

ارزیابی قابلیت داده‌های همدوسی تداخل‌سنجی راداری سنتینل-۱ جهت تهیه نقشه پوشش زمین

مسعود سلیمانی^۱، سارا عطارچی^{۲*}، نرجس محمودی وانعلیا^۱، فریمه بخشی‌زاده^۱، حامد احمدی^۱

۱- دانشجوی دکتری سنجش‌ازدور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران

۲- استادیار گروه سنجش‌ازدور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۹/۱۲/۲۷ تاریخ پذیرش مقاله: ۱۴۰۰/۰۹/۱۵

چکیده

در این مطالعه، جهت ارزیابی قابلیت‌های سری زمانی داده‌های تداخل‌سنجی رادار دریچه مصنوعی (*InSAR*) و یادگیری ماشین در تهیه نقشه پوشش زمین، داده‌های ماهواره سنتینل-۱ (شامل ۱۶ تصویر *SLC* با تفکیک زمانی تقریباً ۲۴ روزه) در بازه زمانی ۲۰۱۸ تا ۲۰۲۰ برای محدوده‌ای از شهرستان اهواز در استان خوزستان استفاده شدند. از طریق پردازش‌های *InSAR*، ۲۵ تصویر همدوسی بر اساس جفت تصاویر رادار در بازه‌های زمانی مختلف تولید گردیدند. پنج طبقه غالب پوشش زمین در منطقه شامل: اراضی ساخته‌شده، اراضی کشاورزی، پهنه‌های آبی، خاک لخت و پوشش گیاهی طبیعی متراکم، شناسایی و در نظر گرفته شدند. با استفاده از تصاویر قدرت تفکیک مکانی بالای گوگل ارث، در مجموع ۴۹۳۰ نمونه آموزشی با توزیع مکانی مناسب برای تمامی طبقات پوشش زمین اخذ گردید. تصاویر چندزمانه همدوسی به‌عنوان ورودی طبقه‌بندی‌کننده ماشین بردار پشتیبان (*SVM*) استفاده شدند. فرایند آموزش و ارزیابی صحت کرنل‌های مختلف *SVM* به ترتیب با استفاده از ۸۰ و ۲۰ درصد نمونه‌های آموزشی صورت گرفت. بر اساس نتایج طبقه‌بندی، میزان صحت کلی در کرنل‌های خطی، چندجمله‌ای درجه دو، چندجمله‌ای درجه چهار، چندجمله‌ای درجه شش، تابع پایه شعاعی و سیگموئید به ترتیب برابر با ۶۰/۷، ۶۴/۷، ۶۷/۷، ۶۹/۹، ۶۶/۳ و ۵۹/۵ درصد و مقدار ضریب کاپا ۵۰/۸۸، ۵۵/۸۷، ۵۹/۶۲، ۶۲/۳۸، ۵۷/۸۷ و ۴۹/۳۸ درصد ارزیابی گردید. در نتیجه، بالاترین میزان صحت کلی و ضریب کاپا برای کرنل چندجمله‌ای درجه شش و کمترین میزان آن برای کرنل سیگموئید به دست آمد. بر اساس نتایج ارزیابی صحت کاربر و صحت تولیدکننده در تمامی کرنل‌ها، اراضی ساخته‌شده بالاترین میزان صحت (۹۳ - ۹۸ درصد) و پوشش گیاهی متراکم کمترین میزان صحت (۱۱ - ۵۶/۲۵ درصد) را به خود اختصاص دادند. به‌طورکلی نتایج حاصل، بر پتانسیل بالای داده‌های *InSAR* جهت شناسایی طبقات پوشش زمین تأکید دارد. در این میان، تأثیر الگوریتم طبقه‌بندی نیز بر میزان کارایی داده‌ها حائز اهمیت است.

کلید واژه‌ها: تهیه نقشه پوشش زمین، طبقه‌بندی، ماشین بردار پشتیبان، تداخل‌سنجی رادار دریچه مصنوعی، همدوسی.

* نویسنده مکاتبه کننده: تهران، خیابان انقلاب، خیابان قدس، کوچه آذین، دانشکده جغرافیا، گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشگاه تهران.

۱- مقدمه

طبقه‌بندی پوشش زمین^۱ به‌عنوان یک منبع اطلاعاتی کاربردی، نقش بسیار مهمی در مدیریت منابع سطح زمین دارد و در بسیاری از حوزه‌های علمی، اجتماعی و اقتصادی مانند مدیریت مسائل زیست‌محیطی و ارزیابی خطر، بهره‌برداری مؤثر از منابع طبیعی، توسعه شهری و کشاورزی مورد استفاده قرار می‌گیرد [۱]. نوع پوشش زمین متغیری پویا و منعکس‌کننده تعامل بین فعالیت‌های اقتصادی - اجتماعی و تغییرات محیطی - منطقه‌ای است. از این‌رو لازم است که این نقشه‌ها جهت تصمیم‌گیری‌های مؤثر و کارآمد، به‌طور مرتب به‌روزرسانی شده و مورد استفاده قرار بگیرند. نقشه‌های پوشش زمین به‌روز شده می‌توانند اطلاعات قابل اطمینانی را در مقیاس‌های محلی، منطقه‌ای و ملی در اختیار سازمان‌های ذی‌ربط قرار دهند [۲]. علاوه بر این، تهیه نقشه‌های پوشش زمین در فواصل زمانی مناسب می‌تواند برای تشخیص و نظارت بر تغییرات به وجود آمده در سطح زمین جهت آگاهی از وضعیت موجود و پیش‌بینی خطرات تهدیدکننده محیط طبیعی در آینده، مورد استفاده قرار گیرد [۱]. در نتیجه دسترسی به اطلاعات پوشش زمین در مقیاس‌های زمانی مختلف، برای سیاست‌گذاری‌ها و تصمیم‌گیری‌های مدیریتی در سطوح محلی، منطقه‌ای و جهانی بسیار حائز اهمیت است [۳]. اما به دلیل تأثیر فراوان پویایی مکانی و زمانی بر روی انواع طبقات/ کلاس‌های پوشش زمین، تهیه نقشه از آنها با چالش‌های بسیار زیادی روبرو است [۴]. داده‌های سنجش‌ازدور چندزمانه^۲ منبع اطلاعاتی بسیار مهمی جهت طبقه‌بندی و تهیه نقشه انواع پوشش زمین به حساب می‌آیند. در بیش از دو دهه اخیر، مطالعات زیادی اهمیت داده‌های سنجش‌ازدور چندزمانه را به‌عنوان یک منبع داده‌ای ارزشمند

به‌منظور شناسایی و تهیه نقشه پوشش‌های مختلف زمین مورد بررسی قرار داده‌اند [۵، ۶، ۷، ۸، ۹، ۱۰، ۱۱، ۱۲، ۱۳، ۱۴ و ۱۵]. در این میان استفاده از داده‌های چند طیفی اپتیک (محدوده طیفی ۰/۴ تا ۳ میکرومتر) بدین منظور، به دلیل عواملی همچون ساعت تصویربرداری، وجود ابر یا مه و کمبود تعداد یا کیفیت این تصاویر، با محدودیت مواجه هستند [۱ و ۱۶]. یکی از راهکارهای مؤثر جهت افزایش صحت نقشه‌های پوشش زمین و رفع محدودیت‌های مذکور استفاده از مقادیر باز پراکنش^۳ تصاویر رادار با درجه مصنوعی (SAR)^۴ است [۱۷، ۱۸، ۱۹ و ۲۰]. امروزه به‌کارگیری داده‌های SAR در زمینه تهیه نقشه پوشش زمین، با استفاده از جدیدترین نسل ماهواره‌های راداری و به‌صورت چندزمانه، به‌راحتی امکان‌پذیر شده است. دسترسی رایگان به تصاویر سری زمانی ماهواره سنتینل-۱^۵ با قدرت تفکیک زمانی ۱۲ روز، پتانسیل‌های قابل توجهی را برای استفاده از این داده‌ها در طبقه‌بندی پوشش زمین فراهم نموده است [۲۱]. سنتینل-۱ مجهز به سنجنده SAR در باند C است. این ماهواره توانایی تصویربرداری در چهار حالت مختلف با قدرت تفکیک مکانی حداقل ۵ متر و عرض برداشت حداکثر ۴۰۰ کیلومتر را در ساعات مختلف شبانه‌روز و شرایط آب‌وهوایی متنوع دارا می‌باشد [۲۲]. مقادیر باز پراکنش داده‌های SAR یا سایر شاخص‌های مشتق‌شده از آن نظیر مؤلفه‌های پلاریمتریک و بافت، می‌توانند به‌عنوان ورودی الگوریتم‌های مختلف طبقه‌بندی پوشش زمین، مورد استفاده قرار بگیرند [۲۳ و ۲۴]. باین‌حال داده‌های SAR به دلیل پایین بودن قابلیت باز پراکنش در باند C، در شناسایی و تفکیک برخی طبقات پوشش زمین با خطا و بالطبع محدودیت همراه

^۳ Backscatter^۴ Synthetic Aperture Radar^۵ Sentinel-1^۱ Land Cover^۲ Multi temporal

زمانی ماهواره سنتینل ۱- برای تهیه نقشه محصولات کشاورزی در اسپانیا استفاده کرده‌اند. نتایج حاصل از این بررسی نشان می‌دهد که استفاده از داده‌های باز پراکنش (شدت انرژی) و همدوسی *InSAR* به‌صورت جداگانه، صحت‌های قابل‌توجهی (بین ۷۰ تا ۸۰ درصد) را در طبقه‌بندی انواع محصولات کشاورزی فراهم می‌کنند. همچنین این تحقیق نشان می‌دهد که ترکیب داده‌های همدوسی و باز پراکنش، می‌تواند صحت کلی طبقه‌بندی محصولات کشاورزی را به میزان بیش از ۷ درصد بهبود بخشد (صحت کلی بیش از ۸۶ درصد) [۲۳]. در مطالعه‌ای دیگر جیکوب و همکاران (۲۰۲۰)، میزان کارایی و عملکرد داده‌های همدوسی *InSAR* ماهواره سنتینل ۱- را برای تهیه نقشه پوشش زمین با استفاده از استراتژی‌ها و الگوریتم‌های مختلف طبقه‌بندی از قبیل: تجزیه و تحلیل‌هایی مبتنی بر پیکسل و شیء، طبقه‌بندی‌های نظارت‌شده و نظارت‌نشده و الگوریتم‌های مختلف یادگیری ماشین، مورد بررسی قرار داده‌اند. نتایج بررسی‌های آنها نشان داد که داده‌های همدوسی *InSAR* در همه موارد صحت بالاتری را نسبت به استراتژی‌های طبقه‌بندی مبتنی بر باز پراکنش دارا هستند [۲]. جمالی (۲۰۱۹) با استفاده از داده‌های باز پراکنش سنتینل ۱- و به‌کارگیری دو الگوریتم یادگیری ماشین شامل ماشین بردار پشتیبان (*SVM*)^۵ و جنگل تصادفی (*RF*)^۶ اقدام به تهیه نقشه پوشش زمین کرده است. پس از ارزیابی هفت سناریو مختلف تعریف‌شده در این تحقیق، طبقه‌بندی‌کننده‌های *SVM* و *RF* بهترین عملکرد خود را به ترتیب با صحت کلی ۷۵/۳۰ و ۷۵/۳۵ درصد نشان داده‌اند [۲۹]. در پژوهشی دیگر ناول و هالدر (۲۰۱۹) از سری زمانی داده‌های باز پراکنش سنتینل ۱- در قطبش‌های *VV* و *VV/VH* برای طبقه‌بندی پوشش

هستند [۲۵].

تکنیک تداخل‌سنجی رادار دریچه مصنوعی (*InSAR*)^۱ می‌تواند اطلاعات کامل‌تری را در مقایسه با شدت باز پراکنش به‌صورت تصاویر همدوسی (کوهرنس)^۲ ارائه دهد [۱۶، ۲۶ و ۲۷]. در این روش، از اطلاعات فاز دو تصویر *SAR* که در مقاطع زمانی متفاوتی از یک ناحیه به دست آمده‌اند، جهت تولید تداخل‌نگاشت^۳ استفاده می‌شود. تداخل‌نگاشت حاوی مقادیر اختلاف فاز ثبت‌شده توسط سنجنده *SAR* در یک بازه زمانی مشخص است که جهت پایش و اندازه‌گیری تغییر شکل و جابه‌جایی زمین بکار گرفته می‌شود. تصویر همدوسی یکی از تولیدات پردازش‌های *InSAR* است که به‌منظور اندازه‌گیری میزان شباهت بین جفت تصاویر *SAR* انتخابی و ارزیابی کیفیت تداخل‌نگاشت مورد استفاده قرار می‌گیرد [۲۸]. دامنه مقادیر همدوسی بین صفر تا ۱ متغیر است. در تصاویر همدوسی مناطق ساخته‌شده و بدون تغییر معمولاً مقادیر همدوسی بالایی دارند، در مقابل مناطقی نظیر پوشش گیاهی و پهنه‌های آبی که در طول زمان به‌شدت پویا بوده و تغییرات زیادی دارند، دارای مقادیر همدوسی به‌مراتب پایین‌تری هستند [۱۶]. براین اساس، این پیش‌فرض مطرح می‌شود که تغییرات همدوسی بین جفت تصاویر *SAR* ناشی از پویایی پدیده‌های سطح زمین در گذر زمان است و از این‌رو می‌تواند اطلاعات ارزشمندی را به‌منظور شناسایی و طبقه‌بندی پوشش‌های مختلف زمین ارائه دهد. تاکنون مطالعات متعددی در زمینه استفاده از داده‌های *SAR* به‌عنوان ورودی الگوریتم‌های مختلف طبقه‌بندی پوشش زمین انجام شده است. کوئردا^۴ و همکاران (۲۰۲۰) در پژوهش خود از داده‌های سری

^۱ Interferometric Synthetic Aperture Radar

^۲ Coherence

^۳ Interferogram

^۴ Mestre-Quereda

^۵ Support Vector Machines

^۶ Random Forest

افزایش قابل توجه مقدار ضریب کاپا^۵ نسبت به حالت استفاده از تصاویر مجزا می شود [۳۲].

با بررسی مطالعات گذشته به طور کلی می توان نتیجه گرفت که در اغلب پژوهش های انجام شده در زمینه تهیه نقشه پوشش زمین، از داده های چند طیفی اپتیک، باز پراکنش رادار در قطبش های مختلف و یا تلفیق آنها استفاده شده است. در سال های اخیر، استفاده از داده های همدوسی *InSAR* نیز مورد توجه قرار گرفته و محدود مطالعاتی بر کاربرد و کارایی این داده ها جهت شناسایی و تفکیک طبقات مختلف پوشش زمین تاکید داشته اند. در این میان، رویکردهای طبقه بندی مختلفی نیز، اعم از روش های طبقه بندی نظارت شده و یا نظارت نشده بکار گرفته شده اند. در میان روش های طبقه بندی نظارت شده، الگوریتم های طبقه بندی مبتنی بر یادگیری ماشین، کاربرد گسترده ای پیدا کرده اند. در همین خصوص مطالعات بسیاری بر توانایی بالای الگوریتم طبقه بندی *SVM* به عنوان یک روش نظارت شده مبتنی بر یادگیری ماشین، تأکید داشته اند [۲۹ و ۳۰]. با توجه به اینکه خصوصیات آماری داده های همدوسی *InSAR* بسیار متأثر از شرایط محیطی نظیر خصوصیات باز پراکنش عوارض سطح زمین و نیز وضعیت اتمسفر هستند [۱۶]، لذا قابلیت های این داده ها در زمینه تهیه نقشه پوشش زمین را نمی توان مستقل از شرایط محیطی در نظر گرفت. این مهم لزوم ارزیابی قابلیت های این داده ها و نقاط ضعف و قوت آنها را برای شرایط محیطی مختلف، آشکار می سازد. علی رغم پتانسیل بالای داده های *InSAR* سنتینل ۱-، و از طرف دیگر تنوع اقلیمی و به تبع از آن تنوع پوشش زمین در ایران و نیز ضرورت افزایش صحت طبقه بندی پوشش زمین، این داده ها تاکنون در ایران برای تهیه نقشه پوشش زمین مورد استفاده قرار نگرفته اند. در همین راستا مطالعه حاضر برای اولین بار در

زمین در هند استفاده کرده اند. در این پژوهش از الگوریتم های *SVM*، *RF*، درخت تصمیم (*DT*)^۱ و شبکه عصبی مصنوعی (*ANN*)^۲ با شش ترکیب باندی مختلف برای طبقه بندی داده ها در شش طبقه استفاده شده است. به طور کلی نتایج حاصل از بررسی آنها نشان می دهد که الگوریتم های *SVM* و *RF* عملکرد بسیار خوبی نسبت به سایر الگوریتم ها دارند [۳۰]. ابدیکان و همکاران (۲۰۱۶) پتانسیل بهره گیری از داده های سنتینل ۱- را جهت تهیه نقشه پوشش زمین در شهر استانبول ترکیه مورد بررسی قرار دادند. بدین منظور، داده های *InSAR* با عرض برداشت وسیع^۳ در قطبش های *VH* و *VV* در نظر گرفته شدند. در ادامه، ترکیبات مختلف قطبش های *VH* و *VV* را مورد تجزیه و تحلیل قرار دادند. نتایج طبقه بندی تصاویر با استفاده از الگوریتم *SVM* حاکی از آن بود که ترکیب داده های دوقطبی، صحت کلی را به مقدار ۹۳/۲۸ درصد نسبت به استفاده از قطبش های *VH* و *VV* با مقادیر ۷۳/۸۵ و ۷۰/۷۴ درصد، افزایش می دهد [۳۱]. روییز و همکاران (۲۰۱۰) در پژوهش خود، از داده های باز پراکنش ماهواره *Radarsat-1* در باند *C* و تصاویر ماهواره لندست ۷ (*ETM +*)، برای تهیه نقشه های پوشش زمین باهدف تخمین وسعت و نوع محصولات اراضی کشاورزی در کشور مکزیک استفاده کرده اند. در این پژوهش از روش حداکثر احتمال^۴ جهت طبقه بندی داده های مزبور به صورت مجزا و تلفیقی استفاده شده است. نتایج حاصل از ارزیابی آنها نشان داد که میزان صحت طبقه بندی علی رغم وابستگی به نوع پوشش زمین، با تلفیق تصاویر راداری و اپتیک تمایز بهتری را بین انواع طبقات مورد انتظار ارائه می دهد و سبب

^۱ Decision Tree^۲ Artificial Neural Networks^۳ Interferometric Wide (IW) swath^۴ Maximum Likelihood^۵ Kappa coefficient

شکل (۱)، چارچوب کلی اقدامات انجام‌شده در این پژوهش را به‌صورت شماتیک نشان می‌دهد.

۲-۱- منطقه مورد مطالعه

مطابق با شکل (۲)، منطقه مورد مطالعه (مستطیل قرمز رنگ) قسمتی از محدوده تحت پوشش تصویر ماهواره سنتینل-۱ است که در استان خوزستان، قسمت شمالی شهرستان اهواز و در محدوده جغرافیایی بین ۴۸ درجه و ۲۷ دقیقه و ۴۵ ثانیه تا ۴۸ درجه و ۵۱ دقیقه طول شرقی و ۳۱ درجه و ۳۷ دقیقه و ۴۰ ثانیه عرض شمالی با مساحت تقریبی ۱,۷۰۰ کیلومترمربع (معادل ۱۷۰,۰۰۰ هکتار) قرار دارد. متناسب باهدف پژوهش در خصوص ارزیابی قابلیت داده‌های *InSAR* جهت شناسایی و تفکیک پوشش‌های مختلف زمین، این محدوده از نظر تنوع طبقات پوشش زمین شرایط بسیار مناسبی دارد [۳۳ و ۳۴]. پوشش‌های غالب این محدوده شامل: اراضی کشاورزی، اراضی ساخته‌شده، اراضی بایر، پوشش‌های گیاهی طبیعی و پهنه‌های آبی می‌باشند. لازم به ذکر است که در قسمت شمالی محدوده انتخابی، اراضی کشاورزی شرکت کشت و صنعت نیشکر دهخدا نیز قرار دارند. قطعات بزرگ اراضی کشاورزی در این کشت و صنعت سبب سهولت در فرایند برداشت نقاط آموزشی، ارزیابی دقیق صحت طبقه‌بندی در طبقه کشاورزی و دور بودن از خطاهای مربوط به پیکسل مخلوط در فرایند طبقه‌بندی می‌شود.


۲-۲- داده‌های ماهواره سنتینل-۱

ماهواره سنتینل-۱ با همکاری اتحادیه اروپا و آژانس فضایی اروپا در سال ۲۰۱۴ به فضا پرتاب شد. این ماهواره دارای یک سنجنده *SAR* در باند *C* (طول موج تقریباً ۵/۶ سانتی‌متر) است که قادر است در قطبش‌های مختلف اعم از *VH*، *VV*، *HH* و *HV*، تصویربرداری کند [۳۵ و ۳۶].


ایران به طور خاص باهدف ارزیابی قابلیت سری زمانی داده‌های همدوسی *InSAR* در زمینه تهیه نقشه پوشش زمین سامان‌دهی شده است. استان خوزستان به‌عنوان یکی از مناطق دارای تنوع پوشش زمین جهت ارزیابی قابلیت این داده‌ها مدنظر قرار گرفت. بدین منظور از طریق توسعه یک طرح طبقه‌بندی نظارت‌شده مبتنی بر داده‌های ماهواره‌ای، با بهره‌گیری از داده‌های *InSAR*، الگوریتم طبقه‌بندی‌کننده *SVM* نظر به قابلیت‌های منحصربه‌فرد آن، جهت شناسایی و تفکیک طبقات مختلف پوشش زمین به کار گرفته شد. در طبقه‌بندی‌کننده *SVM* جهت تفکیک داده‌ها در فضای ویژگی، از کرنل‌های مختلفی استفاده می‌شود. با این پیش‌فرض که نوع تابع کرنل می‌تواند نتایج طبقه‌بندی را تحت تأثیر قرار دهد، لذا در این مطالعه ارزیابی قابلیت کرنل‌های مختلف *SVM* نیز جهت تهیه نقشه پوشش زمین با استفاده از داده‌های همدوسی *InSAR* مدنظر قرار گرفته است.

۲- مواد و روش‌ها

در این مطالعه جهت تهیه نقشه پوشش زمین از داده‌های همدوسی *InSAR* استفاده شده است. بدین منظور یک سری زمانی یک‌ساله (۲۰۲۰-۲۰۱۸) از داده‌های *SAR* دارای اطلاعات فاز ماهواره سنتینل-۱ برای محدوده شهرستان اهواز واقع در استان خوزستان 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 طبقات مختلف پوشش زمین استفاده شدند. فرایند آموزش طبقه‌بندی‌کننده *SVM* و در نهایت ارزیابی صحت نقشه‌های پوشش زمین تولیدی مبتنی بر هر کرنل، با استفاده از نمونه‌های آموزشی اخذشده از تصاویر با قدرت تفکیک مکانی بالای گوگل ارث (*Google Earth*) صورت گرفته است.



شکل ۱: چارچوب کلی رویکرد تهیه نقشه پوشش زمین با استفاده از داده‌های سری زمانی همدوسی تصاویر SAR ماهواره سنتینل ۱-.



شکل ۲: موقعیت منطقه مورد مطالعه (مستطیل قرمز رنگ به عنوان بخشی از محدوده تحت پوشش تصویر ماهواره سنتینل ۱- به شماره برش ۱۱) در استان خوزستان واقع در جنوب غربی ایران.

^۱ Slice Number

جدول ۱: مشخصات داده‌های InSAR با عرض برداشت وسیع به‌دست‌آمده از ماهواره سنتینل-۱ و خط مبنای مکانی - زمانی
جفت تصاویر انتخابی جهت تولید تصاویر همدوسی.

تاریخ تصویر	شماره مدار	خط مبنای مکانی (متر) / خط مبنای زمانی (روز)				
۲۰۱۸-۱۱-۲۱	۲۴۶۸۰	۴۸ / ۱۶,۵۲	۲۴ / -۱۰۹,۳۸	۲۴ / -۲۶,۲۴	۴۸ / -۲۱,۰۷	
۲۰۱۸-۱۲-۱۵	۲۵۰۳۰					
۲۰۱۹-۰۱-۰۸	۲۵۳۸۰					
۲۰۱۹-۰۲-۰۱	۲۵۷۳۰	۲۴ / ۴۴,۵۵	۳۶ / -۴۴,۶۵	۶۰ / -۱۷,۲۱		
۲۰۱۹-۰۲-۲۵	۲۶۰۸۰					
۲۰۱۹-۰۴-۰۲	۲۶۶۰۵	۲۴ / -۲۷,۴۴	۲۴ / -۳۸,۸۸	۶۰ / -۴۸,۰۴	۶۰ / -۹۹,۰۲	
۲۰۱۹-۰۴-۲۶	۲۶۹۵۵					
۲۰۱۹-۰۵-۲۰	۲۷۳۰۵	۳۶ / -۱۳۴,۶۴	۲۴ / -۸۶,۷۰	۴۸ / -۶۱,۱۵	۴۸ / -۴۵,۷۹	۴۸ / -۱۰۲,۱۳
۲۰۱۹-۰۶-۲۵	۲۷۸۳۰					
۲۰۱۹-۰۷-۱۹	۲۸۱۸۰	۲۴ / -۱۲۱,۱۲	۴۸ / -۳۰,۱۱	۴۸ / ۹۶,۰۹	۷۲ / -۷۷,۸۴	۷۲ / -۹۳,۵۱
۲۰۱۹-۰۸-۱۲	۲۸۵۳۰					
۲۰۱۹-۰۹-۰۵	۲۸۸۸۰	۲۴ / -۵۰,۶۲	۲۴ / -۴۷,۱۰			
۲۰۱۹-۰۹-۲۹	۲۹۲۳۰					
۲۰۱۹-۱۱-۱۶	۲۹۹۳۰					
۲۰۱۹-۱۲-۱۰	۳۰۲۸۰					
۲۰۲۰-۰۱-۰۳	۳۰۶۳۰					

در قالب سه زیرنوار شامل *IW-1* (حداقل زاویه فرود^۵) تا *IW-3* (حداکثر زاویه فرود) برداشت می‌شود. هر کدام-یک از این زیرنوارها متشکل از تعدادی *Burst* هستند که در نهایت هر یک از آنها به صورت یک تصویر مجزا پردازش می‌شوند. داده‌های برداشت‌شده از طریق حالت *IW* پس از اعمال پردازش‌هایی در قالب محصولات سطح ۱ *SLC*^۶ ارائه می‌شوند که شامل مقادیر فاز و دامنه بوده و برای اهداف *InSAR* مناسب هستند [۳۶]. جدول (۱)، مشخصات تصاویر *SLC* مورد استفاده را به‌صورت خلاصه نشان می‌دهد.

۲-۳- تکنیک *InSAR* و محاسبه همدوسی

تکنیک *InSAR* یک فناوری سنجش‌ازدوری است که

در این پژوهش، از ۱۶ تصویر ماهواره سنتینل-۱ مربوط به حالت *IW* به شماره برش ۱۱ (شکل (۲)) در بازه زمانی ۲۰۱۸/۱۱/۲۱ تا ۲۰۲۰/۱/۳ (معادل ۱۳۹۷/۸/۳۰ تا ۱۳۹۸/۱۰/۱۳) استفاده شده است. حالت *IW* داده‌ها را با یک عرض برداشت ۲۵۰ کیلومتری و قدرت تفکیک مکانی ۵ متر (در راستای برد مایل^۱) در ۲۰ متر (در راستای آزیموت^۲) به صورت تک نگاه^۳ ثبت می‌نماید [۳۶]. در این حالت از طریق تکنیک مشاهده زمین با اسکن‌های پیش‌رونده^۴، تصویر

^۱ Range

^۲ Azimuth

^۳ Single Look

^۴ Terrain Observation with Progressive Scans SAR (TOPSAR)

^۵ Incidence Angle

^۶ Single Look Complex

تداخل‌نگاشت‌ها و تصحیح آنها نسبت به خطاهای موجود، مجموعه‌ای از تداخل‌نگاشت‌ها در بازه‌های زمانی مختلف از محدوده مورد مطالعه به دست آمد. ناهمبستگی مکانی و زمانی بین تصاویر SAR سبب می‌شود تا تقریباً هر تداخل‌نگاشت شامل مناطق بزرگی باشد که در آن همدوسی بسیار پایین است [۳۸]. ناهمبستگی مکانی از تفاوت در هندسه تصویربرداری بین دو تصویر مینا^۵ و پیرو^۶ مربوط به زمان‌های مختلف حاصل می‌شود. ناهمبستگی زمانی ناشی از تغییرات خصوصیات بازپراکنشی سطح زمین و اتمسفر در طول زمان حاصل می‌شود. تغییرات منطقه در طول زمان سبب می‌شود تا جفت تصاویر دارای اختلاف زمانی بالا، از همبستگی و به بیان دیگر، همدوسی پایینی برخوردار باشند. در نتیجه، میزان تغییرات همدوسی در انواع طبقات پوشش زمین با یکدیگر متفاوت است [۳۹]. در مناطق شهری که پوشش زمین عمدتاً شامل ساختمانها یا اراضی ساخته شده است، تغییرات اندکی در دامنه مقادیر همدوسی مشاهده می‌شود و همبستگی بالایی در بین جفت تصاویر انتخابی وجود دارد. در حالیکه در مناطق دارای پوشش گیاهی، به دلیل تغییرات فنولوژیکی گیاه در طول دوره رشد، میزان تغییرات همدوسی بسیار بالاست [۱]. تصاویر SAR تهیه شده از یک سنجنده در مقاطع زمانی مختلف ممکن است از نظر هندسی، کاملاً بر یکدیگر منطبق نباشند؛ لذا به منظور تهیه نقشه پوشش زمین با استفاده از داده‌های همدوسی، ضرورت دارد تصاویر نسبت به یک تصویر مبنای مشترک، ثبت هندسی شوند. فرایند ثبت هندسی، سبب انطباق تصاویر SAR شده و امکان ارزیابی دقیق تغییرات ایجاد شده در طول زمان‌های مختلف را در یک پیکسل فراهم می‌کند [۴۰]. بر اساس شکل (۱)، مراحل پردازش‌های InSAR در این مطالعه

مبتنی بر تلفیق داده‌های SAR اخذ شده از یک منطقه در زمان‌های مختلف می‌باشد. تصاویر تکراری SAR می‌توانند جهت تشخیص تغییرات ایجاد شده در سطح زمین مانند حرکت یا تغییر ارتفاع مورد استفاده قرار بگیرند [۳۷]. در این تکنیک، اختلاف فاز بین دو موج/ تصویر مربوط به دو زمان متفاوت در قالب یک تداخل-نگاشت اندازه‌گیری شده و سپس این اختلاف فاز به تغییر فاصله بین سنجنده و هدف و یا جابه‌جایی سطح زمین نسبت داده می‌شود. تصویر همدوسی یکی از تولیدات اصلی InSAR می‌باشد [۳۸]. این تصویر به طور مرسوم جهت ارزیابی کیفیت تداخل‌نگاشت تولید شده مورد استفاده قرار گرفته و با رابطه (۱) بیان می‌شود:

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

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 [۳۹]. از این رو،

رابطه (۱) به صورت رابطه (۲) بیان می‌گردد:

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

در رابطه (۲)، L تعداد نمونه‌های موجود در یک پنجره است. مقادیر تغییرات γ در این معادله، بین صفر و ۱ قرار دارند. مقادیر کم γ بیانگر همدوسی پایین و مقادیر بالای آن نشان‌دهنده همدوسی بالا است. بعد از تولید

^۱ Expectation operator

^۲ Complex

^۳ Co-Registered

^۴ Kernel

^۵ Master

^۶ Slave

کشاورزی (شامل زراعت آبی و دیم و باغات)، پهنه‌های آبی (شامل رودخانه، دریاچه و تالاب)، خاک لخت و پوشش گیاهی طبیعی متراکم (شامل مراتع) شناسایی شدند. هنگامی که زیرمجموعه‌های داخل یک مجموعه داده، تنوع بالایی داشته باشند، بهتر است نمونه‌گیری از هر یک از زیرمجموعه‌ها به صورت مستقل انجام پذیرد تا مقدار واریانس در یک مجموعه داده مشابه، کاهش یابد [۴۱]. بر همین اساس نمونه‌برداری با روش تصادفی طبقه‌ای^۴ انجام گرفت. بدین منظور جهت نمونه‌برداری از طبقات مختلف پوشش زمین، از آرشیو تصاویر با قدرت تفکیک مکانی بالای گوگل ارث مربوط به منطقه مورد مطالعه، بهره گرفته شد. با توجه به بازه زمانی تصاویر همدوسی (۲۰۱۸/۱۱/۲۱ تا ۲۰۲۰/۱/۳)، برای اجتناب از ورود خطا در فرایند نمونه‌برداری خصوصاً در رابطه با طبقات اراضی کشاورزی و خاک لخت، از تمامی تصاویر قدرت تفکیک مکانی بالای گوگل ارث قابل دسترس در همین بازه زمانی، جهت اخذ نمونه‌های آموزشی طبقات مختلف پوشش زمین استفاده گردید. چرا که نظر به پویایی برخی پوشش‌های زمین نظیر اراضی کشاورزی در طول زمان، ممکن است یک زمین کشاورزی برخی مواقع از سال بایر باشد. بنابراین نمونه‌برداری باید به گونه‌ای انجام شود که بین خاک لخت و زمین‌های کشاورزی تفکیک قائل و تعداد مناسب نمونه از این دو طبقه برداشت شود. بدین طریق، در مجموع ۴,۹۳۰ نمونه آموزشی (به ازای هر طبقه حدود ۱,۰۰۰ نمونه) اخذ گردید. شکل (۳)، الگوی توزیع مکانی نمونه‌های آموزشی تهیه شده از طبقات مختلف پوشش زمین را در منطقه مورد مطالعه، نشان می‌دهد.

۲-۵- طبقه‌بندی کننده SVM

یکی از مؤثرترین راهکارهای استخراج اطلاعات مفید از تصاویر ماهواره‌ای، فرایند طبقه‌بندی است. در حقیقت

به منظور تولید داده‌های همدوسی چندزمانه به صورت زیر هستند که تمامی این مراحل در نرم‌افزار GMTSAR تحت سیستم عامل لینوکس اجرا شده‌اند:

(۱) تشکیل شبکه تداخل‌نگاشت بر اساس قاعده ترکیب ۲ از n . بدین ترتیب با توجه به تعداد تصاویر SLC مورد استفاده (۱۶ تصویر)، تعداد ۱۲۰ حالت مختلف (ترکیب ۲ از ۱۶) جهت انتخاب جفت تصاویر لحاظ گردید. سپس با تعریف حد آستانه خط مبناهای مکانی و زمانی به ترتیب کوچکتر از ۲۰۰ متر و حداکثر ۷۲ روز، تعداد ۲۵ جفت تصویر در بازه زمانی مورد مطالعه جهت ادامه مراحل پردازش انتخاب شد (جدول (۱)).

(۲) ثبت هندسی تصاویر SLC نسبت به یک تصویر مبنای یکسان با استفاده از داده‌های مداری دقیق و مدل ارتفاعی رقومی (DEM)^۱ ماهواره SRTM با قدرت تفکیک مکانی ۳۰ متر.

(۳) محاسبه میزان همدوسی مجموعه جفت تصاویر انتخابی جهت پردازش InSAR با استفاده از رابطه (۲).

(۴) زمین مرجع کردن^۲ و انتقال داده‌های همدوسی تولیدشده از مختصات فاصله مایل و آزیموت راداری به مختصات جغرافیایی زمینی با اندازه پیکسل ۵۰ متر.

۲-۴- تهیه نمونه‌های آموزشی

جهت بررسی بصری و شناخت اولیه تعداد طبقات موجود در منطقه مورد مطالعه، از محصول پوشش زمین سنجنده مادیس (MODIS)^۳ (MCD12Q1) مربوط به سال ۲۰۱۹ با اندازه پیکسل ۵۰۰ متر استفاده گردید. با استفاده از این محصول، تعداد پنج طبقه غالب و متنوع در منطقه شامل: اراضی ساخته شده، اراضی

^۱ Digital Elevation Model

^۲ Geocoding

^۳ Moderate Resolution Imaging Spectroradiometer

^۴ Stratified Random Sampling

شود، پاسخ تنها ابرصفحه‌هایی هستند که از مبدأ می‌گذرند. فاصله عمودی صفحه تا مبدأ با تقسیم قدر مطلق مقدار پارامتر b بر طول w به دست می‌آید. اگر داده‌ها/ نمونه‌های آموزشی به صورت خطی تفکیک‌پذیر باشند، می‌توان دو ابر صفحه مرزی را به گونه‌ای انتخاب کرد که هیچ داده‌ای بین آنها نباشد و سپس فاصله بین این دو ابر صفحه موازی را به حداکثر رساند. با به کارگیری قضایای هندسی، فاصله این دو ابر صفحه مرزی عبارت است از: $2/|w|$ ؛ پس باید $|w|$ را به حداقل رساند [۴۴]. همچنین باید از قرار گرفتن نقاط داده در ناحیه درون مرز جلوگیری کرد. این کار با اعمال یک محدودیت ریاضی امکان‌پذیر است. لذا مسئله بهینه‌سازی به صورت رابطه (۳) تعریف می‌شود:

$$\begin{aligned} |w| \rightarrow \min \\ C_i(w \cdot x_i + b) \geq 1 \quad 1 \leq i \leq n \end{aligned} \quad \text{رابطه (۳)}$$

در رابطه (۳)، پارامتر C_i ، طبقه مربوط به نمونه X_i را مشخص می‌کند. هدف اصلی این الگوریتم یافتن بیشترین فاصله بین دو طبقه و در نتیجه افزایش صحت طبقه‌بندی است. یکی دیگر از قابلیت‌های طبقه‌بندی‌کننده SVM، توانایی غلبه بر مشکل توزیع غیرخطی داده‌ها است. در این حالت با استفاده از توابع کرنل، داده‌ها به فضایی با ابعاد بزرگتر انتقال می‌یابند که سبب بهبود فرایند تفکیک‌پذیری شده و ابر صفحه جداکننده نیز در آن فضا تعیین می‌شود [۴۵]. متداول‌ترین کرنل‌ها شامل خطی، چندجمله‌ای، تابع پایه شعاعی (RBF)^۵ و سیگموئید می‌باشند که روابط مربوط به هر یک از آنها در جدول (۲)، ارائه شده است. در کاربردهای مربوط به طبقه‌بندی تصاویر ماهواره‌ای، کرنل RBF معمولاً نتایج بهتری را ارائه داده است [۴۶].

^۵ Radial Basis Function


طبقه‌بندی یک نگاشت^۱ از فضای تصویر به فضای عوارض زمینی است. هدف از طبقه‌بندی در این مطالعه، تبدیل اطلاعات چندزمانه حاصل از تصاویر همدوسی InSAR به فضای طبقات از پیش تعریف‌شده است؛ تا بتوان اطلاعات ورودی را با حداکثر اطمینان و صحت، به هر طبقه نسبت داد. همان‌طور که در پیشینه تحقیق اشاره شد، SVM یکی از کارآمدترین روش‌های طبقه‌بندی نظارت‌شده محسوب می‌شود. مزیت اصلی این طبقه‌بندی‌کننده، توانایی حل مسائل طبقه‌بندی پیچیده با تعداد ویژگی‌های^۲ فراوان و نمونه‌های آموزشی کم است که سبب شده این روش به عنوان یک گزینه مناسب برای طبقه‌بندی تصاویر سنجش‌ازدوری مورد استفاده قرار گیرد [۴۲]. فرض اصلی این روش این است که هیچ‌گونه اطلاعاتی از چگونگی توزیع داده‌ها وجود ندارد. SVM درواقع یک طبقه‌بندی‌کننده باینری است که برای تفکیک طبقات مختلف در مجموعه داده‌ها، ابر صفحه‌ای^۳ (که عبارت است از یک معادله خطی) را بر روی آنها برازش می‌دهد. نخستین مرحله برای تعیین ابر صفحه، پیدا کردن نزدیک‌ترین داده‌های مربوط به دو طبقه است. نمونه‌های واقع در مرز طبقات و نزدیک به ابر صفحه بهینه، بردارهای پشتیبان^۴ (دو ابر صفحه مرزی) نام دارند [۴۳]. برای جدا کردن طبقات، ابر صفحه‌های زیادی وجود دارد ولی ابر صفحه‌ای که بیشترین حاشیه را ایجاد کند؛ به عنوان ابر صفحه بهینه انتخاب می‌شود. روابط ریاضی ابر صفحه بهینه و بردارهای پشتیبان که مرز جداکننده طبقات را تشکیل می‌دهند، در شکل (۴) نشان داده شده است. مطابق با شکل (۴)، پارامتر b ، عرض از مبدأ ابر صفحه بهینه با حداکثر مرز جداکننده است. اگر از b صرف‌نظر

^۱ Mapping


^۲ Feature

^۳ Hyperplane

^۴ Support Vectors



شکل ۳: توزیع مکانی نمونه‌های آموزشی اخذشده از گوگل ارث برای طبقات مختلف پوشش زمین (اراضی ساخته‌شده: ۱,۰۰۰ نمونه؛ اراضی کشاورزی: ۱,۰۰۰ نمونه؛ پهنه‌های آبی: ۹۱۵ نمونه؛ خاک لخت: ۱,۱۰۰ نمونه؛ و پوشش گیاهی متراکم: ۹۱۵ نمونه).



شکل ۴: نحوه ایجاد ایر صفحه بهینه در بین داده‌های دو طبقه در یک فضای ویژگی دوبعدی.

جدول ۲: انواع توابع کرنل در الگوریتم SVM [۴۲].

تابع کرنل	فرمولاسیون	پارامترهای کرنل
خطی (Linear)	$K(x_i, x_j) = (x_i, x_j)$	-
چندجمله‌ای (Polynomial)	$K(x_i, x_j) = ((x_i, x_j) + 1)^d$	d, γ, c
تابع پایه شعاعی (RBF)	$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right)$	ε, γ, c
سیگموئید (Sigmoid)	$K(x_i, x_j) = \tanh(-\alpha(x_i, x_j) + c)$	γ, c

۲-۶- ارزیابی صحت

اطلاعات موضوعی مستخرج از داده‌های سنجش‌ازدور همواره حاوی برخی خطاها هستند. بنابراین قبل از استفاده توسط کاربران یا تصمیم‌گیران، باید صحت و درستی این اطلاعات مورد ارزیابی قرار گیرد و درجه اطمینان آنها مشخص شود [۴۷]. بر همین اساس، ارزیابی صحت^۱، به عنوان آخرین مرحله از تولید نقشه‌های حاصل از طبقه‌بندی به حساب می‌آید.

همان‌طور که شکل (۱) نشان می‌دهد، در این مطالعه برای ارزیابی صحت نتایج طبقه‌بندی، نمونه‌های آموزشی اخذشده برای تمامی طبقات به دو قسمت ۸۰ و ۲۰ درصد تفکیک شدند. ۸۰ درصد از نمونه‌ها به‌منظور آموزش مدل طبقه‌بندی‌کننده، در فرایند طبقه‌بندی استفاده شدند. ۲۰ درصد باقیمانده نیز با استفاده از ماتریس خطا^۲، برای ارزیابی صحت نتایج طبقه‌بندی به کار گرفته شدند.

ماتریس خطا یکی از روش‌های استاندارد جهت ارزیابی عملکرد و صحت یک مدل طبقه‌بندی است. ماتریس خطا بر اساس رابطه بین نمونه‌های کنترل زمینی و تصویر طبقه‌بندی‌شده محاسبه می‌شود [۴۸]. در یک ماتریس خطا داده‌هایی که درست طبقه‌بندی شده‌اند، بر روی قطر اصلی ماتریس قرار می‌گیرند و درایه‌های

غیر قطری ماتریس، میزان خطا را در طبقه‌بندی نشان می‌دهند. یکی از مهم‌ترین فاکتورهایی که در گام اول در ماتریس خطا موردتوجه قرار می‌گیرد، صحت کلی^۳ است. این فاکتور، صحت را بر اساس تعداد پیکسل‌هایی که به‌درستی طبقه‌بندی شده‌اند، محاسبه می‌کند. ضریب کاپا یکی دیگر از فاکتورهایی است که با استفاده از ماتریس خطا محاسبه می‌شود و در مقایسه با صحت کلی از اعتبار بالاتری برای ارزیابی صحت نقشه‌های طبقه‌بندی برخوردار است. ضریب کاپا میزان صحت برخلاف صحت کلی و بر اساس تمامی پیکسل‌هایی که درست و اشتباه طبقه‌بندی شده‌اند، محاسبه می‌کند. علاوه بر صحت کلی و ضریب کاپا، دو فاکتور دیگر نیز وجود دارند که می‌توان با استفاده از آنها میزان صحت را برای هر یک از طبقات به‌صورت جداگانه محاسبه نمود. فاکتور صحت تولیدکننده^۴ به آن دسته از پیکسل‌هایی اشاره دارد که در واقعیت متعلق به طبقه موردنظر هستند ولی اشتباهاً به طبقات دیگری اختصاص داده شده‌اند. در مقابل فاکتور صحت کاربر^۵ به آن دسته از پیکسل‌هایی اشاره دارد که به‌اشتباه طبقه‌بندی شده‌اند و در واقع متعلق به طبقه موردنظر نیستند ولی طبقه‌بندی‌کننده آنها را جزء آن طبقه

^۳ Overall accuracy^۴ Producer accuracy^۵ User accuracy^۱ Accuracy assessment^۲ Confusion matrix

خاص در نظر گرفته است [۴۹].

۳- نتایج و بحث

در ادامه، این قسمت در سه بخش مجزا به طور کامل توضیح داده شده است.

۳-۱- تجزیه و تحلیل داده‌های همدوسی

این مطالعه باهدف ارزیابی کاربرد داده‌های همدوسی *InSAR* در زمینه شناسایی و تفکیک پوشش‌های مختلف زمین، با استفاده از ۱۶ تصویر *SAR* دارای اطلاعات فاز در باند *C* به‌دست‌آمده از ماهواره سنیتل-۱، در محدوده‌ای از شهرستان اهواز انجام شده است. در ادامه از میان حالات مختلف ترکیب تصاویر *SAR*، تعداد ۲۵ جفت تصویر با حداقل و حداکثر تفکیک زمانی به ترتیب ۲۴ و ۷۲ روز برای تولید تصاویر همدوسی پردازش شدند. الگوی مکانی - زمانی میزان همدوسی محاسبه‌شده در بازه‌های زمانی مختلف (جفت تصاویر انتخابی) در شکل (۵) نشان داده شده است. همان‌طور که مشاهده می‌شود، الگوی مکانی متغیر مقادیر همدوسی در زمان‌های مختلف نشان‌دهنده نوعی واریانس و تغییرات نسبتاً قابل‌توجه در تصاویر است. این تغییرات مکانی - زمانی حاوی اطلاعات ارزشمندی هستند که در گذر زمان ناشی از تغییرات خصوصیات فیزیکی و شیمیایی عوارض سطح زمین حاصل شده‌اند. در شکل (۵)، ناحیه آبی‌رنگ با الگوی تقریباً ستاره‌ای در مرکز نقشه‌ها، محدوده شهر اهواز است که تغییرات نسبتاً کمتری را در مقایسه با سایر نواحی در منطقه مورد مطالعه نشان می‌دهد. این مهم حاکی از نرخ تغییرات بسیار کم محیط‌های شهری و اراضی ساخته‌شده (مقادیر بالای همدوسی) و استحکام هندسی بسیار بالای آنها در تصاویر همدوسی مربوط به زمان‌های مختلف است. از سوی دیگر، الگوی مکانی - زمانی متغیر و نرخ تغییرات بالاتر سایر نواحی به‌ویژه پوشش گیاهی و پهنه‌های آبی در تصاویر همدوسی به‌وضوح مشهود است. این امر به دلیل استحکام هندسی بسیار کمتر و پویایی بالای این پدیده‌ها در گذر زمان است.

تأثیر اتمسفر یکی از منابع نوفه/ نویزهای شناخته‌شده در پردازش‌های *InSAR* به شمار می‌رود که به لحاظ مکانی - زمانی در طول مسیر انتشار امواج راداری متفاوت است [۳۸]. با توجه به عواملی همچون نزدیکی به دریا و شرایط اتمسفر ناپایدار در منطقه مورد مطالعه، بنابراین تفکیک زمانی بلندمدت بین جفت تصاویر انتخابی می‌تواند سبب افزایش نویز و کاهش همبستگی و همدوسی بین دو تصویر گردد. در چنین مواردی سیگنال‌های اتمسفری (حاصل تقدم و تأخر فاز ناشی از تأثیر شرایط پویای اتمسفر) مقادیر فاز جفت تصاویر را به شدت تحت تأثیر قرار می‌دهند. براین اساس، با وجود امکان پردازش جفت تصاویر با تفکیک زمانی بسیار طولانی‌تر به‌منظور افزایش داده‌های ورودی طبقه‌بندی‌کننده، به دلیل اجتناب از خطاهای اتمسفری و همچنین افزایش نسبت سیگنال به نویز تصاویر همدوسی و به‌طور کلی حداقل نمودن ناهمبستگی زمانی، یک آستانه تفکیک زمانی حداکثر ۷۲ روزه لحاظ گردید.

یکی دیگر از عوامل مؤثر بر پردازش‌های *InSAR* و محصولات آن، ناهمبستگی مکانی ناشی از تغییر در مدار گردش ماهواره در زمان‌های متوالی است. این تغییر و میزان خطای ناشی از آن به‌وسیله خط مبنای مکانی ارزیابی می‌شود. بدیهی است که با افزایش خط مبنای مکانی جفت تصاویر انتخابی، میزان همبستگی مکانی تصاویر کاهش و سبب وارد شدن خطا به برآوردهای فاز می‌شود [۵۰]. در این مطالعه جفت تصاویر به نحوی انتخاب شدند که خط مبنای مکانی کوچکتر از ۲۰۰ متر داشته باشند، که این میزان برای پردازش‌های *InSAR* مطلوب است [۵۱]. بر اساس جدول (۱)، حداکثر طول خط مبنای مکانی اندازه‌گیری شده برابر با ۱۳۴/۶۴- متر برای جفت تصویر مربوط به بازه زمانی ۲۰۱۹/۵/۲۰ تا ۲۰۱۹/۶/۲۵ است.


۳-۲- طبقه‌بندی پوشش زمین

در این مطالعه جهت طبقه‌بندی پوشش زمین با روش


SVM، از طریق به کارگیری ۲۵ تصویر همدوسی تولیدی، از کرنل های مختلف خطی، چندجمله ای، تابع پایه شعاعی و سیگموئید استفاده شده و نتایج خروجی هر کرنل در طبقات مختلف پوشش زمین با استفاده از نمونه های آموزشی، مورد بررسی و ارزیابی قرار گرفته است. شکل های (۶) تا (۱۲)، نتایج ارزیابی صحت طبقه بندی بر اساس ماتریس خطای تشکیل شده با استفاده از طبقات نمونه های آموزشی و طبقات شناسایی شده در نقشه های پوشش زمین تولیدی به ازای هر یک از کرنل های *SVM* را نشان می دهند. بدین ترتیب، مقادیر صحت در هر طبقه (شکل های (۶) تا (۱۱)) و همچنین صحت کلی و ضریب کاپا (شکل (۱۲)) برای هر یک از توابع کرنل بر اساس ماتریس های خطا برآورد شده است.

همان طور که در نمودار شکل (۱۲) نشان داده شده است، کرنل چندجمله ای درجه شش، با صحت کلی ۶۹/۹ درصد و ضریب کاپا ۶۲/۳۸ درصد، بالاترین میزان صحت را در مقایسه با سایر کرنل ها به خود اختصاص داده است. در نتیجه، این کرنل جهت طبقه بندی و تولید نقشه پوشش زمین انتخاب و مورد استفاده قرار گرفته است. نقشه طبقه بندی حاصل از این کرنل در شکل (۱۳) نشان داده شده است. علاوه بر این، مطابق با شکل های (۶) تا (۱۱)، فاکتورهای صحت کاربر و صحت تولیدکننده در تمامی کرنل ها در طبقه اراضی ساخته شده، مقادیر بالایی را نشان می دهند، درحالی که طبقه پوشش گیاهی متراکم نسبت به سایر طبقات در کرنل های مختلف، مقادیر صحت پایین تری را نشان داده است. بدین ترتیب، بالاترین صحت کاربر و صحت تولیدکننده مربوط به کرنل چندجمله ای درجه شش برای طبقه اراضی ساخته شده با مقادیر به ترتیب ۹۷/۵۲ و ۹۸/۵۰ درصد و در مقابل پایین ترین صحت کاربر و صحت تولیدکننده مربوط به کرنل سیگموئید برای طبقه پوشش گیاهی متراکم با مقادیر به ترتیب ۲۹/۷۳ و ۱۱ درصد است. صحت نسبتاً کم طبقه بندی برای طبقه پوشش گیاهی متراکم می تواند به دلیل


قدرت تفکیک مکانی تصاویر استفاده شده (۵۰ متر) در کرنل های مختلف باشد که سبب ایجاد پیکسل های مخلوط شده است. در این پیکسل ها علاوه بر پوشش گیاهی با تراکم اندک، خاک پس زمینه نیز وجود دارد که سبب کاهش میزان صحت طبقه بندی در آنها شده است. براین اساس می توان خاطرنشان کرد که تصاویر همدوسی *InSAR* در تفکیک طبقه مربوط به پوشش گیاهی متراکم به دلیل موارد گفته شده و همچنین تغییرات فصلی که موجب تغییر تراکم پوشش های گیاهی طبیعی در واحد سطح می شوند، با محدودیت بالایی روبرو است. ولی در مقابل در خصوص شناسایی و تفکیک طبقه مربوط به اراضی ساخته شده بالاترین میزان صحت (بالاتر از ۹۳ درصد) و به تبع از آن بهترین عملکرد را در میان تمامی کرنل ها داشته است. به لحاظ صحت کلی و ضریب کاپا مطابق با شکل (۱۲)، بهترین و بدترین عملکرد به ترتیب مربوط به کرنل های چندجمله ای درجه شش و سیگموئید است. براین اساس، دامنه مقادیر صحت کلی و ضریب کاپا به ازای کرنل های مورد بررسی به ترتیب بین ۵۹/۵ تا ۶۹/۹ درصد (معادل ۱۰/۴ درصد اختلاف بین مقادیر حداقل و حداکثر صحت کلی) و ۴۹/۳۸ تا ۶۲/۳۸ درصد (معادل ۱۳ درصد اختلاف بین مقادیر حداقل و حداکثر ضریب کاپا) متغیر است. تنوع در نتایج عملکرد کلی کرنل های مختلف مورد بررسی، حاکی از آن است که میزان کارایی تصاویر همدوسی در تولید نقشه های پوشش زمین، به نوع تابع کرنل مورد استفاده نیز بستگی دارد. براین اساس، متناسب با خصوصیات آماری مجموعه داده های ورودی طبقه بندی کننده، باید تابع کرنلی انتخاب گردد که بالاترین صحت و بهترین عملکرد را در تفکیک طبقات مختلف ارائه دهد. بنابراین، به طور کلی می توان گفت در کنار بهره گیری از داده های همدوسی *InSAR*، نوع الگوریتم طبقه بندی کننده نیز به عنوان پارامتری اثرگذار بر صحت طبقه بندی باید مورد توجه قرار گیرد.




شکل ۵: الگوی مکانی - زمانی مقادیر همدوسی محاسبه شده در بازه‌های زمانی مختلف با استفاده از پردازش *InSAR* مبتنی بر داده‌های ماهواره سنتینل -۱.




شکل ۶: نتایج ارزیابی صحت طبقه بندی به ازای طبقات مختلف در کرنل خطی.




شکل ۷: نتایج ارزیابی صحت طبقه بندی به ازای طبقات مختلف در کرنل چندجمله ای درجه دو.




شکل ۸: نتایج ارزیابی صحت طبقه بندی به ازای طبقات مختلف در کرنل چندجمله ای درجه چهار.




شکل ۹: نتایج ارزیابی صحت طبقه‌بندی به‌ازای طبقات مختلف در کرنل چندجمله‌ای درجه شش.




شکل ۱۰: نتایج ارزیابی صحت طبقه‌بندی به‌ازای طبقات مختلف در کرنل تابع پایه شعاعی.



شکل ۱۱: نتایج ارزیابی صحت طبقه‌بندی به‌ازای طبقات مختلف در کرنل سیگموئید.



شکل ۱۲: نتایج ارزیابی صحت طبقه‌بندی (صحت کلی و صحت کاپا) به‌ازای کرنل‌های مختلف.



شکل ۱۳: نقشه طبقه‌بندی پوشش زمین به‌دست‌آمده با استفاده از داده‌های *InSAR* و الگوریتم *SVM* (کرنل چندجمله‌ای درجه شش).

۳-۳- محدودیت‌ها و راهکارها

با توجه به موارد پیش‌گفته می‌توان نتیجه گرفت که استفاده از داده‌های همدوسی *InSAR* به‌تنهایی برای تولید نقشه پوشش زمین با تعداد طبقات محدود، بسیار

کارآمد هستند. اما به دلیل ضعف این داده‌ها در شناسایی و تفکیک برخی طبقات پوشش زمین مانند پوشش گیاهی متراکم، استفاده از داده‌های مکمل نظیر باز پراکنش راداری در قطبش‌های مختلف نیز ضروری

در واقع حاوی اطلاعات مربوط به خواص طیفی پدیده‌های مختلف سطح زمین هستند. از آنجاکه پدیده‌های جغرافیایی به سبب خصوصیات فیزیکی و شیمیایی مختلف خود، رفتار طیفی متفاوتی دارند؛ لذا با بهره‌گیری از داده‌های اپتیک می‌توان از این تفاوت‌ها جهت تفکیک آنها استفاده نمود [۴۹]. اما با این وجود، داده‌های اپتیک نیز نظیر سایر منابع داده‌سنجش‌ازدوری با محدودیت‌هایی همراه هستند. بنابراین ضمن در نظر گرفتن محدودیت‌های داده‌های اپتیک مانند پوشش مکانی و زمانی، موقعیت جغرافیایی و همچنین شرایط ابرناکی منطقه، می‌توان از این داده‌ها نیز به صورت مکمل با داده‌های *InSAR* جهت افزایش صحت طبقه‌بندی استفاده نمود. تاکنون مطالعات متعددی از جمله [۳۲، ۵۲ و ۵۳] در این زمینه انجام شده‌اند که نشان می‌دهند استفاده ترکیبی از تصاویر اپتیک و راداری، اطلاعات مفیدی را درباره پوشش‌های مختلف زمین فراهم می‌کنند و می‌توانند صحت طبقه‌بندی پوشش زمین را در مقایسه با استفاده از تصاویر منفرد، بهبود بخشند.

۴- نتیجه‌گیری و پیشنهادها

این پژوهش باهدف بررسی امکان استفاده از سری زمانی داده‌های تداخل‌سنجی رادار درپچه مصنوعی (*InSAR*) جهت تهیه نقشه پوشش زمین در ایران انجام گرفته است. برای این منظور سری زمانی تصاویر فاز مختص *InSAR* به‌دست‌آمده از ماهواره سنتینل-۱ برای تولید تصاویر همدوسی مورد پردازش قرار گرفته و به‌عنوان ورودی به کرنل‌های مختلف الگوریتم طبقه‌بندی‌کننده *SVM* معرفی شدند. با توجه به نتایج به‌دست‌آمده، از میان کرنل‌های مختلفی که جهت طبقه‌بندی مورد ارزیابی قرار گرفته‌اند، کرنل چندجمله‌ای درجه شش، با صحت کلی ۶۹/۹ درصد و ضریب کاپا برابر با ۶۲/۳۸ درصد، بالاترین صحت را نسبت به سایر کرنل‌ها ارائه داده و به‌عنوان بهترین کرنل برای تهیه نقشه طبقه‌بندی پوشش زمین انتخاب شد. همچنین ارزیابی صحت طبقه‌بندی نشان داد که طبقه/

به نظر می‌رسد. در همین راستا، در مطالعه‌ای که توسط کوئردا و همکاران (۲۰۲۰) در ارتباط با استفاده از داده‌های سری زمانی ماهواره سنتینل-۱ و تصاویر همدوسی *InSAR* جهت تهیه نقشه محصولات کشاورزی در اسپانیا انجام شده، نشان می‌دهد که استفاده تلفیقی از داده‌های *InSAR* و بازپراکنش راداری می‌تواند صحت طبقه‌بندی را به میزان قابل توجهی افزایش دهد (افزایش بیش از ۷ درصد در صحت کلی) [۲۳].

افزون بر دلایل گفته شده، یکی دیگر از علل صحت نامطلوب طبقه‌بندی در برخی طبقات نظیر پوشش گیاهی متراکم، می‌تواند تعداد کم ویژگی‌های ورودی به طبقه‌بندی‌کننده باشد. در این مطالعه تنها از ۲۵ جفت تصویر (تصاویر همدوسی) مربوط به بازه‌های زمانی مختلف استفاده شده است. طبیعتاً برای پایش پدیده‌های پویا، نمونه‌برداری‌های زمانی با فواصل کوتاه‌تری نیاز است. بر همین اساس، با توجه به پویایی بسیار شدید برخی طبقات پوشش زمین مانند پوشش گیاهی، خصوصاً در شرایطی که طبقه تمام سطح پیکسل را نپوشاند (وجود پیکسل‌های مخلوط)، ضرورت استفاده از مشاهدات بیشتر در طول زمان احساس می‌شود. بدین صورت که با کاهش تفکیک زمانی بین جفت تصاویر انتخابی و پردازش تعداد بیشتری تصاویر همدوسی می‌توان علاوه بر کاهش اثرات احتمالی ناشی از ناهمبستگی زمانی، حجم اطلاعات مفید بیشتری وارد فرایند طبقه‌بندی نمود. برای این منظور می‌توان از داده‌های *InSAR* ماهواره‌های سنتینل-۱ *A* و *B* به صورت مستقل با تفکیک زمانی ۱۲ روزه و یا تلفیق داده‌های هر دو ماهواره که قدرت تفکیک زمانی شش‌روزه را ارائه می‌دهند، استفاده کرد.

داده‌های چند طیفی اپتیک مانند ماهواره سنتینل-۲ و ماهواره‌های لندست با قدرت تفکیک مکانی و زمانی مناسب نیز می‌توانند به‌عنوان داده‌های مکمل جهت افزایش کارایی داده‌های *InSAR* به منظور تهیه نقشه پوشش زمین مورد استفاده قرار گیرند. داده‌های اپتیک

می تواند میزان صحت طبقه بندی را افزایش دهد. همچنین جهت کاهش اثرات ناهمبستگی زمانی و افزایش نسبت سیگنال به نویز داده های *InSAR* و متعاقباً بهبود صحت طبقه بندی، بهتر است از مجموعه داده های هر دو ماهواره سنتینل-۱ و *B* استفاده گردد و با رعایت آستانه خط مبنای مکانی و زمانی مطلوب، تعداد بیشتری تصاویر همدوسی تولید و وارد طبقه بندی کننده گردند.

امروزه با توجه به توسعه نرم افزارهای متن باز و بسیار کارآمد در زمینه پردازش های *InSAR*، می توان با صرف زمان و هزینه های پردازشی نه چندان زیاد در قیاس با داده های اپتیک و باز پراکنش رادار، داده های سری زمانی همدوسی *InSAR* را با کیفیت بالا و در زمان مناسب تهیه نمود. با بهره گیری از این داده ها در تلفیق با قابلیت های الگوریتم های مختلف طبقه بندی نظارت-شده مبتنی بر یادگیری ماشین، امکان نظارت جامع و دقیق بر تغییرات پوشش زمین فراهم شده است. تغییرات پوشش زمین به عنوان یکی از مؤلفه های کلیدی در پایش تغییرات شکل/جابه جایی زمین به شمار می رود. در مطالعات مربوط به تجزیه و تحلیل سری زمانی تغییرات شکل زمین (به عنوان مثال فرونشست زمین یا زمین لغزش) با استفاده از *InSAR*، می توان در کنار مدل سازی جابه جایی زمین، تغییرات پوشش های مختلف سطح زمین را با بهره گیری از داده های همدوسی، پایش و ارزیابی نمود. بدین طریق امکان مدل سازی و بررسی ارتباط بین تغییرات شکل/جابه جایی زمین و تغییرات پوشش سطح زمین وجود دارد.

کلاس مربوط به اراضی ساخته شده در تمامی کرنل ها، بالاترین مقدار صحت (بین ۹۳ تا ۹۸٫۵ درصد به لحاظ صحت های کاربر و تولید کننده) و در مقابل طبقه پوشش گیاهی متراکم، پایین ترین مقدار صحت (بین ۱۱ تا ۵۶٫۲۵ درصد به لحاظ صحت های کاربر و تولید کننده) را به خود اختصاص داده اند. سایر طبقات پوشش زمین نیز پس از اراضی ساخته شده در مجموع بر اساس صحت های کاربر و تولید کننده به ترتیب عبارت اند از خاک لخت، اراضی کشاورزی و پهنه های آبی. بر اساس یافته های این پژوهش، قابلیت های داده های همدوسی *InSAR*، مستقل از نوع تابع کرنل *SVM* نیست. به این معنی که الگوریتم طبقه بندی کننده می تواند تأثیر بسزایی بر نتایج داشته باشد. به طوری که در این مطالعه اختلاف عملکرد کلی برابر با حداکثر ۱۳ درصد بین توابع کرنل مختلف *SVM* مشاهده گردید. این مهم در خصوص رویکردهای مختلف طبقه بندی نیز می تواند صادق باشد. بنابراین به طور کلی می توان گفت، داده های همدوسی *InSAR* اطلاعات مفیدی برای طبقه بندی پوشش زمین خصوصاً برای برخی طبقات نظیر اراضی ساخته شده، خاک لخت و اراضی کشاورزی ارائه می دهند که در صورت بهره گیری از الگوریتم طبقه بندی کننده مناسب، می توانند بسیار مثمر ثمر واقع گردند.

پیشنهاد می شود که در پژوهش های آتی برای دستیابی به صحت های بالاتر و بهبود نتایج طبقه بندی، از داده های باز پراکنش راداری نیز به عنوان مکمل داده های همدوسی *InSAR* استفاده شود. استفاده مشترک از داده های همدوسی و باز پراکنش راداری

مراجع

- [1] F. Sica, A. Pulella, M. Nannini, M. Pinheiro, and P. Rizzoli, "Repeat-pass SAR interferometry for land cover classification: A methodology using Sentinel-1 Short-Time-Series," *Remote Sens. Environ.*, vol. 232, p. 111277, 2019.
- [2] A. W. Jacob et al., "Sentinel-1 InSAR coherence for land cover mapping: A comparison of multiple feature-based classifiers," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, pp. 535–552, 2020.
- [3] M. Çavur, H. S. Duzgun, S. Kemeç, and D. C. Demirkan, "Land use and land cover classification of Sentinel 2-A: St Petersburg case study," *Int. Arch. Photogramm.*

- Remote Sens. Spat. Inf. Sci., vol. 42, no. 1, p. W2, 2019.
- [4] D. Bargiel, "A new method for crop classification combining time series of radar images and crop phenology information," *Remote Sens. Environ.*, vol. 198, pp. 369–383, 2017.
- [5] V. A. Parsa and E. Salehi, "Spatio-temporal analysis and simulation pattern of land use/cover changes, case study: Naghadeh, Iran," *J. Urban Manag.*, vol. 5, no. 2, pp. 43–51, 2016.
- [6] G. T. Ayele et al., "Time series land cover mapping and change detection analysis using geographic information system and remote sensing, Northern Ethiopia," *Air, Soil Water Res.*, vol. 11, p. 1178622117751603, 2018.
- [7] H. N. T. Thanh, T. M. Doan, E. Tomppo, and R. E. McRoberts, "Land use/land cover mapping using multitemporal sentinel-2 imagery and four classification methods—A case study from dak nong, vietnam," *Remote Sens.*, vol. 12, no. 9, p. 1367, 2020.
- [8] S. Moulds, W. Buytaert, and A. Mijic, "A spatio-temporal land use and land cover reconstruction for India from 1960–2010," *Sci. data*, vol. 5, no. 1, pp. 1–11, 2018.
- [9] X. Zhang, W. Shi, and Z. Lv, "Uncertainty assessment in multitemporal land use/cover mapping with classification system semantic heterogeneity," *Remote Sens.*, vol. 11, no. 21, p. 2509, 2019.
- [10] S. Xie, L. Liu, X. Zhang, and X. Chen, "Annual land-cover mapping based on multi-temporal cloud-contaminated landsat images," *Int. J. Remote Sens.*, vol. 40, no. 10, pp. 3855–3877, 2019.
- [11] Y. Hu, L. Zhen, and D. Zhuang, "Assessment of land-use and land-cover change in Guangxi, China," *Sci. Rep.*, vol. 9, no. 1, pp. 1–13, 2019.
- [12] P. K. Mishra, A. Rai, and S. C. Rai, "Land use and land cover change detection using geospatial techniques in the Sikkim Himalaya, India," *Egypt. J. Remote Sens. Sp. Sci.*, vol. 23, no. 2, pp. 133–143, 2020.
- [13] A. Capolupo, C. Monterisi, and E. Tarantino, "Landsat Images Classification Algorithm (LICA) to automatically extract land cover information in Google Earth Engine environment," *Remote Sens.*, vol. 12, no. 7, p. 1201, 2020.
- [14] S. Xie, L. Liu, and J. Yang, "Time-Series Model-Adjusted Percentile Features: Improved Percentile Features for Land-Cover Classification Based on Landsat Data," *Remote Sens.*, vol. 12, no. 18, p. 3091, 2020.
- [15] J. Ai, C. Zhang, L. Chen, and D. Li, "Mapping Annual Land Use and Land Cover Changes in the Yangtze Estuary Region Using an Object-Based Classification Framework and Landsat Time Series Data," *Sustainability*, vol. 12, no. 2, p. 659, 2020.
- [16] R. Z. Khalil, "InSAR coherence-based land cover classification of Okara, Pakistan," *Egypt. J. Remote Sens. Sp. Sci.*, vol. 21, pp. S23–S28, 2018.
- [17] A. Khan, H. Govil, G. Kumar, and R. Dave, "Synergistic use of Sentinel-1 and Sentinel-2 for improved LULC mapping with special reference to bad land class: a case study for Yamuna River floodplain, India," *Spat. Inf. Res.*, pp. 1–13, 2020.
- [18] Y. Chen, S. Qiao, G. Zhang, Y. J. Xu, L. Chen, and L. Wu, "Investigating the potential use of Sentinel-1 data for monitoring wetland water level changes in China's Momoge National Nature Reserve," *PeerJ*, vol. 8, p. e8616, 2020.
- [19] Y. Ban, P. Zhang, A. Nascetti, A. R. Bevington, and M. A. Wulder, "Near real-time wildfire progression monitoring with Sentinel-1 SAR time series and deep learning," *Sci. Rep.*, vol. 10, no. 1, pp. 1–15, 2020.
- [20] V. Nizalapur and A. Vyas, "Texture Analysis for Land Use Land Cover (lulc) Classification in Parts of Ahmedabad, Gujarat," *Int. Arch. Photogramm. Remote*

- Sens. Spat. Inf. Sci., vol. 43, pp. 275–279, 2020.
- [21] L. Orlíková and J. Horák, "Land Cover Classification Using Sentinel-1 SAR Data," in 2019 International Conference on Military Technologies (ICMT), 2019, pp. 1–5.
- [22] D. Geudtner and R. Torres, "Sentinel-1 system overview and performance," in 2012 IEEE International Geoscience and Remote Sensing Symposium, 2012, pp. 1719–1721.
- [23] A. Mestre-Quereda, J. M. Lopez-Sanchez, F. Vicente-Guijalba, A. W. Jacob, and M. E. Engdahl, "Time-Series of Sentinel-1 Interferometric Coherence and Backscatter for Crop-Type Mapping," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 13, pp. 4070–4084, 2020.
- [24] M. Arias, M. Á. Campo-Bescós, and J. Álvarez-Mozos, "Crop classification based on temporal signatures of Sentinel-1 observations over Navarre province, Spain," *Remote Sens.*, vol. 12, no. 2, p. 278, 2020.
- [25] M. Ramanuja, "Review of synthetic aperture radar frequency, polarization, and incidence angle data for mapping the inundated regions," *Journal of Applied Remote Sensing*, vol. 12, no. 2, 2018.
- [26] F. Vicente-Guijalba et al., "Assessing hypertemporal Sentinel-1 coherence maps for land cover monitoring," in 2017 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), 2017, pp. 1–3.
- [27] M. E. Engdahl and J. M. Hyypä, "Land-cover classification using multitemporal ERS-1/2 InSAR data," *IEEE Trans. Geosci. Remote Sens.*, vol. 41, no. 7, pp. 1620–1628, 2003.
- [28] Z. Xuedong, L. Wenxi, and H. Shuguang, "Urban Change Detection in TerraSAR Image Using the Difference Method and SAR Coherence Coefficient," *J. Eng. Sci. Technol. Rev.*, vol. 11, no. 3, 2018.
- [29] A. Jamali, "Sentinel-1 Image Classification Using Machine Learning Algorithms Based on the Support Vector Machine and Random Forest," *Int. J. Geoinformatics*, vol. 16, no. 2.
- [30] A. Navale and D. Haldar, "Evaluation of machine learning algorithms to Sentinel SAR data," *Spat. Inf. Res.*, pp. 1–11, 2019.
- [31] S. Abdikan, F. B. Sanli, M. Ustuner, and F. Calò, "Land cover mapping using sentinel-1 SAR data," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 41, p. 757, 2016.
- [32] J. Soria-Ruiz, Y. Fernandez-Ordonez, and I. H. Woodhouse, "Land-cover classification using radar and optical images: a case study in Central Mexico," *Int. J. Remote Sens.*, vol. 31, no. 12, pp. 3291–3305, 2010.
- [33] Daripour, N., amanpour, S, "An analysis of the environmental crisis and spatial distribution of green space in Ahwaz," *Journal of Environmental Science Studies*, vol. 2, no. 4, pp. 546–555, 2018 (Persian).
- [34] Arvin, M., pour ahmad, A., zanganeh shahraki, S, "Evaluation of vacant lands for infill development by used of hybrid decision-making techniques and ARCGIS (case study: Ahvaz city)," *Geographical Planning of Space*, vol. 7, no. 26, pp. 163–182, 2018 (Persian).
- [35] R. Torres et al., "GMES Sentinel-1 mission," *Remote Sens. Environ.*, vol. 120, pp. 9–24, 2012.
- [36] D. Geudtner, R. Torres, P. Snoeij, and M. Davidson, "Sentinel-1 System Overview," in Proceedings of the 9th European Conference on Synthetic Aperture Radar, Nürnberg, Germany, 2012, pp. 23–26.
- [37] D. Massonnet and K. L. Feigl, "Radar interferometry and its application to changes in the Earth's surface," *Rev. Geophys.*, vol. 36, no. 4, pp. 441–500, 1998.
- [38] P. A. Rosen et al., "Synthetic aperture radar interferometry," *Proc. IEEE*, vol. 88,

- no. 3, pp. 333–382, 2000.
- [39] R. Touzi, A. Lopes, J. Bruniquel, and P. W. Vachon, "Coherence estimation for SAR imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 37, no. 1, pp. 135–149, 1999.
- [40] Yague-Martinez, N., De Zan, F., & Prats-Iraola, P., "Coregistration of interferometric stacks of Sentinel-1 TOPS data," *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 7, pp. 1002–1006, 2017.
- [41] T. C. Christofides, "Randomized response in stratified sampling," *J. Stat. Plan. Inference*, vol. 128, no. 1, pp. 303–310, 2005.
- [42] C. J. C. Burges, "A tutorial on support vector machines for pattern recognition," *Data Min. Knowl. Discov.*, vol. 2, no. 2, pp. 121–167, 1998.
- [43] K.-B. Duan and S. S. Keerthi, "Which is the best multiclass SVM method? An empirical study," in *International workshop on multiple classifier systems*, 2005, pp. 278–285.
- [44] H. Fathizad, A. Safari, M. Bazgir, and G. Khosravi, "Evaluation of SVM with Kernel method (linear, polynomial, and radial basis) and neural network for land use classification," *IJRDR*, vol. 23, no. 4, pp. 729–743, 2017 (Persian).
- [45] A. Darvishi Boloorani, N. Neysani Samany, R. Papi, and M. Soleimani, "Dust source susceptibility mapping in Tigris and Euphrates basin using remotely sensed imagery," *CATENA*, vol. 209, p. 105795, 2022.
- [46] A. Foroudi Khowr, M. Saneie, and M. Azhdari Moghaddam, "Comparison of Adaptive Neuro Fuzzy Inference System (ANFIS) and Support Vector Machines(SVM) for discharge capacity prediction of a sharp-crested weirs," *Iran. J. Irrig. Drain.*, vol. 11, no. 5, pp. 772–784, 2017 (Persian).
- [47] A. Darvishi Boloorani, R. Papi, M. Soleimani, L. Karami, F. Amiri, and N. Neysani Samany, "Water bodies changes in Tigris and Euphrates basin has impacted dust storms phenomena," *Aeolian Res.*, vol. 50, p. 100698, 2021.
- [48] S. V Stehman, M. K. Arora, T. Kasetkasem, and P. K. Varshney, "Estimation of fuzzy error matrix accuracy measures under stratified random sampling," *Photogramm. Eng. Remote Sens.*, vol. 73, no. 2, pp. 165–173, 2007.
- [49] J. R. Jensen, *Introductory digital image processing: a remote sensing perspective.*, no. Ed. 2. Prentice-Hall Inc., 1996.
- [50] R. Papi, S. Attarchi, and M. Soleimani, "Analysing Time Series of Land Subsidence in the West of Tehran Province (Shahriar Plain) and its Relation to Groundwater Discharge by InSAR Technique," *Geogr. Sustain. Environ.*, vol. 10, no. 1, pp. 109–128, 2020 (Persian).
- [51] P. Berardino, G. Fornaro, R. Lanari, and E. Sansosti, "A new algorithm for surface deformation monitoring based on small baseline differential SAR interferograms," *IEEE Trans. Geosci. Remote Sens.*, vol. 40, no. 11, pp. 2375–2383, Nov. 2002.
- [52] M. Sandberg, "Land cover mapping with multi-temporal SAR and optical satellite data," 2016.
- [53] N. Joshi et al., "A review of the application of optical and radar remote sensing data fusion to land use mapping and monitoring," *Remote Sens.*, vol. 8, no. 1, p. 70, 2016.



Evaluation of Sentinel-1 Interferometric SAR Coherence efficiency for Land Cover Mapping

Masoud Soleimani¹, Sara Attarchi^{2*}, Narjes Mahmoody-Vanolya¹, Farimah Bakhshizadeh¹, Hamed Ahmadi¹

1- PhD Student in Remote Sensing and GIS, Faculty of Geography, University of Tehran

2- Assistant Professor, Department of Remote Sensing and GIS, Faculty of Geography, University of Tehran

Abstract

In this study, in order to evaluate the capabilities of Interferometric Synthetic Aperture Radar (InSAR) time series data and machine learning for land cover mapping, a time series of Sentinel-1 SAR data (including 16 SLC images with approximately 24 days time interval) from 2018 to 2020 were used for a region of Ahvaz County located in Khuzestan province. Based on different SAR pairs, 25 coherence images were obtained in different time periods using InSAR processing. Five dominant land cover classes in the region including built-up lands, agricultural lands, water bodies, bare soil, and dense natural vegetation cover were identified and selected. Through Google Earth's high-resolution imagery, a total of 4,930 ground samples with appropriate spatial distribution for all land cover classes were obtained. The obtained multi-temporal coherence images were used as input variables to the support vector machine (SVM) classifier. The training and validation process of different SVM kernels was performed using 80% and 20% of the ground truth samples, respectively. Based on the classification results the overall accuracy in different kernels including linear, 2th-degree polynomial, 4th-degree polynomial, 6th-degree polynomial, radial base function (RBF), and sigmoid were computed 60.7, 64.7, 67.7, 69.9, 66.3, and 59.5%, and Kappa coefficients were reported 50.8, 55.87, 59.62, 62.38, 57.87, and 49.38%, respectively. Accordingly, the highest and the lowest overall accuracy and Kappa coefficient belong to the 6th-degree polynomial and sigmoid kernels, respectively. Based on the user and producer accuracy assessments in all kernels, the built-up land has the highest accuracy (93%–up to 98.5%), and in opposite the dense vegetation has the lowest accuracy (11%–up to 56.25%). Generally, the results emphasize the high potential of Sentinel-1 InSAR coherence data in land cover mapping. Meanwhile, the contribution of the classifier to the efficiency of data is also important.

Key words: Land cover mapping, Classification, Support Vector Machine (SVM), Interferometric SAR (InSAR), Coherence.