

Evaluating the efficiency of InSAR coherence in crop type mapping using machine learning

Fatemeh Amiri, Ali Shamsoddini*, Sharifikia, Mohamad

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

* Corresponding Author: ali.shamsoddini@modares.ac.ir

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 1,258 fields containing various crops. To avoid mixed pixels, a 10-meter buffer was established around the edges of each crop field. A total of 106,026 pixels from the coherence images were sampled and randomly divided into three groups: training (70%), validation (10%), and test (20%). 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 89.69% 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 70.7%. 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.

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

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

^{*}نویسنده عهده دار مکاتبات: ali.shamsoddini@modares.ac.ir

چکیده

مقدمه

استفاده بهینه از زمین‌های کشاورزی یکی از دغدغه‌های مسئولان است چرا که کشاورزی از نظر اشتغال‌زایی، ارزآوری، تامین امنیت غذایی کشور و وابستگی کمتر به ارز خارجی از اهمیت بالایی برخوردار است. به دست آوردن اطلاعات مربوط به الگوی توزیع مکانی و سطح زیر کشت محصولات زراعی می‌تواند به استفاده کارآمد از آنها کمک کند. از جمله روش‌های مناسب، به منظور حصول اطلاعات در مورد سطح زیر کشت محصولات زراعی، بهره‌گیری از تصاویر ماهواره‌ای است. حوزه سنجش از دور با قابلیت ارائه تصاویر دارای قدرت تفکیک‌های مناسب و همچنین پوشش مکانی و زمانی وسیع، به رویکردی غالب جهت استخراج سطح زیر کشت و پایش محصولات زراعی تبدیل شده است. یکی از داده‌های سنجش از دوری که اخیراً در حوزه نقشه‌برداری نوع محصول زراعی مورد توجه قرار گرفته، تصاویر همدوسی تداخل سنجی رادار در پیچ‌های مصنوعی است که به دلیل حساسیت بالا به ساختار محصولات زراعی، کمک زیادی به نظارت و نقشه‌برداری آن‌ها می‌کند. در ادبیات جهانی، تصاویر همدوسی InSAR به‌طور گسترده در تحقیقات مرتبط با محصولات زراعی مورد استفاده قرار گرفته‌اند. این درحالیست که، در ایران، بهره‌گیری از داده‌های همدوسی برای پایش فنولوژی و تفکیک محصولات زراعی مختلف، علی‌رغم قابلیت‌های منحصر به فرد آن، چندان مورد توجه قرار نگرفته است. از این رو 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 به منظور نقشه‌برداری نوع محصول زراعی است. بدین منظور یک سری زمانی یک‌ساله برای سال زراعی ۱۳۹۸ (۲۰۱۹ میلادی) از داده‌های همدوسی دارای اطلاعات فاز ماهواره سنتینل ۱- برای بخشی از اراضی دشت اردبیل واقع در غرب و شمال غرب شهر اردبیل تهیه گردید. در این راستا زنجیره‌ای از جفت تصاویر راداری با خط مبنای مکانی و زمانی کوتاه جهت تولید داده‌های همدوسی استفاده شد. داده‌های میدانی از ۱۳۵۸ قطعه زمین با محصولات مختلف برداشت شد. در مرز قطعات زراعی یک حریم ۱۰ متری برای جلوگیری از پیکسل‌های مخلوط در نظر گرفته شد. در مجموع ۱۵۶۰۲۶ پیکسل از تصاویر همدوسی برای نمونه، برداشت و به صورت تصادفی به سه دسته آموزشی (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمایشی (۱۵٪) تقسیم شد. به منظور 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 ساخته شده و خاک لخت مقایسه شد تا از عدم اختلاط آنها اطمینان حاصل گردد. بدین ترتیب داده‌های همدوسی چندزمانه در بازه انتخابی به عنوان ورودی طبقه‌بندی‌کننده ماشین بردار پشتیبان با کرنل‌های مختلف، جهت 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 مختلف در مقایسه با هم و همچنین نسبت به مناطق ساخته شده و خاک لخت است. بر این اساس داده‌های همدوسی انطباق خوبی با مراحل فنولوژیکی اصلی محصولات زراعی نشان می‌دهند. از میان کرنل‌های مختلف طبقه‌بندی‌کننده ماشین بردار پشتیبان، کرنل تابع پایه شعاعی بالاترین میزان صحت کلی برابر با ۵۹/۶۹ درصد را با ترکیب مختلفی از پارامترهای C و گاما در مرحله اعتبارسنجی به دست داد. صحت کلی نقشه نوع محصول زراعی تولید شده با استفاده از طبقه‌بندی‌کننده ماشین بردار پشتیبان و کرنل تابع پایه شعاعی، در مرحله آزمایش برابر با ۶۰/۶ درصد است که بهترین عملکرد را در شناسایی گندم و بدترین را برای یونجه داشته است. صحت کاربر برای گیاهان گندم و سیب‌زمینی بالاتر و برای گیاهان ذرت، باقلا و یونجه پایین‌تر است.

جمع بندی

به طور کلی می‌توان گفت تصاویر همدوسی اطلاعات ارزشمندی به منظور 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 نظیر تعداد نمونه‌های آموزشی هر محصول، تعداد ویژگی‌های همدوسی، استفاده از داده‌های مکمل، اختلاف منظر 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 تاثیر قرار می‌دهند که بایستی مورد توجه قرار گیرند.

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

۱- مقدمه

کشاورزی نقش مهمی در حفظ بقای انسان دارد (Liu et al, ۲۰۲۳) و در مقایسه با سایر بخش‌های اقتصادی از نظر اشتغال‌زایی، ارزآوری، تامین امنیت غذایی کشور و وابستگی کمتر به ارز خارجی از اهمیت بالایی برخوردار است (Akbari et al, ۲۰۰۳). بر همین اساس استفاده بهینه از زمین‌های کشاورزی یکی از دغدغه‌های مسئولان است. به دست آوردن اطلاعات مربوط به الگوی توزیع مکانی و سطح زیر کشت محصولات زراعی می‌تواند به نظارت و مدیریت پایدار منابع کشاورزی (Li et al, ۲۰۲۲) و استفاده کارآمد از آنها کمک کند (Abiyat et al, ۲۰۲۲).

از جمله روش‌های مناسب، کم‌هزینه و سریع به منظور حصول اطلاعات در مورد سطح زیر کشت محصولات زراعی، بهره‌گیری از تصاویر ماهواره‌ای است (Alizadeh et al, ۲۰۱۸). همگام با پیشرفت‌های روزافزون در حوزه سنجش‌ازدور با قابلیت 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 جهت استخراج سطح زیر کشت و پایش محصولات زراعی تبدیل شده است (Azzari & Lobell., ۲۰۱۷). از جمله داده‌های سنجش‌ازدوری رایج مورد استفاده در این زمینه می‌توان به مجموعه داده‌های اپتیک، باز پراکنش راداری و لیدار اشاره نمود. 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 زیادی به نظارت و نقشه‌برداری آن‌ها می‌کند (Zhao et al., ۲۰۲۴). در تکنیک InSAR، اختلاف فاز بین جفت تصاویر مربوط به زمان‌های مختلف در قالب تداخل‌نگاشت^۳ اندازه‌گیری شده و سپس این اختلاف فاز به تغییر فاصله بین سنجنده و هدف و یا جابه‌جایی سطح زمین نسبت داده می‌شود (Crosetto et al., ۲۰۰۲). 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 به‌منظور شناسایی و طبقه‌بندی پوشش‌های مختلف زمین از ارائه دهد (Quereda et al., ۲۰۲۰).

مطالعات بسیاری در خصوص بهره‌گیری از تصاویر همدوسی در حوزه نقشه‌برداری نوع محصول زراعی انجام شده است. ژو^۵ و همکاران (۲۰۱۷) به ارزیابی تاثیر استفاده تلفیقی از داده‌های اپتیک لندست ۸ و همدوسی سنتینل-۱ بر صحت طبقه‌بندی محصول گندم زمستانه در مناطق کشاورزی شهری در جنوب چین با استفاده از طبقه‌بندی‌کننده‌های RF و ماشین بردار پشتیبان (SVM)^۶ پرداختند. نتایج کار آنها نشان داد که در شرایط آب و هوایی نامساعد که تصاویر اپتیک مناسب در دسترس نباشند، می‌توان از داده‌های همدوسی سنتینل-۱ به عنوان جایگزین استفاده کرد. همچنین دریافتند که در مجموع طبقه‌بندی‌کننده SVM به لحاظ صحت کلی، ضریب کاپا و سرعت اجرا بهتر از RF عمل کرده است. کوئردا^۷ و همکاران (۲۰۲۰) بر اهمیت بهره‌گیری از داده‌های همدوسی جهت افزایش صحت نقشه‌برداری نوع محصول زراعی در اسپانیا تاکید داشته‌اند. نتایج بررسی‌های آنها نشان داد که صحت کلی طبقه‌بندی نظارت‌شده جنگل تصادفی (RF)^۸ برای این مجموعه داده در قطبش VV با قدرت تفکیک زمانی ۱۲ روزه برابر با

^۱ Coherence

^۲ Interferometric Synthetic Aperture Radar

^۳ Interferogram

^۴ Synthetic Aperture Radar

^۵ Zhou

^۶ Support Vector Machine

^۷ Quereda

^۸ Random Forest

۸/۷۳٪ است. در مطالعه جاکوب^۱ و همکاران (۲۰۲۰)، کارایی داده‌های همدوسی تداخل سنجی سنتینل-۱ به منظور نقشه‌برداری پوشش زمین، مورد بررسی قرار گرفت. آنها دریافتند که صحت کلی طبقه‌بندی نظارت‌شده مبتنی بر RF برای این مجموعه داده در قطبش VH+VV با قدرت تفکیک زمانی ۱۲ روزه برابر با ۷۰٪ است. مطالعات نصیری‌زاده دیزجی^۲ و همکاران (۲۰۲۱) و ویلارویا^۳ و همکاران (۲۰۲۲)، نیز موید انطباق خوب داده‌های سری زمانی همدوسی با مراحل فنولوژیکی اصلی محصولات زراعی است. پاندیت^۴ و همکاران (۲۰۲۲)، از محصولات همدوسی برای پایش مراحل فنولوژیکی، تعیین کل مدت زمان کشت و تخمین تاریخ کاشت و برداشت برای محصول Bengal-gram استفاده کردند. نتایج این مطالعه نشان داد که تحلیل سری زمانی همدوسی اطلاعات قابل اعتمادی در مورد مراحل رشد محصول ارائه می‌دهد و این رویکرد می‌تواند برای پایش سایر محصولات نیز مورد استفاده قرار گیرد. هوبر^۵ و همکاران (۲۰۲۳) در مطالعه‌ای از تصاویر همدوسی InSAR به عنوان شاخصی برای پایش فعالیت‌های کشاورزی (مانند کاشت، جوانه زنی، برداشت و خاک‌ورزی) با در نظر گرفتن شرایط آب‌وهوایی (برف، باران، یخبندان) استفاده کردند. یافته‌های این مطالعه تاکید دارد تصاویر همدوسی یک شاخص قابل اعتماد برای پایش فعالیت‌های مختلف کشاورزی با شرایط جوی متفاوت هستند. ژائو^۶ و همکاران (۲۰۲۴) قابلیت همدوسی سری زمانی Sentinel-۱ را به عنوان ابزاری کارآمد برای نقشه‌برداری از محصولات اصلی در مناطق مهم تولیدکننده غلات چین معرفی کردند. با بررسی مطالعات گذشته به‌طور کلی می‌توان نتیجه گرفت که در سال‌های اخیر، استفاده از داده‌های همدوسی InSAR به منظور نقشه‌برداری محصولات زراعی مورد توجه قرار گرفته و نتایج مطالعات مذکور گواه توانایی این مجموعه داده جهت پایش وضعیت محصولات زراعی و شناسایی آنها است. در این زمینه، از منظر نوع روش طبقه‌بندی نیز طیف وسیعی از رویکردهای طبقه‌بندی نظارت شده و نظارت‌نشده مورد استفاده قرار گرفته‌اند (Senanayake et al., ۲۰۲۰). در همین خصوص مطالعات بسیاری بر توانایی بالای الگوریتم طبقه‌بندی SVM به‌عنوان یک روش نظارت‌شده مبتنی بر یادگیری ماشین، تأکید داشته‌اند (Zhou et al., ۲۰۱۷; Jamali., ۲۰۲۰; Navale & Haldar., ۲۰۱۹).

با مرور مطالعات پیشین، می‌توان دریافت که در ادبیات جهانی، تصاویر همدوسی InSAR به‌طور گسترده در تحقیقات مرتبط با محصولات زراعی مورد استفاده قرار گرفته‌اند. این مجموعه‌داده نه‌تنها در تفکیک انواع مختلف محصولات و بررسی مراحل فنولوژیکی

^۱ Jacob

^۲ Nasirzadehdizaji

^۳ Villarroya

^۴ Pandit

^۵ Huber

^۶ Zhao


آنها مؤثر بوده، بلکه در تلفیق با سایر داده‌ها مانند داده‌های اپتیک و بازپراکنش نیز نتایج مطلوبی ارائه کرده است. علاوه بر این، به‌منظور افزایش صحت و کارایی نتایج، روش‌های مختلف یادگیری ماشین و یادگیری عمیق نیز مبتنی بر این مجموعه داده‌ها مورد استفاده قرار گرفته‌اند. این درحالیست که، در ایران، با وجود بهره‌گیری از داده‌های InSAR در حوزه‌هایی مانند طبقه‌بندی پوشش زمین (Soleimani et al, ۲۰۲۱)، ارزیابی فرسایش خاک (Ebrahimzadeh et al, ۲۰۲۳)، بهره‌گیری از داده‌های همدوسی برای پایش فنولوژی و تفکیک محصولات زراعی مختلف، علی‌رغم قابلیت‌های منحصر به فرد آن، مورد توجه قرار نگرفته است. با در نظر گرفتن تنوع اقلیمی ایران، الگوهای مکانی کشت عمدتاً سنتی و ناهمگن و کوچک‌مساحت در اراضی زیر کشت محصولات زراعی متنوع در نواحی مختلف کشور، بررسی دقیق کارایی این داده‌ها در تفکیک انواع محصولات زراعی، ضروری به نظر می‌رسد. ارزیابی قابلیت داده‌های همدوسی InSAR در مطالعه فنولوژی محصولات زراعی، اطلاعات مفیدی جهت پیاده‌سازی رویکردهای نقشه‌برداری نوع محصول زراعی ارائه می‌دهد که این مهم با توجه به ضرورت و اهمیت دسترسی به نقشه‌های تفکیک نوع محصول قابل اطمینان، راه را برای اتخاذ سیاست‌های مدیریت کشاورزی بهینه در ایران هموار می‌سازد.

بر این اساس، مطالعه حاضر با هدف ارزیابی قابلیت 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 به منظور تفکیک داده‌ها در فضای ویژگی، کرنل‌های مختلفی به کار گرفته می‌شود. از آنجایی که نوع تابع کرنل می‌تواند نتایج طبقه‌بندی را تحت تأثیر قرار دهد، لذا در این مطالعه قابلیت کرنل‌های مختلف SVM نیز مورد ارزیابی قرار می‌گیرد.

۲- مواد و روش‌ها

در این مطالعه جهت تهیه نقشه محصولات زراعی از داده‌های همدوسی چندزمانه InSAR استفاده شده است. بدین منظور یک سری زمانی یک‌ساله برای سال زراعی ۱۳۹۸ (۲۰۱۹ میلادی) از داده‌های SAR دارای اطلاعات فاز ماهواره سنتینل ۱- برای بخشی از اراضی دشت اردبیل واقع در غرب و شمال غرب شهر اردبیل تهیه گردید. در ادامه شبکه‌ای از جفت تصاویر SAR با خط مبناهای مکانی و زمانی کوتاه جهت پردازش InSAR و تولید داده‌های همدوسی تشکیل داده شد. بدین ترتیب داده‌های همدوسی چندزمانه تولیدشده به‌عنوان ورودی الگوریتم طبقه‌بندی‌کننده SVM با کرنل‌های مختلف، جهت 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 مربوط به نوع محصولات زراعی صورت گرفته است. شکل (۱) ساختار کلی فرایند انجام این مطالعه را نمایش می‌دهد.




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

۱-۲- منطقه مورد مطالعه

مطابق با شکل (۲)، منطقه مورد مطالعه (مستطیل قرمز رنگ) 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 با مساحت تقریبی ۱۷۸/۷۳ کیلومتر مربع (معادل ۱۷۸۷۳ هکتار) قرار دارد. متناسب با هدف پژوهش در خصوص ارزیابی قابلیت داده‌های InSAR جهت شناسایی و تفکیک محصولات زراعی، این محدوده از نظر تنوع محصولات زراعی شرایط مناسبی دارد چرا که دشت اردبیل به وسیله ارتفاعات بصورت حلقه‌ای

گرداگرد محاصره شده است و از طرفی یک دشت آبرفتی به عنوان پست‌ترین سطح توپوگرافی در مرکز دشت قرار گرفته است (Ezzati et al, ۲۰۱۷). این مسئله توام با بارندگی تجمعی سالانه حدود ۳۰۰ میلی‌متر (Meteorological Yearbook of Ardabil Province, ۱۴۰۰)، منطقه مورد مطالعه را به طور طبیعی برای فعالیت‌های کشاورزی مناسب نموده است.



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

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 می‌گردد. 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 ۱۲ روزه به صورت Single Look است. در حالت تصویربرداری IW، از طریق تکنیک

^۱ Single Look Complex

^۲ Interferometric Wide Swath

^۳ Swath width

مشاهده زمین با اسکن‌های پیش‌رونده (1 TOPSAR)، تصویر در قالب سه زیرنوار IW^1 (حداقل زاویه فرودی) تا IW^3 (حداکثر زاویه فرودی) برداشت می‌گردد. هر کدام از زیرنوارها از تعدادی Burst تشکیل شده‌اند که در نهایت هر یک از این Burst ها به صورت یک تصویر مجزا مورد پردازش قرار می‌گیرند. تصاویر برداشت‌شده از طریق حالت IW پس از اعمال پردازش‌هایی در قالب محصولات سطح یک SLC در دو قطبش VV و VH ارائه می‌شوند که شامل مقادیر فاز و دامنه بوده و برای اهداف InSAR مناسب هستند (Soleimani et al, ۲۰۲۱).

در این مطالعه، یک سری زمانی یکساله (پوشش‌دهنده سال زراعی ۲۰۱۹) شامل ۳۲ تصویر SAR ماهواره سنتینل-۱ A مربوط به شماره برش^۲ ۱۸، مسیر^۳ ۱۰۱ و گذر صعودی/بالارو^۴ در بازه زمانی ۱۵ اکتبر ۲۰۱۸ تا ۱۰ نوامبر ۲۰۱۹ از طریق سایت مرکز دسترسی آزاد کوپرنیک سازمان فضایی اروپا^۵ دانلود گردید.

در اینجا با توجه به موقعیت منطقه مورد مطالعه، جهت کاهش حجم و زمان محاسبات، تصاویر مربوط به زیر نوار IW^2 جهت پردازش InSAR مدنظر قرار گرفتند. مطالعات گذشته پیرامون بهره‌گیری از اطلاعات همدوسی InSAR جهت نقشه‌برداری نوع محصول زراعی، بر قابلیت بالاتر تصاویر مربوط به قطبش VV جهت تفکیک محصولات زراعی تاکید داشته‌اند (Mestre-Quereda et al., ۲۰۲۰). بر این اساس، در مطالعه حاضر نیز باندهای راداری با قطبش VV در سری زمانی تصاویر جهت پردازش استفاده شدند.

۲-۳- تکنیک InSAR و محاسبه همدوسی

تکنیک InSAR یک فناوری سنجنش‌زدوری است که مبتنی بر تلفیق داده‌های SAR اخذشده از یک منطقه در زمان‌های مختلف می‌باشد. تصاویر تکراری SAR می‌توانند جهت تشخیص تغییرات ایجادشده در سطح زمین مانند حرکت یا تغییر ارتفاع مورد استفاده قرار بگیرند (Soleimani et al, ۲۰۲۱). این تصاویر به طور مرسوم جهت ارزیابی کیفیت تداخل‌نگاشت تولیدشده مورد استفاده قرار گرفته و به صورت رابطه (۱) بیان می‌شوند:

^۱ Terrain Observation with Progressive Scans SAR

^۲ Slice number

^۳ Track

^۴ Ascending

^۵ European Space Agency Copernicus Open Access Hub (<https://scihub.copernicus.eu/>)

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

در رابطه (۱)، $E\{0\}$ عملگر امید ریاضی^۱ است و S_1 و S_2 ، بیانگر دو تصویر پیچیده^۲ و ثبت هندسی شده^۳ SAR می‌باشند. برای 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^۴ جایگزین می‌شود (Touzi et al, ۱۹۹۹). از این رو، رابطه (۱) به صورت رابطه (۲) بیان می‌گردد:

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

در رابطه (۲)، L تعداد نمونه‌های موجود در یک پنجره است. دامنه تغییرات مقادیر γ در این معادله، بین صفر و ۱ قرار دارند. مقادیر کم γ بیانگر همدوسی پایین و مقادیر بالای آن نشان‌دهنده همدوسی بالا است. 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 بوده و تغییرات زیادی دارند، دارای مقادیر همدوسی به مراتب پایین‌تری هستند (Holzer & Galloway, ۲۰۰۵). بطور کلی، مراحل پردازش‌های InSAR در این مطالعه به منظور تولید تصاویر همدوسی چندزمانه به شرح زیر هستند:

- دانلود یک سری زمانی یک ساله (از اکتبر ۲۰۱۸ تا نوامبر ۲۰۱۹) از تصاویر SAR-SLC دارای اطلاعات فاز ماهواره سنیتل ۱-A (حالت تصویربرداری IW) پوشش‌دهنده منطقه مورد مطالعه
- انتخاب زوج تصاویر مبنا و پیرو به صورت زنجیره‌وار (با تفکیک زمانی ۱۲ روزه و حداکثر طول خط‌مبنای مکانی ۲۰۰ متر) به منظور محاسبه سری زمانی همدوسی InSAR (جدول ۱) و (شکل ۳)
- ساخت مدل گراف در نرم افزار SNAP به منظور اتوماتیک‌سازی مراحل پردازش زوج تصاویر SAR (شکل ۴):

(۱) فراخوانی تصاویر مبنا^۵ و پیرو^۶ (Read)

(۲) جداسازی ۲-IW پوشش‌دهنده منطقه مورد مطالعه جهت کاهش حجم و زمان پردازش (TOPSAR-Split)

(۳) دانلود و اضافه کردن داده‌های مداری دقیق متناظر با تصاویر مبنا و پیرو (Apply-Orbit-File)

^۱ Expectation operator

^۲ Complex

^۳ Co-Registered

^۴ Kernel

^۵ Master

^۶ Slave

- (۴) ثبت هندسی^۱ تصویر پیرو نسبت به تصویر مبنا با استفاده از داده‌های مداری دقیق و مدل 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 ارتقاء کیفیت تصاویر همدوسی در هنگام ادغام Burst ها (Enhanced-Spectral-Diversity)
- (۶) محاسبه همدوسی InSAR بین تصاویر مبنا و پیرو با استفاده از رابطه (۲) و انجام عملیات multi-looking جهت کاهش نویز اسپکل^۵ و تولید پیکسل‌های مربعی شکل از طریق تعریف کرنل با ابعاد ۱۰ پیکسل در راستای فاصله مایل $3 \times$ پیکسل در راستای آزیموت بر اساس فاصله پیکسل‌های^۶ تصویر در دو راستای فاصله مایل (۲/۳۲ متر) و آزیموت (۱۳/۹۳ متر) راداری (Coherence)
- (۷) ادغام Burst ها در تصویر همدوسی محاسبه‌شده به منظور ایجاد تصویر یکنواخت با استفاده از داده‌های خروجی مراحل (۵) و (۶) (TOPSAR-Deburst)
- (۸) زمین مرجع کردن^۷ و انتقال تصاویر همدوسی تولیدشده از مختصات فاصله مایل و آزیموت راداری به مختصات جغرافیایی زمینی با استفاده از DEM جهت تولید تصاویر با اندازه پیکسل مربعی تقریباً ۱۲/۸۲ متر (Terrain-Correction)
- (۹) خروجی گرفتن از تصاویر همدوسی تولیدشده در فرمت‌های رایج (نظیر geotiff و hdr) جهت استفاده در نرم‌افزارهای پردازش تصویر (Write)
- برش زدن منطقه مورد مطالعه از تصاویر همدوسی چندزمانه InSAR محاسبه‌شده جهت استفاده در الگوریتم‌های طبقه‌بندی‌کننده به عنوان ویژگی یا متغیر ورودی

^۱ Coregistration

^۲ Digital Elevation Model

^۳ Stack

^۴ Enhanced Spectral Diversity


^۵ Speckle

^۶ Pixel spacing


^۷ Geocoding

جدول ۱- شبکه زوج تصاویر انتخابی به صورت زنجیره وار (تفکیک زمانی ۱۲ روزه) به منظور محاسبه سری زمانی همدوسی InSAR با استفاده از تصاویر گذر صعودی ماهواره سنتینل-۱ A در شماره برش ۱۸، مسیر ۱۰۱ و قطبش VV (تعداد تصاویر مورد استفاده: ۳۲، تعداد تصاویر همدوسی تولیدشده: ۳۱)

شماره زوج	بازه زمانی	خط‌مبنای مکانی (متر)	شماره زوج	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 ۲۰۱۹/۰۸/۳۱	-۴۴,۱۴
۱۲	۲۰۱۹/۰۲/۲۴ تا ۲۰۱۹/۰۳/۰۸	۱۸,۲۱	۲۸	۲۰۱۹/۰۸/۳۱ تا ۲۰۱۹/۰۹/۰۴	-۹۴,۳۸
۱۳	۲۰۱۹/۰۳/۰۸ تا ۲۰۱۹/۰۳/۲۰	-۵۳,۷۱	۲۹	۲۰۱۹/۰۹/۰۴ تا ۲۰۱۹/۰۹/۱۶	-۳۲,۳۲
۱۴	۲۰۱۹/۰۳/۲۰ تا ۲۰۱۹/۰۴/۰۱	-۵۵,۸۳	۳۰	۲۰۱۹/۰۹/۱۶ تا ۲۰۱۹/۰۹/۲۸	-۴۷,۵۷
۱۵	۲۰۱۹/۰۴/۰۱ تا ۲۰۱۹/۰۴/۱۳	۱۲,۴۵	۳۱	۲۰۱۹/۰۹/۲۸ تا ۲۰۱۹/۱۰/۱۰	-۳۷,۴۲
۱۶	۲۰۱۹/۰۴/۱۳ تا ۲۰۱۹/۰۴/۲۵	-۱۰۶,۷۷			



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-۱ A 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 ارائه شده است).




شکل ۴- مدل گراف ساخته شده در نرم افزار SNAP به منظور اتوماتیک سازی مراحل پردازش جفت تصاویر راداری ماهواره سنتینل-۱ A برای محاسبه سری زمانی تصاویر همدوسی InSAR.

۴-۲- داده های 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 نقشه برداری میدانی برداشت گردیده اند، برای سال زراعی ۱۳۹۸ (۲۰۱۹ میلادی) به دست آمدند (شکل ۵). در مجموع ۱۳۵۸ قطعه زمین زراعی با حداکثر، میانگین و حداقل مساحت به ترتیب ۱، ۱۳ و ۰/۱ هکتار استفاده گردید. این قطعات زراعی مربوط به ۹ محصول غالب و متنوع در منطقه شامل یونجه، جو، لوبیا، ذرت، باقلا، کتان، سیب زمینی، چغندر قند و گندم هستند. به منظور برداشت نمونه های آموزشی، اعتبارسنجی و آزمایش جهت پیاده سازی روش طبقه بندی تصویر مبتنی بر یادگیری ماشین، یک حریم ۱۰ متری برای مرز قطعات زراعی در نظر گرفته می شود (از مرز قطعات به سمت داخل) تا از وجود پیکسل های مخلوط در نمونه های به دست آمده از مزارع همجوار مربوط به محصولات زراعی ناهمسان در تصاویر همدوسی جلوگیری گردد. در خصوص مزارع همجوار مربوط به محصولات زراعی همسان، حریم نامبرده لحاظ نمی شود. سپس در مجموع ۱۵۶۰۲۶ پیکسل از تصاویر همدوسی به عنوان نمونه از قطعات زراعی مختلف برداشت و بصورت تصادفی به سه دسته شامل نمونه های آموزشی (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمایشی (۱۵ درصد) تفکیک می شوند (جدول ۲).

به منظور نقشه برداری نوع محصول زراعی با استفاده از رویکردهای طبقه بندی تصاویر ماهواره ای، آگاهی از تقویم زراعی منطقه ضرورت دارد. تقویم زراعی حاصل از تجربیات کشاورزان در طول زمان، منبعی قابل استناد جهت آگاهی از زمان کاشت، رویش و

برداشت هر محصول است که در این مطالعه از طریق بهره‌گیری از دانش کشاورزان محلی جمع‌آوری گردید. در شکل (۶)، تقویم زراعی محصولات موردبررسی ارائه شده است.



شکل ۵- توزیع مکانی قطعات مزارع در منطقه مورد مطالعه استفاده شده جهت اخذ نمونه‌های آموزشی، اعتبارسنجی و آزمایشی

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

کلاس زراعی	آموزش	اعتبارسنجی	آزمایش	جمع کل
یونجه	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



کشت رویش برداشت

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

۵-۲- انتخاب ویژگی و بررسی پاسخ فنولوژیکی محصولات زراعی به همدوسی InSAR

از آنجاکه تمامی تصاویر همدوسی چندزمانه تولیدشده ممکن است حاوی اطلاعات ارزشمند جهت تفکیک محصولات زراعی نباشند، لذا انتخاب بازه زمانی مناسب برای استفاده از این تصاویر در الگوریتم‌های طبقه‌بندی‌کننده به منظور کاهش حجم پردازش ضروری به نظر رسید. بدین منظور، مقادیر میانگین همدوسی محصولات زراعی مختلف در سری زمانی یکساله به منظور تولید نمودار چرخه فنولوژی آنها استخراج می‌گردند. جهت اجتناب از خطاهای احتمالی مانند اختلاط مزارع همجوار و همچنین پیکسل‌های مخلوط، در قطعات زراعی مربوط به محصولات مختلف، پلیگون‌های مستطیلی شکل دربرگیرنده چندین پیکسل به عنوان نمونه از وسط قطعات لحاظ می‌شوند. در نهایت، با در نظر گرفتن تقویم زراعی منطقه (شکل ۶)، بازه زمانی مناسب جهت ورود تصاویر همدوسی به عنوان ویژگی به الگوریتم طبقه‌بندی‌کننده انتخاب می‌شود.

در حالت ایده‌آل چنانچه حرکات جابجایی زمین ناشی از زلزله، فرونشست و زمین‌لغزش رخ نداده باشد، انتظار می‌رود مناطق ساخته‌شده در گذر زمان سیگنال‌های فاز و به تبع از آن رفتار همدوسی راداری نسبتاً ثابتی داشته باشند. از طرف دیگر، انتظار می‌رود محصولات زراعی در مراحل ابتدایی فصل رویش رفتار همدوسی مشابه با خاک لخت داشته باشند (همدوسی نسبتاً بالا) و با شروع رویش و متراکم شدن آنها، مقدار همدوسی کاهش یابد. در پایان فصل رشد و به هنگام برداشت محصولات نیز قاعدتاً افزایش مقادیر همدوسی و مجدداً میل به سمت رفتار خاک لخت در مزارع را می‌توان انتظار داشت. بر این اساس، جهت حصول اطمینان از پاسخ فنولوژیکی محصولات زراعی به داده‌های همدوسی InSAR و همچنین قابلیت اطمینان این داده‌ها در بازه زمانی انتخابی، رفتار همدوسی آنها در قیاس با مناطق ساخته‌شده و خاک لخت مورد بررسی قرار می‌گیرد. محدوده‌های شاهد انتخابی بدین منظور شامل منطقه ساخته‌شده (سقف سالن‌های یک مرغداری واقع در شمال شرق منطقه مورد مطالعه)، خاک لخت (یک زمین بایر و فاقد پوشش گیاهی در مجاورت کارخانه لاستیک‌سازی گلدستون در نواحی غربی منطقه مورد مطالعه) و قطعه‌های برداشت‌شده از مزارع به تفکیک محصولات هستند (شکل ۷). سپس مقادیر آماره میانگین همدوسی در محدوده‌های شاهد بصورت سری زمانی استخراج و مبنای بررسی قرار می‌گیرند.



خاک لخت



منطقه ساخته شده




مزرعه لوبیا



مزرعه جو



مزرعه یونجه



مزرعه کتان



مزرعه باقلا



مزرعه ذرت



مزرعه گندم



مزرعه چغندر قند



مزرعه سیب زمینی

شکل ۷- محدوده‌های شاهد انتخابی (پلیگون قرمز رنگ) از منطقه مورد مطالعه به منظور بررسی پاسخ فنولوژیکی محصولات زراعی به همدوسی

InSAR

۲-۶- طبقه‌بندی تصویر

SVM یک تئوری 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, ۱۹۹۵). الگوریتم SVM یک طبقه-بندی کننده نرم محسوب می‌شود و توانایی غلبه بر مشکل توزیع غیر خطی داده‌ها را دارد. در این حالت با بهره‌گیری از توابع کرنل، داده‌ها به فضایی با ابعاد بالاتر انتقال داده می‌شوند که منجر به بهبود فرایند تفکیک پذیری گردیده و ابر صفحه جداکننده نیز در آن فضا تعیین می‌شود (Ren et al., ۲۰۱۸). جزئیات بیشتر در مورد مبانی ریاضی این طبقه‌بندی کننده را می‌توان در (Zhu & Blumberg ۲۰۰۲) یافت.

در رابطه با طبقه‌بندی کننده SVM، تعیین نوع کرنل، پارامترهای C (هزینه^۱) و گاما^۲ بر عملکرد مدل تاثیرگذار هستند. در اینجا، از رویکرد جست و جوی شبکه‌ای^۳ مبتنی بر اعتبارسنجی متقابل^۴ جهت یافتن بهترین ترکیب پارامترهای C و گاما استفاده می‌شود. بهره‌گیری از تکنیک اعتبارسنجی متقابل سبب می‌شود که از مشکل بیش‌پرازش^۵ مدل جلوگیری به عمل آید (Lin et al., ۲۰۰۸).

^۱ Cost

^۲ Gamma

^۳ Grid search

^۴ Cross validation

^۵ Overfitting

در روش جست‌وجوی شبکه‌ای فرایند یافتن مقادیر بهینه ترکیب پارامترهای C و γ ، بر اساس تعیین مقدار حداقل (کران پایین)، مقدار حداکثر (کران بالا) و تعداد مراحل یا سطوح در یک دامنه عددی مشخص انجام می‌شود. دامنه عددی دقیقی برای مقادیر پارامترهای C و γ وجود ندارد. با این حال، چنانچه دامنه وسیع‌تری در نظر گرفته شود احتمال اینکه روش جست‌وجوی شبکه‌ای بتواند بهترین مقدار را برای پارامترهای ترکیبی بیابد، بیشتر است (Syarif et al., ۲۰۱۶). از طرف دیگر، جهت تعیین توالی گام‌های تغییر مقادیر پارامترها در دامنه عددی موردنظر از مقیاس‌های مختلفی نظیر خطی و لگاریتمی استفاده می‌شود. همانطور که مطالعات پیشین تاکید داشته‌اند، لحاظ کردن تغییرات نمایی در توالی مقادیر پارامترها مبتنی بر یک مقیاس لگاریتمی، مناسب‌تر است (Hsu et al., ۲۰۰۳). بر این اساس، دامنه عددی نسبتاً وسیعی از 0.1 تا 100 در 10 سطح با مقیاس لگاریتمی به منظور اجرای روش جست‌وجوی شبکه‌ای در نظر گرفته می‌شود. با استفاده از تکنیک اعتبارسنجی متقابل به ازای مقادیر مختلفی از پارامترهای C و γ ، ابتدا داده‌ها به k زیر مجموعه تقسیم می‌شوند (در اکثر مطالعات $k=10$)، سپس در یک فرایند جایگشتی، 9 زیرمجموعه برای آموزش و یک زیرمجموعه برای اعتبارسنجی مدل استفاده می‌شود (Syarif et al., ۲۰۱۶). بدین ترتیب، میانگین صحت کلی در تکرارهای متوالی اعتبارسنجی متقابل جهت ارزیابی نتایج و انتخاب پارامترهای بهینه استفاده می‌شود. این فرایند به تفکیک کرنل‌های مختلف SVM شامل خطی^۱، چندجمله‌ای^۲، تابع پایه شعاعی^۳ و سیگموئید^۴ انجام می‌گردد.

۲-۷- ارزیابی صحت

ماتریس خطا^۵ یکی از روش‌های استاندارد جهت ارزیابی عملکرد و صحت یک مدل طبقه‌بندی است. ماتریس خطا بر اساس رابطه بین نمونه‌های کنترل زمینی و تصویر طبقه‌بندی شده محاسبه می‌شود (Stehman et al, ۲۰۰۷). در این مطالعه، صحت کلی^۶ و

^۱ Linear

^۲ Polynomial

^۳ Radial basis function (RBF)

^۴ Sigmoid

^۵ Confusion matrix


^۶ Overall accuracy

ضریب کاپا^۱ به دست آمده از ماتریس خطا به عنوان معیارهای ارزیابی عملکرد کلی طبقه‌بندی و از از صحت کاربر^۲ و صحت تولیدکننده^۳ نیز به منظور ارزیابی عملکرد مدل در کلاس‌های مختلف استفاده می‌شود.

۳- نتایج

۳-۱- انتخاب بازه زمانی مناسب جهت انتخاب ویژگی

بر اساس شکل (۸)، بازه زمانی ۲۰ مارس تا ۱۰ اکتبر ۲۰۱۹ (۲۹ اسفند ۱۳۹۷ تا ۱۸ مهر ۱۳۹۸) جهت تعیین نوع محصولات زراعی در منطقه مورد مطالعه مدنظر قرار گرفت. این بازه انتخابی پوشش‌دهنده تمامی محصولات زراعی به لحاظ زمان رویش تا برداشت است. بر اساس جدول (۱)، در این بازه زمانی ۱۷ تصویر همدوسی استفاده می‌شود که مشتمل بر زوج تصاویر شماره ۱۴ تا ۳۰ هستند.



شکل ۸- مقادیر میانگین همدوسی به تفکیک نمونه‌های محصولات زراعی مختلف در منطقه مورد مطالعه در بازه زمانی ۱۵ اکتبر ۲۰۱۸ (۲۳ مهر ۱۳۹۷) تا ۱۰ اکتبر ۲۰۱۹ (۱۸ مهر ۱۳۹۸).

^۱ Kappa coefficient


^۲ User's Accuracy

^۳ Producer's Accuracy


به منظور حصول 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) در بازه زمانی انتخابی مورد بررسی قرار گرفت. به دلیل تنوع محصولات زراعی از لحاظ دوره‌های کاشت، رویش و برداشت؛ جهت استخراج فنولوژی مبتنی بر تصاویر چندزمانه همدوسی و تحلیل‌پذیرتر نمودن اطلاعات، محصولات بر اساس دوره رویش تا برداشت 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 در دوره‌های رویش تا برداشت استخراج گردیدند (شکل‌های ۹ تا ۱۲). همانطور که نتایج نشان می‌دهد، در بازه زمانی انتخابی، سیگنال‌های فنولوژیکی محصولات مورد بررسی، اختلاطی با سیگنال‌های مناطق ساخته‌شده و خاک لخت ندارند. افزون بر این، روند تغییرات زمانی سیگنال‌های همدوسی محصولات زراعی مختلف در پاسخ به تغییرات فنولوژیکی آن‌ها الگوی نسبتاً متفاوتی نشان می‌دهد. این مهم حاکی از کارایی و قابلیت اطمینان داده‌های همدوسی InSAR جهت استفاده در الگوریتم طبقه‌بندی نوع محصول زراعی است.

جدول ۳- دسته‌بندی محصولات زراعی بر اساس زمان رویش و برداشت به منظور سهولت بررسی پاسخ فنولوژیکی به همدوسی InSAR


دسته	نام محصول	زمان کشت	زمان رویش	زمان برداشت	بازه زمانی بررسی از رویش تا برداشت - تعداد ماه
۱	جو	نیمه اول آبان	نیمه اول فروردین	نیمه اول مرداد	اول فروردین تا آخر مرداد (نیمه دوم مارس تا نیمه دوم آگوست) - ۵ ماه
	گندم			نیمه دوم مرداد	
۲	کتان	نیمه اول فروردین	نیمه اول اردیبهشت	نیمه دوم مرداد	اول اردیبهشت تا آخر شهریور (نیمه دوم آوریل تا نیمه دوم سپتامبر) - ۵ ماه
	لوبیا		نیمه دوم اردیبهشت	نیمه اول شهریور	
	باقلا			نیمه اول مرداد	
	سیب زمینی		نیمه اول خرداد	نیمه دوم شهریور	
۳	چغندر قند	نیمه دوم فروردین	نیمه دوم اردیبهشت	نیمه دوم مهر تا نیمه اول آبان	نیمه دوم اردیبهشت تا نیمه اول آبان (نیمه اول می تا نیمه اول نوامبر) - ۶ ماه
	ذرت	نیمه دوم فروردین تا نیمه اول خرداد	نیمه اول تیر	مهر	
۴	یونجه	فروردین	نیمه دوم اردیبهشت	- نیمه دوم خرداد - نیمه دوم مرداد - نیمه اول مهر	نیمه دوم اردیبهشت تا نیمه اول مهر (نیمه اول می تا نیمه اول اکتبر) - ۵ 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 قند (دسته‌بندی ۳ در جدول ۳)



شکل ۱۲- مقادیر میانگین همدوسی InSAR در محدوده‌های شاهد انتخابی از منطقه ساخته‌شده، 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

در خصوص طبقه‌بندی‌کننده SVM، ترکیب مختلف پارامترهای c و γ به تفکیک کرنل‌های مختلف در قالب مرحله اعتبارسنجی بررسی گردید. بدین ترتیب برای هر یک از کرنل‌های SVM، ترکیب بهینه پارامترها که بالاترین میزان صحت کلی را به دست داده‌اند، در جدول (۴) ارائه شده است. کرنل خطی فاقد پارامتر γ است، به همین دلیل فرایند جست‌وجوی شبکه‌ای بصورت تک

بعدی برای آن انجام شده است. همانطور که نتایج نشان می‌دهد، کرنل تابع پایه شعاعی (RBF) بالاترین میزان صحت کلی را با ترکیب مختلفی از پارامترهای c و γ به دست داده است. بدین ترتیب، جهت اجرای نهایی طبقه‌بندی‌کننده SVM در مرحله آزمایش از کرنل RBF مبتنی بر ضرایب بهینه مشخص شده در جدول (۴) استفاده گردید.

جدول ۴- ترکیب بهینه پارامترهای c و γ در کرنل‌های مختلف (سطر تیره‌رنگ بیانگر بالاترین صحت و به تبع از آن بهترین ترکیب پارامترها و کرنل است).


نوع کرنل	پارامترهای بهینه		صحت کلی (%)
	c	γ	
خطی	۱۲/۹۲	---	۵۷/۲۰
چندجمله‌ای	۴/۶۴	۰/۰۷	۵۸/۳۵
تابع پایه شعاعی	۴/۶۴	۰/۲۱	۵۹/۶۹
سیگموئید	۱۲/۹۲	۰/۰۱	۵۳/۷۰

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

در اینجا، نتایج پیاده‌سازی الگوریتم طبقه‌بندی‌کننده SVM با استفاده از ویژگی‌های انتخابی (زوج تصاویر همدوسی شماره ۱۴ تا ۳۰ در جدول ۱) و پارامترهای بهینه ارائه شده است. جهت ارزیابی صحت نقشه نوع محصول تولیدشده از نمونه‌های آزمایشی بهره گرفته شد. لازم به 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 ارائه شده است. با بکارگیری ویژگی‌های همدوسی و بر اساس ضرایب و کرنل بهینه، این الگوریتم صحت کلی ۶۰/۶ درصد نشان می‌دهد که بهترین عملکرد را در شناسایی گندم و بدترین را برای یونجه داشته است (جدول ۵). شکل (۱۳) نقشه نوع محصول تولیدشده را نمایش می‌دهد.

جدول ۵- نتایج نقشه برداری نوع محصول زراعی با استفاده از طبقه بندی کننده SVM

کلاس های زراعی	خطای Omission (%)	صحت تولید کننده (%)	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
سیب زمینی	۴۸,۳	۵۱,۷	۲۸,۷	۷۱,۳
چغندر قند	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 تولید شده توسط الگوریتم طبقه بندی کننده SVM - کرنل RBF

۴-۱- بررسی پاسخ فنولوژیکی محصولات زراعی مبتنی بر همدوسی InSAR

شکل (۸) مقادیر میانگین همدوسی به تفکیک نمونه‌های محصولات زراعی مختلف در منطقه مورد مطالعه در بازه زمانی ۱۵ اکتبر ۲۰۱۸ (۲۳ مهر ۱۳۹۷) تا ۱۰ اکتبر ۲۰۱۹ (۱۸ مهر ۱۳۹۸) را نشان می‌دهد. همانطور که در شکل (۸) مشاهده می‌شود، در پایان (سمت راست نمودار) و شروع (سمت چپ نمودار) سال زراعی، محصولات مورد بررسی به ترتیب کاهش و افزایش همدوسی را تجربه کرده‌اند. 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. بر این اساس، بازه زمانی ۲۰ مارس تا ۱۰ اکتبر ۲۰۱۹ (۲۹ اسفند ۱۳۹۷ تا ۱۸ مهر ۱۳۹۸) به عنوان بازه زمانی مورد بررسی جهت 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 مختلف مبتنی بر همدوسی چندزمانه InSAR مشاهده می‌شود. مطالعه اسدی و شمس‌الدینی (۲۰۲۴) نیز در همین منطقه، با استفاده از داده‌های بازپراکنش راداری ماهواره سنتینل-۱، به شناسایی و تفکیک محصولات مختلف شامل یونجه، گندم، جو، لوبیا، ذرت، باقلا، کتان، سیب‌زمینی و چغندر قند پرداخته است. این پژوهش نیز، زمان مناسب برای بررسی محصولات مذکور را بر اساس اطلاعات فنولوژیکی استخراج‌شده از تقویم زراعی منطقه و رسم سری زمانی NDVI^۱ تعیین کرده است. بر اساس نتایج این مطالعه، بازه زمانی مناسب برای بررسی محصولات از ۷ می 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 تأییدکننده نتایج مطالعه حاضر در خصوص انتخاب بازه زمانی مناسب مبتنی بر همدوسی InSAR جهت مطالعه رفتار فنولوژیکی محصولات زراعی است. تفاوت تقریبی ۵۰ روزه بین زمان آغاز دوره فنولوژیکی در مطالعه اسدی و شمس‌الدینی (۲۰۲۴) با تحقیق حاضر را می‌توان به تفاوت قابلیت‌های 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 عملکرد بهتری در تشخیص مراحل ابتدایی رشد گیاه و جوانه‌زنی داشته باشند (Nasirzadehdizaji, ۲۰۲۱).

^۱ Normalized Difference Vegetation Index

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 جهت استفاده در الگوریتم طبقه‌بندی‌کننده صحت می‌گذارد. بر اساس نتایج ژائو و همکاران، (۲۰۲۴)، میانگین مقادیر همدوسی InSAR برای محصولات برنج و ذرت در دوره‌های شخم‌زنی و کاشت، تحت تاثیر سیگنال‌های حاصل از خاک لخت، افزایش می‌یابند. پس از اتمام مراحل اولیه و آغاز مرحله رشد، امواج فاز راداری با گیاهان در تعامل قرار می‌گیرند و با تغییرات فیزیکی و هندسی برگ‌ها سبب کاهش مقادیر همدوسی می‌شوند. در نهایت، با پایان دوره رشد، همزمان با فرآیند برداشت، امواج فاز راداری مجدداً تحت تأثیر سیگنال‌های ناشی از خاک لخت قرار گرفته و مقادیر همدوسی افزایش می‌یابند. بر این اساس، با پایش تغییرات مقادیر همدوسی و انجام ارزیابی‌های مناسب از مراحل کاشت، رشد و برداشت، می‌توان اثرات عوامل مزاحم مانند خاک لخت و مناطق ساخته‌شده را شناسایی و از داده‌ها حذف کرد. در مطالعه حاضر نیز به منظور کنترل رفتار فنولوژیکی ۴ دسته محصولات زراعی (جدول ۳) در قیاس با سیگنال‌های به‌دست‌آمده از مناطق ساخته‌شده و خاک لخت در دوره‌های رویش تا برداشت محصولات (شکل‌های ۹ تا ۱۲)، نتایج نشان داد که منطقه ساخته‌شده دارای سیگنال نسبتاً ثابتی است و همبستگی خوبی نیز بین مقادیر همدوسی و مراحل فنولوژی محصولات زراعی در قیاس با خاک لخت وجود دارد. برای تمامی محصولات زراعی، رفتار همدوسی در ابتدای دوره رشد نزدیک به رفتار خاک لخت است که با رویش و تکامل محصول و رسیدن به مرحله اوج رشد، تفاوت رفتار آنها به حداکثر می‌رسد. در پایان فصل رشد نیز رفتار همدوسی محصولات مختلف به رفتار خاک لخت متمایل شده‌اند. در خصوص شکل (۱۲)، الگوی نوسانی در رفتار همدوسی یونجه به خاطر 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 ویلارویا و همکاران، (۲۰۲۲)؛ نصیری‌زاده دیزجی، (۲۰۲۱)؛ بوسکایر و همکاران (۲۰۲۰) و کوئردا و همکاران (۲۰۲۰) نیز موید آن است که در مراحل رویشی اصلی محصولات زراعی، میزان همدوسی در بخش‌های مختلف منطقه کمتر 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

بر اساس نتایج ارائه شده در جدول (۴)، کرنل تابع پایه شعاعی (RBF) بالاترین میزان صحت کلی را با ترکیب مختلفی از پارامترهای c و گاما به دست داده است. صحت کلی به دست آمده از این کرنل ۵۹/۶۹٪ است. کرنل سیگموئید با ۵۳/۷۰٪ صحت کلی، کمترین میزان صحت کلی را داشته است. در کاربردهای مربوط به طبقه‌بندی تصاویر ماهواره‌ای، کرنل RBF معمولاً نتایج بهتری را ارائه داده است (Forudikhor et al, ۲۰۱۰). نتایج کاوزوگلو و کولکسن (۲۰۰۹) نیز نشان می‌دهد که طبقه‌بندی‌کننده SVM با استفاده

از کرنل RBF از نظر صحت کلی بهتر از سایرین عمل می‌کند. در همین راستا، خسروی (۲۰۲۴) نیز در مطالعه خود از کرنل RBF استفاده نموده و اذعان داشته است که از جمله رایج‌ترین توابع کرنل در حوزه طبقه‌بندی داده‌های سنجش‌ازدور است. انتخاب تابع کرنل SVM به نوع و ماهیت داده‌ها و مسئله بستگی دارد. کرنل RBF در مسائل پیچیده بهتر عمل می‌کند. هنگامی که شناختی از نوع داده‌ها و ماهیت آنها در اختیار نیست و توزیع داده‌ها غیرخطی است، این تابع مقادیر بهینه را به خود اختصاص می‌دهد (Forudikhor et al, ۲۰۱۰).

۴-۳- کارایی تصاویر همدوسی و طبقه‌بندی‌کننده SVM و عوامل موثر بر آنها

نتایج مدل‌سازی با استفاده از ویژگی‌های انتخاب شده و پارامترهای بهینه در مرحله آزمایش عملکرد مدل در جدول (۵) ارائه شده است. صحت کلی مدل‌سازی ۶۰/۶ است. مدل بهترین عملکرد را در شناسایی گندم و بدترین را برای یونجه داشته است. در این مطالعه از تصاویر قطبش VV استفاده شده است. احتمالاً ساختار عمودی گیاه گندم بر این مسئله بی‌تاثیر نبوده و توانسته با موج ارسالی رادار در حالت عمودی برهمکنش بیشتری نشان دهد (Villarroya-Carpio et al., ۲۰۲۲). دلیل عملکرد بهتر مدل در شناسایی گندم را می‌توان به این مورد مرتبط دانست.

بر اساس جدول (۵) صحت کاربر برای گیاهان گندم یا سیب‌زمینی بالاتر و برای گیاهان ذرت، باقلا و یونجه پایین‌تر است. دلیل این مسئله می‌تواند به تعداد نمونه‌های آموزشی هر محصول مرتبط باشد. همانطور که در جدول (۲) آمده است، تعداد نمونه‌های آموزشی برای گیاهان گندم و سیب‌زمینی بالاتر و برای گیاهان ذرت، باقلا و یونجه کمتر است. بر این اساس می‌توان نتیجه گرفت که تعداد نمونه‌های آموزشی بر عملکرد مدل تاثیر گذار است و بیشتر بودن آنها می‌تواند به بهبود صحت طبقه‌بندی بیانجامد. در همین خصوص، همانطور که فو^۱ و همکاران (۲۰۲۳) در مطالعه‌ای جهت بررسی اثرات نمونه‌های آموزشی بر صحت نقشه برداری نوع محصول با الگوریتم‌های یادگیری ماشین اذعان داشتند، 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 کلاس-هایی که نمونه‌های آموزشی کم بوده است منجر به کاهش میزان صحت کلی مدل نیز شده است.

یکی دیگر از دلایل احتمالی در رابطه با پائین بودن صحت کلی طبقه‌بندی ویژگی‌های همدوسی را می‌توان کم بودن تعداد آنها عنوان کرد. در این مطالعه به منظور ارزیابی کارایی تصاویر همدوسی چندزمانه InSAR تنها از داده‌های SAR ماهواره سنتینل-۱

^۱ Fu

A مربوط به گذر صعودی و قطبش VV استفاده گردید که تعداد ۱۷ ویژگی بدین طریق تولید شد. چنانچه از داده‌های قطبش VH و همچنین گذر نزولی نیز استفاده گردد، می‌توان تعداد ویژگی‌های قابل استخراج را به حدوداً سه و نیم برابر (تا ۶۸ ویژگی) افزایش داد. طبیعتاً فرایند انتخاب ویژگی از بین ۶۸ ویژگی نسبت به تنها ۱۷ ویژگی می‌تواند اطلاعات بیشتر و مهمتری جهت واردسازی به طبقه‌بندی‌کننده به دست دهد. امهرت^۱ و همکاران (۲۰۲۲) نیز در مطالعه‌ای به منظور نقشه‌برداری محصولات زراعی با استفاده از تکنیک تداخل‌سنجی راداری، تاکید داشته‌اند که بهره‌گیری ترکیبی از داده‌های SAR مربوط به قطبش‌های VV و VH نتایج طبقه‌بندی را بهبود می‌بخشد. 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 چهار برابر افزایش می‌دهد. علاوه بر این، در مطالعه حاضر تصاویر همدوسی از داده‌های SAR با تفکیک زمانی ۱۲ روزه تولید شده‌اند، به منظور افزایش تعداد ویژگی‌ها می‌توان از فواصل زمانی طولانی‌تر مانند ۲۴ و ۳۶ روزه نیز استفاده کرد. البته بایستی در نظر داشت که افزایش فاصله زمانی بین تصاویر متوالی می‌تواند سبب غالب شدن اثرات ناشی از پویایی شرایط جوی بر ناهمبستگی زمانی فاز گردد و بدین ترتیب نتوان اطلاعات چندانی از تغییرات فنولوژیکی محصولات زراعی به دست آورد. با علم به این مسئله، همانطور که کوئردا و همکاران (۲۰۲۰) نیز در خصوص نقشه‌برداری نوع محصولات زراعی اذعان داشته‌اند، چنانچه داده‌های سنتینل-۱ A و B با تفکیک زمانی ۶ روزه در دسترس باشند، می‌توان با ترکیب‌های ۶، ۱۲ و حداکثر ۱۸ روزه؛ تعداد ویژگی‌های بیشتری به منظور طبقه‌بندی محصولات زراعی تولید نمود.

از آنجاکه داده‌های همدوسی مبتنی بر تصاویر فاز رادار محاسبه می‌شوند، بنابراین به خصوصیات فیزیکی پدیده‌ها حساس هستند. بر این اساس، ممکن است برخی محصولات زراعی مختلف دارای خصوصیات هندسی و فیزیکی مشابه، رفتار همدوسی مشابهی نشان دهند که این مهم تفکیک آنها را با مشکل مواجه می‌سازد. لذا ضرورت بهره‌گیری از مجموعه داده‌های مکمل در کنار این داده‌ها احساس می‌شود. نتایج مطالعات کوئردا و همکاران (۲۰۲۰)، جاکوب و همکاران (۲۰۲۰)، ژو و همکاران (۲۰۱۷) نیز تاییدکننده این مسئله است. داده‌های اپتیک از جمله مجموعه داده‌هایی هستند که می‌توان به این منظور مورد استفاده قرار داد. داده‌های چندطیفی اپتیک با دسترسی رایگان، به دلیل حساسیت به خصوصیات شیمیایی عوارض از طریق اندازه‌گیری رفتار طیفی آنها، اطلاعات ارزشمندی در مورد محصولات زراعی مختلف ارائه می‌دهند که جهت شناسایی و تفکیک آنها بسیار کارآمد هستند و می‌توانند در کنار تصاویر همدوسی InSAR به افزایش صحت تفکیک محصولات زراعی کمک نمایند. در خصوص سایر مجموعه داده‌ها، مطالعات گذشته نظیر کوئردا و همکاران (۲۰۲۰)، ویلارویا و همکاران (۲۰۲۲)، نصیری‌زاده دیزجی و همکاران (۲۰۲۱)، بر کارایی داده‌های بازپراکنش راداری در قطبش‌های مختلف به منظور شناسایی محصولات زراعی تاکید داشته‌اند. لذا انتظار می‌رود که تلفیق ویژگی‌های

^۱ Amherdt

مستخرج از همدوسی InSAR و بازپراکنش راداری در قطبش‌های مختلف و گذرهای نزولی و صعودی صحت طبقه‌بندی را تا حدی ارتقاء دهد.

عواملی همچون اختلاف منظر سنجنده (خط‌مبنای مکانی)، توپوگرافی زمین (شیب و جهت) و فاصله زمانی بین تصاویر رادار بر میزان اطلاعات قابل استخراج از داده‌های همدوسی موثر هستند. بر این اساس، ممکن است محصولات زراعی یکسان در نواحی مختلف رفتار همدوسی متفاوتی به دست دهند که کاملاً مرتبط با خصوصیات فیزیکی آنها نباشد و در واقع ناشی از یکی از عوامل نامبرده باشد. این مسئله بطور کلی اشاره به تصادفی عمل کردن داده‌های همدوسی در شرایط محیطی متفاوت دارد که ممکن است ناشی از تفاوت در مناطق مختلف به علت اثرات ناهمبستگی مکانی و زمانی باشد. به منظور مرتفع‌سازی این مسئله توسعه شاخص‌های مبتنی بر سری زمانی تصاویر همدوسی InSAR که بتواند در خصوص این چالش اطلاعات تکمیلی به طبقه‌بندی‌کننده وارد کند، ممکن است راهگشا واقع گردد (Ebrahimzadeh et al, ۲۰۲۳).

نوع و کارایی الگوریتم طبقه‌بندی تصویر نیز می‌تواند بر میزان صحت نتایج موثر باشد. طبقه‌بندی‌کننده SVM که در این مطالعه استفاده شد، به عنوان یکی از مرسوم‌ترین و پرکاربردترین روش‌های مبتنی بر یادگیری ماشین در زمینه نقشه‌برداری نوع محصول زراعی به شمار می‌رود. با این حال، امروزه رویکردهای کارآمد و جدیدتری مبتنی بر یادگیری عمیق نیز توسعه داده شده‌اند که بطور گسترده‌ای در زمینه‌های مختلف خصوصاً نقشه‌برداری نوع محصول زراعی استفاده شده‌اند. لذا توصیه می‌گردد به منظور افزایش صحت نقشه‌برداری محصولات زراعی از روش‌های نوین به صورت مکمل استفاده گردد. در این راستا، نتایج مطالعه جاکوب و همکاران (۲۰۲۰) و اسدی و شمس‌الدینی (۲۰۲۴) نیز موید استفاده مکمل از روش‌های نوین و افزایش صحت نقشه‌برداری محصولات زراعی است.

۵- نتیجه‌گیری

مطالعه حاضر با هدف ارزیابی کارایی داده‌های همدوسی تداخل‌سنجی راداری (InSAR) جهت نقشه‌برداری نوع محصول زراعی مبتنی بر روش‌های یادگیری ماشین در دشت اردبیل انجام شده است. بدین منظور، از یک سری زمانی یک‌ساله (۱۳۹۷-۱۳۹۸) شامل ۳۲ تصویر SAR از ماهواره سنتینل-۱ A برای تولید تصاویر همدوسی چندزمانه استفاده شده است. با بکارگیری 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 مختلف مرتبط با آنها در سری زمانی به منظور استخراج نمودار چرخه فنولوژی آنها محاسبه گردید. بر این اساس، بازه زمانی ۲۰ مارس تا ۱۰ اکتبر ۲۰۱۹ (۲۹ اسفند ۱۳۹۷ تا ۱۸ مهر ۱۳۹۸)، که تمامی مراحل

رشد تا برداشت محصولات زراعی موردبررسی را پوشش می‌دهد، به‌عنوان دوره زمانی مناسب جهت ارزیابی قابلیت داده‌های همدوسی InSAR انتخاب شد. این بازه زمانی شامل ۱۷ تصویر همدوسی است که امکان تفکیک دقیق‌تر محصولات زراعی و بررسی رفتار فنولوژیکی آنها را فراهم می‌کند. در ادامه، به منظور حصول اطمینان از ارتباط مقادیر همدوسی InSAR با مراحل فنولوژیکی محصولات زراعی موردبررسی، رفتار زمانی سیگنال‌های همدوسی مربوط به هر یک از محصولات زراعی نامبرده در قیاس با سیگنال‌های مناطق ساخته‌شده و خاک لخت در چندین مزرعه شاهد مورد ارزیابی قرار گرفت. در نهایت، تصاویر همدوسی در بازه زمانی انتخابی به‌عنوان ویژگی‌های ورودی برای کالیبراسیون یک طبقه‌بندی‌کننده ماشین بردار پشتیبان (SVM) با کرنل‌های مختلف برای ارزیابی قابلیت‌های این مجموعه‌داده جهت شناسایی و تفکیک محصولات زراعی مورد استفاده قرار گرفتند. بطور کلی یافته‌های حاصل از این پژوهش را می‌توان به‌صورت زیر خلاصه کرد:

- بررسی مقادیر سری زمانی همدوسی در مناطق شاهد انتخابی حاکی از تمایز رفتار همدوسی محصولات زراعی مختلف در مقایسه با هم و همچنین نسبت به مناطق ساخته‌شده و خاک لخت است. بر این اساس، داده‌های همدوسی InSAR انطباق خوبی با مراحل فنولوژیکی اصلی محصولات زراعی نشان می‌دهند که این مهم بر کارآمدی این داده‌ها جهت پایش وضعیت محصولات و شناسایی آنها تاکید دارد.

- از میان کرنل‌های مختلف SVM، کرنل تابع پایه شعاعی (RBF) بالاترین میزان صحت کلی برابر با ۵۹/۶۹ درصد را با ترکیب بهینه‌ای از پارامترهای C و گاما در مرحله اعتبارسنجی، فراهم نمود.

- صحت کلی نقشه نوع محصول زراعی تولیدشده با استفاده از طبقه‌بندی‌کننده SVM و کرنل RBF در مرحله آزمایش برابر با ۶۰/۶۶ درصد است که بهترین عملکرد را در شناسایی گندم و ضعیف‌ترین عملکرد را برای یونجه داشته است.

هدف اصلی مطالعه حاضر ارزیابی پاسخ فنولوژیکی محصولات زراعی غالب در شرایط اقلیمی ایران مبتنی بر همدوسی InSAR جهت درک کارایی این مجموعه‌داده و هموار کردن مسیر برای بکارگیری آن در ادبیات رویکردهای نقشه‌برداری نوع محصول زراعی و تفکیک سطح زیرکشت اراضی در راستای مدیریت بهینه کشاورزی در کشور است. همانطور که نتایج نشان داد، داده‌های همدوسی InSAR در فرایند طبقه‌بندی تصویر با صحت کلی بیش از ۶۰٪ بطور کلی اطلاعات مفید و قابل توجهی جهت مطالعه رفتار فنولوژیکی محصولات زراعی مختلف و همچنین نقشه‌برداری آنها ارائه می‌دهند. بررسی مطالعات داخلی و خارجی پیشین در حوزه‌های مشابه به ویژه 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 بکارگیری روش‌های یادگیری عمیق به صورت مستقل و گروهی می‌توان صحت نقشه‌برداری محصولات زراعی را بهبود بخشید.

Abiyat, M., Abiyat, M., and Abiyat, M. (۲۰۲۲). Evaluation of Efficiency between Classification Methods and Spectral Indices in Cropped Area Estimation of Shush County. *Water and Soil*, 36(۴), ۴۹۳-۵۰۹. <https://doi.org/10.22077/jsw.2022.76746.1167>. (Persian)

Akbary, N., Sameti, M., & Hadyan, v. (۲۰۰۳). The impact of public expenditures on agriculture value added. *eqtesad-e keshavarzi va towse'e*, ۱۱(۱-۲), ۱۳۷-۱۶۶. <https://sid.ir/paper/24163/fa>. (Persian)

Alizadeh, P., Kamkar, B., shataee, S., kazemi posht masari, H. (۲۰۱۸). 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(۳), ۴۱-۶۱. <https://doi.org/10.22092/aj.2018.121231.1268>. (Persian)

Amherdt, S., Di Leo, N. C., Pereira, A., Cornero, C., & Pacino, M. C. (۲۰۲۲). Assessment of interferometric coherence contribution to corn and soybean mapping with Sentinel-۱ data time series. *Geocarto international*, ۱-۲۲. <https://doi.org/10.1080/10106049.2022.2144472>.

Asadi, B., & Shamsoddini, A. (۲۰۲۴). Crop mapping through a hybrid machine learning and deep learning method. *Remote Sensing Applications: Society and Environment*, ۳۳, ۱۰۱۰۹۰. <https://doi.org/10.1016/j.rsase.2023.101090>.

Asadi, B., and shamsoddini, A. (۲۰۲۴). Crop mapping using a combination of Sentinel-۱ and ۲ images in Ardabil province. *Iranian Journal of Remote Sensing and GIS*, ۱۶(۳), ۲۵-۴۶. <https://doi.org/10.48308/gisj.2023.103090>. (Persian)

Azzari, G. and Lobell, D.B., ۲۰۱۷. Landsat-based classification in the cloud: an opportunity for a paradigm shift in land cover monitoring. In: *Remote Sensing of Environment, Big Remotely Sensed Data: tools, applications and experiences*. ۲۰۲. pp. ۶۴-۷۴. <https://doi.org/10.1016/j.rse.2017.05.020>.

Busquier, M., Lopez-Sanchez, J. M., Mestre-Quereda, A., Navarro, E., González-Dugo, M. P., & Mateos, L. (۲۰۲۰). Exploring TanDEM-X interferometric products for crop-type mapping. *Remote Sensing*, ۱۲(۱۱), ۱۷۷۴.

Crosetto, M., Tscherning, C. C., Crippa, B., & Castillo, M. (۲۰۰۲). Subsidence monitoring using SAR interferometry: Reduction of the atmospheric effects using stochastic filtering. *Geophysical Research Letters*, ۲۹(۹), ۲۶-۱. <https://doi.org/10.1029/2001GL013044>.

Ebrahimzadeh, S., Soleimani, M., Atarchi, S., Saadat Novin, M., Shabanian, H. (۲۰۲۳). Detection of areas with severely eroded soils using Sentinel-۱ interferometric SAR coherence (Study area: Khuzestan province). *jgit* ۲۰۲۳; ۱۱ (۳): ۵۹-۸۴. <http://dx.doi.org/10.61186/jgit.11,3,59>. (Persian)

Engdahl, M. E., Borgeaud, M., & Rast, M. (۲۰۰۱). The use of ERS-۱/۲ tandem interferometric coherence in the estimation of agricultural crop heights. *IEEE transactions on geoscience and remote sensing*, ۳۹(۸), ۱۷۹۹-۱۸۰۶. <https://doi.org/10.1109/36.942008>.

Ezzati, H., Pourbayramian, S., Sarvoghmet, Moharram. (۲۰۱۷), The effect of Yamchi Dam on increasing the groundwater level of the Ardabil Plain aquifer, ۱۰th National Geology Conference of Payam Noor University. <https://civilica.com/doc/621832>. (Persian)

Forudikhor, A., Sanei, M., Ajdari Moghadam, M. (۲۰۱۰). 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*, ۱۱(۵), ۷۷۲-۷۸۴. <https://civilica.com/doc/1210864>. (Persian)

Fu, Y., Shen, R., Song, C., Dong, J., Han, W., Ye, T., & Yuan, W. (۲۰۲۳). Exploring the effects of training samples on the accuracy of crop mapping with machine learning algorithm. *Science of Remote Sensing*, ۷, ۱۰۰۰۸۱. <https://doi.org/10.1016/j.srs.2023.100081>.

Holzer, T. L., & Galloway, D. L. (۲۰۰۵). Impacts of land subsidence caused by withdrawal of underground fluids in the United States. [https://doi.org/10.1130/2005.4.16\(8\)](https://doi.org/10.1130/2005.4.16(8)).

Hsu, C. W., Chang, C. C., & Lin, C. J. (۲۰۰۳). A practical guide to support vector classification.

Huber, M., Kumar, V., Steele-Dunne, S. C., & Rommen, B. (۲۰۲۳, July). Sentinel-۱ InSAR Coherence as an Indicator of Monitor Farming Activities. In *IGARSS ۲۰۲۳-۲۰۲۳ IEEE International Geoscience and Remote Sensing Symposium* (pp. ۴۲۹-۴۳۲). IEEE. <https://doi.org/10.1109/IGARSS52108.2023.10281022>.

Jacob, A. W., Vicente-Guijalba, F., Lopez-Martinez, C., Lopez-Sanchez, J. M., Litzinger, M., Kristen, H., ... & Engdahl, M. E. (۲۰۲۰). Sentinel-۱ 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*, ۱۳, ۵۳۵-۵۵۲. <https://doi.org/10.1109/JSTARS.2019.2908847>.

Jamali, A., ۲۰۲۰ “Sentinel-۱ Image Classification Using Machine Learning Algorithms Based on the Support Vector Machine and Random Forest,” *Int. J. Geoinformatics*, vol. ۱۶, no. ۲.

Jensen, J. R. (۱۹۹۶). *Introductory digital image processing: a remote sensing perspective* (No. Ed. ۲). Prentice-Hall Inc.

Kavzoglu, T., & Colkesen, I. (۲۰۰۹). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, ۱۱(۵), ۳۵۲-۳۵۹. <https://doi.org/10.1016/j.jag.2009.06.002>.

Khosravi, I. (۲۰۲۴). Crop Mapping from Landsat-۸ Images Time Series Using Machine-Learning Methods (Case Study: Marvdasht in Fars Province). *Geography and Environmental Planning*, ۳۵(۲), ۴۵-۶۶. <https://doi.org/10.22108/gep.2024.138610.16.1>. (Persian)

Li, G., Cui, J., Han, W., Zhang, H., Huang, S., Chen, H., & Ao, J. (۲۰۲۲). Crop type mapping using time-series Sentinel-۲ imagery and U-Net in early growth periods in the Hetao irrigation district in China. *Computers and Electronics in Agriculture*, 203, ۱۰۷۴۷۸. <https://doi.org/10.1016/j.compag.2022.107478>.

Lin, S. W., K.C. Ying, S.C. Chen, and Z.J. Lee. ۲۰۰۸. Particle swarm optimization for parameter determination and feature selection of support vector machines. *Expert systems with applications*, 35(۴), ۱۸۱۷-۱۸۲۴. <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. (۲۰۲۳). Comparisons between temporal statistical metrics, time series stacks and phenological features derived from NASA Harmonized Landsat Sentinel-۲ data for crop type mapping. *Computers and Electronics in Agriculture*, 211, ۱۰۸۰۱۵. <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. (۲۰۲۰). Time-series of Sentinel-۱ interferometric coherence and backscatter for crop-type mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, ۴۰۷۰-۴۰۸۴. <http://dx.doi.org/10.1109/JSTARS.2020.3008096>.

Meteorological Yearbook of Ardabil Province (۱۴۰۰), Ardabil Province Meteorological Organization. (Persian)

Nasirzadehdizaji, R., Cakir, Z., Sanli, F. B., Abdikan, S., Pepe, A., & Calo, F. (۲۰۲۱). Sentinel-۱ interferometric coherence and backscattering analysis for crop monitoring. *Computers and Electronics in Agriculture*, ۱۸۵, ۱۰۶۱۱۸. <https://doi.org/10.1016/j.compag.2021.106118>.

Navale. A and D. Haldar., ۲۰۱۹ "Evaluation of machine learning algorithms to Sentinel SAR data," *Spat. Inf. Res.*, pp. ۱-۱۱. <http://dx.doi.org/10.21203/rs.3.rs-۴۰۱۱۸6/v1>.

Pandit, A., Sawant, S., Mohite, J., & Pappula, S. (۲۰۲۲). Sentinel-۱-derived coherence time-series for crop monitoring in Indian agriculture region. *Geocarto International*, ۳۷(۲۵), ۹۴۹۷-۹۵۱۷. <https://doi.org/10.1080/1010.6489.2021.2022008>.

Ren, F., Y. Li, and M. Hu. ۲۰۱۸. Multi-classifier ensemble based on dynamic weights. *Multimedia Tools and Applications*, 77(۱۶), ۲۱۰۸۳-۲۱۱۰۷. <https://doi.org/10.1007/s11042-017-0480-0>.

Senanayake, S., Biswajeet, P., Alfredo, H., Jane, B. (۲۰۲۰). "A Review on Assessing and Mapping Soil Erosion Hazard Using Geo-Informatics Technology for Farming System Management" *Remote Sensing* ۱۲, no. ۲۴: ۴۰۶۳. <https://doi.org/10.3390/rs12244063>.

Soleimani, M., Attarchi, S., Mahmoodi-Vanolya, N., Bakhshizadeh, F., Ahmadi, H. (۲۰۲۱). Evaluation of Sentinel-۱ Interferometric SAR Coherence efficiency for Land Cover Mapping. *jgit* ۲۰۲۱; ۹ (۳) :۸۵-۱۰۷. <http://dx.doi.org/10.52047/jgit.9,3,85>. (Persian)

Stehman, S. V., Arora, M. K., Kasetkasem, T., & Varshney, P. K. (2017). Estimation of fuzzy error matrix accuracy measures under stratified random sampling. *Photogrammetric Engineering & Remote Sensing*, 73(2), 160-173. <http://dx.doi.org/10.1016/j.pers.2017.01.001>.

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), 1002-1009. <http://dx.doi.org/10.12928/telkomnika.v14i4.3906>.

Touzi, R., Lopes, A., Bruniquel, J., & Vachon, P. W. (1999). Coherence estimation for SAR imagery. *IEEE transactions on geoscience and remote sensing*, 37(1), 130-149. <https://doi.org/10.1109/37.739147>.

Vapnik, V.N. 1995. The Nature of Statistical Learning Theory. New York: Springer Verlag. <http://dx.doi.org/10.1007/978-1-4757-2449-0>.

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, 113208. <https://doi.org/10.1016/j.rse.2022.113208>.

Zhao, Q., Xie, Q., Peng, X., Bao, Y., Jia, T., Yue, L., ... & Zhu, J. (2023). 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, 903-908. <https://doi.org/10.5194/isprs-archives-XLVIII-1-2023-903-2023>.

Zhao, R., You, W., & Fan, D. (2023). Staple crop mapping potential analysis and application of Sentinel-1 interferometric coherence: A case study in the Songnen Plain, China. *Advances in Space Research*, 71(7), 2993-3010. https://ui.adsabs.harvard.edu/link_gateway/2023AdSpR...71.2993Z/doi:10.1016/j.asr.2023.06.037.

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), 1210. <https://doi.org/10.3390/s17061210>.

Zhu, G., and D.G. Blumberg. (2002). Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel. *Remote Sensing of Environment*, 80(2), 233-240. [http://dx.doi.org/10.1016/S0034-4267\(01\)00300-4](http://dx.doi.org/10.1016/S0034-4267(01)00300-4).