

## Original Article



Iranian Remote Sensing GIS  
Journal of Sensing

## Analysis of Methods, Challenges, and Perspectives in Rural Road Networks Detection with a Focus on Remote Sensing Images

Ali Javadi Moghadam and Abbas Kiani\*

### Affiliation

\*Department of Geomatics,  
Faculty of Civil  
Engineering, Babol  
Noshirvani University of  
Technology, Babol, Iran

### ABSTRACT

**Background and Objective:** By advancement of remote sensing and deep learning technologies, the automatic identification of road networks, especially in rural and secondary roads, has become feasible. Moreover, traditional mapping methods, due to their high cost and time-consuming nature, have been increasingly replaced by approaches based on remote sensing data and machine learning. Preparing a map of the road network involves various methods, and one cost-effective approach is automatic road detection using remote sensing images. Research shows that deep learning-based methods can provide more reliable accuracies than conventional ones. For the rural road network, satellite images with medium spatial resolution and free access cannot achieve high accuracy; thus, image fusion can be applied to enhance spatial resolution and improve detection algorithms. One fusion method is super-resolution. This study serves as a reference for comparing and selecting automatic road detection methods and improving the spatial resolution of remote sensing images to identify narrow roads (e.g., rural networks), enabling researchers to choose appropriate data and algorithms based on their objectives.

**Materials and Methods:** This research aims to investigate the existing methods for road network detection and the utilization of satellite images with medium spatial resolution for this purpose. Initially, the data and methods applicable for generating a road network map were examined. Subsequently, the principles used in the field of road network detection using remote sensing images were described, and based on these principles, classification methods, segmentation, road index, and machine learning were implemented. Methods for improving the spatial resolution of satellite images were also investigated for employing satellite images with medium spatial resolution. Finally, the methods were reviewed in terms of input parameters, mechanism, and output, to identify their strengths and weaknesses and to utilize them optimally for various applications.

**Discussion and Analysis:** According to the reviews of the examined articles from various authentic journals in the field of road network detection, classification, segmentation, road index, and machine learning methods account for approximately 28%, 31%, 5%, and 36% shares, respectively. In recent years, classification and segmentation methods based on neural networks have been developed, encompassing a larger share (about 60%) of machine learning methods in general. Additionally, in super-resolution, investigations show that methods based on traditional techniques and deep learning account for approximately 44% and 56% shares, respectively, and most recently, deep learning-based approaches are under development.

**Conclusion:** The investigations show that using deep learning models in road network detection provides better results than traditional methods and gradually replaces these methods. Deep learning models with the ability to extract complex features and reduce the need for human intervention have improved the accuracy and efficiency of the detection process. On the other hand, super-resolution techniques based on deep learning can solve problems arising from the lack of high-resolution images by increasing the spatial resolution of images. By preserving spectral features and reducing noise, these techniques can provide higher-quality images for road detection. One of the main challenges in road detection from satellite images is the presence of vegetation cover and shadows, which can lead to incomplete and inconsistent detection of roads. To improve this problem, techniques such as tensor voting have been proposed, which can complete and correct roads that have been incompletely detected. Overall, combining super-resolution and deep learning methods for identifying road networks provides a cost-effective and efficient approach to updating road maps. These approaches, by reducing the costs and time required for detection, can be widely used by researchers and professionals in various fields. Furthermore, with further development and improvement of these techniques, new solutions can be developed for road construction, maintenance, and planning.

**Keywords:** Medium spatial resolution satellite images, Artificial intelligence, Road network, Remote sensing, Super-resolution.

### Citation:

Javadi Moghadam, A., Kiani, A., Analysis of Methods, Challenges, and Perspectives in Rural Road Networks Detection with a Focus on Remote Sensing Images, Iran J Remote Sens GIS. 17(3): 139-176.





# تحلیل روش‌ها، چالش‌ها و دیدگاه‌هایی در زمینه شناسایی شبکه راه‌های روستایی با محوریت استفاده از تصاویر سنجش از دوری

علی جوادی مقدم و عباس کیانی\*

## سمت

\*گروه مهندسی نقشه‌برداری، دانشکده عمران، دانشگاه صنعتی نوشیروانی بابل، بابل، ایران

## چکیده

**سابقه و هدف:** با پیشرفت فناوری‌های سنجش از دوری و یادگیری عمیق، شناسایی خودکار شبکه راه‌ها، به‌ویژه راه‌های روستایی و فرعی، امکان‌پذیر شده است. همچنین روش‌های سنتی نقشه‌برداری، به دلیل هزینه‌بر و زمان‌بر بودن، جای خود را به روش‌های مبتنی بر داده‌های سنجش از دوری و یادگیری ماشین داده‌اند. تهیه نقشه از شبکه راه‌ها روش‌های متفاوتی دارد و یکی از روش‌های مقرون به صرفه، شناسایی خودکار از طریق تصاویر سنجش از دوری است. بنابر نوع مسیر مورد مطالعه که شبکه راه‌های روستایی است، تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط و دسترسی رایگان را نمی‌توان گزینه‌ای برای دستیابی به دقت‌های بالا در نظر گرفت؛ از این رو می‌توان از روش‌های تلفیق تصاویر ماهواره‌ای استفاده کرد که حد تفکیک مکانی را بهبود می‌بخشند، به کار برد. یکی از راه‌های تلفیق تصاویر ماهواره‌ای، الگوریتم‌های سوپرزولوشن است. این مطالعه می‌تواند مرجعی برای مقایسه و انتخاب روشی در شناسایی شبکه راه‌ها به صورت خودکار و همچنین شیوه‌های به‌منظور بهبود حد تفکیک مکانی تصاویر سنجش از دوری، برای کمک به شناسایی راه‌های کم‌عرض (مانند شبکه راه‌های روستایی) باشد تا محققان، با توجه به هدف و نوع شبکه راه مورد مطالعه، داده‌ها و الگوریتم مناسب را برگزینند.

**مواد و روش‌ها:** هدف این پژوهش بررسی روش‌های رایج تشخیص شبکه راه‌ها و چگونگی استفاده از تصاویر ماهواره‌ای، با حد تفکیک مکانی متوسط، برای این کار است. ابتدا داده‌ها و روش‌های کاربردی، برای تولید نقشه شبکه راه، بررسی شد. در ادامه، اصول به‌کاررفته در حوزه تشخیص شبکه راه‌ها، با استفاده از تصاویر سنجش از دوری تشریح شد و روش‌ها در چهار دسته کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین تقسیم شدند. همچنین روش‌های بهبود حد تفکیک مکانی بررسی شدند. در نهایت روش‌ها از نظر پارامترهای ورودی، نحوه سازوکار و خروجی قابل ارائه بررسی شده‌اند تا نقاط قوت و ضعف هر یک شناسایی شود و بتوان از آنها، در کاربردهای گوناگون، به بهترین نحو استفاده کرد.

**نتایج و بحث:** با توجه به بررسی‌های انجام‌شده روی مقاله‌هایی از مجله‌های معتبر گوناگون در زمینه تشخیص شبکه راه‌ها، روش‌های مبتنی بر کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین به ترتیب، سهم‌هایی حدود ۲۸، ۳۱، ۵ و ۳۶ درصدی را دارند. در سال‌های اخیر روش‌های کلاسه‌بندی و قطعه‌بندی با شبکه‌های عصبی توسعه یافته‌اند و به‌طور کلی روش‌های مبتنی بر یادگیری ماشین سهم بیشتری (حدود ۶۰٪) دارند. در زمینه سوپرزولوشن نیز، بررسی‌های انجام‌شده نشان می‌دهد روش‌های مبتنی بر شیوه‌های سنتی و یادگیری عمیق، به ترتیب، سهم‌هایی حدود ۴۴ و ۵۶٪ دارند و در سال‌های اخیر، اغلب رویکردهای مبتنی بر یادگیری عمیق در حال توسعه است.

**نتیجه‌گیری:** بررسی‌ها نشان می‌دهد استفاده از مدل‌های یادگیری عمیق، در تشخیص شبکه راه‌ها، نتایجی بهتر از روش‌های سنتی دربردارد و این شیوه‌ها به تدریج جایگزین روش‌های قدیمی شده‌اند. مدل‌های یادگیری عمیق، با امکان استخراج ویژگی‌های پیچیده و کاهش نیاز به مداخله انسانی، دقت و کارایی فرایند تشخیص را بهبود بخشیده‌اند. از طرف دیگر، تکنیک‌های سوپرزولوشن مبتنی بر یادگیری عمیق می‌توانند، با افزایش حد تفکیک مکانی تصاویر، مشکلات ناشی از کمبود تصاویر دارای وضوح بالا را حل کنند. این تکنیک‌ها، با حفظ ویژگی‌های طیفی و کاهش نویز، می‌توانند تصاویر با کیفیت‌تری برای تشخیص راه‌ها ارائه دهند. به‌طور کلی، ترکیب روش‌های سوپرزولوشن و یادگیری عمیق برای شناسایی شبکه راه‌ها رویکردی مقرون به صرفه و کارآمد را در به‌روزرسانی نقشه‌های راه به دست می‌دهد. این رویکردها سبب کاهش هزینه‌ها و زمان مورد نیاز برای تشخیص می‌شوند و بدین ترتیب محققان و متخصصان می‌توانند، در زمینه‌های گوناگون، استفاده گسترده‌ای از آنها داشته باشند. همچنین، با توسعه بیشتر این تکنیک‌ها و بهبود دقت آنها، برای مدیریت و برنامه‌ریزی ساخت و نگهداری جاده‌ها راهکارهای جدیدی ایجاد می‌شود.

**واژه‌های کلیدی:** تصاویر ماهواره‌ای حد تفکیک متوسط، هوش مصنوعی، شبکه راه‌ها، سنجش از دور، سوپرزولوشن.

## استناد:

جوادی مقدم، ع.، کیانی، ع.، تحلیل روش‌ها، چالش‌ها و دیدگاه‌هایی در زمینه شناسایی شبکه راه‌های روستایی با محوریت استفاده از تصاویر سنجش از دوری، نشریه سنجش از دور و GIS ایران، سال ۱۷، شماره ۳، پاییز ۱۴۰۴: ۱۳۹-۱۷۶.



## ۱- مقدمه

راه‌ها همواره عامل توسعه و پیشرفت کشورها بوده‌اند و جاده‌ها نقش کلیدی در توسعه سیستم‌های حمل‌ونقل ایفا می‌کنند. از جمله این موارد، می‌توان به افزودن ناوبری خودکار جاده، وسایل نقلیه بدون سرنشین و برنامه‌ریزی شهری اشاره کرد که هم در صنعت و هم در زندگی روزمره اهمیت دارند (Gao et al., 2019). برای بهره‌برداری بهتر از ظرفیت جاده‌ها، باید نقشه‌ای کامل، جامع و به‌روز از شبکه راه‌های موجود، در دست متولی این کار باشد تا بتوان به موقعیت، طول و دیگر اطلاعات مورد نیاز دست یافت. برای تولید یا به‌روزرسانی نقشه شبکه جاده‌ها، می‌توان از دو روش استفاده کرد؛ نخست، بررسی سنتی با مراجعه مستقیم به محل پروژه و دوم، با استفاده از رویکردهای سنجش از دور معمولاً پرحمت، وقت‌گیر و همراه با صرف هزینه زیادند؛ به همین دلیل است که باید به دنبال روش‌هایی بود تا، علاوه بر دربرگرفتن مناطق وسیع، بتوان هزینه و زمان اجرای پروژه را کاهش داد. در دهه‌های اخیر، بهره‌گیری از تصاویر سنجش از دوری به شیوه‌ای متداول در حوزه نقشه‌برداری تبدیل شده و این فناوری راه را برای کاربرد تشخیص خودکار جاده‌ها، در مقیاس بزرگ، باز کرده است.

تصاویر سنجش از دوری دسته‌بندی‌های گوناگونی دارند که با توجه به نوع کاربرد آنها، می‌توان از هریک بهره گرفت. این تصاویر، از منظر فاصله، به دو دسته تصاویر هوای و تصاویر ماهواره‌ای تقسیم می‌شود و هریک انواع و ویژگی‌های متعددی دارد. تصاویر هوای را نیز می‌توان، براساس سکوی پرواز، به دو بخش تصاویر هوایی (تصویربرداری در محدوده‌های بزرگ، با هواپیما) و تصاویر پهپاد دسته‌بندی کرد. تصاویر پهپاد، به دلیل محدوده عملیاتی کم و گسترده بودن شبکه راه‌ها برای استخراج این شبکه‌های وسیع اطلاعاتی، از نظر زمانی و هزینه‌ای بهینه نیستند. تصاویر ماهواره‌ای دارای حد تفکیک مکانی متفاوتی‌اند، اعم از بالا،

متوسط و پایین، که برحسب نیاز و مساحت منطقه مطالعاتی انتخاب می‌شوند. انواع این تصاویر، براساس دسترسی، در دو دسته رایگان و تجاری قرار می‌گیرند. به دلیل قیمت بالا و دسترسی دشوار به تصاویر تجاری، استفاده از تصاویر رایگان در دست مقرون‌به‌صرفه و منطقی‌تر به نظر می‌رسد و سبب کاهش چشمگیر هزینه‌های اجرایی هر پروژه می‌شود. یکی از ماهواره‌های موجود با حد تفکیک مکانی متوسط و رایگان که طی سال‌های اخیر مورد توجه بسیاری از عوامل این عرصه قرار گرفته، ماهواره سنتینل-۲ است. حد تفکیک مکانی باندهای چندطیفی تصاویر دریافتی از این ماهواره ده و بیستمتری است و در مقایسه با عرض راه‌ها که حدود هفت تا شصت متر (در یک باند) هستند، در شناسایی راه‌های کم‌عرض، دچار مشکل می‌شوند؛ بنابراین اخیراً راهکارهایی، به منظور استفاده ترکیبی از تصاویر متفاوت برای بهبود این مسئله، از سوی محققان مطرح شده که یکی از آنها توسعه الگوریتم‌های سوپرزولوشن<sup>۱</sup> (Adigun et al., 2022; Galar Idoate et al., 2019) است. به صورت کلی، با استفاده از این تکنیک‌ها می‌توان تصاویر دارای رزولوشن مکانی متوسط را بهبود داد و از آنها استفاده مفیدتری کرد.

طبق آخرین آمار اعلام‌شده، حدود ۲۲۰ هزار کیلومتر انواع راه در ایران، اعم از بزرگراه، آزادراه، راه‌های شهری، راه‌های بین‌شهری و راه‌های روستایی، سرتاسر کشور را به هم متصل می‌کند (Market Analysis News Site, 1400). تولید نقشه، از شبکه راه‌هایی با این وسعت، کاری زمان‌بر و نیازمند صرف هزینه بسیار است. از این‌رو، بنابر ضرورت و اهمیت مسئله مذکور و با توجه به موارد گفته‌شده، باید در پی روش‌هایی برای تولید نقشه شبکه‌ای وسیع از راه‌های هر منطقه بود؛ بدین ترتیب، ضمن آگاهی از وضعیت کنونی راه‌های کشور، امکان به‌روزرسانی دوره‌ای نقشه‌ها با

1. Super Resolution

سازوکار و خروجی قابل ارائه، بررسی و نقاط قوت و ضعف هریک شناسایی شد تا بتوان از آنها، در کاربردهای گوناگون، به بهترین نحو بهره برد.

## ۲- مبانی نظری

در این بخش، سعی شده است طی سه دسته‌بندی کلی داده‌های کاربردی به‌منظور شناسایی شبکه‌ راه‌ها، روش‌های شناسایی شبکه‌ راه‌ها و روش‌های بهبود حد تفکیک مکانی تصاویر سنجش‌ازدوری و نیز بیان مبانی نظری الگوریتم‌ها و داده‌های مورد استفاده، روند پیشرفت و اهمیت حوزه‌ پایش شبکه‌ راه‌ها بهتر توضیح داده شود.

۱-۲- داده‌های کاربردی به‌منظور شناسایی شبکه‌ راه‌ها داده‌های مورد استفاده در تشخیص شبکه‌ راه‌ها طیف گسترده‌ای از داده‌های نقشه‌برداری را دربرمی‌گیرد. در این راستا، بنابر گستردگی منطقه مورد مطالعه، عرض راه‌های منطقه و عواملی از این دست، می‌توان نوع داده مناسب (شکل ۱) را انتخاب کرد. این دسته‌بندی به‌کمک مطالعات و داده‌های در دسترس انجام شده است.

صرف کمترین هزینه و وقت، در زمان‌های گوناگون و برحسب نیاز مدیران و سازمان‌ها، وجود خواهد داشت. هدف اصلی این پژوهش بررسی روش‌های مطرح و جدید، با هدف تشخیص شبکه‌ راه‌ها، ضمن تأکید بر راه‌های فرعی روستایی و بین‌شهری است. در این راستا، داده‌های کاربردی به‌منظور شناسایی شبکه‌ راه‌ها نیز بررسی شده و براساس وسعت و عرض شبکه‌ راه‌های مدنظر و نحوه دسترسی به داده‌ها، تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط مورد توجه این مطالعه است. برای تحلیل پژوهش‌های انجام‌شده در زمینه تشخیص شبکه‌ راه‌ها از نظر ورودی، محصولات، پارامترهای مورد نیاز، خروجی و هزینه، دسته‌بندی طبق روش‌های مبتنی بر کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین<sup>۱</sup> انجام شده است. از آنجاکه استفاده از تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط، در تشخیص شبکه‌ راه‌های روستایی ارجحیت داشت، روش‌های بهبود حد تفکیک مکانی، همانند فیوژن<sup>۲</sup> و سوپرزولوشن نیز تشریح و ویژگی‌های هریک بررسی شد. در نهایت، روش‌ها از نظر پارامترهای ورودی، نحوه

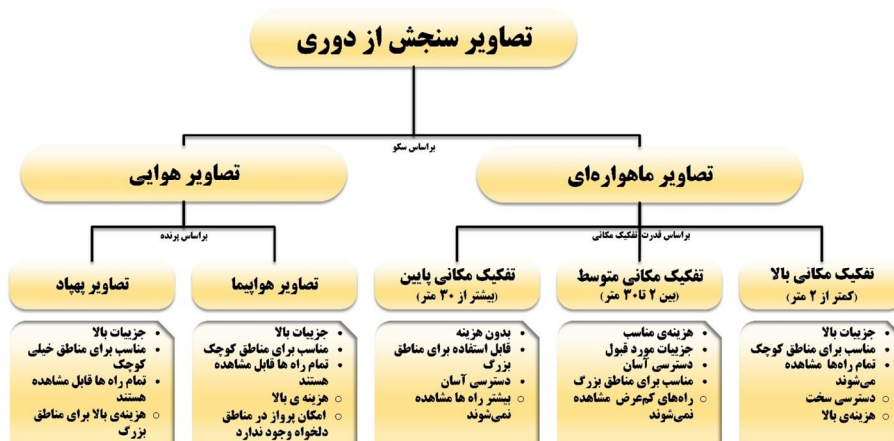


شکل ۱. روش‌های دریافت داده برای تهیه نقشه راه

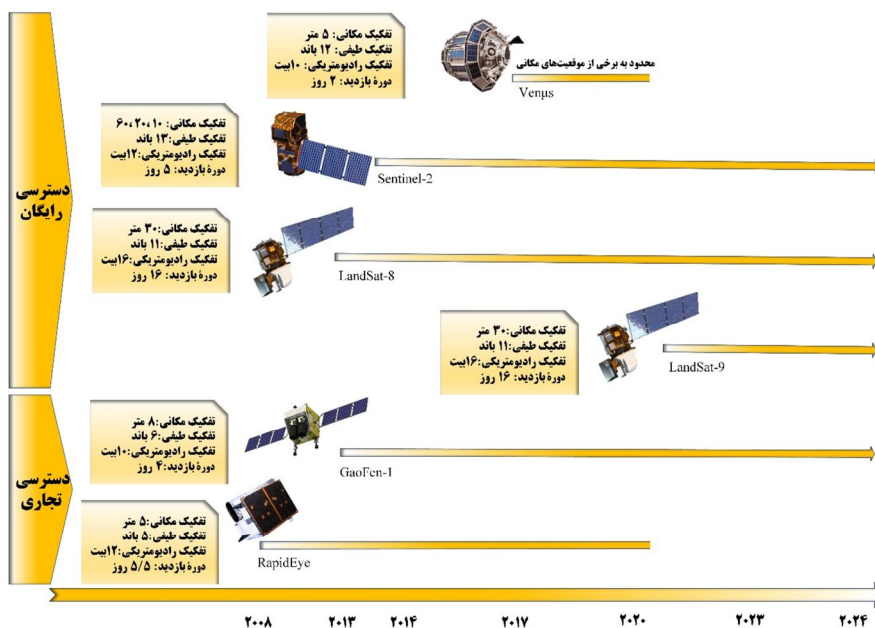
1. Machine Learning (ML)
2. Fusion (Pan Sharpening)

بنابر موارد مطرح شده در شکل ۲، دریافته می‌شود که استفاده از تصاویر هوایی برای تشخیص شبکه راه‌ها، از منظر هزینه، به صرفه و منطقی نیست؛ به دلیل آنکه شبکه راه‌ها وسعت و گستردگی زیادی دارند و بنابراین باید به سراغ تصاویر ماهواره‌ای رفت. در استفاده از تصاویر سنجش از دوری، پارامترهای گوناگونی مانند حد تفکیک مکانی و حد تفکیک طیفی و نحوه دسترسی، با توجه به کاربرد، در نظر گرفته می‌شود. ویژگی‌های برخی سنجنده‌ها با دسته‌بندی نوع دسترسی به آنها در شکل ۳ ترسیم شده است.

داده‌های مورد استفاده در تشخیص شبکه راه‌ها طیف گسترده‌ای از تصاویر سنجش از دوری را در برمی‌گیرد که بنابر گستردگی منطقه مورد مطالعه، عرض راه‌های منطقه و عواملی از این دست، می‌توان نوع داده مناسب را انتخاب کرد. تصاویر سنجش از دوری را می‌توان به دو بخش کلی تصاویر ماهواره‌ای و هوایی تقسیم کرد که در شکل ۲، به کمک مطالعات مروری (Z. Chen et al., 2022; Liu et al., 2024; Sharma et al., 2023)، برخی مزایا و معایب آن مطرح شده است.



شکل ۲. برخی مزایا و معایب تصاویر سنجش از دوری کاربردی برای تشخیص راه، به صورت دسته‌بندی شده



شکل ۳. ویژگی‌های برخی سنجنده‌ها با حد تفکیک مکانی متوسط و سری زمانی دسترسی به داده‌های آنها

منبع: (L. Chen et al., 2022; Dick et al., 2022; Masek et al., 2020; Spoto et al., 2012)



به‌منزله پیوندهای بین آنها در نظر گرفته شده است. نمونه‌ای از تشخیص شبکه راه‌های روستایی که به راه‌های مواصلاتی بین روستاها و شهرهای اطراف اطلاق می‌شود، در شکل ۴ ارائه شده است.

در طول سال‌ها، روش‌های متعددی برای شناسایی شبکه راه‌ها توسعه یافته که همواره به کار می‌روند و هر روش ممکن است پیرو یک یا چند اصل باشد. در شکل ۵، برخی روش‌های تشخیص شبکه راه و اصول آنها آورده شده است.

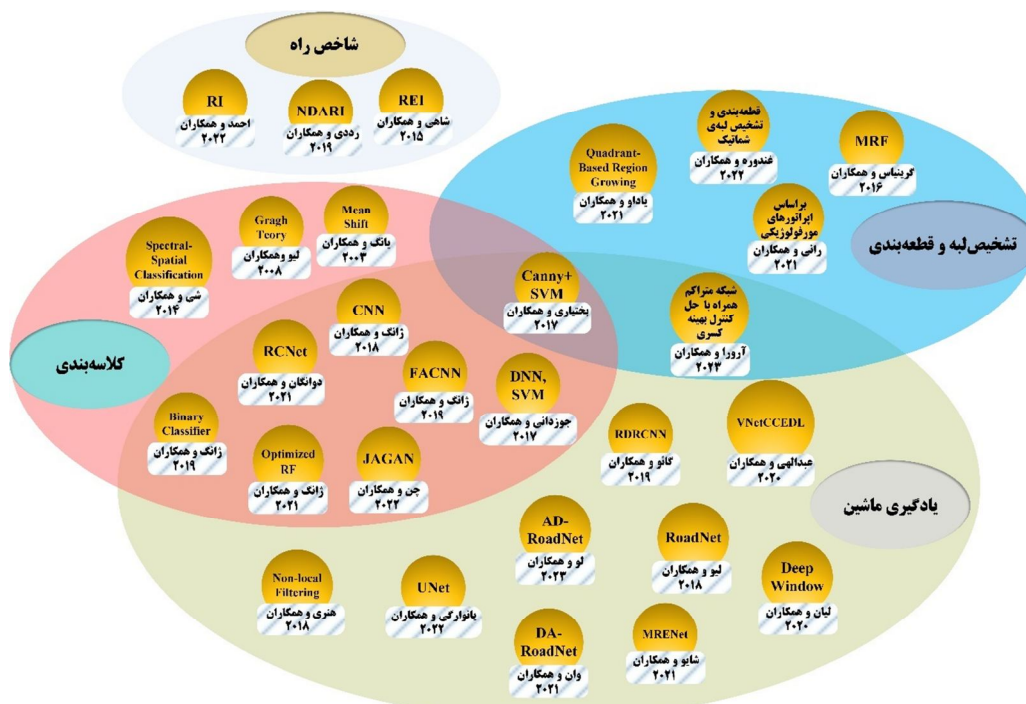
شایان ذکر است که ماهواره‌های بسیاری به‌منظور تصویربرداری از زمین و پایش عوارض پرتاب شده‌اند، اما، به‌دلیل محدودیت در نگارش، در این پژوهش فقط چند مورد اصلی و مرسوم بررسی شده است.

## ۲-۲- روش‌های شناسایی شبکه راه‌ها

شبکه راه‌ها، مانند بسیاری از شبکه‌ها، شامل مجموعه‌ای از مکان‌ها و مجموعه‌ای از پیوندهاست که ارتباطات بین این مکان‌ها را بیان می‌کنند. در این مطالعه، شهرها و روستاها به‌منزله این مکان‌ها، و راه‌های مواصلاتی نیز



شکل ۴. شبکه راه‌ها: تصویر گوگل ارث از منطقه (الف)؛ نقشه راه OSM<sup>۱</sup> از منطقه (ب)؛ نمونه‌ای از شبکه راه شناسایی شده (ج)؛ داده واقعیت زمینی (د)



شکل ۵. دسته‌بندی برخی روش‌های تشخیص شبکه راه‌ها براساس اصول به‌کاررفته

منبع: Abdollahi et al., 2020a; Ahmed et al., 2022; Arora et al., 2023; Bakhtiari et al., 2017; Chen et al., 2022b; Gao et al., 2019; Ghandorh et al., 2022; Grinias et al., 2016; Henry et al., 2018; Lian et al., 2020; Liu & Wang, 2008; Liu et al., 2018; Luo et al., 2023; Shahi et al., 2015; Shao et al., 2021; Yadav, 2021; Yanuargi & Utami, 2022; Zhang et al., 2019a; Zhang et al., 2019b; Zhang et al., 2021; Zhang et al., 2018

در ادامه، مختصری از مبانی مرتبط با روش‌های یادشده در شکل ۵ مطرح می‌شود.

### ۱-۲-۲- تشخیص لبه

اغلب برنامه‌های کاربردی پردازش تصویر در تصاویر سنجش از دور نیازمند تقسیم‌بندی تصویر به بخش‌های کوچک‌تر، شامل اشیاء و مناطق تشکیل‌دهنده تصویرهاست. الگوریتم‌های تقسیم‌بندی تصویر، به‌طور کلی، بر یکی از دو ویژگی اساسی مقادیر شدت روشنایی تصویر استوار است: تشابه و ناپیوستگی. تا کنون، تشخیص لبه به‌منزله رایج‌ترین روش برای تشخیص ناپیوستگی‌های معنی‌دار در سطح تصویر خاکستری به کار می‌رفته است (Jing et al., 2022). لبه را می‌توان به‌منزله ناپیوستگی در سطح خاکستری، رنگ، بافت و ... در تصویر تعریف کرد (Sonka et al., 2014).

بسیاری از روش‌های کلاسیک برای تشخیص لبه بر پایه مشتق پیکسل‌های تصویر اصلی عمل می‌کنند. اپراتورهای تشخیص لبه کلاسیک مانند رابرتز، سوبل، و اپراتور لاپلاسیان تابع گاوسی، با محاسبه مشتقات جزئی در یک همسایگی، لبه‌های تصویری را شناسایی می‌کنند. تشخیص لبه براساس مشتق در دو کلاس کلی قرار می‌گیرد: محاسبه براساس مشتق مرتبه اول و دوم. این روش‌های تشخیص لبه ساده، اما درعین حال به نویز حساس‌اند. به‌منظور کاهش اثر نویز، ابتدا تصویر مورد نظر نرم و سپس برای تشخیص لبه اقدام می‌شود؛ البته این کار کنتراست لبه‌ها را کاهش می‌دهد و موجب دشواری در مکان‌یابی برخی لبه‌های ضعیف تصویر خواهد شد (Kiani & Ebadi, 2015). به‌طور کلی، الگوریتم‌های تشخیص لبه با دو چالش اصلی مواجه‌اند؛ تشخیص نقاط نادرست به‌منزله لبه که اغلب ناشی از نویز است و دیگری بریده بودن مرز اشیاء که از کیفیت پایین تصویر و یا ضعف روش تشخیص لبه ناشی می‌شود. علاوه بر روش‌های گفته‌شده، روش‌های جدید دیگری نیز به‌منظور تشخیص لبه تصاویر به کار رفته است: روش‌های مبتنی بر شبکه عصبی، فازی،

الگوریتم کلونی مورچه‌ها، مورفولوژی و موارد دیگر (Versaci & Morabito, 2021). در این میان، به‌کمک تئوری اطلاعات، تحقیقاتی هم درباره استخراج لبه‌های تصویر انجام شده است. این روش عملکردی بهتر از روش‌های کلاسیک تشخیص لبه‌ها دارد و از ویژگی پیوستگی لبه‌های استخراجی بهره می‌برد اما عملکرد بهینه این روش در استخراج پیوسته لبه‌های قوی تصویر است و قادر به شناسایی همه تغییرات تصویری نیست. با توجه به این مشکلات و همچنین کارآمدی روش تشخیص لبه با آنتروپی و ویژگی پیوسته بودن لبه‌ها در این شیوه که مورد نیاز کاربردهای سنجش‌ازدوری است، در برخی تحقیقات، پیشنهاد رویکردی جدید براساس تئوری اطلاعات و با بهره‌گیری از سیستمی قانون‌مبنا داده شده است (Kiani & Sahebi, 2015). تحقیقات بسیاری در زمینه تشخیص لبه انجام شده است و انتخاب روش بهینه باید با توجه به کیفیت رادیومتریکی و مکانی داده تصویری ورودی، زمان پردازش و همچنین توجعی انجام شود که متناسب با نوع کاربرد، از خروجی تشخیص لبه انتظار می‌رود.

### ۲-۲-۲- روش‌های قطعه‌بندی

قطعه‌بندی<sup>۱</sup> عبارت است از فرایند تقسیم تصاویر به مناطق پیوسته، ناپیوسته و همگن فضایی، با توجه به ویژگی‌های مکانی یا طیفی. روش‌های قطعه‌بندی تصویر بسیاری با کاربردهای گوناگون پیشنهاد شده است؛ باین حال فقط اندکی از آنها به نتایج کمی متقاعدکننده منجر می‌شوند (Kiani et al., 2019a). زیرا، در بیشتر موارد، مناطق مورد نظر بسیار ناهمگن‌اند. روش‌های قطعه‌بندی تصویر را می‌توان به روش‌های قطعه‌بندی مبتنی بر پیکسل، مبتنی بر لبه و مبتنی بر منطقه تقسیم کرد (Blaschke et al., 2004). در قطعه‌بندی مبتنی بر پیکسل، هر پیکسل به‌طور مستقل برچسب‌گذاری می‌شود. این روش بسیار ساده

1. Segmentation

مناطق با پوشش‌های متفاوت زمین (مانند جنگل‌ها یا مناطق شهری)، می‌تواند چالش‌ساز باشد. تغییرات فصلی نیز ممکن است در کیفیت تصاویر و در نتیجه، دقت شناسایی تأثیر بگذارد. به علاوه، کیفیت داده‌های آموزشی و وجود داده‌های متنوع و باکیفیت برای آموزش مدل‌ها اهمیت بسیاری دارد و ممکن است در دسترس نباشند.

شناسایی جاده‌ها و ساختمان‌ها، در روش‌های سنجش از دور، به‌طور فزاینده‌ای به‌منزله فرایندهایی مکمل در نظر گرفته می‌شود. این دو نوع ویژگی زمینی از جنبه‌های گوناگونی به یکدیگر وابسته‌اند و شناسایی جداگانه آنها می‌تواند چالش‌های فراوانی به‌همراه داشته باشد. در این زمینه، مقالات علمی بسیاری بر این نکته تأکید کرده‌اند که شناسایی مستقل این دو ویژگی، به‌ویژه در مناطق شهری، معمولاً با مشکلاتی مواجه است. برای نمونه، وجود انحرافات بصری در تشخیص جاده‌ها و ساختمان‌ها ممکن است شباهت‌های هندسی و ظاهری داشته باشند که باعث می‌شود شناسایی این دو از یکدیگر دشوار شود. بسیاری از مطالعات اخیر بر روش‌هایی تمرکز دارند که بتوانند این دو ویژگی را هم‌زمان و در چارچوبی یکپارچه، شناسایی کنند تا دقت و کارایی فرایند تفسیر تصاویر سنجش از دور بهبود یابد. برخی مطالعات، برای استخراج جاده‌ها از تصاویر دارای وضوح بالا در سنجش از دور، به روش‌های دومرحله‌ای پرداخته‌اند. هدف اصلی کاربرد این شیوه‌ها بهبود دقت و کارایی شناسایی جاده‌هاست که از روش‌های طبقه‌بندی تصویر برای شناسایی نواحی مرتبط با جاده‌ها استفاده می‌کنند (Kahraman et al., 2018). در این شیوه، از ویژگی‌های طیفی و فضایی تصاویر استفاده می‌شود. پس از طبقه‌بندی اولیه، یک سری تکنیک‌های پردازش تصویر (از جمله، فیلتر کردن و بهبود بافت) به کار می‌رود تا نتایج شناسایی شده تصحیح و اصلاح شوند. این مرحله به بهبود پیوستگی و دقت نتایج کمک می‌کند.

است اما احتمال دارد، در مورد تصاویری که لبه‌های واضح یا مناطق متمایز ندارند، مؤثر نباشد. قطعه‌بندی مبتنی بر لبه، پس از شناسایی لبه‌ها در تصویر، این لبه‌ها را در تشکیل مناطق به کار می‌برد. این روش دقیق‌تر از قطعه‌بندی مبتنی بر پیکسل است اما ممکن است زمان‌بر باشد. قطعه‌بندی مبتنی بر منطقه ابتدا مناطق را در تصویر شناسایی می‌کند و سپس به هر منطقه برچسبی را اختصاص می‌دهد. این روش از دو روش دیگر دقیق‌تر است اما اجرای آن ممکن است زمان‌بر باشد.

### ۳-۲-۲- کلاسه‌بندی

شناسایی جاده‌ها، به‌روش طبقه‌بندی تصاویر در سنجش از دور، برای شناسایی و تفکیک جاده‌ها از دیگر عناصر داخل این تصاویر استفاده می‌شود. الگوریتم‌های متفاوت کلاسه‌بندی، مانند روش‌های طبقه‌بندی سنتی همچون نزدیک‌ترین همسایه (KNN)، ماشین‌های بردار پشتیبان<sup>۱</sup> و روش‌های یادگیری عمیق<sup>۲</sup>، مانند شبکه‌های عصبی کانولوشن (CNN) به‌طور خاص برای شناسایی ویژگی‌های پیچیده و الگوهای فضایی طراحی شده‌اند. البته طبقه‌بندی را نباید به این روش‌ها منحصر دانست و محققان بسیاری، با استفاده از طبقه‌بندی گره‌های درختی و روش‌های دیگر نیز، به طبقه‌بندی پرداختند. برای نمونه، کیانی<sup>۳</sup> و همکاران (۲۰۱۹b) با استفاده از سیستم‌های دانش‌پایه، روش‌های تفسیر تصاویر سنجش از دوری را با هدف بهبود دقت و کارایی تفسیر محصولات زمین از تصاویر با تفکیک بالا، بررسی کرده‌اند. در این مطالعه، تکنیک‌ها و الگوریتم‌های گوناگون برای تحلیل و تفسیر داده‌های سنجش از دور بررسی شده و نمونه‌هایی از کاربرد این روش‌ها در تحلیل داده‌ها آمده است. نتایج این تحقیق کارایی بالای سیستم‌های دانش‌پایه را در کمک به تحلیل و طبقه‌بندی تصاویر سنجش از دور نشان می‌دهد.

تولید نقشه‌های جاده‌ای دارای چالش‌هایی مانند ناهمگونی پوشش زمین است؛ شناسایی جاده‌ها در

1. Support Vector Machine (SVM)
2. Deep Learning (DL)
3. Kiani



الگوها و ویژگی‌های پیچیده‌تر داده‌ها را دارد. روش‌های قدیمی یادگیری ماشین، مانند درخت تصمیم‌گیری<sup>۳</sup> و ماشین بردار پشتیبان (Bakhtiari et al., 2017; Jozdani et al., 2019) را نمی‌توان به‌طور مستقیم روی داده‌های خام، همچون تصاویر و متون، به‌منظور یادگیری داده‌ها اعمال کرد. به‌عبارتی باید ویژگی‌هایی را از داده‌های خام، به‌منزله بازنمایی<sup>۴</sup> این داده‌ها، استخراج کرد و ویژگی‌های مورد نظر را به‌صورت ورودی الگوریتم‌های یادگیری ماشین به کار برد. اما مدل‌های یادگیری عمیق نیازی به گام مجزا برای استخراج ویژگی ندارند و لایه‌های شبکه‌های عصبی قادرند بازنمایی‌های ضمنی داده‌های خام را در روال آموزش شبکه فراگیرند. کاربرد این روش‌ها در تشخیص راه به‌گونه‌ای است که احتمال دارد رویکردهای متفاوتی در هریک از زیرمجموعه‌های هوش مصنوعی وجود داشته باشد. برای نمونه، استفاده از کلاسه‌بندی مبتنی بر یادگیری ماشین، مانند SVM (Bakhtiari et al., 2017) و یا کلاسه‌بندی مبتنی بر یادگیری عمیق، همانند روش‌های JAGAN<sup>۵</sup> (Chen et al., 2022) و FACNN<sup>۶</sup> (Zhang et al., 2019) را می‌توان نام برد. قطعه‌بندی‌های براساس یادگیری عمیق نیز دارای روش‌های گوناگونی است (Arora et al., 2023; Wei et al., 2019).

دیپان<sup>۱</sup> و همکاران (۲۰۱۸) تکنیک‌های گوناگون یادگیری ماشین برای شناسایی جاده‌ها در تصاویر ماهواره‌ای و سنجش از دور را بررسی کردند. آنها چندین الگوریتم یادگیری ماشین را آزمودند و عملکرد آنها را در شناسایی الگوهای جاده‌ای، در داده‌های تصویری، تحلیل کردند. نتایج نشان می‌دهد که استفاده از این الگوریتم‌ها دقت شناسایی جاده‌ها را بهبود چشمگیری می‌بخشد. این محققان نتایج کار خود را بررسی و بر اهمیت ادامه پژوهش در این حوزه، به‌منظور حصول بهبود بیشتر در شناسایی جاده‌ها با استفاده از تصاویر سنجش از دور، تأکید کرده‌اند.

شناسایی جاده‌ها، با استفاده از طبقه‌بندی تصاویر در سنجش از دور، فرایندی پیچیده است که به روش‌های پیشرفته تحلیل داده‌ها و الگوریتم‌های یادگیری ماشین نیاز دارد. با پیشرفت فناوری‌ها و تکنیک‌های جدید، دقت این روش‌ها همواره در حال افزایش است و به بهبود مدیریت و برنامه‌ریزی شهری و زیرساخت‌های حمل‌ونقل کمک می‌کند. چون روش‌های آشکارسازی ساختمان و جاده بر روش‌های پیش‌پردازش مشابهی متکی‌اند، بعید به نظر می‌رسد که سیستم‌های استخراج، درمورد هر دو کلاس به‌صورت مجزا، موفق باشد و از این‌رو بهتر است در پایگاه دانش جامعی از اشیای بالقوه گنجانده شود.

#### ۴-۲-۲- یادگیری ماشین

هوش مصنوعی<sup>۲</sup> شامل مجموعه‌ای از روش‌هاست که رایانه‌ها را قادر می‌سازد، به‌منظور تصمیم‌گیری درباره مسائل گوناگون، عملکردی هوشمندانه و انسان‌گونه داشته باشند. در این راستا روش‌های متفاوتی، همچون یادگیری ماشین و یادگیری عمیق به‌منزله زیرمجموعه هوش مصنوعی، توسعه یافته‌اند که می‌توان از آنها برای آموزش سیستم‌های هوشمند، به‌منظور انجام دادن فعالیت‌های گوناگون، بهره گرفت. یادگیری ماشین در تشخیص الگوها و انجام دادن پیش‌بینی‌های مبتنی بر داده‌ها مفید است اما یادگیری عمیق امکان تشخیص

#### ۳-۲- بهبود حد تفکیک مکانی تصاویر سنجش‌ازدوری

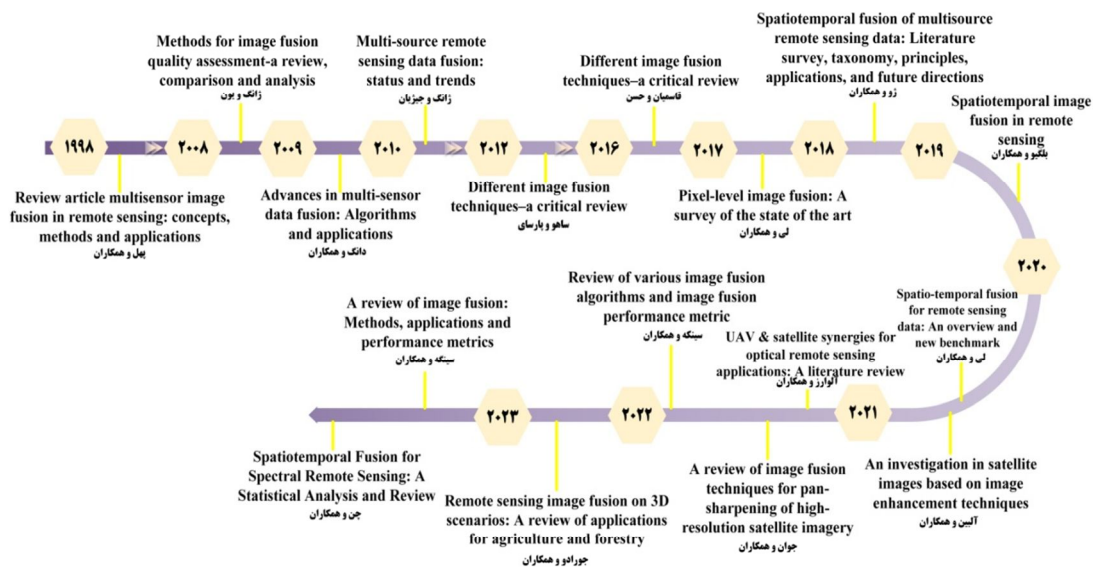
این نوع بهبود تصاویر ماهواره‌ای، با هدف افزایش حد تفکیک مکانی، با حفظ ویژگی‌های طیفی و رادیومتریکی انجام می‌شود. برای انجام دادن این بهبود، استفاده از فیوژن تصاویر کاری متداول است که به دو تصویر هم‌زمان، یکی با حد تفکیک مکانی بالا و دیگری

1. Deepan
2. Artificial Intelligence (AI)
3. Decision Tree
4. Representation
5. Joint Channel-Space Attention Mechanism and Generative Adversarial Network
6. Fully Atrous Convolutional Neural Network

### ۱-۳-۲- فیوژن

در روش‌های بهبود حد تفکیک مکانی مبتنی بر فیوژن، تصاویر فراطیفی دارای وضوح فضایی بالا از طریق ادغام تصویری فراطیفی دارای وضوح فضایی پایین با اطلاعات کمکی ایجاد می‌شود. روش‌های بهبود مبتنی بر فیوژن به رویکرد جایگزینی مؤلفه<sup>۱</sup>، رویکرد عددی و مبتنی بر آمار<sup>۲</sup>، رویکرد چندتفکیک‌پذیری<sup>۳</sup> و رویکرد مبتنی بر بهینه‌سازی<sup>۴</sup> طبقه‌بندی می‌شوند (Ablin et al., 2020). با توجه به گستردگی موضوع، برخی بررسی‌ها در این زمینه در شکل ۶ گرد آمده است تا، برای اطلاعات بیشتر، به آنها مراجعه شود.

با حد تفکیک طیفی بالا، نیاز دارد. با تکامل حوزه روش‌های بهبود حد تفکیک مکانی تصاویر ماهواره‌ای، الگوریتم‌های سوپررزولوشن که اغلب در ماشین بینایی کاربرد داشته‌اند، وارد این حوزه شده‌اند. این الگوریتم‌ها، در ابتدای مسیر، به صورت نگاشتی ثابت عمل می‌کردند؛ در ادامه روند پیشرفت آنها، رویکردهای یادگیری ماشین و الگوریتم‌های مبتنی بر همسایگی همراه با بهینه‌سازی حداقل مربعات وارد این عرصه شدند اما نتوانستند نتایجی مطلوب دربر داشته باشند. از سال ۲۰۱۷ تا کنون نیز، رویکردهای مبتنی بر یادگیری عمیق در حال توسعه است که هم از نظر دقت و هم از نظر کارایی، نتایج مورد قبولی داشته‌اند.



شکل ۶. برخی بررسی‌های انجام‌شده در زمینه فیوژن

منبع:

Ablin et al., 2020; Alvarez-Vanhard et al., 2021; Belgiu & Stein, 2019; Chen et al., 2023b; Dong et al., 2009; Ghassemian, 2016; Javan et al., 2021; Jurado et al., 2022; Li et al., 2017; Li et al., 2020; Pohl & Van Genderen, 1998; Sahu & Parsai, 2012; Singh et al., 2021; Singh et al., 2023; Zhang, 2008; Zhang, 2010; Zhu et al., 2018

1. Component Substitution Approach
2. Numerical and Statistical-Based Approach
3. Multiresolution Approach
4. Optimization-Based Approach

## ۲-۳-۲- الگوریتم‌های سوپررزولوشن

سوپررزولوشن تک‌تصویر<sup>۱</sup> از الگوریتم‌های پردازش تصویر است که بر بازیابی تصویری با وضوح بالا از تصویری دارای وضوح پایین تمرکز دارد. تکنیک‌های گوناگونی که در گذشته توسعه یافته‌اند نتایج درخور توجهی به‌همراه داشته‌اند. با استفاده از روش‌های گوناگون، می‌توان به سوپررزولوشن تصاویر دست پیدا کرد. یکی از رویکردها مبتنی بر بازسازی تصویر (RE)<sup>۲</sup> است (Dong et al., 2011; Yang et al., 2010) که هدف آن بازتولید ویژگی‌های ظاهر شده در تصویر LR<sup>۳</sup> تا سطح وضوح بالاتر یا، به عبارت دیگر، به دست آوردن تصویر حل‌شده<sup>۴</sup> نهایی، با همان ویژگی‌های ادراکی تصویر LR اما دارای رزولوشن بالاتر است. به‌نحوی، روش‌های RE سعی می‌کنند کیفیت دامنه LR را پس از درون‌یابی اولیه، تکرار کنند تا از تأثیرات تاری و خطاهای ناشی از الگوریتم‌های درون‌یابی جلوگیری کنند. تعداد اندکی از رویکردهای دیگر به روش‌های مبتنی بر یادگیری ماشین متمایل‌اند؛ این رویکردها از دیکشنری استفاده می‌کنند و هدفشان یادگیری نحوه تبدیل از تصاویر دارای وضوح پایین به تصاویر با وضوح بالاست. همچنین برخی الگوریتم‌ها که پیچیدگی اندکی دارند، بدون استفاده از منابع بسیار، نتایج بهتری را هدف قرار می‌دهند. مجموعه‌ای از الگوریتم‌های مبتنی بر همسایگی<sup>۵</sup> (Huang et al., 2015; Kim & Kwon, 2010) مبتنی بر یادگیری ماشین‌اند؛ این الگوریتم‌ها با استفاده از پچ‌های دارای وضوح بالا که در دیکشنری ذخیره می‌شوند، آموخته می‌شوند. این پچ‌ها را می‌توان، به همان روشی که با تصاویر دارای وضوح پایین مطابقت دارند، ترکیب کرد. این روش با استفاده از فاصله اقلیدسی، برای جست‌وجوی همسایه و به‌دنبال آن، بهینه‌سازی مسئله حداقل مربعات، بهبود می‌یابد. باین‌حال این فرایندها بهینه نیستند و هنگامی که مقیاس تصویر مورد نظر نسبتاً بالاتر باشد، در کار شکست می‌خورند (Bevilacqua et al., 2012; Gao et al., 2012; Zhang et al., 2012). روش‌های یادشده را

می‌توان به‌منزله رویکردهای سنتی در نظر گرفت. الگوریتم‌های سوپررزولوشن جدید بر یادگیری عمیق مبتنی‌اند که علاوه بر دقت بالا، کارایی و بازدهی بهتری را نیز به‌همراه دارند.

با توجه به موارد بیان‌شده، سوپررزولوشن را می‌توان شامل دو دسته روش‌های سنتی و روش‌های یادگیری عمیق دانست. از آنجا که هدف تحقیق حوزه کاربردهای سنجش‌ازدوری و زادگاه اصلی سوپررزولوشن حوزه ماشین بینایی است، تمرکز مطالعات بر این دو حوزه خواهد بود. بنابراین برخی مطالعات انجام‌شده در شکل ۷ دسته‌بندی شده‌اند.

با توجه به فراگیر شدن روش‌های مبتنی بر یادگیری عمیق، به داده‌های آموزشی، به‌ویژه در حوزه سنجش از دور احساس نیاز می‌شود؛ از این رو محققان این حوزه مجموعه داده‌هایی را به‌منظور آموزش شبکه‌های یادگیری عمیق، گرد آورده‌اند. این مجموعه داده‌ها معمولاً شامل پچ‌هایی از رزولوشن اولیه (پچ دارای رزولوشن کم) و رزولوشن نهایی (رزولوشن بالا) می‌شوند. دو مورد از مجموعه داده‌های کاربردی، در زمینه سوپررزولوشن، در ادامه بیان شده است و می‌توان جزئیات آنها را در تحقیقات ارجاع‌داده‌شده، یافت.

• Sen2Venµs (Michel et al., 2022)

• Sen2Rapid (Galar Idoate et al., 2019)

## ۳- دسته‌بندی و معرفی روش‌ها

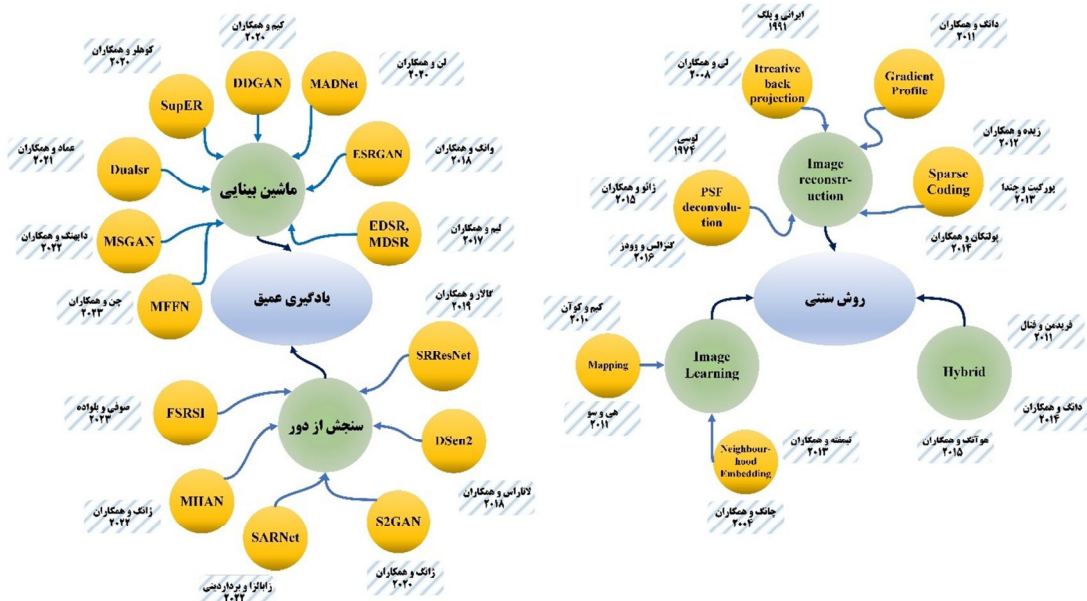
طبق توضیحات بخش پیشین، مطالعات در این پژوهش حول دو محور روش‌های تشخیص شبکه راه‌ها و بهبود حد تفکیک مکانی تصاویر سنجش‌ازدوری به‌روش سوپررزولوشن انجام شده است.

1. Single Image Super-Resolution
2. Image Reconstruction
3. Low Resolution
4. Super Resolved Image
5. Neighbourhood Embedding

در این زمینه در شکل ۹ اشاره شده است که در صورت نیاز به اطلاعات بیشتر، می‌توان به آن مطالعات مراجعه کرد. شاهی<sup>۱</sup> و همکاران (۲۰۱۵) رویکردی خودکار و سریع را برای استخراج جاده آسفالت، از تصاویر WorldView-2 (WV-2) مطرح کردند. روش پیشنهادی براساس شاخص طیفی جدید است که می‌تواند جاده‌های آسفالت را به‌طور خودکار استخراج کند. در این مطالعه، از یک طیف‌سنج رادیومتر با برد کامل و تصاویر WV-2 استفاده شده است. هدف این مطالعه توسعه شاخص جدیدی با نام REI<sup>۲</sup> است که حداقل میزان دقت ثابت ۸۶٪ در استخراج جاده آسفالت را به دست آورد. برای ارزیابی دقت، شاخص REI با BAI<sup>۳</sup> مقایسه شد و مقایسه نتایج نشان داد که REI جاده‌ها را کمتر از BAI طبقه‌بندی می‌کند.

۱-۳- مطالعات در زمینه شناسایی شبکه راه‌ها  
راه‌ها را می‌توان، با رویکردهای گوناگونی، از تصاویر سنجش‌ازدوری استخراج کرد و هر رویکرد ممکن است جزء دسته‌ای منحصر به فرد یا چند دسته باشد. دسته‌های تشخیص راه و برخی مطالعات در این زمینه، در شکل ۸، به صورت سری زمانی آورده شده و در ادامه، توضیح داده شده‌اند.

از آنجاکه میزان و تعداد تحقیقات در این حوزه، با توجه به اهمیت آن، بسیار زیاد است و امکان مرور همه آنها در پژوهش پیش رو وجود ندارد، فقط تعدادی از آنها، به صورت نمونه، توضیح داده شده‌اند تا به‌طور کلی، روند توسعه روش‌ها شناسایی شود؛ همچنین به برخی بررسی‌ها




شکل ۷. برخی روش‌های سوپرزولوشن، طبق دو دسته کلی مبتنی بر رویکرد سنتی و یادگیری عمیق

منبع: Chang et al., 2004; Chen et al., 2023a; Daihong et al., 2022; Emad et al., 2021; Freedman & Fattal, 2011; Galar Idoate et al., 2019; Gonzalez & Woods, 2006; He & Siu, 2011; Huang et al., 2015; Irani & Peleg, 1991; Kim & Kwon, 2010; Kim et al., 2020; Köhler et al., 2020; Lan et al., 2020; Lanaras et al., 2018; Lim et al., 2017; Polatkan et al., 2014; Purkait & Chanda, 2013; Soufi & Belouadha, 2023; Sun et al., 2008; Timofte et al., 2013; Wang et al., 2018; Zabalza & Bernardini, 2022; Zeyde et al., 2012; Zhang et al., 2020; Zhang et al., 2022; Zhao et al., 2015

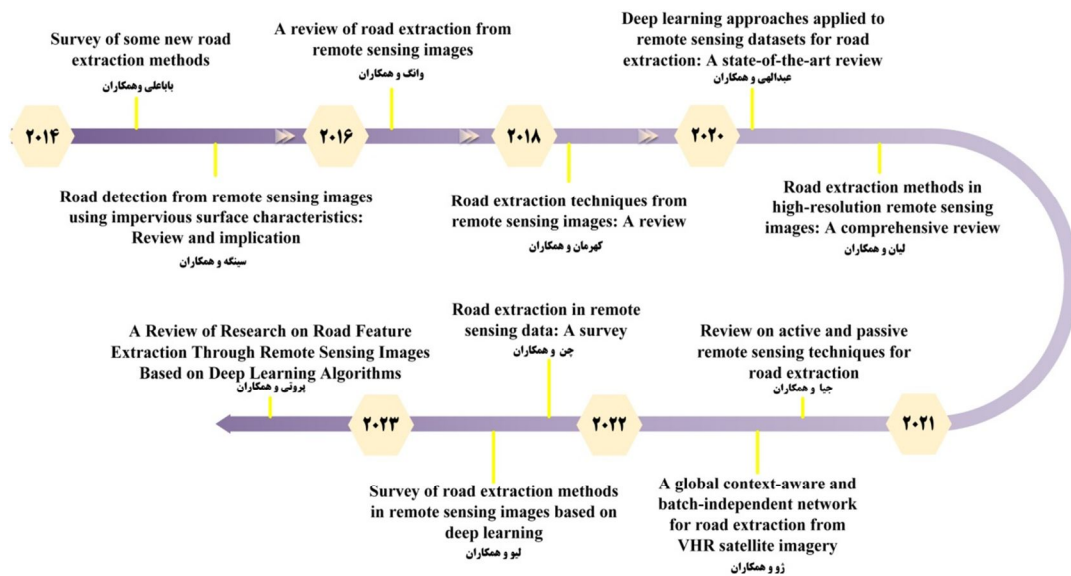
1. Shahi
2. Road Extraction Index
3. Built-Up Area Index

بیشتری را جاده در نظر بگیرد و به علاوه، این شاخص توانایی شناسایی راه‌های خاکی و شسته را ندارد.

علاوه بر این، این شاخص طیفی یک مرکز ساختمان را به اشتباه طبقه‌بندی کرد؛ این خطا می‌تواند، در تصاویر با حد تفکیک مکانی پایین، ساختمان‌های نزدیک به هم



شکل ۸. روند پیشرفت زمانی برخی مطالعات در زمینه تشخیص شبکه راه



شکل ۹. برخی بررسی‌های انجام‌شده در زمینه تشخیص شبکه راه

منبع: Abdollahi et al., 2020a; Babaali et al., 2014; Chen et al., 2022c; Jia et al., 2021; Kahraman et al., 2018; Lian et al., 2020; Liu et al., 2022; Pruthi & Dhingra, 2023; Singh & Garg, 2014; Wang et al., 2016; Winiwarter et al., 2024; Zhang et al., 2024a; Zhu et al., 2021; Zhu et al., 2024

گریناس<sup>۳</sup> و همکاران (۲۰۱۶) الگوریتم قطعه‌بندی جدیدی را براساس مدل میدان تصادفی مارکوف (MRF)<sup>۴</sup> و تحلیل داده‌های گسترده، برای تعیین ویژگی‌های مرتبط به مشکل طبقه‌بندی، مطرح کردند. در رویکرد پیشنهادی که عملیات به صورت خودکار و در مقیاس بزرگ شیء‌مبنا<sup>۵</sup> است، جاده‌ها و ساختمان‌ها به طور خودکار و مشترک، از تصاویر ماهواره‌ای دارای وضوح بالا استخراج و با استفاده از ویژگی‌های مبتنی بر شیء، شامل نشانه‌های بصری و شکل، شناسایی می‌شوند. در مرحله قطعه‌بندی، بخش‌های روستایی مناطق حاشیه شهری به جز جاده‌های روستایی، شناسایی و حذف می‌شود و طبقه‌بندی اولیه مناطق شهری باقی می‌ماند. به دنبال آن، قطعه‌بندی مبتنی بر MRF به استخراج مناطق یا اشیا، فقط در آن مناطق، منجر می‌شود. از آنجاکه روش مورد استفاده یک قطعه‌بندی نظارت‌نشده است، به اندازه روش‌های نظارت‌شده مانند روش‌های مبتنی بر شبکه‌های عصبی، نمی‌توان به آن اعتماد کرد.

احمد<sup>۱</sup> و همکاران (۲۰۲۲) روشی را براساس ترکیب شاخص جاده<sup>۲</sup> و عملگری مورفولوژیکی با نام Bot-Hat مطرح کردند. وظیفه این عملگر برجسته کردن ویژگی‌های جاده و سرکوب ویژگی‌های اطراف آن بود. روش پیشنهادی روی داده‌های سنتینل-۲، در دو منطقه مجزای لاهور و ریچموند، اعمال شد و FI-Score این مناطق، به ترتیب، ۰/۷۶/۱۰ و ۰/۸۳/۸۱ به دست آمد. براساس نتایج، مشاهده می‌شود که جاده‌های مجاور پوشش‌های گیاهی مرتفع و زمین‌های بایر با دقت بیشتری استخراج شده‌اند. به دلیل استفاده چند الگوریتم، همانند شاخص جاده، طبقه‌بندی و عملگر مورفولوژیکی، در انتها، خطای تجمعی روش پیشنهادی مقدار بزرگی به خود می‌گیرد و زمان زیادی صرف پردازش می‌شود؛ بنابراین بهتر است از مراحل کمتری در روش تشخیص راه‌ها استفاده شود. به منظور جمع‌بندی، خلاصه بررسی‌های انجام‌شده در تشخیص راه، براساس شاخص راه، در جدول ۱ آمده است.

جدول ۱. خلاصه بررسی‌های انجام‌شده در تشخیص راه، براساس شاخص راه

منبع	معایب	مزایا	داده	روش پیشنهادی
Shahi et al., 2015	• تشخیص مرز ساختمان به منزله جاده فقط جاده‌های آسفالتی را تشخیص می‌دهد	• طبقه‌بندی سریع داده به راه و غیرراه • تشخیص جاده‌های آسفالتی، با دقت بالا	تصاویر WorldView-2	REI
Reddy et al., 2019	• در تشخیص بخش‌های کم‌عرض و راه‌های کنار ساختمان و درخت‌ها دچار مشکل می‌شود	• سرعت بالا در تشخیص راه	تصاویر لندست-۸ OLI	NDARI
Ahmed et al., 2022	• بالا بودن تعداد مراحل در تشخیص راه باعث افزایش خطای تجمعی می‌شود	• طبقه‌بندی سریع داده به راه و غیرراه • جاده‌های مجاور پوشش‌های گیاهی مرتفع و زمین‌های بایر با دقت بیشتری استخراج می‌شوند	تصاویر سنتینل-۲	RI

1. Ahmed
2. Road Index (RI)
3. Grinias
4. Markov Random Field Model
5. Object\_Based Image Analysis (OBIA)



می‌کند و به همین دلیل، قادر به استخراج پیکسل‌های جاده‌های پوشانده شده با درختان است اما، باینکه این مشکل را حل می‌کند، برخی از پیکسل‌های مربوط به درختان نزدیک جاده‌ها را به منزله پیکسل جاده برچسب‌گذاری می‌کند و در نتیجه، وضوح لبه‌های جاده‌ها تحت تأثیر قرار می‌گیرد.

به منظور جمع‌بندی، خلاصه بررسی‌های انجام شده در تشخیص راه براساس قطعه‌بندی، در جدول ۲ آمده است.

بختیاری<sup>۱</sup> و همکاران (۲۰۱۷) روشی نیمه خودکار را برای تشخیص جاده‌ها، در تصاویر ماهواره‌ای با وضوح بالا WorldView و QuickBird و تصاویر هوایی UltraCam مطرح کردند؛ عملکرد آن براساس چهار مرحله اصلی است. در مرحله اول، الگوریتم تشخیص لبه Canny برای جداسازی جاده‌ها از تصاویر استفاده می‌شود. در مرحله دوم، روش ادغام کامل Lambda Schedule برای ترکیب بخش‌های مجاور اعمال می‌شود. در سومین مرحله، ماشین بردار پشتیبان برای طبقه‌بندی کل تصویر به کار می‌رود و در نهایت، روش عملیات مورفولوژیکی، مانند تکنیک‌های erosion, dilation, opening و closing برای حذف اجسام نامطلوب استفاده می‌شود. با این روش، میانگین دقت کلی بیش از ۸۱٪ و میانگین ضریب کاپای بیش از ۷۸٪، در طبقه‌بندی تصویر به دو کلاس غیرجاده‌ای و جاده‌ای، به دست آمد که نشان‌دهنده موفقیت روش پیشنهادی است. اما درعین حال دارای محدودیت در تشخیص راه‌های با پیچیدگی زیاد (مارپیچ و تقاطع) است؛ بدین صورت که با افزایش پیچیدگی‌ها، دقت آن کاهش می‌یابد.

غندوره<sup>۱</sup> و همکاران (۲۰۲۲)، با استفاده از تشخیص لبه و قطعه‌بندی شماتیک برپایه یادگیری عمیق، ساختاری را معرفی کردند. این ساختار از یک رمزگذار<sup>۲</sup> ترکیبی استفاده می‌کند که به دو بخش تقسیم می‌شود: بخش اول ویژگی‌ها را با وضوح کامل استخراج و بخش دوم کدگذاری ویژگی با وضوح بالا را تولید می‌کند. در بخش دوم از لایه‌های max-pooling برای افزایش میدان دریافت کلی شبکه استفاده می‌شود و اطلاعات زمینه‌ای کافی برای کار با آن را در اختیار شبکه قرار می‌دهد. قبل از اینکه ویژگی‌های هر دو بخش با هم اضافه شوند، یک نقشه فعال‌سازی دوبعدی برای هر بخش ایجاد می‌شود و به شبکه اجازه می‌دهد میزان توجهی را که به ویژگی‌ها از هر مرحله رمزگذار معطوف می‌شود، انتخاب کند. این مسئله تقسیم‌بندی جاده‌های بزرگ و تولید ماسک‌های تقسیم‌بندی لبه‌های ظریف را تسهیل می‌کند و به این علت که عملکرد ماژول تشخیص لبه به عملکرد قطعه‌بندی بستگی بسیار دارد، ویژگی‌ای ضروری است. داده‌های دارای کیفیت خوب و کلاس‌های متعادل به اندازه ساختار شبکه مهم‌اند. در مورد این تحقیق، کلاس‌ها بسیار نامتعادل‌اند؛ بنابراین با توابع از دست دادن متقابل آنتروپی وزنی و توابع از دست دادن Tversky بررسی شده و نشان داده‌اند که ترکیب این دو می‌تواند عملکرد آموزش شبکه را در موقعیتی بسیار نامتعادل (داده‌های آموزشی نامگن و کم‌کیفیت)، افزایش دهد.

آرورا<sup>۳</sup> و همکاران (۲۰۲۳) شبکه‌ای متراکم، با اتصالات پرش وزنی<sup>۴</sup> را برای تقسیم‌بندی جاده‌ها براساس تصاویر ماهواره‌ای دارای وضوح بالا، پیشنهاد کردند. این شبکه با حل یک مسئله کنترل بهینه کسری<sup>۵</sup> طراحی شده و شامل مجموع وزنی خروجی لایه‌های پیشین در انتقالی خاص است (برخلاف شبکه‌های متراکم اصلی که خروجی لایه‌های قبلی به هم متصل می‌شود)؛ بنابراین کارآمدی روش پیشنهادی، از نظر محاسباتی، بیشتر از روش‌های هم‌تراز است. مدل پیشنهادی اطلاعات محلی و جهانی را هم‌زمان بررسی

1. Ghandorh
2. Encoder
3. Arora
4. Heavy Weight Connections
5. Fractional Optimal Control
6. Bakhtiari

جدول ۲. خلاصه بررسی‌های انجام‌شده در تشخیص راه، براساس قطعه‌بندی

منبع	معایب	مزایا	داده	روش پیشنهادی
Grinias et al., 2016	• قطعه‌بندی نظارت‌نشده • هزینه بالا در تهیه داده‌ها	• سرعت بالا در تشخیص راه‌ها • نیاز نداشت به داده‌های آموزشی	تصاویر ماهواره‌ای با وضوح بالا	MRF
Ghandorh et al., 2022	• هزینه بالا در تهیه داده‌ها • وابستگی بین تشخیص لبه و قطعه‌بندی	• افزایش عملکرد آموزش شبکه • به دلیل استفاده از دو LossFunction • آنتروپی وزنی و Tversky	تصاویر ماهواره‌ای با وضوح بالا	قطعه‌بندی و تشخیص لبه شماتیک
Arora et al., 2023	• برخی پیکسل‌های مربوط به درختان نزدیک جاده‌ها را با عنوان پیکسل جاده برچسب‌گذاری می‌کند	• از نظر محاسباتی، کارآمدی بیشتری در قیاس با روش‌های هم‌تراز دارد • رویکرد پیشنهادی اطلاعات محلی و جهانی را هم‌زمان بررسی می‌کند؛ به همین دلیل، قادر به استخراج پیکسل‌های جاده‌های پوشانده‌شده با درختان است	• MRD (Mnih, 2013) • ORD (Liu et al., 2018) • تصاویر ماهواره‌ای با وضوح بالا	شبکه متراکم همراه با حل کنترل بهینه کسری

آنها براساس آزمایش‌هایی به دو نتیجه اصلی رسیده‌اند؛ نخست، مدل MLP به دقیق‌ترین طبقه‌بندی در قیاس با دیگر روش‌های مورد استفاده، دست می‌یابد. دوم، پیش‌آموزش بدون نظارت با استفاده از رمزگذارهای خودکار (RAE<sup>۱</sup>، SAE<sup>۲</sup> و AE<sup>۳</sup>) به بهبود نتیجه طبقه‌بندی منجر نمی‌شود. تفاوت اندکی که در دقت طبقه‌بندی MLP در مقایسه با مدل‌های دیگر، مانند طبقه‌بندی‌کننده‌های SVM و GB<sup>۴</sup>، وجود دارد بیان می‌کند که دیگر طبقه‌بندی‌کننده‌های پیشرفته یادگیری ماشین هنوز اعتماد لازم را جلب می‌کنند تا بتوانند نقشه‌برداری از مناظر پیچیده را انجام دهند.

جانگ و همکاران (۲۰۲۱)، برای بهینه‌سازی روش طبقه‌بندی RF<sup>۱</sup>، با استفاده از بهینه‌ساز Bayesian

جانگ<sup>۱</sup> و همکاران (۲۰۱۹) طبقه‌بندی کاربری/پوشش زمین و تشخیص تغییر مناطق شهری را براساس تصاویر سنجنش از دور با وضوح بسیار بالا<sup>۲</sup>، با استفاده از روش‌های مبتنی بر یادگیری عمیق، بررسی می‌کند. در این رویکرد پیشنهادی، شبکه عصبی (FACNN) برای یادگیری طبقه‌بندی پوشش زمین، معرفی و روی داده‌های سال‌های ۲۰۱۴ و ۲۰۱۷ شهر ووهان (چین) از سنجنده Beijing-2 اعمال می‌شود. نتایج نشان می‌دهد که روش پیشنهادی با دقت کلی مورد قبول ۰/۷۴۳، توانسته راه‌ها و ریل‌ها را طبقه‌بندی کند. این رویکرد به دلیل استفاده از تصاویر دارای وضوح بسیار بالا و تعداد کلاس‌های انتخابی بالا، عملکرد بهینه ندارد و باعث افزایش زمان پردازش می‌شود اما، به دلیل استفاده از سه باند RGB، می‌تواند این مشکل را حل کند و بسیاری از تصاویر سازگاری داشته باشد.

جوزدانی<sup>۳</sup> و همکاران (۲۰۱۹) بین معماری‌های متفاوت DNN<sup>۴</sup>، یعنی پرسپترون چندلایه عمیق منظم (MLP)<sup>۵</sup> و شبکه‌های عصبی کانولوشن و دیگر موارد، و SVM به منظور بررسی پتانسیل آنها برای نقشه‌برداری مناطق شهری، مقایسه‌ای تجربی انجام دادند.

1. Zhang
2. Very High Resolution (VHR)
3. Jozdani
4. Deep Neural Network
5. Regular Deep MultiLayer Perceptron
6. Regular AutoEncoder
7. Sparse AutoEncoder
8. variational AutoEncoder
9. Gradient Boosting Trees
10. Random Forest

کردند. برای آزمودن عملکرد آن، از مجموعه داده‌های پوشش زمین پیچیده خودساخته، مبتنی بر تصاویر GaoFen-5 AHSI، بهره بردند؛ این داده‌ها شامل مناظری می‌شود که ترکیبی از مناطق معدنی و کشاورزی حاشیه شهری- روستایی است. مدل پیشنهادی به دقت کلی  $0.96/0.9$ ، مقدار کاپا با  $0.79/0.41$ ، امتیاز F1 با  $0.85/0.86$  و میانگین دقت  $0.82/0.30$  دست یافت و بدین ترتیب مشخص شد که JAGAN می‌تواند، در بهبود طبقه‌بندی، مؤثرتر از مدل‌هایی مانند SVM و KNN باشد. در ضمن، در این مطالعه، بهترین دقت به کلاس راه‌ها تعلق داشت که گویای ظرفیت استفاده این مدل در شناسایی شبکه راه‌هاست.

به منظور جمع‌بندی، بررسی‌های انجام‌شده برای تشخیص راه براساس کلاسه‌بندی، به صورت مختصر در جدول ۳ آمده است.

پژوهشی انجام داده‌اند. در این مطالعه، روش پیشنهادی با روش‌های RF و SVM مقایسه و در دو حالت سه باند RGB و تمامی دوازده باند آزمایش شده است. نتایج به دست آمده دقت  $0.95/0.5$  و بازخوانی  $0.88/0.9$ ، برای طبقه‌بندی راه در حالت استفاده از دوازده باند را نشان می‌دهد که بیشتر از روش‌های مورد مقایسه است. بنابراین انتظار می‌رود طبقه‌بندی‌کننده تصادفی جنگل توسعه یافته، با بهینه‌سازی فرآیند بیزی، عملکرد بهتر طبقه‌بندی پوشش اراضی شهری را ارائه دهد تا بتوان مدیریت شهری را به شیوه‌ای دقیق‌تر به دست آورد. در همین حال، با داشتن مجموعه داده آموزشی مناسب، این روش می‌تواند طیف گسترده‌ای از کاربردها را در مدیریت منابع زمین، مدیریت راه‌ها و کاربردهای کشاورزی پیدا کند.

چن<sup>۱</sup> و همکاران (۲۰۲۲b) ساختار شبکه‌ای عصبی را به منظور طبقه‌بندی، بررسی و با نام JAGAN مطرح

جدول ۳. بررسی‌های انجام‌شده برای تشخیص راه براساس کلاسه‌بندی به صورت مختصر

منبع	معایب	مزایا	داده	روش پیشنهادی
Bakhtiari et al., 2017	• محدودیت در تشخیص راه‌های با پیچیدگی زیاد؛ • هزینه بالای داده‌های مورد استفاده	• سرعت بالا در تهیه نقشه؛ • هزینه پایین محاسباتی؛	• WorldView • QuickBird • تصاویر هوایی UltraCam	• Canny + SVM
Zhang et al., 2019b	• هزینه بالای داده‌های مورد استفاده • بهینه نبودن در تعداد طبقات؛	• به دلیل استفاده از RGB می‌تواند با تصاویر زیادی سازگاری داشته باشد	Beijing-2	FACNN
Jozdani et al., 2019	• هزینه بالای داده‌های مورد استفاده	• مورد اعتماد بودن در نقشه‌برداری از مناظر پیچیده؛ • بررسی روش‌های متفاوت	IKONOS	• SVM • DNN • MLP
(Zhang et al., 2021)	• رزولوشن پایین داده‌های مورد استفاده	• استفاده از داده‌های رایگان • سرعت پایین در آموزش؛ • بررسی تأثیر تعداد باندها	تصاویر سنتینل-۲	Optimized RF
Chen et al., 2022b	• هزینه بالای داده‌های آموزشی؛ • هزینه بالای داده‌های مورد استفاده	• طبقه‌بندی راه‌ها با دقت بالا؛ • تشخیص راه‌های دارای پیچیدگی	GaoFen-5 AHSI	JAGAN

استخراج کردند تا دریابند الگوریتم استخراج این داده‌ها از تصاویر ماهواره‌ای دارای وضوح متوسط تا چه اندازه دقیق است و چگونه می‌توان، برای گردآوری اطلاعات جاده‌های جدیدی که در نسخه‌های RBI فعلی وجود ندارند، از آن استفاده کرد. این مطالعه روی تصاویر ماهواره سنتینل-۲ انجام شده و داده‌های GPS نرم‌افزار مسیریابی GRAB، به منزله داده‌های آموزشی و واقعیت زمینی<sup>۹</sup>، به کار رفته است. براساس نتایج، مدل آموزش دیده با دقت بسیار بالا ۰/۹۹۷ و softmax loss فقط ۰/۰۰۵ است. داده‌های GPS نیز ماسک حقیقت زمینی بسیار خوبی را برای آموزش داده‌های با ارزش loss اندک و کیفیت بالا به دست می‌دهند. باین حال باید وضوح تصویر و دقت داده‌های GPS را در نظر داشت؛ این داده‌ها ممکن است برای به‌روزرسانی نقشه‌های ۱:۲۵۰۰۰ کافی باشد اما، برای تهیه یا به‌روزرسانی نقشه‌های دقیق‌تر، باید از تصاویر دارای وضوح بیشتر بهره برد.

لو<sup>۱۰</sup> و همکاران (۲۰۲۳) شبکه استخراج جاده‌ای، با رمزگشایی کمکی به نام AD-RoadNet<sup>۱۱</sup> را پیشنهاد می‌کنند که نمایش جاده‌ای در مقیاس چندگانه و بهبود اتصال را براساس دو ماژول، جدا می‌کند؛ ماژول میدان گیرنده ترکیبی (HRFM)<sup>۱۲</sup> و ماژول نمایش ویژگی توپولوژیکی (TFRM)<sup>۱۳</sup>. در رمزگذار معرفی شده است تا، با تطبیق اندازه میدان گیرنده RF برای جاده‌های دارای مقیاس‌های متفاوت، بر ویژگی‌های جاده هدف تأکید کند. TFRM در

گائو<sup>۱</sup> و همکاران (۲۰۱۹)، برای استخراج راه از تصاویر ماهواره‌ای دارای رزولوشن بالا، روشی را مطرح کرده‌اند که با استفاده از شبکه‌ای عصبی با ساختار RDRCNN<sup>۲</sup>، راه‌ها را تشخیص می‌دهد و در گام پس‌پردازش، از عملیات مورفولوژی ریاضی و یک الگوریتم رأی‌گیری تنسور<sup>۳</sup> برای بهبود عملکرد آن استفاده می‌شود. مرحله پس‌پردازش برای رفع نواقصی مانند راه‌هایی به کار رفته که به‌هردلیل (مانند وجود سایه و یا پوشش گیاهی)، شبکه عصبی آنها را به‌صورت کامل تشخیص نداده است. در نهایت، شیوه مطرح شده با روش‌های CNN، UNet و RDRCNN مقایسه شد که به ترتیب، دارای دقت کلی ۹۸/۵۰٪، ۹۷/۵۶٪، ۹۷/۵۳٪ و ۹۸/۱۳٪ بوده‌اند. شایان ذکر است که روش پیشنهادی، با F1-Score ۹۹/۶۵٪، بهترین عملکرد را در قیاس با دیگر روش‌ها داشته است. تصاویر ماهواره‌ای دارای رزولوشن بالا به‌رغم مزایای فراوانشان، به دلیل تجاری بودن، هزینه زیادی دارند و دسترسی به آنها دشوار است.

عبداللهی<sup>۴</sup> و همکاران (۲۰۲۰b) شبکه کانولوشنی مبتنی بر یادگیری عمیق، با نام مدل VNet را برای تولید نقشه جاده‌ای با وضوح بالا، معرفی کردند. علاوه بر این، تابع تلفات دوگانه جدیدی را با نام متقاطع آنتروپی-تاس-از دست دادن (CEDL)<sup>۵</sup> تعریف کردند که آنتروپی متقاطع (CE)<sup>۶</sup> و تلفات تاس (DL)<sup>۷</sup> را ترکیب می‌کند و اطلاعات محلی و اطلاعات جهانی را برای کاهش تأثیر تعادل نداشتن کلاس‌ها و بهبود نتایج استخراج جاده، در نظر می‌گیرد. پس از ارزیابی دقت رویکرد پیشنهادی VNetCCEDL به میانگین دقت ۹۰/۶۴٪ در مورد مجموعه داده ماساچوست و ۹۲/۴۱٪ در مورد مجموعه داده اتاوا دست یافت. روش پیشنهادی با تکنیک‌های پیشرفته استخراج جاده مقایسه شد و نتایج ثابت کرد که این تکنیک، در استخراج جاده، عملکردی بهتر از دیگر تکنیک‌های هم‌رده مبتنی بر یادگیری عمیق دارد.

یانواری و اوتامی<sup>۸</sup> (۲۰۲۲)، با استفاده از الگوریتم CNN با ساختار UNet، داده‌های شبکه جاده‌ای را

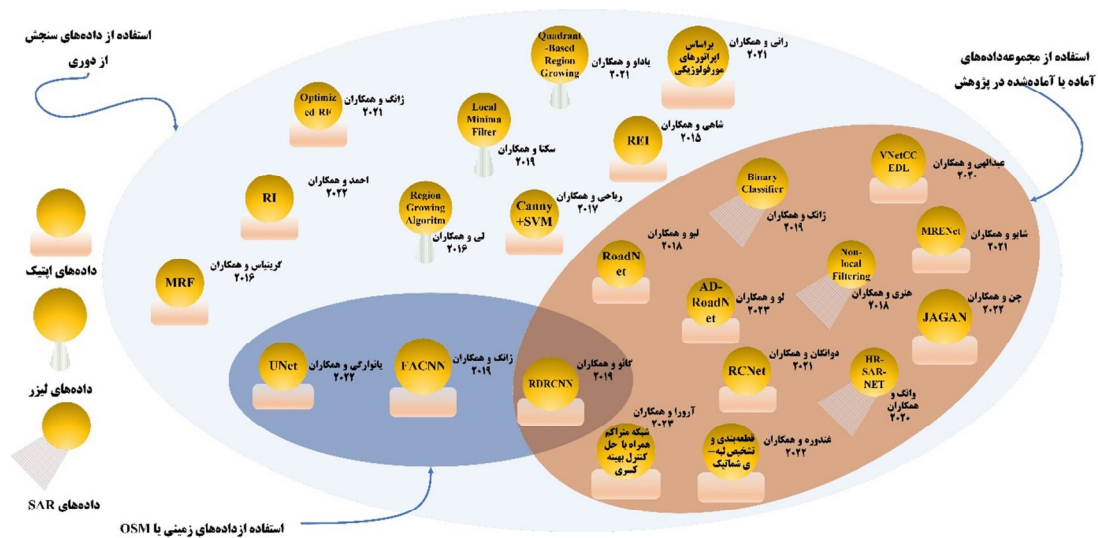
1. Gao
2. Refined Deep Residual Convolutional Neural Network
3. Tensor Voting Algorithm
4. Abdollahi
5. Cross-Entropy-Dice-Loss
6. Cross-Entropy
7. Dice Loss
8. Yanuargi & Utami
9. Ground Truth
10. Luo
11. Auxiliary-Decoding Road Extraction Network
12. Hybrid Receptive Field Module
13. Topological Feature Representation Module

رمزگشایی کمکی، برای نشان دادن ویژگی‌های توپولوژیکی با اطلاعات موقعیت رمزگذاری شده در رمزگذار مشترک معرفی شده است؛ در مسدود کردن جاده‌ها به رمزگشای اصلی کمک می‌کند و بنابراین ارتباط بین رمزگذار و رمزگشای اصلی را بهبود می‌بخشد. ماژول اضافه شده می‌تواند عملکرد شبکه را با کاهش FT و افزایش تداوم و همواری جاده

استخراج شده، بهبود بخشد؛ بدین ترتیب از قطعه قطعه شدن راه جلوگیری می‌کند. به منظور جمع‌بندی، خلاصه بررسی‌های انجام شده در تشخیص راه براساس یادگیری ماشین در جدول ۴ آمده است. در پی این بررسی‌ها، مطالعات حوزه تشخیص راه را می‌توان براساس داده‌های به‌کاررفته در پژوهش، به صورت شکل ۱۰ ارائه کرد.

جدول ۴. خلاصه بررسی‌های انجام شده برای تشخیص راه، براساس یادگیری ماشین

منبع	معایب	مزایا	داده	روش پیشنهادی
Wei et al., 2019	هزینه بالای داده‌های مورد استفاده	• استفاده از رأی‌گیری تنسوری برای تکمیل نواقص راه‌های تشخیص داده شده؛ داشتن عملکرد بهتر از روش‌های UNet و CNN	تصاویر ماهواره‌ای با رزولوشن بالا	RDRCNN
Abdollahi, Pradhan, & Alamri, 2020b	استفاده از تصاویر Google Earth	• کاهش تأثیر تعادل نداشتن کلاس؛ سرعت بالا در شناسایی راه‌ها	• Massachusetts dataset (Mnih, 2013) Liu et al., Ottawa dataset 2018	VNetCCEDL
Shao et al., 2021	• هزینه بالای داده‌های مورد استفاده در صحنه‌های شهری پیچیده بررسی نشده است	• خطوط مرکزی جاده را ایجاد می‌کند؛ شبکه طراحی شده می‌تواند زمینه دریافت را گسترش دهد، ویژگی‌های چندسطحی را یکپارچه کند و به آموزش دیدن شبکه با اطلاعات فراوان حاوی ویژگی‌های جاده‌ها منجر شود	تصاویر ماهواره‌ای با رزولوشن بالا	MRENet
Yanuari & Utami, 2022	• دقت پایین داده‌های GPS نرم‌افزار مسیریابی حد تفکیک مکانی اندک تصاویر سنتینل-۲	• داده‌های رایگان؛ • کافی بودن برای به‌روزرسانی نقشه‌های ۱:۲۵۰۰۰؛ ساختار ساده برای شبکه مورد استفاده	• داده‌های GPS نرم‌افزار مسیریابی GRAB • تصاویر سنتینل-۲	UNet
Luo et al., 2023	استفاده نکردن از تصاویر خام ماهواره‌ای	بهبود تداوم و همواری جاده استخراج شده در قیاس با روش‌های هم‌تراز	• Massachusetts dataset (Mnih, 2013) • The DeepGlobe road (Tao et al., 2019) dataset	AD-RoadNet



شکل ۱۰. دسته‌بندی مطالعات تشخیص راه بر اساس اطلاعات ورودی به سیستم

برای آموزش شبکه عصبی تشخیص راه‌هاست. برای حل این مشکل می‌توان نرم‌افزارهای در دسترس، همانند Google Earth را به کار برد و داده‌های آموزشی را به صورت دستی تولید کرد و یا از داده‌های آماده، همچون OSM، بهره برد. البته انتخاب داده‌های آموزشی، با توجه به دقت مورد نیاز، چه بسا چالش برانگیز یا ساده باشد.

با مراجعه به مطالعات انجام‌شده در بخش تشخیص شبکه راه‌ها، داده‌های مورد استفاده معمولاً تصاویر با حد تفکیک مکانی بالا و بسیار بالاست تا بتوان به دقت مدنظر رسید؛ اما این داده‌ها به صرف هزینه بسیاری نیاز دارد. علاوه بر این، دسترسی به این داده‌ها در ایران با مشکلاتی همراه است. از این‌رو، در برخی موارد، از تصاویر با حد تفکیک مکانی متوسط و دسترسی رایگان استفاده شده است اما، به دلیل رزولوشن اندک، توانایی تشخیص راه‌های کم‌عرض وجود ندارد؛ بنابراین باید روش‌هایی را مدنظر داشت که با استفاده از آنها بتوان، با تصاویر رایگان، به حد تفکیک مکانی خوب دست یافت. به همین دلیل، این کار با استفاده از روش سوپررزولوشن انجام شد تا تصویری با رزولوشن متوسط رایگان به تصویری دارای رزولوشن بالا تبدیل شود.

با توجه به بررسی‌های این پژوهش، تشخیص شبکه راه با استفاده از چهار دسته اصلی قطعه‌بندی و تشخیص لبه، شاخص راه، کلاسه‌بندی شامل استفاده از روش‌های مبتنی بر یادگیری ماشین انجام می‌شود. در بین این رویکردها، روش‌های شاخص راه و قطعه‌بندی و تشخیص لبه می‌تواند با سرعت بالا، هزینه و محاسبات اندک، شبکه راه‌ها را تشخیص دهد اما دقت حاصل از این روش‌ها آن اندازه نیست که بتوان به آنها در کارهای دقیق بسنده کرد. در ادامه، روش‌های کلاسه‌بندی وارد عمل می‌شوند که برای اطمینان بیشتر از شبکه راه‌های تشخیص داده‌شده، راه‌حل مناسبی محسوب می‌شوند. دو رویکرد قطعه‌بندی و کلاسه‌بندی را می‌توان برپایه شبکه‌های عصبی طرح‌ریزی کرد؛ این کار تا حد بسیاری سبب افزایش سطح اطمینان به موارد تشخیص داده‌شده می‌شود. البته باید در نظر داشت که شبکه‌های عصبی گاه برای موردی خاص، مانند تشخیص راه، به کار می‌روند؛ این رویکرد، به دلیل اینکه اختصاصاً برای یک موضوع در نظر گرفته شده است، می‌تواند دقت محصول نهایی و اطمینان به آن را افزایش چشمگیر دهد.

یکی از مشکلات این حوزه در دسترس نبودن داده‌های آموزشی دارای دقت بالا و کارایی مناسب،

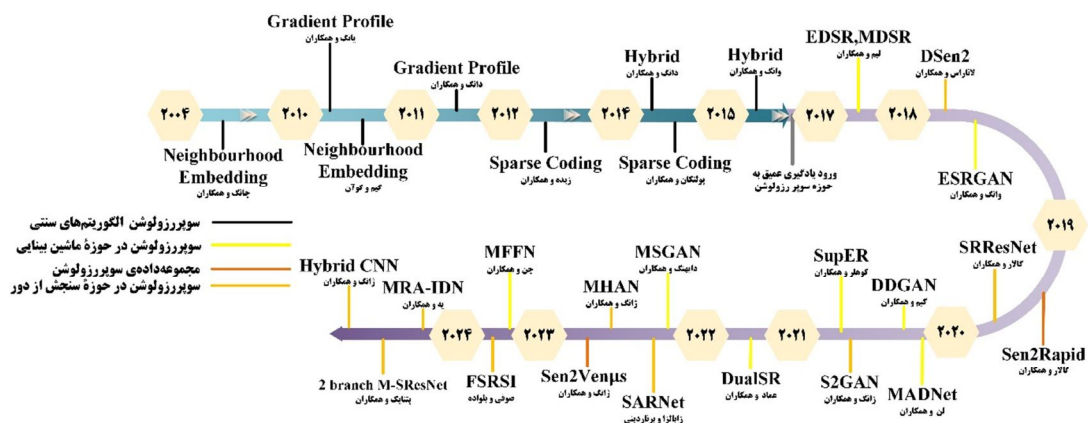


در ادامه، مطالعات انجام شده بررسی می‌شود؛ بدین صورت که ابتدا مطالعات در حوزه ماشین بینایی سپس سنجش‌ازدوری و در انتها، مجموعه داده‌های آماده شده برای انجام دادن سوپررزولوشن در حوزه سنجش‌ازدوری مطرح می‌شود.

در حوزه ماشین بینایی در ابتدا، گتیس<sup>۱</sup> و همکاران (۲۰۱۵) در مورد انتقال شبکه عصبی از شبکه‌های عصبی کانولوشنی استفاده کردند تا کیفیت هنری تصویری را با تصویری دیگر ترکیب کنند. شیه<sup>۲</sup> و همکاران (۲۰۱۲) شبکه‌ای عصبی را برای بازسازی تصاویر با پچ‌های گم شده، مانند تصاویر قدیمی پاره شده، پیشنهاد کردند. افزون‌براین، مسیر یادگیری ماشین شاهد افزایش اتوماسیون بوده است. به همین صورت، در حوزه سوپررزولوشن تک‌تصویر، استفاده از شبکه‌های عصبی عمیق افزایش خارق‌العاده‌ای را در کیفیت ادراکی تصویر تولید شده دربر داشته است. دنگ<sup>۳</sup> و همکاران (۲۰۱۴) مشخص کردند روش‌های پیشرفته قبلی، مانند نمایش پراکنده، مورد خاصی از شبکه عصبی کانولوشنال سه‌لایه آنهاست. پژوهش آنها همچنین مشخص کرد که روش‌های سنتی، در زمینه وضوح تصویر فوق‌العاده، بهینه نیستند.

## ۲-۳- مشخصات مطالعات سوپررزولوشن تک‌تصویر

سوپرزولوشن، به طور کلی، در پی افزایش دقت تفکیک مکانی است؛ ضمن اینکه بر آن است تا ویژگی‌های طیفی تصویر را حفظ کند. سوپررزولوشن را می‌توان، از لحاظ عملکرد، بر اساس روش‌های سنتی و مبتنی بر یادگیری عمیق در نظر گرفت و همچنین از نظر کاربرد، به ساختارهای به کاررفته در حوزه سنجش‌ازدوری و حوزه ماشین بینایی دسته‌بندی کرد. در ضمن، باید در نظر داشت که هر یک از روش‌ها ممکن است دارای ساختار منحصر به فرد یا مشترک با حوزه‌های دیگر باشد. برخی مطالعات، در شکل ۱۱ به صورت سری زمانی و دسته‌بندی شده، مشاهده می‌شود. سوپررزولوشن اغلب در زمینه ماشین بینایی و پردازش تصویر بررسی شده (Freeman et al., 2002) اما برای سوپررزولوشن تک‌تصویر، یعنی افزایش وضوح مکانی تصویری واحد (RGB) با کمک آموخته‌های قبلی از مجموعه‌ای آموزشی، مناسب است. ظهور یادگیری عمیق سبب شده است سوپررزولوشن تک‌تصویر پیشرفت‌های چشمگیری داشته باشد (Kim et al., 2016; Lim et al., 2017). افزون‌براین، روش مذکور به حوزه سنجش از دور نیز راه یافته و به محققان این بخش، کمک شایانی کرده است.



شکل ۱۱. برخی مطالعات انجام شده در سوپررزولوشن

منبع: bPatnaik et al., 2024; Ye et al., 2024; Zhang et al., 2024

1. Gatys
2. Xie
3. Dong

همبستگی ویژگی‌ها، پیشنهاد کردند. در این شبکه، به‌طور ویژه، ماژول چندمقیاسی باقی‌مانده‌ای با مکانیسم توجه (RMAM)<sup>۱۱</sup>، برای افزایش توانایی نمایش ویژگی‌های چندمقیاسی آموزنده، توسعه یافته است. همچنین بلوک مسیر باقی‌مانده دوگانه‌ای (DRPB)<sup>۱۲</sup> مطرح شده است که ویژگی‌های سلسله‌مراتبی تصاویر دارای وضوح پایین اصلی را به کار می‌برد. نتایج مقایسه‌ای عملکرد برتر مدل MADNet را نشان می‌دهد؛ درحالی‌که از چند افزوده و پارامترهای بسیار کمتری استفاده می‌کند.

دایهنگ<sup>۱۳</sup> و همکاران (۲۰۲۲)، برای حل چالش بازسازی اطلاعات و جزئیات با فرکانس بالا در تصویر دارای وضوح پایین که شبکه کانولوشن عمیق ارائه می‌دهد، شبکه متخاصم مولد چندمقیاسی (MSGAN)<sup>۱۴</sup> را پیشنهاد کردند. در این روش، ماژول هرم چندمقیاسی داخل ژنراتور می‌تواند ویژگی‌های حاوی اطلاعات فرکانس بالا را استخراج کند که در پی آن، تصویر دارای وضوح بالا، با نتایج bicubic interpolation، بازسازی می‌شود. در مقایسه با الگوریتم‌های مبتنی بر شبکه‌های کانولوشن ساده، الگوریتم پیشنهادی در دو شاخص PSNR<sup>۱۵</sup> و SSIM<sup>۱۶</sup> بهتر عمل می‌کند. این رویکرد باعث می‌شود در تصاویر دارای الگوهای تکراری، همانند نمای ساختمان (ساختمانی با نمای شیشه‌ای تکرارشونده)، سوپررزولوشن عملکرد بهتری داشته باشد و جزئیات را حفظ کند.

لیم<sup>۱</sup> و همکاران (۲۰۱۷)، برای انجام دادن سوپررزولوشن، دو شبکه ارتقایافته و چندمقیاسه را به ترتیب، با نام‌های EDSR<sup>۲</sup> و MDSR<sup>۳</sup> معرفی کردند. EDSR، با حذف ماژول‌های غیرضروری از معماری ResNet معمولی، نتایج بهبودیافته‌ای به دست می‌دهد و درعین حال مدل فشرده‌سازی می‌شود. مدل پیشنهادی در مقیاس تکی از مدل‌های هم‌زمان پیشی می‌گیرد و عملکرد آن پیشرفت می‌کند. MDSR با ماژول‌های وابسته به مقیاس و شبکه اصلی مشترک، می‌تواند با مقیاس‌های متفاوت سوپررزولوشن در چارچوبی یکپارچه، مقابله‌ای مؤثر داشته باشد. در نهایت هم مدل چندمقیاسی، در مقایسه با مجموعه‌ای از مدل‌های تک‌مقیاس، فشرده باقی می‌ماند و می‌توان عملکرد آن را با مدل تک‌مقیاسی SR مقایسه کرد.

وانگ<sup>۴</sup> و همکاران (۲۰۱۸) مدلی پیشرفته‌تر از SRGAN<sup>۵</sup> (Ledig et al., 2017) را با نام ESRGAN<sup>۶</sup> مطرح کردند که کیفیت ادراکی بهتری، در قیاس با روش‌های قبلی SR، حاصل شود. در این رویکرد به‌طور خاص، بلوک متراکم باقی‌مانده در باقی‌مانده (RRDB)<sup>۷</sup> را بدون نرمال‌سازی دسته‌ای (BN)<sup>۸</sup> به‌منزله واحد ساختمان اصلی شبکه معرفی می‌کنند. علاوه‌براین، این ایده از GAN نسبی‌گرایانه برداشت شده است تا تمایزگر بتواند واقعیت نسبی را به‌جای مقادیر مطلق پیش‌بینی کند. رویکرد مدنظر، با استفاده از ویژگی‌های قبل از فعال‌سازی، perceptual loss را بهبود می‌بخشد؛ این کار می‌تواند نظارت قوی‌تری برای ثبات روشنایی و بازیابی بافت فراهم کند.

بیشتر مدل‌های SR مبتنی بر CNN به قدرت محاسباتی بالایی نیاز دارند و این مسئله کاربردهای دنیای واقعی آنها را بسیار محدود می‌کند. همچنین بیشتر روش‌های مبتنی بر CNN به‌ندرت ویژگی‌های میانی را که برای بازیابی تصویر نهایی مفیدند، بررسی می‌کنند. برای پرداختن به این مسائل، لن<sup>۹</sup> و همکاران (۲۰۲۰) شبکه سبک متراکمی به‌نام MADNet<sup>۱۰</sup> را برای بیان ویژگی‌های چندمقیاسی قوی‌تر و یادگیری

1. Lim
2. Enhanced Deep Super-Resolution Network
3. Multi-Scale Deep Super-Resolution System
4. Wang
5. Super-Resolution Generative Adversarial Networks
6. Enhanced SRGAN
7. Residual-in-Residual Dense Block
8. Batch Normalization
9. Lan
10. A Fast and Lightweight Network for Single-Image Super Resolution
11. Residual Multiscale Module with an Attention Mechanism
12. Dual Residual-Path Block
13. Daihong
14. Multi-Scale Generative Adversarial Network
15. Peak Signal to Noise Ratio
16. Structure Similarity

درمورد سوپرزولوشن در حوزه سنجش از دور مطالعات گوناگونی انجام شده است. در این حوزه، در ابتدا، داده‌های Downsample شده به کار می‌رفت (Lanaras et al., 2018; Zhang et al., 2020). این روش، از لحاظ تهیه داده‌های آموزشی اولیه، بسیار به صرفه و آسان است اما دقت لازم را برای افزایش حد تفکیک مکانی، در دسترس قرار نمی‌دهد. در ادامه مطالعات در این حوزه، داده‌های سنجنده دیگر که حد تفکیک مکانی بیشتر از داده‌های اولیه دارند و از نظر طیفی نیز به این داده‌ها است، به کار رفت. در سطرهای بعدی، به برخی مطالعات انجام شده در این حوزه می‌پردازیم.

لاناراس<sup>۷</sup> و همکاران (۲۰۱۸) ابزاری را برای سوپرزولوشن باندهای دارای وضوح پایین‌تر (بسیست و شصت متری) سنتینل-۲ به صورت داده‌ای یکنواخت و ده متری ارائه کردند. روش مدنظر از دو شبکه عصبی کانولوشنی عمیق برای یادگیری نگاشت مشترک از همه باندهای ورودی به باندهای خروجی به ترتیب ۲X و ۶X استفاده می‌کند. این محققان، برای آموزش شبکه، از داده‌هایی مجازی بهره بردند که خودشان تولید کردند؛ بدین صورت که باندهای شصت و بیست متری را به روش Down sampling به ترتیب، به باندهای ۳۶۰ و ۴۰ متری تبدیل کردند. در ارزیابی‌های کمی، عملکرد شبکه پیشنهادی با نام DSen2 تقریباً ۵۰٪ از بهترین رویکرد در RMSE<sup>۸</sup> مطلوب‌تر است و ویژگی‌های طیفی را بهتر حفظ می‌کند و SRE<sup>۹</sup> را نیز تقریباً ۶ دسی بل افزایش می‌دهد.

چن و همکاران (۲۰۲۳a) که محققان حوزه ماشین بینایی محسوب می‌شوند، برای رسیدگی به مشکلات رایج لبه‌های تصویر تار، انتخاب اندازه کرنل<sup>۱</sup> کانولوشن انعطاف‌ناپذیر و هم‌گرایی آهسته در طول روش آموزشی به دلیل ساختار شبکه اضافی در الگوریتم‌های سوپرزولوشن، شبکه سوپرزولوشن از طریق شبکه فیوژن ویژگی‌های چندسطحی به نام MFFN<sup>۲</sup> را مطرح کردند. این مطالعه چهار بخش اصلی دارد. در بخش نخست، بلوک باقی‌مانده دوگانه (DRB)<sup>۳</sup> با ساختار نامتقارن را پیشنهاد کردند؛ بلوک باقی‌مانده ابتدا دو بار گسترش می‌یابد، سپس دو بار فشرده می‌شود و دو لایه اتصال باقی‌مانده برای استخراج مؤثر اطلاعات ویژگی به کار می‌رود. دوم، واحد وزنی همبستگی خودکاری (ACW)<sup>۴</sup> را پیشنهاد کردند که می‌تواند وزن‌ها را با توجه به اطلاعات ویژگی‌ها، محاسبه و کانال‌های ویژگی‌های متفاوت را به صورت تطبیقی، وزن کند تا اطلاعات ویژگی‌ها به گونه‌ای مؤثر انتقال یابد. سوم، واحد نقشه‌برداری ویژگی‌های کم‌عمق (SFMU)<sup>۵</sup> طراحی کردند که سطوح متفاوت ویژگی‌های کم‌عمق را از طریق لایه‌های کانولوشن فیلدهای گیرنده متفاوت در هر شاخه استخراج می‌کند. چهارم، با طراحی واحد بازسازی چندمسیره‌ای (MPRU)<sup>۶</sup> طراحی کردند که می‌تواند اطلاعات ویژگی‌های چندشاخه را به دست آورد تا از اطلاعات ویژگی‌های سطوح گوناگون، برای بازسازی جنبه‌های متفاوت تصویر، به طور کامل استفاده شود. روش مطرح شده سبب شد PSNR و SSIM، به ترتیب، ۳۳/۹۴ و ۰/۹۲۱۴ حاصل شود. نتایج تجربی به دست آمده نشان می‌دهد که مدل پیشنهادی می‌تواند نوارهای تصویر را بهبود مؤثری بخشد و تصاویر دارای کیفیت بالا را بازسازی کند. به این دلیل، این رویکرد ممکن است در زمینه تصاویر ماهواره‌ای نیز عملکرد خوبی داشته باشد.

به منظور جمع‌بندی، خلاصه بررسی‌های انجام شده در سوپرزولوشن حوزه ماشین بینایی در جدول ۵ آمده است.

1. Kernel
2. Multi-level Features Fusion Network
3. Dual Residual Block
4. AutoCorrelation Weight
5. Shallow Feature Mapping Unit
6. Multi-Path Reconstruction Unit
7. Lanaras
8. Root Mean Square Error
9. Signal to Reconstruction Error Ratio

جدول ۵. بررسی‌های انجام‌شده در سوپررزولوشن حوزه ماشین بینایی، به صورت مختصر

منبع	معایب	مزایا	داده	روش پیشنهادی
Lim et al., 2017	• نبود روش‌های هم‌سطح برای مقایسه	• استفاده جدی از یادگیری عمیق در سوپررزولوشن • عملکرد بهتر از روش‌های سنتی سوپررزولوشن	DIV2K (Timofte et al., 2017) Set5  Bevilacqua et al., 2012))  Set14 (Zeyde et al., 2012)  BSD100 (Martin et al., 2001)  Urban100 (Huang et al., 2015)	<b>EDSR</b> <b>MDSR</b>
Wang et al., 2018	• افزایش هزینه محاسباتی	• فراهم کردن نظارت قوی‌تری برای ثبات روش‌های بازبینی بافت	Set5 (Bevilacqua et al., 2012) Set14 (Zeyde et al., 2012) BSD100 (Martin et al., 2001) Urban100 (Huang et al., 2015)	<b>ESRGAN</b>
Lan et al., 2020	• استفاده از شبکه متراکم که باعث افزایش زمان آموزش می‌شود	• استفاده از پارامترهای کمتر • بررسی ویژگی‌های میانی که برای بازبینی تصویر نهایی مفیدند	Set14 (Zeyde et al., 2012)  Urban100 (Huang et al., 2015)	<b>MADNet</b>
Daihong et al., 2022	• استفاده از bicubic interpolation در ساختار رویکرد که ممکن است باعث افزایش خطا شود	• عملکرد مورد قبول در تصاویر با الگوهای تکراری	Set5 (Bevilacqua et al., 2012)  Set14 (Zeyde et al., 2012)  BSD100 (Martin et al., 2001)	<b>MSGAN</b>
Chen et al., 2023a	• هزینه محاسباتی بالا به دلیل تعدد مراحل	• حل مشکل تاری در لبه‌ها • وزن‌دهی مؤثر به ویژگی‌ها • تشکیل تصویر نهایی با نویز اندک و شباهت ساختاری بالا	DIV2K (Timofte et al., 2017) Set5 (Bevilacqua et al., 2012)  Set14 (Zeyde et al., 2012)  Manga109 (Matsui et al., 2017)  BSD100 (Martin et al., 2001)  Urban100 (Huang et al., 2015)	<b>MF2N</b>

۲/۵ متر استفاده کردند. نتایج بیانگر آن است که SARNet-RG16 و SARNet16، SARNet8، Bicubic برای PSNR و SSIM، به ترتیب، ۲۹/۴۷۱ و ۰/۹۳۶، ۳۳/۵۷۸ و ۰/۹۹۰، ۳۳/۷۱۸ و ۰/۹۹۱ و ۳۳/۷۴۰ و ۰/۹۹۰ را کسب کردند و روش پیشنهادی، با ۱۶ RCAB، بهترین عملکرد را داشته است. این مطالعه فقط در یک منطقه انجام شده؛ بدین مفهوم که داده‌های آموزشی فقط از یک منطقه به نام نابارا (در اسپانیا) تهیه شده است و بنابراین استفاده از این شبکه آموزش دیده، برای بهره‌گیری در مناطق متنوع، جامعیت کافی را ندارد. صوفی و بلوادا<sup>۴</sup> (۲۰۲۳)، طی پژوهشی، رویکرد جدیدی برای بهبود کیفیت تصاویر ماهواره‌ای سنتینل-۲ را با استفاده از تکنیک‌های یادگیری عمیق با سوپرزولوشن، مطرح کردند. در این پژوهش، راه‌حلی عمومی پیشنهاد شده است که با در نظر گرفتن محدودیت‌های حجمی و وابستگی بین باندهای طیفی اعمال شده از طریق ویژگی‌های تصاویر ماهواره‌ای، وضوح فضایی را از ۱۰ متر به ۲/۵ متر (ضریب مقیاس ۴) بهبود می‌بخشد. این مطالعه مدل FSRSI<sup>۵</sup> را پیشنهاد می‌کند که از پتانسیل شبکه‌های کانولوشن عمیق بهره می‌برد و مفاهیم پیشرفته‌ای، از جمله شبکه در شبکه، یادگیری پایان به پایان، ترکیب چندمقیاسی، بهینه‌سازی شبکه عصبی، شتاب و انتقال فیلتر<sup>۶</sup> را ادغام می‌کند؛ بنابراین روش مورد نظر از تمامی پیشرفت‌های پیشنهادی در روش‌های مطالعه شده، برای به دست آوردن معماری مناسب، پارامترسازی مناسب و پردازش خاص در مورد ویژگی‌های تصاویر ماهواره‌ای چندطیفی، بهره می‌گیرد. آزمایش این راه‌حل نشان داد که از نظر نتایج رضایت‌بخشی دارد. با این حال توجه به همبستگی

ژانگ و همکاران (۲۰۲۰) رویکردی مبتنی بر GAN(S2GAN) را برای افزایش وضوح فضایی تصاویر چندطیفی با چند وضوح سنتینل-۲، پیشنهاد کردند (بدین معنی که تصاویر طیف‌های گوناگون دارای حد تفکیک‌های متفاوت‌اند). رویکرد پیشنهادی شامل دو مرحله اصلی است: (۱) افزایش حد تفکیک مکانی باندهای بیست و شصت متری، با هدایت آنها به باندهای مرتبط ده متری از طریق شبکه عصبی مولد؛ (۲) متمایز کردن مؤثر باندهای سوپرزولوشن شده از باندهای حقیقت زمینی آنها، با استفاده از شبکه عصبی تشخیص دهنده. بنابراین در این مطالعه، از یادگیری مخالف شبکه‌های مولد و متمایزکننده استفاده شده است. رویکرد پیشنهادی نتایج مورد قبولی داشته است اما، به دلیل محدود بودن داده‌های مورد آزمایش، احتمال دارد نتایج مورد اطمینان نباشد.

ژانگ و همکاران (۲۰۲۲) شبکه‌ای به نام MHAN<sup>۱</sup> پیشنهاد کردند تا با استفاده از ماژول‌های مرتبه‌های متفاوت توجه مرتبه بالا (HOA)<sup>۲</sup>، برای مشخص کردن نقشه‌ها با باندهای فرکانسی گوناگون، به‌طور کامل از ویژگی‌های سلسله‌مراتبی بهره‌برداری کند. رویکرد مطرح شده شامل دو جزء شبکه استخراج ویژگی برای استخراج ویژگی و یک شبکه اصلاح ویژگی با مکانیسم HOA به منظور بازیابی جزئیات می‌شود. این شبکه روی دو مجموعه داده AID (Xia et al., 2017) و RSSCN7 (Zou et al., 2015) به کار رفته است و نتایج داده‌اند عملکرد MHAN مطرح شده، در مقایسه با روش‌های پیشرفته، بهتر است و زمان اجرا و هزینه GPU کمتری نیاز دارد.

سابالسا و برناردینی<sup>۳</sup> (۲۰۲۲) روشی با نام SARNet را معرفی کردند و ساختارهای متفاوتی از آن، همچون SARNet8، SARNet16 و SARNet-RG16 را آزمودند. آنها، به دلیل شباهت طیفی بالا و رایگان بودن پلنت اسکوپ، به منظور آموزش شبکه عصبی، از جفت تصویرهای پلنت اسکوپ (۵ متر) و سنتینل-۲ (۱۰ متر) برای افزایش حد تفکیک مکانی از ۱۰ متر به

1. Mixed High-Order Attention Network
2. High-Order Attention
3. Zabalza & Bernardini
4. Soufi & Belouadha
5. Fast Super Resolution Single-Image
6. Acceleration and Filter Transfer

گالار ایدوناته<sup>۱</sup> و همکاران (۲۰۱۹) مجموعه داده‌ای برای اعمال سوپررزولوشن روی تصاویر سنتینل-۲ تهیه کردند. این مجموعه داده بین داده‌های RapidEye (پنج‌متری) و سنتینل-۲ جمع‌آوری شده؛ به‌صورتی که فقط چهار باند سنتینل-۲، به‌دلیل شباهت طیفی‌شان، استفاده شده است. این مجموعه شامل ۶۰۴۸ پیچ<sup>۲</sup> ۹۶×۹۶ پیکسل از نه موقعیت مکانی متفاوت در سال ۲۰۱۸ تهیه شده است. هر مجموعه داده تشکیل شده از دنیای واقعی ممکن است مشکلاتی داشته باشد که از آنها می‌توان به ثبت اشتباه محلی، به‌دلیل تأثیرات اختلاف‌منظر و متعادل نبودن تعداد تاریخ‌ها و تعداد پیچ در بین سایت‌های متفاوت اشاره کرد؛ بنابراین باید از این نوع مشکلات چشم‌پوشی کرد یا مجموعه‌ای با استحکام بیشتر به وجود آورد.

کیفیت بصری و ادراکی و همچنین سرعت استنتاج، طیفی این راه‌حل را از نظر ظرفیت پردازش هر نوع تصویر چندطیفی و یادگیری برای تعمیم بهتر در زمان، قدرتمند و عمومی می‌کند.

برای جمع‌بندی، خلاصه بررسی‌های انجام‌شده در سوپررزولوشن حوزه سنجنش از دور در جدول ۶ آمده است.

برای آموزش شبکه‌های مورد نیاز به منظور انجام دادن سوپررزولوشن، به مجموعه‌ای از داده‌های اولیه نیاز است؛ می‌توان این داده‌ها را در مطالعه گرد آورد و یا از داده‌های آماده استفاده کرد. از این‌رو در ادامه، برخی مجموعه داده‌های آماده‌شده برای سوپررزولوشن در حوزه سنجنش از دور بررسی می‌شود.

جدول ۶. خلاصه بررسی‌های انجام‌شده در سوپررزولوشن حوزه سنجنش از دور

منبع	معایب	مزایا	داده	روش پیشنهادی
Lanaras et al., 2018	• افزایش نویز نتایج • کیفیت پایین در داده‌های آموزشی	• کاهش هزینه به‌دلیل استفاده از داده‌آسان • کاهش RMSE در قیاس با روش‌های هم‌دوره	• داده‌های Downsample شده • سنتینل-۲ • تصاویر سنتینل-۲	DSen2
Zhang et al., 2020	• محدود بودن داده‌های مورد آزمایش	• استفاده از شبکه‌های مولد و متمایزکننده؛ • کاهش هزینه به‌دلیل استفاده از داده‌آسان	• داده‌های Downsample شده • سنتینل-۲	S2GAN
Zhang et al., 2022	• جامع نبودن مجموعه داده مورد استفاده (ممکن است در شرایط گوناگون، مانند تغییرات آب‌وهوایی، نتایج متفاوتی داشته باشد)؛ • وجود نداشتن جامعیت کافی در استفاده از این شبکه آموزش‌دیده برای بهره‌گیری در مناطق متنوع	• استفاده از مکانیسم HOA برای بازیابی جزئیات؛ • زمان اجرا و هزینه GPU کمتر، در مقایسه با روش‌های رایج	• AID (Xia et al., 2017) • RSSCN7 (Zou et al., 2015)	MHAN
(Zabalza & Bernardini, 2022)	• وجود نداشتن جامعیت کافی در استفاده از این شبکه آموزش‌دیده برای بهره‌گیری در مناطق متنوع	• رایگان بودن داده آموزشی • نظارت بر تولید داده آموزشی؛ • تأکید شبکه مورد استفاده بر حفظ ویژگی‌های طیفی	• پلنت اسکوپ • سنتینل-۲	SARNet
(Soufi & Belouadha, 2023)	• استفاده از تصاویر یک‌سجنده • افزایش نویز بر اثر اعمال مقیاس چهاربرابری	• سرعت بالا • ترکیب چندسجنده از پیشنهاد‌های مطرح‌شده	• تصاویر سنتینل-۲	FSRSI

1. Galar Idoate
2. Patch



منشأ اصلی سوپررزولوشن در کاربردهای ماشین بینایی است؛ در این حوزه، مطالعات بسیاری انجام شده و پس از آن، سوپررزولوشن وارد بخش سنجش از دوری شده است. در میان مطالعات، می‌توان مشاهده کرد که استفاده از ساختارهای برپایه GAN موارد استفاده بیشتر و نتایج بهتری دارد. همچنین برای انجام دادن سوپررزولوشن، به داده‌های آموزشی نیاز است؛ در این مورد نیز مطالعاتی انجام شده است که می‌تواند در تولید این داده کمک کند و یا، برای این کار، می‌توان از مجموعه داده‌های آماده بهره برد.

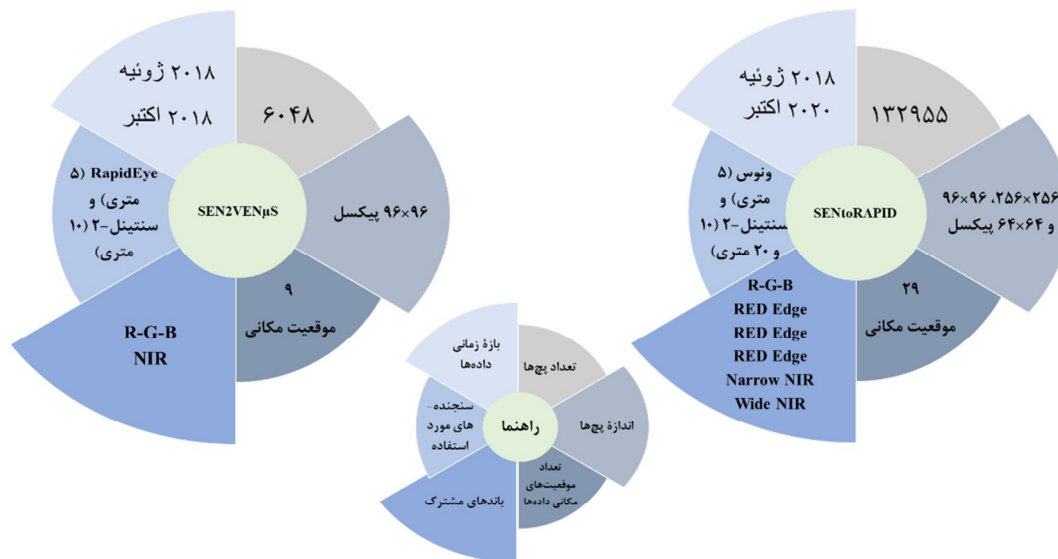
#### ۴- بحث و تحلیل

در طول این پژوهش، مطالعات منتشر شده در مجله‌های معتبر گوناگون از سوی محققان، در دو زمینه تشخیص شبکه راه و سوپررزولوشن، بررسی شده است. با توجه به این پژوهش‌ها، روش‌های مبتنی بر کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین به ترتیب، سهم‌هایی حدود ۲۸، ۳۱، ۵ و ۳۶ درصدی در دو زمینه اشاره شده دارند؛ البته باید در نظر داشت که با پیشرفت

میشل<sup>۱</sup> و همکاران (۲۰۲۲)، برای انجام دادن عملیات SISR بر پایه یادگیری عمیق، مجموعه داده‌ای جمع‌آوری کردند. این مجموعه داده ۲۹ موقعیت مکانی متفاوت را با مجموعاً ۱۳۲۹۵۵ پیکسل  $۲۵۶ \times ۲۵۶ \times ۹۶$  و  $۶۴ \times ۶۴$  پیکسل دارای وضوح پنج متر پوشش می‌دهد و می‌تواند در آموزش و مقایسه الگوریتم‌های سوپررزولوشن، برای رساندن وضوح فضایی هشت باند از باندهای سنتینل-۲ (باندهای بیست و ده‌متری) به پنج متر، استفاده شود. این مجموعه داده، به دلایلی مانند تنوع فراوان در مناطق عکس‌برداری شده و شباهت چشمگیر طیفی بین باندهای طیفی سنتینل-۲ و ونوس، می‌تواند مجموعه داده‌ای مورد اعتماد برای آموزش شبکه سوپررزولوشن باشد.

به منظور جمع‌بندی، خلاصه بررسی‌های انجام شده در سوپررزولوشن در شکل ۱۲ آمده است.

با بررسی مطالعات انجام شده در زمینه سوپررزولوشن، می‌توان این مطالعات را به سه بخش سوپررزولوشن در ماشین بینایی، سوپررزولوشن در سنجش از دور و مجموعه داده سوپررزولوشن تقسیم کرد.



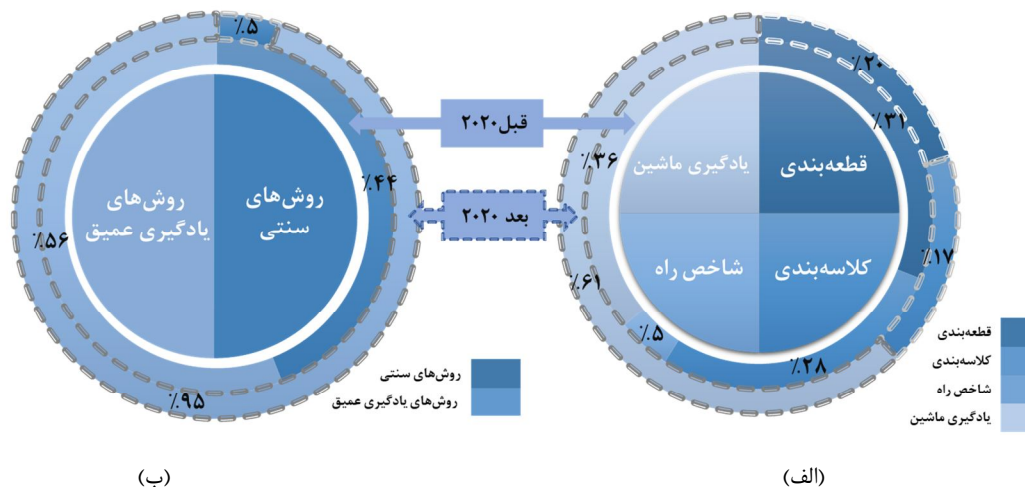
شکل ۱۲. خلاصه مجموعه داده سوپررزولوشن در حوزه سنجش از دور

منبع: (Galar Idoate et al., 2019; Michel et al., 2022)

لبه‌های خطی ظاهر می‌شوند. اما در عین حال این روش‌ها، به دلیل حساسیت به نویز و توانایی نداشتن در تشخیص راه‌های پیچیده، محدودیت‌هایی داشتند. با پیشرفت فناوری، الگوریتم‌های قطعه‌بندی جایگزین شدند که با توجه به ویژگی پیوستگی راه‌ها، عملکرد بهتری نشان دادند اما این روش‌ها نیز، در مورد مناطق با پوشش گیاهی متراکم یا سایه‌های گسترده، دچار مشکل می‌شدند. با افزایش پیچیدگی شبکه راه‌ها و نیاز به دقت بالاتر، روش‌های مبتنی بر هوش مصنوعی، به ویژه یادگیری عمیق، به منزله راه‌حلی کارآمد مطرح شدند. در ابتدا الگوریتم‌های یادگیری ماشین ساده‌تر، مانند SVM و درخت‌های تصمیم، به کار رفتند اما با پیشرفت سخت‌افزارهای پردازشی و ظهور شبکه‌های عصبی عمیق، مانند CNN و GAN، تحول چشمگیری در این حوزه پدید آمد. این شبکه‌ها، با توانایی استخراج خودکار ویژگی‌ها و یادگیری الگوهای پیچیده، توانستند دقت تشخیص راه‌ها را افزایش چشمگیری دهند. همچنین استفاده از شبکه‌های GAN، برای تولید داده‌های مصنوعی و بهبود عملکرد مدل‌ها، گامی مهم در این زمینه محسوب می‌شود. با توجه به مطالعات اخیر، می‌توان دریافت که استفاده از الگوریتم‌های یادگیری عمیق از جمله رویکردهایی است که سبب توسعه و بهبود مطالعات آتی در این حوزه می‌شود.

شبکه‌های عصبی و ترندهای یادگیری عمیق در سال‌های اخیر، روش‌های مبتنی بر کلاسه‌بندی و قطعه‌بندی با یادگیری عمیق توسعه یافته‌اند و سهم روش‌های مبتنی بر یادگیری ماشین افزایش داشته است (حدود ۶۱٪). همچنین، با توجه به مقاله‌های بررسی شده در زمینه سوپررزولوشن، روش‌های مبتنی بر روش‌های سنتی و یادگیری عمیق به ترتیب، سهم‌هایی حدود ۴۴ و ۵۶ درصدی را داشتند و در سال‌های اخیر، اغلب رویکردهای سوپررزولوشن مبتنی بر یادگیری عمیق در حال توسعه بوده‌اند. میزان مطالعات انجام شده در هر دو زمینه، به صورت شماتیک، در شکل ۱۳ آمده و به برخی بررسی‌ها درباره تلفیق تصاویر نیز در شکل ۶ اشاره شده است.

تهیه نقشه مکانی شبکه راه‌ها و به‌روزرسانی دوره‌ای، همواره در مدیریت و برنامه‌ریزی برای ساخت و نگهداری جاده‌ها، موضوع مهمی بوده است. تشخیص راه‌ها بر اساس تصاویر سنجنش از دوری، در مراحل ابتدایی، به صورت دستی انجام می‌شد که فرایندی دشوار، زمان‌بر و همراه با خطاهای انسانی بود؛ به همین علت، طی سال‌ها، روش‌های اتوماتیک جانشین آن شد. در مراحل اولیه، روش‌های تشخیص راه بر اساس الگوریتم‌های تشخیص لبه توسعه یافتند؛ چراکه راه‌ها، در تصاویر سنجنش از دور، اغلب به صورت



شکل ۱۳. میزان مطالعات انجام شده: رویکردها در زمینه شناسایی شبکه راه‌ها (الف)؛ رویکردها در زمینه سوپررزولوشن (ب)

دارند. باید در نظر داشت که لازمه استفاده از شبکه‌های عصبی جمع‌آوری یا در دسترس بودن داده‌های آموزشی است تا بتوان شبکه مدنظر را آموزش داد و از آن بهره‌برداری کرد. در استفاده از سایر روش‌ها، همانند روش‌های قطعه‌بندی، مدل‌ها انعطاف‌پذیری لازم را برای تشخیص راه‌های پیچیده ندارند؛ به‌همین دلیل استفاده از مدل‌های آموزش‌پذیر ارجحیت دارد. در بحث تشخیص راه‌ها با شاخص، به‌علت تنوع در جنس مسیر همانند خاکی و آسفالتی، نمی‌توان از شاخصی منحصر به فرد برای تشخیص تمامی راه‌ها استفاده کرد؛ از این رو به‌کارگیری شاخص‌ها، به‌منظور تشخیص و طبقه‌بندی راه‌ها، نمی‌تواند روشی مورد اعتماد و جامع باشد. حد تفکیک مکانی داده‌های مورد استفاده، در راستای دستیابی به هدف تحقیق، اهمیت چشمگیری دارد. استفاده از تصاویر دارای حد تفکیک مکانی متوسط، به‌دلیل دسترسی رایگان، موجب ایجاد اختلال در تشخیص راه‌های با عرض کم خواهد شد؛ بنابراین برای بهبود دقت تشخیص راه‌ها، باید از تصاویر با حد تفکیک مکانی بالا استفاده کرد یا رویکردهایی همانند تلفیق تصاویر و سوپرزولوشن را مدنظر قرار داد.

با توجه به مطالعاتی که در زمینه تشخیص شبکه‌های راه‌ها بررسی شد، روش‌های گوناگونی مطرح شده است. این روش‌ها شامل کلاس‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین می‌شود و سهم این روش‌ها به‌ترتیب، حدود ۲۸، ۳۱، ۵ و ۳۶٪ است. در نهایت، می‌توان نتیجه گرفت که در تشخیص شبکه‌های راه‌ها، روش‌های مبتنی بر یادگیری ماشین و در حوزه سوپرزولوشن، روش‌های مبتنی بر یادگیری عمیق، به‌دلیل کارایی بالاتر بیشتر نتایج بهتر، کاربرد گسترده‌تری دارند. با توجه به تمرکز مطالعات سال‌های اخیر بر استفاده از مدل‌های یادگیری عمیق، چنین دریافت می‌شود که رویکردهای آتی شناسایی شبکه راه‌ها بر مدل‌های یادگیری عمیق متکی خواهد بود. در مجموع، با تکیه بر بررسی‌های انجام‌شده، برای عملیاتی‌سازی شناسایی شبکه راه‌ها و فراهم کردن

داده مناسب، برای تشخیص راه، داده‌ای است که حد تفکیک مکانی آن کمتر از حداقل عرض راه در منطقه مورد مطالعه باشد تا تشخیص راه به‌صورت مطلوب انجام شود. از آنجاکه شبکه راه‌های روستایی عرض کمی دارد، تصاویر با حد تفکیک مکانی بالا پاسخگوی نیاز خواهند بود اما، به‌دلیل دسترسی مشکل و هزینه بالا، استفاده از آنها صرفه اقتصادی و زمانی ندارد. از سویی، تصاویری دارای حد تفکیک مکانی متوسط نیز در دست است که به‌دلیل ناهم‌خوانی رزولوشن آنها با عرض برخی راه‌ها، احتمال از دست‌رفتنی در تشخیص وجود دارد. بنابراین برای بهینه کردن هزینه عملیات اجرایی و دقت خروجی حاصل، روش‌های بهبود حد تفکیک مکانی تصاویر مطرح شدند.

در این مطالعه، روش‌های سوپرزولوشن به‌منزله راه‌حلی برای بهبود حد تفکیک مکانی تصاویر بررسی شدند. این روش‌ها به دو دسته سنتی و نوین تقسیم می‌شوند. روش‌های سنتی، مانند درون‌یابی، به‌دلیل توانایی نداشتن در یادگیری ویژگی‌های پیچیده و حفظ جزئیات تصویر، جای خود را به روش‌های نوین مبتنی بر یادگیری عمیق داده‌اند. شبکه‌های عمیق، همانند SRCNN و ESRCNN، با توانایی یادگیری ویژگی‌های سطح بالا و حفظ اطلاعات طیفی، عملکرد بهتری در افزایش رزولوشن تصاویر دارند. با این حال چالش‌هایی مانند نیاز به داده‌های آموزشی گسترده و زمان پردازش طولانی هنوز وجود دارند که نیازمند توجه بیشترند.

## ۵- نتیجه‌گیری و پیشنهادها

این پژوهش با هدف بررسی روش‌های تشخیص شبکه راه‌ها و بهینه‌سازی استفاده از تصاویر ماهواره‌ای دارای حد تفکیک مکانی متوسط انجام شده است. نتایج نشان می‌دهد که روش‌های مبتنی بر شبکه‌های عصبی، به‌ویژه یادگیری عمیق، به‌دلیل توانایی در استخراج خودکار ویژگی‌ها و یادگیری الگوهای پیچیده، عملکردی بهتر از روش‌های مبتنی بر قطعه‌بندی و شاخص‌های طیفی

- Sensing Datasets for Road Extraction: A State-of-the-Art Review**, Remote Sensing, 12(9), P. 1444, <https://doi.org/10.1109/ACCESS.2020.3026658>.
- Abdollahi, A., Pradhan, B. & Alamri, A., 2020b, **VNet: An End-to-End Fully Convolutional Neural Network for Road Extraction from High-Resolution Remote Sensing Data**, IEEE Access, 8, PP. 179424-179436, <https://doi.org/10.1109/ACCESS.2020.3026658>.
- Ablin, R., Sulochana, C.H. & Prabin, G., 2020, **An Investigation in Satellite Images Based on Image Enhancement Techniques**, European Journal of Remote Sensing, 53(sup2), PP. 86-94, <https://doi.org/10.1080/22797254.2019.1673216>.
- Adigun, O., Olsen, P.A. & Chandra, R., 2022, **Location Aware Super-Resolution for Satellite Data Fusion**, IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium.
- Ahmed, M.W., Saadi, S. & Ahmed, M., 2022, **Automated Road Extraction Using Reinforced Road Indices for Sentinel-2 Data**, Array, 16, P. 100257, <https://doi.org/10.1016/j.array.2022.100257>.
- Alvarez-Vanhard, E., Corpetti, T. & Houet, T., 2021, **UAV & Satellite Synergies for Optical Remote Sensing Applications: A Literature Review**, Science of Remote Sensing, 3, P. 100019, <https://doi.org/10.1016/j.srs.2021.100019>.
- Arora, S., Suman, H.K., Mathur, T., Pandey, H.M. & Tiwari, K., 2023, **Fractional Derivative Based Weighted Skip Connections for Satellite Image Road Segmentation**, Neural Networks, 161, PP. 142-153, <https://doi.org/10.1016/j.neunet.2023.01.031>.
- Babaali, K.O., Zigh, E., Djebbouri, M. & Kadiri, M., 2014, **Survey of Some New Road Extraction Methods**, The International Journal Of Engineering And Science (IJES), 3(11), PP. 28-33.
- Badran, A., El-Geneidy, A. & Miranda-Moreno, L., 2024, **A Review of Techniques to Extract Road Network Features from Global Positioning System Data for Transport Modelling**, Transport Reviews, 44(1), PP. 69-84, <https://doi.org/10.1080/01441647.2023.2229521>.
- امکان به‌روزرسانی با صرف زمان و هزینه مناسب، می‌توان با استفاده از رویکردهای سوپررزولوشن، حد تفکیک مکانی داده‌های رایگان را افزایش داد و سپس رویکردهای مبتنی بر یادگیری عمیق شناسایی شبکه راه را به کار برد. در این زمینه، با توجه به امکانات طرح، مانند میزان توانایی سخت‌افزار در دسترس برای آموزش شبکه‌ها و در دست بودن مجموعه داده مناسب، می‌توان رویکردهای مدنظر را تعیین کرد. از چالش‌های تشخیص راه‌ها، می‌توان به وجود پوشش گیاهی و سایه در تصاویر اشاره کرد که باعث می‌شود راه‌ها به صورت کامل و یکپارچه تشخیص داده نشوند. برای بهبود تقریبی این مسئله، رویکردی همچون رأی‌گیری تنسوری مطرح شده است که توانایی تکمیل و تصحیح راه‌هایی را دارد که به صورت ناقص تشخیص داده شده‌اند. در مجموع این پژوهش، با بیان دسته‌بندی‌ها و رویکردهای برتر در زمینه‌های مطرح شده، می‌تواند به محققان یاری رساند تا، با توجه به نوع کاربرد و منابع مورد استفاده، الگوریتم و داده‌های مورد نیاز خود را به منظور شناسایی شبکه راه‌ها، انتخاب و استفاده کنند. در این مطالعه، به داده‌های لیدار و SAR برای تشخیص راه‌های روستایی، با استفاده از تصاویر سنجش از دور، اشاره شد. اما به علت اهمیت این داده‌ها، پیشنهاد می‌شود در مطالعات آینده، تأثیرات داده‌های مکمل، همانند داده‌های لیدار و SAR با جزئیات بیشتری بررسی شود. این داده‌ها، به دلیل قابلیت‌های تکمیلی‌شان در شناسایی ویژگی‌های فیزیکی و ساختاری راه‌ها، می‌توانند به منزله گزینه‌هایی برای روش‌های هیبرید در کنار تصاویر سنجش از دوری عمل کنند. همچنین روش‌های پردازشی مختص این داده‌ها نیز نیازمند تحلیل و ارزیابی دقیق‌اند تا، در شناسایی شبکه راه‌ها، کاربردی مؤثر داشته باشند.

#### ۶- منابع

Abdollahi, A., Pradhan, B., Shukla, N., Chakraborty, S. & Alamri, A., 2020a, **Deep Learning Approaches Applied to remote**

- Bakhtiari, H.R.R., Abdollahi, A. & Rezaeian, H., 2017, **Semi Automatic Road Extraction from Digital Images**, The Egyptian Journal of Remote Sensing and Space Science, 20(1), PP. 117-123, <https://doi.org/10.1016/j.ejrs.2017.03.001>.
- Belgiu, M. & Stein, A., 2019, **Spatiotemporal Image Fusion in Remote Sensing**, Remote Sensing, 11(7), P. 818, <https://doi.org/10.3390/rs11070818>.
- Bevilacqua, M., Roumy, A., Guillemot, C. & Alberi-Morel, M.L., 2012, **Low-Complexity Single-Image Super-Resolution Based on Nonnegative Neighbor Embedding**, <https://doi.org/10.5244/C.26.135>.
- Blaschke, T., Burnett, C. & Pekkarinen, A., 2004, **Image Segmentation Methods for Object-Based Analysis and Classification**, Remote Sensing Image Analysis: Including the Spatial Domain, 5, PP. 211-236.
- Botelho, J. Jr., Costa, S.C., Ribeiro, J.G. & Souza, C.M. Jr., 2022, **Mapping Roads in the Brazilian Amazon with Artificial Intelligence and Sentinel-2**, Remote Sensing, 14(15), P. 3625, <https://doi.org/10.3390/rs14153625>.
- Chang, H., Yeung, D.-Y. & Xiong, Y., 2004, **Super-Resolution through Neighbor Embedding**, Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004, CVPR 200.
- Chen, L., Letu, H., Fan, M., Shang, H., Tao, J., Wu, L., Zhang, Y., Yu, C., Gu, J. & Zhang, N., 2022a, **An Introduction to the Chinese High-Resolution Earth Observation System: Gaofen-1~ 7 Civilian Satellites**, Journal of Remote Sensing, <https://doi.org/10.34133/2022/976953>.
- Chen, W., Ouyang, S., Yang, J., Li, X., Zhou, G. & Wang, L., 2022b, **JAGAN: A Framework for Complex Land Cover Classification Using Gaofen-5 AHSI Images**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15, PP. 1591-1603, <https://doi.org/10.1109/JSTARS.2022.3144339>.
- Chen, Z., Deng, L., Luo, Y., Li, D., Junior, J.M., Gonçalves, W.N., Nurunnabi, A.A.M., Li, J., Wang, C. & Li, D., 2022c, **Road Extraction in remote Sensing Data: A Survey**, International Journal of Applied Earth Observation and Geoinformation, 112, P. 102833, <https://doi.org/10.1016/j.jag.2022.102833>.
- Chen, Y., Xia, R., Yang, K. & Zou, K., 2023a, **MFFN: Image Super-Resolution via Multi-Level Features Fusion Network**, The Visual Computer, 40, PP. 489-504, <https://doi.org/10.1007/s00371-023-02795-0>.
- Chen, G., Lu, H., Zou, W., Li, L., Emam, M., Chen, X., Jing, W., Wang, J. & Li, C., 2023b, **Spatiotemporal Fusion for Spectral Remote Sensing: A Statistical Analysis and Review**, Journal of King Saud University-Computer and Information Sciences, <https://doi.org/10.1016/j.jksuci.2023.02.021>.
- Daihong, J., Sai, Z., Lei, D. & Yueming, D., 2022, **Multi-Scale Generative Adversarial Network for Image Super-Resolution**, Soft Computing, 26(8), PP. 3631-3641, <https://doi.org/10.1007/s00500-022-06822-5>.
- Deepan, P., Abinaya, S., Haritha, G. & Iswarya, V., 2018, **Road Recognition from Remote Sensing Imagery Using Machine Learning**, International Research Journal of Engineering and Technology, 5(3), PP. 3677-3683.
- Dick, A., Raynaud, J.-L., Rolland, A., Pelou, S., Coustance, S., Dedieu, G., Hagolle, O., Burochin, J.-P., Binet, R. & Moreau, A., 2022, **Venus: Mission Characteristics, Final Evaluation of the First Phase and Data Production**, Remote sensing, (14)14, P. 3281, <https://doi.org/10.3390/rs14143281>.
- Dong, J., Zhuang, D., Huang, Y. & Fu, J., 2009, **Advances in Multi-Sensor Data Fusion: Algorithms and Applications**, Sensors, 9(10), PP. 7771-7784, <https://doi.org/10.3390/s91007771>.
- Dong, W., Zhang, L., Shi, G. & Wu, X., 2011, **Image Deblurring and Super-Resolution by Adaptive Sparse Domain Selection and Adaptive Regularization**, IEEE Transactions on Image Processing, 20(7), PP. 1838-1857, <https://doi.org/10.1109/TIP.2011.2108306>.
- Dong, C., Loy, C.C., He, K. & Tang, X., 2014, **Learning a Deep Convolutional Network for Image Super-Resolution**, Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part IV 13.
- Emad, M., Peemen, M. & Corporaal, H., 2021, **Dualsr: Zero-Shot Dual Learning for Real-World Super-Resolution**, Proceedings of the IEEE/CVF winter conference on applications of computer vision.

- Freedman, G. & Fattal, R., 2011, **Image and Video Upscaling from Local Self-Examples**, ACM Transactions on Graphics (TOG), 30(2), PP. 1-11, <https://doi.org/10.1145/1944846.1944852>.
- Freeman, W.T., Jones, T.R. & Pasztor, E.C., 2002, **Example-Based Super-Resolution**, IEEE Computer Graphics and Applications, 22(2), PP. 56-65, <https://doi.org/10.1109/38.988747>.
- Galar Idoate, M., Sesma Redín, R., Ayala Lauroba, C. & Aranda, C., 2019, **Super-Resolution for Sentinel-2 Images**, International Archives of The Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archives, 2019, XLII-2/W16, PP. 95-102, <https://doi.org/10.5194/isprs-archives-XLII-2-W16-95-2019>.
- Gao, X., Zhang, K., Tao, D. & Li, X., 2012, **Image Super-Resolution with Sparse Neighbor Embedding**, IEEE Transactions on Image Processing, 21(7), PP. 3194-3205, <https://doi.org/10.1109/TIP.2012.2190080>.
- Gao, L., Song, W., Dai, J. & Chen, Y., 2019, **Road Extraction from High-Resolution Remote Sensing Imagery Using Refined Deep Residual Convolutional Neural Network**, Remote Sensing, 11(5), P. 552, <https://doi.org/10.3390/rs10091461>.
- Gatys, L.A., Ecker, A.S. & Bethge, M., 2015, **A Neural Algorithm of Artistic Style**, arXiv preprint arXiv:1508.06576, <https://doi.org/10.48550/arXiv.1508.06576>.
- Ghandorh, H., Boulila, W., Masood, S., Koubaa, A., Ahmed, F. & Ahmad, J., 2022, **Semantic Segmentation and Edge Detection—Approach to Road Detection in Very High Resolution Satellite Images**, Remote Sensing, 14(3), P. 613, <https://doi.org/10.3390/rs14030613>.
- Ghassemian, H., 2016, **A Review of Remote Sensing Image Fusion Methods**, Information Fusion, 32, PP. 75-89, <https://doi.org/10.1016/j.inffus.2016.03.003>.
- Gonzalez, R.C. & Woods, R.E., 2006, **Digital Image Processing**, Pearson Education, <https://books.google.com/books?id=MaYuAAAQBAJ>.
- Grinias, I., Panagiotakis, C. & Tziritas, G., 2016, **MRF-Based Segmentation and Unsupervised Classification for Building and Road Detection in Peri-Urban Areas of High-Resolution Satellite Images**, ISPRS Journal of Photogrammetry and Remote Sensing, 122, PP. 145-166, <https://doi.org/10.1016/j.isprsjprs.2016.10.010>.
- He, H. & Siu, W.-C., 2011, **Single Image Super-Resolution Using Gaussian Process Regression**, CVPR 2011, Colorado Springs, CO, USA, PP. 449-456, <https://doi.org/10.1109/CVPR.2011.5995713>.
- Henry, C., Azimi, S.M. & Merkle, N., 2018, **Road Segmentation in SAR Satellite Images with Deep Fully Convolutional Neural Networks**, IEEE Geoscience and Remote Sensing Letters, 15(12), PP. 1867-1871.
- Huang, J.-B., Singh, A. & Ahuja, N., 2015, **Single Image Super-Resolution from Transformed Self-Exemplars**, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, PP. 5197-5206, <https://doi.org/10.1109/CVPR.2015.7299156>.
- Irani, M. & Peleg, S., 1991, **Improving resolution by Image Registration**, CVGIP: Graphical Models and Image Processing, 53(3), PP. 231-239, [https://doi.org/10.1016/1049-9652\(91\)90045-L](https://doi.org/10.1016/1049-9652(91)90045-L).
- Javan, F.D., Samadzadegan, F., Mehravar, S., Toosi, A., Khatami, R. & Stein, A., 2021, **A Review of Image Fusion Techniques for Pan-Sharpener of High-Resolution Satellite Imagery**, ISPRS Journal of Photogrammetry and Remote Sensing, 171, PP. 101-117, <https://doi.org/10.1016/j.isprsjprs.2020.11.001>.
- Jia, J., Sun, H., Jiang, C., Karila, K., Karjalainen, M., Ahokas, E., Khoramshahi, E., Hu, P., Chen, C. & Xue, T., 2021, **Review on Active and Passive Remote Sensing Techniques for Road Extraction**, Remote Sensing, 13(21), P. 4235, <https://doi.org/10.3390/rs13214235>.
- Jing, J., Liu, S., Wang, G., Zhang, W. & Sun, C., 2022, **Recent Advances on Image Edge Detection: A Comprehensive Review**, Neurocomputing, 503, PP. 259-271, <https://doi.org/https://doi.org/10.1016/j.neucom.2022.06.083>.
- Jozdani, S.E., Johnson, B.A. & Chen, D., 2019, **Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification**, Remote Sensing, 11(14), P. 1713, <https://doi.org/10.3390/rs11141713>.

- Jurado, J.M., López, A., Pádua, L. & Sousa, J.J., 2022, **Remote Sensing Image Fusion on 3D Scenarios: A Review of Applications for Agriculture and Forestry**, International Journal of Applied Earth Observation and Geoinformation, 112, P. 102856, <https://doi.org/10.1016/j.jag.2022.102856>.
- Kahraman, I., Karas, I. & Akay, A.E., 2018, **Road Extraction Techniques from Remote Sensing Images: A Review**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 42, PP. 339-342, <https://doi.org/10.5194/isprs-archives-XLII-4-W9-339-2018>.
- Kiani, A. & Ebadi, H., 2015, **Development of a New Method for Edge Detection from High-Resolution Aerial/Satellite Images, with Emphasis on Threshold Optimization and Using Imperialist Competitive Algorithm [Research]**, Journal of Geomatics Science and Technology, 4(4), PP. 67-82, <https://doi.org/http://jgst.issgeac.ir/article-1-308-en.html>.
- Kiani, A. & Sahebi, M.R., 2015, **Edge Detection Based on the Shannon Entropy by Piecewise Thresholding on Remote Sensing Images**, IET Computer Vision, 9(5), PP. 758-768, <https://doi.org/10.1049/iet-cvi.2013.0192>.
- Kiani, A., Ebadi, H. & Farnood Ahmadi, F., 2019a, **Development of An Object-Based Interpretive System Based on Weighted Scoring Method in a Multi-Scale Manner**, ISPRS International Journal of Geo-Information, 8(9), P. 398, <https://doi.org/10.3390/ijgi8090398>.
- Kiani, A., Ebadi, H. & Khanlou, H.A., 2019b, **Object Based Interpretation of High Spatial Remote Sensing Images Based on Knowledge-Based Systems**, Iranian Journal of Remote Sensing & GIS, 10(4), PP. 27-54, [https://gisj.sbu.ac.ir/article\\_96622\\_bf8570bd278dd917e7ffa46f870cfc82.pdf](https://gisj.sbu.ac.ir/article_96622_bf8570bd278dd917e7ffa46f870cfc82.pdf).
- Kim, K.I. & Kwon, Y., 2010, **Single-Image Super-Resolution Using Sparse Regression and Natural Image Prior**, IEEE Transactions on Pattern Analysis and Machine Intelligence, 32(6), PP. 1127-1133, <https://doi.org/10.1109/TPAMI.2010.25>.
- Kim, J., Lee, J.K. & Lee, K.M., 2016, **Accurate Image Super-Resolution Using Very Deep Convolutional Networks**, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, <https://doi.org/10.48550/arXiv.1511.04587>.
- Kim, G., Park, J., Lee, K., Lee, J., Min, J., Lee, B., Han, D.K. & Ko, H., 2020, **Unsupervised Real-World Super Resolution with Cycle Generative Adversarial Network and Domain Discriminator**, IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, WA, USA, 2020, PP. 1862-1871, <https://doi.org/10.1109/CVPRW50498.2020.00236>.
- Köhler, S., Wojcik, M., Xu, K. & Dernburg, A.F., 2020, **Dynamic Molecular Architecture of the Synaptonemal Complex**, BioRxiv, <https://doi.org/10.1101/2020.02.16.947804>.
- Lan, R., Sun, L., Liu, Z., Lu, H., Pang, C. & Luo, X., 2020, **MADNet: A Fast and Lightweight Network for Single-Image Super Resolution**, IEEE Transactions on Cybernetics, 51(3), PP. 1443-1453, <https://doi.org/10.1109/TCYB.2020.2970104>.
- Lanaras, C., Bioucas-Dias, J., Galliani, S., Baltsavias, E. & Schindler, K., 2018, **Super-Resolution of Sentinel-2 Images: Learning a Globally Applicable Deep Neural Network**, ISPRS Journal of Photogrammetry and Remote Sensing, 146, PP. 305-319, <https://doi.org/10.1016/j.isprsjprs.2018.09.018>.
- Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J. & Wang, Z., 2017, **Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network**, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, PP. 105-114, <https://doi.org/10.1109/CVPR.2017.19>.
- Li, S., Kang, X., Fang, L., Hu, J. & Yin, H., 2017, **Pixel-Level Image Fusion: A Survey of the State of the Art**, Information Fusion, 33, PP. 100-112, <https://doi.org/10.1016/j.inffus.2016.05.004>.
- Li, J., Li, Y., He, L., Chen, J. & Plaza, A., 2020, **Spatio-Temporal Fusion for Remote Sensing Data: An Overview and New Benchmark**, Science China Information Sciences, 63, PP. 1-17, <https://doi.org/10.1007/s11432-019-2785-y>.
- Lian, R., Wang, W., Mustafa, N. & Huang, L., 2020, **Road Extraction Methods in High-**



- Resolution Remote Sensing Images: A Comprehensive Review**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, PP. 5489-5507, <https://doi.org/10.1109/JSTARS.2020.3023549>.
- Lim, B., Son, S., Kim, H., Nah, S. & Mu Lee, K., 2017, **Enhanced Deep Residual Networks for Single Image Super-Resolution**, IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Honolulu, HI, USA, PP. 1132-1140, <https://doi.org/10.1109/CVPRW.2017.151>.
- Liu, W. & Wang, H., 2008, **An Interactive Image Segmentation Method Based on Graph Theory**, J. Electron. Inf. Technol, 8(30), PP. 1973-1976, <https://doi.org/10.3390/s23146394>.
- Liu, Y., Yao, J., Lu, X., Xia, M., Wang, X. & Liu, Y., 2018, **RoadNet: Learning to Comprehensively Analyze Road Networks in Complex Urban Scenes from High-Resolution Remotely Sensed Images**, IEEE Transactions on Geoscience and Remote Sensing, 57(4), PP. 2043-2056, <https://doi.org/10.1109/TGRS.2018.2870871>.
- Liu, P., Wang, Q., Yang, G., Li, L. & Zhang, H., 2022, **Survey of Road Extraction Methods in Remote Sensing Images Based on Deep Learning**, PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science, 90(2), PP. 135-159, <https://doi.org/10.1007/s41064-022-00194-z>.
- Liu, R., Wu, J., Lu, W., Miao, Q., Zhang, H., Liu, X., Lu, Z. & Li, L., 2024, **A Review of Deep Learning-Based Methods for Road Extraction from High-Resolution Remote Sensing Images**, Remote Sensing, 16(12), P. 2056, <https://doi.org/10.3390/rs16122056>.
- Luo, Z., Zhou, K., Tan, Y., Wang, X., Zhu, R. & Zhang, L., 2023, **AD-RoadNet: An Auxiliary-Decoding Road Extraction Network Improving Connectivity While Preserving Multiscale Road Details**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, <https://doi.org/10.1109/JSTARS.2023.3289583>.
- Market Analysis News Site, 1400, <https://www.tahlilbazaar.com/news/129756/>.
- Martin, D., Fowlkes, C., Tal, D. & Malik, J., 2001, **A Database of Human Segmented Natural Images and Its Application to Evaluating Segmentation Algorithms and Measuring Ecological Statistics**, Proceedings Eighth IEEE International Conference on Computer Vision, ICCV 2001.
- Masek, J.G., Wulder, M.A., Markham, B., McCorkel, J., Crawford, C.J., Storey, J. & Jenstrom, D.T., 2020, **Landsat 9: Empowering Open Science and Applications through Continuity**, Remote Sensing of Environment, 248, P. 111968, <https://doi.org/10.1016/j.rse.2020.111968>.
- Matsui, Y., Ito, K., Aramaki, Y., Fujimoto, A., Ogawa, T., Yamasaki, T. & Aizawa, K., 2017, **Sketch-Based Manga Retrieval Using Manga109 Dataset**, Multimedia Tools and Applications, 76, PP. 21811-21838, <https://doi.org/10.48550/arXiv.1510.04389>.
- Michel, J., Vinasco-Salinas, J., Inglada, J. & Hagolle, O., 2022, **SEN2VEN $\mu$ S, a Dataset for the Training of Sentinel-2 Super-Resolution Algorithms**, Data, 7(7), P. 96, <https://doi.org/10.3390/data7070096>.
- Mnih, V., 2013, **Machine Learning for Aerial Image Labeling**, University of Toronto (Canada).
- Patnaik, A., Bhuyan, M. & MacDorman, K.F., 2024, **A Two-Branch Multi-Scale Residual Attention Network for Single Image Super-Resolution in Remote Sensing Imagery**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, <https://doi.org/10.1109/JSTARS.2024.3371710>.
- Pohl, C. & Van Genderen, J.L., 1998, **Review Article Multisensor Image Fusion in Remote Sensing: Concepts, Methods and Applications**, International Journal of Remote Sensing, 19(5), PP. 823-854, <https://doi.org/10.1080/014311698215748>.
- Polatkan, G., Zhou, M., Carin, L., Blei, D. & Daubechies, I., 2014, **A Bayesian Nonparametric Approach to Image Super-Resolution**, IEEE Transactions on Pattern Analysis and Machine Intelligence, 37(2), PP. 346-358, <https://doi.org/10.1109/TPAMI.2014.2321404>.
- Pruthi, J. & Dhingra, S., 2023, **A Review of Research on Road Feature Extraction Through Remote Sensing Images Based on Deep Learning Algorithms**, 3rd International Conference on Innovative Sustainable Computational Technologies (CISCT), 8-9<sup>th</sup> Sept., <https://doi.org/10.1109/CISCT57197.2023.10351299>.

- Purkait, P. & Chanda, B., 2013, **Image Upscaling Using Multiple Dictionaries of Natural Image Patches**, Asian Conference on Computer Vision, [https://doi.org/10.1007/978-3-642-37431-9\\_22](https://doi.org/10.1007/978-3-642-37431-9_22).
- Reddy, S.L.K., Rao, C.V., Kumar, P.R., Anjaneyulu, R.V.G. & Bothale, V.M., 2019, **Automatic Road Feature Extraction Using MRF from LANDSAT-8 OLI Images**, 2019 IEEE Recent Advances in Geoscience and Remote Sensing: Technologies, Standards and Applications (TENARSS), Kochi, India, 2019, PP. 15-20, <https://doi.org/10.1109/TENARSS48957.2019.8976046>.
- Sahu, D.K. & Parsai, M., 2012, **Different Image Fusion Techniques-A Critical Review**, International Journal of Modern Engineering Research (IJMER), 2(5), PP. 4298-4301.
- Shahi, K., Shafri, H.Z., Taherzadeh, E., Mansor, S. & Muniandy, R., 2015, **A Novel Spectral Index to Automatically Extract Road Networks from WorldView-2 Satellite Imagery**, The Egyptian Journal of Remote Sensing and Space Science, 18(1), PP. 27-33, <https://doi.org/10.1016/j.ejrs.2014.12.003>.
- Shao, Z., Zhou, Z., Huang, X. & Zhang, Y., 2021, **MRENet: Simultaneous Extraction of Road Surface and Road Centerline in Complex Urban Scenes from Very High-Resolution Images**, Remote Sensing, 13(2), P. 239, <https://doi.org/10.3390/rs13020239>.
- Sharma, P., Kumar, R. & Gupta, M., 2023, **Remote Sensing Images based Road Network Extraction Using Deep Learning: A Systematic Review**, Research Square Platform LLC, <https://dx.doi.org/10.21203/rs.3.rs-2493427/v1>.
- Singh, P.P. & Garg, R.D., 2014, **Road Detection from Remote Sensing Images Using Impervious Surface Characteristics: Review and Implication**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 40, PP. 955-959, <https://doi.org/10.5194/isprsarchives-XL-8-955-2014>.
- Singh, S., Mittal, N. & Singh, H., 2021, **Review of Various Image Fusion Algorithms and Image Fusion Performance Metric**, Archives of Computational Methods in Engineering, 28, PP. 3645-3659, <https://doi.org/10.1007/s11831-020-09518-x>.
- Singh, S., Singh, H., Bueno, G., Deniz, O., Singh, S., Monga, H., Hrisheeksha, P. & Pedraza, A., 2023, **A Review of Image Fusion: Methods, Applications and Performance Metrics**, Digital Signal Processing, 137, P. 104020, <https://doi.org/10.1016/j.dsp.2023.104020>.
- Sonka, M., Hlavac, V. & Boyle, R., 2014, **Image Processing, Analysis, and Machine Vision**, Cengage Learning.
- Soufi, O. & Belouadha, F.Z., 2023, **FSRSI: New Deep Learning-Based Approach for Super-Resolution of Multispectral Satellite Images**, Ingenierie des Systemes d'Information, 28(1), P. 113, <https://doi.org/10.18280/isi.280112>.
- Spoto, F., Sy, O., Laberinti, P., Martimort, P., Fernandez, V., Colin, O., Hoersch, B. & Meygret, A., 2012, **Overview of Sentinel-2**, IEEE International Geoscience and Remote Sensing Symposium, Munich, Germany, PP. 1707-1710, <https://doi.org/10.1109/IGARSS.2012.6351195>.
- Sun, J., Xu, Z. & Shum, H.-Y., 2008, **Image Super-Resolution Using Gradient Profile Prior**, IEEE Conference on Computer Vision and Pattern Recognition, Anchorage, AK, PP. 1-8, <https://doi.org/10.1109/CVPR.2008.4587659>.
- Tao, C., Qi, J., Li, Y., Wang, H. & Li, H., 2019, **Spatial Information Inference Net: Road Extraction Using Road-Specific Contextual Information**, ISPRS Journal of Photogrammetry and Remote Sensing, 158, PP. 155-166, <https://doi.org/10.1016/j.isprsjprs.2019.10.001>.
- Timofte, R., De Smet, V. & Van Gool, L., 2013, **Anchored Neighborhood Regression for Fast Example-Based Super-Resolution**, 2013 IEEE International Conference on Computer Vision, Sydney, NSW, Australia, PP. 1920-1927, <https://doi.org/10.1109/ICCV.2013.241>.
- Timofte, R., Agustsson, E., Van Gool, L., Yang, M.-H. & Zhang, L., 2017, **Ntire 2017 Challenge on Single Image Super-Resolution: Methods and Results**, 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Honolulu, HI, USA, PP. 1110-1121, <https://doi.org/10.1109/CVPRW.2017.149>.
- Versaci, M. & Morabito, F.C., 2021, **Image Edge Detection: A New Approach Based on Fuzzy Entropy and Fuzzy Divergence**, International Journal of Fuzzy Systems, 23(4), PP. 918-936, <https://doi.org/10.1007/s40815-020-01030-5>.

- Wang, W., Yang, N., Zhang, Y., Wang, F., Cao, T. & Eklund, P., 2016, **A Review of Road Extraction from Remote Sensing Images**, Journal of Traffic and Transportation Engineering (English Ed.), 3(3), PP. 271-282, <https://doi.org/10.1016/j.jtte.2016.05.005>.
- Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Qiao, Y. & Change Loy, C., 2018, **Esrgan: Enhanced Super-Resolution Generative Adversarial Networks**, Proceedings of the European Conference on Computer Vision (ECCV) Workshops.
- Wei, Y., Zhang, K. & Ji, S., 2019, **Road Network Extraction from Satellite Images Using CNN Based Segmentation and Tracing**, IGARSS 2019, IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan, PP. 3923-3926, <https://doi.org/10.1109/IGARSS.2019.8898565>.
- Winiwarter, L., Coops, N.C., Bastyr, A., Roussel, J.-R., Zhao, D.Q., Lamb, C.T. & Ford, A.T., 2024, **Extraction of Forest Road Information from CubeSat Imagery Using Convolutional Neural Networks**, Remote Sensing, 16(6), P. 1083, <https://doi.org/10.3390/rs16061083>.
- Xia, G.-S., Hu, J., Hu, F., Shi, B., Bai, X., Zhong, Y., Zhang, L. & Lu, X., 2017, **AID: A Benchmark Data Set for Performance Evaluation of Aerial Scene Classification**, IEEE Transactions on Geoscience and Remote Sensing, 55(7), PP. 3965-3981, <https://doi.org/10.1109/TGRS.2017.2685945>.
- Xie, J., Xu, L. & Chen, E., 2012, **Image Denoising and Inpainting with Deep Neural Networks**, NIPS'12: Proceedings of the 26th International Conference on Neural Information Processing Systems, 1, PP. 341-343, <https://dl.acm.org/doi/10.5555/2999134.2999173>.
- Yadav, M., 2021, **A Multi-Constraint Combined Method for Road Extraction from Airborne Laser Scanning Data**, Measurement, 186, P. 110077, <https://doi.org/10.1016/j.measurement.2021.110077>.
- Yang, J., Wright, J., Huang, T.S. & Ma, Y., 2010, **Image Super-Resolution via Sparse Representation**, IEEE Transactions on Image Processing, 19(11), PP. 2861-2873, <https://doi.org/10.1109/TIP.2010.2050625>.
- Yanuari, B. & Utami, E., 2022, **Convolutional Neural Network for Road Network Detections Using Sentinel 2A**, International Journal of Innovative Science and Research Technology, 7(12), PP. 463-468, <https://doi.org/10.5281/zenodo.7487943>.
- Ye, W., Lin, B., Lao, J., Liu, Y. & Lin, Z., 2024, **MRA-IDN: A Lightweight Super-Resolution Framework of Remote Sensing Images Based on Multi-Scale Residual Attention Fusion Mechanism**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 17, PP. 7781-7800, <https://doi.org/10.1109/JSTARS.2024.3381653>.
- Zabalza, M. & Bernardini, A., 2022, **Super-Resolution of Sentinel-2 Images Using a Spectral Attention Mechanism**, Remote Sensing, 14(12), P. 2890, <https://doi.org/10.3390/rs14122890>.
- Zeyde, R., Elad, M. & Protter, M., 2012, **On Single Image Scale-Up Using Sparse-Representations**, Curves and Surfaces: 7th International Conference, Avignon, France, June 24-30, Revised Selected Papers 7, [https://doi.org/10.1007/978-3-642-27413-8\\_47](https://doi.org/10.1007/978-3-642-27413-8_47).
- Zhang, Y., 2008, **Methods for Image Fusion Quality Assessment-A Review, Comparison and Analysis**, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 37(PART B7), 1101-1109.
- Zhang, J., 2010, **Multi-Source Remote Sensing Data Fusion: Status and Trends**, International Journal of Image and Data Fusion, 1(1), PP. 5-24, <https://doi.org/10.1080/19479830903561035>.
- Zhang, K., Gao, X., Tao, D. & Li, X., 2012, **Single Image Super-Resolution with Non-Local Means and Steering Kernel Regression**, IEEE Transactions on Image Processing, 21(11), PP. 4544-4556, <https://doi.org/10.1109/TIP.2012.2208977>.
- Zhang, Z., Liu, Q. & Wang, Y., 2018, **Road Extraction by Deep Residual U-Net**, IEEE Geoscience and Remote Sensing Letters, 15(5), PP. 749-753.
- Zhang, Q., Kong, Q., Zhang, C., You, S., Wei, H., Sun, R. & Li, L., 2019a, **A New Road Extraction Method Using Sentinel-1 SAR Images Based on the Deep Fully Convolutional Neural Network**, European Journal of Remote Sensing, 52(1), PP. 572-582, <https://doi.org/10.1080/22797254.2019.1694447>.

- Zhang, C., Wei, S., Ji, S. & Lu, M., 2019b, **Detecting Large-Scale Urban Land Cover Changes from Very High Resolution Remote Sensing Images Using CNN-Based Classification**, ISPRS International Journal of Geo-Information, 8(4), P. 189, <https://doi.org/10.3390/ijgi8040189>.
- Zhang, K., Sumbul, G. & Demir, B., 2020, **An Approach to Super-Resolution of Sentinel-2 Images Based on Generative Adversarial Networks**, Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS), Tunis, Tunisia, 2020, PP. 69-72, <https://doi.org/10.1109/M2GARSS47143.2020.9105165>.
- Zhang, T., Su, J., Xu, Z., Luo, Y. & Li, J., 2021, **Sentinel-2 Satellite Imagery for Urban Land Cover Classification by Optimized Random Forest Classifier**, Applied Sciences, 11(2), P. 543, <https://doi.org/10.3390/app11020543>.
- Zhang, Y., Dong, L., Yang, H., Qing, L., He, X. & Chen, H., 2022, **Weakly-Supervised Contrastive Learning-Based Implicit Degradation Modeling for Blind Image Super-Resolution**, Knowledge-Based Systems, 249, P. 108984, <https://doi.org/10.1016/j.knosys.2022.108984>.
- Zhang, Y., Zhang, L., Wang, Y. & Xu, W., 2024a, **AGF-Net: Adaptive Global Feature Fusion Network for Road Extraction from Remote-Sensing Images**, Complex & Intelligent Systems, 10, PP. 4311-4328, <https://doi.org/10.1007/s40747-024-01364-9>.
- Zhang, W., Tan, Z., Lv, Q., Li, J., Zhu, B. & Liu, Y., 2024b, **An Efficient Hybrid CNN-Transformer Approach for Remote Sensing Super-Resolution**, Remote Sensing, 16(5), P. 880, <https://doi.org/10.3390/rs16050880>.
- Zhao, N., Wei, Q., Basarab, A., Dobigeon, N., Kouame, D. & Tourneret, J.-Y., 2015, **Fast Single Image Super-Resolution**, arXiv preprint arXiv:1510.00143, <https://doi.org/10.1109/TIP.2016.2567075>.
- Zhu, X., Cai, F., Tian, J. & Williams, T.K.-A., 2018, **Spatiotemporal Fusion of Multisource Remote Sensing Data: Literature Survey, Taxonomy, Principles, Applications, and Future Directions**, Remote Sensing, 10(4), P. 527, <https://doi.org/10.3390/rs10040527>.
- Zhu, Q., Zhang, Y., Wang, L., Zhong, Y., Guan, Q., Lu, X., Zhang, L. & Li, D., 2021, **A Global Context-Aware and Batch-Independent Network for Road Extraction from VHR Satellite Imagery**, ISPRS Journal of Photogrammetry and Remote Sensing, 175, PP. 353-365, <https://doi.org/10.1016/j.isprs.2021.03.016>.
- Zhu, X., Huang, X., Cao, W., Yang, X., Zhou, Y. & Wang, S., 2024, **Road Extraction from Remote Sensing Imagery with Spatial Attention Based on Swin Transformer**, Remote Sensing, 16(7), P. 1183, <https://doi.org/10.3390/rs16071183>.
- Zou, Q., Ni, L., Zhang, T. & Wang, Q., 2015, **Deep Learning Based Feature Selection for Remote Sensing Scene Classification**, IEEE Geoscience and Remote Sensing Letters, 12(11), PP. 2321-2325, <https://doi.org/10.1109/LGRS.2015.2475299>.

**This Page is Intentionally Left Blank**