



## ORIGINAL RESEARCH PAPER

## Analysis and classification of land use using aerial imagery and deep learning based on U-Net architecture

M. Farhangi<sup>†</sup>, A. Milan<sup>\*</sup>, S. Sadeghian

Department of Surveying Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

## ABSTRACT

Received: 07 September 2024  
 Reviewed: 01 October 2024  
 Revised: 16 October 2024  
 Accepted: 18 November 2024

## KEYWORDS:

Land use classification  
 Aerial imagery  
 Deep learning  
 Convolutional neural network  
 U-Net

\* Corresponding author

✉ a\_milan@sbu.ac.ir

☎ (+9821) 73932456

**Background and Objectives:** Accurate land use classification is essential for effective natural resource management, urban planning, precision agriculture, and environmental monitoring. Such classification helps predict and prevent environmental issues. Methods like high-resolution satellite and aerial imagery, GIS, and deep learning techniques, including Convolutional Neural Networks (CNN) and the U-Net architecture, offer high precision in analyzing and classifying aerial images. The U-Net network, known for its unique structure, excels in defining land use boundaries. This study focuses on a region in Poland, using the U-Net model to enhance classification accuracy and efficiency through regularization techniques and the Adam optimizer.

**Methods:** This research used high-resolution aerial images and a deep learning model based on the U-Net architecture to achieve precise land use classification. The approach aimed at improving classification accuracy across four land use categories. High-resolution aerial images were collected, corrected geometrically and radiometrically to create orthophotos. These images were labeled and cropped to 256x256 pixels, with data augmentation techniques such as rotation and flipping applied. The dataset was divided into training (75%), validation (25%), and testing (5% of the validation set). The U-Net model includes convolutional blocks with 3x3 kernels, normalization layers, and dropout layers, organized into encoding, decoding, and output layers. Hyperparameters included the Adam optimizer, a learning rate of 0.0001, and a batch size of 16. Model performance was evaluated using metrics like overall accuracy, kappa coefficient, and Jaccard score.

**Findings:** The algorithm was tested on data from Poznań, Poland, utilizing high-resolution aerial images from 2021 with a 25 cm spatial resolution. The data, labeled by experts, covered four land use types: buildings, forests, roads, and water. Out of 769 labeled images, 576 were used for training (expanded to 2304 samples after augmentation), 183 for validation, and 10 for testing. The model, developed using Python and Keras on TensorFlow and trained in Google Colab, achieved high accuracy after 96 iterations, validated against expert-labeled maps. While the U-Net model performed well in general classification, it encountered challenges with rare classes like water. Data augmentation and more samples for such classes could improve accuracy. The training and validation accuracy reached 0.95 and 0.85, respectively, with validation errors stabilizing around 0.5. The U-Net model demonstrated significant improvements in accuracy, kappa coefficient, and Jaccard index compared to previous studies, underscoring the importance of high-quality data and precise parameter tuning.

**Conclusion:** The study assessed the U-Net deep learning model for accurate land use classification using aerial images. Results indicate that the model effectively identified and differentiated between land use types with high precision. The U-Net structure achieved an overall accuracy of 92.47%, a Jaccard index of 54.45%, and a kappa coefficient of 79.59%. These results demonstrate the model's strong capability in defining class boundaries. Future improvements could involve utilizing multispectral and hyperspectral images for more detailed information, combining U-Net with other networks like ANN, optimizing hyperparameters with advanced search methods, and employing transfer learning, especially with limited training data. Implementing these strategies could enhance accuracy and efficiency in land use classification, with broader applications in scientific and practical fields.



NUMBER OF REFERENCES

31



NUMBER OF FIGURES

7



NUMBER OF TABLES

5

## مقاله پژوهشی

## تحلیل و طبقه‌بندی کاربری اراضی با استفاده از تصاویر هوایی و یادگیری عمیق مبتنی بر معماری U-Net

مهدی فرهنگی، اصغر میلان\*، سعید صادقیان

گروه مهندسی نقشه برداری، دانشکده مهندسی عمران آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران

## چکیده

**پیشینه و اهداف:** طبقه‌بندی دقیق کاربری اراضی برای مدیریت مؤثر منابع طبیعی، برنامه‌ریزی شهری، کشاورزی دقیق و پایش محیط زیست ضروری است. طبقه‌بندی به پیش‌بینی و پیش‌گیری از مشکلات زیست‌محیطی کمک می‌کند. روش‌هایی مانند تصاویر ماهواره‌ای و هوایی با وضوح بالا، GIS و تکنیک‌های یادگیری عمیق از جمله شبکه‌های عصبی کانولوشنال (CNN) و معماری U-Net دقت بالایی در تحلیل و طبقه‌بندی تصاویر هوایی ارائه می‌دهند. شبکه U-Net با ساختار منحصر به فرد خود در تعریف مرزهای کاربری اراضی برتری دارد. این مطالعه بر روی منطقه‌ای در لهستان تمرکز دارد و از مدل U-Net برای افزایش دقت و کارایی طبقه‌بندی از طریق تکنیک‌های منظم‌سازی و بهینه‌سازی Adam استفاده می‌کند.

**روش‌ها:** در این تحقیق از تصاویر هوایی با قدرت تفکیک ۲۵ سانتی‌متر و در باند مرئی برای تحلیل و طبقه‌بندی کاربری اراضی استفاده شده است. مدل U-Net به دلیل معماری خاص خود، شامل بلوک‌های کانولوشن و فعال‌سازی ReLU، برای استخراج ویژگی‌های مکانی دقیق و حفظ جزئیات تصویر انتخاب شد. به منظور افزایش دقت و جلوگیری از بیش‌برازش، از تکنیک‌های منظم‌سازی مانند حذف تصادفی (Dropout) و Regularization L2 بهره گرفته شد. همچنین، برای بهبود همگرایی مدل، روش‌های افزون‌سازی داده و تکنیک توقف زود هنگام (Early Stopping) به کار رفته است. تصاویر هوایی به قطعات کوچک‌تر با ابعاد ۲۵۶×۲۵۶ پیکسل تقسیم و به سه مجموعه آموزشی، اعتبارسنجی و آزمون تقسیم شدند.

**یافته‌ها:** الگوریتم U-Net بر روی داده‌های شهر پوزنان در کشور لهستان اعمال شد. این داده‌ها توسط کارشناسان برچسب‌گذاری شدند و شامل چهار نوع کاربری اراضی: ساختمان‌ها، جنگل‌ها، جاده‌ها و آب هستند. از ۷۶۹ تصویر برچسب‌گذاری شده، ۵۷۶ تصویر برای آموزش مدل (که پس از تکنیک افزون‌سازی داده به ۲۳۰۴ تصویر گسترش یافت)، ۱۸۳ تصویر برای اعتبارسنجی و ۱۰ تصویر نیز برای آزمایش استفاده شد. این مدل، با استفاده از زبان برنامه‌نویسی Python و کتابخانه Keras بر بستر TensorFlow توسعه یافته و در Google Colab آموزش داده شد و پس از ۹۶ تکرار به دقت بالایی رسید و با نقشه‌های برچسب‌گذاری شده توسط کارشناسان اعتبارسنجی شد. در حالی که مدل U-Net در دسته‌بندی کلی عملکرد خوبی داشت، با چالش‌هایی در کلاس‌های نادر مانند آب مواجه شد. افزایش داده‌ها و نمونه‌های بیشتر برای این کلاس‌ها می‌تواند دقت را بهبود بخشد. دقت‌های آموزش و اعتبارسنجی به ترتیب به ۰.۹۵ و ۰.۸۵ رسید و خطای اعتبارسنجی در حدود ۰.۵ تثبیت شد. مدل U-Net بهبودهای قابل توجهی در دقت کلی، ضریب کاپا و امتیاز ژاکارد نسبت به مطالعات قبلی نشان داد که حاکی از اهمیت داده‌های با کیفیت و تنظیم دقیق پارامترها است.

**نتیجه‌گیری:** در این مطالعه، مدل یادگیری عمیق U-Net، برای دسته‌بندی دقیق کاربری اراضی با استفاده از تصاویر هوایی مورد ارزیابی قرار گرفت. نتایج نشان می‌دهد که این مدل به طور مؤثر انواع کاربری اراضی را با دقت بالا شناسایی و تفکیک کرده است. ساختار U-Net دقت کلی ۹۲.۴۷٪، امتیاز ژاکارد ۵۴.۴۵٪ و ضریب کاپا ۷۹.۵۹٪ را به دست آورد. این نتایج توانایی قوی مدل را در تعریف مرزهای کلاس‌ها نشان می‌دهد. بهبودهای آینده می‌تواند شامل استفاده از تصاویر چند طیفی و فراطیفی برای اطلاعات دقیق‌تر، ترکیب U-Net با سایر شبکه‌ها مانند ANN، بهینه‌سازی فرآیندها با استفاده از روش‌های جستجوی پیشرفته و به‌کارگیری یادگیری انتقالی، به ویژه در شرایط با داده‌های محدود باشد. اجرای این استراتژی‌ها می‌تواند دقت و کارایی در دسته‌بندی کاربری اراضی را افزایش دهد و کاربردهای وسیع‌تری در زمینه‌های علمی و عملی ارائه دهد.

تاریخ دریافت: ۱۷ شهریور ۱۴۰۳  
تاریخ داور: ۱۰ مهر ۱۴۰۳  
تاریخ اصلاح: ۲۵ مهر ۱۴۰۳  
تاریخ پذیرش: ۲۸ آبان ۱۴۰۳

## واژگان کلیدی:

طبقه‌بندی کاربری اراضی  
تصاویر هوایی  
یادگیری عمیق  
شبکه عصبی کانولوشنی

\* نویسنده مسئول

a\_milan@sbu.ac.ir

① ۰۲۱-۷۳۹۳۲۴۵۶

## مقدمه

امروزه، طبقه‌بندی دقیق کاربری اراضی نقشی حیاتی در طیف گسترده‌ای از زمینه‌ها از جمله مدیریت منابع طبیعی، برنامه‌ریزی شهری، کشاورزی دقیق و نظارت بر محیط زیست ایفا نموده و شناسایی دقیق کاربری اراضی نقشی اساسی در مدیریت پایدار منابع طبیعی دارا می‌باشد [۱]. این اطلاعات، کمک می‌کنند تا بتوان مسائل نظیر کاهش مساحت زمین‌های کشاورزی، جنگل‌زدایی و خسارات محیط‌زیستی را پیش‌بینی و از آنها پیشگیری نمود [۲]. به علاوه، شناخت دقیق کاربری اراضی باعث بهبود مدیریت منابع در دسترس و بهینه‌سازی در استفاده از منابع نظیر آب و کود شده و در تعیین مناطق مختلف مسکونی، تجاری، صنعتی و فضای سبز به برنامه‌ریزان کمک می‌نماید تا برنامه‌های توسعه شهری را بر اساس نیازها و منابع موجود بهینه‌سازی کنند [۳]. در نهایت، شناخت مناطق حساس محیط‌زیستی نظیر مناطق حفاظت‌شده و آبخیزها می‌تواند به حفظ و حفاظت از محیط‌زیست کمک نماید و از تخریب این مناطق جلوگیری کند [۴]. برای تعیین کاربری اراضی، از منابع و روش‌های مختلفی استفاده می‌شود که هر کدام ویژگی‌ها و مزایای خاص خود را دارند.

استفاده از تصاویر ماهواره‌ای و هوایی با وضوح بالا از جمله ابزارهای مهم در تحلیل کاربری اراضی است [۵]. این تصاویر اطلاعات دقیقی از وضعیت فعلی اراضی را فراهم نموده و به تحلیل تغییرات زمانی و مکانی در این کاربری‌ها کمک می‌کنند [۶]. با این حال، استخراج اطلاعات دقیق از تصاویر هوایی، به ویژه در مناطقی با تنوع کاربری بالا، چالش‌برانگیز است [۷]. سیستم‌های اطلاعات جغرافیایی (GIS) یکی دیگر از ابزارهای موثر در تعیین کاربری اراضی هستند که با استفاده از آنها، داده‌های مکانی و آماری از منابع مختلف نظیر سنجش از دور، نقشه‌های جغرافیایی و داده‌های زمین‌شناسی، می‌توانند به طور دقیق مورد تجزیه و تحلیل قرار گرفته و اطلاعات دقیقی از وضعیت و کاربری اراضی ارائه دهند. باید به این نکته توجه نمود که مطالعات میدانی اهمیت زیادی در تحلیل کاربری اراضی دارند، این مطالعات شامل نمونه‌برداری از خاک و گیاهان، اندازه‌گیری عمق آب‌های زیرزمینی و داده‌های زمین‌شناسی می‌شوند که با انجام آنها می‌توان به تحلیل دقیقی از وضعیت اکولوژیک و استفاده از اراضی پرداخت. همچنین مدل‌های آماری و ریاضی ابزارهای مؤثری برای تحلیل کاربری اراضی هستند، این مدل‌ها شامل استفاده از مدل‌های آماری مانند تحلیل عاملی و خوشه‌بندی، مدل‌های ریاضی مانند مدل‌های مفهومی و شبکه‌های بیزی برای پیش‌بینی و تحلیل کاربری اراضی می‌باشند که با ارائه مدل‌های تحلیلی دقیق به مدیران و تصمیم‌گیران کمک می‌کنند. استفاده از تکنیک‌های یادگیری عمیق و هوش مصنوعی هم به عنوان یکی از روش‌های نوین در تحلیل کاربری اراضی مورد استفاده قرار می‌گیرند. این تکنیک‌ها از شبکه‌های عصبی عمیق برای تحلیل تصاویر هوایی و ماهواره‌ای و استخراج ویژگی‌های پیچیده استفاده می‌کنند که به تحلیل دقیق‌تری از وضعیت کاربری اراضی کمک می‌کنند. این روش‌ها با ترکیب و استفاده موازی، می‌توانند

به تحلیل جامع و دقیقی از کاربری اراضی در مقیاس‌های مختلف مانند شهری، روستایی و محیط‌های طبیعی کمک کنند و اطلاعات مفیدی برای تصمیم‌گیری‌های مدیریتی و برنامه‌ریزی فراهم آورند. طبقه‌بندی کاربری اراضی با استفاده از یادگیری عمیق به دلیل دقت بالا و توانایی پردازش حجم زیادی از داده‌ها، به عنوان یک رویکرد مؤثر و پیشرفته در این حوزه شناخته شده است. در این روش، از شبکه‌های عصبی عمیق برای تحلیل تصاویر هوایی و ماهواره‌ای استفاده می‌شود که ساختارهای مختلفی دارند و هر کدام ویژگی‌ها و کاربردهای خاص خود را دارند [۸]. در ادامه، به توضیح برخی از مهم‌ترین ساختارهای یادگیری عمیق برای طبقه‌بندی کاربری اراضی پرداخته می‌شود. شبکه‌های عصبی کانولوشنی (CNN) یکی از رایج‌ترین و موفق‌ترین ساختارهای یادگیری عمیق در تحلیل تصاویر هستند. این شبکه‌ها با استفاده از لایه‌های کانولوشنی، توانایی استخراج ویژگی‌های مکانی از تصاویر را دارند. CNNها برای طبقه‌بندی تصاویر هوایی و شناسایی الگوهای مختلف کاربری اراضی بسیار مؤثر هستند. شبکه‌های عصبی بازگشتی (RNN) نیز در تحلیل داده‌های سری زمانی و تصاویر متوالی کاربرد دارند. این شبکه‌ها با استفاده از حافظه داخلی خود، می‌توانند اطلاعات زمانی را نگهداری کرده و تحلیل کنند. در زمینه طبقه‌بندی کاربری اراضی، RNNها می‌توانند تغییرات زمانی در کاربری اراضی را تشخیص و تحلیل کنند. شبکه‌های عصبی مولد (GAN) نیز به عنوان یک ابزار قدرتمند در تولید داده‌های مصنوعی و تقویت داده‌ها کاربرد دارند. GANها با استفاده از دو شبکه رقابتی، توانایی تولید تصاویر مصنوعی با کیفیت بالا را دارند که می‌توانند برای افزایش دقت مدل‌های طبقه‌بندی کاربری اراضی مورد استفاده قرار گیرند. در نهایت، شبکه‌های عصبی عمیق هیبریدی که ترکیبی از ساختارهای مختلف شبکه‌های عصبی هستند، نیز در تحلیل و طبقه‌بندی کاربری اراضی مورد استفاده قرار می‌گیرند. این شبکه‌ها با ترکیب ویژگی‌های مختلف از شبکه‌های CNN، RNN و GAN، می‌توانند دقت و کارایی بالاتری در تحلیل تصاویر هوایی و ماهواره‌ای داشته باشند [۹].

یادگیری عمیق، به عنوان زیرشاخه‌ای از هوش مصنوعی، در سال‌های اخیر پیشرفت‌های چشمگیری داشته و به عنوان ابزاری قدرتمند برای حل مسائل پیچیده پردازش تصویر از جمله طبقه‌بندی تصاویر هوایی مطرح شده است [۱۰]. شبکه‌های عصبی کانولوشنی (CNN)، به عنوان یکی از زیر شاخه‌های یادگیری عمیق، در استخراج ویژگی‌های مکانی از تصاویر و طبقه‌بندی آنها به طور مؤثری عمل می‌کنند. معماری شبکه U-Net، یک ساختار CNN مبتنی بر رمزگشایی و رمزنگاری است که به طور خاص برای وظایف استخراج ویژگی و طبقه‌بندی تصویری طراحی شده است. این، قابلیت استخراج و بازسازی ویژگی‌های مکانی و معنایی تصاویر را به طور همزمان داراست. U-Net با ساختار منحصر به فرد خود، دقت بالایی در شناسایی و تفکیک مرزهای کلاس‌های مختلف کاربری اراضی ارائه می‌دهد [۱۱]. با توجه به این موارد، استفاده از تصاویر هوایی با وضوح بالا و معماری شبکه U-Net مبتنی بر یادگیری عمیق CNN،

داده‌های برچسب‌گذاری شده و دقت پایین در برخی کلاس‌ها، همچنان وجود دارند.

این مطالعه روشی مبتنی بر معماری شبکه U-Net برای طبقه‌بندی دقیق کاربری اراضی ارائه می‌دهد. نوآوری تحقیق حاضر در به‌کارگیری تکنیک‌های بهینه‌سازی و منظم‌سازی، از جمله حذف تصادفی و نرمال‌سازی دسته، برای بهبود همگرایی و کاهش بیش‌برازش در مدل U-Net نهفته است. این معماری به دلیل توانایی بالا در استخراج ویژگی‌های مکانی و حفظ جزئیات دقیق تصویر، در حوزه طبقه‌بندی تصاویر کارآمد است. معماری U-Net با بهره‌گیری از بلوک‌های کانولوشن و فعال‌سازی ReLU، عملکرد قابل ملاحظه‌ای در شناسایی الگوهای پیچیده دارد. افزون بر این، مسیرهای رمزنگاری و رمزگشایی با فیلترهای افزایشی و لایه‌های تجمیع‌کننده بیشینه و Conv2DTranspose، امکان تحلیل و بازسازی دقیق تصاویر را فراهم می‌سازد. استفاده از داده‌های هوایی با کیفیت بالا برای افزایش دقت در طبقه‌بندی کاربری اراضی نیز، از دیگر جنبه‌های نوآورانه این پژوهش است. همچنین، استفاده از تنظیم دقیق فرایمترها همچون تابع بهینه‌ساز Adam، نرخ یادگیری، ابعاد دسته‌بندی و تعداد مسیر رمزنگاری و رمزگشایی مناسب، موجب بهبود عملکرد مدل و دقت طبقه‌بندی شده است. این تحقیق به منظور ارائه روشی دقیق و کارآمد برای تحلیل و طبقه‌بندی کاربری اراضی، به‌ویژه در مناطقی با تنوع کاربری بالا و پیچیدگی‌های مکانی، طراحی شده است.

### روش تحقیق

در این پژوهش با هدف طبقه‌بندی دقیق کاربری اراضی، از تصاویر هوایی و مدل یادگیری عمیق کانولوشنی مبتنی بر معماری U-Net استفاده شده است. این روش با تمرکز بر افزایش دقت و صحت طبقه‌بندی تصاویر، به تحلیل کاربری اراضی در چهار دسته مختلف پرداخته است. فرایند طی شده برای طبقه‌بندی کاربری اراضی با یادگیری عمیق U-Net که در این مقاله صورت گرفته است در شکل (۱) نشان داده شده است.

مطابق شکل (۱) ابتدا تصاویر هوایی با وضوح بالا تهیه گردید. سپس در بخش آماده‌سازی داده‌ها تصحیحات هندسی و رادیومتریکی جهت تهیه تصویر ارتوفتو اعمال و همچنین برچسب‌گذاری تصویر بصورت دستی، برای هر کاربری (ساختمان، راه، پوشش جنگلی و آب)، توسط کارشناس خبره صورت گرفت. در ادامه کل تصویر به‌همراه برچسب تصویر، به تصاویر کوچک به ابعاد  $256 \times 256$  پیکسل، برش داده شد تا به عنوان نمونه داده‌های آموزشی، اعتبارسنجی و آزمون از این تصاویر و برچسب‌های متناظر تهیه شده، استفاده گردد. سپس از تکنیک‌های افزون‌سازی داده، مانند چرخش در سه جهت: (۱) چرخش  $90^\circ$  درجه، (۲) وارونه‌سازی افقی و (۳) وارونه‌سازی عمودی، استفاده شد. استفاده از تکنیک‌های افزون‌سازی داده در یادگیری عمیق به دو دلیل اصلی انجام می‌شود:

رویکردی نوآورانه و کارآمد برای تحلیل و طبقه‌بندی دقیق کاربری اراضی ارائه می‌دهد [۱۲]. این روش می‌تواند به بهبود دقت و کارایی فرایند طبقه‌بندی و ارائه اطلاعات ارزشمند برای تصمیم‌گیری در زمینه‌های مختلف کمک کند.


در سال‌های اخیر، تحلیل و طبقه‌بندی کاربری اراضی با استفاده از تصاویر هوایی و روش‌های یادگیری عمیق توجه بسیاری از پژوهشگران را به خود جلب کرده است. این تحقیقات با هدف بهبود دقت و کارایی در تفکیک انواع کاربری‌های اراضی انجام شده‌اند. مطالعه انجام شده توسط وون کیونگ باک و همکاران در سال ۲۰۲۴ نشان داد که مدل SiU-Net در مقایسه با DeepLabv3+ و U-Net، عملکرد بهتری در طبقه‌بندی پوشش زمین با داده‌های ماهواره‌ای Sentinel-2 دارد [۱۳]. در تحقیقی دیگر، توان لین جیانگ و همکاران از U-Net برای طبقه‌بندی پوشش زمین در منطقه معدنی ویتنام استفاده کردند و نشان دادند که توابع بهینه‌ساز Nadam و Adadelta دقت بالاتری دارند و U-Net قادر به نظارت بر تغییرات پوشش زمین است [۱۴]. در مطالعه‌ای که توسط جاناناتان سولورزانو و همکاران در سال ۲۰۲۱ صورت گرفت، ترکیب داده‌های چندطیفی (MS) و راداری (SAR) برای مدل U-Net مورد بررسی قرار گرفت. در تحقیق آنها نتایج حاکی از آن بود که این ترکیب دقت طبقه‌بندی باغ‌ها و جنگل‌ها را بهبود می‌بخشد [۱۵]. در تحقیقی از اندرو کلارک و همکاران، تاثیر تغییر پارامترهای مختلف شبکه‌های عصبی کانولوشنی بر عملکرد طبقه‌بندی پوشش زمین مورد بررسی قرار گرفت و نتایج نشان داد که مدل‌های پیچیده‌تر دقت بالاتری دارند [۱۶]. حسام النجار و همکاران با استفاده از ادغام مدل رقومی سطح (DSM) و تصاویر پهپاد با شبکه‌های عصبی کانولوشنی (CNN)، بهبود دقت طبقه‌بندی پوشش زمین را بررسی کردند و نشان دادند که ادغام داده‌ها بهبود قابل توجهی در دقت دارد [۱۷]. تجندرا کومار یاداو و همکاران در سال ۲۰۲۱، استفاده از تصاویر پهپادی و یادگیری عمیق را برای طبقه‌بندی پوشش زمین را در معدن زغال سنگ Mae\_Moh در تایلند بررسی کردند و به دقت بالایی در طبقه‌بندی دست یافتند [۱۸]. میثم محرمی و همکاران در سال ۱۴۰۰ نقشه پوشش اراضی را با تصاویر ماهواره‌ای و دو الگوریتم یادگیری عمیق و جنگل تصادفی تهیه کردند و نشان دادند که شبکه عصبی عمیق دقت بهتری نسبت به جنگل تصادفی دارد [۱۹].

با توجه به بررسی‌های صورت گرفته در مطالعات پیشین و همچنین اهمیت و ضرورت تهیه نقشه پوشش زمین در مدیریت و تصمیم‌گیری‌های کلان کشوری، استفاده از تصاویر هوایی با وضوح بالا و روش‌های یادگیری عمیق می‌تواند دقت قابل توجهی در طبقه‌بندی کاربری اراضی فراهم کند. تحقیقات اخیر نشان داده‌اند که شبکه‌های عصبی کانولوشنی (CNN) و به‌ویژه معماری U-Net در استخراج ویژگی‌های مکانی از تصاویر و طبقه‌بندی دقیق آن‌ها بسیار موثر عمل می‌کنند. با این حال، چالش‌هایی همچون بیش‌برازش مدل، کمبود

در شکل (۲)، عمل چرخش بر روی یک نمونه از تصاویر در سه جهت نمایش داده شده است.

در گام بعدی، به منظور آموزش و ارزیابی مدل یادگیری عمیق U-Net، تصاویر به سه مجموعه آموزش، اعتبارسنجی و آزمون تقسیم‌بندی شدند. این تقسیم‌بندی از جهت حفظ استقلال و عملکرد صحیح مدل بسیار حیاتی است. حدود ۷۵ درصد از کل داده‌های این مجموعه برای آموزش مدل، اختصاص یافت که شامل تصاویر و برچسب‌های مربوط به چهار دسته مختلف پوشش کاربری (ساختمان‌ها، جنگل‌ها، جاده‌ها و آب) است. این داده‌ها به طور تصادفی انتخاب شده‌اند تا مدل بتواند تنوع داده‌ها را یاد بگیرد و عملکرد بهتری در طبقه‌بندی داشته باشد. ۲۵ درصد باقی‌مانده داده‌ها برای بخش اعتبارسنجی، مورد استفاده قرار گرفت. این مجموعه داده برای ارزیابی مدل استفاده می‌شود تا از تنظیمات بهینه مدل و جلوگیری از بیش برازش اطمینان حاصل شود. ۵ درصد از مجموعه داده‌های اعتبارسنجی نیز به صورت تصادفی انتخاب شده و به بخش آزمون، اختصاص یافت. این مجموعه کوچک‌تر برای ارزیابی نهایی عملکرد مدل پس از اتمام فرایند آموزش استفاده می‌گردد. نتایج حاصل از این مجموعه به عنوان ارزیابی نهایی عملکرد مدل در طبقه‌بندی کاربری اراضی مورد استفاده قرار گرفت. برای اطمینان از تعمیم‌پذیری مدل، تمامی مجموعه‌ها، شامل تصاویر مختلف از هر چهار پوشش کاربری مورد نظر بوده و به صورت تصادفی و بدون تداخل انتخاب شدند. این فرایند تضمین می‌کند که مدل قادر است به درستی و با دقت بالا، انواع مختلف کاربری اراضی را طبقه‌بندی کند. در گام بعد نیاز به طراحی ساختار شبکه و فیلتر کانولوشنی می‌باشد.

جهت طراحی ساختار شبکه و فیلتر کانولوشنی، بایستی شناخت دقیقی از معماری U-net داشت. معماری U-Net یک معماری شبکه عصبی کانولوشنی (CNN) است که ابتدا در سال ۲۰۱۵ برای برنامه‌های پردازش تصویر پزشکی معرفی شد [۲۲]. این معماری اصطلاحاً به دلیل شباهت ساختارش به حرف "U"، U-Net نامگذاری شده است. U-Net از ساختاری که شامل لایه‌های کانولوشنی بالا به پایین و سپس لایه‌های کانولوشنی پایین به بالا است، استفاده می‌کند. ساختار اصلی U-Net شامل دو بخش اصلی است که عبارتند از:



شکل ۱: روش پیشنهادی در این تحقیق جهت طبقه‌بندی کاربری اراضی  
Fig. 1: The proposed method in this study for land use classification

○ افزایش حجم داده‌ها: ایجاد نمونه‌های جدید و متنوع از داده‌های موجود، به مدل کمک می‌کند که با حجم بیشتری از داده‌ها آموزش ببیند و این امر به بهبود دقت و عملکرد مدل کمک می‌کند [۲۰].  
○ کاهش بیش برازش: اعمال تغییرات تصادفی مانند چرخش، تغییر مقیاس و افزودن نویز به داده‌های آموزشی، باعث می‌شود که مدل به الگوهای کلی‌تری توجه کند و به دقت و عملکرد بهتری بر روی داده‌های جدید واکنش نشان دهد، در نتیجه بیش برازش را کاهش می‌دهد [۲۱].



شکل ۲: نمایی از افزون‌سازی داده (تکنیک چرخش و وارونه‌سازی)  
Fig. 2: A view of data augmentation (rotation and flipping technique)



تصادفی برخی از نوره‌ها در هر لایه، به جلوگیری از وابستگی بیش از حد مدل به ویژگی‌های خاص داده آموزشی و در نتیجه بهبود کارایی بر روی داده‌های جدید کمک می‌کند.


در بخش طراحی ساختار شبکه، مدل مورد نظر شامل سه بخش اصلی مسیر رمزنگاری، مسیر رمزگشایی و لایه خروجی است که هر یک با اهداف خاصی در فرایند پردازش و طبقه‌بندی تصاویر به کار گرفته شده‌اند. مسیر رمزنگاری شامل ۵ مرحله است که در هر مرحله ابعاد فیلترهای کانولوشن کاهش می‌یابد (از فیلتر با ابعاد  $256 \times 256$  در اولین مرحله تا فیلتر با ابعاد  $16 \times 16$  در مرحله آخر). این کار باعث استخراج ویژگی‌های پیچیده‌تر از تصاویر در مراحل پایین‌تر و ویژگی‌های با سطح پایین‌تر مانند لبه‌ها و بافت‌ها در مراحل بالاتر می‌شود. همچنین در انتهای هر مرحله از یک لایه تجمیع‌کننده بیشینه برای کاهش ابعاد تصویر و کنترل پیچیدگی مدل استفاده شده است. مسیر رمزگشایی شامل ۵ مرحله است، با این تفاوت که در هر مرحله با استفاده از لایه‌های Conv2DTranspose ابعاد تصویر افزایش می‌یابد. همچنین در هر مرحله خروجی این لایه با خروجی مربوطه در مسیر رمزنگاری با ابعاد مشابه ترکیب می‌شود تا اطلاعات مکانی از مسیر رمزنگاری به مسیر رمزگشایی منتقل شود و در نهایت منجر به خروجی با قدرت تفکیک بالا و دقت مطلوب در طبقه‌بندی تصویر گردد. در نهایت، یک لایه کانولوشن با فیلتری به ابعاد  $5 \times 5$  و هسته  $1 \times 1$  برای خروجی مدل در نظر گرفته شده است. خروجی این لایه با ابعاد تصویر مطابقت دارد و هر پیکسل خروجی نشان‌دهنده احتمال تعلق آن پیکسل به یکی از ۵ دسته (۴ طبقه کاربری اراضی به همراه پس‌زمینه) می‌باشد. برای تبدیل خروجی به یک برچسب کاربری از عملگر Softmax استفاده شده است. عوارضی که در مجموعه ۴ کاربری تعریف شده قرار نگیرند، توسط مدل یادگیری عمیق به دسته پس‌زمینه اختصاص داده می‌شود.

○ بخش انقباضی (Encoder): در این بخش، تصاویر ورودی از طریق یک سری لایه کانولوشنی و لایه‌های تجمیع‌کننده (معمولاً لایه‌های تجمیع‌کننده بیشینه) کاهش می‌یابند و ویژگی‌های مهم برای تصمیم‌گیری بعدی استخراج می‌شوند [۲۳]. این فرایند به صورت تدریجی انجام می‌شود و به کاهش ابعاد تصویر و افزایش عمق (تعداد کانال‌ها) منجر می‌شود.

○ بخش انبساطی (Decoder): در این بخش، با استفاده از لایه‌های کانولوشنی پایین به بالا و لایه‌های کانولوشن معکوس، ابعاد تصویر افزایش می‌یابد و ویژگی‌های استخراج شده در بخش رمزنگاری بازسازی می‌شوند [۲۴]. در واقع، این بخش بازسازی دقیق تصویر را با استفاده از ویژگی‌هایی که در بخش رمزنگاری به دست آمده‌اند، انجام می‌دهد.

شکل (۳) ساختاری از مدل U-Net با لایه ورودی و خروجی و همچنین لایه‌های رمزگزار، تجمیع‌کننده و رمزگشا را نشان می‌دهد.

عملکرد اصلی U-Net در برنامه‌های تصویری به طور خاص در شناسایی و طبقه‌بندی اجسام و عوارض در تصاویر و همچنین سایر وظایف پردازش تصویر است. برخلاف شبکه‌های CNN معمولی که معمولاً اطلاعات محیطی اطراف یک نقطه را در نظر می‌گیرند، U-Net قادر است اطلاعات محیطی بیشتری را در نظر بگیرد و از آنها برای بازسازی دقیق‌تر و بهتر تصاویر استفاده کند، به ویژه در مواردی که نیاز به بازسازی دقیق تصاویر و یا اجسام کوچک در تصاویر وجود دارد [۲۵]. مدل U-Net طراحی شده در این مطالعه، از بلوک‌های کانولوشنی تشکیل شده است که هر بلوک شامل دو لایه کانولوشن با هسته  $3 \times 3$ ، اعمال‌کننده فعال‌سازی ReLU و یک لایه نرمال‌سازی دسته و حذف تصادفی (Dropout) است. استفاده از نرمال‌سازی دسته، به بهبود همگرایی مدل و کاهش پدیده بیش برآزش کمک می‌کند. Dropout نیز با حذف



شکل ۳: نمونه‌ای از ساختار معماری U-Net  
Fig. 3: An example of the U-Net architecture

○ اندازه دسته‌بندی: اندازه دسته ۱۶ انتخاب شده است. دسته‌بندی به فرایند تقسیم کردن داده‌های آموزشی به زیرمجموعه‌های کوچک‌تر گفته می‌شود که در هر تکرار برای آموزش مدل مورد استفاده قرار می‌گیرند. انتخاب اندازه مناسب دسته می‌تواند بر حافظه مورد نیاز برای آموزش مدل و سرعت همگرایی آن تأثیر بگذارد.

تنظیمات و ساختار مدل، به مدل U-Net این امکان را می‌دهد تا با دقت و کارایی بالا، وظایف طبقه‌بندی تصویر را انجام دهد و به نتایج مطلوبی در طبقه‌بندی کاربری اراضی دست یابد.

در جدول (۱) بطور خلاصه، معماری شبکه U-Net طراحی شده آمده است.

گام آخر در طبقه‌بندی کاربری اراضی، ارزیابی نتایج به‌دست‌آمده از مدل است. این ارزیابی شامل استفاده از معیارهای دقت کلی، ضریب کاپا و امتیاز ژاکارد می‌باشد تا اطمینان حاصل شود که مدل به‌درستی توانسته است کاربری‌های مختلف را شناسایی و دسته‌بندی کند. این معیارها کمک می‌کنند تا عملکرد مدل به‌طور دقیق‌تر مورد سنجش قرار گیرد و نقاط ضعف و قوت آن مشخص شود.

دقت کلی (رابطه ۱)، یکی از ساده‌ترین و متداول‌ترین معیارهای ارزیابی عملکرد مدل‌های طبقه‌بندی است. این معیار نشان‌دهنده نسبت تعداد نمونه‌های درست طبقه‌بندی شده به کل نمونه‌ها است [۲۷]. به عبارت دیگر، دقت کلی نشان می‌دهد که مدل چقدر در تشخیص نمونه‌ها به درستی عمل کرده است.

$$\text{Overall\_Accuracy} = \frac{TP}{TP + FP + FN} \quad (1)$$

تنظیم فرآیندها در طراحی مدل U-net از اهمیت بالایی برخوردار است، این تنظیمات به طور مستقیم بر عملکرد و دقت مدل تأثیر می‌گذارد. انتخاب صحیح فرآیندها می‌تواند زمان آموزش را کاهش داده و از بروز بیش‌برازش در مدل جلوگیری کند. همچنین تنظیم نادرست این پارامترها می‌تواند منجر به کاهش دقت و بروز نوسانات در فرایند آموزش شود؛ بنابراین دستیابی به تعادل مناسبی بین دقت و کارایی مدل ضروری است. از مهم‌ترین فرآیندهایی که در این مطالعه تنظیم شدند عبارت است از:

- تابع بهینه‌ساز: الگوریتم Adam و SGD به عنوان توابع بهینه‌ساز انتخاب شده است. Adam یکی از رایج‌ترین الگوریتم‌های بهینه‌سازی برای شبکه‌های عصبی عمیق است که با به‌روزرسانی لحظه‌ای نرخ یادگیری برای هر پارامتر، به همگرایی سریع‌تر مدل کمک می‌کند [۲۶]. SGD یک الگوریتم بهینه‌سازی است که در هر مرحله وزن‌های مدل را بر اساس یک نمونه تصادفی از داده‌ها به‌روزرسانی می‌کند و به دلیل پردازش سریع‌تر با داده‌های بزرگ استفاده می‌شود. الگوریتم SGD پایه بسیاری از روش‌های پیشرفته‌تر بهینه‌سازی مثل Adam، RMSProp و AdaGrad است که مشکلات مربوط به نوسان‌ها و نرخ یادگیری را بهتر مدیریت می‌کنند.
- نرخ یادگیری: مقدار ۰.۰۰۰۱ برای نرخ یادگیری در نظر گرفته شده است. نرخ یادگیری پارامتری است که میزان به‌روزرسانی وزن‌های مدل را در هر تکرار تعیین می‌کند. مقدار مناسب نرخ یادگیری می‌تواند بر سرعت همگرایی و عملکرد نهایی مدل تأثیرگذار باشد.

جدول ۱: معماری U-Net طراحی شده  
Table 1: Designed U-Net Architecture

| بخش<br>(Section)  | توضیحات<br>(Description)                                                                                           |
|-------------------|--------------------------------------------------------------------------------------------------------------------|
| بلوک‌های کانولوشن | شامل دو لایه کانولوشن با هسته ۳×۳<br>(Includes two convolution layers with a 3×3 kernel)                           |
| تابع فعال‌سازی    | ReLU                                                                                                               |
| نرمال‌سازی دسته   | بهبود همگرایی و کاهش بیش‌برازش<br>(Improves convergence and reduces overfitting)                                   |
| حذف تصادفی        | جلوگیری از وابستگی بیش از حد به ویژگی‌های خاص<br>(Prevents excessive dependency on specific features)              |
| مسیر رمزنگاری     | ۵ مرحله با افزایش فیلترها (۱۶ تا ۲۵۶)<br>(5 stages with increasing filters (16 to 256))                            |
| لایه تجمیع‌کننده  | کاهش ابعاد تصویر و کنترل پیچیدگی مدل<br>(Reduces image dimensions and controls model complexity)                   |
| مسیر رمزگشایی     | ۵ مرحله با Conv2DTranspose برای افزایش ابعاد تصویر<br>(5 stages with Conv2DTranspose to increase image dimensions) |
| ترکیب خروجی       | انتقال اطلاعات مکانی از مسیر رمزنگاری<br>(Transfers spatial information from the encoding path)                    |
| لایه خروجی        | ۵ فیلتر با هسته ۱×۱<br>(5 filters with a 1×1 kernel)                                                               |
| تابع بهینه‌ساز    | Adam & SGD                                                                                                         |
| نرخ یادگیری       | 0.0001                                                                                                             |
| ابعاد دسته‌بندی   | 16                                                                                                                 |

در این رابطه:

○ TP: تعداد نمونه‌هایی که به درستی به عنوان مثبت طبقه‌بندی شده‌اند.

○ TN: تعداد نمونه‌هایی که به درستی به عنوان منفی طبقه‌بندی شده‌اند.

○ FP: تعداد نمونه‌هایی که به اشتباه به عنوان مثبت طبقه‌بندی شده‌اند.

○ FN: تعداد نمونه‌هایی که به اشتباه به عنوان منفی طبقه‌بندی شده‌اند.

ضریب کاپا (رابطه ۲)، معیاری است که میزان توافق بین دو مجموعه داده (به عنوان مثال، پیش‌بینی‌های مدل و مقادیر واقعی) را با در نظر گرفتن احتمال توافق اتفاقی اندازه‌گیری می‌کند [۲۸]. این معیار نسبت به دقت کلی حساس‌تر است زیرا اثرات اتفاقی را در نظر می‌گیرد.

$$Kappa\_Coefficient = \frac{p_o - p_e}{1 - p_e} \quad (۲)$$

در این رابطه:

○  $p_o$ : دقت مشاهده شده (دقت کلی)

○  $p_e$ : دقت تصادفی

امتیاز ژاکارد (رابطه ۳)، معیاری برای سنجش شباهت بین دو مجموعه است. این معیار اغلب در زمینه‌های طبقه‌بندی و خوشه‌بندی استفاده می‌شود. امتیاز ژاکارد بین ۰ و ۱ یا به صورت درصدی محاسبه می‌شود [۲۹]. مقادیر بالاتر نشان دهنده شباهت بیشتر بین دو مجموعه است.

$$Jaccard\_Score = |A \cap B| / |A \cup B| \quad (۳)$$

که در آن:

○  $|A \cap B|$ : تعداد عناصر مشترک بین دو مجموعه A و B

○  $|A \cup B|$ : تعداد کل عناصر در دو مجموعه A و B

امتیاز F1 (رابطه ۴)، در بازه‌ای از ۰ تا ۱ قرار دارد که مقادیر بالاتر نشان‌دهنده عملکرد بهتر مدل است [۳۰].

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (۴)$$

که در آن:

○ Precision (دقت): درصد پیش‌بینی‌های مثبت صحیح از کل پیش‌بینی‌های مثبت مدل است. به عبارت دیگر، دقت به ما می‌گوید که چه مقدار از پیش‌بینی‌های مثبت مدل، واقعاً صحیح بوده‌اند.

$$Precision = \frac{TP}{TP + FP} \quad (۵)$$

○ Recall (یادآوری): درصد نمونه‌های مثبت واقعی که به درستی توسط مدل شناسایی شده‌اند. این معیار نشان می‌دهد که مدل چقدر خوب در تشخیص تمام نمونه‌های مثبت عمل کرده است.


$$Recall = \frac{TP}{TP + FN} \quad (۶)$$

امتیاز F1 برای ارزیابی مدل‌هایی که ممکن است در شناسایی کلاس‌های نادر ضعیف عمل کنند، مناسب است، زیرا این معیار هم به Precision و هم به Recall توجه دارد و تعادل بین آنها را برقرار می‌کند. امتیاز F1 جزو معیارهای ارزیابی در این پژوهش نبوده و صرفاً جهت مقایسه عملکرد مدل با سایر مطالعات پیشین به کار گرفته شده است.

این معیارها به طور گسترده‌ای برای ارزیابی عملکرد مدل‌های یادگیری ماشین و یادگیری عمیق در مسائل مختلف طبقه‌بندی و قطعه‌بندی تصویر استفاده می‌شوند و هر کدام مزایا و کاربردهای خاص خود را دارند.

#### پایه‌سازی روش تحقیق

برای پایه‌سازی الگوریتم پیشنهادی در این مطالعه از داده‌های شهر پوزنان (Poznański) در غرب استان ویلکوپولسکا (Wielkopolskie) از کشور لهستان استفاده شده است. این شهر در کنار رودخانه وارتا (Warta) واقع شده و به عنوان یکی از قدیمی‌ترین و بزرگ‌ترین شهرهای لهستان شناخته می‌شود. این منطقه با مساحت ۵۲۳/۰۱۶ هکتار در بازه‌ای از طول جغرافیایی ۱۶°۴۲'۰۳" تا ۱۶°۴۵'۰۴" شرقی و بازه‌ای از عرض جغرافیایی ۵۲°۲۹'۵۸" تا ۵۲°۳۱'۱۵" شمالی قرار دارد. شکل (۴) موقعیت و پوشش این منطقه را نمایش می‌دهد.



شکل ۴: منطقه مطالعاتی: تصویر اورتوفتو از شهر پوزنان - ویلکوپولسکا - لهستان  
Fig. 4: Study Area: Orthophoto of the City of Poznań - Wielkopolska - Poland




پردازشی مانند حافظه و پردازنده را فراهم می‌کند. در نتیجه، مدل قادر است عملیات کانولوشن و آموزش را با سرعت بیشتری انجام دهد که این مسئله به‌ویژه در مدل‌هایی با تعداد لایه‌های زیاد مانند U-Net اهمیت دارد. دوماً، این اندازه به مدل کمک می‌کند تا جزئیات محلی بیشتری از تصاویر را ببیند، به‌خصوص در شناسایی لبه‌ها و مرزهای کاربری‌های اراضی مانند جاده‌ها و ساختمان‌ها. قطعات کوچک‌تر امکان پردازش دقیق‌تر و استخراج بهتر ویژگی‌های مکانی را فراهم می‌کنند که برای بهبود دقت طبقه‌بندی ضروری است. علاوه بر این، برش تصاویر به این اندازه تنوع بیشتری از داده‌ها را به مدل ارائه می‌دهد که باعث افزایش تعمیم‌پذیری و بهبود دقت مدل در مواجهه با داده‌های جدید می‌شود. همچنین، اندازه  $256 \times 256$  پیکسل با معماری U-Net سازگار است و از تغییرات شدید در ابعاد ورودی در طی مراحل مختلف مدل جلوگیری می‌کند که این تناسب به بهبود همگرایی مدل و کاهش مشکلاتی مانند اعوجاج در تصاویر خروجی کمک می‌کند. به طور کلی، این اندازه بهینه به دلیل افزایش دقت و کارایی مدل، یکی از عوامل کلیدی در بهبود عملکرد U-Net در این پژوهش بوده است.

برای پیاده‌سازی و اجرای مدل یادگیری عمیق U-Net، از زبان برنامه‌نویسی Python استفاده شده است. تمامی مراحل آموزش و ارزیابی مدل در محیط Google Colab با استفاده از سرور گرافیکی T4 GPU انجام گرفته است. Google Colab به دلیل داشتن پردازنده‌های گرافیکی قدرتمند (مانند T4 GPU)، توانسته است زمان محاسباتی مدل را به طور قابل توجهی کاهش داده و فرایند آموزش را تسریع کند. این ویژگی به ویژه برای مدل‌های یادگیری عمیق با حجم داده‌های بالا و تعداد تکرارهای زیاد، ضروری است. به علاوه از مجموعه‌ای از کتابخانه‌های متنوع برای پردازش تصاویر، آماده‌سازی داده‌ها و پیاده‌سازی مدل استفاده شد. برای بارگذاری و پردازش تصاویر، از کتابخانه‌هایی مانند PIL، tifffile و gdal استفاده شده است. برای مصورسازی نتایج و تحلیل داده‌ها از Matplotlib و ابزارهای مرتبط مانند PrettyTable و Pandas بهره گرفته شده است. در بخش تقسیم‌بندی داده‌ها، کتابخانه scikit-learn برای تقسیم داده‌های آموزشی، اعتبارسنجی و آزمون استفاده شد. همچنین، از OpenCV برای پردازش و تحلیل تصاویر و کتابخانه Keras برای طراحی و آموزش مدل‌های یادگیری عمیق بهره گرفته شد.

در این پژوهش از تصاویر هوایی در سال ۲۰۲۱ استفاده شده است [۳۱]. این تصاویر با وضوح بالا و قدرت تفکیک مکانی ۲۵ سانتی متر در سه باند اصلی محدوده طیف مرئی در شرایط نوری مناسب اخذ شده است. انتخاب داده‌های مربوط به کشور لهستان به دلیل چندین عامل مهم صورت گرفته است. نخست آنکه، دسترسی به داده‌های هوایی با کیفیت بالا برای مناطق داخلی ایران، فرایندی زمان‌بر و مستلزم هزینه‌های بالایی است. از سوی دیگر، در صورت تهیه داده‌ها، برچسب‌گذاری دقیق و گسترده آن‌ها به دلیل وسعت مناطق، امری بسیار پیچیده و زمان‌بر محسوب می‌شد. در مقابل، داده‌های هوایی مناطقی از کشور لهستان به صورت رایگان در دسترس پژوهشگران بوده و پیش از این توسط کارشناسان به طور کامل برچسب‌گذاری شده است، که این امر علاوه بر کاهش هزینه‌ها، به میزان قابل توجهی موجب تسریع در انجام پژوهش می‌شود. همچنین، داده‌های استفاده شده از نظر تصحیحات هندسی و رادیومتریکی کیفیت بالایی داشته و برای بهره‌برداری در مدل‌های یادگیری عمیق از جمله U-Net کاملاً مناسب بودند. از دیگر مزایای این منطقه، تنوع کاربری‌های اراضی آن (شامل ساختمان‌ها، جنگل‌ها، جاده‌ها و آب‌ها) است که امکان ارزیابی دقیق‌تر مدل و تعمیم‌پذیری نتایج به سایر مناطق و همچنین سایر مطالعات را فراهم می‌کند. در شکل (۵) نمونه‌ای از برچسب‌های تهیه شده نشان داده شده است. راهنمای موجود در این شکل، برای سایر اشکال مشابه در این مطالعه، صادق است.

از ۷۶۹ تصویر برچسب‌گذاری شده با ابعاد  $256 \times 256$  پیکسل، تعداد ۵۷۶ تصویر به بخش داده‌های آموزشی اختصاص داده شد که پس از اعمال تکنیک‌های افزون‌سازی داده، تعداد مجموعه داده‌های آموزشی به ۲۳۰۴ نمونه افزایش یافت. ۱۸۳ تصویر به بخش داده‌های اعتبارسنجی و ۱۰ تصویر به مجموعه داده‌های آزمون اختصاص داده شد.

در این پژوهش، تصاویر هوایی به قطعات کوچک‌تر با اندازه  $256 \times 256$  پیکسل برش داده شدند که این انتخاب به دلایل مختلفی بر بهبود کارایی مدل یادگیری عمیق U-Net تأثیرگذار بوده است. اولاً، برش تصاویر به این اندازه باعث کاهش حجم داده‌های پردازشی و به تبع آن کاهش پیچیدگی محاسباتی می‌شود که امکان استفاده بهینه‌تر از منابع



شکل ۵: برچسب تهیه شده توسط کارشناس از کاربری‌های مورد مطالعه

Fig. 5: Label prepared by the expert for the studied land uses

جولوگیری از بیش‌برازش اهمیت دارد، زیرا مدل ممکن است به خوبی بر روی داده‌های آموزشی عمل کند اما در مواجهه با داده‌های جدید عملکرد ضعیفی داشته باشد. با توقف آموزش در بهترین نقطه، نه تنها زمان آموزش کاهش می‌یابد، بلکه مدل بهینه‌تری نیز به دست می‌آید که به ویژگی‌های اصلی داده‌های آموزشی و اعتبارسنجی پاسخ می‌دهد. این امر به پیش‌بینی‌های دقیق‌تر مدل کمک می‌کند و موجب دستیابی به دقت و کارایی بالاتر در طبقه‌بندی کاربری اراضی می‌شود.

در آخر نقشه تهیه شده توسط مدل یادگیری عمیق U-net، توسط معیارهای ارزیابی دقت با نقشه تهیه شده توسط کارشناس مورد مقایسه قرار گرفت. در جدول (۲) نقشه تهیه شده توسط مدل، برای برخی از مجموعه داده‌های آزمون به همراه نقشه تهیه شده توسط کارشناس خبره و معیارهای ارزیابی عملکرد مدل، آمده است.

همچنین به منظور محاسبه دقت مدل در تشخیص مرزهای کاربری‌های اراضی نیز، از ابزار Metrics در کتابخانه scikit-learn استفاده شد. این ترکیب از کتابخانه‌ها و ابزارها، به اجرای موفق و کارآمد مدل U-Net کمک کرده و فرآیند پیاده‌سازی، آموزش و ارزیابی مدل را تسریع و بهبود بخشیده است.

پس از اعمال تنظیمات و طراحی ساختار U-net، مجموعه داده آموزشی به مدل معرفی گردید. در گام بعدی مدل U-net پس از ۹۶ تکرار، به بیشترین دقت رسیده و فرآیند آموزش خود را با استفاده از تکنیک Early Stopping، متوقف نمود. تکنیک Early Stopping برای جلوگیری از بیش‌برازش در فرآیند آموزش مدل U-Net استفاده شده است. این روش به‌صورت خودکار آموزش مدل را متوقف می‌کند زمانی که دقت آن بر روی مجموعه اعتبارسنجی به حداکثر مقدار خود رسیده و از آن پس شروع به کاهش می‌کند. استفاده از Early Stopping به دلیل

جدول ۲: پیش‌بینی مدل U-Net برای مجموعه داده‌های آزمون

Table 2: U-Net Model Predictions for the Test Dataset

| شماره تصویر | Image number | تهیه شده توسط U-Net<br>(Generated by U-Net) | تهیه شده توسط کارشناس خبره<br>(Produced by an Expert) | تصویر اصلی<br>(Original) |
|-------------|--------------|---------------------------------------------|-------------------------------------------------------|--------------------------|
| تصویر اول   | First Image  |                                             |                                                       |                          |
| تصویر دوم   | Second Image |                                             |                                                       |                          |
| تصویر سوم   | Third Image  |                                             |                                                       |                          |

معیار ارزیابی  
(Evaluation Criteria)

| دقت کلی<br>(Overall Accuracy) | ضریب کاپا<br>(Kappa Coefficient) | امتیاز ژاکارد<br>(Jaccard Score) |
|-------------------------------|----------------------------------|----------------------------------|
| First Image                   | 86.37                            | 76.11                            |
| Second Image                  | 90.55                            | 89.57                            |
| Third Image                   | 75.01                            | 66.01                            |

## نتایج و بحث


نیز به سرعت کاهش یافته است، اما پس از حدود ۵۰ تکرار به یک مقدار ثابت (در حدود ۰.۵) می‌رسد و سپس نوسانات کمی را نشان می‌دهد. بهترین نقطه مدل در دقت و مقدار افت آن برای هر دو مجموعه داده آموزش و تست در جدول (۳) آورده شده است.

جدول ۳: دقت و افت حاصل از آموزش مدل برای مجموعه داده‌های آموزش و اعتبارسنجی

Table 3: Accuracy and loss achieved from model training for the training and validation datasets

| دقت آموزش (Training accuracy) | افت آموزش (Training loss) | دقت اعتبارسنجی (Validation accuracy) | افت اعتبارسنجی (Validation loss) |
|-------------------------------|---------------------------|--------------------------------------|----------------------------------|
| 0.9503                        | 0.1958                    | 0.8883                               | 0.3941                           |

با توجه به جدول (۳) مدل به طور کلی عملکرد خوبی به ویژه در داده‌های آموزشی دارد. دقت بالا در هر دو مجموعه داده‌های آموزشی و اعتبارسنجی نشان‌دهنده این است که مدل به خوبی آموزش دیده و می‌تواند داده‌های جدید را نیز به خوبی تشخیص دهد. در شکل (۷)، نمودار پراکندگی رابطه بین خطای اعتبارسنجی و دقت، نشان داده شده است.




شکل ۷: رابطه بین دقت و افت اعتبارسنجی

Fig. 7: The relationship between accuracy and validation degradation

جدول (۲) نشان‌دهنده عملکرد مطلوب مدل U-Net در طبقه‌بندی تصاویر هوایی با دقت بالا می‌باشد. همانگونه که از نتایج مشخص است مدل توانسته به خوبی ویژگی‌های مختلف موجود در تصاویر را شناسایی کرده و طبقه‌بندی‌های دقیقی را ارائه دهد. با این حال، برخی محدودیت‌ها و چالش‌ها نیز در طول پژوهش مشاهده شد که می‌توانند بهبودهای بیشتری را ایجاد کنند. یکی از مواردی که بایستی به آن توجه کرد، چالش مربوط به کلاس‌های نادر آب می‌باشد. در برخی موارد، مدل در تشخیص کلاس‌های نادر مانند آب، دقت کمتری داشت. این مسئله می‌تواند به دلیل تعداد کم نمونه‌های آموزشی مربوط به این کلاس‌ها باشد. استفاده از تکنیک‌های افزایش داده و جمع‌آوری داده‌های بیشتر برای این کلاس‌ها می‌تواند به بهبود دقت مدل کمک کند. دقت مدل یادگیری عمیق U-Net با استفاده از مجموعه داده‌های آموزش و سپس ارزیابی دقت مدل آموزش دیده برای مجموعه داده‌های اعتبارسنجی در طول ۹۶ تکرار در شکل (۶) نشان داده شده است. در شکل (۶)، محور عمودی نمودار، نشان‌دهنده دقت یا افت مدل بوده و محور افقی نمودار، متعلق به تعداد تکرار آموزش و اعتبارسنجی مدل است.

طبق نمودار شکل (۶) قسمت (ب)، دقت مدل در داده‌های آموزشی به سرعت افزایش می‌یابد و در حدود ۰.۹۵ به تعادل می‌رسد. این نشان می‌دهد که مدل به خوبی آموزش دیده است. همچنین دقت مدل در داده‌های اعتبارسنجی نیز به طور کلی افزایش می‌یابد، اما پس از حدود ۲۰ تکرار به مقدار حدود ۰.۸۵ می‌رسد و سپس تغییرات کوچکی را نشان می‌دهد. نقطه بهترین مدل نشان‌دهنده بهترین عملکرد مدل در داده‌های اعتبارسنجی است. در این نقطه از فرایند آموزش، دقت اعتبارسنجی تقریباً به حداکثر مقدار خود رسیده است. همچنین مطابق نمودار شکل (۶) قسمت (الف)، خطای مدل در داده‌های آموزشی به سرعت کاهش می‌یابد و پس از حدود ۶۰ تکرار به یک مقدار کم (تقریباً نزدیک به صفر) می‌رسد. همچنین خطای مدل در داده‌های اعتبارسنجی



شکل ۶: الف) افت مدل و ب) دقت مدل برای مجموعه داده‌های آموزش و اعتبارسنجی

Fig. 6: a) Model loss and b) Model accuracy for training and validation datasets

نتایج به دست آمده از این پژوهش و نتایج مقالات منتخب را نشان می‌دهد.



نتایج جدول (۵) نشان می‌دهد که مدل U-Net به کار رفته در این پژوهش با استفاده از بهینه‌ساز Adam، بهبود قابل توجهی در دقت کلی، ضریب کاپا و امتیاز ژاکارد نسبت به مطالعات پیشین داشته است. این بهبودها را می‌توان به استفاده از تکنیک‌های منظم‌سازی مانند حذف تصادفی و Regularization L2، روش‌های افزون‌سازی داده، تکنیک توقف زودهنگام و تنظیم بهینه فراپارامترها نسبت داد. معیارهای ارزیابی به دست آمده از بهینه‌ساز SGD نیز، علی‌رغم تنظیمات یکسان در بخش فراپارامترهای مدل U-Net، این بهینه‌ساز دقت قابل قبولی را ارائه نداده است که حاکی از تاثیر بسزای انتخاب دقیق بهینه‌ساز در عملکرد مدل یادگیری عمیق است. نتایج این پژوهش تأیید می‌کند که مدل U-Net پیشنهادی قادر به شناسایی دقیق تر و بهتر کلاس‌های مختلف کاربری اراضی است و می‌تواند به عنوان یک ابزار کارآمد در تحلیل و طبقه‌بندی کاربری اراضی با دقت بالا مورد استفاده قرار گیرد. لازم به ذکر است که تفاوت‌های جغرافیایی و شرایط محیطی مناطق مختلف مورد مطالعه می‌تواند تأثیر قابل توجهی بر دقت مدل‌های یادگیری عمیق در طبقه‌بندی کاربری اراضی داشته باشد. اگرچه نتایج ارائه شده در جدول (۴) نشان‌دهنده عملکرد U-Net در مناطق گوناگون است، این مقایسه باید با در نظر گرفتن تفاوت‌های شرایط مکانی و نوع داده‌ها مورد استفاده تفسیر گردد. به همین دلیل، این مقایسه به عنوان یک مقایسه کلی از عملکرد مدل پیشنهادی، ارائه شده و نتایج نمی‌توانند به طور دقیق برای تمام مناطق جغرافیایی تعمیم یابند.

این نمودار نشان‌دهنده اثربخشی مدل U-Net در طبقه‌بندی کاربری اراضی بوده و نشان می‌دهد که در شرایط بهینه، مدل می‌تواند به دقت بالایی در حدود ۰.۸۵ تا ۰.۹۵ برسد. با افزایش عملکرد مدل، کاهش خطای اعتبارسنجی مشهود است. نقاطی که در نزدیکی خطای اعتبارسنجی پایین و دقت بالا متمرکز شده‌اند، نشان‌دهنده مدل‌هایی هستند که عملکرد بهتری دارند. برای بهبود بیشتر عملکرد مدل و کاهش خطای اعتبارسنجی، نیاز به بهینه‌سازی‌های بیشتری در مراحل آموزش و اعتبارسنجی وجود دارد. همچنین، می‌توان به اهمیت داشتن مجموعه داده‌های با کیفیت بالا و مناسب برای آموزش مدل‌های یادگیری عمیق اشاره کرد. به طور کلی، این نمودار اهمیت تنظیم دقیق فراپارامترها و استفاده از داده‌های آموزشی مناسب در بهبود عملکرد مدل را نشان می‌دهد. در نهایت نقشه کل منطقه مورد مطالعه برای چهار کاربری ساختمان، جنگل، جاده و آب، توسط مدل آموزش یافته، تهیه گردید که در جدول (۴) مشهود است. برای بررسی تاثیر انتخاب الگوریتم بهینه‌ساز در آموزش مدل یادگیری عمیق، علاوه بر بهینه‌ساز Adam، از مدل یادگیری عمیق آموزش دیده مبتنی بر الگوریتم بهینه‌ساز SGD با مولفه‌های یکسان در فراپارامترها، نیز مورد بررسی قرار گرفته و نتایج آن در جدول (۴) آمده است.

جدول (۴)، نشان‌دهنده عملکرد مدل U-Net در تفکیک و طبقه‌بندی کاربری اراضی بر اساس تصاویر هوایی بر با دو الگوریتم بهینه‌ساز Adam و SGD می‌باشد. برای ارزیابی بهتر عملکرد مدل پیشنهادی، نتایج حاصل از مدل U-Net با داده‌های هوایی با قدرت تفکیک ۲۵ سانتی‌متر در باند مرئی با نتایج مطالعات پیشین مقایسه شد. جدول (۵) مقایسه‌ای بین

جدول ۴: نقشه پوشش کاربری توسط معماری U-Net به تفکیک هر بهینه‌ساز برای کل منطقه مورد مطالعه

Table 8: Land cover map generated by the U-Net architecture, separated by each optimizer, for the entire study area

| تهیه شده توسط U-Net<br>(Generated by U-Net)                                         |                                                                                     |                                                                                                                                                                                                                                                      |                                                                                      |
|-------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|
| تصویر اصلی<br>(Original)                                                            | تهیه شده توسط کارشناس خبره<br>(Produced by an Expert)                               | بهینه‌ساز<br>(Optimiser)                                                                                                                                                                                                                             | راهنما<br>(Legend)                                                                   |
|                                                                                     |                                                                                     | Adam                                                                                                                                                                                                                                                 | SGD                                                                                  |
|  |  |                                                                                                                                                                   |  |
|                                                                                     |                                                                                     | <div> <div>Background</div> <div>پس زمینه</div> </div> <div> <div>Building</div> <div>ساختمان</div> </div> <div> <div>Woodland</div> <div>جنگل</div> </div> <div> <div>Water</div> <div>آب</div> </div> <div> <div>Road</div> <div>جاده</div> </div> |                                                                                      |



جدول ۵: ارزیابی عملکرد مدل پیشنهادی با نتایج مطالعات پیشین

Table 5: Evaluation of the proposed model's performance compared to previous studies

| معیار ارزیابی<br>(Evaluation Criteria) |                         |                                  |                               |                          |                                  | مطالعات                             |
|----------------------------------------|-------------------------|----------------------------------|-------------------------------|--------------------------|----------------------------------|-------------------------------------|
| امتیاز ژاکارد<br>(Jaccard Score)       | امتیاز F1<br>(F1 Score) | ضریب کاپا<br>(Kappa Coefficient) | دقت کلی<br>(Overall Accuracy) | بهینه‌ساز<br>(Optimizer) | Studies                          |                                     |
| -                                      | 58.00                   | -                                | 76.00                         | Adam                     | Jonathan Solórzano et al. (2021) | جاناتان سولورزانو و همکاران<br>۲۰۲۱ |
| -                                      | -                       | 78.10                            | 82.20                         | Adam                     | Linh T. Giang et al. (2020)      | توان لین جیانگ و همکاران<br>۲۰۲۰    |
| -                                      | 54.10                   | -                                | 90.50                         | Adam                     | Won-Kyung Baek et al. (2024)     | وون کیونگ باک و همکاران<br>۲۰۲۴     |
| 56.00                                  | -                       | 72.50                            | -                             | Adam                     | Andrew Clark et al. (2023)       | اندرو کلارک و همکاران<br>۲۰۲۳       |
| 54.45                                  | 92.63                   | 79.59                            | 92.47                         | Adam                     | This Study. (2024)               | مطالعه حاضر<br>۲۰۲۴                 |
| 51.71                                  | 15.89                   | 4.51                             | 44.56                         | SGD                      |                                  |                                     |

## نتیجه‌گیری

در این مقاله، به تحلیل و طبقه‌بندی دقیق کاربری اراضی با استفاده از تصاویر هوایی و مدل یادگیری عمیق CNN مبتنی بر معماری U-Net پرداخته شد. نتایج حاصل از این مطالعه نشان‌دهنده عملکرد قوی و دقت بالای مدل در تفکیک انواع کاربری‌های اراضی مختلف می‌باشد. نتایج حاصله توسط سه معیار ارزیابی مهم به صورت زیر است:

○ امتیاز ژاکارد: امتیاز ژاکارد نیز در بررسی عملکرد، مدل ۵۴.۴۵ درصد محاسبه شد. این شاخص که معیار خوبی برای ارزیابی دقت طبقه‌بندی تصویر است، در مدل پیشنهادی بهبود قابل توجهی را نشان داد. مقدار بالای امتیاز ژاکارد نشان‌دهنده توانایی مدل در شناسایی دقیق مرزهای کلاس‌های مختلف است.

○ ضریب کاپا: این ضریب برای ارزیابی توافق بین دسته‌های پیش‌بینی شده توسط مدل و دسته‌های واقعی استفاده می‌شود. ضریب کاپا ۷۹.۵۹ درصد نشان‌دهنده توافق قوی بین نتایج مدل و داده‌های واقعی است.

○ دقت کلی: دقت کلی هدست‌آمده، ۹۲.۴۷ درصد بود که نشان‌دهنده عملکرد خوب مدل در تشخیص و طبقه‌بندی صحیح پیکسل‌های تصاویر هوایی به کلاس‌های مختلف کاربری اراضی می‌باشد. این دقت بالا به دلیل استفاده از ساختار U-Net و بهره‌گیری از لایه‌های کانولوشن و عملیات رمزنگاری و رمزگشایی باشد که ویژگی‌های مکانی و معنایی تصاویر را به خوبی استخراج و پردازش می‌کنند.

مدل U-Net مورد استفاده در این مطالعه با توجه به ساختار ویژه خود توانست به خوبی ویژگی‌های مکانی و بافتی تصاویر هوایی را استخراج کند و به نتایج بسیار مطلوبی در طبقه‌بندی دست یابد. تصاویر خروجی حاصل از این مدل به وضوح نشان‌دهنده توانایی آن در تشخیص و تفکیک مناطق مختلف مانند جنگل‌ها، ساختمان‌ها، جاده‌ها و آب‌ها هستند. بررسی نتایج برای کلاس‌های مختلف کاربری اراضی

(ساختمان‌ها، جنگل‌ها، آب‌ها و جاده‌ها) نشان داد که مدل در شناسایی کلاس‌های با ویژگی‌های بارز مانند ساختمان‌ها و جاده‌ها عملکرد بهتری دارد. این به دلیل ویژگی‌های برجسته و مشخص این کلاس‌ها در تصاویر هوایی است. در مقابل، کلاس‌هایی با ویژگی‌های کمتر مشخص، مانند آب، ممکن است چالش‌های بیشتری برای مدل ایجاد کنند، اگرچه دقت آن‌ها نیز قابل قبول بود. استفاده از الگوریتم Adam برای بهینه‌سازی و تنظیم مناسب نرخ یادگیری و اندازه دسته‌ها به بهبود همگرایی مدل و کاهش خطاهای آموزشی کمک کرد. همچنین، استفاده از لایه‌های نرمال‌سازی دسته و حذف تصادفی به کاهش پدیده بیش‌برازش و بهبود کارایی مدل روی داده‌های جدید کمک کرد. زمان آموزش مدل نیز مورد بررسی قرار گرفت و نتایج نشان داد که با استفاده از بهینه‌ساز Adam و تنظیمات مناسب فرآیند آموزش، مدل توانست در زمان مناسبی به همگرایی برسد. در مقایسه با روش‌های مرسوم و سایر معماری‌های یادگیری عمیق، U-Net با ساختار بهینه‌شده خود، توانسته است مرزهای بین کلاس‌های مختلف کاربری اراضی را با دقت بیشتری تشخیص دهد. این ویژگی‌ها، به همراه استفاده از تصاویر هوایی با قدرت تفکیک بالا و باند مرئی، نشان می‌دهد که مدل پیشنهادی نه تنها در شناسایی دقیق کلاس‌ها مؤثر است بلکه قادر به بهبود قابل توجه دقت کلی طبقه‌بندی نیز می‌باشد. بدین ترتیب، استفاده از این مدل می‌تواند به عنوان رویکردی نوین و کارآمد در تحلیل و طبقه‌بندی کاربری اراضی مورد توجه قرار گیرد.

## پیشنهادهای تحقیقات آتی

با توجه به نتایج حاصل از این پژوهش و به منظور بهبود بیشتر دقت کارایی مدل‌های یادگیری عمیق در طبقه‌بندی کاربری اراضی، پیشنهاد می‌شود از تصاویر چند طیفی و ابرطیفی با ترکیب این تصاویر با داده‌های هوایی بهره‌گیری شود، زیرا این تصاویر می‌توانند اطلاعات بیشتری از



software and true color satellite images. *Sustain.* 2019 Oct 1;11(19). <https://doi.org/10.3390/su11195266>

[4] Kanmani K, Padmanabhan V, Pari P. Accuracy Assessment of different classifiers for Sustainable Development in Landuse and Landcover mapping using Sentinel SAR and Landsat-8 data. *EAI Endorsed Trans Energy Web.* 2023;10:1–10. <https://doi.org/10.4108/ew.4141>

[5] Hao M, Dong X, Jiang D, Yu X, Ding F, Zhuo J. Land-use classification based on high-resolution remote sensing imagery and deep learning models. *PLoS One [Internet].* 2024;19(4 April):1–16. Available from: <http://dx.doi.org/10.1371/journal.pone.0300473>

[6] Boyle SA, Kennedy CM, Torres J, Colman K, Pérez-Estigarribia PE, De La Sancha NU. High-resolution satellite imagery is an important yet underutilized resource in conservation biology. *PLoS One.* 2014;9(1):1–11. <https://doi.org/10.1371/journal.pone.0086908>

[7] Mousavi, S. M., Ebadi, H., & Kiani, A. (2019). An optimized deep learning-based method for the spectral-spatial classification of high-resolution images in semi-urban areas. *Journal of Scientific Research in Surveying Science and Technology*, 9(2), December, 20. [in Persian]

[8] Sawant S, Ghosh JK. Land use land cover classification using Sentinel imagery based on deep learning models. *J Earth Syst Sci [Internet].* 2024 May 24;133(2):101.

[9] Zhao S, Tu K, Ye S, Tang H, Hu Y, Xie C. Land Use and Land Cover Classification Meets Deep Learning: A Review. *Sensors (Basel).* 2023;23(21). <https://doi.org/10.4108/ew.4141>

[10] Khankeshizadeh E, Mohammadzadeh A, Arefi H, Mohsenifar A, Pirasteh S, Fan E, et al. A Novel Weighted Ensemble Transferred U-Net Based Model (WETUM) for Postearthquake Building Damage Assessment From UAV Data: A Comparison of Deep Learning- and Machine Learning-Based Approaches. *IEEE Trans Geosci Remote Sens [Internet].* 2024;62:1–17.

[11] Unnikrishnan A, Sowmya V, Soman KP. Deep learning architectures for land cover classification using red and near-infrared satellite images. *Multimed Tools Appl.* 2019 Jul 15;78(13):18379–94. <https://doi.org/10.1007/s11042-019-7179-2>

[12] Haq MA, Rahaman G, Baral P, Ghosh A. Deep Learning Based Supervised Image Classification Using UAV Images for Forest Areas Classification. *J Indian Soc Remote Sens.* 2021 Mar 1;49(3):601–6. <https://doi.org/10.1007/s12524-020-01231-3>

[13] Baek WK, Lee MJ, Jung HS. Land Cover Classification From RGB and NIR Satellite Images Using Modified U-Net Model. Vol. 12, *IEEE Access.* 2024. p. 69445–55. <https://doi.org/10.1109/ACCESS.2024.3401416>

[14] Giang TL, Dang KB, Le QT, Nguyen VG, Tong SS, Pham VM. U-net convolutional networks for mining land cover classification based on high-resolution UAV imagery. *IEEE Access.* 2020;8:186257–73.

ویژگی‌های کاربری‌های موجود در سطح زمین فراهم کنند و دقت طبقه‌بندی را افزایش دهند. همچنین، ترکیب داده‌های طیفی مختلف به شناسایی بهتر کلاس‌های پیچیده کمک می‌کند. علاوه بر این، پیاده‌سازی و ارزیابی مدل‌های ترکیبی مانند ترکیب معماری U-Net با شبکه‌های توجه (Attention Networks) می‌تواند در تشخیص و تفکیک دقیق‌تر مرزهای کلاس‌های کاربری اراضی موثر باشد. بهینه‌سازی فرآیندها با استفاده از روش‌های جستجوی پیشرفته مانند جستجوی شبکه‌ای (Grid Search) و جستجوی تصادفی (Random Search) نیز به یافتن ترکیب بهینه پارامترها و در نتیجه بهبود کارایی مدل کمک می‌کند. استفاده از روش‌های یادگیری انتقالی و مدل‌های پیش آموزش‌دیده می‌تواند زمان آموزش مدل را کاهش داده و دقت آن را افزایش دهد، به ویژه در شرایطی که داده‌های آموزشی محدود هستند. اجرای این پیشنهادها می‌تواند دقت و کارایی مدل‌های یادگیری عمیق را در طبقه‌بندی کاربری اراضی ارتقا دهد و به کاربردهای گسترده‌تری در زمینه‌های مختلف علمی و عملی منجر شود.

## مشارکت نویسندگان

میزان مشارکت نویسندگان در نگارش این مقاله به شرح زیر است: نویسنده اول مسئولیت گردآوری و آماده‌سازی داده‌ها، انجام محاسبات، تجزیه و تحلیل آماری داده‌ها، تحلیل و تفسیر اطلاعات و نتایج و تهیه پیش‌نویس مقاله را بر عهده داشته است. نویسنده دوم به عنوان استاد راهنمای پژوهش، در طراحی پژوهش، نظارت بر مراحل انجام آن، بررسی و کنترل نتایج و همچنین اصلاح، بازبینی و نهایی‌سازی مقاله نقش داشته است. نویسنده سوم نیز در طراحی پژوهش مشارکت داشته و در مطالعه و بازبینی مقاله همکاری کرده است.

## تشکر و قدردانی

نویسندگان مقاله از تمامی عزیزانی که در این تحقیق همکاری داشته‌اند، کمال قدردانی و سپاس خود را اعلام می‌نمایند.

## تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است»

## منابع و مآخذ

- [1] Dyson J, Mancini A, Frontoni E, Zingaretti P. Deep learning for soil and crop segmentation from remotely sensed data. *Remote Sens.* 2019;11(16). <https://doi.org/10.3390/rs11161859>
- [2] Khan BA, Jung J woo. applied sciences Semantic Segmentation of Aerial Imagery Using U-Net with Self-Attention and Separable Convolutions. 2024. <https://doi.org/10.3390/app14093712>
- [3] Chapa F, Hariharan S, Hack J. A new approach to high-resolution urban land use classification using open access

hyperspectral remote sensing image classification. *Int J Remote Sens* [Internet]. 2020;41(7):2664–83. Available from: <https://doi.org/10.1080/01431161.2019.1694725>

[27] Pashaei M, Kamangir H, Starek MJ, Tissot P. Review and evaluation of deep learning architectures for efficient land cover mapping with UAS hyper-spatial imagery: A case study over a wetland. *Remote Sens*. 2020 Mar 1;12(6). <https://doi.org/10.3390/rs12060959>

[28] Thompson WD, Walter SD. A reappraisal of the kappa coefficient. *J Clin Epidemiol* [Internet]. 1988 Jan;41(10):949–58.

[29] Fletcher S, Isla MZ. Comparing sets of patterns with the Jaccard index. Vol. 22, *Australasian Journal of Information Systems*. 2018. <https://doi.org/10.3127/ajis.v22i0.1538>

[30] M H, M.N S. A Review on Evaluation Metrics for Data Classification Evaluations. *Int J Data Min Knowl Manag Process* [Internet]. 2015 Mar 31;5(2):01–11. Available from: <http://www.aircconline.com/ijdkp/V5N2/5215ijdkp01.pdf>. <https://doi.org/10.5121/ijdkp.2015.5201>

[31] Boguszewski A, Batorski D, Ziemba-Jankowska N, Dziedzic T, Zambrzycka A. LandCover.ai: Dataset for Automatic Mapping of Buildings, Woodlands, Water and Roads from Aerial Imagery. 2020 May 5.

## معرفی نویسندگان

### AUTHOR(S) BIOSKETCHES



**مهدی فرهنگ‌ی** فارغ‌التحصیل مهندسی نقشه‌برداری از دانشگاه صنعتی اراک در سال ۱۴۰۲ است و در حال حاضر به عنوان دانشجوی استعداد درخشان در مقطع کارشناسی ارشد فتوگرامتری در دانشگاه شهید بهشتی مشغول به تحصیل است. او دارای سابقه فعالیت‌های علمی و پژوهشی

متعددی است که شامل مقالات پذیرش شده در حوزه‌های مختلفی از جمله پایش تغییرات کاربری اراضی، ارزیابی دقت روش‌های طبقه‌بندی در تحلیل کاربری اراضی، مدل‌سازی سری زمانی مکانی TEC یونسفری با استفاده از یادگیری ماشین و شبکه‌های عصبی و ارزیابی نظام کاداستر معدن می‌باشد.

وی همچنین به عنوان دبیر انجمن علمی نقشه‌برداری دانشگاه صنعتی اراک در سال‌های ۱۳۹۹ و ۱۴۰۰ فعالیت داشته است. او با تمرکز بر کاربرد هوش مصنوعی و به‌ویژه مدل‌های یادگیری عمیق در حوزه فتوگرامتری و سنجش از دور، به پژوهش و فعالیت‌های علمی در این زمینه‌ها پرداخته است.

**Farhangi, M., M.Sc. Student in Photogrammetry, Faculty of Civil, Water, and Environmental Engineering, Shahid Beheshti University, Tehran, Iran.**

✉ [m.farhangi@sbu.ac.ir](mailto:m.farhangi@sbu.ac.ir)

<https://doi.org/10.1109/ACCESS.2020.3030112>

[15] Solórzano J V., Mas JF, Gao Y, Gallardo-Cruz JA. Land use land cover classification with U-net: Advantages of combining sentinel-1 and sentinel-2 imagery. Vol. 13, *Remote Sensing*. 2021. <https://doi.org/10.3390/rs13183600>

[16] Clark A, Phinn S, Scarth P. Optimised U-Net for Land Use–Land Cover Classification Using Aerial Photography. *PFG – J Photogramm Remote Sens Geoinf Sci* [Internet]. 2023 Apr 13;91(2):125–47. Available from: <https://link.springer.com/10.1007/s41064-023-00233-3>. <https://doi.org/10.1007/s41064-023-00233-3>

[17] Al-Najjar HAH, Kalantar B, Pradhan B, Saeidi V, Halin AA, Ueda N, et al. Land cover classification from fused DSM and UAV images using convolutional neural networks. *Remote Sens*. 2019 Jun 1;11(12). <https://doi.org/10.3390/rs11121461>

[18] Mohrrami, M., & Nisani Samani, N. (2021). Comparison of deep learning and random forest methods in urban land cover classification (Case study: Tabriz city). *Journal of Scientific Research in Surveying Science and Technology*, 11(4), June, 23–11. [in Persian]

[19] Yadav TK, Chidburee P, Mahavik N. Land cover classification based on uav photogrammetry and deep learning for supporting mine reclamation: A case study of mae moh mine in lampang province, thailand. *Appl Environ Res*. 2021;43(4):39–54. <https://doi.org/10.35762/AER.2021.43.4.4>

[20] Yang S, Xiao W, Zhang M, Guo S, Zhao J, Shen F. Image Data Augmentation for Deep Learning: A Survey. 2022.

[21] Cubuk ED, Zoph B, Mane D, Vasudevan V, Le Q V. Autoaugment: Learning augmentation strategies from data. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognit*. 2019;2019-June(Section 3):113–23. <https://doi.org/10.1109/CVPR.2019.00020>

[22] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation BT - *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. In: Navab N, Hornegger J, Wells WM, Frangi AF, editors. Cham: Springer International Publishing; 2015. p. 234–41. <https://doi.org/10.3390/rs11121461>

[23] Omi T, Ueda N, Aihara K. Fully neural network based model for general temporal point processes. In: *Advances in Neural Information Processing Systems*. 2019.

[24] Trabelsi K, Ammar A, Masmoudi L, Boukhris O, Chtourou H, Bouaziz B, et al. Sleep Quality and Physical Activity as Predictors of Mental Wellbeing Variance in Older Adults during COVID-19 Lockdown: ECLB COVID-19 International Online Survey. *Int J Environ Res Public Health* [Internet]. 2021 Apr 19;18(8):4329.

[25] Zhou Z, Rahman Siddiquee MM, Tajbakhsh N, Liang J. UNet++: A Nested U-Net Architecture for Medical Image Segmentation. In 2018. p. 3–11.

[26] Bera S, Shrivastava VK. Analysis of various optimizers on deep convolutional neural network model in the application of



**سعید صادقیان** دانشیار گروه مهندسی نقشه برداری در دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی، دارای مدرک دکتری از دانشگاه تهران در رشته مهندسی نقشه برداری- فتوگرامتری است. وی علاوه بر تدریس در دانشگاه، دارای

سوابق علمی و اجرایی بسیاری نیز می باشد. او به عنوان عضو هیات تحریریه نشریه علمی پژوهش های سنجش از دور و اطلاعات مکانی فعالیت دارد و تجربه ریاست آموزشکده نقشه برداری سازمان نقشه برداری کشور در بازه زمانی ۱۳۸۵ تا ۱۳۹۲ را نیز دارا می باشد.

**Sadeghian, S.** Associate Professor at the Department of Surveying Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

✉ [sa\\_sadeghian@sbu.ac.ir](mailto:sa_sadeghian@sbu.ac.ir)



**اصغر میلان** استادیار گروه مهندسی نقشه برداری در دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی، دارای مدرک دکتری از دانشگاه صنعتی خواجه نصیرالدین طوسی در رشته مهندسی نقشه برداری- فتوگرامتری می باشد. ایشان تا کنون

موفق به چاپ مقالات متعدد در مجلات و کنفرانس های داخلی و بین المللی معتبر شده اند. زمینه های تخصصی ایشان عبارتند از: فتوگرامتری، سنجش از دور، کاداستر و پردازش تصاویر می باشد

**Milan, A.** Assistant Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

✉ [a\\_milan@sbu.ac.ir](mailto:a_milan@sbu.ac.ir)

**Citation (Vancouver):** Farhangi M, Milan A, Sadeghian S. [Analysis and classification of land use using aerial imagery and deep learning based on U-Net architecture]. *J. RS. GEOINF. RES.* 2024; 2(2): 277-292

 <https://doi.org/10.22061/jrsgr.2024.11250.1083>



#### 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/>)