

## Evaluation of optimizers' performance in U-Net and ResNet-34 deep learning models for accurate land use classification from aerial images

Mahdi Farhangi<sup>1</sup> , Mohammad Mahdi Esfandiary<sup>2</sup> , Asghar Milan\*<sup>3</sup> , Saeid Sadeghian<sup>4</sup>

1- Master's student in photogrammetry, Faculty of civil engineering, Water and environmental engineering, Shahid Beheshti University, Tehran, Iran.  
 Email: [ma.farhangi@mail.sbu.ac.ir](mailto:ma.farhangi@mail.sbu.ac.ir)

2- Bachelor's student in surveying engineering, Faculty of civil engineering, Water and environmental engineering, Shahid Beheshti University, Tehran, Iran . Email: [mo.esfandiary@mail.sbu.ac.ir](mailto:mo.esfandiary@mail.sbu.ac.ir)

3- (\*Corresponding author) Assistant professor, Faculty of civil engineering, Water and environmental engineering, Shahid Beheshti University, Tehran, Iran. Email: [a\\_milan@sbu.ac.ir](mailto:a_milan@sbu.ac.ir)

4- Associate professor, Faculty of civil engineering, Water and environmental engineering, Shahid Beheshti University, Tehran, Iran.  
 Email: [sa\\_sadeghian@sbu.ac.ir](mailto:sa_sadeghian@sbu.ac.ir)

### Article Info

#### Date of receive:

2025/01/02

#### Date of last review:

2025/06/28

#### Date of accept:

2025/06/28

#### Date of online publication:

2025/06/28

#### Keywords:

Land use classification,  
 Aerial imagery,  
 Optimizer,  
 U-Net,  
 ResNet

### Extended Abstract

#### Introduction

Accurate land use classification using deep learning models has become a crucial aspect of remote sensing and geographic information systems (GIS), enabling precise monitoring and management of natural and urban environments. In recent years, convolutional neural networks (CNNs) have gained significant attention in image segmentation and classification tasks, particularly due to their ability to automatically extract hierarchical spatial features. Among these, U-Net and ResNet-34 have demonstrated remarkable success in remote sensing applications, with U-Net excelling in pixel-wise segmentation tasks and ResNet-34 offering deeper feature extraction capabilities. Despite the success of deep learning models, their performance is highly influenced by the choice of optimization algorithm. Optimizers play a fundamental role in adjusting model parameters, impacting convergence speed, computational efficiency, and generalization ability. Selecting an appropriate optimizer is crucial to ensuring that the model effectively learns complex spatial patterns while minimizing classification errors. However, the comparative impact of different optimizers on U-Net and ResNet-34 for land use classification remains underexplored. This study aims to evaluate the effectiveness of six optimizers—SGD, Adam, RMSprop, Adagrad, Nadam, and AdamW—when applied to U-Net and ResNet-34 for land use classification using high-resolution aerial imagery. The research primarily focuses on assessing how different optimization techniques influence classification accuracy, model stability, and computational efficiency in remote sensing applications ... ▶ Page 08

### How to Cite:

Farhangi, M. Esfandiary, M.M. Milan, A. Sadeghian, S. (2025). Evaluation of optimizers' performance in U-Net and ResNet-34 deep learning models for accurate land use classification from aerial images. Scientific - Research Quarterly Geographical Data (SEPEHR). 34(134), 07-31.

The findings provide insights into the most suitable optimizer for training deep learning models for land use classification, thereby assisting future research and practical implementations.

### Materials and Methods

The dataset used in this study comprises aerial images from selected regions in Poland, which were obtained from high-resolution remote sensing data sources. These images were pre-processed and divided into three sets: training, validation, and testing. In total, 616 labeled images (256×256 pixels each) were utilized, with 462 images allocated for training, 154 for validation, and 15 for final testing. Given the limited dataset size, data augmentation techniques such as horizontal and vertical flipping, rotation at different angles, and brightness adjustments were applied to enhance model generalization and prevent overfitting. Both U-Net and ResNet-34 were implemented using Python, TensorFlow, and Keras, and the training was conducted in Google Colab's cloud environment to utilize GPU acceleration for efficient computation. Each model was trained using the six selected optimizers, with hyperparameters tuned to achieve optimal performance. Model evaluation was conducted based on multiple performance metrics, including Overall Accuracy, Kappa Coefficient, F1-score, Jaccard Index, Mean Absolute Error, and Allocation Discrepancy. To better understand the impact of each optimizer on model convergence and training stability, training and validation loss curves were analyzed, allowing for an assessment of optimization efficiency and the prevention of issues such as gradient vanishing or overfitting. Furthermore, the training epochs were scaled using a custom epoch compression technique, ensuring that the optimization progress was clearly visualized without excessive data compression.

### Results and Discussion

The experimental results confirmed that ResNet-34 consistently outperformed U-Net across all evaluation metrics, emphasizing the importance of deeper architectures in enhancing classification accuracy. The superior performance of ResNet-34 can be attributed to its residual learning framework, which facilitates efficient feature propagation and mitigates gradient vanishing issues, making it particularly effective for remote sensing image classification. Among the evaluated optimizers, RMSprop and Adam yielded the highest classification accuracies, ensuring faster convergence and lower classification errors. The best accuracy achieved in ResNet-34 was 87.54% using RMSprop, whereas in U-Net, the highest accuracy was 77.17%. These results suggest that adaptive optimizers like RMSprop and Adam dynamically adjust learning rates, leading to more efficient weight updates and improved generalization. Conversely, Adagrad demonstrated the weakest performance, achieving 83.71% accuracy in ResNet-34

and 77.87% in U-Net, which can be attributed to its aggressive learning rate decay, causing stagnation in later training epochs. Similarly, SGD exhibited slower convergence, resulting in lower classification accuracy compared to adaptive methods. These findings align with previous research, which suggests that adaptive optimizers, particularly Adam and RMSprop, enhance deep learning model generalization and classification precision. Additionally, comparisons with prior studies revealed that many recent works utilize Mean Intersection over Union (MIoU) and Frequency-Weighted IoU (FWIoU) as key performance indicators. Although these metrics were not directly employed in the present study, their relevance in remote sensing classification underscores the importance of optimizing segmentation models for both pixel-wise accuracy and spatial consistency.

### Conclusion

This study demonstrated that the choice of optimizer significantly impacts the accuracy, efficiency, and stability of U-Net and ResNet-34 models in land use classification. ResNet-34 consistently achieved higher accuracy compared to U-Net, reinforcing the advantage of deeper architectures in aerial image processing. Among the optimizers, RMSprop and Adam emerged as the most effective, delivering faster convergence rates, higher classification accuracies, and improved generalization. Meanwhile, SGD and Adagrad exhibited slower convergence and lower classification accuracy, indicating that their static learning rate mechanisms are less suitable for complex remote sensing datasets.

For future research, it is recommended to explore hybrid optimization strategies, where SGD is employed during early training stages to enhance generalization, followed by adaptive optimizers like Adam or RMSprop to accelerate convergence and stabilize learning. Moreover, further investigations into emerging optimization techniques, such as Lion, AdaBelief, and RAdam, could provide valuable insights into their potential applications in deep learning-based remote sensing tasks. Additionally, the integration of advanced architectures, such as U-Net++, UNet3+, and Transformer-based segmentation models, could further improve classification precision by capturing multi-scale spatial features more effectively. Expanding the dataset to include multi-resolution and multi-spectral aerial imagery would also enable a more comprehensive assessment of optimizer adaptability across diverse geospatial environments. Overall, these findings emphasize that careful selection of the optimizer is essential for maximizing deep learning model performance in remote sensing applications. By incorporating advanced optimization techniques and architectural innovations, future studies can further enhance the accuracy and robustness of land use classification models, ultimately contributing to more efficient environmental monitoring and urban planning.



صفحات ۳۱ - ۰۷

## فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۴، شماره ۱۳۴، تابستان ۱۴۰۴



مقاله پژوهشی

doi <https://doi.org/10.22131/sepehr.2025.2049444.3113>

## ارزیابی عملکرد بهینه‌سازها در مدل‌های یادگیری عمیق U-Net و ResNet-34

## برای طبقه‌بندی دقیق کاربری اراضی از تصاویر هوایی

مهدی فرهنگ‌ی<sup>۱</sup>، محمدمهدی اسفندیاری<sup>۲</sup>، اصغر میلان<sup>۳\*</sup>، سعید صادقیان<sup>۴</sup>

۱- دانشجوی کارشناسی ارشد فتوگرامتری دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، تهران، ایران [ma.farhangi@mail.sbu.ac.ir](mailto:ma.farhangi@mail.sbu.ac.ir)  
 ۲- دانشجوی کارشناسی مهندسی نقشه‌برداری دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، تهران، ایران [mo.esfandiary@mail.sbu.ac.ir](mailto:mo.esfandiary@mail.sbu.ac.ir)  
 ۳- (\*نویسنده مسئول) استادیار دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، تهران، ایران [a\\_milan@sbu.ac.ir](mailto:a_milan@sbu.ac.ir)  
 ۴- دانشیار دانشکده مهندسی عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، تهران، ایران [sa\\_sadeghian@sbu.ac.ir](mailto:sa_sadeghian@sbu.ac.ir)

## چکیده

مطالعه کاربری اراضی و تغییرات آن در دوره‌های زمانی نقشی کلیدی در مدیریت منابع طبیعی و برنامه‌ریزی شهری ایفا می‌کند. یکی از روش‌های بهینه و مقرون به صرفه در این زمینه استفاده از الگوریتم‌ها و روش‌های طبقه‌بندی تصاویر هوایی و سنجش از دور است. طبقه‌بندی تصاویر هوایی با استفاده از مدل‌های یادگیری عمیق یکی از روش‌های پیشرفته در پردازش داده‌های مکانی محسوب می‌شود که بهبود صحت و کارایی آن به انتخاب مدل مناسب و تنظیم بهینه فرآیندها بستگی دارد. در این پژوهش، عملکرد دو مدل یادگیری عمیق U-Net و ResNet-34 در ترکیب با شش بهینه‌ساز مختلف شامل Adam، SGD، AdamW، Nadam، Adagrad، RMSprop بررسی شده است. نتایج نشان داد که ResNet-34 در تمامی معیارهای ارزیابی عملکرد بهتری نسبت به U-Net ارائه داده است. بالاترین صحت کلی در مدل ResNet-34 با بهینه‌ساز RMSprop برابر با ۸۷/۵۴٪ بود، در حالی که همین بهینه‌ساز در مدل U-Net صحت ۷۷/۱۷٪ را به دست آورد. بهینه‌ساز Adam نیز در ResNet-34 صحت ۸۳/۹۷٪ و در U-Net صحت ۶۳/۳۰٪ را ارائه داد. در مقابل، بهینه‌ساز Adagrad ضعیف‌ترین عملکرد را داشت و همگرایی کندی نشان داد. تحلیل معیارهای ضریب کاپا، امتیاز ژاکارد و امتیاز F1 تأیید کرد که بهینه‌سازهای تطبیقی مانند RMSprop و Adam تأثیر مثبتی بر بهبود صحت مدل‌ها دارند. نتایج این تحقیق نشان داد که انتخاب مدل مناسب و بهینه‌ساز کارآمد نقش مهمی در افزایش صحت و کاهش خطای مدل‌های یادگیری عمیق دارد. در مطالعات آینده، بررسی بهینه‌سازی ترکیبی روش‌های کلاسیک و تطبیقی و استفاده از مدل‌های پیشرفته‌تر مانند U-Net++ و بهینه‌سازهای نوظهور نظیر Lion، AdaBelief و RAdam پیشنهاد می‌شود.

## اطلاعات مقاله

تاریخ دریافت:

۱۴۰۳/۱۰/۱۳

تاریخ آخرین بازنگری:

۱۴۰۴/۰۴/۰۷

تاریخ پذیرش:

۱۴۰۴/۰۴/۰۷

تاریخ انتشار:

۱۴۰۴/۰۴/۰۷

## واژه‌های کلیدی:

طبقه‌بندی کاربری

اراضی؛

تصویر هوایی؛

بهینه‌ساز؛

مدل‌های یادگیری عمیق

ResNet-34 و U-Net

## استناد به این مقاله:

فرهنگی، م؛ اسفندیاری، م.م؛ میلان، الف؛ صادقیان، س (۱۴۰۴) ارزیابی عملکرد بهینه‌سازها در مدل‌های یادگیری عمیق U-Net و ResNet-34 برای طبقه‌بندی دقیق کاربری اراضی از تصاویر هوایی؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۴ (۱۳۴)، ۳۱-۰۷.

## ۱- مقدمه

پیچیده و با ابعاد بالا، نتایج بهتری به دست دادند (Digra,

*Dhir, & Sharma, 2022*)

SVM برای تفکیک داده‌ها با مرزهای غیرخطی و RF با ترکیب چندین درخت تصمیم‌گیری صحت بالاتری داشتند (Talukdar et al., 2020). با ظهور روش‌های یادگیری عمیق، مدل‌هایی مانند U-Net که از ساختار شبکه عصبی کانولوشنی (CNN) استفاده می‌کنند، موفقیت‌های چشمگیری در طبقه‌بندی تصاویر ماهواره‌ای با صحت بالا کسب کردند (Xu et al., 2020). این مدل به‌ویژه برای پردازش تصاویر هوایی با وضوح بالا کاربرد دارد. علاوه بر این، مدل‌های ViTs<sup>۶</sup> نیز اخیراً در برخی کاربردها نتایج مشابه یا بهتری نسبت به CNN‌ها نشان داده‌اند. اما به دلیل نیاز به داده‌های آموزشی بزرگ و پیچیدگی محاسباتی بالاتر، هنوز مدل‌هایی مانند U-Net به دلیل کارایی بالاتر و نیاز کمتر به داده‌های آموزشی ترجیح داده می‌شوند (Bazi et al., 2021).

با این وجود، تحقیقاتی برای غلبه بر این چالش‌ها انجام شده است. به‌عنوان نمونه، Naanjam و Farnood Ahmadi (۲۰۲۴) یک شبکه خودآموزی بهبودیافته برای استخراج ساختمان‌ها و جاده‌ها از داده‌های سنجش از دور نوری و راداری پیشنهاد کرده‌اند که می‌تواند برای مطالعه حاضر مفید باشد (Naanjam & Farnood Ahmadi, 2024). در این میان، بهینه‌سازها نقش حیاتی در بهبود عملکرد مدل‌های یادگیری عمیق ایفا می‌کنند. بهینه‌سازها با تنظیم و به‌روزرسانی وزن‌ها و بایاس‌ها براساس گرادینان‌های محاسبه شده از تابع هزینه، به کاهش خطا و بهبود صحت کلی مدل‌ها کمک می‌کنند (Hassan, Shams, Hikal, & Elmougy, 2023). علاوه بر این، بهینه‌سازها با مدیریت نرخ یادگیری و استفاده از تکنیک‌های خاص برای تنظیم دینامیکی این نرخ، فرآیند یادگیری را پایدارتر و کارآمدتر می‌سازند (Bera & Shrivastava, 2020). از این رو، انتخاب و تنظیم بهینه‌ساز مناسب به یکی از چالش‌های کلیدی در حوزه یادگیری عمیق تبدیل شده است، به‌ویژه در کاربردهایی مانند تحلیل

طبقه‌بندی دقیق کاربری اراضی از تصاویر هوایی با وضوح بالا یکی از چالش‌های مهم در حوزه فتوگرامتری، سنجش از دور و علوم جغرافیایی است (Kampffmeyer, Salberg, & Jenssen, 2016). این موضوع نقش حیاتی در مدیریت منابع طبیعی، برنامه‌ریزی شهری، و پایش تغییرات محیطی دارد (Saeedizadeh, Jalali, Khan, Kebria, & Mohamed, 2024). روش‌های سنتی طبقه‌بندی، علی‌رغم کاربرد گسترده، معمولاً به دلیل وابستگی به ویژگی‌های دستی و محدودیت در شناسایی الگوهای پیچیده موجود در داده‌ها، صحت کافی را ارائه نمی‌دهند. با ظهور فناوری‌های یادگیری عمیق، امکان استخراج خودکار ویژگی‌های پیچیده و انجام طبقه‌بندی‌های دقیق‌تر فراهم شده است. بنابراین، بررسی و ارزیابی مدل‌های یادگیری عمیق برای ارتقای صحت در طبقه‌بندی کاربری اراضی، امری ضروری و اجتناب‌ناپذیر به نظر می‌رسد (Audebert, Le Saux, & Lefèvre, 2018).

در گذشته، از طرق مختلفی برای طبقه‌بندی تصاویر هوایی و ماهواره‌ای مانند آستانه‌گذاری، روش‌های آماری و کاهش ابعاد داده‌ها استفاده می‌شد که محدودیت‌هایی داشتند (Lakshminarayana & Rao, 2010). روش‌های آستانه‌گذاری در داده‌های ساده خوب عمل می‌کردند، اما در داده‌های پیچیده صحت کمتری داشتند (El fallah, El kharrim, & Belghyti, 2024). روش‌های آماری، نظیر طبقه‌بندی بیشترین شباهت<sup>۱</sup>، برای داده‌هایی که از توزیع نرمال تبعیت می‌کنند، مناسب بودند ولی در داده‌های پیچیده و غیرنرمال کارایی لازم را نداشتند (Strahler, 1980). همچنین، روش‌های کاهش ابعاد مانند PCA<sup>۲</sup> به دلیل از دست دادن اطلاعات مهم، صحت محدودی ارائه می‌دادند (Zhang et al., 2019). با پیشرفت در یادگیری ماشین، روش‌هایی چون ماشین بردار پشتیبان (SVM)<sup>۳</sup> و جنگل تصادفی (RF)<sup>۴</sup> به‌ویژه برای داده‌های

1- Maximum Likelihood Classification

2- Principal Component Analysis

3- Support Vector Machine

4- Random Forest

5- Convolutional Neural Network

6- Vision Transformer (ViTs)

در مطالعه‌ای توسط باک<sup>۹</sup> و همکاران نیز، از Nadam برای بهینه‌سازی مدل‌های یادگیری عمیق مانند SiU-Net استفاده شد. نتایج نشان داد که SiU-Net بهینه‌شده با Nadam با ارائه صحت کلی بالاتر و کاهش تأثیر عدم توازن داده‌ها، توانست عملکرد بهتری نسبت به مدل‌های DeepLabV 3+ و U-Net ارائه دهد (Baek, Lee, & Jung, 2024).

هیتون<sup>۱۰</sup> و همکاران با معرفی RMSProp<sup>۱۱</sup> به‌عنوان یک روش بهینه‌سازی برای مسائل یادگیری عمیق، توانستند مشکلات نوسانات نرخ یادگیری در روش‌های سنتی را برطرف کنند (Hinton, Srivastava, & Swersky, 2012).

همچنین AdamW که توسط لوشچیلوف و هاتر<sup>۱۲</sup> (۲۰۱۹) معرفی شد، نسخه‌ای اصلاح‌شده از Adam است که با هدف جداسازی کاهش وزن<sup>۱۳</sup> از گرادیان به‌روزرسانی طراحی شده است (Loshchilov & Hutter, 2019). در مطالعه اخیر توسط محققین دانشگاه صنعتی راجکوت هند، بهینه‌ساز RMSProp به‌همراه سایر بهینه‌سازها مانند AdamW، Adam و SGD برای بهبود مدل LL-UNET به‌کار گرفته شده است. این مطالعه نشان داد که RMSProp و AdamW در استخراج سریع و دقیق ساختمان‌ها از تصاویر هوایی، عملکرد قابل توجهی دارند و باعث کاهش خطای مدل در نمونه‌های محدود می‌شوند (Koringa & Patel, 2024).

دوچی<sup>۱۴</sup> و همکاران با معرفی Adagrad<sup>۱۵</sup> گامی مهم در جهت بهینه‌سازی نرخ یادگیری تطبیقی برداشتند. این روش با محاسبه مجموع مربعات گرادیان‌ها و تنظیم نرخ یادگیری براساس آن، توانست در مسائل با ویژگی‌های پراکنده به‌خوبی عمل کند (Duchi, Elad, & Yoram, 2012).

در پژوهش اخیر فن<sup>۱۶</sup> و همکاران، از Adagrad برای بهینه‌سازی شبکه‌های یادگیری عمیق برای تشخیص اهداف

تصاویر هوایی با وضوح بالا که صحت و کارایی مدل‌ها اهمیت بالایی دارد.

در راستای بهینه‌سازی مدل‌های یادگیری عمیق و بررسی نقاط قوت و ضعف بهینه‌سازهای مختلف، مطالعات بسیاری انجام شده است. روش گرادیان نزولی تصادفی (SGD)<sup>۱</sup> یکی از قدیمی‌ترین الگوریتم‌های بهینه‌سازی است که توسط رابینز و مونرو<sup>۲</sup> معرفی شد. این روش ساده و کارآمد به دلیل عملکرد مناسب در مسائل با داده‌های بزرگ و نرخ یادگیری ثابت شناخته شده است (Robbins & Monro, 1951).

اخیراً نیز در مطالعه‌ای توسط دینگ<sup>۳</sup> و همکاران، بهینه‌ساز SGD در آموزش مدل‌های U-Net، Res-FCN، SCIMF-Net و SE-U-Net برای استخراج اطلاعات کاربری و پوشش زمین از تصاویر سنجنش از دور به‌کار گرفته شد (Ding, Wang, Peng, Shao, & Deng, 2024).

بهینه‌ساز Adam<sup>۴</sup> که توسط کینگما و باء<sup>۵</sup> معرفی شد، یکی از پرکاربردترین بهینه‌سازها در یادگیری عمیق است و توانسته است عملکرد چشمگیری در مسائل پیچیده ارائه دهد (Kingma & Ba, 2014).

مطالعه غزنوی<sup>۶</sup> و همکاران نشان داد که این بهینه‌ساز همچنان یکی از انتخاب‌های اصلی برای آموزش مدل‌های U-Net، از جمله نسخه‌های ساده، Residual Attention، VGG16-U-Net و U-Net در مسائل مرتبط با طبقه‌بندی تصاویر ماهواره‌ای و استخراج اطلاعات از منابع آبی است (Ghaznavi, Saberioon, Brom, & Itzerott, 2024).

روش Nadam<sup>۷</sup> توسط دوزات<sup>۸</sup> معرفی شد و نسخه‌ای بهبود یافته از Adam با ترکیب نرمال‌سازی نرخ یادگیری و Nesterov Momentum بود که توانست عملکرد بهتری در مسائل پیچیده ارائه دهد (Dozat, 2016).

9- Baek

10- Hinton

11- Root Mean Square Propagation

12- Loshchilov & Hutter

13- Weight Decay

14- Duchi

15- Adaptive Gradient Algorithm

16- Fan

1- Stochastic Gradient Descent

2- Robbins & Monro

3- Ding

4- Adaptive Moment Estimation

5- Kingma & Ba

6- Ghaznavi

7- Nesterov-accelerated Adaptive Moment Estimation

8- Dozat

تابع هزینه، ابعاد جستجو و انواع شرط توقف ارزیابی می‌شوند. این ویژگی‌ها تأثیر قابل توجهی بر عملکرد مدل دارند و در انتخاب بهینه‌ساز مناسب برای یک مسئله خاص اهمیت دارند.

#### • سرعت همگرایی

سرعت همگرایی میزان کاهش تابع هزینه در هر گام یادگیری را تعیین می‌کند. بهینه‌سازهایی که از نرخ یادگیری تطبیقی استفاده می‌کنند، معمولاً سرعت همگرایی بالاتری دارند. در مقابل، روش‌هایی با نرخ یادگیری ثابت ممکن است در مسائل پیچیده زمان بیشتری برای رسیدن به همگرایی نیاز داشته باشند.

#### • میزان پایداری

پایداری به توانایی یک بهینه‌ساز در جلوگیری از نوسانات شدید و حرکت تدریجی به سمت مقدار بهینه مربوط است. روش‌هایی که از میانگین‌گیری گرادینان‌ها یا کاهش تطبیقی نرخ یادگیری بهره می‌برند، معمولاً پایداری بیشتری دارند. در مقابل، روش‌های ساده‌تر ممکن است نوسانات بیشتری را تجربه کنند و نیاز به تنظیم دقیق‌تری داشته باشند.

#### • پیچیدگی تابع و غیرخطی بودن آن

در مسائل با توابع هزینه پیچیده و غیرخطی، بهینه‌سازهایی که از میانگین‌گیری گرادینان‌های گذشته و اصلاحات مبتنی بر شتاب استفاده می‌کنند، عملکرد بهتری دارند. روش‌های ساده‌تر ممکن است در یافتن بهینه‌های مناسب دچار مشکل شوند، به‌ویژه در مسائلی که دارای توابع هزینه با سطح‌های پیچیده هستند.

#### • ابعاد جستجو

مدل‌های یادگیری عمیق شامل تعداد زیادی پارامتر قابل یادگیری هستند که منجر به افزایش ابعاد فضای جستجو می‌شود. بهینه‌سازهایی که نرخ یادگیری هر پارامتر را به‌طور مستقل تنظیم می‌کنند، معمولاً در این شرایط عملکرد بهتری دارند. در مقابل، روش‌هایی که از نرخ یادگیری یکنواخت استفاده می‌کنند، ممکن است در فضاهای پارامتری با ابعاد بالا دچار مشکلاتی مانند گیر افتادن در بهینه‌های محلی شوند.

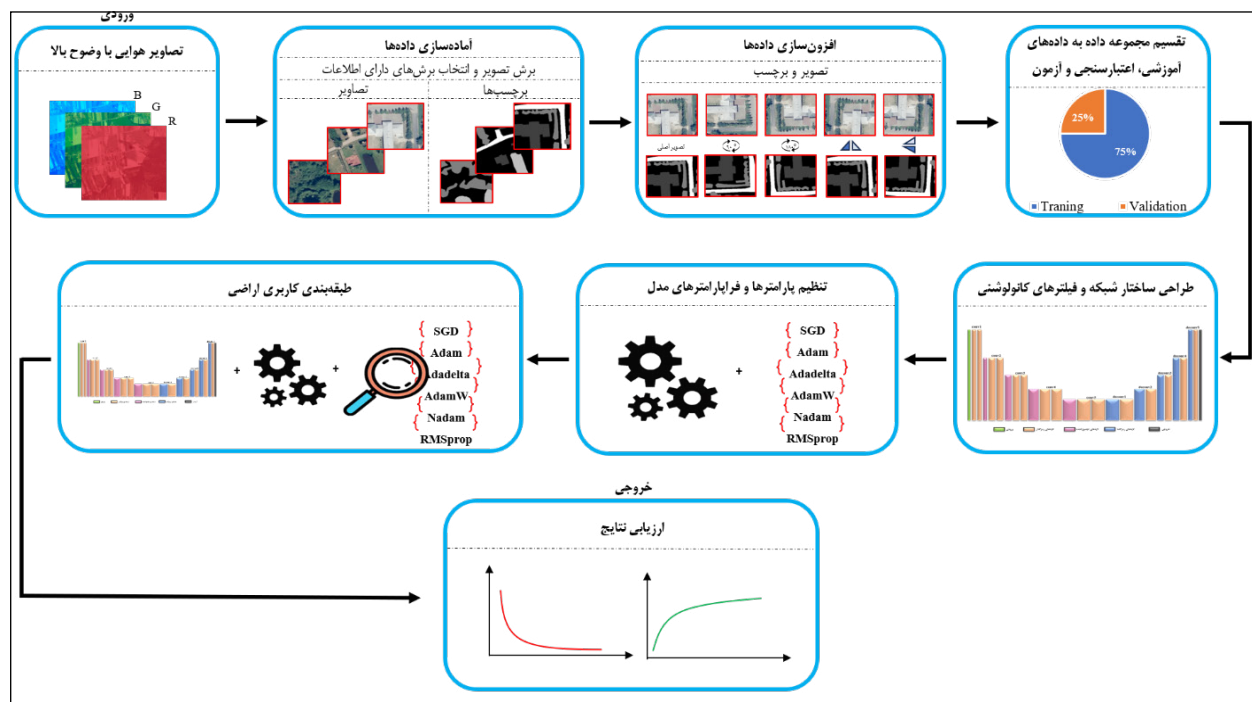
کوچک در تصاویر مادون قرمز استفاده شد. این مطالعه نشان داد که عملکرد مدل MST-UNet بهبود پیدا کرد (Fan et al., 2024). روش Adadelta که توسط زایلر<sup>۱</sup> معرفی شد، به‌عنوان نسخه بهبود یافته Adagrad مطرح شد و توانست از کاهش شدید نرخ یادگیری در طول زمان جلوگیری کند (Zeiler, 2012). در مطالعه اخیر توسط واساوی<sup>۲</sup> و همکاران، از Adadelta برای بهینه‌سازی مدل U-Net در طبقه‌بندی اشیاء از تصاویر ماهواره‌ای با وضوح بسیار بالا استفاده شد و نشان داد که انتخاب بهینه‌ساز مناسب نقش مؤثری در تفکیک و طبقه‌بندی دقیق اشیایی مانند ساختمان‌ها، جاده‌ها و آب‌ها ایفا می‌کند (Vasavi, Likhitha, Premchand, & Yasaswini, 2024).

بررسی مطالعات گذشته نشان می‌دهد که مدل U-Net و ساختارهای پایه‌ای<sup>۳</sup> آن مانند VGG 16، نسخه‌های گوناگون ResNet، InceptionV3 و دیگر مدل‌ها، همراه با بهینه‌سازهای مختلف، به‌طور گسترده در زمینه‌های بسیاری کاربرد دارند. لازم به‌ذکر است که در مدل‌های یادگیری عمیق، ساختار پایه، به معماری پایه‌ای اطلاق می‌شود که مسئول استخراج ویژگی‌ها<sup>۴</sup> از ورودی است. این ویژگی‌ها سپس برای انجام وظایف خاص مانند طبقه‌بندی<sup>۵</sup>، شناسایی<sup>۶</sup> و قطعه‌بندی<sup>۷</sup> استفاده می‌شوند. با این حال، در اغلب این پژوهش‌ها، به نقاط ضعف و چالش‌های بهینه‌سازی این مدل‌ها در طبقه‌بندی تصاویر هوایی کمتر پرداخته شده است. نقد و بررسی دقیق روش‌های پیشنهادی در تحقیقات پیشین نشان می‌دهد که هر یک از این بهینه‌سازها دارای مزایا و محدودیت‌هایی هستند که می‌توانند بر صحت و کارایی مدل تأثیر بگذارند.

#### ۱-۱- ویژگی‌های بهینه‌سازها در فرآیند یادگیری

بهینه‌سازهای مختلف در یادگیری عمیق براساس ویژگی‌هایی مانند سرعت همگرایی، میزان پایداری، پیچیدگی

- 1- Zeiler
- 2- Vasavi
- 3- Backbones
- 4- Features
- 5- Classification
- 6- Detection
- 7- Segmentation



نگاره ۱: فرایند کلی انجام تحقیق

## ۲- روش پژوهش

بهینه‌سازی مدل‌های یادگیری عمیق تأثیر قابل توجهی بر صحت و کارایی آن‌ها دارد. در این راستا، انتخاب مناسب‌ترین بهینه‌ساز می‌تواند نقش مهمی در بهبود عملکرد مدل U-Net در تفکیک تصاویر با صحت بالا ایفا کند. نگاره ۱، فرایند کلی انجام این مطالعه را نشان می‌دهد.

مطابق نگاره ۱، بعد از فراخوانی تصویر هوایی با وضوح بالا در بخش آماده‌سازی داده‌ها، برچسب‌گذاری تصویر به صورت دستی، برای چهار کاربری ساختمان، راه، پوشش جنگلی و آب، توسط کارشناس خبره صورت گرفت. این داده‌ها متعلق به یک مجموعه داده معیار<sup>۱</sup> هستند که توسط تولیدکننده داده طبقه‌بندی شده و شامل چهار کلاس مذکور هستند. در ادامه، کل تصویر به همراه برچسب تصویر، به تصاویر کوچک به ابعاد ۲۵۶×۲۵۶ پیکسل برش داده شد و برش‌هایی که عاری از هرگونه کلاس طبقه‌بندی بودند، حذف شدند تا تصاویر دارای اطلاعات مفید به عنوان نمونه داده‌های آموزشی، اعتبارسنجی و آزمون از این تصاویر

## • انواع شرط توقف

شرایط توقف تعیین می‌کنند که الگوریتم چه زمانی متوقف شود. معیارهای رایج شامل تغییرات ناچیز در مقدار تابع هزینه، تعداد گام‌های مشخص بدون بهبود، یا کاهش میزان تغییرات گرادیان‌ها است. برخی بهینه‌سازها به دلیل وابستگی به میانگین‌گیری گرادیان‌ها، بهتر از سایرین می‌توانند این شرایط را رعایت کنند، درحالی‌که برخی روش‌ها ممکن است نیاز به تنظیم دستی دقیق‌تری داشته باشند.

پژوهش حاضر با هدف ارزیابی عملکرد مدل‌های U-Net و ResNet در مقایسه شش بهینه‌ساز شامل SGD، Adam، AdamW، RMSprop، Nadam و Adagrad، با داده‌های پیش‌پردازش شده از تصاویر هوایی انجام می‌شود. این مطالعه تلاش دارد ضمن شناسایی بهترین ترکیب پارامترها و بهینه‌سازها، به تحلیل نقاط ضعف و قوت هر روش پرداخته و نقش آن‌ها را در بهبود صحت و کارایی تفکیک تصاویر هوایی با وضوح بالا بررسی کند. نتایج این پژوهش می‌تواند در توسعه مدل‌های کارآمدتر و بهبود سیستم‌های نظارت بر زمین و طبقه‌بندی تصاویر هوایی تأثیرگذار باشد.

بیش برآزش استفاده شود. از این میان، ۵ درصد از مجموعه داده اعتبارسنجی، به صورت تصادفی به مجموعه آزمون اختصاص یافت تا عملکرد نهایی مدل پس از آموزش ارزیابی شود. مدل U-Net، با ساختاری شبیه حرف "U"، به عنوان مدل پایه این پژوهش انتخاب شده است. این مدل شامل دو بخش اصلی است: بخش رمزگذار که با استفاده از لایه‌های کانولوشنی و تجمیعی ویژگی‌ها را استخراج کرده و اطلاعات ورودی را فشرده می‌کند، و بخش رمزگشا که از طریق کانولوشن معکوس و بزرگ‌نمایی تدریجی، تصویر بازسازی شده را تولید می‌کند. این طراحی، ویژگی‌های استخراج شده را به طور دقیق بازسازی کرده و مدل را برای طبقه‌بندی نهایی آماده می‌کند. در جدول (۱)، معماری U-Net و ResNet طراحی شده در این تحقیق به طور

و برچسب‌های متناظر تهیه شده، استفاده شوند. برای بهبود صحت و کاهش بیش‌برآزش در یادگیری عمیق، از تکنیک‌های افزون‌سازی داده مانند چرخش (۹۰ و ۱۸۰ درجه) و وارونه‌سازی افقی و عمودی استفاده شد. این روش‌ها با ایجاد نمونه‌های متنوع، حجم داده‌ها را افزایش داده و مدل را به شناسایی الگوهای کلی‌تر ترغیب می‌کنند، در نتیجه عملکرد آن بر روی داده‌های جدید بهبود می‌یابد. در این مطالعه، ۷۵ درصد از داده‌ها شامل تصاویر و برچسب‌های مرتبط با دو نوع کاربری (جنگل‌ها و منابع آبی) برای آموزش مدل به صورت تصادفی انتخاب شد تا تنوع داده‌ها و صحت مدل در طبقه‌بندی افزایش یابد. ۲۵ درصد دیگر به مجموعه اعتبارسنجی اختصاص یافت تا در طول آموزش برای ارزیابی مدل و تنظیم پارامترها و جلوگیری از

جدول ۱: معماری U-Net و ResNet طراحی شده

ResNet	U-Net	پارامتر
استفاده از Residual Blocks برای جلوگیری از مشکلات Vanishing Gradient و بهبود یادگیری	شامل دولایه کانولوشن با هسته ۳×۳	بلوک‌های کانولوشن
ReLU		تابع فعال‌سازی <sup>۱</sup>
Batch Normalization برای هر لایه کانولوشن به منظور بهبود همگرایی و سرعت یادگیری		نرمال‌سازی دسته <sup>۲</sup>
جلوگیری از وابستگی بیش از حد به ویژگی‌های خاص		حذف تصادفی <sup>۳</sup>
ترکیبی از کانولوشن‌های Conv2D و Residual Blocks برای استخراج ویژگی‌ها به طور مؤثر	۵ مرحله با افزایش فیلترها (۱۶ تا ۲۵۶)	مسیر رمزنگاری
استفاده از Max Pooling برای کاهش ابعاد و استخراج ویژگی‌های مهم		تجمیع‌کننده پیشینه
۵ مرحله با Conv2D Transpose برای افزایش ابعاد تصویر		مسیر رمزگشایی
انتقال اطلاعات مکانی از مسیر رمزنگاری		ترکیب خروجی
۵ فیلتر با هسته ۱×۱		لایه خروجی
Adagrad, Adamw, Nadam, SGD, Adam, RMSprop adam, Adadelta		توابع بهینه‌ساز
Adagrad = Adamw = Nadam = SGD = Adam = RMSprop = 0.00007		نرخ یادگیری هر بهینه‌ساز
۲۰۰ تکرار با اعمال شرط توقف زودهنگام <sup>۴</sup>		تعداد تکرار
Adagrad = Adamw = Nadam = SGD = Adam = RMSprop = 32		اندازه دسته‌بندی <sup>۵</sup>
Softmax		تابع خروجی


1- Activation Function

2- Batch Normalization

3- Dropout

4- Early Stopping

5- Patch Size



نگاره ۲: نمونه‌ای از ساختار معماری U-Net

زمان محاسباتی استفاده شده است. ساختار مدل مورد استفاده در این تحقیق از سه بخش اصلی مسیر رمزگذار، مسیر رمزگشا و لایه خروجی تشکیل شده است. هر کدام از این بخش‌ها نقش ویژه‌ای در پردازش و طبقه‌بندی تصاویر ایفا می‌کنند. نگاره ۲، ساختاری از مدل U-Net با سه بخش اصلی ذکر شده را نشان می‌دهد. با توجه به جدول (۱)، می‌توان نتیجه گرفت که به‌طور کلی ساختار پایه ResNet نیز مشابه نگاره ۲ است.

مطابق نگاره ۲، در مسیر رمزگذار، پنج مرحله وجود دارد که در هر مرحله ابعاد فیلترهای کانولوشن به تدریج کاهش می‌یابد (از فیلتر  $256 \times 256$  در مرحله اول به فیلتر  $16 \times 16$  در مرحله آخر). این کاهش ابعاد به مدل اجازه می‌دهد تا در مراحل ابتدایی ویژگی‌های ساده‌تری مانند لبه‌ها و بافت‌ها و در مراحل پایین‌تر، ویژگی‌های پیچیده‌تری را از تصاویر استخراج کند. در پایان هر مرحله از یک لایه تجمیع‌کننده پیشینه برای کاهش ابعاد تصویر و کنترل پیچیدگی مدل استفاده شده است. در مسیر رمزگشا، پنج مرحله مشابه رمزگذار وجود دارد که در هر مرحله، ابعاد تصویر با استفاده

خلاصه ارائه شده است. لازم به ذکر است که مقادیر نرخ یادگیری برای هر بهینه‌ساز براساس مطالعات و منابع معتبر که از نظر کاربردی شباهت زیادی با پژوهش حاضر داشتند، انتخاب شده است. در این منابع، نرخ‌های پیشنهادی برای هر بهینه‌ساز با توجه به ماهیت الگوریتم و ویژگی‌های داده‌های ورودی تعیین شده‌اند. با این حال، به‌منظور بهینه‌سازی عملکرد مدل و دستیابی به بهترین نتیجه، این مقادیر با انجام تغییرات کوچک و سعی و خطا حول مقدار اولیه تنظیم شده‌اند. فرآیند تنظیم شامل بررسی تأثیر مقادیر مختلف بر معیارهای ارزیابی مورد استفاده در این مطالعه بوده است.

توقف زودهنگام یکی از روش‌های رایج در آموزش مدل‌های یادگیری عمیق برای جلوگیری از بیش‌برازش است. این تکنیک با متوقف کردن فرآیند آموزش در صورت عدم بهبود صحت یا کاهش خطا پس از تعداد مشخصی تکرار، به تعادل عملکرد مدل در داده‌های آموزشی و آزمایشی کمک می‌کند. در پژوهش حاضر، از این روش برای بهینه‌سازی آموزش، دستیابی به صحت بالا، و کاهش

### Adam - ۲-۱-۲

Adam یکی از پرکاربردترین بهینه‌سازها است که با ترکیب مزایای روش‌های Adagrad و RMSprop، یادگیری سریع‌تر و پایدارتر را ارائه می‌دهد (Bera & Shrivastava, 2020). این بهینه‌ساز با بهره‌گیری از میانگین وزنی نمای گرادیان‌ها و واریانس‌ها، روند به‌روزرسانی پارامترها را بهینه می‌کند که در روابط (۲ تا ۴) ارائه شده است.

$$\hat{a}_t = \frac{a_t}{(1 - \beta_1^t)} \quad \text{رابطه (۲)}$$

$$\hat{u}_t = \frac{u_t}{(1 - \beta_2^t)} \quad \text{رابطه (۳)}$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{u}_t + \epsilon}} \hat{a}_t \quad \text{رابطه (۴)}$$

در گام  $t$ ، گرادیان‌های معمولی  $u_t$  و میانگین مربعی گرادیان‌ها  $a_t$  و  $\hat{a}_t$  و نسخه‌های اصلاح‌شده این مقادیرند که به ترتیب با استفاده از عوامل  $\beta_1^t$  و  $\beta_2^t$  و کاهش میانگین نمایی در طول زمان اصلاح می‌شوند. پارامترهای مدل در گام  $t$  با نماد  $\theta_t$  نمایش داده می‌شوند و  $\epsilon$  یک مقدار ثابت کوچک است که از تقسیم بر صفر جلوگیری می‌کند. همچنین،  $\beta_1^t$  و  $\beta_2^t$  ضریب‌های کاهش نمایی برای میانگین گرادیان‌ها و میانگین مربعی گرادیان‌ها هستند. در این مدل، اصلاحات با استفاده از میانگین‌های وزنی نمای از گرادیان‌ها و واریانس‌ها به‌دست می‌آید. این باعث می‌شود که مدل به‌طور سریع‌تر و پایدارتر به سمت بهینه‌سازی پیش رود.

### AdamW - ۳-۱-۲

نسخه بهبود یافته Adam است که به‌جای اضافه کردن ضریب پسماند<sup>۳</sup> به گرادیان‌ها، آن را مستقیماً به‌روزرسانی پارامترها اضافه می‌کند تا از اضافه وزن ناخواسته در مدل جلوگیری کند (Pagliardini, Ablin, & Grangier, 2024). قانون به‌روزرسانی AdamW در رابطه (۵) ارائه شده است.

از لایه‌های Conv2DTranspose افزایش می‌یابد. خروجی این لایه‌ها با خروجی‌های متناظر در مسیر رمزگذار که ابعاد مشابه دارند، ادغام می‌شود تا اطلاعات مکانی از رمزگذار به رمزگشا منتقل شده و تصویری با رزولوشن بالا و صحت مناسب برای طبقه‌بندی تولید شود. در پایان، یک لایه کانولوشن با فیلتر  $5 \times 5$  و هسته  $1 \times 1$  برای تولید خروجی مدل تعبیه شده که ابعاد آن با تصویر ورودی مطابقت دارد و تابع Softmax خروجی را به برجسب‌های نهایی تبدیل می‌کند. تنظیم فرآیندهای مدل نقش مهمی در صحت و عملکرد آن دارد. انتخاب صحیح این پارامترها، مانند نرخ یادگیری، اندازه دسته داده‌ها و نوع بهینه‌ساز، می‌تواند زمان آموزش را کاهش داده و از بیش‌برازش جلوگیری کند، درحالی‌که تنظیمات نامناسب باعث کاهش صحت و نوسان در فرآیند آموزش می‌شود. این تنظیمات، همراه با ساختار U-Net، صحت و کارایی بالای مدل را در طبقه‌بندی تصاویر تضمین می‌کند.

### ۱-۲- بهینه‌سازها

#### SGD - ۱-۱-۲

یک روش ساده و مؤثر برای بهینه‌سازی که در آن گرادیان‌ها به صورت تصادفی و در دسته‌های کوچک به‌روزرسانی می‌شوند. این یک تکنیک بهینه‌سازی است که در هر گام زمانی  $t$ ، پارامتر  $\theta_t$  را به‌روزرسانی می‌کند. قانون به‌روزرسانی وزن در SGD در رابطه (۱) داده شده است (Bera & Shrivastava, 2020).

$$\theta_{t+1} = \theta_t - \eta d_t \quad \text{رابطه (۱)}$$

$\theta$ ، پارامترهای مدل در گام زمانی  $t$  است؛  $\eta$  نرخ یادگیری ثابت، که اندازه تغییرات در پارامترها را تعیین می‌کند و  $d_t$ ، گرادیان تابع هدف نسبت به پارامترها در گام زمانی  $t$  را نشان می‌دهد.

1- first moment

2- second moment

3- Weight Decay

## فصلنامه علمی - پژوهشی اطلاعات جغرافیایی ( ۳۳ )

ارزیابی عملکرد بهینه‌سازها در مدل‌های یادگیری عمیق U-Net و ResNet-34 برای ... / ۱۷

از گرادیان‌های مربعی  $R[d^2]_t$  تقسیم می‌کند. این قانون در رابطه (۷) ارائه شده است (Bera & Shrivastava, 2020).

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{R[d^2]_t + \varepsilon}} d_t \quad \text{رابطه (۷)}$$

RMSprop با تنظیم خودکار نرخ یادگیری در هر گام، به‌طور مؤثر از تغییرات ناگهانی در مسیر همگرایی جلوگیری می‌کند و باعث تسریع در روند یادگیری مدل‌های پیچیده می‌شود.

### ۲-۱-۶-AdaGrad

AdaGrad یکی از اولین روش‌های بهینه‌سازی تطبیقی است که نرخ یادگیری هر پارامتر را براساس مقدار تاریخی گرادیان‌ها تنظیم می‌کند (Duchi et al., 2012). معادله به‌روزرسانی آن رابطه (۸) است.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{G_t + \varepsilon}} g_t \quad \text{رابطه (۸)}$$

$G_t$ ، مجموع مربعات گرادیان‌ها تا لحظه  $t$  برای تطبیق نرخ یادگیری است. این پارامترها به AdaGrad کمک می‌کنند تا نرخ یادگیری را برای پارامترهایی که کمتر به‌روزرسانی شده‌اند، افزایش دهد و برای پارامترهایی که بیشتر به‌روزرسانی شده‌اند، کاهش دهد (Giang et al., 2020). جدول (۲)، به‌طور کلی ویژگی‌های کلیدی بهینه‌سازهای مختلف را که در فرآیند آموزش مدل‌های یادگیری عمیق

$$\begin{cases} m(t) = \beta_1 m(t-1) + (1 - \beta_1) g(t), & \bar{m}(t) = \frac{m^{(t)}}{(1 - \beta_1^t)} \\ v(t) = \beta_2 v(t-1) + (1 - \beta_2) g(t), & \hat{v}(t) = \frac{v(t)}{1 - \beta_2^t} \\ o(t) = o(t-1) - \eta \left( \frac{\bar{m}(t)}{\sqrt{\hat{v}(t) + \varepsilon}} + \lambda o(t-1) \right) \end{cases}$$

رابطه (۵)

$g(t)$ ، گرادیان تابع هدف نسبت به پارامترهای مدل در زمان  $t$  بوده و  $\lambda$ ، ضریب وزن‌دهی برای کاهش وزن است.

### ۲-۱-۴-Nadam

Nadam نسخه‌ای از Adam است که از تکنیک Nesterov Momentum برای بهبود سرعت همگرایی استفاده می‌کند و یک نوع از قوانین به‌روزرسانی وزن‌ها است که در رابطه (۶) نشان داده شده است (Bera & Shrivastava, 2020).

$$\theta_{(t+1)} = \theta_t - \frac{\eta}{\sqrt{\hat{u}_t + \varepsilon}} \left( \frac{\beta_1 a_{t-1}}{1 - \beta_1^t} + \frac{1 - \beta_1}{1 - \beta_1^t} d_t \right) \quad \text{رابطه (۶)}$$

### ۲-۱-۵-RMSprop

یک روش بهینه‌سازی که نرخ یادگیری را براساس میانگین مربعات گرادیان‌های اخیر تنظیم می‌کند و در مسائل یادگیری عمیق با پارامترهای مختلف مؤثر است. قانون به‌روزرسانی وزن در RMSprop به‌صورتی است که نرخ یادگیری را براساس ریشه دوم میانگین نمایی کاهش

جدول ۲: مقایسه ویژگی‌های کلیدی بهینه‌سازهای مختلف در فرآیند آموزش مدل‌های یادگیری عمیق

نقطه ضعف	مزیت اصلی	تنظیم نرخ یادگیری	نوع بهینه‌سازی	بهینه‌ساز
همگرایی کند، نوسانات زیاد	سادگی، کارایی در مسائل بزرگ	ثابت	گرادیان کاهشی تصادفی ثابت	SGD
حساسیت به تنظیمات اولیه	همگرایی سریع، مناسب برای داده‌های دارای خطا	تطبیقی	ترکیبی (Adagrad + RMSprop)	Adam
تنظیم نیازمند صحت بالا	بهبود تعمیم‌پذیری، کاهش وزن اضافه‌مدل	تطبیقی	اصلاح شده از Adam	AdamW
پیچیدگی محاسباتی بالا	همگرایی سریع‌تر از Adam	تطبیقی	Adam + Nesterov Momentum	Nadam
ممکن است در برخی شرایط به دام بهینه محلی بیافتد.	عملکرد بهتر از SGD در مسائل غیرایستا	تطبیقی	میانگین‌گیری نمایی گرادیان‌ها	RMSprop
کاهش شدید نرخ یادگیری در طول زمان	یادگیری سریع‌تر برای ویژگی‌های نادر	تطبیقی	تجمعی	AdaGrad

جدول ۳: معیارهای ارزیابی‌های یادگیری عمیق

توضیحات	رابطه	بهینه‌ساز	رابطه
TP: تعداد نمونه‌هایی که به درستی به (+) طبقه‌بندی شده‌اند. TN: تعداد نمونه‌هایی که به درستی به (-) طبقه‌بندی شده‌اند. FP: تعداد نمونه‌هایی که به اشتباه به (+) طبقه‌بندی شده‌اند. FN: تعداد نمونه‌هایی که به اشتباه به (-) طبقه‌بندی شده‌اند.	$Overall Accuracy = \frac{TP}{TP + TN + FP + FN}$	صحت کلی	(۹)
$P_o$ : دقت مشاهده‌شده (دقت کلی) $P_e$ : دقت تصادفی	$Kappa Coefficient = \frac{P_o - P_e}{1 - P_e}$	ضریب کاپا	(۱۰)
Precision: نسبت نمونه‌های (TP) به کل نمونه‌ها (TP+FP) Recall: نسبت نمونه‌های (TP) به کل نمونه‌ها (TP+FN)	$F_1 Score = 2 \times \left( \frac{Precision \times Recall}{Precision + Recall} \right)$	امتیاز F1	(۱۱)
$ A \cap B $ : تعداد عناصر مشترک بین دو مجموعه A و B $ A \cup B $ : تعداد کل عناصر در دو مجموعه A و B	$Jaccard Score = \frac{ A \cap B }{ A \cup B }$	امتیاز ژاکارد	(۱۲)
$P_i$ : مقدار پیش‌بینی شده برای کلاس i است. $O_i$ : مقدار واقعی برای کلاس i است.	$Normalized QD = \frac{\frac{1}{2} \sum_i  P_i - O_i }{\sum_i O_i}$	اختلاف مقدار نرمال شده	(۱۳)
$P_{total}$ : مجموع پیش‌بینی‌ها برای تمام کلاس‌ها است. $O_{total}$ : مجموع مقادیر واقعی برای تمام کلاس‌ها است.	$AD = \frac{1}{2} \sum_i \left  \frac{P_i}{P_{total}} - \frac{O_i}{O_{total}} \right $	اختلاف تخصیص	(۱۴)
$A_i$ : مجموعه پیش‌بینی شده برای کلاس i. $B_i$ : مجموعه واقعی برای کلاس i. $ A_i \cap B_i $ : تعداد پیکسل‌هایی که هم در پیش‌بینی و هم در کلاس واقعی موجود هستند (تقاطع). $ A_i \cup B_i $ : تعداد کل پیکسل‌هایی که در پیش‌بینی یا کلاس واقعی یا هر دو موجود هستند (اتحاد). N: تعداد کلاس‌ها.	$\begin{cases} IoU_i = \frac{ A_i \cap B_i }{ A_i \cup B_i } \\ MIoU = \frac{1}{N} \sum_{i=1}^N IoU_i \end{cases}$	MIoU	(۱۵)
$w_i$ : وزن کلاس i است که معمولاً از طریق فرکانس (تعداد پیکسل‌های موجود در کلاس i) محاسبه می‌شود.	$FWIoU = \frac{\sum_{i=1}^N w_i IoU_i}{\sum_{i=1}^N w_i}$	FWIoU	(۱۶)

علاوه بر این، دو معیار دیگر به نام‌های اختلاف مقدار<sup>۳</sup> و اختلاف تخصیص<sup>۴</sup> نیز برای بررسی انحرافات کمی در نتایج پیش‌بینی شده در مقایسه با حقیقت‌زمینی<sup>۵</sup> اضافه شده‌اند

(Pontius & Millones, 2011)

جدول (۳)، روابط ریاضی مربوط به هر یک از این معیارها را نشان می‌دهد. معیارهای رابطه ۹ الی ۱۴، به‌طور گسترده‌ای در ادبیات تحقیق برای بررسی عملکرد مدل‌های طبقه‌بندی و تفکیک تصاویر به‌کار رفته‌اند. در این تحقیق نیز، از معیارهای ارزیابی جدول (۳)، به‌دلیل سادگی و کاربرد

مورد استفاده قرار می‌گیرند، مقایسه می‌کند. هر یک از این بهینه‌سازها براساس نوع بهینه‌سازی، روش تنظیم نرخ یادگیری، مزایا و نقاط ضعف‌شان بررسی شده‌اند.

## ۲-۲- معیارهای ارزیابی

در مرحله نهایی طبقه‌بندی کاربری اراضی، عملکرد مدل با استفاده از معیارهای ارزیابی استاندارد شامل صحت کلی، ضریب کاپا، امتیاز F1<sup>۱</sup> و امتیاز ژاکارد<sup>۲</sup> تحلیل می‌شود. این معیارها نقاط قوت و ضعف مدل را مشخص کرده و دقت آن را در تشخیص صحیح نمونه‌ها ارزیابی می‌کنند.

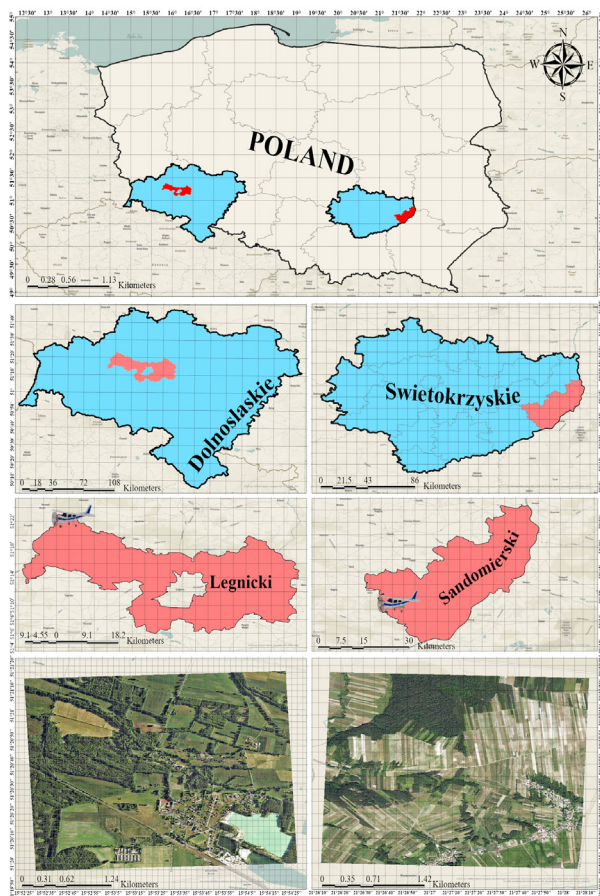
3- Quantity Disagreement

4- Allocation Disagreement

5- Ground Truth

1- F1 Score

2- Jaccard Score



نگاره ۳: منطقه مطالعاتی: تصاویر اورتوفتو از شهرهای لگنیسکی و ساندومیرسکی لهستان

در این مطالعه، از تصاویر هوایی تهیه‌شده در سال ۲۰۲۱ که از جمله داده‌های مرجع<sup>۷</sup> بوده، بهره گرفته شده است (Boguszewski, Batorski, Ziemia-Jankowska, Dziedzic, & Zambrzycka, 2020). این تصاویر دارای وضوح بالا با حد تفکیک مکانی ۲۰ الی ۲۵ سانتی‌متر بوده و در سه باند اصلی طیف مرئی و تحت شرایط نوری مناسب ثبت شده‌اند. با توجه به محدودیت‌های زمانی در دسترسی به داده‌های هوایی با کیفیت بالا و هزینه‌های بالای پردازش و برچسب‌گذاری داده‌های مناطق داخلی کشور، تصمیم بر آن شد تا از داده‌های هوایی مناطق لهستان استفاده شود. این داده‌ها که به‌صورت رایگان در دسترس بوده و پیش‌تر

گسترده آن‌ها برای ارزیابی کلی کارایی مدل استفاده شده است. با این حال، در برخی از مطالعات مشابه، از معیارهای دیگری مانند میانگین هم‌پوشانی بر اتحاد (MioU)<sup>۱</sup> و هم‌پوشانی بر اتحاد وزن‌دار بر اساس فرکانس (FWIoU)<sup>۲</sup> نیز برای ارزیابی استفاده شده است. این معیارها به‌ویژه در زمینه طبقه‌بندی چندکلاسه و تفکیک تصویر به‌کار می‌روند و می‌توانند دیدگاه دقیقی از عملکرد مدل‌ها در مقیاس کلاسه‌ای فراهم کنند.

### ۳- پیاده‌سازی و ارائه نتایج

برای پیاده‌سازی مطالعه حاضر، از زبان برنامه‌نویسی Python و کتابخانه Keras بر مبنای TensorFlow استفاده شد. به‌منظور تسهیل فرایند آموزش و ارزیابی، تمامی مراحل در محیط برنامه‌نویسی Google Colab انجام شد. تصویر هوایی اول مورد استفاده در این مطالعه با تفکیک مکانی ۲۰ سانتی‌متر از شهر لگنیسکی<sup>۳</sup> استان دولنوشلانسکی<sup>۴</sup> کشور لهستان انتخاب شده است. این منطقه با مساحت حدودی ۵۴۷/۶۰ هکتار در طول جغرافیایی ۱۵° ۵۲' ۲۷" تا ۱۵° ۵۴' ۲۷" شرقی و عرض جغرافیایی ۵۱° ۱۹' ۵۷" تا ۵۱° ۲۱' ۱۸" شمالی قرار دارد. همچنین برای اطمینان از تعمیم‌پذیری مدل یادگیری عمیق و بررسی تأثیر هر یک از بهینه‌سازهای به‌کار گرفته شده، تصویر هوایی دوم با تفکیک مکانی ۲۵ سانتی‌متر از منطقه‌ای دیگر کشور لهستان، برای آزمون، مورد استفاده قرار گرفت. منطقه آزمون در شهر ساندومیرسکی<sup>۵</sup> از استان سویتوکریسکی<sup>۶</sup> به مختصات جغرافیایی ۲۱° ۲۶' ۱۱" تا ۲۱° ۲۸' ۱۲" شرقی و ۵۰° ۳۶' ۱۳" تا ۵۰° ۳۷' ۳۲" شمالی واقع شده است. نگاره ۳، مناطق مورد مطالعه را نشان می‌دهد.

1- Mean Intersection over Union (MioU)

2- Frequency-Weighted Intersection over Union (FWIoU)

3- Legnicki

4- Dolnoslaskie

5- Sandomierski

6- Swietokrzyskie

7- Benchmark Data

ضریب کاپا، امتیاز F1، امتیاز ژاکارد، اختلاف مقدار و اختلاف تخصیص برای ارزیابی دقت و کیفیت تفکیک کاربری اراضی مورد بررسی قرار گرفتند.

در مدل U-Net، بهینه‌ساز RMSprop با صحت کلی ۹۵/۱۲ درصد و ضریب کاپای ۰/۹۷۹ بهترین عملکرد را از خود نشان داد. امتیاز F1 و ژاکارد این بهینه‌ساز نیز بالاتر از سایر روش‌ها بود که نشان‌دهنده توانایی بالای آن در تفکیک کلاس‌های مختلف است. در مقابل، Adagrad با صحت کلی ۷۷/۶۲ درصد و ضریب کاپای ۰/۶۰۱ ضعیف‌ترین عملکرد را داشت، که نشان می‌دهد این بهینه‌ساز تطبیق‌پذیری کمتری با داده‌های پیچیده تصاویر هوایی دارد.

در مدل ResNet-34، بهینه‌ساز Adam با صحت کلی ۹۷/۲۳ درصد و ضریب کاپای ۰/۹۴۸ بهترین عملکرد را ارائه داد. همچنین Nadam و AdamW نیز صحتی نزدیک به ۹۷ درصد داشتند که نشان‌دهنده کارایی بالای این روش‌ها در ترکیب با مدل‌های یادگیری عمیق است. در مقابل، SGD در این مدل ضعیف‌ترین عملکرد را نشان داد و صحت کلی آن ۷۸/۶۴ درصد بود که در مقایسه با سایر روش‌ها پایین‌تر است. به‌طور کلی، مقایسه عملکرد دو مدل نشان می‌دهد ResNet-34 نسبت به U-Net در اکثر موارد عملکرد بهتری داشته است، که این موضوع می‌تواند ناشی از پیچیدگی معماری و ظرفیت بالاتر ResNet-34 در یادگیری ویژگی‌های تصاویر هوایی باشد. همچنین، بهینه‌سازهای تطبیقی مانند Adam، RMSprop و Nadam در هر دو مدل عملکرد مطلوبی داشتند و نتایج نشان داد که روش‌های مبتنی بر نرخ یادگیری پویا در افزایش دقت و کاهش خطای مدل‌های یادگیری عمیق مؤثرتر هستند.

در گام بعدی، صحت و خطای مجموعه داده آموزشی و اعتبارسنجی مدل یادگیری عمیق U-Net و ResNet-34 در استفاده از هر بهینه‌ساز، به‌دست آمده و به‌ترتیب در نگاره ۴ و نگاره ۵ نشان داده شده است.

توسط کارشناسان، پردازش و برچسب‌گذاری شده‌اند، امکان اجرای سریع‌تر و دقیق‌تر مدل‌های یادگیری عمیق را فراهم می‌آورند. کیفیت بالای داده‌های لهستان از نظر تصحیحات هندسی و رادیومتریکی، آن‌ها را برای کاربرد در این پژوهش بسیار مناسب ساخته است. در گام بعدی، تصاویر به قطعات کوچک‌تری با ابعاد ۲۵۶×۲۵۶ برش داده شده و به سه مجموعه آموزشی، اعتبارسنجی و آزمون تقسیم شدند.

از ۶۱۶ تصویر برچسب‌گذاری شده با ابعاد ۲۵۶×۲۵۶ پیکسل، تعداد ۴۶۲ تصویر برای داده‌های آموزشی اختصاص یافت. برای افزایش تنوع داده‌ها و بهبود عملکرد مدل، از تکنیک‌های افزون‌سازی داده استفاده شد که تعداد نمونه‌های آموزشی را به ۲۳۱۰ تصویر افزایش داد. این فرآیند شامل اعمال انعکاس آینه‌ای افقی و عمودی و چرخش تصویر با زوایای ۹۰ و ۱۸۰ درجه بود.

این تبدیلات با استفاده از توابع flipud، fliplr و rot90 در کتابخانه NumPy اجرا شد. این روش موجب افزایش قدرت تعمیم‌دهی مدل شده و به بهبود عملکرد آن در شرایط متنوع کمک می‌کند. همچنین، ۱۵۴ تصویر برای اعتبارسنجی و ۱۵ تصویر برای آزمون در نظر گرفته شد.

پس از طراحی ساختار مدل‌های U-Net و ResNet-34، شش بهینه‌ساز مذکور، مورد استفاده قرار گرفتند و داده‌های آموزشی و اعتبارسنجی همراه با برچسب‌های مربوطه به مدل معرفی شدند. در نهایت، پس از چندین تکرار و دستیابی به حداکثر صحت کلی، فرآیند آموزش با استفاده از تکنیک Early Stopping متوقف شد. خروجی مدل‌ها شامل شش نقشه کاربری اراضی منطقه مورد مطالعه واقع در شهر لگنیسکی است که با استفاده از بهینه‌سازهای مختلف تهیه شد. در نگاره ۴، نقشه تولیدشده توسط مدل و نقشه مرجع تهیه‌شده توسط کارشناس نمایش داده شده است.

نتایج ارائه‌شده در جدول (۴) نشان می‌دهد که عملکرد مدل‌های U-Net و ResNet-34 در ترکیب با بهینه‌سازهای مختلف، تفاوت قابل‌توجهی دارد. معیارهای صحت کلی،

جدول ۴: عملکرد مدل یادگیری عمیق U-Net و ResNet در شهر لگنسیکی

تصویر هوایی	نقشه تهیه شده توسط کارشناس	راهنما	
		<p>چاهه</p> <p>پوشش گیاهی</p> <p>پوشش آبی</p> <p>سختاب</p> <p>ساختار</p>	مدل
RMSprop	Adam	SGD	U-Net
AdamW	Nadam	Adagrad	
			ResNet-34
RMSprop	Adam	SGD	
AdamW	Nadam	Adagrad	

ادامه جدول ۴: عملکرد مدل یادگیری عمیق U-Net و ResNet در شهر لگنیسکی

مدل	بهینه‌ساز	صحت کلی	ضریب کاپا	امتیاز F1	امتیاز ژاکارد	اختلاف مقدار	اختلاف تخصیص
U-Net	SGD	۹۲/۱۹	۰/۸۵۲	۹۱/۳۳	۶۰/۶۵	۰/۰۴۱	۰/۱۲۵
	Adam	۹۴/۸۰	۰/۹۰۳	۹۴/۷۵	۸۰/۷۰	۰/۰۳۰	۰/۰۷۵
	RMSprop	۹۵/۱۲	۰/۹۷۹	۹۵/۰۹	۸۱/۹۶	۰/۰۳۱	۰/۰۶۲
	Adagrad	۷۷/۶۲	۰/۶۰۱	۷۹/۵۰	۴۴/۵۷	۰/۱۸۷	۰/۳۱۳
	Nadam	۹۲/۳۳	۰/۸۵۵	۹۲/۲۵	۷۵/۹۳	۰/۰۳۱	۰/۱۳۱
	AdamW	۹۵/۱۰	۰/۹۰۹	۹۵/۰۹	۸۸/۷۵	۰/۰۳۰	۰/۰۶۲
ResNet-34	SGD	۷۸/۶۴	۰/۵۵۹	۷۶/۳۹	۴۲/۱۳	۰/۰۳۶	۰/۴۶۹
	Adam	۹۷/۲۳	۰/۹۴۸	۹۷/۲۲	۸۹/۱۳	۰/۰۱۹	۰/۰۳۲
	RMSprop	۹۶/۸۵	۰/۹۴۱	۹۶/۸۴	۸۷/۶۴	۰/۰۲۳	۰/۰۳۹
	Adagrad	۸۹/۶۹	۰/۸۰۱	۸۷/۹۱	۴۹/۹۸	۰/۰۴۵	۰/۲۰۰
	Nadam	۹۷/۱۴	۰/۹۴۷	۹۷/۱۳	۸۹/۰۴	۰/۰۲۰	۰/۰۳۴
	AdamW	۹۷/۲۲	۰/۹۴۸	۹۷/۲۱	۸۹/۲۲	۰/۰۱۹	۰/۰۳۳

نشان داده‌اند، همگرایی کندتری داشته و خطای بالاتری را دارا هستند.

نتایج نگاره (۵) نشان می‌دهد که بهینه‌سازهای تطبیقی مانند Adam، RMSprop و Nadam در مدل ResNet-34 عملکرد بهتری ارائه داده‌اند. این روش‌ها در هر دو مرحله آموزش و اعتبارسنجی به کاهش سریع‌تر خطا و افزایش سریع‌تر صحت کمک کرده‌اند. در مقابل، SGD و Adagrad به دلیل نرخ یادگیری ثابت و کاهش تدریجی بهینه‌سازی، عملکرد ضعیف‌تری را از خود نشان داده‌اند و نیاز به تعداد تکرار بیشتری برای رسیدن به دقت بالاتر دارند.

افزون بر این، مطالعه، برای بررسی دقیق‌تر و مقایسه بهتر بهینه‌سازها، دو مدل یادگیری عمیق آموزش‌یافته در منطقه لگنیسکی را بر روی یک مجموعه داده جدید واقع در شهر ساندومیرسکی مورد ارزیابی قرار داد. نتایج حاصل از این ارزیابی در جدول (۵) ارائه شده است.

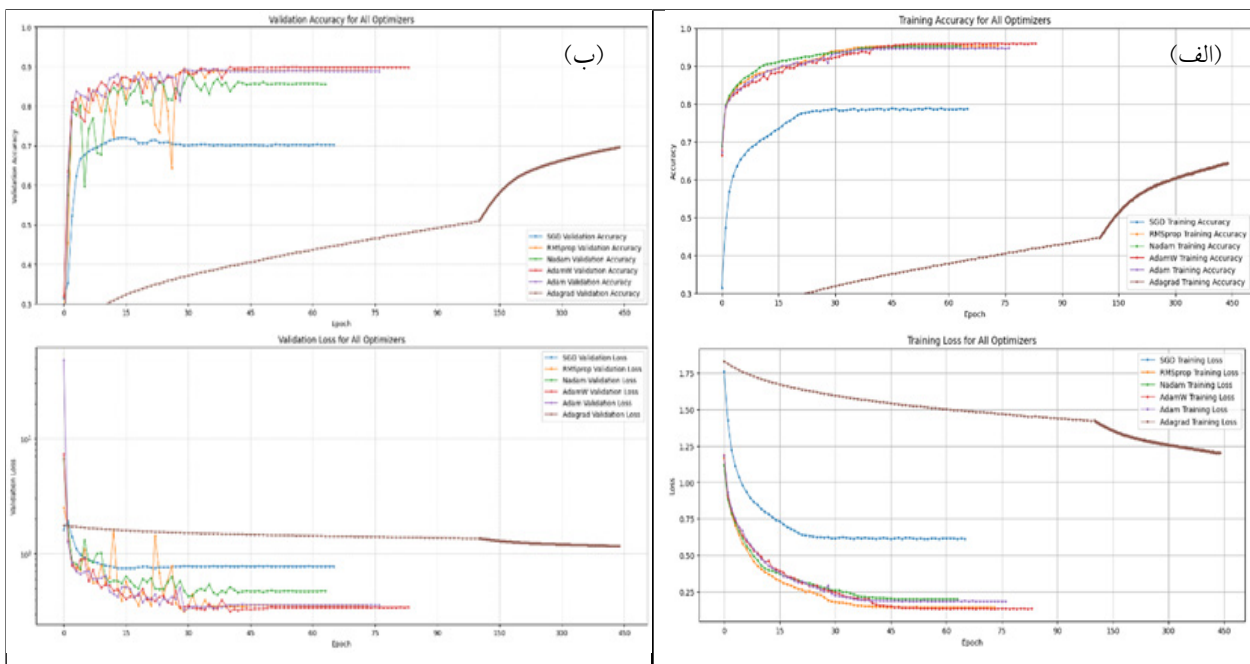
جدول ارائه‌شده، نتایج پیش‌بینی مدل‌های U-Net و ResNet-34 را به تفکیک هر بهینه‌ساز نشان می‌دهد. معیارهای ارزیابی شامل صحت کلی، ضریب کاپا، امتیاز

برای نمایش دقیق‌تر روند همگرایی و تفکیک بهتر نمودارهای مربوط به هر بهینه‌ساز، محور افقی (Epoch) به صورت مقیاس‌بندی شده تنظیم شده است. در این مقیاس‌بندی، در مراحل اولیه آموزش (۰ تا ۱۰۰ دوره)، مقیاس محور به صورت خطی تنظیم شده است تا روند همگرایی هر بهینه‌ساز به وضوح قابل مشاهده باشد. پس از دوره ۱۰۰، به دلیل کاهش سرعت تغییرات و جلوگیری از تراکم بیش از حد داده‌ها، مقیاس محور فشرده‌تر شده است. این روش امکان تحلیل دقیق‌تر تفاوت‌های عملکردی بین بهینه‌سازها را در مراحل پایانی آموزش و اعتبارسنجی فراهم می‌کند.

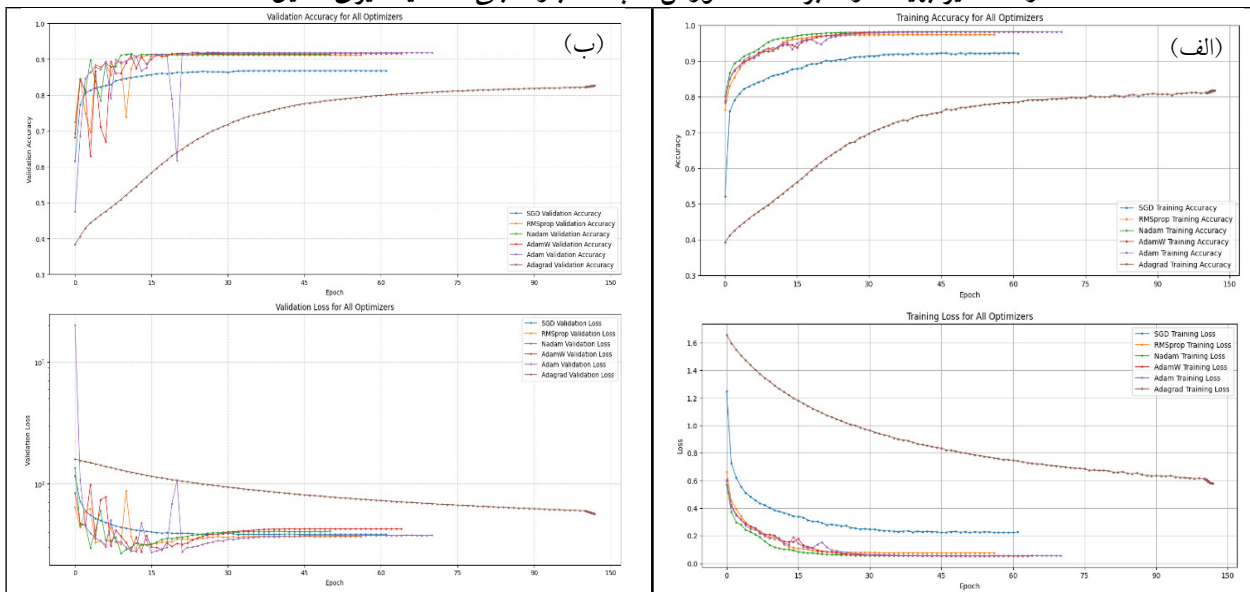
نتایج ارائه‌شده در نگاره (۴) نشان می‌دهد که بهینه‌سازهای تطبیقی مانند Adam، RMSprop و Nadam در هر دو مرحله آموزش و اعتبارسنجی عملکرد بهتری ارائه داده‌اند. این بهینه‌سازها با کاهش سریع‌تر خطا و افزایش سریع‌تر صحت در مدل را نشان داده و در مقدار ثابتی تثبیت شده‌اند. در مقابل، SGD و Adagrad به دلیل عدم امکان تنظیم پویا به صورت ذاتی، عملکرد ضعیف‌تری از خود

## فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (سپهر)

ارزیابی عملکرد بهینه‌سازها در مدل‌های یادگیری عمیق U-Net و ResNet-34 برای ... / ۲۳



نگاره ۴: تأثیر بهینه‌سازها بر الف) آموزش - ب) اعتبارسنجی مدل یادگیری عمیق U-Net



نگاره ۵: تأثیر بهینه‌سازها بر الف) آموزش - ب) اعتبارسنجی مدل یادگیری عمیق ResNet

همچنین، Nadam و Adam نیز در مدل ResNet-34 عملکرد مناسبی از خود نشان داده‌اند، به طوری که صحت کلی این مدل با این دو بهینه‌ساز به ترتیب ۸۶/۸۶ و ۸۳/۹۷ درصد بوده است. این نتایج نشان می‌دهد که بهینه‌سازهای تطبیقی مانند Adam، RMSprop، Nadam و Adam باعث بهبود همگرایی و افزایش دقت مدل ResNet-34 شده‌اند.

F1، امتیاز ژاکارد، اختلاف مقدار و اختلاف تخصیص مورد بررسی قرار گرفته‌اند. مدل ResNet-34 در اکثر موارد عملکرد بهتری نسبت به U-Net داشته است. صحت کلی این مدل در ترکیب با بهینه‌ساز RMSprop برابر با ۸۷/۵۴ درصد بوده که بالاترین مقدار در بین تمامی ترکیب‌های آزمایش شده است.

جدول ۵: عملکرد مدل یادگیری عمیق U-Net و ResNet در شهر ساندومیرسکی

تصویر هوایی	نقشه تهیه شده توسط کارشناس	واقعاً	
		<p>واقعاً</p> <p>یوتش جنگلی (سبز)</p> <p>چاه (قرمز)</p> <p>یوتش آبی (آبی)</p> <p>سرایانه (سیاه)</p> <p>ساختار (سفید)</p>	مدل
RMSprop	Adam	SGD	U-Net
AdamW	Nadam	Adagrad	
RMSprop	Adam	SGD	ResNet-34
AdamW	Nadam	Adagrad	

جدول ۵: عملکرد مدل یادگیری عمیق U-Net و ResNet در شهر ساندومیرسکی

مدل	بهینه‌ساز	صحت کلی	ضریب کاپا	امتیاز F1	امتیاز ژاکارد	اختلاف مقدار	اختلاف تخصیص
U-Net	SGD	۶۸/۹۲	۰/۰۸۴	۶۴/۶۱	۱۸/۲۵	۰/۹۴۳	۰/۸۹۱
	Adam	۶۳/۳۰	۰/۱۸۵	۶۷/۶۴	۲۳/۰۲	۰/۳۴۴	۰/۷۲۵
	RMSprop	۷۷/۱۷	۰/۴۵۳	۷۳/۷۷	۲۶/۰۹	۰/۱۷۹	۰/۴۶۴
	Adagrad	۷۷/۸۷	۰/۵۱۴	۹۹/۷۹	۲۸/۵۴	۰/۲۵۰	۰/۴۳۲
	Nadam	۶۱/۳۲	۰/۲۴۶	۸۴/۵۶	۲۰/۷۰	۰/۲۶۰	۰/۸۶۴
	AdamW	۷۷/۰۰	۰/۳۵۶	۴۵/۷۳	۳۱/۳۸	۰/۳۸۳	۰/۶۴۱
ResNet-34	SGD	۸۱/۶۳	۰/۵۵۷	۸۸/۸۱	۳۵/۴۸	۰/۱۳۴	۰/۴۰۰
	Adam	۸۳/۹۷	۰/۶۲۱	۵۹/۸۴	۳۸/۰۵	۰/۱۲۸	۰/۳۲۷
	RMSprop	۸۷/۵۴	۰/۷۲۳	۶۸/۸۸	۳۹/۷۵	۰/۱۵۴	۰/۲۸۰
	Adagrad	۸۳/۷۱	۰/۵۷۳	۲۰/۸۲	۲۷/۱۶	۰/۶۳۰	۰/۴۶۱
	Nadam	۸۶/۸۶	۰/۷۰۴	۸۳/۸۷	۳۹/۵۷	۰/۱۴۷	۰/۲۷۶
	AdamW	۸۲/۵۳	۰/۵۹۴	۴۶/۸۳	۳۴/۶۷	۰/۱۴۴	۰/۳۳۹

در مدل U-Net، بهترین عملکرد مربوط به بهینه‌ساز Adam و RMSprop است. این برتری در برخی بهینه‌سازها مانند Nadam و RMSprop به‌وضوح مشاهده می‌شود که نشان‌دهنده عملکرد بهتر مدل‌های عمیق‌تر در شناسایی الگوهای پیچیده داده‌های ورودی است.

در معیارهای اختلاف مقدار و اختلاف تخصیص، مشخص است که بهینه‌سازهای Adam و RMSprop کمترین مقدار را برای مدل ResNet-34 به‌دست آورده‌اند که نشان‌دهنده پایین‌تر بودن میزان خطای پیش‌بینی این مدل در مقایسه با سایر روش‌ها است. در مقابل، بهینه‌سازهایی مانند Nadam در مدل U-Net بیشترین میزان خطا را ثبت کرده‌اند که نشان می‌دهد این روش‌ها برای این مدل چندان مناسب نبوده‌اند.

### ۳-۱- بحث

در این مطالعه، عملکرد دو مدل یادگیری عمیق U-Net و ResNet-34 در ترکیب با شش بهینه‌ساز مختلف مورد بررسی قرار گرفت. ارزیابی نتایج از طریق معیارهای صحت کلی، ضریب کاپا، امتیاز F1، امتیاز ژاکارد، اختلاف مقدار و اختلاف تخصیص انجام شد. علاوه بر تحلیل معیارهای

در مدل U-Net، بهترین عملکرد مربوط به بهینه‌ساز Adam و RMSprop است. این برتری در برخی بهینه‌سازها مانند Nadam و RMSprop به‌وضوح مشاهده می‌شود که نشان‌دهنده عملکرد بهتر مدل‌های عمیق‌تر در شناسایی الگوهای پیچیده داده‌های ورودی است.

در مدل U-Net، بهترین عملکرد مربوط به بهینه‌ساز Adam و RMSprop است. این برتری در برخی بهینه‌سازها مانند Nadam و RMSprop به‌وضوح مشاهده می‌شود که نشان‌دهنده عملکرد بهتر مدل‌های عمیق‌تر در شناسایی الگوهای پیچیده داده‌های ورودی است.

مقایسه ضریب کاپا نشان می‌دهد که مدل ResNet-34 با بهینه‌ساز RMSprop بالاترین مقدار ۰/۷۲۳ را داشته، درحالی‌که بیشترین مقدار این معیار در مدل U-Net با بهینه‌ساز Adagrad تنها ۰/۵۱۴ بوده است. این تفاوت نشان می‌دهد که مدل ResNet-34 با روش‌های بهینه‌تر قادر به بهبود دقت پیش‌بینی طبقه‌بندی‌ها بوده، درحالی‌که برخی از بهینه‌سازها در مدل U-Net تأثیر مطلوبی نداشته‌اند. بررسی امتیاز ژاکارد و امتیاز F1 نیز نشان می‌دهد که مدل ResNet-34 در تمامی بهینه‌سازها مقادیر بالاتری نسبت به

استفاده از این بهینه‌سازها در مقدار ۹۷ درصد ثابت مانده است. همچنین، خطای اعتبارسنجی نشان داد که مدل‌های آموزش‌دیده با SGD و Adagrad دارای نوسانات بیشتری هستند و مقدار خطای آن‌ها در مقایسه با سایر روش‌ها بالاتر باقی مانده است.

مقایسه عملکرد مدل‌ها و بهینه‌سازها نشان داد که ResNet-34 در اکثر موارد صحت بالاتری نسبت به U-Net داشته است. علاوه بر این، بهینه‌سازهای تطبیقی مانند Adam، RMSprop و Nadam نسبت به روش‌های ساده‌تری مانند SGD و Adagrad عملکرد بهتری ارائه دادند. نتایج این تحقیق نشان داد که استفاده از معماری‌های عمیق‌تر همراه با بهینه‌سازهای تطبیقی می‌تواند باعث افزایش صحت و کاهش خطای مدل‌های یادگیری عمیق در طبقه‌بندی تصاویر هوایی شود.

همچنین نتایج جدول (۵) نیز نشان می‌دهد که مدل ResNet-34 در تمامی معیارها نسبت به U-Net عملکرد بهتری ارائه داده است. همچنین، بهینه‌ساز RMSprop بهترین عملکرد را در هر دو مدل داشته و منجر به بیشترین دقت کلی و کمترین میزان خطا شده است. بهینه‌سازهای Adam و Nadam نیز در مدل ResNet-34 نتایج قابل توجهی داشته‌اند. در مقابل، بهینه‌سازهای SGD در اکثر موارد عملکرد ضعیف‌تری نشان داده‌اند، به‌ویژه در مدل U-Net که در برخی ترکیب‌ها خطای پیش‌بینی آن‌ها به میزان چشمگیری بالا بوده است. یادآوری می‌شود با اینکه بهینه‌ساز Adagrad در مدل U-Net نتوانست عملکرد مناسبی را در شهر لگنیسکی از خود نشان دهد و صحت کلی آن برابر با ۷۷/۶۲ درصد بوده است اما با نگاهی به عملکرد آن در شهر ساندومیرسکی، نتیجه می‌شود که مدل U-Net با به‌کارگیری بهینه‌ساز Adagrad فراتر از انتظار عمل کرده و بیشترین تطابق‌یابی ممکن را با صحت کلی ۷۷/۸۷ درصد در پیش‌بینی کاربری‌های اراضی داشته است. این نتایج تأکید می‌کند که استفاده از بهینه‌سازهای تطبیقی در مدل‌های پیچیده‌تر مانند ResNet-34 می‌تواند تأثیر بسزایی در بهبود دقت پیش‌بینی و کاهش خطا داشته باشد.

عددی، روند همگرایی مدل‌ها در طول فرآیند آموزش و اعتبارسنجی نیز مورد بررسی قرار گرفت.

نتایج ارائه‌شده در جدول (۴) نشان می‌دهد که ResNet-34 در اکثر موارد عملکرد بهتری نسبت به U-Net داشته است. درحالی‌که U-Net نیز صحت مناسبی را ارائه داده، اما مدل ResNet-34 به دلیل معماری عمیق‌تر و ظرفیت بالاتر در استخراج ویژگی‌ها، دقت بالاتری را در اکثر بهینه‌سازها کسب کرده است. بهینه‌ساز Adam در ترکیب با ResNet-34 بهترین عملکرد را ارائه داده و صحت کلی ۹۷/۲۳ درصد را به‌دست آورده است، درحالی‌که در مدل U-Net، بهترین عملکرد مربوط به بهینه‌ساز RMSprop با صحت ۹۵/۱۲ درصد بوده است.

نتایج نشان داد که بهینه‌سازهای تطبیقی مانند Adam، RMSprop و Nadam، به دلیل تنظیم پویا و کارآمد نرخ یادگیری، عملکرد بهتری نسبت به روش‌های SGD و Adagrad داشتند. این مزیت به‌ویژه در سرعت همگرایی و کاهش سریع‌تر خطا در مراحل ابتدایی آموزش مشهود بود. از سوی دیگر، Adagrad ضعیف‌ترین عملکرد را در هر دو مدل ارائه داد که ناشی از کاهش بیش‌ازحد نرخ یادگیری در مراحل پایانی آموزش است.

تحلیل نگاره (۵) نشان داد که مدل ResNet-34، با استفاده از بهینه‌سازهای تطبیقی، در زمان کوتاه‌تری به حداکثر صحت ممکن رسیده و مقدار خطای آن کاهش یافته است. در نمودار Training Loss، بهینه‌سازهای Adam، RMSprop و Nadam سریع‌تر به مقدار حداقل خطا همگرا شده‌اند، درحالی‌که SGD و Adagrad به دلیل نرخ یادگیری ثابت، همگرایی کندتری داشته‌اند. همچنین، در نمودار صحت آموزشی، مشاهده شد که بهینه‌سازهای تطبیقی در کمتر از ۲۰ تکرار به صحت بالای ۹۵ درصد رسیدند، درحالی‌که SGD و Adagrad به تعداد تکرارهای بیشتری برای همگرایی نیاز داشتند.

در نمودار صحت اعتبارسنجی نیز، عملکرد بهینه‌سازهای تطبیقی برتری خود را حفظ کرده و صحت مدل با

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی ( فصلنامه علمی )

ارزیابی عملکرد بهینه‌سازها در مدل‌های یادگیری عمیق U-Net و ResNet-34 برای ... / ۲۷

به‌منظور بررسی دقیق‌تر، نتایج مطالعه‌ی حاضر با سایر مشابه استفاده کرده‌اند، مقایسه شده است. این مقایسه در پژوهش‌های مرتبط که از همین مجموعه داده یا روش‌های قالب جدول (۶) ارائه شده است.

جدول ۶: مقایسه عملکرد مدل‌های یادگیری عمیق در به‌کارگیری بهینه‌سازهای مختلف با دیگر مطالعات انجام شده

مطالعات	مدل یادگیری عمیق	بهینه‌ساز	صحت کلی	ضریب کاپا	امتیاز FI	امتیاز ژاکارد	اختلاف مقدار	اختلاف تخصیص	MIoU	FWIoU
مطالعه حاضر	U-Net	SGD	۹۲/۱۹	۰/۸۵۲	۹۱/۳۳	۶۰/۶۵	۰/۰۴۱	۰/۱۲۵		
		Adam	۹۴/۸۰	۰/۹۰۳	۹۴/۷۵	۸۰/۷۰	۰/۰۳۰	۰/۰۷۵		
		RMSprop	۹۵/۱۲	۰/۹۷۹	۹۵/۰۹	۸۱/۹۶	۰/۰۳۱	۰/۰۶۲		
		Adagrad	۷۷/۶۲	۰/۶۰۱	۷۹/۵۰	۴۴/۵۷	۰/۱۸۷	۰/۳۱۳		
		Nadam	۹۲/۳۳	۰/۸۵۵	۹۲/۲۵	۷۵/۹۳	۰/۰۳۱	۰/۱۳۱		
		AdamW	۹۵/۱۰	۰/۹۰۹	۹۵/۰۹	۸۸/۷۵	۰/۰۳۰	۰/۰۶۲		
		SGD	۷۸/۶۴	۰/۵۵۹	۷۶/۳۹	۴۲/۱۳	۰/۰۳۶	۰/۴۶۹		
	ResNet-34	Adam	۹۷/۲۳	۰/۹۴۸	۹۷/۲۲	۸۹/۱۳	۰/۰۱۹	۰/۰۳۲		
		RMSprop	۹۶/۸۵	۰/۹۴۱	۹۶/۸۴	۸۷/۶۴	۰/۰۲۳	۰/۰۳۹		
		Adagrad	۸۹/۶۹	۰/۸۰۱	۸۷/۹۱	۴۹/۹۸	۰/۰۴۵	۰/۲۰۰		
		Nadam	۹۷/۱۴	۰/۹۴۷	۹۷/۱۳	۸۹/۰۴	۰/۰۲۰	۰/۰۳۴		
		AdamW	۹۷/۲۲	۰/۹۴۸	۹۷/۲۱	۸۹/۲۲	۰/۰۱۹	۰/۰۳۳		
		AdamW	۷۴/۱۶	۰/۵۹۶					۵۴/۱۶	۶۴/۲۱
		AdamW	۸۳/۸۳	۰/۷۳۰					۶۱/۷۷	۷۴/۱۱
Zhuohong Li <sup>۱</sup> و همکاران (Li et al., 2022)	L2HNet									
	DeepLabv3+									
Bingyu Chen <sup>۲</sup> و همکاران (Chen, Xia, & Huang, 2021)	ResNet-50									
	MobileNetv2									
Liguo Weng <sup>۳</sup> و همکاران (Weng et al., 2023)	U-Net									
	DeepLabv3+									
	SegNet									
Andrew Clark <sup>۴</sup> و همکاران (Clark, Phinn, & Scarth, 2023)	SGD		۶۸/۷۰							
	Adam		۸۰/۲۰							
	Adadelata		۸۴/۸۱							
	Nadam		۸۴/۰۰							
	RMSprop		۸۲/۴۴							
Won-Kyung Baek <sup>۵</sup> و همکاران (Baek et al., 2024)	U-Net		۹۰/۵۰							

- 1- Zhuohong Li
- 2- Bingyu Chen
- 3- Liguo Weng
- 4- Andrew Clark
- 5- Won-Kyung Baek

## ۴- نتیجه گیری

در این پژوهش، عملکرد دو مدل یادگیری عمیق U-Net و ResNet-34 در ترکیب با شش بهینه‌ساز مختلف به منظور طبقه‌بندی تصاویر هوایی با وضوح بالا مورد بررسی قرار گرفت. هدف اصلی تحقیق، تحلیل اثر بهینه‌سازهای مختلف بر دقت و کارایی مدل‌های طبقه‌بندی و ارزیابی دقیق‌تر مزایا و محدودیت‌های هر ترکیب مدل-بهینه‌ساز بود. به همین منظور، معیارهای ارزیابی صحت کلی، ضریب کاپا، امتیاز F1، امتیاز ژاکارد، اختلاف مقدار و اختلاف تخصیص برای هر ترکیب محاسبه و مقایسه شد.

نتایج نشان داد که مدل ResNet-34 در تمامی معیارهای ارزیابی، عملکرد بهتری نسبت به U-Net ارائه داده است. این برتری به دلیل معماری عمیق‌تر و استفاده از بلوک‌های باقی‌مانده<sup>۱</sup> در ResNet-34 است که باعث کاهش مشکل ناپدید شدن گرادینان، افزایش دقت و بهبود توانایی مدل در استخراج ویژگی‌های سطح بالا از تصاویر هوایی شده است. در مقابل، مدل U-Net، به دلیل طراحی متقارن مبتنی بر رمزگذاری-رمزگشایی، در برخی از موارد، محدودیت‌هایی در تشخیص مرزهای کلاس‌های مختلف در داده‌های مکانی نشان داد. با این حال، این مدل نیز می‌تواند در طبقه‌بندی تصاویر هوایی عملکرد قابل قبولی ارائه دهد.

مقایسه بهینه‌سازهای مورد استفاده نشان داد که بهینه‌سازهای تطبیقی مانند RMSprop و Adam بالاترین میزان صحت و پایداری را در هر دو مدل ارائه داده‌اند. این بهینه‌سازها به دلیل تنظیم پویا و خودکار نرخ یادگیری، موجب بهبود روند همگرایی شده و دقت مدل را افزایش داده‌اند. بهینه‌ساز RMSprop در مدل U-Net بهترین نتایج را ارائه کرد، در حالی که در مدل ResNet-34، Adam و Nadam نیز عملکرد بسیار مطلوبی داشتند.

در مقابل، بهینه‌سازهای کلاسیک مانند SGD و Adagrad عملکرد ضعیف‌تری از خود نشان دادند. علت این امر، وابستگی زیاد این روش‌ها به نرخ یادگیری ثابت و کاهش

هدف از این مقایسه، بررسی تأثیر بهینه‌سازهای مختلف بر عملکرد مدل‌های یادگیری عمیق و شناسایی نقاط قوت و ضعف روش ارائه‌شده در تحقیق حاضر است. نتایج جدول (۶)، عملکرد مدل‌های مختلف یادگیری عمیق در ترکیب با بهینه‌سازهای مختلف را در مطالعات گوناگون و تحقیق حاضر نشان می‌دهد. همان‌طور که مشاهده می‌شود، عملکرد مدل‌های U-Net و ResNet-34 با بهینه‌سازهای مختلف از نظر معیارهای صحت کلی، ضریب کاپا، امتیاز F1، امتیاز ژاکارد، اختلاف مقدار و اختلاف تخصیص تفاوت‌های قابل توجهی دارد.

در تحقیق حاضر، بهینه‌ساز RMSprop در هر دو مدل U-Net و ResNet-34 عملکرد برتری از خود نشان داد و بهترین نتایج را در مقایسه با سایر بهینه‌سازها کسب کرد. در مقابل، SGD و Adagrad در مدل‌های مختلف عملکرد ضعیف‌تری داشتند که این تفاوت‌ها در مقایسه با سایر مطالعات نیز مشهود است.

با توجه به نتایج مقایسه‌ای، در مطالعه‌های قبلی، بهینه‌سازهایی مانند Adam و AdamW نیز در بسیاری از مدل‌ها عملکرد مناسبی داشتند، به‌ویژه در مطالعه ژوهونگ لی و مطالعه بینگیو چن که استفاده از Adam در مدل‌های U-Net و DeepLabv3+ نتایج خوبی به همراه داشت.

همچنین، مشاهده می‌شود که برخی از مطالعات از مدل‌های دیگری مانند L2HNet و MobileNetv2 استفاده کرده‌اند که با توجه به تفاوت‌های معماری مدل‌ها، نتایج آن‌ها از نظر صحت کلی و دیگر معیارها متفاوت است، اما همچنان دارای عملکرد ضعیف‌تری نسبت به مدل‌های استفاده شده در مطالعه حاضر است.

این مقایسه نشان‌دهنده اهمیت انتخاب مدل و بهینه‌ساز مناسب در راستای بهبود عملکرد مدل‌های یادگیری عمیق در طبقه‌بندی و تفکیک تصاویر هوایی است و می‌تواند به پژوهشگران در انتخاب بهینه‌ترین ترکیب مدل‌ها و بهینه‌سازها کمک کند.

است که در مراحل اولیه آموزش از SGD برای بهره‌گیری از خاصیت تعمیم‌پذیری آن استفاده شود و در تکرارهای بالاتر، که مدل به سمت بهینه‌های موضعی همگرا می‌شود، از بهینه‌سازهای تطبیقی مانند Adam یا RMSprop بهره گرفته شود تا سرعت و پایداری فرآیند بهینه‌سازی بهبود یابد.

همچنین، مطالعه تأثیر پارامترهای مختلف بهینه‌سازی نظیر نرخ یادگیری، اندازه دسته‌بندی، تعداد مراحل رمزنگاری و رمزگشایی، و تعداد فیلترهای خروجی می‌تواند اطلاعات بیشتری درباره نحوه بهبود عملکرد مدل‌ها فراهم کند. در همین راستا، بررسی عملکرد این بهینه‌سازها بر روی مجموعه داده‌های متنوع‌تر شامل تصاویر هوایی و ماهواره‌ای با حد تفکیک‌های مختلف و از مناطق جغرافیایی مختلف توصیه می‌شود.

علاوه بر این، ارزیابی بهینه‌سازهای نوظهور نظیر Lion، AdaBelief و RAdam می‌تواند به درک بهتر پتانسیل روش‌های جدید در بهینه‌سازی مدل‌های یادگیری عمیق کمک کند. در نهایت، استفاده از معماری‌های پیشرفته‌تر مانند U-Net++ که دارای ساختار ماژولار بهبودیافته برای استخراج ویژگی‌های چندمقیاسی است، می‌تواند صحت و کارایی مدل‌های طبقه‌بندی تصاویر هوایی را افزایش داده و بهبودهای چشمگیری را در دقت مدل‌ها فراهم آورد.

### تعارض منافع

در این پژوهش، حامی مالی و تعارض منافع وجود ندارد.

### References

- 1- Audebert, N., Le Saux, B., & Lefèvre, S. (2018). Beyond RGB: Very high resolution urban remote sensing with multimodal deep networks. *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, 20–32. Retrieved from <https://doi.org/10.1016/j.isprsjprs.2017.11.011>
- 2- Baek, W. K., Lee, M. J., & Jung, H. S. (2024). Land Cover Classification From RGB and NIR Satellite Images Using Modified U-Net Model. *IEEE Access*. Retrieved from <https://doi.org/10.1109/ACCESS.2024.3401416>

کند سرعت همگرایی در بهینه‌سازی پارامترها است. به‌طور مشخص، Adagrad به دلیل کاهش بیش از حد نرخ یادگیری در مراحل پایانی آموزش، نتوانست به دقت مطلوبی دست یابد. همچنین، SGD به‌رغم تعمیم‌پذیری مناسب، در مقایسه با روش‌های تطبیقی، سرعت همگرایی کمتری داشت و در برخی موارد، مقدار بالایی از خطای طبقه‌بندی را نشان داد. به‌منظور درک بهتر عملکرد روش پیشنهادی، نتایج حاصل از این مطالعه با یافته‌های تحقیقات پیشین مورد مقایسه قرار گرفت. بررسی مطالعات پیشین نشان داد که برخی از مقالات مشابه، از معیارهای MIoU و FWIoU برای ارزیابی مدل‌های طبقه‌بندی استفاده کرده‌اند. در حالی که این معیارها در پژوهش حاضر مورد استفاده قرار نگرفتند، نتایج نشان می‌دهد که روش‌های مبتنی بر بهینه‌سازهای تطبیقی و مدل‌های عمیق‌تر مانند ResNet-34 در اغلب موارد عملکرد مطلوب‌تری ارائه داده‌اند. علاوه بر این، مقایسه روش‌های موجود تأکید می‌کند که انتخاب مدل مناسب و بهینه‌ساز کارآمد، تأثیر مستقیمی بر دقت و کیفیت نهایی طبقه‌بندی دارد.

علی‌رغم نتایج مطلوبی که در این تحقیق به‌دست آمد، چندین چالش و محدودیت نیز وجود داشت که باید در مطالعات آینده مورد توجه قرار گیرد. یکی از محدودیت‌های اصلی، ماهیت تک‌منطقه‌ای (کشور لهستان) داده‌های مورد استفاده بود که ممکن است تعمیم‌پذیری نتایج را به سایر مناطق جغرافیایی محدود کند. علاوه بر این، برخی از بهینه‌سازها به دلیل حساسیت بالا به پارامترهای تنظیمی، ممکن است نیاز به تنظیمات دقیق داشته باشند که در برخی موارد، به‌درستی بهینه نشوند. این امر می‌تواند تأثیر مستقیمی بر دقت مدل داشته باشد و پیشنهاد می‌شود که در پژوهش‌های آتی، فرایند تنظیم بهینه خودکار پارامترهای بهینه‌سازها به‌طور دقیق‌تری مورد بررسی قرار گیرد.

با توجه به نتایج به‌دست‌آمده، در تحقیقات آینده پیشنهاد می‌شود که عملکرد بهینه‌سازهای تطبیقی مانند RMSprop و Adam در ترکیب با بهینه‌سازهای کلاسیک نظیر SGD مورد بررسی قرار گیرد. یکی از رویکردهای پیشنهادی این

- Detection Algorithm Based on Multi-Scale Feature Decomposition and Fusion and Attention Mechanism. *Sensors*, 24(13), 4227. Retrieved from <https://doi.org/10.3390/s24134227>
- 13- Ghaznavi, A., Saberioon, M., Brom, J., & Itzerott, S. (2024). Comparative performance analysis of simple U-Net, residual attention U-Net, and VGG16-U-Net for inventory inland water bodies. *Applied Computing and Geosciences*, 21(July 2023), 100150. Retrieved from <https://doi.org/10.1016/j.acags.2023.100150>
- 14- Giang, T. L., Dang, K. B., Le, Q. T., Nguyen, V. G., Tong, S. S., & Pham, V. M. (2020). U-net convolutional networks for mining land cover classification based on high-resolution UAV imagery. *IEEE Access*, 8, 186257–186273. Retrieved from <https://doi.org/10.1109/ACCESS.2020.3030112>
- 15- Hassan, E., Shams, M. Y., Hikal, N. A., & Elmougy, S. (2023). The effect of choosing optimizer algorithms to improve computer vision tasks : a comparative study. *Multimedia Tools and Applications*.
- 16- Hinton, G., Srivastava, N., & Swersky, S. (2012). Lecture 6a Overview of mini-batch gradient descent. In *Neural Networks for Machine Learning* (Vol. 4, pp. 1–31).
- 17- Kampffmeyer, M., Salberg, A. B., & Jenssen, R. (2016). Semantic Segmentation of Small Objects and Modeling of Uncertainty in Urban Remote Sensing Images Using Deep Convolutional Neural Networks. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, 680–688. Retrieved from <https://doi.org/10.1109/CVPRW.2016.90>
- 18- Kingma, D. P., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*.
- 19- Koringa, H., & Patel, M. (2024). Automated, Quick, and Precise Building Extraction From Aerial Images Using LI-Unet Model. *Radioelectronic and Computer Systems*, (2(110)), 41–51. Retrieved from <https://doi.org/10.32620/reks.2024.2.04>
- 20- Lakshminarayana, B., & Rao, K. G. (2010). Artificial neural networks in spectral-spatial landuse classification. *ISH Journal of Hydraulic Engineering*, 16, 64–73. Retrieved from <https://doi.org/10.1080/09715010.2010.10515016>
- 3- Bera, S., & Shrivastava, V. K. (2020). Analysis of various optimizers on deep convolutional neural network model in the application of hyperspectral remote sensing image classification. *International Journal of Remote Sensing*, 41(7), 2664–2683. Retrieved from <https://doi.org/10.1080/01431161.2019.1694725>
- 4- Boguszewski, A., Batorski, D., Ziemia-Jankowska, N., Dziedzic, T., & Zambrzycka, A. (2020). LandCover.ai: Dataset for Automatic Mapping of Buildings, Woodlands, Water and Roads from Aerial Imagery.
- 5- Chen, B., Xia, M., & Huang, J. (2021). Mfanet: A multi-level feature aggregation network for semantic segmentation of land cover. *Remote Sensing*. Retrieved from <https://doi.org/10.3390/rs13040731>
- 6- Clark, A., Phinn, S., & Scarth, P. (2023). Optimised U-Net for Land Use–Land Cover Classification Using Aerial Photography. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 91(2), 125–147. Retrieved from <https://doi.org/10.1007/s41064-023-00233-3>
- 7- Digra, M., Dhir, R., & Sharma, N. (2022). Land use land cover classification of remote sensing images based on the deep learning approaches: a statistical analysis and review. *Arabian Journal of Geosciences*, 15(10). Retrieved from <https://doi.org/10.1007/s12517-022-10246-8>
- 8- Ding, X., Wang, Z., Peng, S., Shao, X., & Deng, R. (2024). Research on Land Use and Land Cover Information Extraction Methods for Remote Sensing Images Based on Improved Convolutional Neural Networks. *ISPRS International Journal of Geo-Information*, 13(11). Retrieved from <https://doi.org/10.3390/ijgi13110386>
- 9- Dozat, T. (2016). Incorporating Nesterov Momentum into Adam. *ICLR Workshop*, (1), 2013–2016.
- 10- Duchi, J., Elad, H., & Yoram, S. (2012). Adaptive Subgradient Methods for Online Learning and Stochastic Optimization. In *Journal of Machine Learning Research* 12 (2011) 2121–2159 (Vol. 37, pp. 2122–2159). IEEE.
- 11- El fallah, K., El kharrim, K., & Belghyti, D. (2024). Land use land cover change detection by using remote sensing in Meknes province, Morocco with an indicator based (DPSIR) approach. *Vegetos*. Retrieved from <https://doi.org/10.1007/s42535-024-01110-z>
- 12- Fan, X., Ding, W., Li, X., Li, T., Hu, B., & Shi, Y. (2024). An Improved U-Net Infrared Small Target

4257(80)90011-5

29- Talukdar, S., Singha, P., Shahfahad, Mahato, S., Praveen, B., & Rahman, A. (2020). Dynamics of ecosystem services (ESs) in response to land use land cover (LU/LC) changes in the lower Gangetic plain of India. *Ecological Indicators*, 112(September 2019), 106121. Retrieved from <https://doi.org/10.1016/j.ecolind.2020.106121>

30- Vasavi, S., Likhitha, A. L., Premchand, V. S., & Yasaswini, J. (2024). Object Classification by Effective Segmentation of Tree Canopy Using U-Net Model. *Journal of Advances in Information Technology*, 15(3), 422–434. Retrieved from <https://doi.org/10.12720/jait.15.3.422-434>

31- Weng, L., Pang, K., Xia, M., Lin, H., Qian, M., & Zhu, C. (2023). Sgformer: A Local and Global Features Coupling Network for Semantic Segmentation of Land Cover. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. Retrieved from <https://doi.org/10.1109/JSTARS.2023.3295729>

32- Xu, W., Deng, X., Guo, S., Chen, J., Sun, L., Zheng, X., ... Wang, X. (2020). High-resolution u-net: Preserving image details for cultivated land extraction. *Sensors (Switzerland)*, 20(15), 1–23. Retrieved from <https://doi.org/10.3390/s20154064>

33- Zeiler, M. D. (2012). ADADELTA: An Adaptive Learning Rate Method.

34- Zhang, C., Sargent, I., Pan, X., Li, H., Gardiner, A., Hare, J., & Atkinson, P. M. (2019). Joint Deep Learning for land cover and land use classification. *Remote Sensing of Environment*, 221(May 2018), 173–187. Retrieved from <https://doi.org/10.1016/j.rse.2018.11.014>

21- Li, Z., Zhang, H., Lu, F., Xue, R., Yang, G., & Zhang, L. (2022). Breaking the resolution barrier: A low-to-high network for large-scale high-resolution land-cover mapping using low-resolution labels. *ISPRS Journal of Photogrammetry and Remote Sensing*. Retrieved from <https://doi.org/10.1016/j.isprs.2022.08.008>

22- Loshchilov, I., & Hutter, F. (2019). Decoupled weight decay regularization. In 7th International Conference on Learning Representations, ICLR 2019.

23- Naanjam, R., & Farnood Ahmadi, F. (2024). An improved self-training network for building and road extraction in urban areas by integrating optical and radar remotely sensed data. *Earth Science Informatics*, 17(3), 2159–2176. Retrieved from <https://doi.org/10.1007/s12145-024-01270-1>

24- Pagliardini, M., Ablin, P., & Grangier, D. (2024). The AdEMAMix Optimizer: Better, Faster, Older, 1–42.

25- Pontius, R. G., & Millones, M. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407–4429. Retrieved from <https://doi.org/10.1080/01431161.2011.552923>

26- Robbins, H., & Monro, S. (1951). A Stochastic Approximation Method. *The Annals Of Mathematical Statistics*, 22(3), 400–407.

27- Saeezadeh, N., Jalali, S. M. J., Khan, B., Kebria, P. M., & Mohamed, S. (2024). A new optimization approach based on neural architecture search to enhance deep U-Net for efficient road segmentation. *Knowledge-Based Systems*, 296(December 2023), 111966. Retrieved from <https://doi.org/10.1016/j.knsys.2024.111966>

28- Strahler, A. H. (1980). The use of prior probabilities in maximum likelihood classification of remotely sensed data. *Remote Sensing of Environment*, 10(2), 135–163. Retrieved from <https://doi.org/10.1016/0034->

---

## COPYRIGHTS

©2025 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons [Attribution-NoDerivs 4.0 International \(CC BY-ND 4.0\)](https://creativecommons.org/licenses/by-nd/4.0/)



