

## استخراج اتوماتیک شبکه راه براساس ادغام تصاویر ماهواره‌ای سنتینل ۱ و سنتینل ۲ با ویژگی‌های آنالیز بافت در فضای غیرشهری (مطالعه موردی: مسیر شاهرود- میامی)

سید مهدی موسوی\*، دانشجوی کارشناسی ارشد مهندسی راه و ترابری، دانشکده مهندسی عمران،

دانشگاه صنعتی شاهرود

حسین قاسم زاده طهرانی، استادیار گروه مهندسی راه و ترابری، دانشکده مهندسی عمران، دانشگاه

صنعتی شاهرود

بهناز بیگدلی، استادیار گروه سنجش از راه دور و فتوگرامتری، دانشکده مهندسی عمران، دانشگاه

صنعتی شاهرود

Email: eng.mousavi1996@gmail.com

دریافت: ۱۴۰۰/۰۲/۰۴ - پذیرش: ۱۴۰۰/۰۴/۰۲

### چکیده

سنجش از دور در بسیاری از زمینه‌های علمی و تحقیقاتی، از جمله در مهندسی راه و حمل و نقل، کاربردهای گسترده‌ای دارد که می‌توان به مهم‌ترین کاربرد آن یعنی استخراج شبکه راه و تهیه نقشه شماتیک آن اشاره کرد. استخراج شبکه راه‌ها از تصاویر ماهواره‌ای نوعی فناوری مکمل برای دستیابی به اطلاعات به‌شمار می‌آید که تفسیر و آنالیز تصویر را ساده‌تر کرده و باعث ارتقای کیفیت می‌شود. هدف اساسی این پژوهش، استخراج اتوماتیک شبکه راه در مسیر شاهرود- میامی بوده که نقشه شبکه راه حاصله به عنوان ورودی سیستم مدیریت روسازی (PMS) مورد استفاده قرار گیرد. روش پیشنهادی در این مطالعه مبتنی بر تکنیک ادغام و تلفیق تصاویر ماهواره‌های سنتینل ۱ و سنتینل ۲ با روش حداکثر رأی‌گیری به منظور استفاده بیشینه از اطلاعات طیفی و مکانی چند تصویر (افزایش جزئیات) به جای تک‌تصویر، با استفاده از ویژگی‌های بافت، می‌باشد. در ادامه، برای انجام طبقه‌بندی نظارت شده، از دو طبقه‌بند غیرپارامتریک شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) و یک طبقه‌بند پارامتریک حداکثر احتمال شباهت (ML) در دو کلاس کلی راه و غیرراه استفاده شد. نمونه‌های آزمایشی به صورت تصادفی و همگن و نمونه‌هایی از تصاویر و نقشه‌های موجود منطقه برای ارزیابی دقت طبقه‌بندی استفاده شدند. نتایج نشان داد که ادغام و تلفیق نتایج طبقه‌بندی‌ها با روش حداکثر رأی‌گیری موجب بهبود دقت حدود ۴٪ برای ماهواره سنتینل ۱ و حدود ۶٪ برای ماهواره سنتینل ۲ در شناسایی مسیر و شبکه راه‌ها شده است. همچنین، ضریب کاپا در روش حداکثر رأی‌گیری نسبت به ANN (بهترین عملکرد مؤثر طبقه‌بندی‌ها) برای ماهواره سنتینل ۱ حدود ۰/۱۱ و برای ماهواره سنتینل ۲ حدود ۰/۰۶ رشد داشته است.

واژه‌های کلیدی: استخراج راه، شبکه عصبی مصنوعی، ادغام تصویر، طبقه‌بندی نظارت شده، سنجش از دور

## ۱. مقدمه

شبکه راه‌ها برترین سرمایه‌های حمل و نقل ملی هر کشور و از مهم‌ترین تسهیلات استراتژیک یک کشور محسوب می‌شوند. توسعه و رشد اقتصادی یک کشور به طور خلاصه و دقیق به سیستم حمل و نقل قابل دسترسی آن مرتبط است. از آنجا که مدیران به طور دقیق شناخت کاملی از وضعیت مسیر و روسازی خطوط تحت مدیریت خود ندارند، همیشه اطلاعات مورد نیاز خود را به صورت سنتی و توسط روش‌های قدیمی جمع‌آوری می‌کنند. در این مواقع به کارگیری سیستم سنجش از راه دور می‌تواند به عنوان یک بازوی قدرتمند به پشتیبانی و حمایت از مدیریت بشتابد (جوادیان و جعفرپور، ۱۳۸۸). استخراج راه‌ها از تصاویر سنجش از راه دور یک روش سریع و اقتصادی برای به دست آوردن داده‌های حمل و نقل و به روز رسانی پایگاه داده سیستم اطلاعات جغرافیایی (GIS) است. از طرفی، تصاویر سنجش از راه دور قابلیت توصیف سطوح شهری و غیرشهری از قبیل جاده و دیگر اشیای ساخت بشر را دارد که روش‌های مختلفی برای استخراج راه‌ها از تصاویر سنجش از راه دور ارائه و توسعه داده شده‌اند (میائو و همکاران، ۲۰۱۳). برخی از روش‌های سنتی اولیه مبتنی بر یادگیری بدون نظارت استفاده کرده و برخی نیز سعی در استفاده از اطلاعات ذاتی تصویر، از جمله رنگ، بافت و مرز داشته‌اند (گائو و همکاران، ۲۰۱۸). از عوامل محدود کننده استخراج اتوماتیک راه‌ها نیز می‌توان به پدیده‌ها در همسایگی راه، عوارض و وسایل نقلیه در راه‌ها، پل‌ها و سایه‌های آن‌ها، سایه‌های ابر و خطاهای سنسور اشاره کرد که پیچیدگی شناسایی راه‌ها را افزایش می‌دهند (بختیاری و همکاران، ۲۰۱۷). وانگ و همکاران (۲۰۱۳) با استفاده از تصویر ماهواره‌ای QuickBird در منطقه کونمینگ یونان به وسعت ۶/۱۲ کیلومتر مربع، مطالعه‌ای روی استخراج راه‌ها انجام دادند. در این مطالعه، از چهار نوع پردازش استفاده شد که به ترتیب عبارتند از: استخراج اطلاعات

معنایی در منطقه، تشخیص لبه جاده، پالایش نقاط جاده و ردیابی جاده. در نهایت، تمام ویژگی‌ها با یکدیگر ادغام شده و نقشه شبکه راه‌ها به دست آمد. نتایج نشان داد دقتی که از پردازش‌ها برای استخراج اطلاعات جاده‌ای به دست آمد از دقت مناسب و بالایی برخوردار بود. شی و همکاران (۲۰۱۴) روش جدیدی برای استخراج راه اصلی شهری از تصاویر با وضوح بالای چندطیفی Ziyuan-3 ارائه دادند که براساس ادغام طبقه‌بندی طیفی - مکانی و ویژگی‌های شکل در دو مرحله انجام شده است. در مرحله اول، طبقه‌بندی طیفی و مکانی تصاویر با استفاده از ماشین بردار پشتیبان به دو کلاس راه و غیرراه تقسیم شده است. در مرحله دوم، نقشه خروجی حاصل از طبقه‌بندی راه با ویژگی‌های شکل فیلتر شده تا راه‌های طبقه‌بندی نشده را حذف کند. با بررسی نتایج به دست آمده مشاهده شد که روش پیشنهادی قادر است به نتایج نسبتاً خوبی در استخراج راه اصلی شهری دست یابد. اما با این حال، این روش برای استخراج اتصال پیچیده راه ناموفق است. وانگ و همکاران (۲۰۱۴) یک روش جدید پیشنهاد دادند که ابتدا استخراج جاده از تصاویر چندمقیاسی صورت گرفته و در نهایت با عملیات مورفولوژی ریاضی پردازش شود. داده مورد استفاده، تصویر هوایی در منطقه Yangjiang چین با ابعاد ۲۷۱۹×۲۸۰۸ و روی آسفالت شهری درجه بالا (عرض جاده ۱۰ متر) مورد مطالعه قرار گرفت. در روش چندمقیاسی، ابتدا عملیات فیلترینگ نویز و قطعه‌بندی آغاز شده، سپس بافت‌ها با پنجره ۵×۵ استخراج شده و به باندهای اصلی اضافه شدند. در نهایت، راه‌های استخراج شده براساس مورفولوژی ریاضی پردازش و بهینه‌سازی شدند. با بررسی نتایج حاصله مشاهده شد که نتایج این پژوهش رضایت‌بخش و قابل اعتماد است. بختیاری و همکاران (۲۰۱۷) یک روش نیمه-اتوماتیک برای تشخیص جاده‌ها از تصاویر ماهواره‌ای با وضوح بالا در محدوده شهری پیشنهاد کردند که در این مطالعه، از

باند قرمز، سبز و آبی (RGB) و وضوح مکانی یک متر انجام گردید. روش شبکه هرم چندویژگی دارای یک شبکه عصبی قدرتمند با ۱۰۱ لایه و دو قابلیت پردازش ویژگی می‌باشد. در مرحله بهینه‌سازی این روش، تابع افت وزن‌دار برای حل مشکل عدم تعادل کلاس راه ارائه شد. نتایج نشان می‌دهد که از مقایسه الگوریتم پیشنهادی (MFPN) با روش‌های دیگر، این روش در تمام معیارهای عملکرد بهتر عمل می‌کند؛ به‌ویژه، این روش باعث بهبود استخراج برای جاده‌های باریک روستایی شده است. ژانگ و همکاران (۲۰۱۹) به‌منظور توسعه مداوم شبکه‌های حمل و نقل یک روش خودکار مبتنی بر شبکه عصبی عمیق (DNN<sup>۲</sup>) در شهر پکن کشور چین برای استخراج جاده‌ها از تصویر دو قطبی سنتینل ۱ (VV و VH) معرفی کردند. در تصویر راداری سنتینل ۱ از فرمت GRD و از حالت IW<sup>۳</sup> برای تصویربرداری استفاده شده و ابعاد منطقه مورد مطالعه ۲۵۶×۲۵۶ پیکسل بوده است. در این روش پیشنهادی، از دو مدل گسترده CNN<sup>۴</sup> و FCN<sup>۵</sup> استفاده شده و در گام بعدی، چندین بهینه‌سازی آموزش برای بهبود دقت ارائه شد. علاوه بر این، نتایج نهایی با چهار الگوریتم یادگیری ماشین (SVM-RF-DT-KNN) نیز برای دقت مقایسه شدند. نتایج این مطالعه نشان داد که شبکه پیشنهادی FCN با دقت ۹۵/۱۷ درصد نسبت به شبکه CNN با دقت ۸۸/۸۱ درصد به طور قابل توجهی از برخی روش‌های یادگیری ماشین در دقت بهتر عمل کرده است.

در اکثر مقالات توضیح داده شده، از یک سنجنده برای شناسایی و استخراج شبکه راه‌ها استفاده شده و همچنین تصاویر اخذ شده در این مطالعات به صورت غیررایگان و هزینه‌دار بوده است. در یک دهه اخیر، رویکرد شناسایی و استخراج پدیده‌های زمین به سمت ادغام دو یا چند سنجنده بسیار مورد توجه بوده است.

تصاویر دیجیتال هوایی UltraCam در شهر شیراز، تصویر ماهواره‌ای WorldView در شهر اهواز و همچنین تصویر QuickBird در شهر تهران استفاده شده است. روش پیشنهادی مبتنی بر تشخیص لبه و ویژگی‌های مکانی-طیفی بود. سپس، طبقه‌بندی با استفاده از طبقه‌بندی‌کننده نظارت شده SVM انجام شده و در نهایت کیفیت جاده‌های شناسایی شده با استفاده از تکنیک‌های مورفولوژی بهبود یافته و عوارض غیرراه حذف شدند. با توجه به نتایج حاصل از این پژوهش، مشاهده شد که استخراج جاده با این روش پیشنهادی برای تصویر UltraCam دقت زیادی را فراهم کرده است و از طرفی اعمال عملگر مورفولوژی باعث افزایش ضریب کاپا شده است. عبدالفتاح و چوگمانی (۲۰۱۷) مطالعه‌ای روی یک روش استخراج نیمه‌اتوماتیک با استفاده از داده‌های راداری ماهواره سنتینل ۱ (SAR) انجام دادند که هدف از انجام این تحقیق پیشنهاد یک رویکرد سازگار برای استخراج راه‌ها و مسیرهایی بود که هر ماه در بین مرز تونس و لیبی توسط قاچاقچیان ساخته می‌شدند و از سه مرحله تشکیل شده بود: پیش‌پردازش، تشخیص لبه و استخراج ویژگی شکل. همچنین، از شاخص Sobel برای شناسایی لبه در این رویکرد استفاده شد. به منظور انجام طبقه‌بندی در این تحقیق از دو الگوریتم Perona-Malik و الگوریتم کلاسیک Gaussian استفاده شد که نتایج نشان داد شاخص Correctness الگوریتم Perona-Malik ۱۵٪ بیشتر نسبت به الگوریتم Gaussian توانسته جاده‌ها را استخراج نماید که نشان از برتری آن نسبت به الگوریتم دیگری دارد. گائو و همکاران (۲۰۱۸) یک الگوریتم پیشنهادی به نام شبکه هرم چندویژگی (MFPN<sup>۱</sup>) را در مناطق شهری و حومه پیشنهاد کردند. آزمایش‌ها روی مجموعه‌ای از داده‌های تصاویر سنجنش از دور با وضوح بالا به ابعاد هر تصویر ۱۵۰۰×۱۵۰۰ متر و متشکل از سه

4- Convolutional neural network

5- Fully convolutional neural network

1- Multiple Feature Pyramid Network

2- Deep neural network

3- Interferometric Wide Swath

که در ایران نقشه شبکه راه‌ها را با استفاده از تصاویر ماهواره‌ای استخراج می‌کند. همچنین، در ادامه، نقشه خروجی حاصل از این مطالعه به عنوان ورودی سیستم مدیریت روسازی (PMS) قرار گرفته است. بدین معنی که سیستم مدیریت روسازی دارای شبکه راه‌هایی باشد که به صورت اتوماتیک از تصاویر ماهواره‌ای استخراج شده باشد.

## ۲. روش پیشنهادی

استفاده از سنجنده‌های گوناگون، اعم از راداری و اپتیکی، سبب افزایش اطلاعات ورودی و به دنبال آن افزایش دقت در شناسایی پدیده‌ها می‌شود. با توجه به شکل ۱ که ساختار روش پیشنهادی در آن قابل مشاهده است، ابتدا روی تصاویر ماهواره‌ای سنتینل ۱ و سنتینل ۲ عمل پیش-پردازش صورت گرفته و تصاویر تصحیح می‌شوند. در ادامه، با استفاده از روش آنالیز بافت، ویژگی‌های مرتبط با راه استخراج شده و سپس داده‌ها با استفاده از سه الگوریتم طبقه‌بندی نظارت شده اعم از شبکه عصبی مصنوعی (ANN<sup>۱</sup>)، ماشین بردار پشتیبان (SVM<sup>۲</sup>) و حداکثر احتمال شباهت (ML<sup>۳</sup>) در دو کلاس کلی راه و غیرراه طبقه‌بندی می‌شوند. در پایان، نقشه‌های خروجی حاصل از روش‌های طبقه‌بندی توسط الگوریتم حداکثر رأی‌گیری<sup>۴</sup> با یکدیگر ادغام شده و پیکسل‌هایی که دارای فراوانی بیشتر باشند به عنوان پیکسل منتخب نهایی شناخته شده و نقشه نهایی به دست می‌آید.

چون هر سنجنده در کاربرد خاصی مناسب بوده و دارای محدودیت‌هایی در زمینه سایر کاربردها می‌باشد. از این جهت، در بیشتر مواقع، لازم است تا به منظور یک کاربرد خاص و یا پایش پدیده‌های گوناگون، داده‌ها و تصاویر اخذ شده توسط سنجنده‌های مختلف با یکدیگر به نحوی تلفیق شوند تا داده و یا تصاویر جدید دارای ویژگی‌های تمامی تصاویر و یا داده‌های اولیه باشد (وانگ و همکاران، ۲۰۰۵).

نوآوری در این روش پیشنهادی در واقع رویکرد آنالیز آن بوده است. بدین گونه که در آن به جای استفاده از تک‌تصویر ماهواره‌ای، از تکنیک ادغام دو تصویر ماهواره‌ای (فیوژن) به طور همزمان استفاده شده است. همچنین، در این پژوهش، از تصاویر رایگان و عمومی استفاده شده که هم یک مزیت بوده و هم این مطالعه توانسته با روش پیشنهادی خود با استفاده از تصاویر ماهواره‌ای با قدرت تفکیک مکانی ۱۰ متری (که عرض جاده در حدود یک پیکسل قابل تشخیص است) به استخراج عارضه یک پیکسلی پردازد که کاری بسیار دشوار می‌باشد. در صورتی که در مطالعات ذکر شده در بالا اغلب تصاویر دارای وضوح مکانی ۱ تا ۲ متر بوده‌اند که عرض جاده در حدود ۱۰ تا ۲۰ پیکسل خواهد بود. از طرفی، در ارگان‌ها و سازمان‌های راه بیشتر از عکس-های هوایی و نقشه‌برداری استفاده شده و کمتر به تصاویر ماهواره‌ای پرداخته می‌شود.

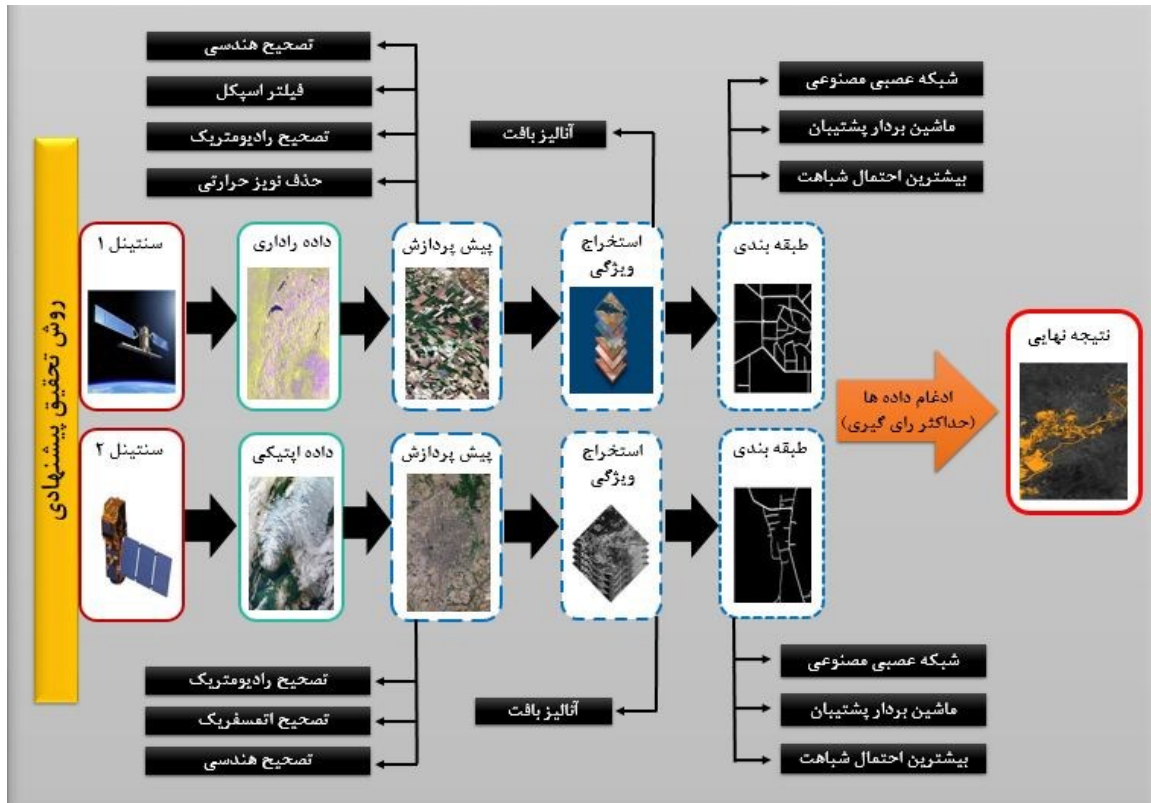
این مطالعه یکی از شاخه‌های سیستم‌های هوشمند حمل و نقل بوده و همچنین جزو اولین گروه‌هایی است

<sup>3</sup>- Maximum Likelihood

<sup>4</sup>- Majority Voting Algorithm

<sup>1</sup>- Artificial Neural Network

<sup>2</sup>- Support Vector Machine



شکل ۱. روش تحقیق پیشنهادی

## ۲-۱. داده‌های سنجنده‌ها

### ۲-۱-۱. ماهواره سنتینل ۱

سری ماهواره‌های سنتینل با کاربردهای مختلف در علوم زمین توسط اتحادیه اروپا طراحی و ساخته شد و مأموریت خود را با ارسال اولین سری از این ماهواره‌ها با نام Sentinel-1 در سال ۲۰۱۴ آغاز نمود. سنتینل ۱ تجهیزات یک سنجنده SAR که در باند C قرار دارد را حمل می‌کند و از توانایی اخذ داده بدون محدودیت در طول شبانه‌روز و در شرایط آب و هوایی مختلف بهره‌مند می‌باشد (آژانس فضایی اروپا، ۲۰۲۰). این سنجنده در چهار حالت از سطح زمین تصویربرداری می‌کند که عبارتند از: حالت  $SM^1$ ، حالت  $IW^2$  و حالت

$WM^3$ ، که حالت اصلی‌ترین نوع تصویربرداری و حالت استفاده شده در این مطالعه می‌باشد. پهنای نوار تصویربرداری در این حالت ۲۵۰ کیلومتر و توان تفکیک مکانی در این نوع تصویربرداری ۱۰ متر در امتداد آزیموت و ۱۰ متر در امتداد رنج و قدرت تفکیک زمانی ۶ روز می‌باشد (لازکی و همکاران، ۲۰۱۷). در این مطالعه، از سنجنده راداری Sentinel-1A و از مد  $IW$  و پلاریزاسیون  $VV$  برای پردازش استفاده گردیده است. پلاریزاسیون  $VV$  یعنی امواج در جهت عمودی ارسال شده و با یک اسکتر عمودی نیز دریافت شده است. همچنین، پلاریزاسیون  $VV$  دارای میزان انرژی در دسترس بیشتر می‌باشد. مشخصات مندرج در تصویر ماهواره‌ای سنتینل ۱ در جدول ۱ قابل مشاهده می‌باشد.

<sup>3</sup>- Wave Mode

<sup>1</sup>- Strip map

<sup>2</sup>- Extra Wide Swath

جدول ۱. مشخصات تصویر ماهواره‌ای سنتینل 1A

کانال	زمان اخذ تصویر برداری	قطبش	جهت مدار	نوع و پردازش تصویر	شماره مدار اخذ تصویر	رزولوشن رنج و آزیموت (متر)
C	9/ Jun/2019 14:19:52 PM	VV	Ascending	IW-GRD	172	10×10

### ۲-۱-۲. ماهواره سنتینل ۲

طیفی مرئی، مادون قرمز نزدیک و مادون قرمز موج کوتاه می‌باشند (آژانس فضایی اروپا، ۲۰۲۰). در این مطالعه، از سنجنده آپتیک Sentinel-2B و شش باند این سنجنده در دو طیف محدوده مرئی و مادون قرمز نزدیک (VNIR) شامل باندهای ۲-۳-۴-۸ و محدوده مادون قرمز طول موج کوتاه (SWIR) که شامل باندهای ۱۱-۱۲ می‌باشد، استفاده گردیده است. مشخصات مندرج در تصویر ماهواره‌ای سنتینل ۲ در جدول ۲ قابل مشاهده می‌باشد.

سنتینل ۲ بخشی از برنامه Copernicus است که توسط آژانس فضایی اروپا برای جمع‌آوری اطلاعات از زمین طراحی و ایجاد شده است. سنجنده تصویربرداری سوار شده روی سنتینل ۲، MSI<sup>۱</sup> نام دارد که تصاویر منحصراً به فردی را ارائه می‌دهد. این تصاویر دارای توان تفکیک مکانی ۱۰، ۲۰ و ۶۰ متر و شامل ۱۳ باند در محدوده

جدول ۲. مشخصات تصویر ماهواره‌ای سنتینل 2B

زمان اخذ تصویر	نوع سنجنده و فرمت تصویر	نام محدوده طیفی	شماره باند	طول موج (نانومتر)	عرض باند (نانومتر)	رزولوشن مکانی (متر)
		مرئی (آبی)	۲	۴۹۰	۶۵	۱۰
		مرئی (سبز)	۳	۵۶۰	۳۵	۱۰
		مرئی (قرمز)	۴	۶۶۵	۳۰	۱۰
11/ Jun/2019 06:56:28 AM	MSI-Level1C	NIR	۸	۸۴۲	۱۱۵	۱۰
		مادون قرمز نزدیک				
		مادون قرمز طول موج کوتاه	۱۱	۱۶۱۰	۹۰	۱۰
		مادون قرمز طول موج کوتاه	۱۲	۲۱۹۰	۱۸۰	۱۰

### ۲-۲. پیش پردازش داده‌ها

پردازش تصاویر است، چرا که تمامی محاسبات بعدی بر اساس تصویر تولیدی در این مرحله انجام می‌گیرد. این امر سبب افزایش قدرت و توان طیفی و مکانی در تصاویر سنجنده می‌گردد. در ادامه، به تشریح پیش پردازش داده‌های راداری و اپتیکی پرداخته شده است.

عموماً به دلیل حرکت ماهواره و زمین در هنگام تصویربرداری خطاهایی روی تصویر ایجاد می‌شود که این خطاها شامل جابه‌جایی، اعوجاج و چرخش می‌باشد. مرحله پیش پردازش داده‌ها یکی از مهم‌ترین مراحل در

<sup>1</sup> - Multi Spectral Instrument

## ۲-۲-۱. پیش پردازش داده راداری

پیش پردازش داده‌های راداری در نرم‌افزار SNAP 8.0 انجام گرفته که در اولین مرحله اثرات نویزهای حرارتی حذف شدند (نویزهای حرارتی اطلاعات رادیومتری و طیفی تصویر راداری را تحت تأثیر قرار می‌دهند). در مرحله بعد، تصحیح رادیومتری انجام گرفت که تصویر راداری از مقادیر شدت<sup>۱</sup> به مقادیر بازپراکنش از سطح تبدیل شدند. در مرحله بعد، از فیلتر Refine Lee که فیلتر خاص تصاویر راداری برای حذف خطاهای اسپکل<sup>۲</sup> است، استفاده شد. وجود اسپکل به خاطر رفتار تصادفی که دارد، برای هر پیکسل متفاوت است و در نتایج نهایی اثر خواهد گذاشت. در مرحله بعد، نوبت به تصحیحات توپوگرافی و هندسی می‌رسد. در این فرایند اعوجاجاتی که حین اخذ تصویر ایجاد شده است و بیشتر به خاطر بی‌نظمی‌های توپوگرافی زمین است، انجام می‌گیرد. علاوه بر این، این تصحیحات سبب حذف خطاهای

$$F_{i,j} = \frac{(H_{i,j} - \bar{H}_{i,j}) \times std(L)_{i,j(w,h)}}{std(H)_{i,j(w,h)} + \bar{L}_{i,j}} \quad (1)$$

Layover و Foreshortening می‌شود که این خطاها معمولاً در جاهایی اتفاق می‌افتد که ما عوارض بلند و مرتفع داریم مانند: کوهستان‌ها، جنگل‌ها و ساختمان‌ها.

## ۲-۲-۲. پیش پردازش داده اپتیکی

پیش از آغاز پیش‌پردازش داده‌های سنتینل ۲، باندهای ۱۱ و ۱۲ که دارای قدرت تفکیک مکانی ۲۰ متری هستند به وسیله تکنیک پن‌شارپ<sup>۳</sup> به داده‌های ۱۰ متری تبدیل می‌شوند. هدف از شارپ کردن این است که یک تصویر با وضوح مکانی پایین و قدرت طیفی بالا را با یک تصویر پانکروماتیک<sup>۴</sup> با رزولوشن مکانی بالاتر ترکیب کنیم تا تصویری با وضوح طیفی و مکانی بالا به دست آید که علاوه بر بهبود قدرت مکانی، بازتاب داده‌ها را نیز حفظ کند. در این مطالعه، به جای تصویر پانکروماتیک، از

باندهای ۱۰ متری سنتینل ۲ (باندهای ۲-۳-۴-۸) استفاده شده که دارای وضوح مکانی بالاتری هستند. از این پس از باندهای ۱۱ و ۱۲ شارپ شده با وضوح ۱۰ متری در این مطالعه استفاده می‌گردد. در این مطالعه، از روش LMVM<sup>۵</sup> برای شارپ کردن استفاده شده است. به گفته کاراتاناسی و همکاران (۲۰۰۷)، طبق مقایسه‌ای که در این پژوهش انجام گرفته این روش (LMVM) نسبت به سایر روش‌های شارپ کردن نظیر PCA، Gram-Schmidt و IHS توانسته بیشترین همجوشی را در تصویر ایجاد کند، به گونه‌ای که علاوه بر بهبود دقت مکانی، موجب بهبود دقت طیفی نیز می‌گردد. روش LMVM یک تابع نرمال سازی را در یک مقیاس محلی در داخل تصویر اعمال می‌کند تا ارزش‌های محلی و واریانس تصویر پانکروماتیک با وضوح بالا با ویژگی‌های طیفی تصویر رزولوشن پایین مطابقت داشته باشد. این نوع از ترکیب اطلاعات، ارتباط بین تصویر با وضوح بالا و تصویر با وضوح پایین را افزایش می‌دهد که در رابطه (۱) ارائه شده است (مانگارا و همکاران، ۲۰۲۰):

که  $F_{i,j}$  تصویر ادغام شده در مختصات پیکسل  $i, j$ ،  $H_{i,j}$  تصویر با وضوح بالا در مختصات پیکسل  $i, j$ ،  $\bar{L}_{i,j}$  میانگین محلی از تصویر وضوح پایین که در مختصات پیکسل  $i, j$  محاسبه شده است،  $\bar{H}_{i,j}$  میانگین محلی از تصویر وضوح بالا که در مختصات پیکسل  $i, j$  محاسبه شده است،  $std(L)_{i,j(w,h)}$  انحراف معیار محلی از تصویر وضوح پایین که در پنجره با سایز  $(w, h)$  و در مختصات پیکسل  $i, j$  محاسبه شده است و  $std(H)_{i,j(w,h)}$  انحراف معیار محلی از تصویر وضوح بالا که در پنجره با اندازه  $(w, h)$  و در مختصات پیکسل  $i, j$  محاسبه شده است. همچنین، در این رابطه، مقدار اطلاعات طیفی حفظ شده در تصویر ادغام شده را می‌توان با تنظیم اندازه پنجره  $(w, h)$  کنترل کرد.

4- Panchromatic

5- Local Mean And Variance Matching

6- Principal components algorithm

1- Intensity

2- Speckle

3- Pansharp

$i, j$  در راستای  $\theta$  در فاصله  $d$  می‌باشد. در بردار جابجایی تعریف شده،  $d_x$  تعداد پیکسل‌ها در راستای محور  $x$  و  $d_y$  تعداد پیکسل‌ها در راستای محور  $y$  می‌باشد.

$$GLCM_d^\theta = \frac{1}{R} \begin{bmatrix} \eta(0,0) & \eta(0,1) & \vdots & \eta(0, N_{g-1}) \\ \eta(1,0) & \eta(1,1) & \vdots & \vdots \\ \vdots & \vdots & \eta(i,j) & \vdots \\ \eta(N_{g-1},0) & \vdots & \vdots & \eta(N_{g-1}, N_{g-1}) \end{bmatrix} \quad (2)$$

این ماتریس از ویژگی‌های مکانی (موقعیت پیکسل‌ها نسبت به یکدیگر) و استخراج انواع ویژگی‌های آماری مرتبه دوم براساس پارامترهای فاصله و یا توجیه زاویه‌ای در پردازش پیکسل‌ها استفاده می‌کند. پارامترهای خروجی حاصل از این ماتریس شامل: کتراست، هم‌وزنی، آنتروپی، میانگین، واریانس و کورولیشن بوده که روابط آنها در زیر تشریح شده است.

$$\text{Contrast} = \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} (i-j)^2 p(i,j) \quad (3)$$

$$\text{Homogeneity} = \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} \frac{p(i,j)}{1+(i-j)^2} \quad (4)$$

$$\text{Entropy} = - \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} p(i,j) \log(p(i,j)) \quad (5)$$

$$\text{Mean} = \mu_i = \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} i \times p(i,j) = \mu_i \quad (6)$$

$$= \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} j \times p(i,j) \quad (7)$$

$$\text{Variance} = \sigma_i^2 = \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} (i - \mu_i)^2 \times p(i,j) = \mu_i$$

$$= \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} (j - \mu_j)^2 \times p(i,j) \quad (8)$$

$$\text{Correlation} = \sum_{i=0}^{N_{g-1}} \sum_{j=0}^{N_{g-1}} \frac{(i - \mu_i)(j - \mu_j)p(i,j)}{\sigma_i \sigma_j}$$

برای انجام پیش‌پردازش تصویر سنتینل ۲ ابتدا تصحیح هندسی صورت گرفته تا داده‌ها Georeference شوند. سپس نوبت به تصحیح اتمسفریک می‌رسد که به منظور حذف نفوذ جو در تصویر بازتابندگی از سطح اعمال می‌گردد. این تصحیح با روش Quick Atmospheric Correction انجام شده تا مقدار بخار آب، دی اکسید کربن، ذرات معلق و پخش ناشی از آبروسل‌ها را شناسایی و از بین ببرد. در ادامه، تصحیح رادیومتریک صورت می‌گیرد که این واسنجی به منظور تنظیم مقادیر پیکسل‌های تصویر از نظر تشعشع، بازتابندگی، و یا میزان روشنایی می‌باشد.

## ۲-۳. استخراج ویژگی‌ها

بافت یکی از ویژگی‌های مهم در شناسایی پدیده‌ها یا نواحی مورد نظر در یک تصویر می‌باشد. ویژگی‌های بافتی بر مبنای وابستگی‌های مکانی درجه خاکستری کاربرد مهمی را در طبقه‌بندی تصاویر دارند. توصیف-گرهای بافت براساس روابط بین مقادیر رقمی هر پیکسل از داده و پیکسل‌های اطراف آن در یک پنجره همسایگی به صورت محلی یا در کل تصویر محاسبه می‌شوند. از این رو، می‌توان اطلاعات بافت تولید شده را به عنوان تابعی از تغییرات مکانی درجات خاکستری پیکسل‌های تصویر در نظر گرفت (لو و همکاران، ۲۰۱۴). در این پژوهش، برای آنالیز بافت از ماتریس هم‌رخداد ( $GLCM^1$ ) استفاده شده است. این ماتریس یا ماتریس مربعی با ابعاد  $N_g \times N_g$  است که  $N_g$  تعداد درجات خاکستری موجود در تصویر است. هر درایه این ماتریس بیانگر تعداد زوج پیکسل‌هایی است که در سطح تصویر دارای درجات خاکستری  $i, j$  بوده و در راستای  $\theta$  از یکدیگر به اندازه  $d$  پیکسل فاصله دارند. در رابطه (۲)، تعداد زوج پیکسل‌های ممکن با  $R$  نمایش داده شده است و  $\eta(i,j)$  تعداد زوج پیکسل‌های با درجات خاکستری

<sup>1</sup>- Gray-Level Co-Occurrence Matrix



## ۲-۴. طبقه‌بندی‌ها

که در این رابطه،  $x$  مقدار ورودی،  $y$  مقدار خروجی و  $h_w(x)$  خروجی شبکه عصبی است.

### ۲-۴-۲. ماشین بردار پشتیبان

طبقه‌بندی کننده ماشین بردار پشتیبان (SVM) به عنوان الگوریتمی نظارت شده به تحلیل داده‌ها به منظور طبقه‌بندی و تحلیل رگرسیونی می‌پردازد. این دسته از طبقه‌بندی کننده‌ها علاوه بر دقت بسیار بالا، از عملکرد سریعی نیز بهرمنند می‌باشند که در سال‌های اخیر مورد توجه محققین بسیاری قرار گرفته است. اساس طبقه‌بندی کننده SVM طبقه‌بندی خطی داده‌ها است، به طوری که خط انتخاب شده برای تقسیم داده‌ها از حاشیه اطمینان بالایی برخوردار باشد و داده‌ها را به دو یا چند کلاس متفاوت با حاشیه اطمینان مناسب تقسیم کند و با استفاده از هسته به کار رفته و مرز حداکثری کلاس‌ها، داده‌ها به فضایی با ابعاد بالاتر تبدیل می‌شود (تقفی و همکاران، ۲۰۲۱).

طبق رابطه (۱۱)،  $a_i$  بیانگر متغیرهای ضریب لاگرانژ و  $y$

$$f(x) = \sum_{i=1}^L a_i y_i k(x_i, x_j) + \gamma \quad (11)$$

برای انتقال ابر صفحه با استفاده از مقادیر آستانه و عملکرد هسته بکار می‌رود که به صورت  $k(x_i, x_j)$  تعریف شده است. در این تحقیق از هسته RBF<sup>۲</sup> برای طبقه‌بندی کننده SVM استفاده شده است.

بردار ویژگی با  $x$  و  $\hat{x}$  نشان داده شده است.  $k$  و  $\gamma$  به ترتیب تابع هسته و متغیرهای هسته می‌باشند. برای مقادیردهی به متغیرهای مورد استفاده در این روش، تحقیقات گسترده‌ای صورت پذیرفته و سپس اعداد بهینه جایگذاری شدند.

$$K(x, \hat{x}) = \exp(-\gamma \|x - \hat{x}\|^2) \quad (12)$$

بردار ویژگی با  $x$  و  $\hat{x}$  نشان داده شده است.  $k$  و  $\gamma$  به ترتیب تابع هسته و متغیرهای هسته می‌باشند. برای مقادیردهی به متغیرهای مورد استفاده در این روش،

طبقه‌بندی تصاویر ماهواره‌ای فرآیند پیچیده‌ای است که ممکن است به وسیله بسیاری از عوامل تحت تأثیر قرار گیرد. انتخاب نوع طبقه‌بندی و آگاهی از اینکه برای هر مسئله چه طبقه‌بندی باید استفاده کرد، از چالش‌های پیشروی انتخاب مدل است (هوانگ و همکاران، ۲۰۰۲). پس از انجام تصحیحات تصاویر ماهواره‌ای و استخراج ویژگی‌ها، حال نوبت به شناسایی پیکسل‌های راه از پیکسل‌های غیرراه می‌رسد که توسط سه الگوریتم شبکه عصبی مصنوعی، ماشین بردار پشتیبان و بیشترین احتمال شباهت صورت گرفته است.

### ۲-۴-۱. شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک سیستم محاسباتی جدید برای یادگیری ماشین، نمایش دانش و در نهایت کسب دانش کاربردی برای به حداکثر رساندن پاسخ خروجی سیستم‌های پیچیده است. یکی از عناصر حیاتی این ایده، ایجاد ساختارهای جدید برای سیستم پردازش اطلاعات است. این رویکرد شامل تعداد زیادی از عناصر پردازشی بسیار به هم پیوسته به نام نورون‌ها است که برای حل مسئله و انتقال اطلاعات از طریق سیناپس‌ها با یکدیگر کار می‌کنند. یادگیری در این سیستم‌ها تطبیقی است. به این معنی که با استفاده از مثال‌ها، وزن سیناپس‌ها به گونه‌ای تغییر می‌کند که سیستم جدید پاسخ صحیح ایجاد می‌کند. یکی از متداول‌ترین روش‌های حل مسئله بهینه‌سازی، شبکه‌های عصبی پس‌انتشار<sup>۱</sup> است (تقفی و همکاران، ۲۰۲۱).

$$a_c = \sum_p w_{pc} \times b_{pc} \quad (9)$$

در رابطه (۹)  $a_c$  جمع ضرب ورودی‌ها بر اساس وزن آنها،  $w_{pc}$  وزن این ورودی و  $b_{pc}$  حاوی مقدار نورون‌های  $c$  است که از نورون‌های  $P$  ورودی می‌گیرد. اگر داده‌ها با  $(x_1, y_1), \dots, (x_n, y_n)$  نشان داده شده باشند و تابع هزینه با  $l$ ، هدف دستیابی به عملکرد زیر است:

$$Q(W) = \sum_{i=1}^n t(h_w(x_i), y_i) \quad (10)$$

<sup>2</sup> - Radial Basis Function

<sup>1</sup> - Back Propagation

تحقیقات گسترده‌ای صورت پذیرفته و سپس اعداد بهینه جایگذاری شدند.

## ۲-۴-۳. بیشترین احتمال شباهت

روش بیشترین شباهت نیز یکی از کاراترین روش‌های طبقه‌بندی تصاویر می‌باشد. در اکثر تحقیقات و مطالعات، این روش به عنوان دقیق‌ترین روش طبقه‌بندی معرفی شده است. در این روش، که از سایر روش‌های موجود برای طبقه‌بندی دقیق‌تر است، میزان کمی واریانس و همبستگی ارزش‌های طیفی باندهای مختلف برای مناطق نمونه محاسبه می‌شود (سان و همکاران، ۲۰۱۳). طبقه‌بندی حداکثر احتمال فرض می‌کند که آمار مربوط به هر کلاس در هر باند به طور معمول توزیع شده و احتمال تعلق یک پیکسل معین به یک کلاس خاص را محاسبه می‌کند. تا زمانی که آستانه احتمال را انتخاب نکنید، همه پیکسل‌ها طبقه‌بندی می‌شوند. هر پیکسل به کلاسی اختصاص می‌یابد که بیشترین احتمال را دارد (یعنی حداکثر احتمال). اگر بیشترین احتمال از آستانه تعیین شده شما کوچکتر باشد، پیکسل طبقه‌بندی نشده باقی می‌ماند. طبقه‌بندی حداکثر شباهت با محاسبه توابع متمایز برای هر پیکسل در تصویر را در رابطه (۱۳) پیاده سازی می‌کند (سان و همکاران، ۲۰۱۳):

$$g_i(x) = \ln p(\omega_i) - \frac{1}{2} \ln \left| \sum_i \right| - \frac{1}{2} (x - m_i)^T \sum_i^{-1} (x - m_i) \quad (13)$$

که در رابطه بالا  $i$  کلاس،  $x$  داده  $n$  بعدی ( $n$  تعداد باندها می‌باشد)،  $p(\omega_i)$  احتمال اینکه کلاس  $\omega_i$  در تصویر رخ دهد و برای همه کلاس‌ها یکسان فرض شود،  $|\sum_i|$  تعیین کننده ماتریس کوواریانس داده‌ها در کلاس  $\omega_i$ ،  $\sum_i^{-1}$  ماتریس معکوس و  $m_i$  بردار میانگین فرض شده است.

که در رابطه بالا  $i$  کلاس،  $x$  داده  $n$  بعدی ( $n$  تعداد باندها می‌باشد)،  $p(\omega_i)$  احتمال اینکه کلاس  $\omega_i$  در تصویر رخ دهد و برای همه کلاس‌ها یکسان فرض شود،  $|\sum_i|$  تعیین کننده ماتریس کوواریانس داده‌ها در کلاس  $\omega_i$ ،  $\sum_i^{-1}$  ماتریس معکوس و  $m_i$  بردار میانگین فرض شده است.

## ۲-۵. ادغام داده‌ها

هدف اصلی ادغام تصاویر، ترکیب داده‌های متمایز و مکمل برای افزایش اطلاعات ظاهری در تصاویر و نیز افزایش قابلیت اطمینان تفسیر است که منجر به ایجاد عملکرد عملیاتی قوی، افزایش اعتماد و کاهش ابهام می‌شود (مانی، ۲۰۲۰). به طور کلی، فرآیند ادغام داده‌ها بسیار ساده‌تر و اقتصادی‌تر از طراحی و ساخت یک سنسور پیشرفته‌ای است که در آن قدرت تفکیک مکانی و طیفی به صورت توأم منظور شده باشد (رومر و همکاران، ۲۰۱۲). یکی از مهم‌ترین و پرکاربردترین روش‌ها در ادغام، روشی مبتنی بر مفهوم رأی‌گیری است که استفاده از این روش در مقایسه با نتیجه یک تصمیم فردی، دارای نتایج دقیق‌تر و قابل اعتمادتری است. ساده‌ترین شکل این روش، الگوریتم رأی‌گیری حداکثری<sup>۱</sup> است (کونچوا و همکاران، ۲۰۰۳). در این روش، اگر تمام نتایج از وزن و دقت یکسانی برخوردار باشند و وزن تمام طبقه‌بندی‌کنندگان برابر باشد، کلاس نهایی با بیشترین رأی به عنوان کلاس منتخب معرفی خواهد شد که در رابطه (۱۴) نشان داده شده است (روتا و گابریاس، ۲۰۰۰).

$$\sum_{i=1}^L d_{i,k} = \max_{j=1}^L d_{i,j} \quad (14)$$

که در این رابطه،  $d_i$  به ازای  $i = 1, 2, \dots, m$  (که در آن  $m$  تعداد مجموعه روش‌های تصمیم‌گیری است) و  $j = 1, 2, \dots, c$  (که در آن  $c$  تعداد کلاس‌های موجود بوده) و بردار  $c$  بعدی  $\{d_{i1}, d_{i2}, \dots, d_{in}\}$  برای هر طبقه‌بندی‌کننده

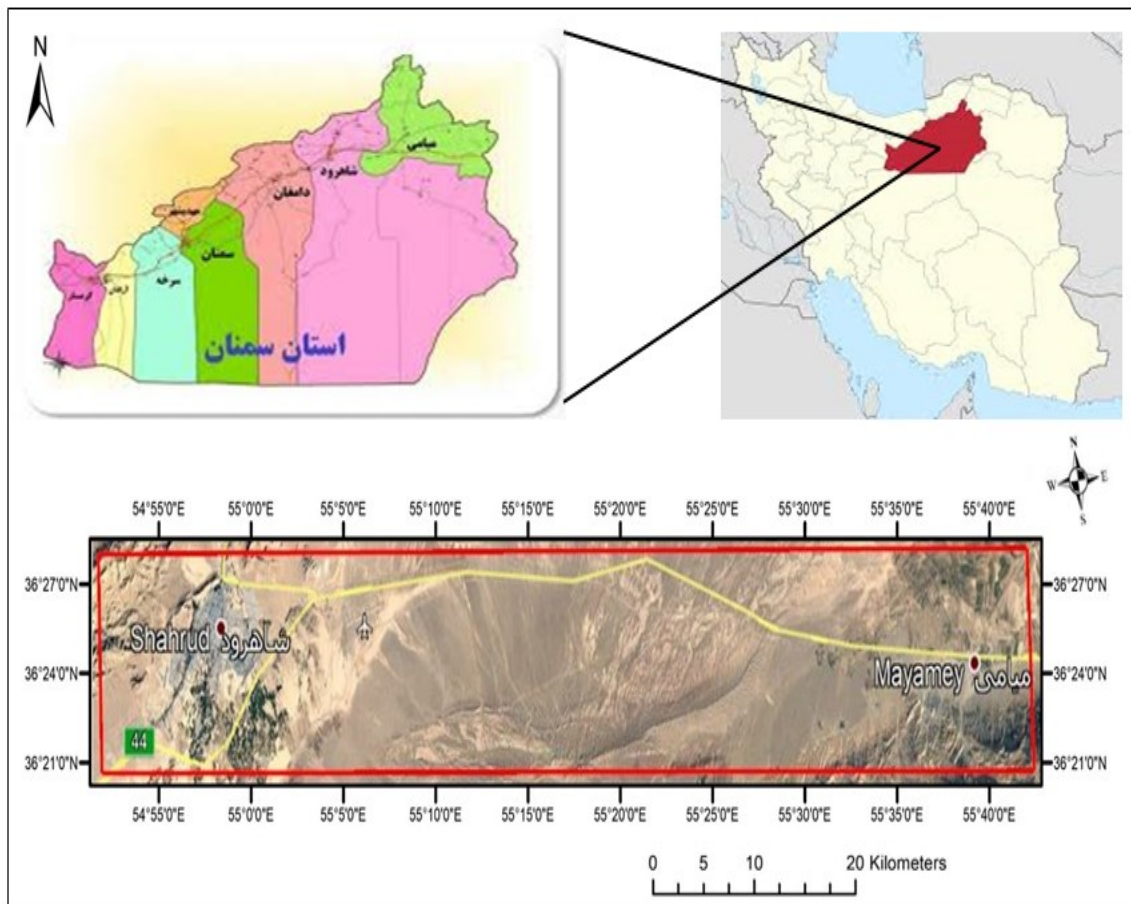
### ۳. منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، حدود ۷۰ کیلومتر از مسیر شاهرود - میامی را شامل می‌شود که در بخش شرق و شمال شرقی استان سمنان قرار گرفته و دارای مختصات ۵۴ درجه و ۵۲ دقیقه تا ۵۵ درجه و ۴۲ دقیقه طول شرقی از نصف النهار گرینویچ و ۳۶ درجه و ۲۱ دقیقه تا ۳۶ درجه و ۲۷ دقیقه عرض جغرافیایی شمالی می‌باشد. ابعاد منطقه مورد مطالعه ۷۴۲۸×۱۰۲۴ پیکسل و ۷۶۰,۶۲۷,۲۰۰ متر مربع می‌باشد. شکل ۲، موقعیت جغرافیایی منطقه و شکل ۳، تصویر دو ماهواره سنتینل ۱ و سنتینل ۲ در این منطقه را نشان می‌دهند.


می‌تواند به کار رود. وقتی که طبقه‌بندی‌کننده‌ها وزن‌های متفاوتی دارند، یک مدل خاص از این روش که رأی‌گیری حداکثر وزن‌دار نامیده می‌شود، مورد استفاده قرار می‌گیرد. به این ترتیب، نقش طبقه‌بندی‌کننده‌های دقیق‌تر در رأی‌گیری افزایش یافته و به آن‌ها وزن بیشتری داده می‌شود. در حالی که طبقه‌بندی‌کننده‌های با دقت کمتر در رأی‌گیری وزن کمتری دریافت می‌کنند.

$$g_i(x) = \sum_{j=1}^M d_{i,j} \times W_j \quad (15)$$


که،  $W_j$  وزن هر طبقه‌بندی‌کننده است و می‌تواند با استفاده از ارزیابی دقت کلی تعیین شود.



شکل ۲. موقعیت جغرافیایی منطقه مورد مطالعه



(الف)



(ب)

شکل ۳. تصاویر ماهواره‌ای منطقه مورد مطالعه: (الف) ماهواره سنتینل ۱ و (ب) ماهواره سنتینل ۲

پیکسل‌ها طبق رابطه (۱۶) به دست می‌آید. دقت کلی طبقه‌بندی بیانگر میزان اعتبار طبقه‌بندی انجام شده می‌باشد.

$$OA = \frac{1}{N} \sum P_{ii} \quad (16)$$

در این رابطه،  $OA$  دقت کلی،  $N$  تعداد پیکسل‌های آزمایشی و  $\sum P_{ii}$  جمع عناصر قطر اصلی ماتریس خطا می‌باشد. به دلیل ایرادات وارده بر دقت کلی، غالباً در کارهای اجرایی که مقایسه دقت طبقه‌بندی مورد توجه است، از شاخص کاپا استفاده می‌شود. چون شاخص کاپا پیکسل‌های نادرست طبقه‌بندی شده را مد نظر قرار می‌دهد. ضریب کاپا، تکنیک چند متغیره گسسته‌ای است به این صورت که اگر یک ماتریس خطا تفاوت معناداری با

۳-۱. معیارهای ارزیابی دقت و صحت طبقه‌بندی یکی از متداول‌ترین روش‌های ارزیابی دقت طبقه‌بندی، آماده کردن ماتریس خطای<sup>۱</sup> طبقه‌بندی است. در این روش، فایل نمونه‌برداری که متشکل از ارزش‌های تمامی پیکسل‌های کلاس‌های تعریف شده است، با تصویر طبقه‌بندی شده حاصل از همان فایل تلافی داده می‌شود. در این صورت تک تک پیکسل‌های نمونه‌برداری شده با کلاس‌های طبقه‌بندی شده تلافی می‌یابد و در نتیجه امکان بررسی صحت طبقه‌بندی پیکسل‌ها فراهم می‌گردد. پس از تولید ماتریس خطا، سایر عناصر مهم ارزیابی صحت از جمله دقت کلی<sup>۲</sup> و ضریب کاپا<sup>۳</sup> را می‌توان به دست آورد (شاتیر و بربرأغلو، ۲۰۱۲). دقت کلی از جمع عناصر قطر اصلی ماتریس خطا تقسیم بر تعداد کل

<sup>3</sup>- Kappa Coefficient

<sup>1</sup>- Error Matrix

<sup>2</sup>- Overall Accuracy

در ادامه، هر Data set به دست آمده از مرحله قبل توسط طبقه‌بندی‌کننده‌های نظارت شده ANN، SVM و ML طبقه‌بندی می‌شوند. در رویکرد فیوژن نیز سه تصویر خروجی طبقه‌بندی شده در یک تصویر ادغام شده‌اند، که ادغام نتایج با شیوه رأی‌گیری حداکثری صورت گرفته است.

در این مطالعه، با تولید کمی بافت‌های مختلف از ماتریس هم‌رخداد در پنجره‌هایی با ابعاد  $5 \times 5$  ویژگی‌های مختلف استخراج شدند. توصیفگرهای ماتریس هم‌رخداد در چهار جهت اصلی  $\theta = 0$ ،  $\theta = 45$ ،  $\theta = 90$  و  $\theta = 135$  تولید شده و سطوح کمیت  $\theta = 32$  برای آن در نظر گرفته شد. خروجی حاصل از ماتریس GLCM برای داده ۱۰ متری سنتینل ۲ در شکل ۴ نشان داده شده است.


دیگری داشته باشد، در ارزیابی صحت برای تصمیم‌گیری آماری مورد استفاده قرار می‌گیرد که بر اساس رابطه (۱۷) تعریف می‌شود (لیونز و همکاران، ۲۰۱۸).

$$Kappa = \frac{P_0 - P_c}{1 - P_c} \quad (17)$$

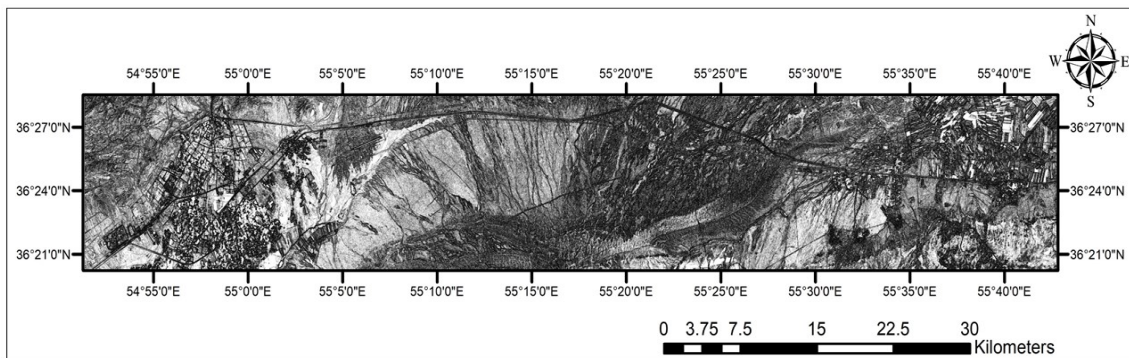
که،  $P_0$  درستی مشاهده شده و  $P_c$  توافق مورد انتظار می‌باشد.

#### ۴. نتایج

با استفاده از دو رویکرد ترکیب و فیوژن داده‌ها، پیکسل‌های راه با دقت بسیار بالایی از دیگر عوارض سطح زمین شناسایی شدند. رویکرد ترکیب داده‌ها، شامل دو Data set از تصاویر ۱۰ متری سنتینل ۱ و سنتینل ۲ به همراه پارامترهای آماری ماتریس GLCM در یک لایه می‌باشد.




Contrast




Homogeneity

#### 1- Quantization Levels


استخراج اتوماتیک شبکه راه براساس ادغام تصاویر ماهواره‌ای سنتینل ۱ و سنتینل ۲ با ویژگی‌های آنالیز...




Entropy



GLCM-Mean



GLCM-Variance




GLCM-Correlation


شکل ۴. نتایج ماتریس هم‌رخداد برای ماهواره سنتینل ۲

SVM و ML در دو کلاس کلی راه و غیرراه و همچنین رویکرد ادغام دوم (MV) برای تصاویر سنتینل ۱ و سنتینل ۲ به ترتیب در شکل‌های ۵ و ۶ به دست آمده است.


پس از اعمال ترکیب داده‌های ماهواره‌ای (باندهای اپتیک و داده راداری) با ویژگی‌های آماری در رویکرد اول به صورت تک لایه، حال نوبت به انجام طبقه‌بندی می‌رسد. نتایج حاصل از سه طبقه‌بند نظارت شده ANN،



NN




SVM




ML

استخراج اتوماتیک شبکه راه براساس ادغام تصاویر ماهواره‌ای سنتینل ۱ و سنتینل ۲ با ویژگی‌های آنالیز...




MV

شکل ۵. نتایج خروجی حاصل از داده سنتینل ۱

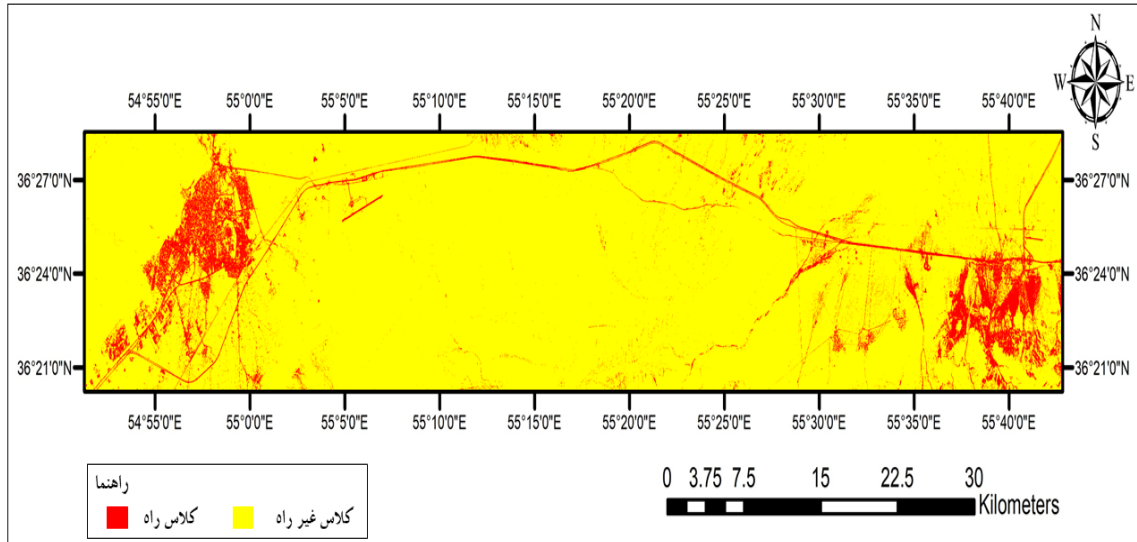


NN

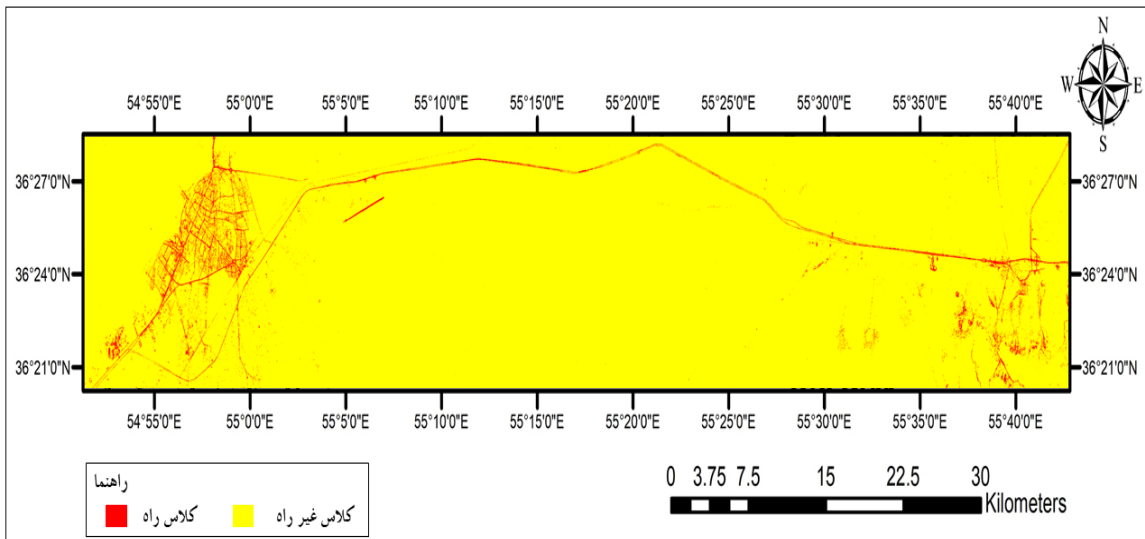


SVM





ML



MV

شکل ۶. نتایج خروجی حاصل از داده سنتینل ۲

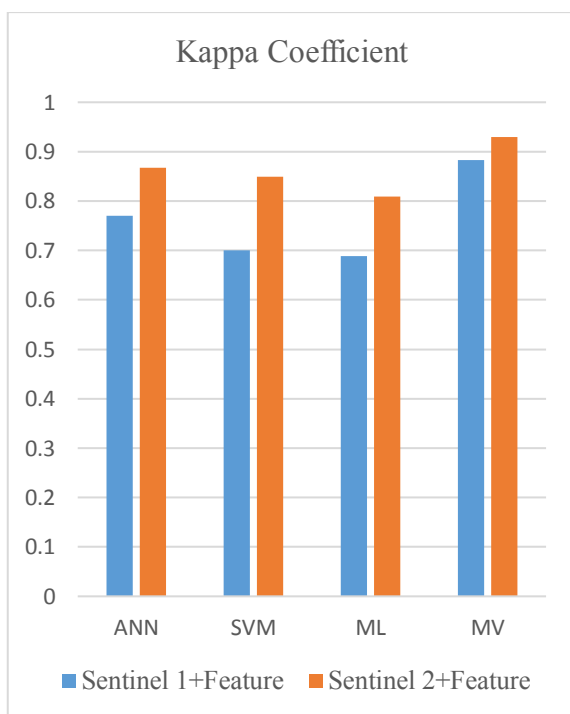
سنتینل ۱ نیز بر همین موضوع تأکید دارد. نکته دیگری که باید به آن اشاره کرد اینست که روش ANN توانسته از میان سایر الگوریتم‌ها در هر دو ماهواره از دقت بیشتری برخوردار باشد که این موضوع دال بر عملکرد بهتر شبکه عصبی مصنوعی نسبت به سایر الگوریتم‌ها می‌باشد. با توجه به شکل‌های ۵ و ۶ و مقایسه دو الگوریتم SVM با ML می‌توان دریافت که با وجود اینکه SVM در هر

نتایج به دست آمده در جدول ۳ نشان می‌دهد که سه طبقه‌بندی نظارت شده ANN، SVM و ML برای ماهواره سنتینل ۲ به ترتیب از دقت ۹۰/۲، ۸۶/۶ و ۸۴/۴ درصد برخوردار بوده و برای ماهواره سنتینل ۱ نیز به ترتیب دارای دقت ۸۴/۷، ۸۱/۳ و ۷۹/۹ درصد بوده است. این نتایج نشان‌دهنده برتری ماهواره سنتینل ۲ نسبت به سنتینل ۱ در استخراج پیکسل‌های راه می‌باشد. همچنین، ضرایب کاپا به دست آمده از ماهواره سنتینل ۲ نسبت به


دو ماهواره سنتینل ۱ و سنتینل ۲ دارای دقت بیشتری می‌باشد اما در برخی مناطق برای استخراج عارضه راه به مشکل خورده است. الگوریتم ML نیز یک سری نواحی غیرراه را به اشتباه عارضه راه معرفی کرده که این نشان-دهنده ضعف الگوریتم ML در این پژوهش بوده است.

جدول ۳. نتایج شیوه‌های ادغام داده‌های راداری و اپتیکی

طبقه‌بندها / داده‌ها	ANN	SVM	ML	MV	
سنتینل ۱+ ویژگی‌ها	دقت کلی	84.7607%	81.3419%	79.9145%	<b>88.4615%</b>
	ضریب کاپا	0.7698	0.7108	0.6889	<b>0.8832</b>
سنتینل ۲+ ویژگی‌ها	دقت کلی	90.2169%	86.6068%	84.4701%	<b>95.7938%</b>
	ضریب کاپا	0.8675	0.8494	0.8194	<b>0.9297</b>



(ب)



(الف)

شکل ۷. دقت کلی و ضریب کاپا حاصل از ادغام و تلفیق داده‌ها: (الف) دقت کلی و (ب) ضریب کاپا

بوده است. همانگونه که در جدول ۳ و شکل ۷ قابل مشاهده است، نتایج خروجی دقت کلی برای رویکرد رأی‌گیری حداکثری (MV) نسبت به روش شبکه عصبی مصنوعی، در ماهواره سنتینل ۲ حدود ۶٪ بهبود پیدا کرده

با استفاده از رویکرد ادغام و تلفیق سه خروجی حاصل از طبقه‌بندی‌کننده‌ها با روش رأی‌گیری حداکثری، تصویری منحصر به فرد به دست آمد که میزان شناسایی پیکسل‌های شبکه راه با استفاده از این شیوه بسیار دقیق‌تر

ضعیف عمل کرده، اما عملکرد شناسایی آن در سنتینل ۲ قابل قبول بوده است.

- از مقایسه دو روش SVM و ML می‌توان نتیجه گرفت که SVM در هر دو ماهواره سنتینل ۱ و سنتینل ۲ با اختلاف کمی دارای دقت و ضریب کاپا بیشتری نسبت به ML می‌باشد. اما این الگوریتم در سنتینل ۲ نسبت به سنتینل ۱ در شناسایی مناطق شهر میامی برای استخراج عارضه راه ضعیف‌تر عمل کرده است.

- الگوریتم ML نیز یک سری نواحی غیرراه را هم در شهر شاهرود و هم در شهر میامی به اشتباه عارضه راه معرفی کرده است که پیش‌بینی می‌شود این الگوریتم پیکسل‌های مشابه با راه (غیرراه) را به اشتباه در کلاس راه طبقه‌بندی کرده باشد.

- از مقایسه رویکرد MV در سنتینل ۱ و سنتینل ۲ نیز می‌توان نتیجه گرفت که نقشه نهایی شبکه راه به‌دست آمده از سنتینل ۲ دارای مسیرهای کامل‌تر و بیشتری می‌باشد. همچنین، خاطر نشان می‌شود که نقشه نهایی MV در سنتینل ۱ همچنان در شناسایی برخی مسیرهای شهر میامی دچار ضعف بوده که ناشی از عملکرد نامناسب الگوریتم‌های طبقه‌بندی است.

- به عنوان پیشنهاد در مطالعات آینده، همانند مطالعه ژانگ و همکاران (۲۰۱۹)، از شبکه عصبی عمیق در کنار سایر طبقه‌بندی‌ها بهره گرفته و تأثیر آن بر رویکرد حداکثر رأی‌گیری مشاهده شود. همچنین، برای بهبود الگوریتم ML یک حد آستانه تعیین شود تا از شناسایی پیکسل‌های مشابه راه جلوگیری گردد. به طور کلی، همان‌طور که در این مطالعه انتظار می‌رفت، به دلیل تلفیق پیکسل به پیکسل نتایج خروجی با وزن‌دهی برابر، پیکسل‌هایی که بیشترین تکرار را در بین هر سه خروجی داشتند به عنوان پیکسل منتخب انتخاب شدند. به همین علت، نتایج تلفیق داده‌های خروجی شبکه راه شناسایی شده در ماهواره‌های سنتینل ۱ و سنتینل ۲، دقت

است. رأی‌گیری حداکثری با دقت کلی ۹۵/۷۹ درصد و ضریب کاپا ۰/۹۲۹۷ برای ماهواره سنتینل ۲ نشان داد که تلفیق داده‌های خروجی به روش MV موجب بهبود شناسایی پیکسل‌های راه می‌شود. همچنین، برای ماهواره سنتینل ۱، رویکرد رأی‌گیری حداکثری با دقت کلی ۸۸/۶۶ درصد و ضریب کاپا ۰/۸۸۳۲، نسبت به روش شبکه عصبی مصنوعی از برتری ۴٪ برخوردار بوده است. با تحلیل کمی ضریب کاپا در روش حداکثر رأی‌گیری نسبت به ANN برای ماهواره سنتینل ۱ حدود ۰/۱۱ و برای ماهواره سنتینل ۲ حدود ۰/۰۶ رشد داشته است.

از مقایسه این پژوهش با مطالعات مشابه گذشته مانند ژانگ و همکاران (۲۰۱۹) نیز می‌توان دریافت که ژانگ و همکاران با استفاده از تک‌تصویر ماهواره‌ای و بهره‌گیری از یک شبکه عصبی عمیق (DNN) برای شناسایی راه به دقت ۹۵/۱۷ درصد دست یافتند که دقت بسیار زیادی می‌باشد. این پژوهش، با استفاده از رویکرد ادغام سه تصویر با روش MV و استفاده از ویژگی‌های بافت برای سنتینل ۲ به دقت ۹۵/۷۹ درصد دست یافت که میزان قابل قبول و زیادی است.

## ۵. نتیجه‌گیری

یکی از روش‌های پرکاربرد، روش ادغام تصاویر ماهواره-ای یا فیوژن می‌باشد که با توجه به پتانسیل بالایی که در عملکرد نتایج دارد، در کاربردهای متنوعی مانند استخراج عوارض شهری و غیرشهری مورد استفاده قرار می‌گیرد. از اهم نتایج و مطالعات صورت گرفته در این پژوهش می‌توان به موارد زیر اشاره کرد:

- روش ANN در شناسایی شبکه راه در هر دو ماهواره سنتینل ۱ و سنتینل ۲ نسبت به سایر الگوریتم‌ها نتایج بهتری را هم در پارامتر دقت کلی و هم در پارامتر ضریب کاپا کسب کرد. با این وجود، این روش در شناسایی برخی جاده‌های شهر میامی در سنتینل ۱

بیشتری نسبت به نتایج حاصل از طبقه‌بندی کننده‌ها دارا می‌باشند. در این پژوهش، تلاش شد تا با استفاده از دو رویکرد ترکیب داده‌ها با ویژگی‌های بافت و ادغام نتایج حاصل از طبقه‌بندی‌ها با روش حداکثر رأی‌گیری، تصویر نهایی شبکه راه‌ها با دقت بسیار زیادی از دیگر عوارض سطح زمین استخراج شود.

## ۶. مراجع

جوادیان، ر. و جعفرپور، ا. ۱۳۸۸. "استفاده از روش‌های تصادفی جهت مدیریت روسازی در سطح شبکه". اولین کنفرانس ملی مهندسی و مدیریت زیرساخت‌ها، تهران.

- Abdelfattah, R. and Chokmani, K. 2017. "A semi automatic off-roads and trails extraction method from Sentinel-1 data". International Geoscience and Remote Sensing Symposium (IGARSS), July, pp. 3728–3731. <https://doi.org/10.1109/IGARSS.2017.8127809>
- Bakhtiari, H. R., Abdollahi, A. and Rezaeian, H. 2017. "Semi automatic road extraction from digital images". Egypt. J. Remote Sens. Sp. Sci., 20(1): 117-123. <https://doi.org/10.1016/j.ejrs.2017.03.001>
- European Space Agency. 2020. "Sentinel Online- ESA". Earth Online. <https://sentinel.esa.int/web/sentinel>
- Gao, X., Sun, X., Zhang, Y., Yan, M., Xu, G., Sun, H., Jiao, J. and Fu, K. 2018. "An end-to-end neural network for road extraction from remote sensing imagery by multiple feature pyramid network". IEEE Access, 6: 39401-39414. <https://doi.org/10.1109/ACCESS.2018.2856088>
- Huang, C., Davis, L. S. and Townshend, J. R. G. 2002. "An assessment of support vector machines for land cover classification". Int. J. Remote Sens., 23: 725-749.
- Karathanassi, V., Kolokousis, P. and Ioannidou, S. 2007. "A comparison study on fusion methods using evaluation indicators". Int. J. Remote Sens., 28(10): 2309-2341. <https://doi.org/10.1080/01431160600606890>
- Kuncheva, L. I., Whitaker, C. J., Shipp, C. A. and Duin, R. P. W. 2003. "Limits on the majority vote accuracy in classifier fusion". Pattern Anal. Appl., 6(1): 22-31.
- Lazecky, M., Comut, C., Qin, Y. and Perissin, D. 2017. "Sentinel-1 interferometry system in the high-performance computing environment". PP. 131-139. In: The Rise of Big Spatial Data, Springer.
- Lu, D., Li, G., Moran, E., Dutra, L. and Batistella, M. 2014. "The roles of textural images in improving land-cover classification in the Brazilian Amazon". Int. J. Remote Sens., 35(24): 8188-8207. <https://doi.org/10.1080/01431161.2014.980920>
- Lyons, M. B., Keith, D. A., Phinn, S. R., Mason, T. J. and Elith, J. 2018. "A comparison of resampling methods for remote sensing classification and accuracy assessment". Remote Sens. Environ., 208: 145-153. <https://doi.org/10.1016/j.rse.2018.02.026>
- Mani, V. R. S. 2020. "A survey of multi sensor satellite image fusion techniques". Int. J. Sens. Sens. Netw., 8(1): 1-10. <https://doi.org/10.11648/J.IJSSN.20200801.11>
- Mhangara, P., Mapurisa, W. and Mudau, N. 2020. "Comparison of image fusion techniques using Satellite pour l'Observation de la terre (SPOT) 6 satellite imagery". Appl. Sci., 10(5): 1881. <https://doi.org/10.3390/app10051881>
- Miao, Z., Shi, W., Zhang, H. and Wang, X. 2013. "Road centerline extraction from high-resolution imagery based on shape features and multivariate adaptive regression splines". IEEE Geosci. Remote Sens. Lett., 10(3): 583-587. <https://doi.org/10.1109/LGRS.2012.2214761>
- Römer, H., Willroth, P., Kaiser, G., Vafeidis, A. T., Ludwig, R., Sterr, H. and Revilla Diez, J. 2012. "Potential of remote sensing techniques for tsunami hazard and vulnerability analysis—a case study from Phangnga province, Thailand". Nat. Hazard Earth Sys. Sci., 12(6): 2103-2126.
- Ruta, D. and Gabrys, B. 2000. "An overview of classifier fusion methods". Comp. Inform. Sys., 7(1): 1-10.
- Schölkopf, B. and Smola, A. 2005. "Support vector machines and kernel algorithms". Encyclopedia of Biostatistics, Wiley, pp. 5328-5335.
- Saghafi, M., Ahmadi, A. and Bigdeli, B. 2021. "Sentinel-1 and Sentinel-2 data fusion system for surface water extraction". J. Appl. Remote Sens., 15(1): 014521. <https://doi.org/10.1117/1.jrs.15.014521>
- Şatır, O. and Berberoğlu, S. 2012. "Land use/cover classification techniques using optical remotely sensed data in landscape planning". Landscape Planning, InTech, Shanghai, China, pp. 21-55.
- Shi, W., Miao, Z., Wang, Q. and Zhang, H. 2014. "Spectral-spatial classification and shape features for urban road centerline extraction". IEEE Geosci. Remote Sens. Lett., 11(4): 788-792.

- Sun, J., Yang, J., Zhang, C., Yun, W. and Qu, J. 2013. "Automatic remotely sensed image classification in a grid environment based on the maximum likelihood method". *Math. Comp. Modell.*, 58(3-4): 573-581. <https://doi.org/10.1016/j.mcm.2011.10.063>
- Wang, Z., Ziou, D., Armenakis, C., Li, D. and Li, Q. 2005. "A comparative analysis of image fusion methods". *IEEE Trans. Geosci. Remote Sens.*, 43(6): 1391-1402.
- Wang, J. L., Qian, J. H. and Ma, R. B. 2013. "Urban road information extraction from high resolution remotely sensed image based on semantic model". In: 21<sup>th</sup> International Conference on Geoinformatics, Shanghai. <https://doi.org/10.1109/Geoinformatics.2013.6626045>
- Wang, J., Qin, Q., Yang, X., Wang, J., Ye, X. and Qin, X. 2014. "Automated road extraction from multi-resolution images using spectral information and texture". *International Geoscience and Remote Sensing Symposium (IGARSS)*, pp. 533-536. <https://doi.org/10.1109/IGARSS.2014.6946477>.
- Zhang, Q., Kong, Q., Zhang, C., You, S., Wei, H., Sun, R. and Li, L. 2019. "A new road extraction method using Sentinel-1 SAR images based on the deep fully convolutional neural network". *Eur. J. Remote Sens.*, 52(1): 572-582. <https://doi.org/10.1080/22797254.2019.1694447>

