



## ORIGINAL RESEARCH PAPER

## Detection of Secondary Roads in Soil and Vegetation areas Based on Deep Learning Model

A. Gholamian, F. Tabib Mahmoudi\*

Department of Surveying and Geomatics Engineering, Faculty of Civil Engineering, Shahid Rajaei Teacher Training University, Tehran, Iran

## ABSTRACT

Received: 25 August 2024  
 Reviewed: 10 October 2024  
 Revised: 10 November 2024  
 Accepted: 30 November 2024

## KEYWORDS:

Road detection  
 Deep Learning  
 Semantic Segmentation  
 Remote Sensing

\* Corresponding author

✉ [fmahmoudi@sru.ac.ir](mailto:fmahmoudi@sru.ac.ir)

☎ (+9821) 22970021

**Background and Objectives:** Roads are known as vital and essential elements in the development of cities, because they play a very important role in communication and transportation and represent the extent of urban development and growth. In order to increase accuracy and efficiency in road detection and classification, researchers have designed and used automatic methods based on deep learning algorithms. These approaches, due to their superior capabilities in recognizing patterns and complex features of images, have effectively replaced traditional methods and have significantly improved the accuracy and speed of road detection.

**Methods:** In this paper, an improved UNet3+ encoder-decoder model has been used for road detection from remote sensing images. In this proposed model, pyramid pooling and spatial and channel attention modules are used to improve road detection results. The spatial attention module is used in the proposed network architecture to improve the network's focus on important locations in feature maps. The channel attention module also allows the network to more focus on important information and perform better at tasks such as feature detection and classification. The pyramid pooling module is designed to receive multi-scale information. This module helps the network to understand different spatial scales by applying averaging at different levels and then resizing the averaged features to the size of the original feature map.

**Findings:** The evaluation of the capabilities of the proposed network in detecting secondary roads in areas with less residential density and with soil and vegetation cover shows the superiority of this network over the original version of UNet3+. The improved network proposed in this paper was able to detect roads more accurately. This shows the power of the network in detecting roads in conditions where there is less environmental interference. Quantitative results obtained from this network show the fact that the use of spatial and channel attention modules and pyramid pooling module has been able to increase the accuracy, recall, F1 score and IOU measures by 6, 15.6, 8.3 and 17.4, respectively, compared to the original version of the UNet3+ network.

**Conclusion:** The challenges raised in the automatic roads detection from remote sensing images, including the effect of shadows and obstruction of the road with buildings and vegetation cover, and the similarity of the secondary roads with the soil background can lead to a decrease in the accuracy of recognizing roads from remote sensing images. The use of improved UNet3+ encoder-decoder architecture capabilities in this research was able to reduce some of these challenges and increase the accuracy of the detection results of secondary roads in areas with soil and vegetation.



NUMBER OF REFERENCES

24



NUMBER OF FIGURES

5



NUMBER OF TABLES

1

## مقاله پژوهشی

## تشخیص جاده‌های فرعی در زمین‌های خاکی و مناطق پوشش گیاهی مبتنی بر روش یادگیری عمیق

امیرحسین غلامیان، فاطمه طبیب محمودی\*

گروه مهندسی نقشه برداری، دانشکده عمران، دانشگاه تربیت دبیر شهید رجائی، تهران، ایران

## چکیده

**پیشینه و اهداف:** جاده‌ها به عنوان عناصر حیاتی و اساسی در توسعه و پیشرفت شهرها شناخته می‌شوند، زیرا نقش بسیار مهمی در ارتباطات و حمل و نقل دارند و نمایانگر میزان توسعه و رشد شهری می‌باشند. به منظور افزایش دقت و کارایی در تشخیص و طبقه‌بندی جاده‌ها، محققان به طراحی و استفاده از روش‌های خودکار مبتنی بر پردازش تصویر و یادگیری عمیق پرداخته‌اند. این رویکردها، به دلیل قابلیت‌های برترشان در تشخیص الگوها و ویژگی‌های پیچیده تصاویر، به طور موثری جایگزین روش‌های سنتی شده‌اند و بهبود چشمگیری در دقت و سرعت تشخیص جاده‌ها ایجاد کرده‌اند.

**روش‌ها:** در این تحقیق از یک مدل بهبودیافته رمزگذار-رمزگشای UNet3+ برای تشخیص جاده از تصاویر سنجنش از دور استفاده شده است. در این مدل پیشنهادی از ماژول‌های تجمیع هرمی، توجه مکانی و توجه کانال برای بهبود نتایج تشخیصی استفاده شده است. ماژول توجه مکانی در معماری شبکه پیشنهادی برای بهبود تمرکز شبکه بر روی مکان‌های مهم در نقشه‌های ویژگی استفاده می‌شود. ماژول توجه کانال نیز به شبکه اجازه می‌دهد تا روی اطلاعات مهم تمرکز بیشتری داشته باشد و در کارهایی مانند تشخیص ویژگی و طبقه بندی بهتر عمل کند. ماژول تجمیع هرمی برای دریافت اطلاعات چند مقیاسی طراحی شده است. این ماژول به شبکه کمک می‌کند تا مقیاس‌های مکانی مختلف را با اعمال میانگین‌گیری در سطوح مختلف و سپس تغییر اندازه ویژگی‌های متوسط به اندازه نقشه ویژگی اصلی، درک کند.

**یافته‌ها:** ارزیابی قابلیت اجرایی شبکه پیشنهادی در تشخیص جاده‌های فرعی در مناطقی که تراکم مسکونی کمتری دارند و دارای پوشش خاکی و گیاهی هستند، نشان دهنده برتری این شبکه نسبت به نسخه اصلی UNet3+ است. شبکه بهبود یافته پیشنهادی در این مقاله توانست جاده‌ها را با دقت بیشتری تشخیص دهد. این امر نشان دهنده قدرت شبکه در تشخیص جاده‌ها در شرایطی است که تداخلات محیطی کمتری وجود دارد. نتایج کمی به دست آمده از این شبکه نمایانگر این واقعیت است که استفاده از ماژول‌های توجه مکانی و کانال و ماژول تجمیع هرمی توانسته است معیارهای دقت، بازخوانی، امتیاز F1 و IOU را به ترتیب ۶، ۱۵، ۶، ۸، ۳ و ۱۷، ۴ نسبت به نسخه اصلی شبکه UNet3+ افزایش دهد.

**نتیجه‌گیری:** چالش‌های مطرح در تشخیص خودکار جاده‌ها از تصاویر سنجنش از دور اعم از تاثیر سایه و انسداد جاده با ساختمان‌ها و پوشش گیاهی و شباهت جاده با پس‌زمینه می‌تواند منجر به کاهش دقت تشخیص جاده‌ها از تصاویر سنجنش از دور گردد. استفاده از قابلیت‌های معماری رمزگذار-رمزگشای بهبودیافته UNet3+ در این تحقیق توانست بخشی از این چالش‌ها را کاهش داده و دقت نتایج تشخیص جاده‌های فرعی در مناطق دارای زمینه خاکی و پوشش گیاهی را افزایش دهد.

تاریخ دریافت: ۰۴ شهریور ۱۴۰۳  
تاریخ داری: ۱۹ مهر ۱۴۰۳  
تاریخ اصلاح: ۲۰ آبان ۱۴۰۳  
تاریخ پذیرش: ۱۰ آذر ۱۴۰۳

## واژگان کلیدی:

تشخیص جاده  
یادگیری عمیق  
قطعه بندی معنایی  
سنجنش از دور

\* نویسنده مسئول

fmahmoudi@sru.ac.ir

۰۲۱-۲۲۹۷۰۰۲۱

## مقدمه

بدلیل زمان بر بودن و هزینه بالای انجام عملیات میدانی، برای به روز کردن اطلاعات و نقشه شبکه‌های جاده‌ها از داده‌های سنجنش از دور استفاده می‌شود که هم از نظر زمانی و هم هزینه ای بصره تر است. جاده‌ها از مهم‌ترین عناصر شهری هستند و شناسایی آنها از داده‌های سنجنش از دور با استفاده از روش‌های سنتی مبتنی بر تعیین دستی ویژگی‌ها و یا استخراج خودکار ویژگی امکان‌پذیر است. از روش‌های سنتی استخراج جاده‌ها می‌توان به تحلیل بافت، تشخیص لبه‌ها و رویکردهای مبتنی بر شکل اشاره کرد. این روش‌ها می‌توانند به طور جداگانه یا ترکیبی استفاده شوند تا اطلاعات دقیق‌تری از جاده‌ها در تصاویر ماهواره‌ای استخراج شود [۹ و ۱۰].

امروزه جاده‌ها نه تنها به عنوان شبکه‌های اصلی ارتباطی در شهرها عمل می‌کنند، بلکه نقش حیاتی در ساختار کلی شهری و عملکرد آن دارند. این فضاها سطح وسیعی از شهر را به خود اختصاص داده و به عنوان عناصر اصلی در شکل‌دهی به شهر و نظم‌دهی به جریان ترافیک و حرکت مردم ایفای نقش می‌کنند [۱ و ۲]. به روز رسانی نقشه‌های جاده‌ای موجود به جهت رشد و توسعه شهری، برنامه ریزی برای کنترل ترافیک، تصمیم‌گیری در شرایط بحران و... الزامی است [۳-۷]. در کاربردهایی اعم از امداد رسانی در زمان‌های بحرانی و وقوع حوادث طبیعی، موجود بودن جزییات و اطلاعات به هنگام از جاده‌ها امکان ارزیابی و مسیریابی را فراهم می‌نماید [۸].

بسیاری از محققین قرار گرفته است [۲۰]. در زمینه تحقیقاتی تشخیص جاده، Lu و همکاران از یک مدل پیشنهادی برای استخراج جاده‌ها با استفاده از تصاویر ماهواره‌ای با قدرت تفکیک خیلی زیاد استفاده نمودند. این مدل با استفاده از شبکه Global-Aware deep Network (GAN) و اضافه نمودن ماژول‌های توجه مکانی و کانال توانست در تصاویری که انسداد جاده‌ها توسط سایه درختان، ساختمان‌ها و عوارض دیگر اتفاق افتاده بود عملکرد خوبی را داشته باشد. این مدل پیشنهادی با استفاده از مجموعه داده DeepGlobe ارزیابی شد [۲۱]. Fan و همکاران از DlinkNet تغییر یافته برای استخراج جاده از مجموعه داده ماساچوست استفاده کردند [۲۲]. Yerram و همکاران از شبکه Unet++ استفاده کردند که در آن از بلوک‌های ResNeXt به عنوان رمزگذار و رمزگشا استفاده می‌شود. آنها برای ارزیابی شبکه پیشنهادی از مجموعه داده ماساچوست در استخراج جاده‌ها استفاده کردند [۲۳].

استفاده از یادگیری عمیق برای استخراج جاده در سنجش از دور مزایای قابل توجهی نسبت به روش‌های سنتی دارد. این موارد شامل دقت بالاتر به دلیل توانایی یادگیری الگوهای پیچیده از داده‌ها، استحکام در مقابل تغییرات ظاهری جاده بدون تنظیم دستی پارامترها، و یادگیری خودکار ویژگی است که نیاز به مهندسی ویژگی‌های دستی را از بین می‌برد. یادگیری عمیق امکان یادگیری سراسری را فراهم می‌کند، فرآیند استخراج را ساده می‌کند و امکان مقیاس‌پذیری را برای مدیریت کارآمد مجموعه داده‌های بزرگ فراهم می‌نماید. علاوه بر این، یادگیری عمیق اطلاعات معنایی در مورد سازه‌های جاده را ضبط می‌کند و قابلیت استفاده از داده‌های استخراج شده را برای کاربردهای مختلف افزایش می‌دهد. به طور کلی، یادگیری عمیق یک رویکرد قدرتمند و امیدوارکننده برای استخراج جاده از تصاویر سنجش از دور است [۲۴]. روش پیشنهادی در این تحقیق مبتنی بر استفاده از شبکه یادگیری عمیق رمزگذار-رمزگشای UNet3+ بهبود یافته است که در آن از قابلیت ماژول‌های تجمیع هرمی، توجه مکانی و توجه کانال استفاده شده است. مهمترین نوآوری‌های این تحقیق در زمینه بهبود نتایج تشخیص جاده‌های فرعی عبارتند از:

- ارزیابی قابلیت ماژول‌های توجه مکانی و کانال به ترتیب برای شناسایی مناطق مهم و کاهش مناطق نامربوط در نقشه‌های ویژگی و تأکید بر کانال‌های آموزنده و در عین حال سرکوب کانال‌های کمتر مرتبط، به منظور تمرکز بر وابستگی‌های بین کانالی می‌باشد.
- ارزیابی قابلیت ماژول تجمیع هرمی در قطعه‌بندی معنایی و استخراج جاده‌ها در مقیاس‌های مختلف از تصویر. این ماژول با ترکیب ویژگی‌ها از چندین مقیاس مختلف، به شبکه امکان می‌دهد تا به اطلاعات زمینه محلی و جهانی به طور همزمان توجه کند.

## روش تحقیق

داده مورد استفاده

در این تحقیق برای ارزیابی نتایج شبکه پیشنهادی از مجموعه داده‌های جاده Deepglobe استفاده شده است. مجموعه داده تشخیص جاده

Courtrai و همکاران روشی را پیشنهاد داده‌اند که در آن از دو فیلتر مورفولوژیکی استفاده می‌شود: opening برای حذف نویزهای کوچک و closing برای پر کردن شکاف‌های کوچک در مرزهای شیء و حذف حفره‌های کوچک داخل شیء [۱۱]. در تحقیق دیگری ادغام فیلترهای جهت‌دار برای تشخیص لبه‌های جاده و فیلترهای طولی مورفولوژیک برای اطمینان از این که تنها جاده‌های واقعی و بلند در تصویر باقی بمانند و سایر اشیاء کوچک و نویزها حذف شوند مورد استفاده قرار گرفته است [۱۲].


روش پیشنهادی Grinias و همکاران برای استخراج جاده از تصاویر سنجش از دور با وضوح بالا، یک روش بدون نظارت است که از ویژگی‌های شکل استفاده کرده و این ویژگی‌ها با مدل میدان تصادفی مارکوف و روش جنگل تصادفی ترکیب می‌شوند تا احتمالات جاده را خوشه‌بندی کنند [۱۳]. Liu و همکاران از تبدیل هاف تعمیم یافته برای شناسایی و استخراج الگوهای منحنی استفاده کردند [۱۴]. از روش‌های سنتی دیگر در تشخیص جاده‌ها، می‌توان به فضای مقیاس و مدل‌های Snakes اشاره کرد که فضای مقیاس تصاویر را به مقیاس‌های مختلف تجزیه می‌کند تا ویژگی‌های مهم مانند لبه‌ها و خطوط را برجسته کند. [۱۵]

روش‌های سنتی برای تشخیص جاده در تصاویر سنجش از دور از معایب متعددی رنج می‌برند. اولاً، این روش‌ها تنها تا حد محدودی می‌توانند با تغییرات محیطی سازگار شوند. این تغییرات می‌تواند شامل تغییرات در نوری، شرایط آب و هوایی یا انواع مواد تشکیل دهنده سطح جاده باشد. این عدم توانایی در سازگاری با تغییرات، در نهایت می‌تواند منجر به کاهش دقت در تشخیص و تجزیه و تحلیل جاده‌ها شود. ثانیاً، این روش‌ها در تشخیص دقیق جاده‌ها در محیط‌های پیچیده با پوشش گیاهی متراکم، انسداد و به هم ریختگی شهری با مشکلاتی مواجه هستند که می‌تواند نویز و ابهام را در فرآیند تشخیص ایجاد نماید. علاوه بر این، بسیاری از روش‌های سنتی نیاز به تنظیم دستی پارامتر دارند که زمان‌بر و ذهنی است و مانع از توانایی دستیابی به نتایج ثابت در سناریوهای مختلف می‌شود. در نهایت، این روش‌ها اغلب بر ویژگی‌ها یا قوانین دست‌ساز تکیه می‌کنند که ممکن است به خوبی به مجموعه داده‌های متنوع تعمیم داده نشوند و سازگاری با محیط‌های جدید یا انواع جاده‌ای که در داده‌های آموزشی نشان داده نشده‌اند، چالش برانگیز است [۱۶]. با ایجاد فرآیند خودکار برای استخراج جاده‌ها، می‌توان علاوه بر کاهش هزینه و اشتباهات نیروی انسانی، دقت و پیوستگی نتایج را نیز افزایش داد.

یکی از روش‌های موثر و جدیدی که اخیراً در استخراج اطلاعات از تصاویر ماهواره‌ای به صورت خودکار استفاده می‌شود، بهره‌گیری از روش‌های یادگیری عمیق است [۱۷ و ۱۸]. استفاده از روش‌های یادگیری عمیق با استفاده از تصاویر با قدرت تفکیک مکانی زیاد و خیلی زیاد در تشخیص جاده‌ها دارای پتانسیل بالایی می‌باشد [۱۹] و به همین علت در سال‌های اخیر در جامعه سنجش از دور، این موضوع مورد توجه

در عملکرد رمزگذار شبکه، ابتدا داده‌های ورودی به اولین بلوک کانولوشنی وارد می‌شوند که شامل دو لایه کانولوشن و توجه مکانی است. پس از پردازش در اولین بلوک، داده‌ها به بلوک دوم منتقل می‌شوند که علاوه بر لایه‌های کانولوشنی و توجه مکانی، شامل لایه تجمیع هرمی نیز می‌باشد. ماژول تجمیع هرمی ویژگی‌های چندمقیاسی را استخراج می‌کند (شکل ۲).

این فرایند برای بلوک‌های سوم، چهارم و پنجم نیز تکرار می‌شود، با این تفاوت که تعداد فیلترها در هر بلوک افزایش می‌یابد تا ویژگی‌های پیچیده‌تری استخراج شوند.



شکل ۲: ساختار ماژول تجمیع هرمی  
Fig. 2: Structure of the pyramid pooling module

بخش رمزگشا در شبکه پیشنهادی UNet3+ بهبودیافته، به منظور بازسازی تصویر نهایی پس از استخراج ویژگی‌ها در بخش رمزگذار طراحی شده است. این بخش شامل چهار بلوک متوالی است که هر کدام به تدریج ابعاد تصویر را افزایش می‌دهند و ویژگی‌های مکانی را بهبود می‌بخشند.

در ابتدا، داده‌های پردازش شده از بخش رمزگذار به اولین بلوک رمزگشا وارد می‌شوند. این بلوک شامل لایه‌های افزایش ابعاد است که ابعاد ویژگی‌ها را به تدریج به اندازه‌های بزرگتر بازمی‌گرداند. سپس، ویژگی‌های استخراج شده از بخش رمزگذار با داده‌های پردازش شده در این بلوک ترکیب می‌شوند تا اطلاعات مکانی دقیق‌تر و جزئی‌تر حفظ شود.

در بلوک دوم، ابعاد ویژگی‌ها بیشتر افزایش می‌یابد و عملیات افزایش ابعاد به ابعاد بزرگتر ادامه می‌یابد. در این مرحله، ویژگی‌های استخراج شده از سطح دوم رمزگذار با ویژگی‌های بازسازی شده ترکیب می‌شوند تا اطلاعات مهم مکانی در این سطح حفظ شود. این فرایند برای بلوک‌های سوم و چهارم نیز تکرار می‌شود. در هر بلوک، لایه‌های کانولوشنی و توجه مکانی برای پردازش و تقویت ویژگی‌ها به کار می‌روند. عملیات افزایش ابعاد و ادغام ویژگی‌ها به تدریج ابعاد تصویر را به اندازه اصلی خود بازمی‌گرداند و جزئیات مکانی دقیق را بازسازی می‌کند.

در پایان، پس از پردازش داده‌ها در چهار بلوک متوالی، خروجی نهایی شامل یک بلوک توجه کانال است که ویژگی‌های مهم در


DeepGlobe یکی از منابع کلیدی در حوزه تشخیص و استخراج جاده‌ها از تصاویر ماهواره‌ای است که در سال ۲۰۱۸ ارائه شد. این مجموعه داده شامل تصاویر ماهواره‌ای با وضوح بالا از ماهواره WorldView-3 است. تصاویر این مجموعه داده با وضوح ۵۰ سانتی‌متر در هر پیکسل ارائه می‌شوند که به تحلیل دقیق و شناسایی جزئیات جاده‌ها کمک می‌کند. این مجموعه داده شامل بیش از ۸,۰۰۰ کیلومتر جاده برچسب‌گذاری شده است و تصاویر از مناطق مختلف جغرافیایی و فرهنگی، از جمله مناطق شهری، نیمه‌شهری، روستایی و کشاورزی در کشورهای مختلف جهان نظیر ایالات متحده (شیکاگو و لس آنجلس)، آلمان (برلین و مونیخ) و ژاپن (توکیو و اوزاکا) جمع‌آوری شده است.

تصاویر این مجموعه داده به صورت قطعه‌های  $1024 \times 1024$  پیکسل تقسیم شده‌اند که فرآیند آموزش مدل‌های یادگیری عمیق را ساده‌تر و موثرتر می‌کند. این تقسیم‌بندی کمک می‌کند تا مدل‌ها به صورت متمرکزتر بر روی بخش‌های مختلف تصاویر تمرکز کنند و دقت تشخیص را افزایش دهند.

فرآیند ایجاد ماسک‌های جاده‌ای در این مجموعه داده با استفاده از برچسب‌گذاری دستی دقیق و با کمک نرم‌افزارهای GIS و پردازش تصویر انجام شده است. این فرآیند شامل شناسایی و ترسیم دقیق خطوط جاده‌ها بر روی تصاویر ماهواره‌ای است که به دستیابی به دقت بالا در تشخیص و استخراج جاده‌ها کمک می‌کند. کارشناسان با تجربه با استفاده از این ابزارها، داده‌های آموزشی و اعتبارسنجی با کیفیت بالا را برای مدل‌های یادگیری عمیق فراهم کرده‌اند. در این تحقیق، از مجموعه داده‌های جاده فرعی در مناطق خاکی و دارای پوشش گیاهی استفاده شده است.

#### روش شناسی

روش پیشنهادی تشخیص جاده در این تحقیق مبتنی بر شبکه رمزگذار-رمزگشای بهبودیافته UNet3+ مشتمل بر ماژول‌های تجمیع هرمی، توجه مکانی و توجه کانال می‌باشد. رمزگذار شبکه UNet3+ پیشنهادی شامل پنج بلوک متوالی است که هر کدام وظیفه استخراج ویژگی‌های تصویر ورودی را بر عهده دارند. هر بلوک شامل چندین لایه کانولوشنی  $3 \times 3$ ، نرمال‌سازی دسته‌ای، و فعال‌سازی ReLU است. علاوه بر این، در هر بلوک از ماژول توجه مکانی برای تقویت ویژگی‌های مهم مکانی استفاده می‌شود (شکل ۱).



شکل ۱: ساختار ماژول توجه مکانی  
Fig. 1: Structure of the spatial attention module

انجام گرفته است. مقادیر پیکسل‌ها قبل از آموزش از محدوده [۰، ۲۵۵] به محدوده [۰، ۱] نرمال شده‌اند. مجموعه داده که از ۶۲۲۶ تصویر تشکیل شده است را بطور تصادفی به سه قسمت آموزش، اعتبارسنجی و تست تقسیم کردیم. مقدار ۸۵٪ برای آموزش، ۱۰٪ برای اعتبارسنجی و ۵٪ برای تست شبکه در نظر گرفته شد.

بهینه‌سازی مدل با استفاده از بهینه‌ساز Adam با نرخ یادگیری اولیه ۰.۰۰۰۱ صورت گرفته است. بهینه‌ساز الگوریتمی است که از طریق به‌روزرسانی وزن‌های مدل باعث کاهش مقدار خروجی تابع ضرر می‌شود. برای بهبود عملکرد مدل و جلوگیری از بیش‌برازش، از EarlyStopping و ReduceLRonPlateau استفاده شده است.

ReduceLRonPlateau به‌طور خودکار نرخ یادگیری را زمانی که معیار عملکرد در مجموعه اعتبارسنجی (مانند خطا یا ضرر) برای چند دوره بهبود نمی‌یابد، کاهش می‌دهد. این فرآیند می‌تواند به شبکه کمک کند تا از ایستایی محلی در فضای جستجو خارج شود و دقت و همگرایی مدل را افزایش دهد.


همچنین، از EarlyStopping برای متوقف کردن آموزش در صورت عدم بهبود اعتبارسنجی پس از ۱۰ دوره استفاده شده است. EarlyStopping یک روش برای جلوگیری از بیش‌برازش مدل به داده‌های آموزشی است و به‌طور خودکار انتخاب بهینه‌ترین مدل را براساس عملکرد آن روی داده‌های اعتبارسنجی تضمین می‌کند. در نهایت، مدل در ۶۰ اپک آموزش داده می‌شود.

#### نتایج اجرای شبکه

در این بخش به منظور ارزیابی قابلیت مدل پیشنهادی بهبودیافته در UNet3+ در تشخیص جاده‌های فرعی در مناطق دارای زمینه خاکی و پوشش گیاهی، نتایج حاصل از اجرای این مدل با نسخه اصلی UNet3+ مقایسه شده است. در این مناطق، به دلیل شباهت زیاد جاده‌های فرعی با پس‌زمینه طبیعی خاک، تشخیص درست جاده‌ها چالش‌برانگیز است. جاده‌های فرعی معمولاً خاکی بوده و رنگ و بافت مشابهی با محیط اطراف دارند و نسخه اصلی شبکه UNet3+ ممکن است در شناسایی صحیح آن‌ها دچار خطا شود و عملکرد ضعیفی داشته باشد (شکل ۴). تداخل پوشش گیاهی با جاده‌ها باعث می‌شود که شبکه نتواند به‌درستی الگوهای جاده‌ای را شناسایی کند و منجر به بروز خطا در تشخیص محل تقاطع‌ها و دیگر ویژگی‌های جاده‌ای شود. همچنین سایه‌های ناشی از پوشش گیاهی یا سازه‌های بزرگ، می‌توانند جاده‌ها را از دید شبکه پنهان کنند و منجر به افزایش خطا در تشخیص شوند. در تقاطع‌ها وجود پوشش گیاهی متراکم می‌تواند باعث پنهان شدن جاده‌ها و تقاطع‌های آن‌ها شود. سایه‌های ایجاد شده توسط درختان و گیاهان دیگر نیز منجر به ایجاد نویز و اختلال در فرآیند تشخیص می‌شود.

افزودن ماژول‌های تجمیع هرمی، توجه مکانی و توجه کانال به معماری UNet3+ در مدل پیشنهادی این مقاله توانسته دقت تشخیص جاده‌ها را بهبود بخشد. این ماژول‌ها به شبکه کمک می‌کنند تا با تمرکز بر

سطح کانال را تقویت می‌کند. این بلوک با استفاده از لایه‌های GlobalAveragePooling2D و کانولوشن دوبعدی، ویژگی‌های مهم را برجسته کرده و به شبکه کمک می‌کند تا نقشه نهایی قطعه‌بندی را با دقت بیشتری تولید کند (شکل ۳).



شکل ۳: ساختار ماژول توجه کانال  
Fig. 3: Structure of the channel attention module

## نتایج تحقیق

### معیارهای ارزیابی

ارزیابی عملکرد مدل‌های یادگیری عمیق به کمک معیارهای مختلفی انجام می‌شود تا بتوان دقت، کارایی، و قابلیت تعمیم مدل‌ها را در وظایف مختلف بررسی کرد. در این تحقیق از معیارهای بازخوانی، امتیاز F1، دقت و IOU استفاده شده است.

○ معیار بازخوانی نسبت پیکسل‌هایی که به درستی به عنوان جاده شناسایی شده‌اند را به تعداد کل پیکسل‌های واقعی جاده در تصویر بدست می‌آورد. این معیار نشان می‌دهد که مدل تا چه حد توانسته است همه پیکسل‌های مربوط به جاده را شناسایی کند.

$$\text{Recall} = \frac{TP}{FN + TP} \quad (1)$$

○ معیار دقت نشان‌دهنده نسبت پیکسل‌هایی است که به‌درستی به عنوان جاده شناسایی شده‌اند به تمام پیکسل‌هایی که مدل به عنوان جاده دسته‌بندی کرده است.

$$\text{Precision} = \frac{TP}{FP + TP} \quad (2)$$

○ معیار امتیاز F1 میانگین هارمونیک بین دقت و بازخوانی است. این معیار با برقراری توازن بین دقت و بازخوانی، زمانی که یک معیار زیاد و دیگری کم باشد، کاهش می‌یابد.

$$F1 - \text{Score} = \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} * 2 \quad (3)$$

○ معیار IOU، یک معیار ارزیابی متداول برای اندازه‌گیری دقت یک مدل تشخیص شیء در بینایی کامپیوتری است. در حوزه قطعه‌بندی معنایی، IOU میزان همپوشانی بین ناحیه‌های قطعه‌بندی شده‌ی پیش‌بینی شده و واقعیت‌زمینی را اندازه‌گیری می‌کند.

$$IOU = \frac{TP}{FP + TP + FN} \quad (4)$$

### جزئیات اجرایی

در این مقاله، برای اجرای مدل‌ها از TensorFlow و Keras استفاده شده است. اجرای مدل‌ها در Google Colaboratory با استفاده از A4 GPU

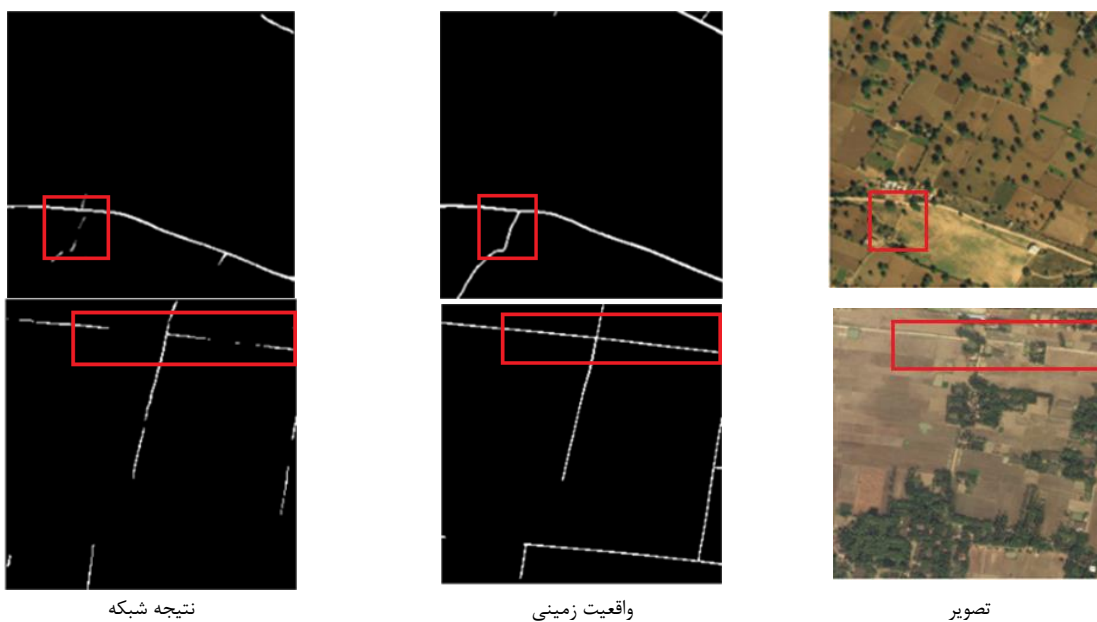
جاده‌ها به دلیل عرض کم و پیچ‌وخم‌های زیاد، ممکن است به راحتی با سایر عناصر شهری اشتباه گرفته شوند.

ویژگی‌های مختلف تصویر، دقت و وضوح بهتری در تشخیص جاده‌ها داشته باشد.

جدول ۱: ارزیابی کمی نتایج مدل پیشنهادی  
Table 1: Quantitative evaluation of the proposed model

network	Precision	Recall	F1 – score	IOU
UNet3+	78.7	69.4	76.3	56.1
UNet3+ with PPM, SAM, CAM	80.4	76.8	61.2	

در مناطق دارای پوشش گیاهی و زمینه خاکی، استفاده از ماژول‌های توجه مکانی و کانال و ماژول تجمیع هرمی می‌تواند به بهبود تشخیص جاده‌ها کمک کند. با این حال، همانطور که در شکل ۵ مشخص است، همچنان در برخی موارد شبکه نتوانسته خطوط جاده‌ای را به‌طور پیوسته تشخیص دهد و این منجر به منقطع شدن خطوط شناسایی شده گردیده است. جاده‌های باریک و پیچیده، که اغلب در مناطق غیرمترکم شهری یافت می‌شوند، می‌توانند باعث افزایش خطاهای تشخیصی شوند. این



شکل ۴: نتایج تشخیص جاده‌های فرعی در نسخه اصلی شبکه UNet3+  
Fig. 4: Secondary roads detection results in UNet3+ main model



شکل ۵: نتایج تشخیص جاده‌های فرعی در شبکه بهبودیافته پیشنهادی UNet3+  
Fig. 5: Secondary roads detection results in proposed modified UNet3+ model

پیچیده را به طور خودکار استخراج کنند و دقت بالاتری در تشخیص جاده‌ها فراهم آورند. به دلیل شباهت زیاد جاده‌های فرعی با پس‌زمینه طبیعی خاک، تشخیص درست این جاده‌ها چالش‌برانگیز است. همچنین، تداخل پوشش گیاهی و سایه‌های آن با جاده‌ها باعث می‌شود که شبکه نتواند به درستی الگوهای جاده‌ای را شناسایی کند و منجر به بروز خطا در تشخیص محل تقاطع‌ها و دیگر ویژگی‌های جاده‌ای شود.

در این تحقیق، برای حل مشکلات و چالش‌های ذکر شده، از معماری UNet3+ بهبودیافته استفاده شده است. این معماری با بهره‌گیری از ماژول‌های توجه مکانی و کانال و تجمیع هرمی طراحی شده تا بتواند تاثیرات چالش‌های فوق‌الذکر را کاهش دهد. یکی از ویژگی‌های برجسته این تحقیق، بهبود معماری UNet3+ از طریق افزودن ماژول‌های توجه مکانی و توجه کانال است. ماژول توجه مکانی به شبکه امکان می‌دهد تا با تمرکز بر نواحی مکانی خاص، به‌طور دقیق‌تری عوارض جاده‌ای را تشخیص دهد. این ماژول با تحلیل مکانی تصاویر و شناسایی بخش‌های مهم و مرتبط، به بهبود دقت و کارایی مدل کمک می‌کند. همچنین، ماژول توجه کانال امکان تمرکز بیشتر بر کانال‌های اطلاعاتی مهم را فراهم می‌سازد. این ماژول با تخصیص وزن‌های مختلف به کانال‌های اطلاعاتی، اطلاعات حیاتی را برای تشخیص بهتر و دقیق‌تر استخراج می‌کند.

افزودن ماژول تجمیع هرمی به معماری شبکه نیز یکی از نوآوری‌های دیگر این تحقیق است. این ماژول با ترکیب اطلاعات در سطوح مختلف و پردازش هم‌زمان اطلاعات سطح بالا و سطح پایین، به بهبود قابلیت‌های تشخیصی شبکه کمک می‌کند. با استفاده از این ماژول، شبکه UNet3+ قادر است تا علاوه بر تشخیص الگوهای ساده، الگوهای پیچیده و پنهان در تصاویر سنجش از دور را نیز شناسایی کند. این ویژگی باعث افزایش دقت و کارایی مدل در شرایط مختلف محیطی و جغرافیایی می‌شود.

با توجه به اینکه داده‌های مورد استفاده در ارزیابی قابلیت اجرایی روش پیشنهادی در این تحقیق از یک منبع خاص و با شرایط جغرافیایی و نوری مشابه تهیه شده‌اند، برای رفع این محدودیت و بهبود عملکرد مدل و افزایش قابلیت تعمیم‌پذیری آن، می‌توان از داده‌های ماهواره‌ای و هوایی مختلف برداشت شده از مناطق مختلف جهان با شرایط آب و هوایی و جغرافیایی متفاوت استفاده کرد. به علاوه، در کنار استفاده از داده‌های متنوع، بهره‌گیری از تکنیک‌های پیشرفته داده‌افزایی نیز می‌تواند به بهبود عملکرد مدل کمک کند. داده‌افزایی با تولید نمونه‌های جدید از داده‌های موجود، به افزایش تنوع داده‌ها و مقاومت مدل در برابر تغییرات محیطی و جغرافیایی کمک می‌کند. استفاده از تکنیک‌هایی نظیر چرخش، تغییر مقیاس، تغییر روشنایی و کنتراست، و ترکیب این تکنیک‌ها با یکدیگر، می‌تواند به تولید داده‌های متنوع‌تر و مقاوم‌تر کمک کند و در نتیجه عملکرد مدل را بهبود بخشد.

همانطور که در جدول ۱ مشخص است، استفاده از ماژول‌های توجه مکانی و کانال و تجمیع هرمی در شبکه بهبودیافته UNet3+ توانسته معیارهای بازخوانی، دقت، امتیاز F1 و IoU را به ترتیب به میزان ۱/۲، ۱/۷، ۰/۵ و ۵/۱ نسبت به نسخه اصلی شبکه UNet3+ بهبود بخشد. این بهبودها نشان‌دهنده توانایی بالای شبکه در تشخیص جاده‌های فرعی، به‌ویژه در مناطق شهری غیرمتراکم، مناطق کشاورزی و دارای پوشش گیاهی است. در مناطقی که جاده‌ها با پس‌زمینه گیاهی و خاکی همپوشانی دارند، شبکه توانسته است بهبود قابل‌توجهی در پیوستگی جاده‌ها و کاهش خطاهای تشخیصی داشته باشد.

با این که این مقادیر نشان‌دهنده دقت بالای شبکه در شناسایی جاده‌های فرعی است، اما همچنان چالش‌هایی مانند تشابه طیفی و بافتی میان جاده‌ها و سایر عوارض زمین، به‌ویژه در مناطق شهری با پوشش گیاهی و ساختمان‌های مشابه، وجود دارد. این تشابه‌ها می‌تواند باعث کاهش دقت شبکه در تشخیص جاده‌ها و ایجاد اشتباهات در تعیین مرزهای دقیق جاده‌ها شوند.

با این حال، در مناطقی که پوشش گیاهی نامتراکم‌تر است، عملکرد شبکه بهبود یافته و شبکه توانسته است جاده‌ها را با دقت بیشتری شناسایی کند. این نشان‌دهنده قدرت شبکه در تشخیص جاده‌ها در شرایطی است که تداخل‌های محیطی کمتری وجود دارد. اما در مناطقی که پوشش گیاهی متراکم، ضعف‌هایی در شناخت تقاطع‌ها و جاده‌های پیچیده مشاهده می‌شود. این ضعف‌ها می‌تواند ناشی از پوشش گیاهی متراکم باشد که باعث مخفی شدن بخشی از جاده‌ها و کاهش وضوح تصویر در این مناطق می‌شود.

در مناطق کشاورزی که جاده‌ها اغلب در مجاورت زمین‌های زراعی قرار دارند، شبکه توانسته است با دقت بالاتری پیوستگی جاده‌ها را تشخیص دهد. این بهبودها به دلیل توانایی شبکه در استخراج و ترکیب اطلاعات از سطوح مختلف تصویر و تحلیل دقیق‌تر ویژگی‌های مکانی و کانال‌های اطلاعاتی است. ترکیب ماژول‌های توجه و تجمیع هرمی به ویژه در شرایطی که شبکه با داده‌های پیچیده و چالش‌های محیطی مختلف روبرو است، به بهبود عملکرد شبکه و افزایش دقت کلی آن کمک کرده است.

## نتیجه‌گیری

این مقاله با هدف تشخیص خودکار عارضه جاده با استفاده از تصاویر سنجش از دور با قدرت تفکیک مکانی زیاد و معماری‌های یادگیری عمیق طراحی شده است. روش‌های سنتی تشخیص جاده‌ها عمدتاً به تحلیل دستی تصاویر و استخراج ویژگی‌های سطح پایین مبتنی بر قوانین خاص متکی بوده‌اند، اما این روش‌ها در مواجهه با پیچیدگی‌های محیطی و تغییرات شرایط نوری و جغرافیایی کارایی خود را از دست می‌دهند. از سوی دیگر، روش‌های یادگیری عمیق قادرند با استفاده از شبکه‌های عصبی پیچیده و یادگیری از داده‌های گسترده، الگوهای

[8] Zhou N, M. Zhou M, Ge L. "Vector Road Map Updating from High-Resolution Remote-Sensing Images with the Guidance of Road Intersection Change Detection and Directed Road Tracing." *Remote Sensing*, 2023; 15(7): 1840. <https://doi.org/10.3390/rs15071840>

[9] Zhu X, Huang X, Cao W, Yang X, Zhou Y, Wang S. "Road Extraction from Remote Sensing Imagery with Spatial Attention Based on Swin Transformer." *Remote Sens.* 2024; 16, 1183. <https://doi.org/10.3390/rs16071183>

[10] Gao L, Shi W, Miao Z, Lv Z. "Method Based on Edge Constraint and Fast Marching for Road Centerline Extraction from Very High-Resolution Remote Sensing Images." *Remote Sens.* 2018; 10, 900. <https://doi.org/10.3390/rs10060900>

[11] Courtrai N, Bourgeois S, Balligand E. "Road network extraction in remote sensing images using morphological operators." *IEEE Transactions on Geoscience and Remote Sensing*, 2010; 48(11): 3980-3990. <https://doi.org/10.1109/TGRS.2010.2052587>

[12] Gamba P, Houshmand B. "Urban road extraction in high-resolution SAR images using contextual information." *IEEE Transactions on Geoscience and Remote Sensing*, 2002; 40(2): 274-282. <https://doi.org/10.1109/TGRS.2002.984692>

[13] Grinias I, Chrysoulakis N, Kontoes C. "Unsupervised road extraction from high resolution satellite images using hybrid methods." *Remote Sensing*, 2014; 6(7): 5806-5822. <https://doi.org/10.3390/rs6075806>

[14] Liu Y, Zhou M. "Road extraction from satellite images using generalized Hough transform." *International Journal of Remote Sensing*, 2017; 28(10): 2331-2341. <https://doi.org/10.1080/01431160701305715>

[15] Lindeberg T. "Scale-space theory: A basic tool for analyzing structures at different scales." *Journal of Applied Statistics*, 1994; 21(2): 225-270. <https://doi.org/10.1080/02664769400000012>

[16] Chen Z, Deng L, Luo Y, Li D, Junior J. M. "Road extraction in remote sensing data: A survey." *International Journal of Applied Earth Observation and Geoinformation*. 2022. <https://doi.org/10.1016/j.jag.2022.102833>

[17] Van Etten A, Lindenbaum D, Bacastow T. M. "Spacenet: A remote sensing dataset and challenge series." *arXiv preprint arXiv:1807.01232*. 2018. <https://doi.org/10.48550/arXiv.1807.01232>

[18] Omati M.E. Tabib Mahmoudi F. "Efficiency analysis of ITN loss function for deep semantic building segmentation." *Earth Sci Inform*, 2024; 17: 2011–2025. <https://doi.org/10.1007/s12145-024-01267-w>

[19] Xu Y, Xie Z, Feng Y, Chen Z. "Road extraction from high-resolution remote sensing imagery using deep learning." *Remote Sensing*, 2018; 10(9): 1461. <https://doi.org/10.3390/rs10091461>

## مشارکت نویسندگان

آقای امیرحسین غلامیان در جمع آوری داده‌ها، تجزیه و تحلیل نتایج مشارکت داشته‌اند. خانم فاطمه طبیب محمودی در ایده پردازی و طراحی پژوهش و نگارش و اصلاح مقاله مشارکت داشته‌اند.

## تشکر و قدردانی

این پژوهش با حمایت مالی دانشگاه تربیت دبیر شهید رجایی طبق ابلاغ گزنت شماره ۵۹۷۳/۶۳ مورخ ۱۴۰۳/۰۴/۱۴ انجام گردیده است.

## تعارض منافع

نویسندگان این مقاله اعلام می‌کنند که در رابطه با انتشار مقاله ارائه شده به طور کامل از اخلاق نشر، از جمله سرقت ادبی، سوء رفتار، جعل داده‌ها و یا ارسال و انتشار دوگانه، پرهیز نموده‌اند. همچنین نویسندگان منافعی تجاری در این راستا نداشته‌اند و در قبال ارائه اثر خود وجهی دریافت ننموده‌اند.

## منابع و مآخذ

[1] Shi Q, Liu, X, Li X. "Road detection from remote sensing images by generative adversarial networks." *IEEE Access*, 2017; 6, 25486-25494. <https://doi.org/10.1109/ACCESS.2018.2831034>

[2] Abdelkarim S.B, Ahmad A.M, Ferwati S, Naji K. "Urban Facility Management Improving Livability through Smart Public Spaces in Smart Sustainable Cities." *Sustainability* 2023; 15, 16257. <https://doi.org/10.3390/su152316257>

[3] Chen Z, Deng L, Luo Y, Li D, Junior J. M, Gonçalves W. N, ... & Li, D. "Road extraction in remote sensing data: A survey." *International Journal of Applied Earth Observation and Geoinformation*, 2022; 112, 102833. <https://doi.org/10.1016/j.jag.2022.102833>

[4] Wei Y, Ji S. "Scribble-based weakly supervised deep learning for road surface extraction from remote sensing images." *IEEE Transactions on Geoscience and Remote Sensing*, 2021; 60: 1-12. <https://doi.org/10.1109/TGRS.2021.3053740>

[5] Omati M.E, Tabib Mahmoudi F. "A Deep Learning Approach based on Specialized Convolutional Blocks in Urban Road Extraction." *JGit* 2024; 12(1): 83-94. <https://doi.org/10.1109/JGIT.2024.123456>

[6] Zhang J, Chen L, Wang C, Zhuo L, Tian Q, Liang X. "Road recognition from remote sensing imagery using incremental learning." *IEEE Transactions on Intelligent Transportation Systems*, 2017; 18(11): 2993-3005. <https://doi.org/10.1109/TITS.2017.2700987>

[7] Wei Z, Zhang Z. "Remote Sensing Image Road Extraction Network Based on MSPFE-Net." *Electronics*, 2023; 12(7): 1713. <https://doi.org/10.3390/electronics12071713>



موضوع استفاده از یادگیری عمیق در تشخیص جاده با موفقیت به اتمام رساند.

**Gholamian, A., Department of Geomatics Engineering, Faculty of Civil, Shahid Rajaee Teacher Training University, Tehran, Iran**

✉ [Amirhoseinghloamian@sru.ac.ir](mailto:Amirhoseinghloamian@sru.ac.ir)



**فاطمه طبیب محمودی** استادیار گروه مهندسی نقشه برداری دانشکده مهندسی عمران دانشگاه تربیت دبیر شهید رجایی می‌باشند. ایشان مدرک کارشناسی مهندسی نقشه برداری را در سال ۱۳۸۳ از دانشگاه صنعتی خواجه نصیرالدین طوسی و مدرک کارشناسی ارشد مهندسی نقشه برداری -

گرایش فتوگرامتری را در سال ۱۳۸۶ از دانشگاه تهران دریافت نمودند. در سال ۱۳۸۹ به عنوان دانشجوی دکتری فتوگرامتری در دانشگاه تهران مشغول به تحقیق شدند و در سال ۱۳۹۳ موفق به اخذ مدرک دکتری تخصصی خود گردیدند. ایشان ده ها مقاله علمی در مجلات و کنفرانس‌های علمی ملی و بین المللی ارائه نموده‌اند و همچنین در کمیته علمی و داوری چندین مجله و کنفرانس علمی نیز فعالیت داشته‌اند. شاخص ترین زمینه‌های تخصصی ایشان عبارتند از: تشخیص الگو، یادگیری ماشین، ادغام داده‌های سنجش از دور و الگوریتم‌های هوشمند.

**Tabib Mahmoudi, F., Assistant Professor at the Department of Geomatics Engineering, Faculty of Civil, Shahid Rajaee Teacher Training University, Tehran, Iran**

✉ [fmahmoudi@sru.ac.ir](mailto:fmahmoudi@sru.ac.ir)

[20] Gao L. Song W, Dai J, Chen Y. "Road extraction from high-resolution remote sensing imagery using refined deep residual convolutional neural network." *Remote Sensing*, 2019; 11(5): 552. <https://doi.org/10.3390/rs11050552>

[21] Lu X, Li S. "Global-aware deep network for road extraction from satellite images." *IEEE Geoscience and Remote Sensing Letters*, 2019; 16(7): 1100-1104. <https://doi.org/10.1109/LGRS.2019.2903593>

[22] Fan H, Long J. "DlinkNet: LinkNet with pretrained encoder and deep supervision for road extraction from aerial imagery." *IEEE Geoscience and Remote Sensing Letters*, 2019; 16(4): 618-622. <https://doi.org/10.1109/LGRS.2018.2882992>

[23] Yerram S, Xu X. "Unet++ with ResNeXt for road extraction from high-resolution satellite images." *Remote Sensing*, 2021; 13(1): 60. <https://doi.org/10.3390/rs13010060>

[24] Xu Y, Xie Z, Feng Y, Chen Z. "Road extraction from high-resolution remote sensing imagery using deep learning." *Remote Sensing*. 2018. <https://doi.org/10.3390/rs10091461>

## معرفی نویسندگان

### AUTHOR(S) BIOSKETCHES



**امیر حسین غلامیان** پس از اتمام تحصیلات دوره کارشناسی رشته مهندسی نقشه برداری، در سال ۱۴۰۰ در گرایش سنجش از دور در مقطع کارشناسی ارشد گروه مهندسی نقشه برداری دانشگاه تربیت دبیر شهید رجایی تحصیلات خود را آغاز نمود.

وی موفق شد که در سال ۱۴۰۳ پایان نامه کارشناسی ارشد خود را در

**Citation (Vancouver):** Gholamian A, Tabib Mahmoudi F. [Detection of Secondary Roads in Soil and Vegetation areas Based on Deep Learning Model]. *J. RS. GEOINF. RES.* 2024; 2(2): 335-343

<https://doi.org/10.22061/jrsgr.2024.11390.1085>



### COPYRIGHTS

© 2024 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) (<https://creativecommons.org/licenses/by-nc/4.0/>)