

تحلیل روش‌ها، چالش‌ها و دیدگاه‌های موجود در زمینه‌ی شناسایی شبکه‌های روستایی با محوریت استفاده از تصاویر سنجش‌ازدوری

علی جوادی مقدم، عباس کیانی*

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

*نویسنده عهده دار مکاتبات: a.kiani@nit.ac.ir

تاریخ پذیرش مقاله: ۱۴۰۳/۱۱/۲۳

تاریخ دریافت مقاله: ۱۴۰۳/۰۸/۱۵

چکیده

سابقه و هدف: با پیشرفت فناوری‌های سنجش‌ازدوری و یادگیری عمیق، شناسایی خودکار شبکه‌ی راه‌ها به‌ویژه در مناطق روستایی و راه‌های فرعی، امکان‌پذیر شده است. همچنین، روش‌های سنتی نقشه‌برداری، به دلیل هزینه‌بر و زمان‌بر بودن، جای خود را به روش‌های مبتنی بر داده‌های سنجش‌ازدوری و یادگیری ماشین داده‌اند. بدین منظور هدف این تحقیق، بررسی جامعی از تحقیقات انجام‌شده در زمینه‌ی تهیه نقشه راه‌ها با استفاده از داده‌های سنجش‌ازدوری خصوصاً در سال‌های اخیر می‌باشد. به‌طور کلی تهیه نقشه از شبکه‌ی راه‌ها، روش‌های متفاوتی را دربر می‌گیرد که یکی از روش‌های قابل اعتماد و مقرون‌به‌صرفه، شناسایی اتوماتیک از طریق تصاویر سنجش‌ازدوری می‌باشد در نگاه کلی بنابر نوع مسیر مورد مطالعه که شبکه‌ی راه‌های روستایی می‌باشد، تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط و دسترسی رایگان نمی‌توانند گزینه‌ای جهت دستیابی به دقت‌های بالا باشند؛ از این رو، می‌توان از روش‌های تلفیق تصاویر ماهواره‌ای که منجر به افزایش حد تفکیک مکانی می‌شوند و نتایج الگوریتم‌های شناسایی را بهبود می‌بخشند، بهره گرفت. یکی از راه‌های تلفیق تصاویر ماهواره‌ای، الگوریتم‌های سوپر رزولوشن می‌باشند. این مطالعه می‌تواند مرجعی جهت مقایسه و انتخاب روشی جهت شناسایی شبکه‌ی راه‌ها به‌صورت خودکار و همچنین روش‌هایی جهت بهبود حد تفکیک مکانی تصاویر سنجش‌ازدوری برای کمک به شناسایی راه‌هایی با عرض کم (مانند شبکه‌ی راه‌های روستایی) باشد، تا محققان با توجه به هدف و نوع شبکه‌ی راه مورد مطالعه، داده‌ها و الگوریتم مناسب را انتخاب نمایند.

مواد و روش: هدف این پژوهش بررسی روش‌های موجود تشخیص شبکه‌ی راه‌ها و چگونگی استفاده از تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط جهت این امر می‌باشد. در ابتدا داده‌ها و روش‌های قابل استفاده جهت تولید نقشه‌ی شبکه‌ی راه مورد بررسی قرار گرفته است. در ادامه، اصول استفاده شده در حوزه‌ی تشخیص شبکه‌ی راه‌ها با استفاده از تصاویر سنجش‌ازدوری تشریح شده و بر اساس این اصول دسته‌بندی بصورت روش‌های مبتنی بر کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین انجام پذیرفته است. جهت به کارگیری تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط نیز روش‌های بهبود حد تفکیک مکانی مورد بررسی قرار گرفته‌اند. در نهایت روش‌ها از نظر پارامترهای ورودی، نحوه سازوکار و خروجی قابل ارائه بررسی شده‌اند تا نقاط قوت و ضعف هر کدام شناسایی شود و بتوان از آنها در کاربردهای مختلف به بهترین نحو استفاده نمود.

بحث و بررسی: با توجه به بررسی‌های انجام‌شده از مقاله‌های مورد بررسی از مجله‌های معتبر مختلف در زمینه‌ی تشخیص شبکه‌ی راه‌ها، روش‌های مبتنی بر کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین به‌ترتیب سهم‌هایی حدود ۲۸، ۳۱، ۵ و ۳۶ درصدی را دارا می‌باشند؛ شایان ذکر است که در سال‌های اخیر روش‌های مبتنی بر کلاسه‌بندی و قطعه‌بندی با شبکه‌های عصبی توسعه یافته‌اند که در حالت کلی روش‌های مبتنی بر یادگیری ماشین سهم بیشتری (حدود ۶۰ درصد) را در بر بگیرد. همچنین در زمینه‌ی سوپر رزولوشن، بررسی‌های انجام‌شده نشان می‌دهد که روش‌های مبتنی بر روش‌های سنتی و یادگیری عمیق به‌ترتیب سهم‌هایی حدود ۴۴ و ۵۶ درصدی را دارا می‌باشند که در سال‌های اخیر اغلب رویکردهای مبتنی بر یادگیری عمیق در حال توسعه هستند.

نتیجه گیری: بررسی‌ها نشان می‌دهد که استفاده از مدل‌های یادگیری عمیق در تشخیص شبکه‌ی راه‌ها نتایج بهتری نسبت به روش‌های سنتی ارائه می‌دهند و به تدریج جایگزین این روش‌ها شده‌اند. مدل‌های یادگیری عمیق با قابلیت استخراج ویژگی‌های پیچیده و کاهش نیاز به مداخله‌ی انسانی، دقت و کارایی فرایند تشخیص را بهبود بخشیده‌اند. از طرف دیگر، تکنیک‌های سوپر رزولوشن مبتنی بر یادگیری عمیق می‌توانند با افزایش حد تفکیک مکانی تصاویر، مشکلات ناشی از کمبود تصاویر با وضوح بالا را حل کنند. این تکنیک‌ها با حفظ ویژگی‌های طیفی و کاهش نویز، می‌توانند تصاویر با کیفیت‌تری برای تشخیص راه‌ها ارائه دهند. به طور کلی، ترکیب روش‌های سوپر رزولوشن و یادگیری عمیق برای شناسایی شبکه‌ی راه‌ها، رویکردی مقرون به صرفه و کارآمد برای به‌روزرسانی نقشه‌های راه ارائه می‌دهد. این رویکردها با کاهش هزینه‌ها و زمان مورد نیاز برای تشخیص، می‌توانند به‌طور گسترده‌ای توسط محققان و متخصصان در زمینه‌های مختلف مورد استفاده قرار گیرند. همچنین، با توسعه‌ی بیشتر این تکنیک‌ها و بهبود دقت آن‌ها، می‌توان به راهکارهای جدیدی برای مدیریت و برنامه‌ریزی ساخت و نگهداری جاده‌ها دست یافت.

کلمات کلیدی: تصاویر ماهواره‌ای حد تفکیک متوسط، هوش مصنوعی، شبکه‌ی راه‌ها، سنجش‌ازدور، سوپر رزولوشن.

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

Ali javadi moghadam, Abbas kiani*

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

* Corresponding author: a.kiani@nit.ac.ir

Received:

Accepted:

Background and Objective: By advancement of remote sensing and deep learning technologies, the automatic identification of road networks, particularly in rural areas 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. Therefore, this study aims to comprehensively review research conducted on the preparation of road maps using remote sensing data, especially in recent years. In general, preparing a map of the road network involves various methods, and one of the reliable and cost-effective methods is automatic road detection using remote sensing images. Examination of various research results indicates that among the available automatic approaches, methods based on deep learning networks can provide acceptable and more reliable accuracies compared to other conventional methods. Considering the common width used in road construction, remote sensing images with different spatial resolutions have been used in research, each with its advantages and disadvantages. In general, for the type of route under study, which is the rural road network, satellite images with medium spatial resolution and free access cannot achieve high accuracy. Thus, satellite images can be integrated to enhance spatial resolution and improve detection algorithms. One way to integrate satellite images is through super-resolution algorithms. This study can serve as a reference for comparing and selecting methods for the automatic detection of road networks and for improving the spatial resolution of remote sensing images to assist in identifying narrow roads (such as rural road networks), so that researchers can select appropriate data and algorithms based on the objective and type of road network under study.

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 ۲۸%, ۳۱%, ۵%, and ۳۶% shares, respectively. In recent years, classification and segmentation methods based on neural networks have been developed, encompassing a larger share (about ۶۰%) of machine learning methods in general. Additionally, in super-resolution, investigations show that methods based on traditional techniques and deep learning account for approximately ۴۴% and ۵۶% 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.

Kay Words: Medium spatial resolution satellite images, artificial intelligence, road network, remote sensing, super-resolution.

۱- مقدمه

راه‌ها همواره عامل توسعه و پیشرفت کشورها بوده‌اند و جاده‌ها نقش کلیدی در توسعه سیستم‌های حمل‌ونقل ایفا می‌کنند. ازجمله‌ی 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 مهم می‌باشند (Gao et al., ۲۰۱۹). برای بهره‌برداری بهتر از ظرفیت جاده‌ها می‌بایست یک نقشه کامل، جامع و بروز از شبکه راه‌های موجود در دست متولی این امر وجود داشته باشد تا بتوان به موقعیت، طول و مابقی اطلاعات موردنیاز دست یافت. برای تولید و یا به‌روزرسانی نقشه شبکه جاده‌ها می‌توان از دو روش استفاده کرد، اول بررسی سنتی با مراجعه مستقیم به محل پروژه و دوم با استفاده از رویکردهای سنجنش‌زدوری (Q. Zhang et al., ۲۰۱۹). روش‌های سنتی نقشه‌برداری معمولاً پرزحمت، وقت‌گیر و همراه با صرف هزینه بالا هستند، به همین دلیل است که باید به دنبال روش‌هایی بود تا علاوه بر در برگرستن مناطق وسیع، بتوان، هزینه و زمان اجرای پروژه را کاهش داد. در دهه‌های اخیر،

بهره‌گیری از تصاویر سنجش‌ازدوری به امری متداول در حوزه نقشه‌برداری تبدیل شده است. این فناوری راه را برای کاربرد تشخیص خودکار جاده‌ها در مقیاس بزرگ باز کرده است.

تصاویر سنجش‌ازدوری دارای دسته‌بندی‌های مختلفی هستند که بسته به نوع کاربرد می‌توان از هر یک بهره گرفت. تصاویر سنجش‌ازدوری را از منظر فاصله می‌توان به دو دسته تصاویر هوابرد و تصاویر ماهواره‌ای تقسیم نمود که هر کدام دارای انواع و ویژگی‌های متعددی هستند. تصاویر هوابرد را نیز می‌توان بر اساس 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 نمی‌باشند. تصاویر ماهواره‌ای دارای حد تفکیک مکانی مختلفی اعم از بالا، متوسط و پایین هستند که بر حسب نیاز و مساحت منطقه مطالعاتی انتخاب می‌شوند. این تصاویر بر اساس دسترسی به داده‌های ماهواره‌ای، انواع آن‌ها در دو دسته‌ی رایگان و تجاری قرار می‌گیرد. به دلیل قیمت بالا و دسترسی دشوار به تصاویر تجاری، استفاده از تصاویر رایگان موجود، مقرون‌به‌صرفه و منطقی‌تر به نظر می‌رسد و سبب کاهش چشمگیر هزینه‌های اجرایی هر پروژه می‌گردد. یکی از ماهواره‌های موجود با حد تفکیک مکانی متوسط و رایگان که طی سال‌های اخیر موردتوجه بسیاری از عوامل این عرصه قرار گرفته، ماهواره سنتینل-۲ است. حد تفکیک مکانی باندهای چند طیفی تصاویر اخذشده توسط این ماهواره ۱۰ و ۲۰ متری است و در مقایسه با عرض راه‌ها که در حدود ۷ تا ۶۰ متر (در یک باند) می‌باشند، در شناسایی راه‌ها با عرض کم، دچار چالش می‌گردند؛ لذا اخیراً راهکارهایی به‌منظور استفاده ترکیبی از تصاویر مختلف جهت بهبود این مسئله توسط محققان ارائه شده که یکی از آن‌ها، توسعه الگوریتم‌های سوپر رزولوشن^۱ (Adigun et al., ۲۰۱۹)، می‌باشد. به‌صورت کلی با استفاده از این تکنیک‌ها می‌توان تصاویر با رزولوشن مکانی متوسط را بهبود داد و از آن‌ها استفاده مفیدتری نمود.

طبق آخرین آمار اعلام شده، حدود ۲۲۰ هزار کیلومتر انواع راه در کشور ایران، اعم از بزرگراه، آزادراه، راه‌های شهری، راه‌های بین‌شهری و راه‌های روستایی، سرتاسر کشور را به هم متصل می‌کند (۱۴۰۰، Market analysis news site). تولید نقشه از شبکه‌ی راه‌هایی با این وسعت کاری زمان‌بر و نیازمند صرف هزینه زیاد می‌باشد. لذا بنا بر ضرورت و اهمیت مسئله مذکور و با توجه به موارد گفته شده می‌بایست به دنبال روش‌هایی بود تا بتوان اقدام به تولید شبکه‌ای وسیع از راه‌های یک منطقه کرد تا ضمن آگاهی از وضعیت کنونی راه‌های کشور امکان به‌روزرسانی دوره‌ای نقشه‌ها با صرف کمترین هزینه و وقت، در زمان‌های مختلف برحسب نیاز مدیران و سازمان‌ها وجود داشته باشد.

هدف اصلی این پژوهش بررسی روش‌های مطرح و جدید باهدف تشخیص شبکه‌ی راه‌ها با تأکید بر راه‌های فرعی روستایی و بین شهری می‌باشد. در این راستا داده‌های قابل استفاده جهت شناسایی شبکه‌ی راه‌ها نیز موردبررسی قرار گرفته که بر اساس وسعت و عرض شبکه راه‌های مدنظر و نحوه دسترسی به داده‌ها، تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط مورد توجه این مطالعه می‌باشد. جهت تحلیل پژوهش‌های انجام شده مرتبط با تشخیص شبکه‌ی راه‌ها از نظر ورودی، محصولات، پارامترهای مورد نیاز، خروجی و هزینه، دسته‌بندی بصورت روش‌های مبتنی بر کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین انجام پذیرفته است. با توجه ترجیح استفاده از تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط در تشخیص شبکه راه‌های روستایی، روش‌های بهبود حد تفکیک مکانی همانند فیوژن^۲ و سوپررزولوشن نیز تشریح شده و ویژگی‌های هر یک موردبررسی قرار گرفت. در نهایت روش‌ها از نظر پارامترهای ورودی، نحوه سازوکار و خروجی قابل ارائه بررسی و نقاط قوت و ضعف هر کدام شناسایی شدند؛ تا بتوان از آن‌ها در کاربردهای مختلف به بهترین نحو استفاده نمود.

۲- مبانی نظری

در این بخش سعی شده تا با سه دسته‌بندی کلی داده‌های قابل استفاده جهت شناسایی شبکه‌ی راه‌ها، روش‌های شناسایی شبکه‌ی راه‌ها و روش‌های بهبود حد تفکیک مکانی تصاویر سنجش‌ازدوری و تشریح مبانی نظری الگوریتم‌ها و داده‌های مورد استفاده، روند پیشرفت و اهمیت حوزه پایش شبکه راه‌ها بهتر توضیح داده شود.

^۱ Super Resolution

^۲ Fusion (Pan Sharpening)


۱-۲- داده‌های قابل استفاده جهت شناسایی شبکه‌ی راه‌ها

داده‌های مورد استفاده در تشخیص شبکه‌ی راه‌ها، طیف گسترده‌ای از داده‌های نقشه‌برداری را دربر می‌گیرد. در این راستا بنا بر گستردگی منطقه‌ی مورد مطالعه، عرض راه‌های موجود در منطقه و عواملی از این دست، می‌توان نوع داده‌ی مناسب که در شکل ۱ آمده را انتخاب نمود. این دسته‌بندی به کمک مطالعات و داده‌های موجود صورت گرفته است.



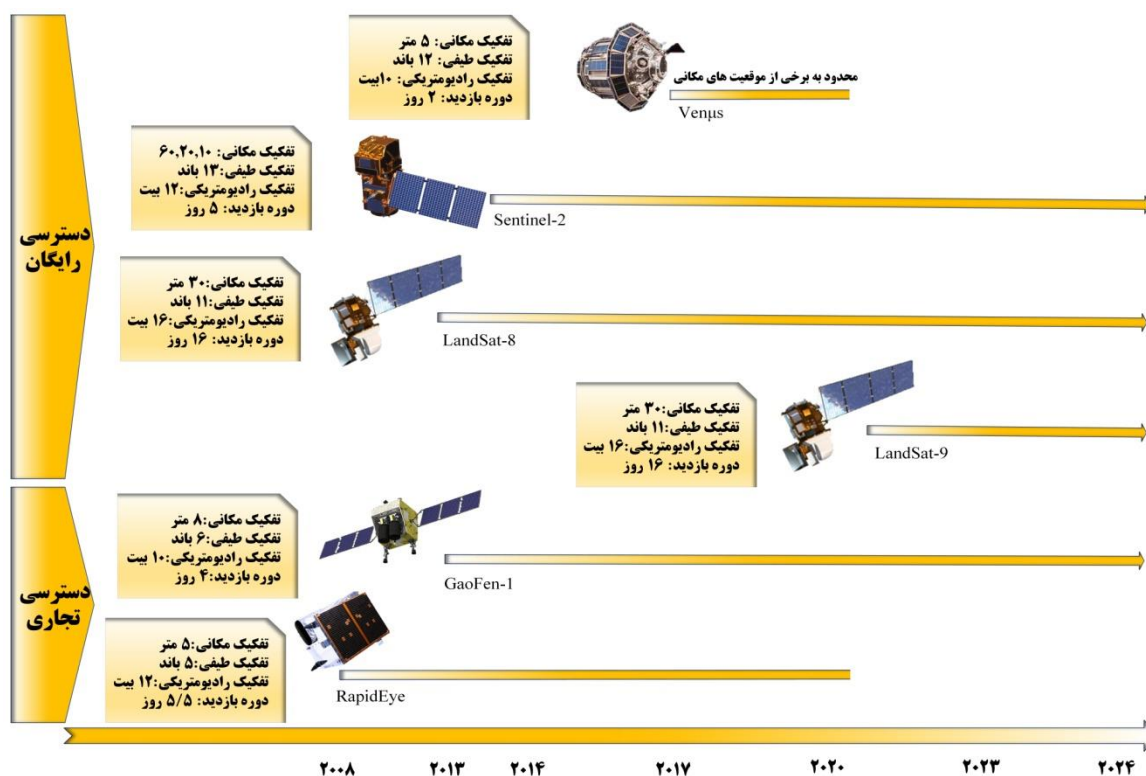
شکل ۱) روش‌های اخذ داده جهت تهیه نقشه‌ی راه (Sharma et al., ۲۰۲۳; Badran et al., ۲۰۲۴).

داده‌های مورد استفاده در تشخیص شبکه‌ی راه‌ها، طیف گسترده‌ای از تصاویر سنجش از دوری را دربر می‌گیرد که بنا بر گستردگی منطقه‌ی مورد مطالعه، عرض راه‌های موجود در منطقه و عواملی از این دست، می‌توان نوع داده‌ی مناسب را انتخاب کرد. تصاویر سنجش از دوری را می‌توان به دو بخش کلی تصاویر ماهواره‌ای و هوایی تقسیم نمود که در شکل ۲ به معرفی برخی از مزایا و معایب آن به کمک مطالعات مروری (Sharma et al., ۲۰۲۳; Liu et al., ۲۰۲۴; Z. Chen et al., ۲۰۲۲) پرداخته شده است.



شکل ۲) برخی از مزایا و معایب تصاویر سنجش از دوری قابل استفاده جهت تشخیص راه به صورت دسته بندی.

بنا بر موارد موجود در شکل ۲ می توان دریافت که استفاده از تصاویر هوایی برای تشخیص شبکه راهها به دلیل آنکه شبکه راهها دارای وسعت و گستردگی زیادی هستند، از منظر هزینه به صرفه و منطقی نمی باشد؛ بنابراین باید به سراغ تصاویر ماهواره ای رفت. در استفاده از تصاویر سنجش از دوری پارامترهای مختلفی مانند حدتفکیک مکانی، حدتفکیک طیفی، نحوه دسترسی و... با توجه به کاربرد در نظر گرفته می شود. ویژگی های برخی از سنجنده های موجود با دسته بندی نوع دسترسی به آنها در شکل ۳ ترسیم شده است.




شکل ۳) ویژگی های برخی از سنجنده ها با حد تفکیک مکانی متوسط و سری زمانی دسترسی به داده های آنها (L. Chen et al., ۲۰۲۲; Dick et al., ۲۰۲۲; Masek et al., ۲۰۲۰; Spoto et al., ۲۰۱۲).

شایان ذکر است که تعداد بسیاری از ماهواره ها در زمینه ی تصویربرداری از زمین و پایش عوارض پرتاب شده اند که به دلیل محدودیت در نگارش، تنها به بررسی چند مورد اصلی و مرسوم پرداخته شده است.

۲-۲- روش های شناسایی شبکه ی راهها


شبکه ی راهها، مانند بسیاری از شبکه ها، شامل مجموعه ای از مکان ها و مجموعه ای از پیوندها که نشانگر ارتباطات بین این مکان ها هستند، می باشند. در این مطالعه این مکان ها، شهرها و روستاها و این پیوندها راه های مواصلاتی بین آنها در نظر گرفته شده است. به عنوان نمونه ای از تشخیص شبکه راه های روستایی که به راه های مواصلاتی بین روستاها و شهرهای اطراف اطلاق می گردد، در شکل ۴ ارائه گردیده است.



الف ب ج د

شکل ۴) شبکه راه‌ها؛ الف) تصویر گوگل ارث از منطقه، ب) نقشه راه OSM^۱ از منطقه، ج) نمونه‌ای از شبکه‌ی راه شناسایی شده، د) داده‌ی واقعیت زمینی (Botelho Jr et al., ۲۰۲۲).

روش‌های متعددی در حوزه‌ی شناسایی شبکه‌ی راه‌ها در طول سال‌ها، توسعه داده شده که همواره مورد استفاده قرار می‌گیرند و هر روش می‌تواند پیرو یک یا چند اصل باشد. در شکل ۵ برخی از روش‌های تشخیص شبکه‌ی راه و اصول مرتبط به آن‌ها آورده شده است.



شکل ۵) دسته‌بندی برخی از روش‌های تشخیص شبکه‌ی راه‌ها بر اساس اصول به کار گرفته شده (Abdollahi, Pradhan, & Alamri, ۲۰۲۰; Ahmed et al., ۲۰۲۲; Arora et al., ۲۰۲۳; Bakhtiari et al., ۲۰۱۷; W. Chen et al., ۲۰۲۲; Gao et al., ۲۰۱۹; Ghandorh et al., ۲۰۲۲; Grinias et al., ۲۰۱۶; Henry et al., ۲۰۱۸; Lian et al., ۲۰۲۰; Liu & Wang, ۲۰۰۸; Yongcheng Liu et al., ۲۰۱۸; Yahui Liu et al., ۲۰۱۸; Luo et al., ۲۰۲۳; Shahi et al., ۲۰۱۵; Shao et al., ۲۰۲۱; Yadav, ۲۰۲۱; Yanuargi & Utami, ۲۰۲۲; C. Zhang et al., ۲۰۱۹; Q. Zhang et al., ۲۰۱۹; Zhang et al., ۲۰۲۱; Zhang et al., ۲۰۱۹).

در ادامه، به مختصری از مبانی مرتبط با روش‌های یاد شده در شکل فوق، پرداخته می‌شود.

۲-۱-۲- تشخیص لبه

اغلب برنامه‌های کاربردی پردازش تصویر در تصاویر سنجنش‌ازدور نیازمند تقسیم‌بندی تصویر به قسمت‌های کوچک‌تر، شامل تقسیم تصویر به اشیاء و مناطق تشکیل دهنده‌ی آن‌ها می‌باشند. الگوریتم‌های تقسیم‌بندی تصویر به‌طور کلی بر یکی از دو ویژگی اساسی مقادیر شدت روشنایی تصویر استوار است: تشابه و ناپیوستگی. تاکنون تشخیص لبه به‌عنوان رایج‌ترین روش برای تشخیص ناپیوستگی‌های معنی‌دار در سطح تصویر خاکستری می‌باشد (Jing et al., ۲۰۲۲). لبه را می‌توان به‌عنوان ناپیوستگی در سطح خاکستری، رنگ، بافت و... در یک تصویر تعریف کرد (Sonka et al., ۲۰۱۴).

بسیاری از روش‌های کلاسیک برای تشخیص لبه بر پایه مشتق پیکسل‌های تصویر اصلی عمل می‌کنند، اپراتورهای تشخیص لبه کلاسیک مانند رابرتز، سوبل، و اپراتور لاپلاسین تابع گاوسی و ... با محاسبه مشتقات جزئی در یک همسایگی به شناسایی لبه‌های تصویری می‌پردازند. تشخیص لبه بر اساس مشتق به دو کلاس کلی دسته‌بندی می‌شود: محاسبه بر اساس مشتق مرتبه اول و دوم. این روش‌های تشخیص لبه ساده ولی درعین حال حساس به نویز می‌باشند. به‌منظور کاهش اثر نویز

^۱ open street map

ابتدا تصویر مورد نظر را نرم کرده و سپس به تشخیص لبه اقدام می‌شود، البته این کار کنتراست لبه‌ها را کاهش می‌دهد و موجب دشواری در مکان‌یابی برخی از لبه‌های ضعیف تصویر خواهد شد (A. Kiani & H. Ebadi, ۲۰۱۵). به‌طور کلی، الگوریتم‌های تشخیص لبه، با دو چالش اصلی مواجه هستند. یکی تشخیص نقاط غلط به‌عنوان لبه که عمدتاً ناشی از نویز هستند و دیگری بریده بودن مرز اشیاء، که ناشی از کیفیت پایین تصویر و یا ضعف روش تشخیص لبه می‌باشد. علاوه بر روش‌های ذکر شده، روش‌های جدید دیگری نیز به‌منظور تشخیص لبه تصاویر استفاده شده‌اند. روش‌های مبتنی بر شبکه عصبی، فازی، الگوریتم کلونی مورچه‌ها، مورفولوژی و غیره (Versaci & Morabito, ۲۰۲۱). در این میان تحقیقاتی هم بر روی استخراج لبه‌های تصویر به کمک تئوری اطلاعات نیز انجام گرفته است. این روش عملکرد بهتری نسبت به روش‌های کلاسیک تشخیص لبه‌ها دارا می‌باشد و از ویژگی پیوستگی لبه‌های استخراجی سود می‌برد، اما عملکرد بهینه این روش در استخراج پیوسته‌ی لبه‌های قوی تصویر است و قادر به شناسایی همه‌ی تغییرات تصویری نمی‌باشد. در برخی تحقیقات نیز با توجه به این مشکلات از یک‌سو و همچنین کارآمدی روش تشخیص لبه با آنتروپی و ویژگی پیوسته بودن لبه‌ها در این روش از سوی دیگر که مورد نیاز کاربردهای سنجش‌ازدوری می‌باشد؛ پیشنهاد یک رویکرد جدید بر اساس تئوری اطلاعات و با بهره‌گیری از یک سیستم قانون مینا داده شده است (Kiani & Sahebi, ۲۰۱۵). تحقیقات بسیاری در زمینه‌ی تشخیص لبه انجام شده است و انتخاب روش بهینه باید با توجه به کیفیت رادیومتریکی و مکانی داده تصویری ورودی، زمان پردازش و همچنین توقعی که متناسب با نوع کاربرد، از خروجی تشخیص لبه انتظار می‌رود، صورت پذیرد.

۲-۲-۲- روش‌های قطعه‌بندی^۱

قطعه‌بندی به فرآیند تقسیم تصاویر به مناطق پیوسته، ناپیوسته و همگن فضایی با توجه به ویژگی‌های مکانی یا طیفی اشاره دارد. بسیاری از روش‌های قطعه‌بندی تصویر برای کاربردهای مختلف پیشنهاد شده است. با این حال، تنها تعداد محدودی منجر به نتایج کمی متقاعدکننده می‌شوند (Kiani et al., ۲۰۱۹)؛ دلیل آن این است که در بیشتر موارد، مناطق موردنظر بسیار ناهمگن هستند. روش‌های قطعه‌بندی تصویر را می‌توان به روش‌های قطعه‌بندی مبتنی بر پیکسل، مبتنی بر لبه و مبتنی بر منطقه تقسیم کرد (Blaschke et al., ۲۰۰۴).

قطعه‌بندی مبتنی بر پیکسل، هر پیکسل را به‌طور مستقل برچسب‌گذاری می‌کند. این روش بسیار ساده است، اما می‌تواند در تصاویری که دارای لبه‌های واضح یا مناطق متمایز نیستند، مؤثر نباشد. قطعه‌بندی مبتنی بر لبه، لبه‌های را در تصویر شناسایی و سپس از این لبه‌ها برای تشکیل مناطق استفاده می‌کند. این روش نسبت به قطعه‌بندی مبتنی بر پیکسل دقیق‌تر است، اما می‌تواند زمان‌بر باشد. قطعه‌بندی مبتنی بر منطقه، مناطق را در تصویر شناسایی می‌کند و سپس به هر منطقه برچسبی را اختصاص می‌دهد. این روش نسبت به دو روش دیگر دقیق‌تر است، اما اجرای آن می‌تواند زمان‌بر باشد.

۲-۲-۳- کلاسه‌بندی

شناسایی جاده‌ها به روش طبقه‌بندی تصاویر در سنجش‌ازدور، جهت شناسایی و تفکیک جاده‌ها از دیگر عناصر موجود در تصاویر سنجش‌ازدور مورد استفاده قرار می‌گیرند. استفاده از الگوریتم‌های کلاس‌بندی مختلف، نظیر روش‌های طبقه‌بندی سنتی مانند K-نزدیک‌ترین همسایه (KNN)، ماشین‌های بردار پشتیبان (SVM) و روش‌های یادگیری عمیق مانند شبکه‌های عصبی کانولوشن (CNN) که به‌طور خاص برای شناسایی ویژگی‌های پیچیده و الگوهای فضایی طراحی شده‌اند. البته طبقه‌بندی را نباید منحصر به روش‌های فوق دانست تحقیقات بسیاری با استفاده از طبقه‌بندی گره‌های درختی و روش‌های دیگر نیز پرداختند. برای نمونه مقاله تفسیر شی مبنای تصاویر سنجش‌ازدوری با حد تفکیک بالا بر مبنای سیستم‌های دانش‌پایه به بررسی روش‌های تفسیر تصاویر سنجش‌ازدور با استفاده از سیستم‌های دانش‌پایه با هدف بهبود دقت و کارایی تفسیر محصولات زمین از تصاویر با تفکیک بالا می‌پردازد (A. Kiani et al., 2018). در این مطالعه، تکنیک‌ها و الگوریتم‌های مختلف برای تحلیل و تفسیر داده‌های سنجش‌ازدور بررسی می‌شود و نمونه‌هایی از کاربرد این روش‌ها در تحلیل داده‌ها ارائه می‌شود. نتایج حاصل از این تحقیق نشان‌دهنده‌ی کارایی بالای سیستم‌های دانش‌پایه در کمک به تحلیل و طبقه‌بندی تصاویر سنجش‌ازدور است.

^۱ Segmentation

تولید نقشه‌های جاده‌ای دارای چالش‌هایی مانند ناهمگونی پوشش زمین است که شناسایی جاده‌ها در مناطقی که پوشش‌های مختلف زمین وجود دارد (مانند جنگل‌ها یا مناطق شهری) می‌تواند چالش‌ساز باشد. همچنین تأثیر تغییرات فصلی می‌تواند بر کیفیت تصاویر و در نتیجه دقت شناسایی تأثیر بگذارند. بعلاوه کیفیت داده‌های آموزشی و وجود داده‌های متنوع و با کیفیت برای آموزش مدل‌ها اهمیت بالایی دارد و ممکن است در دسترس نباشد.

شناسایی جاده‌ها و ساختمان‌ها در روش‌های سنجش‌ازدور به‌طور فزاینده‌ای به‌عنوان فرآیندهایی مکمل در نظر گرفته می‌شوند. این دو نوع ویژگی زمینی از جنبه‌های مختلفی به یکدیگر وابسته‌اند و شناسایی آن‌ها به صورت جداگانه می‌تواند چالش‌های زیادی به همراه داشته باشد. در این زمینه، بسیاری از مقالات علمی بر این نکته تأکید کرده‌اند که شناسایی مستقل این دو ویژگی، به ویژه در مناطق شهری، معمولاً با مشکلاتی مواجه است. به‌عنوان مثال وجود انحرافات بصری، جاده‌ها و ساختمان‌ها می‌توانند به لحاظ هندسی و ظاهری شباهت‌هایی داشته باشند که باعث می‌شود فرایند شناسایی این دو از یکدیگر دشوار باشد. در بسیاری از مطالعات اخیر، تمرکز بر روش‌هایی است که بتوانند این دو ویژگی را به‌طور هم‌زمان و در یک چارچوب یکپارچه شناسایی کنند تا دقت و کارایی فرایند تفسیر تصاویر سنجش‌ازدور بهبود یابد.

در برخی از مطالعات از روش‌های دو مرحله‌ای برای استخراج جاده‌ها از تصاویر با وضوح بالا در سنجش‌ازدور می‌پردازد. هدف اصلی بهبود دقت و کارایی شناسایی جاده‌ها است که از روش‌های طبقه‌بندی تصویر برای شناسایی نواحی مرتبط با جاده‌ها استفاده می‌کنند (Kahraman et al., 2018). این شامل استفاده از ویژگی‌های طیفی و فضایی تصاویر می‌باشد. 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.

مقاله "شناسایی جاده از تصاویر سنجش‌ازدور با استفاده از یادگیری ماشین" به بررسی تکنیک‌های مختلف یادگیری ماشین برای شناسایی جاده‌ها در تصاویر ماهواره‌ای و سنجش‌ازدور می‌پردازد (Deepan et al., ۲۰۱۸). در این مقاله، نویسندگان چندین الگوریتم یادگیری ماشین را مورد آزمون قرار می‌دهند و به تجزیه و تحلیل عملکرد آن‌ها در شناسایی الگوهای جاده‌ای در داده‌های تصویری می‌پردازند. نتایج نشان می‌دهد که استفاده از این الگوریتم‌ها، به طور قابل توجهی دقت شناسایی جاده‌ها را بهبود می‌بخشد. در نهایت، نویسندگان نتایج خود را مورد بحث قرار داده و بر اهمیت ادامه پژوهش در این حوزه تأکید می‌کنند تا بهبودهای بیشتری در شناسایی جاده‌ها از تصاویر سنجش‌ازدور حاصل شود.

در نهایت شناسایی جاده‌ها با استفاده از طبقه‌بندی تصاویر در سنجش‌ازدور یک فرآیند پیچیده است که به روش‌های پیشرفته تجزیه و تحلیل داده‌ها و الگوریتم‌های یادگیری ماشین نیاز دارد. با پیشرفت فناوری‌ها و تکنیک‌های جدید، دقت این روش‌ها به‌طور مداوم در حال افزایش است و به بهبود مدیریت و برنامه‌ریزی شهری و زیرساخت‌های حمل و نقل کمک می‌کند. چون روش‌های آشکارسازی ساختمان و جاده بر روش‌های پیش‌پردازش مشابهی متکی هستند، بعید به نظر می‌رسد که سیستم‌های استخراج برای هر دو کلاس به شکل مجزا موفق باشد و از این رو بهتر است در یک پایگاه دانش جامع از اشیاء بالقوه گنجانده شود.

۲-۴-۲- یادگیری ماشین^۱

هوش مصنوعی^۲ شامل مجموعه‌ای از روش‌ها است، که کامپیوتر را قادر می‌سازد به‌منظور تصمیم‌گیری درباره‌ی مسائل مختلف، عملکردی هوشمندانه و انسان‌گونه داشته باشد. در این راستا، روش‌های مختلفی همچون یادگیری ماشین و یادگیری عمیق^۳ به‌عنوان زیرمجموعه هوش مصنوعی توسعه داده شده‌اند که می‌توان از آن‌ها در جهت آموزش سیستم‌های هوشمند به‌منظور انجام فعالیت‌های مختلف بهره گرفت. یادگیری ماشین برای تشخیص الگوها و انجام پیش‌بینی‌های مبتنی بر داده‌ها مفید باشد. اما یادگیری عمیق قابلیت تشخیص الگوها و ویژگی‌های پیچیده‌تری از داده‌ها را دارد.

^۱ Machine Learning (ML)

^۲ Artificial Intelligence (AI)

^۳ Deep Learning (DL)

روش‌های یادگیری ماشین سنتی نظیر درخت تصمیم‌گیری^۱ و ماشین بردار پشتیبان^۲ (Jozdani, ۲۰۱۷; Bakhtiari et al., ۲۰۱۹) را نمی‌توان به‌طور مستقیم بر روی داده‌های خام نظیر تصاویر و متون به‌منظور یادگیری داده‌ها اعمال کرد. به عبارتی، باید از داده‌های خام، ویژگی‌هایی را به‌عنوان بازنمایی^۳ داده‌های خام استخراج کرد تا از این ویژگی‌ها به‌عنوان ورودی الگوریتم‌های یادگیری ماشین استفاده شود. ولی مدل‌های یادگیری عمیق نیازی به گام مجزا برای استخراج ویژگی ندارند و لایه‌های شبکه‌های عصبی قادر هستند بازنمایی‌های ضمنی داده‌های خام را در روال آموزش شبکه یاد بگیرند. کاربرد این روش‌ها در تشخیص راه به‌طوری است که رویکردهایی مبتنی بر هر یک از زیرمجموعه‌های هوش مصنوعی ممکن است وجود داشته باشد. به‌عنوان مثال استفاده از کلاسه‌بندی مبتنی بر یادگیری ماشین مانند SVM (Bakhtiari et al., ۲۰۱۷) و یا کلاسه‌بندی مبتنی بر یادگیری عمیق همانند روش‌های JAGAN (W. Chen et al., ۲۰۲۲) و FACNN (C. Zhang et al., ۲۰۱۹) می‌توان نام برد. هم‌چنین قطعه‌بندی‌هایی بر اساس یادگیری عمیق نیز وجود دارند (Arora et al., ۲۰۲۳; Wei et al., ۲۰۱۹).

۳-۲- بهبود حد تفکیک مکانی تصاویر سنجش‌ازدوری

این نوع بهبود تصاویر ماهواره‌ای جهت افزایش حد تفکیک مکانی با حفظ ویژگی‌های طیفی و رادیومتریکی می‌باشد. جهت انجام این بهبود، استفاده از فیوژن تصاویر امری متداول می‌باشد که نیازمند دو تصویر هم‌زمان یکی با حد تفکیک مکانی بالا و تصویر دیگر با حد تفکیک طیفی بالا می‌باشد. با تکامل حوزه‌ی روش‌های بهبود حد تفکیک مکانی تصاویر ماهواره‌ای، الگوریتم‌های سوپر رزولوشن که عمدتاً کاربرد ماشین‌بینایی داشته‌اند وارد این حوزه شده‌اند. این الگوریتم‌ها در ابتدای راه خود، به‌صورت نگاشتی ثابت عمل می‌کردند، در ادامه روند پیشرفت خود، رویکردهای یادگیری ماشین و الگوریتم‌های مبتنی بر همسایگی همراه با بهینه‌سازی حداقل مربعات وارد این عرصه شدند ولی نتوانستند نتایجی قابل قبول از خود بر جای بگذارند. هم‌چنین از سال ۲۰۱۷ تاکنون رویکردهای مبتنی بر یادگیری عمیق در حال توسعه هستند که هم از نظر دقت و هم از نظر کارایی نتایج قابل قبولی را نشان داده‌اند.

۱-۳-۲- فیوژن

در روش‌های بهبود حد تفکیک مکانی مبتنی بر فیوژن، تصاویر فراطیفی با وضوح فضایی بالا را با ادغام یک تصویر فراطیفی با وضوح فضایی پایین با اطلاعات کمکی ایجاد می‌کنند. روش‌های بهبود مبتنی بر فیوژن به رویکرد جایگزینی مؤلفه^۴، رویکرد عددی و مبتنی بر آمار^۵، رویکرد چند تفکیک‌پذیری^۶ و رویکرد مبتنی بر بهینه‌سازی^۷ طبقه‌بندی می‌شوند (Ablin et al., ۲۰۲۰). با توجه به گستردگی موضوع برخی از بررسی‌های صورت‌گرفته در این زمینه در شکل ۶ جمع‌آوری شده، تا برای اطلاعات بیشتر به این مطالعات رجوع شود.

^۱ Decision Tree

^۲ Support Vector Machine (SVM)


^۳ Representation

^۴ Component substitution approach

^۵ Numerical and statistical-based approach

^۶ Multiresolution approach

^۷ Optimization-based approach



شکل ۶) برخی از بررسی‌های صورت گرفته در زمینه فیوژن (Belgiu & Stein, ۲۰۱۹; Alvarez-Vanhard et al., ۲۰۲۱; Ablin et al., ۲۰۲۰; G. Chen et al., ۲۰۲۳; Dong et al., ۲۰۰۹; Ghassemian, ۲۰۱۶; Javan et al., ۲۰۲۱; Jurado et al., ۲۰۲۲; Li et al., ۲۰۲۰; Li et al., ۲۰۱۷; Singh et al., ۲۰۲۱; Singh et al., ۲۰۲۳; Zhang, ۲۰۱۰; Zhang, ۲۰۰۸; Zhu et al., ۲۰۱۸; Pohl & Van Genderen, ۱۹۹۸; Sahu & Parsai, ۲۰۱۲).

۲-۳-۲- الگوریتم‌های سوپر رزولوشن

سوپر رزولوشن تک تصویر^۱ یک الگوریتم پردازش تصویر است که بر بازیابی یک تصویر با وضوح بالا از یک تصویر با وضوح پایین تمرکز دارد. تکنیک‌های مختلفی که در گذشته توسعه داده شده‌اند، نتایج قابل توجهی را به همراه داشته‌اند. با استفاده از روش‌های مختلف می‌توان به سوپر رزولوشن تصاویر دست پیدا کرد. یک رویکرد مبتنی بر بازسازی تصویر (RE^2) است (Dong et al., ۲۰۱۰; Yang et al., ۲۰۱۱; et al., ۲۰۱۱) که به دنبال بازتولید ویژگی‌های ظاهر شده در تصویر LR^2 تا سطح وضوح بالاتر هستند. به عبارت دیگر، هدف آن‌ها به دست آوردن یک تصویر حل شده^۴ نهایی با همان ویژگی‌های ادراکی تصویر LR اما با رزولوشن بالاتر است. به نحوی، روش‌های RE سعی می‌کنند کیفیت دامنه LR را پس از درون‌یابی اولیه تکرار کنند تا از اثرات تاری و خطاهای ناشی از الگوریتم‌های درون‌یابی جلوگیری کنند. تعداد کمی از رویکردهای دیگر به روش‌های مبتنی بر یادگیری ماشین متمایل هستند که از دیکشنری استفاده می‌کنند و هدفشان یادگیری نحوه تبدیل از تصاویر با وضوح پایین به تصاویر با وضوح بالا است. همچنین برخی از الگوریتم‌هایی با پیچیدگی کم وجود دارند که بدون استفاده از منابع زیاد، نتایج بهتری را هدف قرار می‌دهند. همچنین مجموعه‌ای از الگوریتم‌های مبتنی بر همسایگی^۵ (Huang et al., ۲۰۱۵; Kim & Kwon, ۲۰۱۰) موجود است که مبتنی بر یادگیری ماشین می‌باشند، این الگوریتم‌ها با استفاده از پچ‌های وضوح بالا که در دیکشنری ذخیره می‌گردند، آموخته می‌شود. این پچ‌ها را می‌توان به همان روشی که با تصاویر با وضوح پایین مطابقت دارند، ترکیب کرد. این روش با استفاده از فاصله اقلیدسی برای انجام جستجوی همسایه و به دنبال آن بهینه‌سازی مسئله حداقل مربعات بهتر می‌شود. بالین حال، این فرآیندها بهینه نیستند و هنگامی که مقیاس تصویر مورد نظر نسبتاً بالاتر باشد در کار شکست می‌خورند (Bevilacqua et al., ۲۰۱۲; Gao et al., ۲۰۱۲; Zhang et al., ۲۰۱۲). از روش‌های یاد شده می‌توان به عنوان رویکردهای سنتی یاد کرد. الگوریتم‌های سوپر رزولوشن جدید مبتنی بر یادگیری عمیق می‌باشند که علاوه بر ارائه دقت بالا، کارایی و بازدهی بهتری را نیز به همراه خواهد داشت.

^۱ Single Image Super-Resolution

^۲ Image Reconstruction


^۳ Low Resolution

^۴ Super Resolved image

^۵ Neighbourhood Embedding


۱-۳- مطالعات مرتبط با شناسایی شبکه‌ی راه‌ها

راه‌ها را می‌توان با رویکردهای مختلفی از تصاویر سنجنش‌ازدوری استخراج نمود که هر رویکرد می‌تواند خود جزو یک دسته منحصر به فرد یا چند دسته باشد. دسته‌های تشخیص راه و برخی از مطالعات انجام شده در این زمینه در شکل ۸ به صورت سری زمانی آورده شده که در ادامه به شرح آن‌ها پرداخته شده است.



شکل ۸) روند پیشرفت زمانی برخی مطالعات در زمینه تشخیص شبکه‌ی راه‌ها.

از آنجایی که حجم و تعداد تحقیقات در حوزه حاضر با توجه به اهمیت آن بسیار بالا بوده و امکان مرور همه‌ی آن‌ها در این تحقیق وجود ندارد لذا تنها تعدادی از کارهای انجام شده به صورت نمونه شرح داده شده‌اند تا به‌طور کلی روند توسعه روش‌ها شناسایی گردد؛ همچنین برخی از بررسی‌های صورت گرفته در این زمینه، در شکل ۹ معرفی شده‌اند که در صورت نیاز به اطلاعات بیشتر به آن مطالعات مراجعه شود



شکل ۹) برخی از بررسی‌های صورت گرفته در زمینه‌ی تشخیص شبکه‌ی راه‌ها (Abdollahi, Pradhan, et al., ۲۰۲۰; Babaali et al., ۲۰۱۴; Z. Chen et al., ۲۰۲۲; Jia et al., ۲۰۲۱; Kahraman et al., ۲۰۱۸; Lian et al., ۲۰۲۰; Liu et al., ۲۰۲۲; Pruthi & Dhingra, ۲۰۲۳; Singh & (Garg, ۲۰۱۴; Wang et al., ۲۰۱۶; Winiwarter et al., ۲۰۲۴; Y. Zhang et al., ۲۰۲۴; Zhu et al., ۲۰۲۱; Zhu et al., ۲۰۲۴).

شاهی و همکاران در سال ۲۰۱۵، یک رویکرد خودکار و سریع برای استخراج جاده آسفالت از تصاویر WorldView-۲ ارائه کرده‌اند. روش پیشنهادی بر اساس شاخص طیفی جدید است که می‌تواند جاده‌های آسفالت را به طور خودکار استخراج کند. در این مطالعه از یک طیف‌سنج رادیومتر با برد کامل و تصاویر WV-۲ استفاده شده است. هدف این مطالعه توسعه شاخص جدیدی به نام REI^۱ است که حداقل میزان دقت ثابت ۸۶٪ در استخراج جاده آسفالت را به دست آورد. برای ارزیابی دقت، شاخص REI با BAI^۲ مورد مقایسه قرار گرفت و مقایسه نتایج نشان داد که REI جاده‌ها را کمتر از BAI طبقه‌بندی می‌کند (Shahi et al., ۲۰۱۵). علاوه بر این، این شاخص طیفی یک مرز ساختمان را به اشتباه طبقه‌بندی کرده است که این خطا می‌تواند در تصاویر با حد تفکیک مکانی پایین تعداد ساختمان‌های نزدیک به هم بیشتری را به‌عنوان جاده در نظر بگیرد؛ همچنین این شاخص توانایی شناسایی راه‌های خاکی و شسته را ندارد.

احمد و همکاران در سال ۲۰۲۲، روشی را بر اساس ترکیب شاخص جاده^۳ و یک عملگر مورفولوژیکی به نام Bot-Hat ارائه داده‌اند که این عملگر مورفولوژیکی وظیفه‌ی برجسته کردن ویژگی‌های جاده و سرکوب ویژگی‌های اطراف آن را دارا بود. روش پیشنهادی بر روی داده‌های سنتینل-۲ در دو منطقه مجزای لاهور و ریچموند اعمال شد که F_۱-Score آن‌ها به ترتیب به ۷۶٪/۱۰ و ۸۳٪/۸۱ به دست آمد. از نتایج مشاهده می‌شود که جاده‌های مجاور پوشش‌های گیاهی مرتفع و زمین‌های بایر با دقت بیشتری استخراج شده‌اند (Ahmed et al., ۲۰۲۲). 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؛ لذا بهتر است از مراحل کمتری در روش تشخیص راه‌ها استفاده شود. به‌منظور جمع‌بندی، بررسی‌های صورت گرفته در تشخیص راه بر اساس شاخص راه به صورت مختصر در جدول ۱ آمده است.

جدول ۱) بررسی‌های صورت گرفته در تشخیص راه بر اساس شاخص راه به صورت مختصر.

نام نویسنده، سال	روش پیشنهادی	داده	مزایا	معایب	ارجاع
شاهی و همکاران، سال ۲۰۱۵	REI	تصاویر WorldView-۲	• طبقه‌بندی سریع داده به راه و غیر راه • تشخیص جاده‌های آسفالت با دقت بالا	• تشخیص مرز ساختمان به‌عنوان جاده • فقط جاده‌های آسفالت را تشخیص می‌دهد	Shahi et al., (۲۰۱۵)
رددی و همکاران، سال ۲۰۱۹	NDARI	تصاویر LANDSAT-۸ OLI	• سرعت بالا در تشخیص راه	• در تشخیص قسمت‌های کم‌عرض و راه‌های کنار ساختمان و درخت‌ها دچار مشکل می‌شود	Reddy et al., (۲۰۱۹)
احمد و همکاران، سال ۲۰۲۲	RI	تصاویر سنتینل-۲	• طبقه‌بندی سریع داده به راه و غیر راه • جاده‌های مجاور پوشش‌های گیاهی مرتفع و زمین‌های بایر با دقت بیشتری استخراج می‌شوند	• بالا بودن تعداد مراحل در تشخیص راه باعث افزایش خطای تجمعی می‌شود	Ahmed et al., (۲۰۲۲)

^۱ Road extraction index

^۲ Built-up area index

^۳ Road Index (RI)

گریناس و همکاران در سال ۲۰۱۶، طی مطالعه‌ای یک الگوریتم قطعه‌بندی جدید را بر اساس مدل میدان تصادفی مارکوف^۱ و یک تجزیه و تحلیل داده‌های گسترده برای تعیین ویژگی‌های مرتبط برای مشکل طبقه‌بندی ارائه دادند. در رویکرد پیشنهادی که عملیات به صورت خودکار و در مقیاس بزرگ مبتنی بر شی^۲ است، جاده‌ها و ساختمان‌ها به طور خودکار و مشترک از تصاویر ماهواره‌ای با وضوح بالا استخراج و با استفاده از ویژگی‌های مبتنی بر شی شامل نشانه‌های بصری و شکل شناسایی می‌شوند. در مرحله قطعه‌بندی، بخش‌های روستایی مناطق حاشیه‌شهری به جز جاده‌های روستایی شناسایی و حذف شده و طبقه‌بندی اولیه مناطق شهری باقی‌مانده، و به دنبال آن قطعه‌بندی مبتنی بر MRF^۳، منجر به استخراج مناطق یا اشیاء فقط در آن مناطق می‌شود (Grinias et al., ۲۰۱۶). از آنجایی که روش مورد استفاده یک قطعه‌بندی نظارت‌نشده است، نمی‌تواند به اندازه‌ی روش‌های نظارت‌شده مانند روش‌های مبتنی بر شبکه‌های عصبی مورد اعتماد واقع گردد.

غندوره و همکاران طی مطالعه‌ای در سال ۲۰۲۲، با استفاده از تشخیص لبه و قطعه‌بندی شماتیک بر پایه یادگیری عمیق ساختاری را معرفی نمودند. این ساختار از یک رمزگذار^۴ 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 مقابل، 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 قسمت با هم اضافه شوند، یک نقشه فعال‌سازی دوبعدی برای هر بخش ایجاد می‌شود و به شبکه اجازه می‌دهد تا میزان توجهی را که به ویژگی‌ها از هر مرحله از رمزگذار معطوف شود، انتخاب کند (Ghandorh et al., ۲۰۲۲). این امر تقسیم‌بندی جاده‌های بزرگ و تولید ماسک‌های تقسیم‌بندی لبه‌های ظریف را تسهیل می‌کند و از آنجایی که عملکرد ماژول تشخیص لبه به شدت به عملکرد قطعه‌بندی بستگی دارد، یک ویژگی ضروری است. داده‌های با کیفیت خوب و کلاس‌های متعادل به اندازه‌ی ساختار شبکه مهم هستند. در مورد این تحقیق، کلاس‌ها به شدت نامتعادل هستند؛ بنابراین آن‌ها با توابع از دست دادن متقابل آنتروپی وزنی و توابع از دست دادن Tversky مورد بررسی قرار و نشان داده‌اند که ترکیب این دو می‌تواند عملکرد آموزش شبکه را در یک موقعیت بسیار نامتعادل (داده‌های آموزشی غیرهمگن و با کیفیت کم) افزایش دهد.

آروا و همکاران در سال ۲۰۲۳، یک شبکه متراکم با اتصالات پرش وزنی^۵ برای تقسیم‌بندی جاده‌ها از تصاویر ماهواره‌ای با وضوح بالا پیشنهاد داده‌اند. شبکه پیشنهادی با حل یک مسئله کنترل بهینه کسری^۶ طراحی شده است. روش پیشنهادی شامل مجموع وزنی خروجی لایه‌های قبلی در یک انتقال خاص است (برخلاف شبکه‌های متراکم اصلی که خروجی لایه‌های قبلی به هم متصل می‌شوند)؛ بنابراین روش پیشنهادی از نظر محاسباتی کارآمدی بیشتری نسبت به روش‌های هم‌تراز دارد (Arora et al., ۲۰۲۳). مدل پیشنهادی اطلاعات محلی و جهانی را به طور هم‌زمان مورد بررسی قرار می‌دهد به همین دلیل قادر به استخراج پیکسل‌های جاده‌های پوشانده شده توسط درختان است. اما درحالی که این مشکل را حل می‌کند، این مدل برخی از پیکسل‌های مربوط به درختان نزدیک جاده‌ها را به عنوان پیکسل جاده برچسب‌گذاری می‌کند و در نتیجه وضوح لبه‌های جاده‌ها تحت تأثیر قرار می‌گیرد.

به منظور جمع‌بندی، بررسی‌های صورت گرفته در تشخیص راه بر اساس قطعه‌بندی به صورت مختصر در جدول ۲ آمده است.

جدول ۲) بررسی‌های صورت گرفته در تشخیص راه بر اساس قطعه‌بندی به صورت مختصر.

نام نویسنده، سال	روش پیشنهادی	داده	مزایا	معایب	ارجاع
گریناس و	MRF	تصاویر ماهواره‌ای با	• سرعت بالا در تشخیص راه‌ها	• قطعه‌بندی نظارت	(Grinias et al.)

^۱ Markov random field model

^۲ Object based Image Analysis (OBIA)

^۳ Markov Random Fields

^۴ Encoder

^۵ Heavy Weight Connections

^۶ fractional optimal control

همکاران، سال	موضوع	• عدم نیاز به داده‌های آموزشی	نشده	۲۰۱۶، (al.)
غندوره و همکاران، سال ۲۰۲۲	قطعه‌بندی و تشخیص لبه‌ی شماتیک	تصاویر ماهواره‌ای با وضوح بالا	افزایش عملکرد آموزش شبکه بدلیل استفاده از دو LossFunction آنتروپی وزنی و Tversky	هزینه بالا در تهیه داده‌ها • هزینه بالا در تهیه داده‌ها وابستگی بین تشخیص لبه و قطعه‌بندی
آرورا و همکاران، سال ۲۰۲۳	شبکه متراکم همراه با حل کنترل بهینه کسری	• MRD (Mnih, ۲۰۱۳) • ORD (Yahui Liu et al., ۲۰۱۸) • تصاویر ماهواره‌ای با وضوح بالا	• از نظر محاسباتی کارآمدی بیشتری نسبت به روش‌های هم‌تراز دارد رویکرد پیشنهادی اطلاعات محلی و جهانی را به طور هم‌زمان موردبررسی قرار می‌دهد به همین دلیل قادر به استخراج پیکسل‌های جاده‌های پوشانده شده توسط درختان است	برخی از پیکسل‌های مربوط به درختان نزدیک جاده‌ها را به‌عنوان پیکسل جاده برچسب‌گذاری می‌کند

ریاحی و همکاران در سال ۲۰۱۷، یک روش نیمه خودکار برای تشخیص جاده‌ها در تصاویر ماهواره‌ای با وضوح بالا QuickBird و WorldView و تصاویر هوایی UltraCam ارائه دادند که روش پیشنهادی بر اساس چهار مرحله اصلی عمل می‌کند. 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. سومین مرحله، ماشین بردار پشتیبان برای طبقه‌بندی کل تصویر استفاده شد و در نهایت، روش عملیات مورفولوژیکی مانند تکنیک‌های dilation، erosion، opening و closing برای حذف اجسام نامطلوب انجام می‌شود (Bakhtiari et al., ۲۰۱۷). روش پیشنهادی توانسته میانگین دقت کلی بیش از ۸۱ درصد و میانگین ضریب کاپا بیش از ۷۸ درصد در طبقه‌بندی تصویر به دو کلاس غیر جاده‌ای و جاده‌ای نشان دهند که نشان‌دهنده موفقیت روش پیشنهادی می‌باشد. ولی همچنین دارای محدودیت در تشخیص راه‌ها با پیچیدگی زیاد (مارپیچ و تقاطع) می‌باشد بدین‌صورت که با افزایش پیچیدگی‌ها دقت روش پیشنهادی کاهش می‌یابد.

ژانگ و همکاران مطالعه‌ای را در سال ۲۰۱۹ انجام داده‌اند که این مطالعه طبقه‌بندی کاربری/پوشش زمین و تشخیص تغییر مناطق شهری را از تصاویر سنجش‌ازدور با وضوح بسیار بالا^۱ با استفاده از روش‌های مبتنی بر یادگیری عمیق بررسی می‌کند. رویکرد پیشنهادی، شبکه عصبی (FACNN^۲) را برای یادگیری طبقه‌بندی پوشش زمین معرفی و بر روی داده‌های سال‌های ۲۰۱۴ و ۲۰۱۷ شهر ووهان (چین) از سنجنده‌ی Beijing-۲ اعمال می‌کند. نتایج به‌دست‌آمده نشان می‌دهد که روش پیشنهادی با دقت کلی قابل قبول ۰/۷۴۳ توانسته راه‌ها و ریل‌ها را طبقه‌بندی کند (C. Zhang et al., ۲۰۱۹). این رویکرد به دلیل استفاده از تصاویر با وضوح بسیار بالا و تعداد کلاس‌های انتخابی بالا به صورت بهینه عمل نمی‌کند و باعث افزایش زمان پردازش می‌شود، ولی به دلیل استفاده از سه باند RGB می‌تواند این مشکل را حل کند و بسیاری از تصاویر سازگاری داشته باشد.

جوزدانی و همکاران در سال ۲۰۱۹، طی مطالعه‌ای یک مقایسه تجربی بین معماری‌های مختلف DNN^۳ (پرسپترون چندلایه عمیق منظم (MLP^۴))، شبکه‌های عصبی کانولوشنال (CNN) و... و SVM برای بررسی پتانسیل آن‌ها برای نقشه‌برداری مناطق شهری انجام داده‌اند. بر اساس آزمایشات خود، به دو نتیجه اصلی رسیده‌اند؛ اول، مدل MLP به دقیق‌ترین طبقه‌بندی نسبت به دیگر روش‌های مورد استفاده دست می‌یابد. دوم، پیش‌آموزش بدون نظارت با استفاده از رمزگذارهای

^۱ Very High Resolution (VHR)

^۲ Fully Atrous Convolutional Neural Network

^۳ Deep Neural Network

^۴ Regular Deep MultiLayer Perceptron

خودکار (RAE^۱, SAE^۲ و AE^۳) منجر به بهبودی در نتیجه طبقه‌بندی نمی‌شود (Jozdani et al., ۲۰۱۹). تفاوت اندکی که در دقت طبقه‌بندی MLP نسبت مدل‌های دیگر مانند طبقه‌بندی‌کننده‌های SVM و GB^۴ وجود دارد، نشان دهنده‌ی این است که دیگر طبقه‌بندی‌کننده‌های پیشرفته یادگیری ماشین هنوز به اندازه‌ی کافی قابل اعتماد هستند تا بتوانند نقشه‌برداری از مناظر پیچیده را انجام دهند.

ژانگ و همکاران در سال ۲۰۲۱، مطالعه‌ای جهت بهینه‌سازی روش طبقه‌بندی RF با استفاده از بهینه‌ساز Bayesian انجام داده‌اند. در این مطالعه روش پیشنهادی با روش‌های RF و SVM مورد مقایسه و در دو حالت سه باند RGB و تمام ۱۲ باند مورد آزمایش قرار گرفته است. نتایج به دست آمده دقت ۹۵/۵٪ و بازخوانی ۸۸/۹٪ برای طبقه‌بندی راه در حالت استفاده از ۱۲ باند نشان می‌دهد که نسبت به روش‌های مورد مقایسه مقدار بیشتری می‌باشد (Zhang et al., ۲۰۲۱). بنابراین، انتظار می‌رود طبقه‌بندی‌کننده تصادفی جنگل توسعه‌یافته با بهینه‌سازی فراپارامتر 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 و همکاران در سال ۲۰۲۲، طی مطالعه یک ساختار شبکه عصبی جهت طبقه‌بندی با نام JAGAN^۵ ارائه نمودند. برای آزمایش عملکرد طبقه‌بندی مدل JAGAN، از مجموعه داده‌های پوشش زمین پیچیده خودساخته مبتنی بر تصاویر GaoFen-۵ AHSI استفاده شده، که شامل مناظر مخلوطی از مناطق معدنی و کشاورزی از حاشیه شهری-روستایی است (W. Chen et al., ۲۰۲۲). مدل پیشنهادی به دقت کلی ۸۶/۰۹ درصد، مقدار کاپا با ۷۹/۴۱ درصد، امتیاز F۱ با ۸۵/۸۶ درصد و میانگین دقت ۸۲/۳۰ درصد دست یافت که نشان می‌دهد JAGAN می‌تواند به طور مؤثری طبقه‌بندی را نسبت به مدل‌هایی مانند SVM، KNN بهبود بخشد. در ضمن در این مطالعه بهترین دقت برای کلاس راه‌ها به دست آمد که این نشان‌دهنده‌ی ظرفیت این مدل جهت استفاده در شناسایی شبکه راه‌ها می‌باشد. به منظور جمع‌بندی، بررسی‌های صورت گرفته در تشخیص راه بر اساس کلاسه‌بندی به صورت مختصر در جدول ۳ آمده است.

جدول ۳) بررسی‌های صورت گرفته در تشخیص راه بر اساس کلاسه‌بندی به صورت مختصر.

نام نویسنده، سال	روش پیشنهادی	داده	مزایا	معایب	ارجاع
بختیاری و همکاران، سال ۲۰۱۷	Canny + SVM	WorldView QuickBird تصاویر هوایی- UltraCam	• سرعت بالا در تهیه نقشه • هزینه‌ی پایین محاسباتی	• محدودیت در تشخیص راه‌ها با پیچیدگی زیاد • هزینه بالا داده‌های مورد استفاده	Bakhtiari et al., (۲۰۱۷)
ژانگ و همکاران، سال ۲۰۱۹	FACNN	Beijing-۲	به دلیل استفاده از RGB می‌تواند با تصاویر زیادی سازگاری داشته‌باشد	• هزینه بالا داده‌های مورد استفاده • بهینه نبودن در تعداد طبقات	C. Zhang et al., (۲۰۱۹)
جوزدانی و همکاران، سال ۲۰۱۹	SVM DNN MLP	IKONOS	• قابل اعتماد بودن در نقشه‌برداری از مناظر پیچیده	• هزینه بالا داده‌های مورد استفاده	Jozdani et al., (۲۰۱۹)

^۱ Regular AutoEncoder

^۲ Sparse AutoEncoder

^۳ variational AutoEncoder

^۴ Gradient Boosting Trees

^۵ Joint channel-space Attention mechanism and Generative Adversarial Network

بررسی روش‌های متفاوت				
• استفاده از داده‌های رایگان				
Zhang et al., ۲۰۲۱	رزولوشن پایین داده‌های مورد استفاده	پایین در	• سرعت آموزش	تصاویر سنتینل ۲
				Optimized RF
ژانک و همکاران، سال ۲۰۲۱				
بررسی تأثیر تعداد باندها				
• طبقه‌بندی راه‌ها با • هزینه‌ی بالا در تهیه				
W. Chen et al., ۲۰۲۲	داده آموزشی	دقت بالا	تشخیص راه‌های دارای هزینه بالا داده‌های مورد استفاده	GaoFen-۵ AHSI
			پیچیدگی	JAGAN
چن و همکاران، سال ۲۰۲۲				

گائو و همکاران در سال ۲۰۱۹، برای استخراج راه از تصاویر ماهواره‌ای با رزولوشن بالا، روشی را ارائه داده‌اند که با استفاده از یک شبکه عصبی با ساختار RDRCNN^۱ اقدام به تشخیص راه‌ها می‌کند و در گام پس پردازش از یک عملیات مورفولوژی ریاضی و یک الگوریتم رأی‌گیری تنسور^۲ جهت بهبود عملکرد آن استفاده می‌شود. مرحله پس پردازش برای رفع نواقصی مانند راه‌هایی که به هر دلیل (مانند وجود سایه و یا پوشش گیاهی) به‌صورت کامل توسط شبکه عصبی تشخیص داده نشده‌اند به کار گرفته شده است. در نهایت روش ارائه شده با روش‌های CNN، UNet، RDRCNN مقایسه شده که به ترتیب دارای دقت کلی ۹۸٪/۵۰، ۹۷٪/۵۶، ۹۷٪/۵۳ و ۹۸٪/۱۳ بوده‌اند؛ لازم به ذکر است که روش پیشنهادی با F1-Score ۹۹٪/۶۵ بهترین عملکرد را نسبت دیگر روش‌ها از خود نشان داده است (Wei et al., ۲۰۱۹). تصاویر ماهواره‌ای با رزولوشن بالا علی‌رغم مزایای فراوانی که دارند، به دلیل تجاری بودن، دارای هزینه‌ی زیاد، نحوه دسترسی و تهیه‌ی دشوار می‌باشند.

عبدالهی و همکاران در سال ۲۰۲۰، یک شبکه کانولوشن مبتنی بر یادگیری عمیق به نام مدل VNet را برای تولید یک نقشه جاده با وضوح بالا معرفی کردند. علاوه بر این، یک تابع تلفات دوگانه جدید به نام متقاطع آنتروپی-تاس-از دست دادن (CEDL^۳) تعریف شده است که آنتروپی متقاطع (CE^۴) و تلفات تاس (DL^۵) را ترکیب می‌کند و اطلاعات محلی و اطلاعات جهانی را برای کاهش تأثیر عدم تعادل کلاس‌ها و بهبود نتایج استخراج جاده در نظر می‌گیرد. پس از ارزیابی دقت رویکرد پیشنهادی VNetCCEDL به میانگین دقت ۹۰٪/۶۴ درصد برای مجموعه داده ماساچوست و ۹۲٪/۴۱ درصد برای مجموعه داده اتاوا دست یافت (Abdollahi, Pradhan, & Alamri, ۲۰۲۰). روش پیشنهادی با تکنیک‌های پیشرفته استخراج جاده مقایسه شده و نتایج ثابت کرد که تکنیک پیشنهادی از سایر تکنیک‌های هم‌رده مبتنی بر یادگیری عمیق در استخراج جاده بهتر عمل می‌کند.

یانوارگی و همکاران در سال ۲۰۲۲، سعی کردند که داده‌های شبکه جاده‌ای را با استفاده از الگوریتم CNN با ساختار UNet استخراج کنند تا دریابند الگوریتم استخراج داده‌های شبکه جاده‌ای از تصاویر ماهواره‌ای با وضوح متوسط چقدر دقیق است و چگونه می‌توان از آن برای جمع‌آوری جاده‌های جدیدی که در نسخه‌های RBI فعلی موجود نیستند، استفاده کرد. این مطالعه بر روی تصاویر ماهواره سنتینل-۲ انجام شده و داده‌های GPS نرم‌افزار مسیریابی GRAB به‌عنوان داده‌های آموزشی و واقعیت زمینی^۶ مورد استفاده قرار گرفته است. بر اساس نتایج به‌دست آمده، مدل ساخته شده با دقت بسیار بالا ۰/۹۹۷ و softmax loss تنها ۰/۰۰۵ است. علاوه بر این داده‌های GPS نیز ماسک حقیقت زمینی بسیار خوبی را برای آموزش داده‌ها با ارزش کم و کیفیت بالا ارائه می‌دهند (Yanuari & Utami, ۲۰۲۲). با این حال باید وضوح تصویر و دقت داده‌های GPS را

^۱ Refined deep residual convolutional neural network

^۲ Tensor voting algorithm

^۳ Cross-Entropy-Dice-Loss

^۴ Cross-Entropy

^۵ Dice Loss

^۶ Ground Truth

در نظر داشت که این داده‌ها برای به‌روزرسانی نقشه‌های ۱:۲۵۰۰۰ می‌تواند کافی باشد ولی برای تهیه و یا به‌روزرسانی نقشه‌های دقیق‌تر از تصاویر با وضوح بیشتر استفاده نمود.

لو و همکاران در سال ۲۰۲۳، یک شبکه استخراج جاده با رمزگشایی کمکی به نام ^۱AD-RoadNet پیشنهاد می‌کنند که نمایش جاده‌ای در مقیاس چندگانه و بهبود اتصال را بر اساس دو ماژول جدا می‌کند؛ ماژول میدان پذیرنده ترکیبی (^۲HRFM) و ماژول نمایش ویژگی توپولوژیکی (^۳TFRM). HRFM در رمزگذار معرفی شده است تا بر ویژگی‌های جاده هدف از طریق تطبیق تطبیقی اندازه میدان گیرنده (^۴RF) برای جاده‌های مقیاس مختلف تأکید کند. TFRM در یک رمزگشای کمکی برای نشان دادن ویژگی‌های توپولوژیکی با اطلاعات موقعیت رمزگذاری شده در رمزگذار مشترک معرفی شده است و سپس به رمزگشای اصلی کمک می‌کند تا جاده‌ها را مسدود کند، بنابراین ارتباط بین رمزگذار و رمزگشای اصلی را بهبود می‌بخشد (Luo et al., ۲۰۲۳). ماژول اضافه شده می‌تواند عملکرد شبکه را با کاهش FT و افزایش تداوم و همواری جاده استخراج‌شده بهبود بخشد که در نهایت از قطعه قطعه شدن راه جلوگیری می‌کند.

به‌منظور جمع‌بندی، بررسی‌های صورت گرفته در تشخیص راه بر اساس یادگیری ماشین به صورت مختصر در جدول ۴ آمده است.

جدول ۴) بررسی‌های صورت گرفته در تشخیص راه بر اساس یادگیری ماشین به صورت مختصر.

نام نویسنده، سال	روش پیشنهادی	داده	مزایا	معایب	ارجاع
گائو و همکاران، سال ۲۰۱۹	RDRCNN	تصاویر ماهواره‌ای با رزولوشن بالا	• استفاده از رأی‌گیری تنسوری جهت تکمیل نواقص موجود در راه‌های تشخیص داده شده بهترین عملکرد نسبت به روش‌های CNN و UNet	هزینه بالا داده‌های مورد استفاده	Wei et al., (۲۰۱۹)
عبداللهی و همکاران، سال ۲۰۲۰	VNetCCEDL	• Massachusetts Mnih,) dataset (۲۰۱۳ Ottawa dataset Yahui Liu et al.,) (۲۰۱۸	• کاهش تأثیر عدم تعادل کلاس سرعت بالا در شناسایی راه‌ها	استفاده از تصاویر Google Earth	Abdollahi, Pradhan, & Alamri, (۲۰۲۰)
شایو و همکاران، سال ۲۰۲۱	MRENet	تصاویر ماهواره‌ای با رزولوشن بالا	• خطوط مرکزی جاده را ایجاد می‌کند شبکه طراحی شده می‌تواند زمینه دریافت را گسترش دهد و ویژگی‌های چند سطحی را یکپارچه کند و منجر به آموزش دیدن شبکه با اطلاعات فراوان با ویژگی‌های جاده‌ها شوند	• هزینه بالا داده‌های مورد استفاده در صحنه‌های شهری پیچیده مورد بررسی قرار نگرفته است	Shao et al., (۲۰۲۱)
یانوارگی و همکاران، سال ۲۰۲۲	UNet	• داده‌های GPS نرم‌افزار مسیریابی GRAB • تصاویر سنتینل ۲	• داده‌های رایگان • برای به‌روزرسانی نقشه‌های ۱:۲۵۰۰۰ می‌تواند کافی باشد ساختار ساده برای شبکه مورد	• دقت پایین داده‌های GPS نرم‌افزار مسیریابی حد تفکیک مکانی کم	Yanuargi) & Utami, (۲۰۲۲)

^۱ Auxiliary-Decoding Road Extraction Network


^۲ Hybrid Receptive Field Module

^۳ Topological Feature Representation Module

^۴ Receptive Field

تصاویر سنتینل ۲	استفاده	لو و همکاران، سال ۲۰۲۳
	- Massachusetts Mnih,) dataset (۲۰۱۳) - The DeepGlobe Tao) road dataset (et al., ۲۰۱۹)	
Luo et al.,) استفاده نکردن از تصاویر خام ماهواره‌ای (۲۰۲۳)	تداوم و همواری جاده استخراج- شده نسبت به روش‌های هم- تراز بهبود یافته است	AD-RoadNet

پیرو بررسی‌های انجام شده فوق‌الذکر، مطالعات حوزه تشخیص راه را می‌توان بر اساس داده‌های استفاده شده در پژوهش، به صورت شکل ۱۰ ارائه نمود.



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

با توجه به بررسی‌های انجام شده، تشخیص شبکه راه با استفاده از چهار دسته اصلی قطعه‌بندی و تشخیص لبه، شاخص راه، کلاسه‌بندی شامل استفاده از روش‌های مبتنی بر یادگیری ماشین صورت می‌پذیرد. در بین این رویکردها، روش‌های شاخص راه و قطعه‌بندی و تشخیص لبه می‌تواند با سرعت بالا، هزینه و محاسبات کم شبکه راه‌ها را تشخیص دهند، ولی دقت به دست آمده از این روش‌ها به اندازه‌ی کافی بالا نیست که بتوان به آن‌ها برای کارهای دقیق بسنده کرد. در ادامه روش‌های کلاسه‌بندی وارد عمل می‌شوند که می‌توانند راه حل مناسبی جهت اطمینان بیشتر از شبکه راه‌های تشخیص داده شده، باشند. دو رویکرد قطعه‌بندی و کلاسه‌بندی می‌توانند بر پایه‌ی شبکه‌های عصبی طرح‌ریزی شوند که باعث می‌شود تا سطح اطمینان به موارد تشخیص داده شده تا حد زیادی افزایش یابد. البته باید در نظر داشت که در بعضی موارد شبکه‌های عصبی برای یک مورد خاص مانند تشخیص راه به کار گرفته شوند، این رویکرد به دلیل اینکه به صورت اختصاصی برای یک موضوع در نظر گرفته شده است می‌تواند تا حد زیادی دقت محصول نهایی و اطمینان به آن را افزایش دهد.

یکی از مشکلات موجود در این حوزه در دسترس نبودن داده‌های آموزشی با دقت بالا و کارایی مناسب جهت آموزش شبکه‌ی عصبی تشخیص راه‌ها دانست. برای حل این مشکل می‌توان به کارگیری نرم‌افزارهای موجود همانند Google Earth به صورت دستی اقدام به تولید داده‌های آموزشی نمود و یا از داده‌های آماده همچون OSM^۱ استفاده نمود. البته انتخاب داده‌های آموزشی بسته به دقت مورد نیاز می‌تواند چالش برانگیز و یا ساده باشد.


با رجوع به مطالعات انجام شده در بخش تشخیص شبکه‌ی راه‌ها، داده‌های مورد استفاده به طور معمول تصاویر با حد تفکیک مکانی بالا و بسیار بالا می‌باشد تا بتوان به دقت مدنظر رسید؛ ولی این داده‌ها نیاز به صرف هزینه‌ی زیاد می‌باشد، علاوه بر این

^۱ Open Street Map

برای دسترسی به این داده‌ها در ایران همراه با مشکلاتی می‌باشد. از این‌رو، در بعضی موارد نیز از تصاویر با حد تفکیک مکانی متوسط با دسترسی رایگان استفاده شده است، ولی به دلیل رزولوشن کم توانایی تشخیص راه‌ها با عرض کم را ندارد؛ بنابراین، باید روش‌هایی را مدنظر داشت تا بتوان با تصاویر رایگان به حد تفکیک مکانی خوب دست یافت. از این‌رو، با استفاده از روش سوپر رزولوشن این عمل را انجام داد تا تصویر با رزولوشن متوسط رایگان را به تصویر به رزولوشن بالا تبدیل نمود.

۲-۳- مشخصات مطالعات سوپر رزولوشن تک تصویر

سوپر رزولوشن، به‌طور کلی به دنبال افزایش دقت تفکیک مکانی با تلاش برای حفظ ویژگی‌های طیفی تصویر می‌باشد. سوپر رزولوشن را می‌توان از لحاظ عملکرد، براساس روش‌های سنتی و مبتنی بر یادگیری عمیق در نظر گرفت و همچنین از نظر کاربرد، به ساختارهای به‌کاررفته در حوزه سنجش‌ازدوری و ساختارهای به‌کاررفته در حوزه ماشین بینایی دسته‌بندی نمود. در ضمن باید در نظر داشت که هر یک از روش‌ها می‌توانند دارای ساختار منحصر به فرد و یا مشترک با حوزه دیگر باشد. دسته‌بندی و برخی از مطالعات انجام شده را به صورت سری زمانی می‌توان در شکل ۱۱ مشاهده نمود. سوپر رزولوشن غالباً در ماشین بینایی و پردازش تصویر مورد بررسی قرار گرفته است (Freeman et al., ۲۰۰۲)، اما عمدتاً برای سوپر رزولوشن تک تصویر، یعنی افزایش وضوح مکانی یک تصویر واحد (RGB) با کمک آموخته‌های قبلی از یک مجموعه آموزشی مناسب می‌باشند. ظهور یادگیری عمیق، سوپر رزولوشن تک تصویر را با پیشرفت‌های زیادی همراه کرده است (Kim et al., ۲۰۱۶; Lim et al., ۲۰۱۷). علاوه بر این، روش مذکور به حوزه سنجش‌ازدور نیز راه پیدا کرده که کمک شایانی به محققان این بخش نموده است.



شکل ۱۱) برخی از مطالعات انجام شده در سوپر رزولوشن (Patnaik et al., ۲۰۲۴; Ye et al., ۲۰۲۴; W. Zhang et al., ۲۰۲۴).

در ادامه به بررسی مطالعات انجام شده پرداخته شده است. بدین‌صورت که در ابتدا مطالعات در حوزه ماشین‌بینایی سپس حوزه سنجش‌ازدوری و در انتها دیتاست‌های آماده شده جهت انجام سوپر رزولوشن در حوزه سنجش‌ازدوری مورد بررسی قرار می‌گیرد.

در حوزه‌ی ماشین‌بینایی در ابتدای امر، گاتیس و همکاران (Gatys et al., ۲۰۱۵) از شبکه‌های عصبی کانولوشنال در کار خود در مورد انتقال شبکه‌ی عصبی استفاده کردند تا کیفیت هنری یک تصویر را با تصویر دیگر ترکیب کنند. Xie و همکاران (Xie et al., ۲۰۱۲) یک شبکه عصبی را برای بازسازی تصاویر با پچ‌های گم‌شده، مانند تصاویر قدیمی پاره شده، پیشنهاد کرده‌اند. جدای از این، مسیر یادگیری ماشین شاهد افزایش اتوماسیون بوده است. به طور مشابه، در حوزه سوپر رزولوشن تک تصویر، استفاده از شبکه‌های عصبی عمیق افزایش خارق‌العاده‌ای را در کیفیت ادراکی تصویر تولیدشده نشان داده است. دانگ و همکاران در کار خود نشان داده‌اند که روش‌های پیشرفته سنتی قبلی، مانند نمایش پراکنده، مورد خاصی از شبکه عصبی

کانولوشنال سه لایه آنها هستند. کار آنها همچنین نشان داد که چگونه روش‌های سنتی برای وضوح تصویر فوق‌العاده بهینه نیستند (Dong et al., ۲۰۱۴). در ادامه به برخی دیگر از مطالعات انجام‌شده در این حوزه پرداخته می‌شود.

لیم و همکاران در سال ۲۰۱۷، برای انجام سوپر رزولوشن دو شبکه‌ی ارتقا یافته و چندمقیاسه به ترتیب با نام‌های EDSR^۱ و MDSR^۲ را معرفی کرده‌اند. EDSR با حذف ماژول‌های غیرضروری از معماری ResNet معمولی، به نتایج بهبود یافته‌ای دست پیدا می‌کند و درعین حال مدل فشرده‌سازی می‌شود. مدل پیشنهادی در مقیاس تکی از مدل‌های هم‌زمان پیشی گرفته و به عملکرد پیشرفت‌های دست می‌یابد. MDSR با ماژول‌های وابسته به مقیاس و شبکه اصلی مشترک، می‌تواند به طور مؤثر با مقیاس‌های مختلف سوپر رزولوشن در یک چارچوب یکپارچه مقابله کند (Lim et al., ۲۰۱۷). درنهایت نیز مدل چند مقیاسی در مقایسه با مجموعه‌ای از مدل‌های تک مقیاس فشرده باقی می‌ماند و عملکرد قابل مقایسه با مدل تک مقیاس SR را نشان می‌دهد.

وانگ و همکاران در سال ۲۰۱۸، یک مدل پیشرفته‌تر از SRGAN^۳ (Ledig et al., ۲۰۱۷) به نام ESRGAN^۴ ارائه کرده‌اند که نسبت به روش‌های قبلی SR به کیفیت ادراکی بهتری دست یابد. در این رویکرد به طور خاص، بلوک متراکم باقیمانده در باقیمانده (RRDB^۵) را بدون نرمال‌سازی دسته‌ای (BN^۶) به عنوان واحد ساختمان اصلی شبکه معرفی می‌کنند. علاوه بر این، این ایده را از GAN نسبی گرایانه گرفته تا به تمایزگر اجازه داده شود واقعیت نسبی را به جای مقادیر مطلق پیش‌بینی کند (Wang et al., ۲۰۱۸). رویکرد مدنظر با استفاده از ویژگی‌های قبل از فعال‌سازی، perceptual loss را بهبود می‌بخشد، که می‌تواند نظارت قوی‌تری برای ثبات روشنایی و بازیابی بافت فراهم کند.

اکثر مدل‌های SR مبتنی بر CNN به قدرت محاسباتی بالایی نیاز دارند، که به طور قابل توجهی کاربردهای دنیای واقعی آنها را محدود می‌کند. علاوه بر این، اکثر روش‌های مبتنی بر CNN به ندرت ویژگی‌های میانی را که برای بازیابی تصویر نهایی مفید هستند، بررسی می‌کنند. برای پرداختن به این مسائل، لن و همکاران در سال ۲۰۲۰، یک شبکه سبک متراکم به نام MADNet^۷ را برای بیان ویژگی‌های چند مقیاسی قوی‌تر و یادگیری همبستگی ویژگی‌ها پیشنهاد می‌کنند که به طور خاص، یک ماژول چند مقیاسی باقیمانده با مکانیزم توجه (RMAM^۸) برای افزایش توانایی نمایش ویژگی‌های چند مقیاسی آموزنده توسعه داده شده است؛ همچنین یک بلوک مسیر باقیمانده دوگانه (DRPB^۹) ارائه می‌کنند که از ویژگی‌های سلسله مراتبی تصاویر با وضوح پایین اصلی استفاده می‌کند (Lan et al., ۲۰۲۰). نتایج مقایسه‌ای عملکرد برتر مدل MADNet را نشان می‌دهد درحالی‌که از چند افزوده و پارامترهای بسیار کمتری استفاده می‌کند.

دایهنگ و همکاران در سال ۲۰۲۲، برای حل چالش بازسازی اطلاعات و جزئیات با فرکانس بالا در تصویر با وضوح پایین ارائه‌شده توسط شبکه کانولوشن عمیق، یک شبکه متخصص مولد چند مقیاسی (MSGAN^{۱۰}) را پیشنهاد می‌کنند. در این روش ماژول هرم چند مقیاسی داخل ژنراتور می‌تواند ویژگی‌های حاوی اطلاعات فرکانس بالا را استخراج کند و سپس تصویر با وضوح بالا، با نتایج bicubic interpolation بازسازی می‌شود. در مقایسه با الگوریتم‌های مبتنی بر شبکه‌های کانولوشن ساده، الگوریتم پیشنهادی در دو شاخص PSNR^{۱۱} و SSIM^{۱۲}، بهتر عمل می‌کند (Daihong et al., ۲۰۲۲). این رویکرد باعث می‌شود تا سوپر رزولوشن در تصاویر با الگوهای تکراری همانند نمای ساختمان (ساختمانی با نمای شیشه‌ای تکرارشونده) بهتر عمل و جزئیات را حفظ کند.

^۱ Enhanced Deep Super-Resolution network

^۲ Multi-scale Deep Super-Resolution system

^۳ Super-Resolution Generative Adversarial Networks

^۴ Enhanced SRGAN

^۵ Residual-in-Residual Dense Block

^۶ Batch Normalization

^۷ A Fast and Lightweight Network for Single-Image Super Resolution

^۸ Residual Multiscale module with an Attention Mechanism

^۹ Dual Residual-Path Block

^{۱۰} Multi-Scale Generative Adversarial Network

^{۱۱} Peak Signal to Noise Ratio

^{۱۲} Strucure Similarity

در سال ۲۰۲۳، چن و همکاران که محققان حوزه ماشین بینایی می‌باشند، برای رسیدگی به مشکلات رایج لبه‌های تصویر تار، انتخاب اندازه‌ی کرنل^۱ کانولوشن انعطاف‌ناپذیر و هم‌گرایی آهسته در طول روش آموزشی به دلیل ساختار شبکه اضافی در الگوریتم‌های سوپررزولوشن، شبکه سوپر رزولوشن از طریق شبکه فیوژن ویژگی‌های چند سطحی به نام MF^۲ را ارائه داده‌اند. این مطالعه دارای ۴ قسمت اصلی می‌باشد؛ اول، بلوک باقیمانده دوگانه (DRB^۳) با ساختار نامتقارن را پیشنهاد می‌کنند؛ بلوک باقیمانده ابتدا دو بار گسترش می‌یابد، سپس دو بار فشرده می‌شود و از دو لایه اتصال باقی‌مانده برای استخراج مؤثر اطلاعات ویژگی استفاده می‌شود. دوم، یک واحد وزنی همبستگی خودکار (ACW^۴) پیشنهاد کرده‌اند که می‌تواند وزن‌ها را با توجه به اطلاعات ویژگی‌ها محاسبه و به‌طور تطبیقی کانال‌های ویژگی‌های مختلف را وزن کند تا به‌طور مؤثر اطلاعات ویژگی‌ها را منتقل نماید. سوم، با طراحی واحد نقشه‌برداری ویژگی‌های کم‌عمق (SFMU^۵) که سطوح مختلف ویژگی‌های کم‌عمق را از طریق لایه‌های کانولوشن فیلدهای گیرنده مختلف در هر شاخه استخراج می‌کند. چهارم، با طراحی واحد بازسازی چندمسیره (MPRU^۶) که می‌تواند اطلاعات ویژگی‌های چند شاخه را به دست آورد تا از اطلاعات ویژگی‌های سطوح مختلف برای بازسازی جنبه‌های مختلف تصویر به‌طور کامل استفاده کند (Y. Chen et al., ۲۰۲۳). روش ارائه‌شده به ترتیب PSNR و SSIM، ۳۳/۹۴ و ۰/۹۲۱۴ را کسب کرده است؛ نتایج تجربی به‌دست‌آمده نشان می‌دهد که مدل پیشنهادی می‌تواند به‌طور مؤثر نوارهای تصویر را بهبود بخشد و تصاویر باکیفیت بالا ای بازسازی کند. به این دلیل این رویکرد ممکن است در زمینه‌ی تصاویر ماهواره‌ای نیز عملکرد خوبی از خود نشان دهد.

به‌منظور جمع‌بندی، بررسی‌های صورت گرفته در سوپر رزولوشن حوزه‌ی ماشین بینایی به‌صورت مختصر در جدول ۵ آمده است.

جدول ۵) بررسی‌های صورت گرفته در سوپر رزولوشن حوزه‌ی ماشین بینایی به‌صورت مختصر.

نام نویسنده، سال	روش پیشنهادی	داده	مزایا	معایب	ارجاع
لیم و همکاران، سال ۲۰۱۷	EDSR MDSR	DIV ^۲ K (Timofte et al., ۲۰۱۷) Set ^۵ (Bevilacqua et al., ۲۰۱۲) Set ^{۱۴} (Zeyde et al., ۲۰۱۲) BSD ^{۱۰۰} (Martin et al., ۲۰۰۱) Urban ^{۱۰۰} (Huang et al., ۲۰۱۵) Set ^۵ (Bevilacqua et al., ۲۰۱۲)	• استفاده از یادگیری عمیق به صورت جدی در سوپر رزولوشن	• نبود روش‌های هم سطح برای مقایسه	Lim et al., (۲۰۱۷)
			• عملکرد بهتر نسبت به روش‌های سنتی سوپر رزولوشن		
وانگ و همکاران، سال ۲۰۱۸	ESRGAN	Set ^{۱۴} (Zeyde et al., ۲۰۱۲) BSD ^{۱۰۰} (Martin et al., ۲۰۰۱) Urban ^{۱۰۰} (Huang et al., ۲۰۱۵)	• نظارت قوی‌تری برای ثبات روشنایی و بازایی بافت فراهم می‌کند	• افزایش هزینه محاسباتی	Wang et al., (۲۰۱۸)
لن و همکاران، سال ۲۰۲۰	MADNet	Set ^{۱۴} (Zeyde et al., ۲۰۱۲) Urban ^{۱۰۰} (Huang et al., ۲۰۱۵)	• استفاده از پارامترهای کمتر • ویژگی‌های میانی را که	• استفاده از شبکه متراکم باعث افزایش زمان	Lan et al., (۲۰۲۰)

^۱ Kernel

^۲ Multi-level Features Fusion Network

^۳ Dual Residual Block

^۴ AutoCorrelation Weight

^۵ Shallow Feature Mapping Unit

^۶ Multi-Path Reconstruction Unit

آموزش می‌شود		برای بازیابی تصویر	نهایی مفید هستند،	بررسی می‌کند			
استفاده از bicubic		عملکرد قابل قبول در	تصاویر با الگوهای	تکراری	Set ^o		دایهنگ و همکاران، سال ۲۰۲۲
(Daihong)	interpolation در	ساخترار رویکرد که	ممکن است باعث	افزایش خطا شود	(Bevilacqua et al., ۲۰۱۲)	MSGAN	
et al.,					Set ^{۱۴}		
(۲۰۲۲)					(Zeyde et al., ۲۰۱۲)		
					BSD۱۰۰		
					(Martin et al., ۲۰۰۱)		
					DIV ^{۲K}		
					(Timofte et al., ۲۰۱۷)		
					Set ^o		
					(Bevilacqua et al., ۲۰۱۲)		
					Set ^{۱۴}		چن و همکاران، سال ۲۰۲۳
(Y. Chen)	هزینه‌ی محاسباتی	• وزن دهی مؤثر به	ویژگی‌ها	تشکیل تصویر نهایی با	(Zeyde et al., ۲۰۱۲)	MFFN	
et al.,	بالا به دلیل تعدد	• مراحل	نویز کم و شباهت	ساختاری بالا	Manga ^{۱۰۹}		
(۲۰۲۳)					(Matsui et al., ۲۰۱۷)		
					BSD۱۰۰		
					(Martin et al., ۲۰۰۱)		
					Urban ^{۱۰۰}		
					(Huang et al., ۲۰۱۵)		

برای سوپر رزولوشن در حوزه سنجش از دور مطالعات مختلفی صورت پذیرفته است. این حوزه در ابتدای کار خود سعی در استفاده از داده‌های Downsample شده داشته است (Lanaras et al., ۲۰۱۸; Zhang et al., ۲۰۲۰). این روش از جهت تهیه داده‌های آموزشی اولیه بسیار به صرفه و آسان بوده ولی دقت کافی جهت افزایش حد تفکیک مکانی را در دسترس قرار نمی‌دهد. در ادامه مطالعات در این حوزه، داده‌های سنجش از دور دیگر که دارای حد تفکیک مکانی بالاتری نسبت به داده‌های اولیه و همچنین از نظر طیفی به این داده‌ها می‌باشد مورد استفاده قرار گرفته است. در ادامه به برخی از مطالعات انجام شده در این حوزه پرداخته می‌شود.

لاناراس و همکاران در سال ۲۰۱۸، ابزاری را برای سوپر رزولوشن باندهای با وضوح پایین‌تر (۲۰ و ۶۰ متری) سنتینل-۲ به یک داده یکنواخت ۱۰ متری ارائه کرده‌اند. روش مدنظر از دو شبکه عصبی کانولوشنال عمیق برای یادگیری نگاشت مشترک از همه باندهای ورودی به باندهای خروجی ۲X، به ترتیب ۶X استفاده می‌کند. برای آموزش شبکه از داده‌های مجازی که توسط خودشان تولید شده، استفاده کرده‌اند؛ بدین صورت که باندهای ۶۰ و ۲۰ متری را به روش Down sampling به ترتیب به باندهای ۳۶۰ و ۴۰ متری تبدیل نموده‌اند (Lanaras et al., ۲۰۱۸). در ارزیابی‌های کمی، شبکه پیشنهادی که DSen^۲ نامیده شد، تقریباً ۵۰ درصد از بهترین رویکرد موجود در RMSE^۱ بهتر عمل می‌کند و ویژگی‌های طیفی را بهتر حفظ می‌کند؛ همچنین SRE^۲ را تقریباً ۶ دسی بل افزایش می‌دهد.

ژانگ و همکاران در سال ۲۰۲۰، طی مقاله‌ای یک رویکرد مبتنی بر GAN(SYGAN) را برای افزایش وضوح فضایی تصاویر چند طیفی با چند وضوح سنتینل-۲ (بدین معنا که تصاویر طیف‌های مختلف دارای حد تفکیک‌های متفاوت هستند) پیشنهاد می‌کنند. رویکرد پیشنهادی شامل دو مرحله اصلی است: (۱) افزایش حد تفکیک مکانی باندهای ۲۰ و ۶۰ متری، با هدایت آن‌ها به باندهای مرتبط ۱۰ متری توسط شبکه عصبی مولد، (۲) به طور مؤثر باندهای سوپر رزولوشن شده را از باندهای حقیقت زمینی آن‌ها توسط شبکه عصبی تشخیص‌دهنده متمایز کند (Zhang et al., ۲۰۲۰). بنابراین در این مطالعه از یادگیری مخالف شبکه‌های مولد و متمایزکننده استفاده شده است. رویکرد پیشنهادی نتایج قابل قبولی را از خود به جا گذاشته ولی به دلیل محدود بودن داده‌های مورد آزمایش، ممکن است نتایج قابل اطمینان نباشد.

^۱ Root Mean Square Error

^۲ Signal to Reconstruction Error ratio

ژانگ و همکاران در سال ۲۰۲۲، شبکه‌ای به نام MHAN^۱ پیشنهاد می‌کنند تا به طور کامل از ویژگی‌های سلسله مراتبی با استفاده از ماژول‌های مرتبه‌های مختلف توجه مرتبه بالا (HOA^۲) برای مشخص کردن نقشه‌ها با باندهای فرکانسی مختلف بهره‌برداری کند. رویکرد ارائه‌شده شامل دو جز شبکه استخراج ویژگی و یک شبکه اصلاح ویژگی با مکانیسم HOA برای بازیابی جزئیات می‌باشد (Zhang et al., ۲۰۲۲). این شبکه بر روی دو دیتاست AID (Xia et al., ۲۰۱۷) و RSSCN^۷ (Zou et al., ۲۰۱۵) مورد استفاده قرار گرفته است که نتایج به دست آمده‌شان داده‌اند که MHAN ارائه‌شده، می‌تواند عملکرد بهتری را در مقایسه با روش‌های پیشرفته با از نظر زمان اجرا و هزینه GPU کمتر ارائه دهد.

زابلزا و برناردینی در سال ۲۰۲۲، روشی به نام SARNet معرفی کردند و ساختارهای مختلفی از آن را همچون SARNet^۸، SARNet^{۱۶} و SARNet-RG^{۱۶} مورد آزمایش قرار دادند. در این مطالعه جهت آموزش شبکه عصبی از جفت تصاویرهای پلنت اسکوپ (۵ متر) و سنتینل-۲ (۱۰ متر) به دلیل شباهت طیفی بالا و رایگان بودن پلنت اسکوپ جهت افزایش حد تفکیک مکانی از ۱۰ متر به ۲/۵ متر استفاده کردند. نتایج حاصله بیانگر آن است که SARNet^۸، SARNet^{۱۶} و SARNet-RG^{۱۶} به ترتیب PSNR و SSIM، ۲۹/۴۷۱ و ۳۳/۵۷۸، ۰/۹۳۶ و ۳۳/۷۱۸، ۰/۹۹۱ و ۳۳/۷۴۰ و ۰/۹۹۰ را کسب نموده و روش پیش پیشنهادی با RCAB^{۱۶} بهترین عملکرد را به نمایش گذاشته است (Zabalza & Bernardini, ۲۰۲۲). این مطالعه فقط در یک منطقه انجام شده، بدین معنا که داده‌های آموزشی تنها از یک منطقه به نام نابارا (اسپانیا) تهیه گردیده است؛ بنابراین جامعیت کافی برای استفاده از این شبکه آموزش دیده برای بهره‌گیری در مناطق متنوع وجود ندارد.

صوفی و بلواده در سال ۲۰۲۳، طی پژوهشی یک رویکرد جدید برای بهبود کیفیت تصاویر ماهواره‌ای Sentinel-۲ با استفاده از تکنیک‌های یادگیری عمیق با سوپر رزولوشن ارائه می‌کنند. در این زمینه، این کار یک راه حل عمومی پیشنهاد می‌کند که وضوح فضایی را از ۱۰ متر به ۲.۵ متر (ضریب مقیاس ۴) با در نظر گرفتن محدودیت‌های حجمی و وابستگی بین باندهای طیفی اعمال شده توسط ویژگی‌های تصاویر ماهواره‌ای بهبود می‌بخشد. این مطالعه مدل FSRSI^۳ را پیشنهاد می‌کند که از پتانسیل شبکه‌های کانولوشن عمیق (CNN) بهره‌برداری می‌کند و مفاهیم پیشرفت‌های از جمله شبکه در شبکه، یادگیری پایان به پایان، ترکیب چند مقیاسی، بهینه‌سازی شبکه عصبی، شتاب و انتقال فیلتر^۴ را ادغام می‌کند؛ بنابراین، روش پیشنهادی از تمام پیشرفت‌های پیشنهادی در روش‌های مطالعه شده، برای به دست آوردن یک معماری مناسب، پارامترسازی مناسب و پردازش خاص برای ویژگی‌های تصاویر ماهواره‌ای چندطیفی بهره می‌برد (Soufi & Belouadha, ۲۰۲۳). آزمایش این راه حل نشان داد که از نظر کیفیت بصری و ادراکی و همچنین از نظر سرعت استنتاج نتایج رضایت بخشی دارند. باین حال، در نظر گرفتن همبستگی طیفی، این راه حل را از نظر ظرفیت پردازش هر نوع تصویر چند طیفی و ظرفیت یادگیری برای تعمیم بهتر در زمان، قدرتمند و عمومی می‌کند.

به منظور جمع‌بندی، بررسی‌های صورت گرفته در سوپر رزولوشن حوزه‌ی سنجش از دور به صورت مختصر در جدول ۶ آمده است.

جدول ۶) بررسی‌های صورت گرفته در سوپر رزولوشن حوزه‌ی سنجش از دور به صورت مختصر.

نام نویسنده، سال	روش پیشنهادی	داده	مزایا	معایب	ارجاع
لاناراس و همکاران، سال ۲۰۱۸	DSen ^۲	• داده‌های Downsample شده‌ی سنتینل-۲	• کاهش هزینه به دلیل استفاده از داده‌ی آسان	• بالا رفتن نویز	(Lanaras et al., ۲۰۱۸)
		• تصاویر سنتینل-۲	• RMSE نسبت به روش‌های هم دوره	• کیفیت پایین در داده‌های آموزشی	
ژانگ و	S ^۲ GAN	• تصاویر سنتینل-۲	• استفاده از شبکه‌های مولد	محدود بودن	(Zhang et al.,)

^۱ Mixed High-Order Attention Network

^۲ High-Order Attention

^۳ Fast Super Resolution Single-Image

^۴ Acceleration and filter transfer

همکاران، سال ۲۰۲۰	• داده‌های Downsample شده- ی سنتینل-۲	و متمایزکننده کاهش هزینه به دلیل استفاده از داده‌ی آسان	داده‌های آزمایش	مورد (۲۰۲۰)
ژانگ و همکاران، سال ۲۰۲۲	AID (Xia et al., ۲۰۱۷) MHAN RSSCN ^v (Zou et al., ۲۰۱۵)	• استفاده از مکانیسم HOA برای بازیابی جزئیات زمان اجرا و هزینه GPU کمتر در مقایسه روش‌های موجود	جامع دیتاست استفاده (ممکن) است در شرایط مختلف، مانند تغییرات آب و هوایی، نتایج متفاوتی ارائه دهد	Zhang et al.,) (۲۰۲۲)
زابالزا و برناردینی، سال ۲۰۲۲	• پلنت اسکوپ • سنتینل-۲	• رایگان بودن داده آموزشی • نظارت بر تولید داده آموزشی تأکید شبکه مورد استفاده بر حفظ ویژگی‌های طیفی بوده است	شبکه آموزش‌دیده برای بهره‌گیری در مناطق متنوع وجود ندارد	Zabalza &) Bernardini, (۲۰۲۲)
صوفی و بلواده، سال ۲۰۲۳	FSRSI تصاویر سنتینل-۲	• سرعت بالا • ترکیب چندی از پیشنهاد‌های انجام شده	یک سنجنده • اعمال مقیاس ۴ برابری باعث افزایش نویز می- شود	Soufi &) Belouadha, (۲۰۲۳)

برای آموزش شبکه‌های مورد نیاز جهت انجام سوپر رزولوشن، نیاز به یک سری داده‌های اولیه دیده می‌شود که این داده‌ها می‌توانند در مطالعه جمع‌آوری شوند و یا از داده‌های آماده استفاده شود. از این‌رو در ادامه برخی از دیتاست‌های آماده شده جهت انجام سوپر رزولوشن در حوزه سنجش‌ازدور مورد بررسی قرار می‌گیرد.

گالار و همکاران در سال ۲۰۱۹، دیتاستی جهت اعمال سوپر رزولوشن بر روی تصاویر سنتینل-۲ تهیه نموده‌اند. این دیتاست بین داده‌های رپیدای^۱ (۵ متری) و سنتینل-۲ جمع‌آوری شده، به صورتی که فقط ۴ باند سنتینل-۲ دو به دلیل شباهت طیفی آن‌ها مورد استفاده قرار گرفته است. این مجموعه شامل ۶۰۴۸ پچ^۲ ۹۶×۹۶ پیکسل از ۹ موقعیت مکانی مختلف در سال ۲۰۱۸ تهیه شده است (Galar Idoate et al., ۲۰۱۹). هر مجموعه‌ای از داده‌های تشکیل شده از دنیای واقعی، می‌تواند مشکلاتی داشته باشد، از این مشکلات می‌توان به ثبت اشتباه محلی به دلیل اثرات اختلاف‌منظر و عدم تعادل تعداد تاریخ‌ها و تعداد پچ در بین سایت‌های مختلف می‌توان اشاره کرد؛ بنابراین می‌بایست از این نوع مشکلات چشم‌پوشی کرد یا مجموعه‌ای با استحکام بالاتر به وجود آورد.


میشل و همکاران در سال ۲۰۲۲، اقدام به جمع‌آوری یک دیتاست جهت انجام عملیات SISR بر پایه یادگیری عمیق نموده‌اند. این مجموعه داده، ۲۹ موقعیت مکانی مختلف را با مجموعاً ۱۳۲۹۵۵ پچ ۲۵۶×۲۵۶، ۹۶×۹۶ و ۶۴×۶۴ پیکسل با

^۱ RapidEye

^۲ Patch

وضوح ۵ متر پوشش می‌دهد و می‌تواند برای آموزش و مقایسه الگوریتم‌های سوپر رزولوشن برای رساندن وضوح فضایی ۸ باند از باندهای سنتینل-۲ (باندهای ۲۰ و ۱۰ متری) به ۵ متر استفاده شود (Michel et al., ۲۰۲۲). این دیتاست به دلایلی مانند تنوع بالا در مناطق عکس‌برداری شده و شباهت بالای طیفی بین باندهای طیفی سنتینل-۲ و ونوس، می‌تواند مجموعه داده‌ای قابل اعتماد جهت آموزش شبکه سوپر رزولوشن باشد.

به‌منظور جمع‌بندی، بررسی‌های صورت گرفته در سوپر رزولوشن به‌صورت مختصر در شکل ۱۲ آمده است.




شکل ۱۲) خلاصه‌ای از دیتاست سوپررزولوشن در حوزه‌ی سنجش‌ازدور (Galar Idoate et al., ۲۰۱۹; Michel et al., ۲۰۲۲).

با بررسی مطالعات انجام شده در حوزه‌ی سوپر رزولوشن، می‌توان این مطالعات را به سه بخش سوپر رزولوشن در ماشین بینایی، سوپر رزولوشن در سنجش‌ازدور و دیتاست سوپر رزولوشن تقسیم نمود. زادگاه اصلی سوپر رزولوشن در کاربردهای ماشین بینایی می‌باشد که مطالعات زیادی صورت گرفته و پس از آن وارد بخش سنجش‌ازدوری شده است. بین مطالعات صورت گرفته می‌توان دید که استفاده از ساختارهای بر پایه‌ی GAN موارد استفاده بیشتر و نتایج بهتری دارد. علاوه بر این، برای انجام سوپر رزولوشن نیازمند داده‌های آموزشی می‌باشد که مطالعاتی در این بخش نیز صورت گرفته که می‌تواند در تولید این داده کمک کند و یا می‌توان از این دیتاست‌های آماده استفاده نمود.

۴- بحث و تحلیل

در طول این پژوهش، مطالعات منتشرشده از مجله‌های معتبر مختلف توسط محققان در دو زمینه‌ی تشخیص شبکه‌ی راه و سوپر رزولوشن موردبررسی قرار گرفته است، که با توجه به مقاله‌های موردبررسی در زمینه‌ی تشخیص شبکه‌ی راه‌ها، روش‌های مبتنی بر کلاسه‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین به‌ترتیب سهم‌هایی حدود ۲۸، ۳۱، ۵ و ۳۶ درصدی را دارا می‌باشند؛ البته با در نظر داشت که با پیشرفت شبکه‌های عصبی و ترندهای یادگیری عمیق در سال‌های اخیر، روش‌های مبتنی بر کلاسه‌بندی و قطعه‌بندی با یادگیری عمیق توسعه داده شده‌اند که سهم روش‌های مبتنی بر یادگیری ماشین انداز‌ه‌ی بیشتری (حدود ۶۱ درصد) را دربر گرفته است؛ همچنین با توجه به مقاله‌های موردبررسی زمینه‌ی سوپر رزولوشن، روش‌های مبتنی بر روش‌های سنتی و یادگیری عمیق به‌ترتیب سهم‌هایی حدود ۴۴ و ۵۶ درصدی را دارا می‌باشند که در سال‌های اخیر اغلب رویکردهای سوپر رزولوشن مبتنی بر یادگیری عمیق در حال توسعه هستند. میزان مطالعات انجام شده در هر دو زمینه به صورت شماتیک در شکل ۱۳ آمده است. همچنین تعدادی از بررسی‌های انجام‌شده مربوط به تلفیق تصاویر در صفحه‌ی ۱۱ آمده است.



شکل ۱۳) میزان مطالعات انجام شده (الف) رویکردهای زمینه‌شناسایی شبکه‌ی راه‌ها (ب) رویکردهای زمینه‌ی سوپر رزولوشن.

تهیه‌ی نقشه‌ی مکانی شبکه‌ی راه‌ها و به‌روزرسانی دوره‌ای همواره یک موضوع مهم جهت مدیریت و برنامه‌ریزی برای ساخت و نگهداری جاده‌ها بوده است. تشخیص راه‌ها از تصاویر سنجش‌ازدوری در ابتدای امر به‌صورت دستی انجام می‌شد که فرایندی دشوار، زمان‌بر و همراه با خطاهای انسانی را ایجاد می‌کرد؛ به همین علت طی سال‌ها به روش‌های اتوماتیک روی آورده شد. در مراحل اولیه، روش‌های تشخیص راه بر اساس الگوریتم‌های تشخیص لبه توسعه یافتند، چرا که راه‌ها در تصاویر سنجش‌ازدور اغلب به صورت لبه‌های خطی ظاهر می‌شوند. باین‌حال، این روش‌ها به دلیل حساسیت به نویز و عدم توانایی در تشخیص راه‌های پیچیده، محدودیت‌هایی داشتند. با پیشرفت فناوری، الگوریتم‌های قطعه‌بندی جایگزین شدند که با توجه به ویژگی پیوستگی راه‌ها، عملکرد بهتری از خود نشان دادند. اما این روش‌ها نیز در مواجهه با مناطق با پوشش گیاهی متراکم یا سایه‌های گسترده، دچار مشکل می‌شدند. با افزایش پیچیدگی شبکه‌ی راه‌ها و نیاز به دقت بالاتر، روش‌های مبتنی بر هوش مصنوعی به ویژه یادگیری عمیق، به‌عنوان راه‌حلی کارآمد مطرح شدند. در ابتدا، الگوریتم‌های یادگیری ماشین ساده‌تر مانند SVM و درخت‌های تصمیم‌مورد استفاده قرار گرفتند، اما با پیشرفت سخت‌افزارهای پردازشی و ظهور شبکه‌های عصبی عمیق مانند CNN و GAN، موجب تحول چشمگیری در این حوزه شده است. این شبکه‌ها با توانایی استخراج خودکار ویژگی‌ها و یادگیری الگوهای پیچیده، توانستند دقت تشخیص راه‌ها را به طور قابل توجهی افزایش 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، ازجمله رویکردهای موردتوسعه و بهبود آتی و غالب در این حوزه می‌باشد.

داده مناسب جهت تشخیص راه داده‌ای می‌باشد که حد تفکیک مکانی آن کمتر از حداقل عرض راه موجود در منطقه مورد مطالعه باشد تا راه به صورت مطلوب تشخیص داده شود. از آنجایی که شبکه‌ی راه‌های روستایی دارای عرض کمی هستند، تصاویر با حد تفکیک مکانی بالا پاسخ‌گوی نیاز خواهند بود، ولیکن به دلیل عدم دسترسی آسان و هزینه‌ی بالا، استفاده از آن‌ها صرفه اقتصادی و زمانی ندارد. از طرفی تصاویری با حد تفکیک مکانی متوسط نیز موجود هستند که به دلیل عدم همخوانی رزولوشن آن‌ها با عرض برخی راه‌ها احتمال از دست رفتگی در تشخیص وجود دارد. بنابراین برای بهینه نمودن هزینه عملیات اجرایی و دقت خروجی حاصل روش‌های بهبود حد تفکیک مکانی تصاویر ارائه شدند.

در این مطالعه، روش‌های سوپر رزولوشن به‌عنوان راه‌حلی برای بهبود حد تفکیک مکانی تصاویر موردبررسی قرار گرفتند. این روش‌ها به دو دسته سنتی و نوین تقسیم می‌شوند. روش‌های سنتی، مانند درون‌یابی، به دلیل عدم توانایی در یادگیری ویژگی‌های پیچیده و حفظ جزئیات تصویر، جای خود را به روش‌های نوین مبتنی بر یادگیری عمیق داده‌اند. شبکه‌های عمیق همانند SRCNN و ESRGAN 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 بیشتر هستند.

۵- نتیجه‌گیری و پیشنهادات

این پژوهش با هدف بررسی روش‌های تشخیص شبکه‌ی راه‌ها و بهینه‌سازی استفاده از تصاویر ماهواره‌ای با حد تفکیک مکانی متوسط انجام شده است. نتایج نشان می‌دهد که روش‌های مبتنی بر شبکه‌های عصبی، به ویژه یادگیری عمیق، به دلیل توانایی در استخراج خودکار ویژگی‌ها و یادگیری الگوهای پیچیده، عملکرد بهتری نسبت به روش‌های مبتنی بر قطعه‌بندی و شاخص‌های طیفی نشان داده‌اند. باید در نظر داشت که لازمه استفاده از شبکه‌های عصبی جمع‌آوری و یا در دسترس بودن داده‌های آموزشی می‌باشد تا بتوان شبکه مد نظر را آموزش داد و از آن بهره‌برداری نمود. در استفاده از سایر روش‌ها همانند روش‌های قطعه‌بندی، مدل‌ها انعطاف‌پذیری لازم جهت تشخیص راه‌های پیچیده را ندارند به همین دلیل استفاده از مدل‌های قابل آموزش ارجحیت دارد. در بحث تشخیص راه‌ها با شاخص به دلیل تنوع در جنس مسیر همانند خاکی، آسفالت و... نمی‌توان از یک شاخص منحصربه‌فرد برای تشخیص تمامی راه‌ها استفاده نمود. لذا به کارگیری شاخص‌های جهت تشخیص و طبقه‌بندی راه‌ها، نمی‌تواند روشی قابل اعتماد و جامع باشد. حد تفکیک مکانی داده‌های مورد استفاده در راستای دستیابی به هدف تحقیق، از اهمیت بالایی برخوردار می‌باشد. استفاده از تصاویر با حد تفکیک مکانی متوسط به دلیل دسترسی رایگان آن‌ها، موجب ایجاد اختلال در تشخیص راه‌ها با عرض کم خواهد شد. لذا برای بهبود دقت تشخیص راه‌ها، می‌بایست از تصاویر با حد تفکیک مکانی بالا استفاده نمود یا رویکردهایی همانند تلفیق تصاویر و سوپر رزولوشن را مدنظر قرار داد.

با توجه به مطالعاتی که در زمینه تشخیص شبکه‌های راه‌ها مورد بررسی قرار گرفته‌اند، روش‌های مختلفی ارائه شده است. این روش‌ها شامل کلاس‌بندی، قطعه‌بندی، شاخص راه و یادگیری ماشین می‌باشند. بر این اساس، سهم این روش‌ها به ترتیب حدود ۲۸، ۳۱، ۵ و ۳۶ درصد می‌باشد. در نهایت می‌توان نتیجه گرفت که در حوزه تشخیص شبکه‌های راه‌ها، روش‌های مبتنی بر یادگیری ماشین و در حوزه سوپر رزولوشن، روش‌های مبتنی بر یادگیری عمیق به دلیل کارایی بالاتر و نتایج بهتر، به طور گسترده‌تری مورد استفاده قرار می‌گیرند. با توجه به تمرکز مطالعات در سال‌های اخیر بر روی استفاده از مدل‌های یادگیری عمیق می‌توان دریافت که رویکردهای آتی شناسایی شبکه‌ی راه‌ها متکی بر مدل‌های یادگیری عمیق خواهد بود. در مجموع با تکیه بر بررسی‌های صورت گرفته، برای عملیاتی سازی هدف شناسایی شبکه راه‌ها و فراهم نمودن امکان به‌روزرسانی با صرف زمان و هزینه مناسب، می‌توان با استفاده از رویکردهای سوپر رزولوشن حد تفکیک مکانی داده‌های رایگان را افزایش داد، سپس رویکردهای مبتنی بر یادگیری عمیق شناسایی شبکه‌ی راه به کار گرفت. در این راستا نیز با توجه به امکانات طرح نظیر میزان توانایی سخت‌افزار در دسترس جهت آموزش شبکه‌ها و موجودیت دیتاست مناسب، می‌توان رویکردهای مدنظر را تعیین نمود. از چالش‌های موجود در تشخیص راه‌ها، می‌توان به وجود پوشش گیاهی و سایه در تصاویر اشاره نمود که باعث می‌شود تا راه‌ها به صورت کامل و یکپارچه تشخیص داده نشوند؛ برای بهبود تقریبی این مسئله رویکردی همچون رأی‌گیری تنسوری ارائه شده که قابلیت تکمیل و تصحیح راه‌هایی که به صورت ناقص تشخیص داده شده‌اند را دارا می‌باشد. در مجموع این پژوهش با ارائه دسته‌بندی‌ها و رویکردهای برتر در زمینه‌های بیان شده، می‌تواند کمک‌کننده‌ی محققان باشد تا بسته به نوع کاربرد و منابع مورد استفاده، الگوریتم و داده‌های مورد نیاز خود را جهت شناسایی شبکه‌ی راه‌ها انتخاب و استفاده نمایند.

در این مطالعه به به کارگیری داده‌های لیدار و SAR بر تشخیص راه‌های روستایی با استفاده از تصاویر سنجش‌ازدور اشاره شد. اما به جهت اهمیت این داده‌ها پیشنهاد می‌گردد در مطالعات آینده تأثیرات داده‌های مکمل، همانند داده‌های لیدار و SAR با جزییات بیشتری مورد بررسی قرار گیرند. این داده‌ها به دلیل قابلیت‌های تکمیلی خود در شناسایی ویژگی‌های فیزیکی و ساختاری راه‌ها، می‌توانند به عنوان گزینه‌های برای روش‌های هیبرید در کنار تصاویر سنجش‌ازدور عمل کنند. همچنین، روش‌های پردازشی مختص این داده‌ها نیز نیازمند تحلیل و ارزیابی دقیق هستند تا بتوانند به طور مؤثر در شناسایی شبکه‌ی راه‌ها به کار گرفته شوند.

- A. Kiani, Ebadi, H., & Khanlou, H. a. (۲۰۱۸). Object based interpretation of high spatial remote sensing images based on knowledge-based systems. *Iranian Journal of Remote Sensing & GIS*, 10(۴), ۲۷-۵۴. https://gisj.sbu.ac.ir/article/۹۶۶۲۲_bf۸۰۷۰bd۷۷۸dd۹۱۷e۷ffa۴۶۸۷۰cfc۸۲.pdf
- A. Kiani, & H. Ebadi. (۲۰۱۵). 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(۴), ۶۷-۸۲. <https://doi.org/http://jgst.issgcac.ir/article-۱-۳۰۸-en.html>
- Abdollahi, A., Pradhan, B., & Alamri, A. (۲۰۲۰). VNet: An end-to-end fully convolutional neural network for road extraction from high-resolution remote sensing data. *IEEE Access*, 8, ۱۷۹۴۲۴-۱۷۹۴۳۶. <https://doi.org/۱۰.۱۱۰۹/ACCESS.۲۰۲۰.۳۰۲۶۶۵۸>
- Abdollahi, A., Pradhan, B., Shukla, N., Chakraborty, S., & Alamri, A. (۲۰۲۰). Deep learning approaches applied to remote sensing datasets for road extraction: A state-of-the-art review. *Remote sensing*, 12(۹), ۱۴۴۴. <https://doi.org/۱۰.۱۱۰۹/ACCESS.۲۰۲۰.۳۰۲۶۶۵۸>
- Ablin, R., Sulochana, C. H., & Prabin, G. (۲۰۲۰). An investigation in satellite images based on image enhancement techniques. *European Journal of Remote Sensing*, 53(sup۲), ۸۶-۹۴. <https://doi.org/۱۰.۱۰۸۰/۲۲۷۹۷۲۵۴,۲۰۱۹,۱۶۷۳۲۱۶>
- Adigun, O., Olsen, P. A., & Chandra, R. (۲۰۲۲). Location Aware Super-Resolution for Satellite Data Fusion. IGARSS ۲۰۲۲-۲۰۲۲ IEEE International Geoscience and Remote Sensing Symposium.
- Ahmed, M. W., Saadi, S., & Ahmed, M. (۲۰۲۲). Automated road extraction using reinforced road indices for Sentinel-۲ data. *Array*, 16, ۱۰۰۲۵۷. <https://doi.org/۱۰.۱۰۱۶/j.array.۲۰۲۲.۱۰۰۲۵۷>
- Alvarez-Vanhard, E., Corpetti, T., & Houet, T. (۲۰۲۱). UAV & satellite synergies for optical remote sensing applications: A literature review. *Science of remote sensing*, 3, ۱۰۰۰۱۹. <https://doi.org/۱۰.۱۰۱۶/j.srs.۲۰۲۱.۱۰۰۰۱۹>
- Arora, S., Suman, H. K., Mathur, T., Pandey, H. M., & Tiwari, K. (۲۰۲۳). Fractional derivative based weighted skip connections for satellite image road segmentation. *Neural Networks*, 161, ۱۴۲-۱۵۳. <https://doi.org/۱۰.۱۰۱۶/j.neunet.۲۰۲۳.۱۰۰۳۱>
- Babaali, K. O., Zigh, E., Djebbouri, M., & Kadiri, M. (۲۰۱۴). Survey of some new road extraction methods. *The International Journal Of Engineering And Science (IJES)*, 3(۱۱), ۲۸-۳۳.
- Badran, A., El-Geneidy, A., & Miranda-Moreno, L. (۲۰۲۴). A review of techniques to extract road network features from global positioning system data for transport modelling. *Transport Reviews*, 44(۱), ۶۹-۸۴. <https://doi.org/۱۰.۱۰۸۰/۰۱۴۴۱۶۴۷,۲۰۲۳,۲۲۹۵۲۱>
- Bakhtiari, H. R. R., Abdollahi, A., & Rezaeian, H. (۲۰۱۷). Semi automatic road extraction from digital images. *The Egyptian Journal of Remote Sensing and Space Science*, 20(۱), ۱۱۷-۱۲۳. <https://doi.org/۱۰.۱۰۱۶/j.ejrs.۲۰۱۷.۰۳.۰۰۱>
- Belgiu, M., & Stein, A. (۲۰۱۹). Spatiotemporal image fusion in remote sensing. *Remote sensing*, 11(۷), ۸۱۸. <https://doi.org/۱۰.۳۳۹۰/rs۱۱۰۷۰۸۱۸>
- Bevilacqua, M., Roumy, A., Guillemot, C., & Alberi-Morel, M. L. (۲۰۱۲). Low-complexity single-image super-resolution based on nonnegative neighbor embedding. <https://doi.org/۱۰.۵۲۴۴/C.۲۶.۱۳۵>
- Blaschke, T., Burnett, C., & Pekkarinen, A. (۲۰۰۴). Image segmentation methods for object-based analysis and classification. *Remote sensing image analysis: Including the spatial domain*, ۲۱۱-۲۳۶.
- Botelho Jr, J., Costa, S. C., Ribeiro, J. G., & Souza Jr, C. M. (۲۰۲۲). Mapping roads in the Brazilian Amazon with artificial intelligence and Sentinel-۲. *Remote sensing*, 14(۱۵), ۳۶۲۵. <https://doi.org/۱۰.۳۳۹۰/rs۱۴۱۵۳۶۲۵>
- Chang, H., Yeung, D.-Y., & Xiong, Y. (۲۰۰۴). Super-resolution through neighbor embedding. Proceedings of the ۲۰۰۴ IEEE Computer Society Conference on Computer Vision and Pattern Recognition, ۲۰۰۴. CVPR ۲۰۰۴.
- Chen, G., Lu, H., Zou, W., Li, L., Emam, M., Chen, X., Jing, W., Wang, J., & Li, C. (۲۰۲۳). Spatiotemporal Fusion for Spectral Remote Sensing: A Statistical Analysis and Review. *Journal of King Saud University-Computer and Information Sciences*. <https://doi.org/۱۰.۱۰۱۶/j.jksuci.۲۰۲۳.۰۲.۰۲۱>
- Chen, L., Letu, H., Fan, M., Shang, H., Tao, J., Wu, L., Zhang, Y., Yu, C., Gu, J., & Zhang, N. (۲۰۲۲). An introduction to the Chinese high-resolution Earth observation system: Gaofen-۱ ~ ۷ civilian satellites. *Journal of Remote Sensing*. <https://doi.org/۱۰.۳۴۱۳۳/۲۰۲۲/۹۷۶۹۵۳>
- Chen, W., Ouyang, S., Yang, J., Li, X., Zhou, G., & Wang, L. (۲۰۲۲). JAGAN: a framework for complex land cover classification using Gaofen-۵ AHSI images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, ۱۵۹۱-۱۶۰۳. <https://doi.org/۱۰.۱۱۰۹/JSTARS.۲۰۲۲.۳۱۴۴۳۳۹>
- Chen, Y., Xia, R., Yang, K., & Zou, K. (۲۰۲۳). MFFN: image super-resolution via multi-level features fusion network. *The Visual Computer*, ۱-۱۶. <https://doi.org/۱۰.۱۰۰۷/s۰۰۳۷۱۰۰۲۳۰۲۷۹۵۰۰>
- Chen, Z., Deng, L., Luo, Y., Li, D., Junior, J. M., Gonçalves, W. N., Nurunnabi, A. A. M., Li, J., Wang, C., & Li, D. (۲۰۲۲). Road extraction in remote sensing data: A survey. *International Journal of Applied Earth Observation and Geoinformation*, 112, ۱۰۲۸۳۳. <https://doi.org/۱۰.۱۰۱۶/j.jag.۲۰۲۲.۱۰۲۸۳۳>
- Daihong, J., Sai, Z., Lei, D., & Yueming, D. (۲۰۲۲). Multi-scale generative adversarial network for image super-resolution. *Soft Computing*, 26(۸), ۳۶۲۱-۳۶۴۱. <https://doi.org/۱۰.۱۰۰۷/s۰۰۵۰۰۰۰۲۲۰۶۸۲۲۰۵>
- Deepan, P., Abinaya, S., Haritha, G., & Iswarya, V. (۲۰۱۸). Road recognition from remote sensing imagery using machine learning. *International Research Journal of Engineering and Technology*, 5(۳), ۳۶۷۷-۳۶۸۳.
- Dick, A., Raynaud, J.-L., Rolland, A., Pelou, S., Coustance, S., Dedieu, G., Hagolle, O., Burochin, J.-P., Binet, R., & Moreau, A. (۲۰۲۲). Venus: Mission characteristics, final evaluation of the first phase and data production. *Remote sensing*, (14)14, ۳۲۸۱. <https://doi.org/۱۰.۳۳۹۰/rs۱۴۱۴۳۲۸۱>

- Dong, C., Loy, C. C., He, K., & Tang, X. (۲۰۱۴). Learning a deep convolutional network for image super-resolution. *Computer Vision—ECCV ۲۰۱۴: ۱۳th European Conference, Zurich, Switzerland, September ۶–۱۲, ۲۰۱۴*, Proceedings, Part IV ۱۳.
- Dong, J., Zhuang, D., Huang, Y., & Fu, J. (۲۰۰۹). Advances in multi-sensor data fusion: Algorithms and applications. *Sensors*, 9(۱), ۷۷۷۱–۷۷۸۴. <https://doi.org/1۰.۳۳۹۰/s۹۱۰۰۷۷۷۱>
- Dong, W., Zhang, L., Shi, G., & Wu, X. (۲۰۱۱). Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization. *IEEE Transactions on Image Processing*, 20(۷), ۱۸۳۸–۱۸۵۷. <https://doi.org/1۰.۱۱۰۹/TIP.۲۰۱۱.۲۱۰۸۳۰۶>
- Emad, M., Peemen, M., & Corporaal, H. (۲۰۲۱). 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. (۲۰۱۱). Image and video upscaling from local self-examples. *ACM Transactions on Graphics (TOG)*, 30(۲), ۱–۱۱. <https://doi.org/1۰.۱۱۴۵/۱۹۴۴۸۴۶.۱۹۴۴۸۵۲>
- Freeman, W. T., Jones, T. R., & Pasztor, E. C. (۲۰۰۲). Example-based super-resolution. *IEEE Computer graphics and Applications*, 22(۲), ۵۶–۶۵. <https://doi.org/1۰.۱۱۰۹/۲۳۸.۹۸۸۷۴۷>
- Galar Idoate, M., Sesma Redín, R., Ayala Lauroba, C., & Aranda, C. (۲۰۱۹). Super-resolution for Sentinel-۲ images. *International Archives of The Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archives*, ۲۰۱۹, XLII-۲/W۱۶, ۹۵–۱۰۲. <https://doi.org/1۰.۵۱۹۴/isprs-archives-XLII-۲-W۱۶-۹۵-۲۰۱۹>
- Gao, L., Song, W., Dai, J., & Chen, Y. (۲۰۱۹). Road extraction from high-resolution remote sensing imagery using refined deep residual convolutional neural network. *Remote sensing*, 11(۵), ۵۵۲. <https://doi.org/1۰.۳۳۹۰/rs۱۰۰۹۱۴۶۱>
- Gao, X., Zhang, K., Tao, D., & Li, X. (۲۰۱۲). Image super-resolution with sparse neighbor embedding. *IEEE Transactions on Image Processing*, 21(۷), ۳۱۹۴–۳۲۰۵. <https://doi.org/1۰.۱۱۰۹/TIP.۲۰۱۲.۲۱۹۰۰۸>
- Gatys, L. A., Ecker, A. S., & Bethge, M. (۲۰۱۵). A neural algorithm of artistic style. *arXiv preprint arXiv:1508.06576*. <https://doi.org/1۰.۴۸۵۵۰/arXiv.1۵۰۸.۰۶۵۷۶>
- Ghandorh, H., Boullila, W., Masood, S., Koubaa, A., Ahmed, F., & Ahmad, J. (۲۰۲۲). Semantic segmentation and edge detection—Approach to road detection in very high resolution satellite images. *Remote sensing*, 14(۳), ۶۱۳. <https://doi.org/1۰.۳۳۹۰/rs۱۴۰۳۰۶۱۳>
- Ghassemian, H. (۲۰۱۶). A review of remote sensing image fusion methods. *Information Fusion*, 32, ۷۵–۸۹. <https://doi.org/1۰.۱۰۱۶/j.inffus.۲۰۱۶.۰۳.۰۰۳>
- Gonzalez, R. C., & Woods, R. E. (۲۰۰۶). *Digital Image Processing*. Pearson Education. <https://books.google.com/books?id=MaYuAAAAQBAJ>
- Grinias, I., Panagiotakis, C., & Tziritas, G. (۲۰۱۶). 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, ۱۴۵–۱۶۶. <https://doi.org/1۰.۱۰۱۶/j.isprsjprs.۲۰۱۶.۰۱.۰۱۰>
- H. He and W. -C. Siu, "Single image super-resolution using Gaussian process regression," *CVPR 2011*, Colorado Springs, CO, USA, ۲۰۱۱, pp. ۴۴۹–۴۵۶. <https://doi.org/1۰.۱۱۰۹/CVPR.۲۰۱۱.۵۹۹۵۱۳>
- Henry, C., Azimi, S. M., & Merkle, N. (۲۰۱۸). Road segmentation in SAR satellite images with deep fully convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 15(۱۲), ۱۸۶۷–۱۰۸۷۱
- J. -B. Huang, A. Singh and N. Ahuja, "Single image super-resolution from transformed self-exemplars," *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, MA, USA, ۲۰۱۵, pp. ۵۱۹۷–۵۲۰۶. <https://doi.org/1۰.۱۱۰۹/CVPR.۲۰۱۵.۷۲۹۹۱۵۶>
- Irani, M., & Peleg, S. (۱۹۹۱). Improving resolution by image registration. *CVGIP: Graphical models and image processing*, ۵۳(۳), ۲۳۱–۲۳۹. [https://doi.org/1۰.۱۰۱۶/۱۰۴۹-۹۶۵۲\(۹۱\)۹۰۰۴۵۰-L](https://doi.org/1۰.۱۰۱۶/۱۰۴۹-۹۶۵۲(۹۱)۹۰۰۴۵۰-L)
- Javan, F. D., Samadzadegan, F., Mehravar, S., Toosi, A., Khatami, R., & Stein, A. (۲۰۲۱). A review of image fusion techniques for pan-sharpening of high-resolution satellite imagery. *ISPRS journal of photogrammetry and remote sensing*, 171, ۱۰۱–۱۱۷. <https://doi.org/1۰.۱۰۱۶/j.isprsjprs.۲۰۲۰.۱۱.۰۰۱>
- Jia, J., Sun, H., Jiang, C., Karila, K., Karjalainen, M., Ahokas, E., Khoramshahi, E., Hu, P., Chen, C., & Xue, T. (۲۰۲۱). Review on active and passive remote sensing techniques for road extraction. *Remote sensing*, 13(۲۱), ۴۲۳۵. <https://doi.org/1۰.۳۳۹۰/rs۱۳۲۱۴۲۳۵>
- Jing, J., Liu, S., Wang, G., Zhang, W., & Sun, C. (۲۰۲۲). Recent advances on image edge detection: A comprehensive review. *Neurocomputing*, 503, ۲۵۹–۲۷۱. <https://doi.org/1۰.۱۰۱۶/j.neucom.۲۰۲۲.۰۶.۰۸۳>
- Jozdani, S. E., Johnson, B. A., & Chen, D. (۲۰۱۹). Comparing deep neural networks, ensemble classifiers, and support vector machine algorithms for object-based urban land use/land cover classification. *Remote sensing*, 11(۱۴), ۱۷۱۳. <https://doi.org/1۰.۳۳۹۰/rs۱۱۱۴۱۷۱۳>
- Jurado, J. M., López, A., Pádua, L., & Sousa, J. J. (۲۰۲۲). Remote sensing image fusion on ۳D scenarios: A review of applications for agriculture and forestry. *International Journal of Applied Earth Observation and GeoInformation*, ۱۱۲, ۱۰۲۸۵۶. <https://doi.org/1۰.۱۰۱۶/j.jag.۲۰۲۲.۱۰۲۸۵۶>
- Kahraman, I., Karas, I., & Akay, A. E. (۲۰۱۸). Road extraction techniques from remote sensing images: A review. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, ۳۳۹–۳۴۲. <https://doi.org/1۰.۵۱۹۴/isprs-archives-XLII-۴-W۱۶-۳۳۹-۲۰۱۸>
- Kiani, A., Ebadi, H., & Farnood Ahmadi, F. (۲۰۱۰). Development of an object-based interpretive system based on weighted scoring method in a multi-scale manner. *ISPRS International Journal of Geo-Information*, 8(۹), ۳۹۸. <https://doi.org/1۰.۳۳۹۰/ijgi۸۰۹۰۳۹۸>
- Kiani, A., & Sahebi, M. R. (۲۰۱۵). Edge detection based on the Shannon Entropy by piecewise thresholding on remote sensing images. *IET Computer Vision*, 9(۵), ۷۵۸–۷۶۸. <https://doi.org/1۰.۱۰۴۹/iet-cvi.۲۰۱۳.۰۱۹۲>
- Kim, G., Park, J., Lee, K., Lee, J., Min, J., Lee, B., Han, D. K., & Ko, H. (۲۰۲۰). 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/CVPRW.2020.9482020>
- 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/10.48000/arXiv.1601.01725>
- 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), 1117-1133. <https://doi.org/10.1109/TPAMI.2010.20>
- 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), 1443-1453. <https://doi.org/10.1109/TCYB.2020.2991014>
- 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, 30-49. <https://doi.org/10.1016/j.isprsjprs.2018.09.018>
- Ledig, C., Theis, L., Huszar, 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, 2017, pp. 100-108. <https://doi.org/10.1109/CVPR.2017.19>
- 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, 1-17. <https://doi.org/10.1007/s11464-019-0780-y>
- 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, 100-117. <https://doi.org/10.1016/j.inffus.2016.05.004>
- 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, 589-607. <https://doi.org/10.1109/JSTARS.2020.2930499>
- 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, 2017, pp. 112-119. <https://doi.org/10.1109/CVPRW.2017.101>
- 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), 130-159. <https://doi.org/10.1007/s41314-022-0194-z>
- Liu, R., Wu, J., Lu, W., Miao, Q., Zhang, H., Liu, X., Lu, Z., & Li, L. (2021). A Review of Deep Learning-Based Methods for Road Extraction from High-Resolution Remote Sensing Images. *Remote sensing*, 16(12), 2067. <https://doi.org/10.3390/rs16122067>
- Liu, W., & Wang, H. (2008). An interactive image segmentation method based on graph theory. *J. Electron. Inf. Technol*, 8(20), 1972-1976. <https://doi.org/10.3390/j8201972>
- Liu, Y., Fan, B., Wang, L., Bai, J., Xiang, S., & Pan, C. (2018). Semantic labeling in very high resolution images via a self-cascaded convolutional neural network. *ISPRS journal of photogrammetry and remote sensing*, 145, 98-90. <https://doi.org/10.1016/j.isprsjprs.2017.12.007>
- 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), 2043-2051. <https://doi.org/10.1109/TGRS.2018.2870871>
- Luo, Z., Zhou, K., Tan, Y., Wang, X., Zhu, R., & Zhang, L. (2022). 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.2022.3228908>
- Market analysis news site. (2020). <https://www.tahlilbazaar.com/news/199707/>
- 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, 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 manga101 dataset. *Multimedia Tools and Applications*, 76, 21811-21838. <https://doi.org/10.48000/arXiv.1601.01725>
- Michel, J., Vinasco-Salinas, J., Inglada, J., & Hagolle, O. (2022). SEN2VENμS, a dataset for the training of Sentinel-2 super-resolution algorithms. *Data*, 7(7), 96. <https://doi.org/10.3390/data707096>
- Mnih, V. (2012). *Machine learning for aerial image labeling*. University of Toronto (Canada).
- Patnaik, A., Bhuyan, M., & MacDorman, K. F. (2021). 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.2021.3221111>
- 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), 823-854. <https://doi.org/10.1080/014317998105748>

- 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), 247-258. <https://doi.org/10.1109/TPAMI.2014.2321144>
- Pruthi, Jyoti & Dhingra, Sunita. (2022). A Review of Research on Road Feature Extraction Through Remote Sensing Images Based on Deep Learning Algorithms. 1-9. <https://doi.org/10.1109/CISCT-2019.0001299>
- 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
- S. L. K. Reddy, C. V. Rao, P. R. Kumar, R. V. G. Anjaneyulu and V. M. Bothale, "Automatic Road Feature Extraction using MRF from LANDSAT-8 OLI Images," *2019 IEEE Recent Advances in Geoscience and Remote Sensing : Technologies, Standards and Applications (TENGARSS)*, Kochi, India, 2019, pp. 10-20. <https://doi.org/10.1109/TENGARSS.2019.8976467>
- Sahu, D. K., & Parsai, M. (2012). Different image fusion techniques—a critical review. *International Journal of Modern Engineering Research (IJMER)*, 2(2), 429-430.
- Shahi, K., Shafri, H. Z., Taherzadeh, E., Mansor, S., & Muniandy, R. (2010). A novel spectral index to automatically extract road networks from WorldView-2 satellite imagery. *The Egyptian Journal of Remote Sensing and Space Science*, 14(1), 27-33. <https://doi.org/10.1016/j.ejrss.2014.12.003>
- Shao, Z., Zhou, Z., Huang, X., & Zhang, Y. (2011). MRENet: Simultaneous extraction of road surface and road centerline in complex urban scenes from very high-resolution images. *Remote sensing*, 13(2), 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-2493477/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, 900-909. <https://doi.org/10.5194/isprsarchives-XI-4-900-2014>
- Singh, S., Mittal, N., & Singh, H. (2011). Review of various image fusion algorithms and image fusion performance metric. *Archives of Computational Methods in Engineering*, 28, 3650-3659. <https://doi.org/10.1007/s11831-020-09018-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*, 104-20. <https://doi.org/10.1016/j.dsp.2023.10420>
- 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), 113. <https://doi.org/10.18280/isi.28.012>
- Spoto, F., Sy, O., Laberinti, P., Martimort, P., Fernandez, V., Colin, O., Hoersch, B., & Meygret, A. (2012). Overview of sentinel-2. 2012 *IEEE International Geoscience and Remote Sensing Symposium*, Munich, Germany, 2012, pp. 1107-1110. <https://doi.org/10.1109/IGARSS.2012.6351190>
- Sun, J., Xu, Z., & Shum, H.-Y. (2008). Image super-resolution using gradient profile prior. *2008 IEEE Conference on Computer Vision and Pattern Recognition*, Anchorage, AK, 2008, pp. 1-8. <https://doi.org/10.1109/CVPR.2008.4587609>
- 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, 100-116. <https://doi.org/10.1016/j.isprsjprs.2019.10.001>
- 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, 2017, pp. 1110-1121. <https://doi.org/10.1109/CVPRW.2017.149>
- 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, 2013, pp. 1920-1927. <https://doi.org/10.1109/ICCV.2013.241>
- Versaci, M., & Morabito, F. C. (2011). Image Edge Detection: A New Approach Based on Fuzzy Entropy and Fuzzy Divergence. *International Journal of Fuzzy Systems*, 23(4), 918-936. <https://doi.org/10.1007/s12485-020-10300-0>
- 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 edition)*, 3(3), 271-282. <https://doi.org/10.1016/j.jtte.2016.05.000>
- 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 - 2019 IEEE International Geoscience and Remote Sensing Symposium*, Yokohama, Japan, 2019, pp. 3923-3926. <https://doi.org/10.1109/IGARSS.2019.8898060>
- 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(1), 1083. <https://doi.org/10.3390/rs16011083>
- 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), 3960-3981. <https://doi.org/10.1109/TGRS.2017.2680940>
- Xie, J., Xu, L., & Chen, E. (2012). Image denoising and inpainting with deep neural networks. *Advances in neural information processing systems*, 25.
- Yadav, M. (2021). A multi-constraint combined method for road extraction from airborne laser scanning data. *Measurement*, 166, 108077. <https://doi.org/10.1016/j.measurement.2021.108077>

- Yang, J., Wright, J., Huang, T. S., & Ma, Y. (2010). Image super-resolution via sparse representation. *IEEE Transactions on Image Processing*, 19(11), 2861-2872. <https://doi.org/10.1109/TIP.2010.2006720>
- Yanuari, B., & Utami, E. (2022). Convolutional Neural Network for Road Network Detections Using Sentinel 2A. *International Journal of Innovative Science and Research Technology*, 8(3-4), 463-468. <https://doi.org/10.2481/zenodo.5487943>
- Ye, W., Lin, B., Lao, J., Liu, Y., & Lin, Z. (2021). 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*, 14(12), 4490. <https://doi.org/10.1109/JSTARS.2021.3117057>
- Zabalza, M., & Bernardini, A. (2022). Super-Resolution of Sentinel-2 Images Using a Spectral Attention Mechanism. *Remote sensing*, 14(12), 4490. <https://doi.org/10.3390/rs14122490>
- Zeyde, R., Elad, M., & Protter, M. (2012). On single image scale-up using sparse-representations. Curves and Surfaces: 9th International Conference, Avignon, France, June 24-26, 2012, Revised Selected Papers 9. https://doi.org/10.1007/978-3-642-27413-8_47
- Zhang, C., Wei, S., Ji, S., & Lu, M. (2019). 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), 189. <https://doi.org/10.3390/ijgi8040189>
- Zhang, J. (2010). Multi-source remote sensing data fusion: status and trends. *International Journal of Image and Data Fusion*, 1(1), 2-24. <https://doi.org/10.1080/19449983.2010.506130>
- 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), 4874-4886. <https://doi.org/10.1109/TIP.2012.2208977>
- Zhang, K., Sumbul, G., & Demir, B. (2020). An approach to super-resolution of Sentinel-2 images based on generative adversarial networks. 2020 Mediterranean and Middle-East Geoscience and Remote Sensing Symposium (M2GARSS), Tunis, Tunisia, 2020, pp. 79-82. <https://doi.org/10.1109/M2GARSS49133.2020.910160>
- Zhang, Q., Kong, Q., Zhang, C., You, S., Wei, H., Sun, R., & Li, L. (2019). 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), 572-582. <https://doi.org/10.1080/22797205.2019.1694447>
- 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), 543. <https://doi.org/10.3390/app11020543>
- Zhang, W., Tan, Z., Lv, Q., Li, J., Zhu, B., & Liu, Y. (2021). An Efficient Hybrid CNN-Transformer Approach for Remote Sensing Super-Resolution. *Remote sensing*, 16(5), 880. <https://doi.org/10.3390/rs16050880>
- 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 B), 1101-1109.
- Zhang, Y., Dong, L., Yang, H., Qing, L., He, X., & Chen, H. (2021). Weakly-supervised contrastive learning-based implicit degradation modeling for blind image super-resolution. *Knowledge-Based Systems*, 249, 108984. <https://doi.org/10.1016/j.knsys.2022.108984>
- Zhang, Y., Zhang, L., Wang, Y., & Xu, W. (2021). AGF-Net: adaptive global feature fusion network for road extraction from remote-sensing images. *Complex & Intelligent Systems*, 1-18. <https://doi.org/10.1007/s40306-021-01364-9>
- Zhang, Z., Liu, Q., & Wang, Y. (2018). Road extraction by deep residual u-net. *IEEE Geoscience and Remote Sensing Letters*, 15(5), 744-748.
- Zhao, N., Wei, Q., Basarab, A., Dobigeon, N., Kouame, D., & Tourneret, J.-Y. (2019). Fast single image super-resolution. *arXiv preprint arXiv:1510.00143*. <https://doi.org/10.1109/TIP.2016.2567070>
- 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, 302-310. <https://doi.org/10.1016/j.isprsjprs.2021.03.016>
- 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(2), 274. <https://doi.org/10.3390/rs10020274>
- Zhu, X., Huang, X., Cao, W., Yang, X., Zhou, Y., & Wang, S. (2021). Road Extraction from Remote Sensing Imagery with Spatial Attention Based on Swin Transformer. *Remote sensing*, 16(7), 1183. <https://doi.org/10.3390/rs16071183>
- Zou, Q., Ni, L., Zhang, T., & Wang, Q. (2019). Deep learning based feature selection for remote sensing scene classification. *IEEE Geoscience and Remote Sensing Letters*, 12(1), 2321-2325. <https://doi.org/10.1109/LGRS.2015.2450299>