <https://doi.org/10.1016/j.compag.2021.106118>.
- Navale, A. & Haldar, D., 2019, **Evaluation of Machine Learning Algorithms to Sentinel SAR Data**, Spat. Inf. Res., PP. 1-11, <http://dx.doi.org/10.21203/rs.3.rs-4011867/v1>.
- Olesk, A., Praks, J., Antropov, O., Zalite, K., Arumäe, T. & Voormansik, K., 2016, **Interferometric SAR Coherence Models for Characterization of Hemiboreal Forests Using TanDEM-X Data**, Remote Sensing, 8(9), P. 700.
- Pandit, A., Sawant, S., Mohite, J. & Pappula, S., 2021, **Sentinel-1-Derived Coherence Time-Series for Crop Monitoring in Indian Agriculture Region**, Geocarto International, 37(25), PP. 9497-9517, <https://doi.org/10.1080/10106049.2021.2022008>.
- Parihar, N., Das, A., Rathore, V.S., Nathawat, M.S. & Mohan, S., 2014, **Analysis of L-Band SAR Backscatter and Coherence for Delineation of Land-Use/Land-Cover**, International Journal of Remote Sensing, 35(18), PP. 6781-6798, <https://doi.org/10.1080/01431161.2014.965282>.
- Ren, F., Li, Y. & Hu, M., 2018, **Multi-Classifer Ensemble Based on Dynamic Weights**, Multimedia Tools and Applications, 77(16), PP. 21083-21107, <https://doi.org/10.1007/s11042-017-5480-5>.
- Senanayake, S., Biswajeet, P., Alfredo, H. & Jane, B., 2020, **A Review on Assessing and Mapping Soil Erosion Hazard Using Geo-Informatics Technology for Farming System Management**, Remote Sensing, 12(24), P. 4063, <https://doi.org/10.3390/rs12244063>.
- Sica, F., Pulella, A., Nannini, M., Pinheiro, M. & Rizzoli, P., 2019, **Repeat-Pass SAR Interferometry for Land Cover Classification: A Methodology Using Sentinel-1 Short-Time-Series**, Remote Sensing of Environment, 232, P. 111277.
- Soleimani, M., Attarchi, S., Mahmoodi-Vanolya, N., Bakhshizadeh, F. & Ahmadi,

- H., 2021, **Evaluation of Sentinel-1 Interferometric SAR Coherence Efficiency for Land Cover Mapping**, jgit., 9(3), PP. 85-107, <http://dx.doi.org/10.52547/jgit.9.3.85> (Persian).
- Sonobe, R., Tani, H., Wang, X., Kobayashi, N. & Shimamura, H., 2015, **Discrimination of Crop Types with TerraSAR-X-Derived Information**, Physics and Chemistry of the Earth, Parts A/B/C, 83, PP. 2-13.
- Stehman, S.V., Arora, M.K., Kasetkasem, T. & Varshney, P.K., 2007, **Estimation of Fuzzy Error Matrix Accuracy Measures under Stratified Random Sampling**, Photogrammetric Engineering & Remote Sensing, 73(2), PP. 165-173, <http://dx.doi.org/10.14358/PERS.73.2.165>.
- Syarif, I., Prugel-Bennett, A. & Wills, G., 2016, **SVM parameter optimization using grid search and genetic algorithm to improve classification performance**, TELKOMNIKA (Telecommunication Computing Electronics and Control), 14(4), PP. 1502-1509, <http://dx.doi.org/10.12928/telkomnika.v14i4.3956>.
- Touzi, R., Lopes, A., Bruniquel, J. & Vachon, P.W., 1999, **Coherence Estimation for SAR Imagery**, IEEE Transactions on Geoscience and Remote Sensing, 37(1), PP. 135-149, <https://doi.org/10.1109/36.739146>.
- Vapnik, V.N., 1995, **The Nature of Statistical Learning Theory**, New York: Springer2V Erlag, <http://dx.doi.org/10.1007/978-1-4757-2440-0>.
- Villarroya-Carpio, A., Lopez-Sanchez, J.M. & Engdahl, M.E., 2022, **Sentinel-1 Interferometric Coherence as a Vegetation Index for Agriculture**, Remote Sensing of Environment, 280, P. 113208, <https://doi.org/10.1016/j.rse.2022.113208>.
- Yang, N., Liu, D., Feng, Q., Xiong, Q., Zhang, L., Ren, T., ... & Huang, J., 2019, **Large-Scale Crop Mapping Based on Machine Learning and Parallel Computation with Grids**, Remote Sensing, 11(12), P. 1500.
- Zhao, Q., Xie, Q., Peng, X., Bao, Y., Jia, T., Yue, L., ... & Zhu, J., 2024, **A Comparison of Sentinel-1 Biased and Unbiased Coherence for Crop Monitoring and Classification**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 48, PP. 903-908, <https://doi.org/10.5194/isprs-archives-XLVIII-1-2024-903-2024>.
- Zhou, T., Pan, J., Zhang, P., Wei, S. & Han, T., 2017, **Mapping Winter Wheat with Multi-Temporal SAR and Optical Images in an Urban Agricultural Region**, Sensors, 17(6), P. 1210, <https://doi.org/10.3390/s17061210>.
- Zhu, G. & Blumberg, D.G., 2002, **Classification Using ASTER Data and SVM Algorithms: The Case Study of Beer Sheva, Israel**, Remote Sensing of Environment, 80(2), PP. 233-240, [http://dx.doi.org/10.1016/S0034-4257\(01\)00305-4](http://dx.doi.org/10.1016/S0034-4257(01)00305-4).

This Page is Intentionally Left Blank



پروہشگاہ علوم انسانی و مطالعات فرہنگی
پرتال جامع علوم انسانی