



ORIGINAL RESEARCH PAPER

Object detection and classification with Sentinel-2 imagery using ResNet

P. Heidari, A. Milan*, A. Gharagozlou

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

ABSTRACT

Received: 05 December 2024
 Reviewed: 30 March 2025
 Revised: 16 May 2025
 Accepted: 26 May 2025

KEYWORDS:

Classification
 Land Cover and Land Use
 Remote Sensing
 Deep Learning
 Convolutional Neural Network

* Corresponding author

✉ a_milan@sbu.ac.ir

☎ (+9821) 73932456

Background and Objectives: Nowadays, getting land cover and land use information is crucial due to the growing number of uses for this data. The primary method for obtaining this information is considered to be through the utilization of remote sensing images. Image classification techniques should be employed so as to extract land cover and use from these images. Deep learning techniques can be utilized effectively to the classification of land cover and land use simply because of their great potential in image classification. But there are also challenges when applying these techniques as well. Model overfitting is one of the most common issues when utilizing deep learning algorithms. Another major issue with these methods is that they demand a significant amount of data during the training stage. Additionally, gradient exploding/vanishing and determining the suitable architecture are further challenges associated with these methods for extracting land cover and use from remote sensing imagery.

Methods: The main objective of this research is to employ different techniques to overcome the challenges to achieve high classification accuracy. To solve the problem of model overfitting, dropout and early stopping approaches were utilized to ensure that the accuracy of the training and test data were close. The data augmentation strategy can prevent model overfitting in addition to addressing the lack of training data. As a result, this method was employed to augment training data and also avoiding model overfitting. The gradient clipping strategy was additionally used in this study to mitigate gradient exploding and vanishing in deep learning models. This study used the ResNet18 model to classify the EuroSat dataset, enabling us to obtain highly effective classification accuracy.

Findings: Initially, this architecture was used with with the early stopping strategy, and the model had an overall accuracy of 91.19 percent and a kappa coefficient of 0.9018. The data augmentation technique was then applied to the same model, and the model achieved an overall accuracy of 91.78 percent with a kappa coefficient of 0.9085, surpassing the previous stage. In the last stage, a dropout method with a rate of 0.5 and a gradient clipping with a threshold of 0.1 were added to the previous model, and the model achieved an overall accuracy of 93.11 percent and a kappa coefficient of 0.9233, which was more accurate than the previous two stages.

Conclusion: These results indicate that the EuroSat's land cover and land use classification accuracy in the final stage was higher than in prior stages.



NUMBER OF REFERENCES

78



NUMBER OF FIGURES

19



NUMBER OF TABLES

4

مقاله پژوهشی

تشخیص و طبقه‌بندی عوارض در تصاویر Sentinel-2 با استفاده شبکه Resnet

پویا حیدری، اصغر میلان*، علیرضا قراگوزلو

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

چکیده

پیشینه و اهداف: امروزه با توجه به استفاده روز افزون از اطلاعات پوشش و کاربری اراضی در کاربردهای مختلف، کسب این اطلاعات امری ضروری می‌باشد. استفاده از تصاویر سنجنش از دوری به عنوان راهکار اصلی کسب این اطلاعات محسوب می‌شود. برای استخراج پوشش و کاربری اراضی از این تصاویر، می‌توان از تکنیک‌های طبقه‌بندی تصاویر بهره برد. با توجه به پتانسیل بالای روش‌های یادگیری عمیق در طبقه‌بندی تصاویر، این روش‌ها می‌توانند به طور موثری در طبقه‌بندی پوشش و کاربری اراضی استفاده شوند. با این حال، استفاده از این روش‌ها همراه با چالش‌هایی نیز می‌باشد. یکی از مشکلات اصلی استفاده از روش‌های یادگیری عمیق، بیش برآزش مدل می‌باشد. از دیگر معضلات اصلی این روش‌ها می‌توان به نیازمند بودن این روش‌ها به تعداد بسیار زیاد داده در مرحله آموزش اشاره نمود. همچنین ناپدید شدن و انفجار گرادیان و انتخاب معماری مناسب از دیگر مشکلات و چالش‌های این روش‌ها برای استخراج پوشش و کاربری اراضی از تصاویر سنجنش از دور می‌باشند.

روش‌ها: هدف اصلی این پژوهش استفاده از تکنیک‌های مختلف برای رفع این چالش‌ها و رسیدن به دقت‌های بالا در انجام طبقه‌بندی پوشش و کاربری اراضی می‌باشد. برای مرتفع نمودن چالش بیش برآزش مدل، از تکنیک‌های حذف تصادفی و توقف زودهنگام استفاده شد تا دقت در داده‌های آموزشی و تست نزدیک به یکدیگر باشند. استفاده از روش داده افزایی می‌تواند کمبود داده‌های آموزشی را برطرف نماید و از بیش برآزش مدل نیز جلوگیری کند. به همین علت از این روش برای افزایش داده‌های آموزشی مدل استفاده شد. تکنیک برش گرادیان نیز در این پژوهش استفاده شد تا از انفجار و ناپدید شدن گرادیان در مدل‌های یادگیری عمیق جلوگیری کند. معماری استفاده شده در این پژوهش برای طبقه‌بندی مجموعه داده EuroSat، مدل ResNet18 بوده است.

یافته‌ها: در ابتدا از این معماری به همراه تکنیک توقف زودهنگام برای انجام طبقه‌بندی استفاده شد و مدل به دقت کلی ۹۱/۱۹ درصد و ضریب کاپای ۰/۹۰۱۸ رسید. سپس به همین مدل تکنیک داده افزایی اضافه شد و مدل به دقت کلی ۹۱/۷۸ درصد و ضریب کاپای ۰/۹۰۸۵ دست یافت که نشان می‌دهد نسبت به مرحله قبلی دقت‌های بهتری حاصل شده است. در مرحله آخر تکنیک حذف تصادفی با نرخ ۰/۵، برش گرادیان با حد آستانه ۰/۱ نیز به مدل قبلی اضافه شد و مدل به دقت کلی ۹۳/۱۱ درصد و ضریب کاپای ۰/۹۲۳۳ رسید که نسبت به دو مرحله قبلی به دقت‌های بهتری رسیده است.

نتیجه‌گیری: این نتایج نشان می‌دهد که دقت طبقه‌بندی پوشش و کاربری اراضی مجموعه داده EuroSat در مرحله آخر نسبت به مراحل قبلی به دقت بهتری دست یافته است.

تاریخ دریافت: ۱۵ آذر ۱۴۰۳

تاریخ داوری: ۱۰ فروردین ۱۴۰۴

تاریخ اصلاح: ۲۶ اردیبهشت ۱۴۰۴

تاریخ پذیرش: ۰۴ خرداد ۱۴۰۴

واژگان کلیدی:

طبقه‌بندی

پوشش و کاربری اراضی

سنجنش از دور

یادگیری عمیق

شبکه عصبی پیچشی

* نویسنده مسئول

a_milan@sbu.ac.ir

۰۲۱-۷۳۹۳۲۴۵۶ ①

مقدمه

فتوگرامتری هوایی و استفاده از داده‌های سنجنش از دوری ماهواره‌ای می‌باشند. در روش نقشه‌برداری زمینی این اطلاعات با استفاده از بررسی میدانی و تفسیر سنتی انجام می‌شود که کاری بسیار فشرده، زمانبر و پرهزینه‌ای می‌باشد [۶]. قبل از اینکه تصاویر ماهواره‌ای در دسترس قرار گیرد، معمولاً از تصاویر فتوگرامتری هوایی و تفسیر سنتی برای این منظور استفاده می‌شد. تفسیر سنتی نیاز به یک اپراتور متخصص داشت. همچنین این کار زمانبر و غیر قابل تکرار بوده است [۷]. امروزه با در دسترس بودن تصاویر ماهواره‌ای سنجنش از دوری، می‌توان اطلاعات پوشش و کاربری اراضی را در یک منطقه وسیع بدست آورد [۸]. این تصاویر علاوه بر ارزان‌تر بودن نسبت به روش‌های دیگر، می‌توانند با استفاده از داده‌های چند زمانی خود، اطلاعات پوشش و کاربری اراضی

امروزه یکی از ابزارهای مهم برای نظارت زمین، اطلاعات پوشش و کاربری اراضی می‌باشد [۱]. استفاده از این اطلاعات می‌تواند برای برنامه‌ریزی در جهت توسعه اقتصادی استفاده شود. پوشش و کاربری اراضی یکی از مهم‌ترین اطلاعات برای مدیران در جهت مدیریت صحیح زمین خواهد بود [۲]. این اطلاعات در حفاظت محیط زیست نیز نقش مهمی را ایفا می‌کند [۳]. همچنین در یک شهر، برنامه‌ریزی در راستای پوشش و کاربری اراضی شهری برای برآورده نمودن نیازهای رو به رشد سریع شهروندان و تضمین توسعه پایدار شهری ضروری است [۴]. روش‌های مختلفی برای کسب اطلاعات پوشش و کاربری اراضی وجود دارد [۵]. این روش‌ها شامل نقشه‌برداری زمینی، استفاده از داده‌های

سنجش از دوری و تصاویر معمول در حوزه پردازش تصویر از لحاظ جزئیات و ساختار تفاوت‌های زیادی دارند [۲۷]. با توجه به چالش‌های مطرح شده در حوزه طبقه‌بندی تصاویر سنجش از دوری با استفاده از مدل‌های یادگیری عمیق، این موضوع یکی از تحقیقات اصلی در حوزه پردازش تصاویر سنجش از دوری است و با توجه به کاربردهای این حوزه در بحث نظارت و پایش زمین، ضرورت انجام پژوهش در این موضوع را دوچندان می‌کند. هدف اصلی این پژوهش، رفع این چالش‌ها و رسیدن به دقت‌های بالا در طبقه‌بندی پوشش و کاربری اراضی می‌باشد. در بخش بعدی به برخی از پژوهش‌های انجام شده در این حوزه پرداخته می‌شود. در بخش سوم این پژوهش به مواد و روش‌های این تحقیق اشاره می‌شود و سپس در بخش بعدی به روش پیشنهادی و نتایج بدست آمده پرداخته می‌شود. در انتها، بخش آخر متعلق به نتیجه‌گیری بدست آمده از این پژوهش خواهد بود.

مروری بر تحقیقات پیشین

استفاده از داده‌های سنجش از دوری برای طبقه‌بندی پوشش و کاربری اراضی اولین بار به سال ۱۹۴۰ میلادی برمی‌گردد، زمانی که فرانسیس جی مارشور شروع به تهیه نقشه از کل ایالات متحده با استفاده از عکس‌برداری هوایی نمود [۲۸]. سال‌ها بعد، پس از پرتاب ماهواره مجهز به اسکنر چندطیفی در جولای ۱۹۷۲ میلادی و شروع برنامه لندست، مطالعات با استفاده از داده‌های تصاویر سنجش از دور برای طبقه‌بندی پوشش و کاربری اراضی به سطح جدیدی گام برداشت. در واقع، با تولد برنامه لندست و انتشار داده‌ها، تلفیق داده‌ها، تشخیص تغییرات زمین به صورت زمانی و کاربردهای اکولوژیکی داده‌های ماهواره‌ای به حوزه پوشش و کاربری اراضی معرفی شد [۲۹]. یکی از رایج‌ترین کاربردهای این تصاویر و داده‌های سنجش از دوری استفاده در تولید اطلاعات پوشش و کاربری اراضی می‌باشد [۳۰].

امروزه نیز برای استخراج پوشش و کاربری اراضی به طور گسترده از تصاویر سنجش از دور و طبقه‌بندی آن‌ها با استفاده از روش‌های یادگیری عمیق استفاده می‌شود [۳۱]. با وجود مزیت‌های روش‌های یادگیری عمیق در انجام این کار نسبت به سایر روش‌ها، همچنان این روش‌ها در طبقه‌بندی پوشش و کاربری اراضی دارای چالش‌ها و ضعف‌هایی هستند و با وجود تحقیقات گسترده درباره این موضوع، اما همچنان این چالش‌ها مانع اصلی رسیدن این مدل‌ها به دقت‌های بالا می‌باشد. در ادامه به برخی از تحقیقات صورت گرفته در این حوزه پرداخته خواهد شد.

لی و همکاران از یادگیری انتقالی برای طبقه‌بندی مجموعه داده UC Merced استفاده نمودند. آن‌ها از ۳ شبکه عصبی پیچشی معروف از پیش آموزش دیده VGG19، ResNet50 و InceptionV3 که از وزن‌های مجموعه داده ImageNet2015 استفاده می‌کردند، بهره بردند. برای ارزیابی عملکرد روش پیشنهادی خود، آن‌ها دقت کلی و ضریب کاپا هر

را به صورت به روز در اختیار کاربران و استفاده‌کنندگان این اطلاعات بگذارند. همچنین تفسیر و تجزیه و تحلیل اطلاعات پوشش و کاربری اراضی با استفاده از تصاویر سنجش از دوری با استفاده از روش‌های اتوماتیک و دقیق پردازش تصاویر رقومی امکان پذیر است [۹]. یکی از روش‌های استخراج اطلاعات پوشش و کاربری اراضی از تصاویر سنجش از دوری، طبقه بندی این تصاویر می‌باشد [۱۰]. الگوریتم‌های یادگیری عمیق در بسیاری از کاربردهای سنجش از دوری استفاده می‌شوند، که یکی از این کاربردها، طبقه‌بندی تصاویر می‌باشد [۱۱، ۱۲]. این روش‌ها به طور موثری طبقه‌بندی پوشش و کاربری اراضی استفاده شده‌اند و پتانسیل بالایی برای انجام این کار دارند [۱۳، ۱۴].

یادگیری عمیق قادر به مدل سازی نمایش سلسله مراتبی ویژگی‌ها است و پوشش و کاربری اراضی را می‌توان با چنین ویژگی‌هایی توصیف کرد، بنابراین مدل یادگیری عمیق یک راه بسیار موثر برای طبقه بندی پوشش و کاربری اراضی می‌باشد [۱۵]. در استخراج ویژگی‌های مکانی چندسطحی استخراج‌شده از تصاویر سنجش از دور، یادگیری عمیق از روش‌های سنتی بهتر عمل کرده و به آنها اجازه می‌دهد تا عملکرد بالایی در طبقه‌بندی تصویر ارائه دهند [۱۶].

یکی از مزیت‌های قابل توجه رویکردهای یادگیری عمیق این است که آنها می‌توانند به طور تطبیقی ویژگی‌های متمایز را از تصاویر بیاموزند [۱۷، ۱۸، ۱۹]. این الگوریتم‌ها بازدهی و انعطاف پذیری بالایی دارند، سازماندهی سطوح مختلفی از اطلاعات برای بیان روابط پیچیده بین داده‌ها را به راحتی انجام می‌دهند و می‌توانند ویژگی‌های معنایی سطح بالا را بیاموزد [۲۰، ۲۱، ۲۲]. با توجه به مزیت‌های بیان شده روش‌های یادگیری عمیق در طبقه‌بندی پوشش و کاربری اراضی، می‌توان از این روش برای این منظور استفاده نمود و به دقت‌های خوبی برای این کار رسید. با این حال مدل‌های یادگیری عمیق برای رسیدن به دقت‌های بالا با چالش‌هایی نیز مواجه هستند. برخی از این چالش‌ها عبارتند از: - از چالش‌های اصلی در استفاده از یادگیری عمیق می‌توان به مشکل بیش‌برازش مدل اشاره نمود [۲۳]. در این حالت مدل‌های یادگیری عمیق در مواجه با داده‌های تست، عملکرد ضعیف‌تری نسبت به داده‌های آموزش خواهد داشت [۲۴].

- یکی از چالش‌های مهم در مدل‌های یادگیری عمیق مسئله ناپدید شدن و انفجار گرادیان است. این مسئله باعث اختلال در پارامترها در طول فرایند آموزش مدل یادگیری عمیق می‌شود که منجر به آموزش ناپایدار مدل می‌گردد [۲۵].

- بهترین راه برای بهبود یک مدل یادگیری عمیق، آموزش آن بر روی داده‌های بسیار زیاد است [۲۶]. چالش دیگر در استفاده از مدل‌های یادگیری عمیق زمانی اتفاق می‌افتد که داده‌های بیشتری برای آموزش مدل یادگیری عمیق وجود نداشته باشد.

- انتخاب یک مدل و معماری مناسب برای انجام طبقه بندی تصاویر سنجش از دوری از چالش‌های اساسی در این حوزه است زیرا، تصاویر

استیواکتاکس و همکاران یک شبکه پیچشی که شامل ۳ لایه پیچشی بود، برای طبقه‌بندی مجموعه داده UC Merced پیشنهاد نمودند. آن‌ها در این تحقیق از تکنیک داده‌افزایی برای افزایش دقت و حل مشکل کمبود داده استفاده نمودند. معیار امتیاز F-1 در روش پیشنهادی آن‌ها ۸۹/۵۳ درصد بوده است [۳۸].

ناوشاد و همکاران از ResNet50 و VGG16 از پیش آموزش داده شده برای طبقه‌بندی تصاویر EuroSat استفاده نمودند. آن‌ها از تکنیک‌های داده‌افزایی، برش‌گردان، حذف تصادفی و توقف زودهنگام برای رسیدن به نتایج بهتر استفاده نمودند. تکنیک برش‌گردان از ناپدید شدن و انفجار گرادیان جلوگیری می‌کند تا مرحله آموزش پایدار بماند. همچنین مقدار برش‌گردان استفاده شده در این پژوهش برابر ۰/۱ بوده است [۳۹].

رنگل و همکاران از مدل‌های AlexNet، ResNet، DenseNet و برای طبقه‌بندی تصاویر سنجنش از دوری EuroSat استفاده نمودند. آن‌ها از تکنیک داده‌افزایی در تمامی مدل‌ها استفاده نمودند. دقت این مدل‌ها به ترتیب برابر ۸۳/۷، ۸۳/۵ و ۹۲/۵ بوده است [۴۰].

ژانگ و همکاران از یک مدل به نام CNN-CapsNet برای طبقه‌بندی پوشش و کاربری اراضی تصاویر استفاده نمودند. شبکه عصبی پیچشی برای استخراج نقشه‌های ویژگی و شبکه کپسولی برای طبقه‌بندی کردن تصاویر استفاده شد. برای جلوگیری از بیش‌برازش این مدل از حذف تصادفی استفاده شد. این شبکه برای طبقه‌بندی دو مجموعه داده AID و NWPU-RESISC45 به دقت کلی ۹۶/۳۲ و ۹۲/۶ درصد رسید [۴۱].

فیاض و همکاران برای انجام طبقه‌بندی مجموعه داده UC Merced از یادگیری انتقالی استفاده نمودند. مدل‌های مورد استفاده آن‌ها برای انجام این کار دو شبکه Inception-v3 و DenseNet121 بوده است. در مدل‌های استفاده شده برای انجام این کار از تکنیک داده‌افزایی استفاده شد. همچنین در میان لایه‌های کاملاً متصل استفاده شده برای انجام طبقه‌بندی از ۲ لایه حذف تصادفی استفاده نمودند. امتیاز F-1 برای این دو شبکه در این طبقه‌بندی به ترتیب برابر ۹۲ و ۹۱ درصد بوده است [۴۲].

آلبارکاتی و همکاران از یک مدل که از ترکیب دو شبکه عصبی پیچشی پیشنهادی به نام‌های IBNR-65 (شامل ۶۵ لایه پنهان) و Densenet-64 (شامل ۶۴ لایه پنهان) بود را برای طبقه‌بندی پوشش و کاربری اراضی استفاده نمودند. آن‌ها همچنین از داده‌افزایی نیز در مدل خود استفاده کردند. دقت طبقه‌بندی این شبکه برای دو مجموعه داده EuroSat و NWPU-RESISC45 به ترتیب برابر ۸۹/۵ و ۹۱/۷ بوده است [۴۳].

دستور و حسن در یک پژوهش جامع ۳۹ شبکه عصبی پیچشی که از یادگیری انتقالی برای طبقه‌بندی پوشش و کاربری اراضی استفاده می‌نمودند را بررسی کردند. آن‌ها مجموعه داده EuroSat را به ۳ بخش تقسیم نمودند. داده‌های آموزش، اعتبار سنجی و تست که به ترتیب ۸۰، ۱۰ و ۱۰ درصد این مجموعه را تشکیل می‌دادند. آن‌ها از داده‌افزایی، توقف زود هنگام نرخ یادگیری انطباقی برای افزایش دقت شبکه‌های

دو معماری بدون یادگیری انتقالی و مبتنی بر یادگیری انتقالی را محاسبه کردند. دقت کلی معماری‌های مبتنی بر یادگیری انتقالی برای معماری‌های VGG19 و ResNet50 به ترتیب ۵۳/۱، ۱۷/۹ و ۵/۴ درصد نسبت به معماری‌های اصلی که دقت آن‌ها ۳۵/۹، ۷۷/۸ و ۸۷٪ بودند افزایش یافت. به طور مشابه، ضریب کاپا معماری‌های مبتنی بر یادگیری انتقال به ترتیب برابر ۰/۹۵۶، ۰/۹۶۸ و ۰/۹۹۳ بودند که ۰/۱۱۹، ۰/۵۹۱ و ۰/۰۶ افزایش را نشان می‌دهد [۳۲].

یو و همکاران از روش داده‌افزایی برای افزایش داده‌ها و رفع مشکل کمبود داده آموزشی استفاده کردند. آن‌ها از یک شبکه عصبی پیچشی که شامل ۴ لایه پیچشی و ۲ لایه ادغام و یک لایه کاملاً متصل بود برای طبقه‌بندی مجموعه داده‌های SAT-4، SAT-6، RSSCN7 و UC Merced استفاده نمودند. در این پژوهش شبکه عصبی پیچشی که از روش داده‌افزایی استفاده می‌کرد نسبت به همان شبکه عصبی پیچشی که از روش داده‌افزایی استفاده نمی‌کرد، عملکرد بهتری داشته است [۳۳].

شاوکی و همکاران از یک مدل CNN-MLP که مزایای شبکه‌های عصبی پیچشی و پرسپترون چند لایه به صورت همزمان را دارد معرفی کردند. در این روش ویژگی‌ها با استفاده از شبکه‌های عصبی پیچشی از قبل آموزش دیده بدون لایه‌های کاملاً متصل ایجاد می‌شوند. سپس پرسپترون چند لایه برای طبقه‌بندی کلاس‌ها استفاده می‌شود. این مدل برای طبقه‌بندی مجموعه داده سنجنش از دوری UC-Merced، AID و NWPU-RESISC45 استفاده شد. همچنین برای افزایش داده برای این مجموعه داده‌ها از تکنیک داده‌افزایی استفاده شد. تکنیک داده‌افزایی دقت طبقه‌بندی این مجموعه داده‌ها را به ترتیب ۲/۶۶، ۴/۱۰ و ۳/۷۰ درصد افزایش داد. دقت نهایی این مدل با استفاده از داده‌افزایی به ترتیب برابر ۹۹/۸۶، ۹۸/۱۰ و ۹۷/۴۰ درصد بوده است [۳۴].

ژانگ و همکاران از یک روش مدل ترکیبی برای طبقه‌بندی تصاویر مجموعه داده EuroSat استفاده نمودند که در ساختار این مدل ترکیبی از شبکه ResNet برای استخراج ویژگی‌ها استفاده شد. دقت شبکه پیشنهادی آن‌ها برای طبقه‌بندی این مجموعه داده ۹۶/۶۲ درصد بوده است [۳۵].

آلم و کومار از مدل‌های از پیش آموزش دیده InceptionV3، ResNetV2 و VGG19 برای طبقه‌بندی مجموعه داده UC Merced استفاده نمودند. آن‌ها از تکنیک حذف تصادفی با مقدار ۰/۵ که یکی از روش‌های نظم دهی است برای جلوگیری از بیش‌برازش استفاده نمودند. آن‌ها از تکنیک توقف زودهنگام در همه مدل‌های خود استفاده نمودند. دقت این مدل‌ها به ترتیب برابر ۹۲/۴۶ و ۹۴/۳۸ و ۹۹/۶۴ بودند [۳۶].

خان و بسلامه یک شبکه ترکیبی که از دو شبکه یادگیری عمیق تشکیل شده بود (شامل شبکه‌های متراکم متصل و شبکه کاملاً پیچشی) را پیشنهاد نمودند. شبکه اول آن‌ها DenseNet و شبکه دوم آن‌ها VGG16 بوده است. دقت کلی طبقه‌بندی روش پیشنهادی آن‌ها برای طبقه‌بندی مجموعه داده‌های UC Merced و EuroSAT برابر با ۹۶ و ۹۱/۶۸ درصد بوده است [۳۷].

شدند. این داده‌ها در آموزش مدل شرکت ندارند و هدف استفاده از آن‌ها ارزیابی مدل در حین فرآیند آموزش با استفاده از مقدار تابع ضرر و دقت داده‌های اعتبار سنجی خواهد بود. داده‌های تست نیز که ۱۰ درصد داده‌ها را شامل می‌شوند برای ارزیابی دقت مدل و پیش‌بینی این داده‌ها با استفاده از مدل آموزش دیده استفاده خواهند شد. این داده‌ها نیز در فرآیند آموزش شبکه استفاده نخواهند شد. همچنین تکنیک توقف زودهنگام در تمامی مراحل اجرایی این تحقیق استفاده شد. در این تکنیک، اگر مقدار ضرر داده اعتبار سنجی در ۱۰ اپک آموزشی بهتر نشد فرآیند آموزش متوقف خواهد شد.

در مرحله اول این پژوهش هیچکدام از تکنیک‌های حذف تصادفی، داده‌افزایی و برش‌گردان استفاده نشد و از نرخ یادگیری ۰/۰۰۱ که مقدار پیش‌فرض بهینه سازتخمین‌گشتاور تطبیقی می‌باشد استفاده شد. تنها تکنیک استفاده شده در این مرحله، توقف زودهنگام بوده است. فرآیند انجام این مرحله در شکل (۱) نشان داده شده است.

در مرحله دوم، تنها از تکنیک‌های داده‌افزایی و توقف زودهنگام برای آموزش شبکه ResNet18 با استفاده از مجموعه داده EuroSat استفاده شد و مقدار نرخ یادگیری نیز همان ۰/۰۰۱ بوده است. در شکل (۲) فرآیند انجام این مرحله نشان داده شده است.

در مرحله سوم، از روش‌های داده‌افزایی، حذف تصادفی، برش‌گردان و توقف زودهنگام برای بهبود عملکرد مدل ResNet18 در طبقه‌بندی پوشش و کاربری اراضی مجموعه داده EuroSat استفاده شد. مقدار نرخ یادگیری در این مرحله نیز ۰/۰۰۱ بوده و همچنین مقدار حد آستانه برش‌گردان و نرخ حذف تصادفی در این مرحله ۰/۱ و ۰/۵ بوده‌اند. در شکل (۳) مراحل انجام این فرآیند مشخص شده است.

در ادامه به مدل استفاده شده و روش‌هایی که منجر به بهبود مدل منجر شده‌اند توضیح داده می‌شود. در انتهای این بخش به روش‌های ارزیابی دقت طبقه‌بندی نیز اشاره خواهد شد.

مدل و معماری ResNet

همانطور که گفته شد، تصاویر مورد استفاده در سنجش از دور، تفاوت‌های اساسی با تصاویر معمول مورد استفاده در بینایی کامپیوتر دارند و به همین دلیل انتخاب یک مدل مناسب برای طبقه‌بندی پوشش و کاربری اراضی می‌تواند روی دقت نهایی طبقه‌بندی تأثیر زیادی داشته باشد. معماری ResNet یکی از مدل‌های شبکه عصبی پیچشی است که در طبقه‌بندی تصاویر سنجش از دور، دقت‌های بالایی را ارائه کرده است [۴۹]. به دلیل دقت‌های بالای این معماری در کاربردهای سنجش از دور و به خصوص در حوزه طبقه‌بندی تصاویر سنجش از دور، از مدل ResNet18 در این پژوهش استفاده شد.

خود استفاده نمودند. نتایج این تحقیق نشان می‌دهد که سه شبکه عصبی پیچشی ResNet50، EfficientNetV2B0 و ResNet152 بهترین نتایج را در طبقه‌بندی مجموعه داده EuroSat حاصل می‌کند. دقت کلی و ضریب کاپای داده‌های تست برای شبکه ResNet50 برابر ۹۶/۷۸ درصد و ۰/۹۶۴۱ و برای شبکه EfficientNetV2B0 برابر ۹۶/۴۱ درصد و ۰/۹۶ بوده است. این معیارها برای شبکه ResNet152 به ترتیب برابر ۹۶/۰۴ و ۰/۹۵۵۹ می‌باشد [۴۴].


پدربیس و همکاران از معماری U-Net برای طبقه‌بندی مجموعه داده UOPNOA استفاده نمودند. این مجموعه داده، از پایگاه داده تصاویر هوایی کشور اسپانیا تولید شده است که به صورت عمومی در دسترس است. آن‌ها برای جلوگیری از ناپدید شدن و انفجار گرادیان از برش‌گردان با حد آستانه ۱ استفاده نمودند [۴۵].

در تحقیقات صورت گرفته تاکنون، محققین برای حل چالش‌های موجود از راهکارهای مختلفی استفاده نمودند. در اکثر آن‌ها برای انجام طبقه‌بندی از مدل‌های شبکه عصبی پیچشی استفاده شده است. این معماری‌ها برای انجام طبقه‌بندی تصاویر سنجش از دور، با توجه به مزیت‌های آن‌ها در انجام این کار به طور گسترده استفاده شده‌اند. در این پژوهش‌ها، برای حل مشکل بیش‌برازش این مدل‌ها از تکنیک‌های توقف زودهنگام و روش حذف تصادفی که یکی از روش‌های نظم‌دهی معروف در روش‌های یادگیری عمیق است استفاده شده است. برای حل کمبود داده و بیش‌برازش در این مدل‌ها از داده‌افزایی استفاده گردیده است که علاوه بر حل این چالش‌ها، به بهبود دقت طبقه‌بندی نیز منجر شده‌اند. همچنین از تکنیک برش‌گردان برای جلوگیری از ناپدید شدن و انفجار گرادیان استفاده شده است. با توجه به مزیت‌های این روش‌ها در حل چالش‌های ذکر شده در پژوهش حاضر برای بهبود دقت طبقه‌بندی پوشش و کاربری اراضی، استفاده از ترکیب روش‌های داده‌افزایی، حذف تصادفی، توقف زودهنگام و برش‌گردان مورد بررسی قرار گرفته است.


روش تحقیق

مراحل انجام شده در این پژوهش


این پژوهش در ۳ مرحله انجام شد و در هر مرحله نسبت به مرحله قبل به صورت افزایشی، تکنیک‌های توقف زودهنگام، داده‌افزایی، حذف تصادفی و برش‌گردان اعمال شد. مجموعه داده در همه مراحل به سه قسمت داده‌های آموزش، اعتبارسنجی و تست تقسیم شدند. داده‌های آموزش که ۷۰ درصد داده‌های این مجموعه داده را شامل می‌شدند، برای آموزش شبکه ResNet18 استفاده شد. داده‌های اعتبار سنجی که ۲۰ درصد کل داده‌ها بودند برای ارزیابی مدل در حین آموزش استفاده



شکل ۱: فرآیند انجام طبقه‌بندی در مرحله اول
Fig. 1: The process of performing classification in the first stage



شکل ۲: مراحل انجام شده در مرحله دوم
Fig. 2: Steps taken in the second stage



شکل ۳: فرآیند انجام شده در مرحله سوم
Fig. 3: The process carried out in the third stage

است. در این بلوک، مولفه اول شامل یک لایه پیچشی دو بعدی با اندازه فیلتر (3×3) و گام ۱ به همراه یک لایه نرمال‌سازی دسته‌ای و یک تابع فعال‌ساز واحد یکسو شده خطی می‌باشد. مولفه دوم این بلوک شامل یک لایه پیچشی دو بعدی با اندازه دو بعدی با اندازه فیلتر (3×3) و گام ۱ به همراه یک لایه نرمال‌سازی دسته‌ای می‌باشد. در نهایت، اتصال میانبر و ورودی قبل از اعمال تابع فعال‌ساز واحد یکسو شده خطی با هم ترکیب می‌شوند. در لایه نرمال‌سازی دسته‌ای تکنیکی برای نرمال‌سازی داده‌ها در زمانی که از لایه پیچشی عبور می‌کند می‌باشد که با این کار داده بعد از اعمال لایه پیچشی، دارای میانگین یک و انحراف معیار واحد خواهد شد. با این کار دقت و سرعت آموزش بهبود داده خواهد شد.

بلوک Convolutional

در بلوک Convolutional ابعاد ورودی و خروجی مطابقت ندارند. اتصال میانبر با استفاده از W_s یک نگاشت خطی را برای تطابق اندازه ابعاد بین x و F با استفاده از رابطه (۲) انجام می‌دهند.

$$y = F(x, \{w_i\}) + w_s x \quad (2)$$

در رابطه (۲)، x و y به ترتیب بردارهای ورودی و خروجی لایه Convolutional هستند و تابع F نشان دهنده لایه ادغام شده است. ساختار بلوک Convolutional همانند بلوک Identity می‌باشد، با این تفاوت‌ها که در اتصال میانبر شامل یک لایه پیچشی دو بعدی با اندازه دو بعدی با اندازه فیلتر (1×1) و گام ۲ به همراه یک لایه نرمال‌سازی دسته‌ای است و اندازه گام اولین لایه پیچشی این بلوک ۲ می‌باشد. شکل کلی ساختار بلوک Convolutional در شکل (۶) نشان داده شده است.

معماری ResNet18


ساختار معماری ResNet18 استفاده شده در این پژوهش در شکل (۷) مشخص شده است.

مطابق شکل (۷)، در ابتدا یک لایه‌گذاری صفر به ابعاد (3×3) بر روی تصویر با ابعاد 224×224 اعمال می‌شود. در مرحله اول، تصویر از یک لایه پیچشی با ابعاد فیلتر (7×7) ، گام ۲ عبور می‌کند که تعداد ۶۴ نقشه ویژگی را تولید خواهد نمود. سپس از یک لایه نرمال‌سازی دسته‌ای با تابع فعال‌ساز واحد یکسو شده خطی عبور می‌کند و در آخر برای کاهش ابعاد تصویر از لایه تجمیع بیشینه با ابعاد (3×3) و گام ۲ استفاده می‌شود.

در مرحله دوم تصویر از یک بلوک Convolutional عبور می‌کند که در آن، لایه پیچشی اول و دوم هر کدام ۶۴ نقشه ویژگی از تصویر را تولید می‌کند. در این مرحله، استثنا از یک بلوک Convolutional که اندازه گام دو لایه پیچشی آن ۱ است، استفاده می‌شود. سپس تصویر از یک بلوک Identity که هر کدام از لایه‌های پیچشی آن ۶۴ نقشه ویژگی را ایجاد می‌کند، عبور خواهد نمود.

مدل ResNet از اصل یادگیری باقی مانده برای سهولت آموزش شبکه‌های بسیار عمیق پیروی می‌کنند [۵۰]. مدل‌های ResNet دارای چندین نسخه است که رایج‌ترین آن‌ها ۵ نسخه‌ای هستند که به صورت جداگانه دارای ۱۸، ۳۴، ۵۰، ۱۰۱ و ۱۵۲ لایه پیچشی می‌باشند. معماری ResNet از چندین لایه پیچشی با یک اتصال باقیمانده تشکیل شده است. در ResNet، یک اتصال میانبر برای رد شدن از برخی از لایه‌های پیچشی اضافه می‌شود. این اتصال میانبر اجازه می‌دهد تا خروجی یک لایه قبلی مستقیماً به خروجی لایه بعدی اضافه شود و یک بلوک باقیمانده ایجاد کند. بلوک باقیمانده از دو یا سه لایه پیچشی با یک اتصال میانبر تشکیل شده است. ساختار ResNet نشان داده است که در وظایف مختلف بینایی کامپیوتری از جمله طبقه‌بندی تصویر روشی موثر است. در سال ۲۰۱۵، مدل اصلی ResNet152 برنده چالش تشخیص تصویری در مقیاس بزرگ ImageNet (ILSVRC) شد که یکی از معتبرترین رقابت‌ها در حوزه بینایی کامپیوتر است [۵۱].

به طور کلی ResNet از اتصالات باقیمانده برای بهبود عملکرد مدل استفاده می‌کند. این مدل برای کاهش مشکل بهینه‌سازی استفاده می‌شود و امکان آموزش شبکه‌های بسیار عمیق‌تر را دارد [۵۲]. همچنین از مدل‌های ResNet می‌توان برای طبقه‌بندی پوشش و کاربری اراضی استفاده نمود [۵۳]. شکل ساختار کلی این شبکه در شکل (۴) نشان داده شده است.



شکل ۴: ساختار کلی شبکه ResNet

Fig 4: General structure of ResNet




شبکه ResNet دارای ۲ بلوک اصلی Identity و Convolutional می‌باشد [۵۴]. این دو بلوک در ادامه توضیح داده خواهند شد. در آخر نیز ساختار ResNet18 توضیح داده خواهد شد.

بلوک Identity

بلوک Identity مورد استفاده در شبکه ResNet به صورت رابطه (۱) تعریف می‌شود:

$$y = F(x, \{w_i\}) + x \quad (1)$$

در رابطه (۱)، x و y به ترتیب بردارهای ورودی و خروجی لایه‌های می‌باشند و تابع $F(x, \{w_i\})$ نشان دهنده نگاشت یادگیری باقیمانده است. در شکل (۵) ساختار کلی یک بلوک Identity مشخص شده



مرحله سوم، چهارم و پنجم مشابه مرحله دوم است، اما در این مراحل بلوک‌های Convolutional و Identity هر مرحله به ترتیب شامل ۱۲۸، ۲۵۶ و ۵۱۲ نقشه ویژگی برای هر کدام از لایه‌های پیچشی داخل بلوک‌های Convolutional و Identity در هر مرحله خواهد بود.

در مرحله آخر یک لایه ادغام میانگین سراسری بر روی تصویر اعمال می‌شود که تصویر را به یک نقشه ویژگی یک بعدی تبدیل خواهد کرد. این لایه مشابه لایه کاملاً متصل عمل خواهد کرد که شامل ۵۱۲ نورون خواهد بود. و سپس در لایه آخر یک لایه کاملاً متصل که به تعداد کلاس‌های طبقه‌بندی نورون دارد استفاده می‌شود تا با استفاده از تابع فعال ساز بیشینه هموار یک لایه طبقه‌بندی کننده وجود داشته باشد. در جدول (۱) ابعاد تصویر بعد از عبور از هر لایه نشان داده شده است.

ارزیابی دقت طبقه بندی

ارزیابی دقت جزء کلیدی در بررسی عملکرد محصولات طبقه‌بندی شده داده‌های سنجش از دوری است، زیرا از ارزیابی عملکرد طبقه‌بندی‌کننده‌های مختلف و تأثیرات نمونه‌برداری پشتیبانی می‌کند. همچنین اعتبارسنجی و ارزیابی دقت طبقه‌بندی محصولات پوشش و کاربری اراضی برای نشان دادن کیفیت محصولات سنجش از دور برای تصمیم‌گیری ضروری است [۶۱]. با توجه به ضرورت بررسی دقت طبقه‌بندی انجام شده با مجموعه داده مورد نظر، در این بخش به معیارهای ارزیابی دقت پوشش و کاربری اراضی که در این تحقیق استفاده شد پرداخته خواهد شد.

ماتریس ابهام

روش استاندارد توصیف عدم قطعیت موضوعی در داده‌های پوشش و کاربری اراضی با استفاده از ماتریس ابهام است. این ماتریس برای بسیاری از معیارهای مختلف برای بدست آوردن شباهت بین برآوردهای داده‌ها و واقعیت زمینی استفاده شده است. این ماتریس مبنایی را برای توصیف دقت طبقه‌بندی و مشخص کردن خطاها فراهم می‌کند که به اصلاح طبقه‌بندی یا برآوردهای حاصل از آن کمک می‌کند [۶۲، ۶۳]. ارزیابی دقت با استفاده از ماتریس‌های ابهام برای نتایج طبقه‌بندی ضروری است تا اطمینان حاصل شود که تا چه حد طبقه‌بندی دقیق است [۶۴]. در قسمت بعدی به معیارهای بدست آمده با استفاده از ماتریس ابهام اشاره خواهد شد.

معیارهای ضریب کاپا و دقت مجموع

شاخص کاپا متداول ترین تکنیک مورد استفاده برای ارزیابی دقت برای ارائه صحت طبقه‌بندی تصویر است و دقت مجموع برای اعتبارسنجی طبقه‌بندی تصاویر استفاده می‌شود [۶۵]. محدوده دقت مجموع از صفر تا ۱۰۰ است، که در آن صفر نشان دهنده کمترین دقت و ۱۰۰ بالاترین است. همچنین مقدار بازه کاپا از صفر تا ۱ است، که صفر نشان دهنده کمترین دقت و ۱ بالاترین دقت است [۶۶]. رابطه ضریب کاپا به صورت رابطه (۹) تعریف می‌شود:

$$Kappa = \frac{2 \times (TP \times TN - FN \times FP)}{(TP + FP) \times (FP + TN) + (TP + FN) \times (FN + TN)} \quad (9)$$

دقت مجموع تصویر طبقه‌بندی‌شده، نحوه طبقه‌بندی هر یک از کلاس‌ها را با واقعیت زمینی مقایسه می‌کند [۶۷]. رابطه کلی آن به صورت رابطه (۱۰) می‌باشد:

$$Overall Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

معیارهای صحت، بازیابی و امتیاز F1

معیار صحت به طبقه‌بندی کلاس‌هایی که در فرآیند طبقه‌بندی به صورت صحیح پیش‌بینی شده است اشاره دارد و معیار بازیابی به نسبت کلاس‌های طبقه‌بندی‌ای که به صورت صحیح پیش‌بینی شده‌اند و کل پیش‌بینی‌های طبقه‌بندی اشاره می‌کند [۶۸]. رابطه این دو معیار در روابط (۱۱) و (۱۲) نشان داده شده است.

در این مطالعه از معماری ResNet18 برای انجام طبقه‌بندی پوشش و کاربری اراضی استفاده شد. دلیل اصلی استفاده از این معماری این است که این معماری با استفاده از اتصالات میانبر نه تنها می‌تواند بهبود عملکرد کلی شبکه بسیار عمیق را فراهم کند، بلکه این مدل می‌تواند از ناپدید شدن گرادین‌ها تا حدی نیز جلوگیری کند تا دقت شبکه کاهش پیدا نکند [۵۵].

تابع ضرر

تابع ضرر وظیفه محاسبه فاصله بین مقدار پیش‌بینی شده توسط مدل و مقدار واقعی را دارد. برای طبقه‌بندی تصاویر سنجش از دور می‌توان از تابع ضرر sparse categorical cross-entropy استفاده نمود [۵۶]. این تابع ضرر در رابطه (۳) مشخص شده است:

$$Loss = - \sum_{i=1}^M y_i \cdot \log \hat{y}_i \quad (3)$$

در رابطه (۳)، $\hat{y}_i$ مقدار پیش‌بینی شده، y_i مقدار واقعی و M تعداد کلاس‌های طبقه‌بندی می‌باشد [۵۷]. در این پژوهش از این تابع ضرر برای محاسبه فاصله مقدار پیش‌بینی شده مدل با مقدار واقعی استفاده شد.

تابع بهینه ساز

تابع بهینه ساز وظیفه به حداقل رساندن مقدار تابع ضرر را در فرآیند آموزش برعهده دارد. این کار با به روز رسانی وزن‌ها در مدل یادگیری عمیق انجام می‌شود. تخمین گشتاور تطبیقی یکی از بهینه‌سازهای پرکاربرد در حوزه یادگیری عمیق است که به طور موثری در آموزش این مدل‌ها استفاده می‌شود [۵۸]. این الگوریتم بهینه‌سازی به همگرایی سریع‌تر مدل کمک می‌کند، از نوسانات در طول فرآیند آموزش جلوگیری می‌کند و در برابر گرادین‌های دارای نویز انعطاف پذیر است [۵۹]. این تابع بهینه‌ساز در روابط (۴) تا (۸) آمده است:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (4)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (5)$$

$$m_{\hat{t}} = \left(\frac{m_t}{1 - \beta_1^t} \right) \quad (6)$$

$$v_{\hat{t}} = \left(\frac{v_t}{1 - \beta_2^t} \right) \quad (7)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{v_{\hat{t}} + \epsilon}} m_{\hat{t}} \quad (8)$$

در روابط بالا m_t بیانگر گشتاور اول، v_t بیانگر گشتاور دوم و g_t مشتق تابع ضرر نسبت به وزن می‌باشند. $m_{\hat{t}}$ و $v_{\hat{t}}$ میزان تصحیحات گشتاور اول و دوم می‌باشند. β_1 و β_2 نرخ‌های کاهشی هستند که به ترتیب برابر ۰/۹۹۹ و ۰/۹ می‌باشند. θ_t وزن‌های مدل، η نرخ یادگیری و ϵ پارامتری ثابت برابر 10^{-8} است که برای صفر نشدن مخرج کسر استفاده می‌شود [۶۰]. در این مطالعه از تابع بهینه ساز تخمین گشتاور تطبیقی برای بهینه‌سازی مدل و به روز رسانی وزن‌ها استفاده شد.

روش داده‌افزایی روش اصلی حل چالش کمبود داده در مدل‌های یادگیری عمیق است که در مرحله آموزش شبکه به داده‌های آموزشی اعمال می‌شود. با استفاده از این روش می‌توان تنوع و اندازه داده‌های آموزشی را افزایش داد که نتیجه این عمل افزایش داده‌های آموزشی و جلوگیری از مشکل بیش‌برازش مدل خواهد بود. روش‌های مختلفی برای انجام تکنیک داده‌افزایی بر روی داده‌های آموزش وجود دارد که می‌توان به تغییر مقیاس، چرخش، برش، جلیبه‌جایی، قرینه‌سازی و افزودن نویز وجود اشاره نمود. استفاده از این روش‌ها بر اساس ماهیت مجموعه داده مورد استفاده برای آموزش شبکه می‌باشد [۷۴].

با توجه به ماهیت مجموعه داده مورد استفاده در این پژوهش، روش‌های قرینه‌سازی افقی و عمودی، چرخش و تغییر مقیاس از روش‌های داده‌افزایی استفاده شد.

روش‌های داده‌افزایی قرینه‌سازی افقی و عمودی، چرخش و تغییر مقیاس ماهیت داده‌های مجموعه داده مورد استفاده در این تحقیق را عوض نمی‌کنند و به همین علت از این روش‌های داده‌افزایی برای افزایش داده‌های آموزشی و جلوگیری از بیش‌برازش مدل استفاده شد.

برش‌گردایان

همانطور که در قسمت قبل توضیح داده شد، انفجار و ناپدید شدن گرادیان یکی از مشکلاتی است که می‌تواند باعث اختلال در روند آموزشی مدل گردد. یکی از روش‌های موثر برای جلوگیری از انفجار و ناپدید شدن گرادیان استفاده از تکنیک برش گرادیان می‌باشد. در این روش مقادیر گرادیان با استفاده از یک مقدار حد آستانه کنترل می‌شوند و این تکنیک اجازه نمی‌دهد که مقادیر گرادیان از این مقدار حد آستانه بیشتر شوند [۷۵]. در طول روند آموزش شبکه، زمانی که یک مقدار گرادیان بسیار زیاد می‌شود و از حد آستانه تعریف شده فراتر می‌رود، آن مقدار برش می‌خورد. بنابراین، حداکثر مقدار ممکن برای مقدار یک گرادیان، به اندازه مقدار حد آستانه است و هر مقدار بالاتر از آن حد آستانه برش می‌خورد [۷۶]. رابطه برش گرادیان در رابطه (۱۴) مشخص شده است [۷۷]:

$$G = \begin{cases} \lambda \frac{G}{\|G\|} & \text{if } \|G\| > \lambda \\ G & \text{Otherwise} \end{cases} \quad (14)$$

در رابطه (۱۴) G بیانگر گرادیان به صورت $G = \frac{\partial L}{\partial \theta}$ می‌باشد. در اینجا L نشان دهنده مقدار ضرر و θ نشان دهنده پارامترهای مدل است. همچنین λ نیز همان مقدار حد آستانه برش گرادیان می‌باشد.

برش گرادیان با حد آستانه 0.1 به مدل اضافه شد تا از انفجار و برش گرادیان جلوگیری شود.

توقف زود هنگام

در آموزش مدل‌های یادگیری عمیق، پیدا کردن اپکی که به بیشترین تعمیم پذیری مدل رسیده است یکی از موثرترین تکنیک‌هایی است که به تعمیم پذیری مدل کمک زیادی می‌کند. توقف زود هنگام روشی است که وقتی مدل در فرآیند آموزش به بیشترین تعمیم پذیری

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (12)$$

امتیاز F1 از ترکیب صحت و بازیابی است و نشان دهنده تعادل در بین دو معیار قبلی می‌باشد [۶۹]. امتیاز F1 به صورت رابطه (۱۳) تعریف می‌شود:

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (13)$$

در این پژوهش برای ارزیابی دقت طبقه بندی از ماتریس ابهام، ضریب کاپا، دقت کلی، صحت، بازیابی و امتیاز F1 استفاده شده است.

روش‌های حل چالش‌های موجود

همانطور که بیان شد، چالش‌هایی در طبقه‌بندی پوشش و کاربری اراضی سنجش از دور با استفاده از مدل‌های یادگیری عمیق وجود دارد که باید برای رسیدن به دقت‌های قابل قبول، روش‌هایی برای رفع این چالش‌ها استفاده نمود. در این قسمت به تکنیک‌هایی که می‌توانند در حل این چالش‌ها موثر باشند اشاره خواهد شد.


روش نظم‌دهی حذف تصادفی

یکی از فرآیندهای موثر در جلوگیری از بیش‌برازش در مدل‌های یادگیری عمیق، روش‌های نظم‌دهی می‌باشند. این روش‌ها باعث می‌شوند که مدل در طول فرآیند اعتبارسنجی با داده‌هایی که برای این امر استفاده می‌شوند عملکرد بهتری از خود نشان دهد. همچنین روش‌های نظم‌دهی باعث می‌شوند که مدل تعمیم‌پذیری بهتری داشته باشد و در نتیجه در پیش‌بینی داده‌های تست نیز دقت بهتری را ارائه کند [۷۰].

یکی از روش‌های نظم‌دهی معروف، متداول و موثر در مدل‌های یادگیری عمیق، روش حذف تصادفی می‌باشد [۷۱]. در این روش برخی از نوره‌ها به طور تصادفی در طول آموزش شبکه حذف می‌شوند که این امر با صفر شدن این نوره‌ها اتفاق می‌افتد. نرخ حذف تصادفی مقدار درصدی از این نوره‌ها می‌باشند که به طور تصادفی حذف می‌شوند [۷۲]. نرخ حذف تصادفی معمولاً بین 0.2 و 0.5 تنظیم می‌شود. در این پژوهش برای جلوگیری از بیش‌برازش مدل از تکنیک حذف تصادفی با نرخ 0.5 استفاده شد.

داده‌افزایی

روش‌های یادگیری عمیق نیاز به تعداد بسیار زیادی داده آموزشی برای رسیدن به دقت‌های بالا و آموزش موثر این مدل‌ها نیاز می‌باشد. استفاده از داده‌های بیشتر در شبکه‌های یادگیری عمیق نه تنها باعث آموزش بهتر و رسیدن به دقت‌های بالاتر می‌شود، بلکه باعث جلوگیری از بیش‌برازش مدل نیز می‌شود. اما همیشه دسترسی به تعداد داده زیاد امکان پذیر نیست و آموزش شبکه نیز با تعداد داده‌های کم، مدل به دقت بالا و تعمیم پذیری مناسبی نخواهد رسید [۷۳].



شکل ۸: تعداد تصاویر موجود در هر کلاس از مجموعه داده EuroSat
Fig. 8: Number of images in each class from the EuroSat dataset

این پژوهش در ۳ مرحله انجام شد و در هر مرحله نسبت به مرحله قبل به صورت افزایشی تکنیک‌های توقف زودهنگام، داده افزایی، حذف تصادفی و برش گرادین اعمال شد. در ادامه همین قسمت به تمامی مراحل انجام شده اشاره خواهد شد.

مرحله اول

در تمامی مراحل این تحقیق، ابتدا مجموعه داده که ابعادی برابر 64×64 داشتند به تصاویری با ابعاد 224×224 تبدیل شدند. دلیل اصلی این تغییر ابعاد تصاویر این است که بتوان از این تصاویر به طور موثر تر برای آموزش مدل ResNet18 استفاده نمود. همچنین در تمامی مراحل اجرایی این پژوهش، تمامی تصاویر نرمال‌سازی شدند و بازه درجات خاکستری تصاویر که صفر تا ۲۵۵ بودند تبدیل به بازه صفر تا یک شده است تا از حجم محاسبات در فرآیند یادگیری کاسته شود. همچنین اندازه دسته استفاده شده در تمامی مراحل آموزشی برابر 64 بوده است. در شکل (۱۰) نمونه‌ای از تصاویر با اندازه دسته ۳۲ به همراه برچسب‌های آن‌ها نشان داده شده است.




شکل ۹: نمونه ای از تصاویر مجموعه داده EuroSat به همراه برچسب‌های هر کلاس
Fig. 9: Sample of images from the EuroSat dataset with labels for each class

رسید، آموزش را متوقف می‌کند. این روش نه تنها باعث تعمیم پذیری بهتر مدل می‌شود، بلکه یکی از روش‌های غلبه بر مشکل بیش برآزش مدل نیز می‌باشد. توقف زودهنگام با نظارت بر مقدار تابع ضرر داده اعتبار سنجی دادن آموزش مدل را متوقف خواهد نمود. اگر این مقدار ضرر در طول آموزش بعد از چند اپک مشخص (که کاربر آن را تعیین می‌کند) کمتر نشد، آموزش متوقف خواهد شد [۷۸].

پیاده سازی روش تحقیق

منطقه و داده های مورد مطالعه

از آنجایی که روش یادگیری عمیق به یک مجموعه داده مناسب جهت آموزش نیاز دارند، استفاده از یک مجموعه داده مناسب تأثیر زیادی در دقت نهایی خواهد داشت. در نتیجه، برای آموزش مدل‌های کارآمد، یک مجموعه آموزشی گسترده و مقدار زیادی از تصاویر مورد نیاز است [۴۶]. اخیراً چندین مجموعه داده برای طبقه‌بندی پوشش و کاربری اراضی برای استفاده در روش‌های یادگیری عمیق ایجاد شده‌اند [۴۷]. یکی از مجموعه داده‌های مورد استفاده در یادگیری عمیق برای طبقه‌بندی پوشش و کاربری اراضی، مجموعه داده EuroSat می‌باشد. تصاویر این مجموعه داده از تصاویر ماهواره Sentinel-2A بدست آمده‌اند که به صورت رایگان در دسترس هستند. این ماهواره دارای ۱۳ باند می‌باشد که قدرت تفکیک مکانی باندهای قرمز، سبز و آبی آن ۱۰ متر می‌باشد. این مجموعه داده شامل ۲۷۰۰۰ تصویر در ۸ کلاس طبقه‌بندی است و هر کلاس شامل ۲۰۰۰ تا ۳۰۰۰ تصویر می‌باشد. در شکل (۸) توزیع تصاویر مربوط به هر کلاس این مجموعه داده مشخص شده است. کلاس‌های این مجموعه داده شامل کلاس‌های محصولات سالیانه، جنگل، گیاهان علفی، بزرگراه، مناطق صنعتی، مرتع، محصولات دائمی، مناطق مسکونی، رودخانه و دریا و دریاچه می‌باشد. ابعاد هر تصویر 64×64 پیکسل می‌باشد که تصاویر این مجموعه داده، از تصاویر Sentinel-2A که از ۳۴ کشور اروپایی اخذ شده بودند بدست آمده است [۴۸]. یک تصویر نمونه از هر کلاس در این مجموعه داده به همراه برچسب‌های آن کلاس در شکل (۹) نمایش داده شده است. این مجموعه داده، یکی از مجموعه داده‌های سنجش از دوری می‌باشد که از آن برای طبقه‌بندی پوشش و کاربری اراضی با استفاده از روش‌های یادگیری عمیق استفاده می‌شود.



شکل ۱۲: نمودارهای دقت و ضرر بر حسب اپک‌های آموزشی برای دو داده آموزش و اعتبار سنجی

Fig. 12: Accuracy and loss charts for both training and validation data

است. لایه حذف تصادفی در این مرحله بین لایه ادغام میانگین سراسری و لایه کاملاً متصل قرار داشته است. نرخ حذف تصادفی که به صورت پیش فرض مقدار ۰/۵ انتخاب شده است، مقداری معمول در کاربردهای طبقه‌بندی است. مقدار حد آستانه ۰/۱ نیز برای مقدار برش گرادیان نیز یکی از مقادیر معمول در این تکنیک است.

فرآیند آموزش در این مرحله در اپک ۳۷ توقف شده است. در اپک ۲۷ که بهترین مدل ما ذخیره شده است، مقادیر دقت و ضرر داده‌های آموزشی برابر ۹۴/۷۳ درصد و ۰/۱۵۲۶ بوده و برای داده‌های اعتبارسنجی برابر ۹۳/۳۹ و ۰/۱۹۲۰ می‌باشد. برای مقایسه و ارزیابی عملکرد این مرحله نسبت به مراحل قبلی باید مقدار دقت و ضرر را در داده‌های اعتبارسنجی مقایسه نمود. مقادیر دقت در این مرحله نسبت به دو مرحله قبلی بهتر شده و مقدار ضرر آن هم کاهش یافته است. همچنین در پیش‌بینی داده‌های تست نیز مقدار دقت این مرحله نسبت به دو مرحله قبلی بهبود داشته است که در ادامه به آن پرداخته خواهد شد.

نتایج و بحث

بعد از انجام ۳ مرحله در قسمت قبل، برای ارزیابی دقت طبقه‌بندی پوشش و کاربری اراضی از معیارهایی استفاده شده که در ادامه به آن‌ها اشاره می‌شود.

ماتریس ابهام و پیش‌بینی تصاویر تست

در شکل (۱۴) ماتریس‌های ابهام داده‌های تست در مرحله اول مشخص شده است.

از شکل (۱۴) مشخص است که این مدل در تشخیص و پیش‌بینی کلاس‌های دریا و دریاچه، بزرگراه، مناطق صنعتی، جنگل و مناطق مسکونی به خوبی عمل کرده و دقت‌های بالای ۹۶ درصد را ارائه نموده است. این مدل اما در طبقه‌بندی کلاس‌های مرتع و محصولات دائمی، پیش‌بینی‌های درست کمتری را انجام داده و به دقت‌های ۷۵/۳۹ و

فرآیند آموزش این مرحله در اپک آموزشی ۱۲۸م متوقف شده است. مقدار دقت و ضرر داده‌های اعتبار سنجی نوسان‌هایی دیده می‌شود اما دامنه این نوسان‌ها نسبت به مرحله اول کمتر است و آموزشی پایدار تر از مرحله قبلی داشته است.

علت اصلی این پایداری، استفاده از داده‌افزایی بر روی داده‌های آموزشی می‌باشد. این تکنیک با اعمال تغییرات قرینه سازی افقی و عمودی، چرخش و تغییر مقیاس بر روی داده‌های آموزشی، نه تنها باعث افزایش داده‌ها در حین آموزش داده‌ها شده است، بلکه آموزش مدل نیز با پایداری بهتری همراه بوده است. این روش دقت طبقه‌بندی را در داده‌های تست نیز بهبود داده است که در قسمت بعدی به آن اشاره خواهد شد.

در اپک ۱۸ که بهترین مدل در این مرحله بوده است، مقدار دقت و مقدار تابع ضرر در داده‌های آموزشی برابر ۹۳/۸۳ درصد و ۰/۱۷۵۷ بوده و مقدار دقت و ضرر در داده‌های اعتبار سنجی برابر ۹۰/۵۴ درصد و ۰/۲۷۴۶ بوده است.


مرحله سوم

در این مرحله، از روش‌های داده‌افزایی، حذف تصادفی، برش گرادیان و توقف زودهنگام برای بهبود عملکرد مدل ResNet18 در طبقه‌بندی پوشش و کاربری اراضی مجموعه داده EuroSat استفاده شد. مقدار نرخ یادگیری در این مرحله نیز ۰/۰۰۱ بوده و همچنین مقدار حد آستانه برش گرادیان و نرخ حذف تصادفی در این مرحله ۰/۱ و ۰/۵ بوده‌اند. در شکل (۱۳) نمودار دقت و مقدار ضرر بر حسب اپک‌های آموزشی برای داده‌های آموزش و اعتبار سنجی در مرحله سوم نشان داده شده است.


از شکل (۱۳) مشخص است که میزان نوسانات مقادیر دقت و ضرر در داده‌های آموزش و اعتبار سنجی نسبت به مرحله قبل نوسانات نرم‌تری داشته است. دلیل آن هم این است که علاوه بر داده‌افزایی، تکنیک‌های حذف تصادفی و برش گرادیان نیز به فرآیند آموزشی مدل اضافه شده

تصاویر نشان داده شده است. اگر تصاویر درست پیش بینی شده باشند، برچسب آن در بالای همان تصویر با رنگ سبز مشخص شده است و اگر مدل آن تصویر را درست پیش‌بینی نکرده باشد، در بالای آن برچسب واقعی و پیش‌بینی مدل با رنگ قرمز معلوم شده است.

۷۳/۴۱ درصد رسیده است که کمترین دقت در بین کلاس‌های دیگر می‌باشد. در شکل (۱۵) نمونه‌هایی از پیش‌بینی‌های مدل این مرحله در اندازه دسته‌ای ۳۲ داده‌های تست مشخص شده است. این نمونه‌ها به طور تصادفی از داده‌های تست انتخاب شده و برچسب‌های آن‌ها در بالای



شکل ۱۳: نمودارهای دقت و ضرر بر حسب اپک‌های آموزشی برای دو داده آموزش و اعتبار سنجی در مرحله سوم
Fig. 13: Accuracy and loss graphs for two training and validation data in the third stage



شکل ۱۴: ماتریس ابهام (شکل راست) و ماتریس ابهام نقشه حرارتی (شکل چپ) مرحله اول طبقه بندی
Fig. 14: Confusion matrix (right figure) and heat map of confusion matrix (left figure) for the first stage of classification



شکل ۱۵: تعدادی از تصاویر داده‌های تست به همراه برچسب‌هایشان که در مرحله اول پیش‌بینی شده‌اند

Fig. 15: Test data images with their predicted labels in the first stage

و بزرگراه مدل کمترین دقت را داشته است. در شکل (۱۷) پیش‌بینی داده‌های تست با استفاده از این مدل مشخص شده است.

شکل (۱۷) نشان می‌دهد که دو تصویر که متعلق به کلاس‌های مناطق صنعتی و بزرگراه بوده‌اند، مناطق مسکونی و محصولات دائمی پیش‌بینی شده‌اند. در ماتریس ابهام نیز می‌توان مشاهده نمود که مدل تعداد ۱۸ و ۷ تصویر متعلق به مناطق صنعتی و بزرگراه را به اشتباه مناطق مسکونی و محصولات دائمی تشخیص داده است.


در شکل (۱۸) ماتریس‌های ابهام مرحله سوم طبقه‌بندی به دو صورت معمول و نقشه حرارتی نشان داده شده است.

این مدل در طبقه‌بندی کلاس‌های دریا و دریاچه، جنگل، مناطق مسکونی، محصولات سالیانه، بزرگراه و مناطق صنعتی به دقت‌های بالایی رسیده است اما در کلاس‌های مرتع و گیاهان علفی شکل با دقت‌های ۸۳/۷۷ و ۸۶/۱۲ درصد دقت‌های کمتری را ارائه نموده است. در شکل (۱۹) پیش‌بینی داده‌های تست با استفاده از این مدل مشخص شده است.

در شکل (۱۵) مشخص است که در بیشتر پیش‌بینی‌ها، مدل به خوبی عمل کرده است، اما در بعضی تصاویر این پیش‌بینی‌ها درست نبوده‌اند. برای مثال سه تصویری که متعلق به کلاس‌های مناطق صنعتی، محصولات دائمی و مرتع بوده را بزرگراه پیش‌بینی کرده است. این تشخیص اشتباه در ماتریس ابهام نیز مشهود است. مدل به ترتیب ۴، ۳۲ و ۳۰ تصویر که متعلق به کلاس‌های مناطق صنعتی، محصولات دائمی و مرتع بوده‌اند را بزرگراه پیش‌بینی نموده است در شکل ۱۵ ۳ تصویر از این کلاس‌ها که بزرگراه تشخیص داده شده است نشان داده شده است. همچنین یک تصویر که متعلق به کلاس محصولات دائمی می‌باشد در کلاس رودخانه پیش‌بینی شده است که همین تصویر در شکل (۱۵) مشاهده می‌شود.

در شکل (۱۶) ماتریس‌های ابهام مرحله دوم طبقه‌بندی به دو صورت معمول و نقشه حرارتی نشان داده شده است.


مدل در کلاس‌های دریا و دریاچه، مناطق مسکونی، رودخانه، محصولات دائمی، جنگل، مرتع و مناطق صنعتی به دقت‌های پیش‌بینی بالای ۹۱ درصد رسیده است و در کلاس‌های گیاهان علفی




شکل ۱۶: ماتریس ابهام‌های مرحله دوم
Fig. 16: The confusion matrices of the second stage



شکل ۱۷: تصاویر داده‌های تست پیش‌بینی شده در مرحله دوم
Fig. 17: Test images and their predicted labels in the second stage



شکل ۱۸: ماتریس ابهام‌های ابهام مرحله سوم
Fig. 18: The confusion matrices of the third stage



شکل ۱۹: تصاویر داده‌های تست پیش‌بینی شده به همراه برجسب‌ها در مرحله سوم
Fig. 19: Test image predictions with their labels in the third stage

همانطور که از جدول بالا مشهود است، مدل در مرحله سوم از همه مدل‌های دیگر بهتر عمل کرده است و دقت مجموع و ضریب کاپای این مرحله ۹۳/۱۱ درصد و ۰/۹۲۳۳ بوده است. این مدل نسبت به مدل‌های مراحل دیگر بهبود دقتی در حد ۱/۳۳ و ۱/۹۲ درصدی رسیده است و ضریب کاپای آن به اندازه ۰/۱۳۸ و ۰/۰۲۱۵ افزایش یافته است.

صحت، بازیابی و امتیاز $F1$

بعد از انجام کلیه مراحل بیان شده در طبقه‌بندی پوشش و کاربری اراضی مجموعه داده EuroSat، این ۳ معیار برای ارزیابی دقت ۳ مرحله طبقه‌بندی انجام شده بر روی داده‌های تست بدست آمد. جدول (۳) این معیارها را برای مدل‌های طبقه‌بندی نشان می‌دهد.

معیار صحت، بازیابی و امتیاز $F1$ در مدل سوم بهتر از تمامی مدل‌های قبلی بوده و این معیارها به ترتیب برابر ۹۳/۳۶، ۹۲/۷۶ و ۹۲/۹۵ درصد بوده است. مدل دوم هم نسبت به مدل اول در این معیارها به ترتیب ۱/۲۵، ۱/۰۲ و درصد نسبت به مدل دوم بهتر عمل کرده و

۱۴ تصویر از داده‌های تست که متعلق به داده‌های گیاهان علفی بوده‌اند، در کلاس محصولات دائمی پیش‌بینی شده‌اند که یکی از این تصاویر که اشتباه پیش‌بینی شده است در شکل (۱۹) نشان داده شده است.

دقت کلی و ضریب کاپا

در جدول (۲) دقت مجموع و ضریب کاپا مدل‌های استفاده شده در این پژوهش نشان داده شده است.

جدول ۲: معیارهای دقت مجموع و ضریب کاپا در مدل‌های اجرایی

مدل (model)	دقت مجموع (overall accuracy)	ضریب کاپا (kappa coefficient)
مرحله ۱ (first stage)	91.19 %	0.9018
مرحله ۲ (second stage)	91.78 %	0.9085
مرحله ۳ (third stage)	93.11 %	0.9233

۹۷/۵۵، ۹۷/۰۲ و ۹۶/۳۵ بیشترین دقت را داشته و در کلاس‌های محصولات دائمی و بزرگراه این معیار با مقدار ۸۲/۳۵ و ۸۲/۴۷ کمترین دقت را در این معیار کسب کرده است.

در مرحله دوم، کلاس‌های جنگل، مناطق صنعتی و بزرگراه که بیشترین صحت را داشتند که مقادیر این کلاس‌ها برای این معیار به ترتیب برابر ۹۸/۵۳، ۹۷/۹۲ و ۹۷/۶۲ درصد بوده است، اما کلاس محصولات دائمی با ۸۴/۲۳ درصد پایین‌ترین صحت را در بین کلاس‌های دیگر داشته است. کلاس‌های دریا و دریاچه و مناطق مسکونی با بازیابی ۹۹ و ۹۸/۷۱ درصد با اختلاف، بیشترین مقادیر را در این معیار داشته‌اند و کلاس بزرگراه نیز با مقدار ۸۱/۳۶، کمترین مقدار صحت را داشته است. همچنین کلاس جنگل با امتیاز F1 برابر ۸۷/۰۶ درصد بیشترین مقدار و کلاس گیاهان علفی با مقدار ۸۷/۶۳ درصد کمترین مقدار امتیاز F1 را در این مرحله داشته‌اند.

در مرحله سوم، بیشترین مقدار صحت برای کلاس مرتع بوده که مقدار آن ۹۸/۷۷ می‌باشد و کمترین مقدار این معیار برابر ۸۶/۰۸ بوده است که متعلق به کلاس محصولات سالیانه بوده است. در کلاس‌های دریا و دریاچه، جنگل، مناطق مسکونی و محصولات سالیانه معیار بازیابی به ترتیب برابر ۹۹، ۹۸/۶، ۹۷/۴۲ و ۹۶/۳۸ بوده است و در کلاس مرتع، این معیار به کمترین مقدار خود که برابر ۸۳/۷۷ درصد رسیده است. همچنین برای معیار امتیاز F1 کلاس‌های دریا و دریاچه و گیاهان علفی با مقدار ۹۷/۳۷ و ۸۸/۳۵ درصد به ترتیب بیشترین و کمترین مقدار این معیار را کسب نموده‌اند.

مقدارهای معیار صحت، بازیابی و امتیاز F1 به ترتیب برابر ۹۲/۲۴، ۹۱/۷۳ و ۹۱/۷۷ درصد بوده است.

جدول ۳: معیارهای صحت، بازیابی و امتیاز F1 بدست آمده برای مدل‌های طبقه‌بندی

مدل (model)	صحت (precision)	بازیابی (recall)	امتیاز F1 (F1 score)
مرحله ۱ (first stage)	92.05 %	90.48 %	90.75 %
مرحله ۲ (second stage)	92.24 %	91.73 %	91.77 %
مرحله ۳ (third stage)	93.36 %	92.76 %	92.95 %

در جدول (۴)، این ۳ معیار ارزیابی دقت برای هر کلاس در این ۳ مدل را مشخص کرده است.

در مرحله اول، طبقه‌بندی پوشش و کاربری اراضی، صحت کلاس‌های جنگل، مناطق مسکونی، دریا و دریاچه، مرتع، مناطق صنعتی، محصولات سالیانه، رودخانه و محصولات دائمی بالای ۹۳ درصد می‌باشد اما در کلاس‌های بزرگراه و گیاهان علفی این معیار نسبت به کلاس‌های دیگر کمتر بوده و برابر ۷۱/۱۸ و ۸۵/۸۰ می‌باشد. معیار بازیابی کلاس‌های دریا و دریاچه، بزرگراه، جنگل و مناطق مسکونی به ترتیب ۹۹/۶۷، ۹۸/۰۲ و ۹۶/۸۵ و ۹۶/۴۵ درصد بوده است اما در کلاس‌های محصولات دائمی و مرتع که این معیار برابر ۷۳/۴۱ و ۷۵/۳۹ درصد بوده است، عملکرد ضعیف‌تری داشته است. در معیار امتیاز F1 کلاس‌های دریا و دریاچه، جنگل و مناطق مسکونی با

جدول ۴: معیارهای صحت، بازیابی و امتیاز F1 برای هر کلاس در طبقه‌بندی در ۳ مدل مورد استفاده

Table 4: Precision, recall and F1 score for each for the classification models

معیارها (metrics)	مدل (model)	کلاس‌ها (classes)									
		محصولات سالیانه (annual crop)	جنگل (forest)	گیاهان علفی (herbaceous vegetation)	بزرگراه (highway)	مناطق صنعتی (industrial)	مرتع (pasture)	محصولات دائمی (permanent crop)	مناطق مسکونی (residential)	رودخانه (river)	دریا و دریاچه (sea/lake)
صحت (درد) (precision)	مرحله ۱ (first stage)	94.98	97.19	85.80	71.78	95.08	95.36	93.78	97.08	94.55	95.51
	مرحله ۲ (second stage)	88.69	98.53	93.24	97.62	97.92	95.65	84.23	90.80	86.13	89.70
	مرحله ۳ (third stage)	86.08	94.63	90.70	94.80	95.62	98.77	91.22	95.57	90.50	95.79
بازیابی (درد) (recall)	مرحله ۱ (first stage)	89.13	96.85	93.38	98.02	97.67	75.39	73.41	96.45	84.90	99.67
	مرحله ۲ (second stage)	88.04	93.71	82.65	81.35	91.44	92.15	94.01	98.71	96.33	99
	مرحله ۳ (third stage)	96.38	98.60	86.12	94.05	93.39	83.77	89.51	97.42	89.39	99
امتیاز F1 (درد) (F1 score)	مرحله ۱ (first stage)	91.96	97.02	89.43	82.47	96.35	84.21	82.35	96.76	89.46	97.55
	مرحله ۲ (second stage)	88.36	96.06	87.63	88.74	94.57	93.87	88.85	94.59	90.94	94.12
	مرحله ۳ (third stage)	90.94	96.58	88.35	94.42	94.49	90.65	90.36	96.49	89.94	97.37

نتیجه‌گیری

امروزه اطلاعات پوشش و کاربری اراضی در کاربردهای مختلف، نقشی ضروری دارد. استفاده از داده‌های سنجش از دوری علاوه بر ارزان‌تر بودن نسبت به روش‌های دیگر، تفسیر و پردازش پوشش و کاربری اراضی با استفاده از روش‌های پردازش رقومی تصاویر را به صورت اتوماتیک امکان‌پذیر می‌کنند. برای استخراج این اطلاعات از تصاویر سنجش از دوری باید از تکنیک‌های طبقه‌بندی تصاویر استفاده نمود. یکی از روش‌های موثر طبقه‌بندی تصاویر، روش‌های یادگیری عمیق می‌باشند که در دهه اخیر مورد توجه جامعه سنجش از دور قرار گرفته است. این روش‌ها پتانسیل بالایی در حوزه طبقه‌بندی تصاویر سنجش از دوری از خود نشان داده و به دقت‌های قابل توجهی نیز در این کار رسیده‌اند. با این حال، استفاده از این روش‌ها در طبقه‌بندی پوشش و کاربری اراضی با چالش‌هایی نیز همراه است. اولین چالش استفاده از این روش‌ها در طبقه‌بندی پوشش و کاربری اراضی، انتخاب یک مدل مناسب برای انجام این کار می‌باشد. دو مشکل اساسی این روش‌ها در انجام این امر، مشکل بیش‌برازش مدل و نیاز به تعداد داده بسیار بالا می‌باشد. یکی دیگر از چالش‌های استفاده از این مدل‌ها، انفجار و ناپدید شدن گرادیان است. انفجار و ناپدید شدن گرادیان باعث اختلال در فرآیند آموزش مدل‌های یادگیری عمیق خواهد شد و به شدت بر دقت و عملکرد این مدل‌ها تاثیر خواهند گذاشت. هدف اصلی این پژوهش رفع این چالش‌ها با استفاده از تکنیک‌های مختلف است. برای حل چالش بیش‌برازش مدل، از روش نظم‌دهی حذف تصادفی و تکنیک توقف زودهنگام می‌توان استفاده نمود. روش داده‌افزایی با اعمال تغییرات بر روی تصویر، یک روش موثر در حل مشکل کمبود داده در روش‌های یادگیری عمیق می‌باشد. همچنین روش برش گرادیان نیز می‌تواند از مشکل انفجار و ناپدید شدن گرادیان در مدل‌های یادگیری عمیق جلوگیری کند. در این پژوهش ابتدا از مدل ResNet18 برای طبقه‌بندی پوشش و کاربری اراضی مجموعه داده EuroSat که در آن تنها از تکنیک توقف زودهنگام بهره می‌برد استفاده شد. در مرحله دوم از همین مدل برای طبقه‌بندی همین مجموعه داده که با تکنیک‌های توقف زودهنگام و داده‌افزایی بهبود داده شده بود استفاده شد. در مرحله سوم تکنیک‌های توقف زودهنگام، داده‌افزایی، حذف تصادفی با نرخ ۰/۵ و برش گرادیان با حد آستانه ۰/۱ استفاده شد. نرخ یادگیری این ۳ مرحله نیز مقدار ۰/۰۰۱ بوده است. در این مراحل، تکنیک‌های استفاده شده به صورت افزایشی به مدل یادگیری عمیق ResNet18 اضافه شد و هر مرحله نسبت به مرحله قبلی دقت‌های بهتری را ارائه میداد. برای ارزیابی دقت مدل‌های پیاده‌سازی شده از معیارهای دقت کلی، ضریب کاپا، صحت، بازیابی و امتیاز F1 استفاده شد. مدل مرحله سوم در تمامی این معیارها نسبت به مدل‌های دیگر دقت بهتری را ارائه داده و مقادیر این معیارها برای این مدل برابر ۹۳/۱۱٪، ۹۲/۳۳٪، ۹۳/۳۶٪، ۹۲/۷۶٪ و ۹۲/۹۵٪ بوده است.

پیشنهادهای تحقیقات آتی

با توجه به نتایج حاصل از این پژوهش، پیشنهاد می‌شود برای رسیدن به دقت‌های بالاتر، مقادیر ابرپارامترهایی مثل نرخ یادگیری، نرخ حذف تصادفی و حد آستانه برش گرادیان با استفاده از روش‌های بهینه‌سازی ابرپارامترها بدست آید. با این کار می‌توان به عملکرد مدل نیز کمک نمود. همچنین از دیگر مجموعه داده‌ها به همراه مدل‌های ResNet34، ResNet50، ResNet101 و ResNet152 نیز می‌توان استفاده کرد تا نتایج این تحقیق به صورت جامع‌تری مورد ارزیابی قرار گیرد. در این پژوهش از مجموعه داده EuroSat که شامل ۳ باند قرمز، سبز و آبی بوده است استفاده شد. پیشنهاد می‌شود برای رسیدن به دقت‌های بالاتر از این مجموعه داده با ۱۳ باند کامل آن استفاده شود. با این کار می‌توان کلاس‌هایی که دارای پوشش گیاهی هستند را به صورت موثرتری در طبقه‌بندی از هم تفکیک نمود. همچنین در این پژوهش، مدل‌ها از ابتدا آموزش داده شدند تا بتوانند داده‌های تست را پیش‌بینی کنند. برای رسیدن به دقت‌های بالاتر می‌توان از تکنیک Transfer Learning استفاده نمود. در این روش از یک مدل از پیش آموزش داده شده استفاده می‌شود. این تکنیک را می‌توان با روش‌های بهینه‌سازی ابرپارامترها ترکیب نمود تا ابرپارامترها نیز برای رسیدن به دقت‌های بالاتر بهینه‌سازی شوند.

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 عزیزی 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 مأخذ

[1] Wang, H., Zhao, X., Zhang, X., Wu, D., & Du, X. (2019). Long Time Series Land Cover Classification in China from 1982 to 2015 Based on Bi-LSTM Deep Learning. *Remote Sensing*, 11(14), 1639. <https://doi.org/10.3390/rs11141639>

analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152, 166-177.

<https://doi.org/10.1016/j.isprsjprs.2019.04.015>

[14] Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., Xu, H., Tan, W., Yang, Q., Wang, J., Gao, J., & Zhang, L. (2020). Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sensing of Environment*, 241, 111716.

<https://doi.org/10.1016/j.rse.2020.111716>

[15] Huang, B., Zhao, B., & Song, Y. (2018). Urban land-use mapping using a deep convolutional neural network with high spatial resolution multispectral remote sensing imagery. *Remote Sensing of Environment*, 214, 73-86.

<https://doi.org/10.1016/j.rse.2018.04.050>

[16] 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).

<https://doi.org/10.1007/s12517-022-10246-8>

[17] Tong, X.-Y., Xia, G.-S., Lu, Q., Shen, H., Li, S., You, S., & Zhang, L. (2020). Land-cover classification with high-resolution remote sensing images using transferable deep models. *Remote Sensing of Environment*, 237, 111322.

<https://doi.org/10.1016/j.rse.2019.111322>

[18] Tong, X. Y., Xia, G. S., Lu, Q., Shen, H., Li, S., You, S., & Zhang, L. (2018). Learning transferable deep models for land-use classification with high-resolution remote sensing images. *arXiv preprint arXiv:1807.05713*. DOI:10.48550/arXiv.1807.05713

[19] Zhang, P., Ke, Y., Zhang, Z., Wang, M., Li, P., & Zhang, S. (2018). Urban Land Use and Land Cover Classification Using Novel Deep Learning Models Based on High Spatial Resolution Satellite Imagery. *Sensors*, 18(11), 3717.

<https://doi.org/10.3390/s18113717>

[20] Zhao, J., Wang, L., Yang, H., Wu, P., Wang, B., Pan, C., & Wu, Y. (2022). A Land Cover Classification Method for High-Resolution Remote Sensing Images Based on NDVI Deep Learning Fusion Network. *Remote Sensing*, 14(21), 5455.

<https://doi.org/10.3390/rs14215455>

[21] Zhang, L., Zhang, L., & Du, B. (2016). Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art. *IEEE Geoscience and Remote Sensing Magazine*, 4(2), 22-40. DOI: 10.1109/MGRS.2016.2540798

[22] Cheng, X., He, X., Qiao, M., Li, P., Hu, S., Chang, P., & Tian, Z. (2022). Enhanced contextual representation with deep neural networks for land cover classification based on remote sensing images. *International Journal of Applied Earth Observation and Geoinformation*, 107, 102706-102706.

<https://doi.org/10.1016/j.jag.2022.102706>

[23] Vali, A., Comai, S., & Matteucci, M. (2020). Zhang, P., Ke, Y., Zhang, Z., Wang, M., Li, P., & Zhang, S. (2018). Urban Land Use and Land Cover Classification Using Novel Deep Learning Models Based on High Spatial Resolution Satellite Imagery. *Sensors*, 18(11), 3717. <https://doi.org/10.3390/s18113717>

[24] Carranza-García, M., García-Gutiérrez, J., & Riquelme, J. C. (2019). A framework for evaluating land use and land cover

[2] Zhang, J., & Zhang, Y. (2007). Remote sensing research issues of the National Land Use Change Program of China. *ISPRS Journal of Photogrammetry and Remote Sensing*, 62(6), 461-472. <https://doi.org/10.1016/j.isprsjprs.2007.07.002>

[3] Cheruto, M.C., Kauti, M.K., Kisangau, P.D. and Kariuki, P. (2016) Assessment of Land Use and Land Cover Change Using GIS and Remote Sensing Techniques: A Case Study of Makueni County, Kenya. *Journal of Remote Sensing and GIS*, 5, 175. DOI: 10.4175/2469-4134.1000175

[4] Mu, L., Wang, L., Wang, Y., Chen, X., & Han, W. (2019). Urban Land Use and Land Cover Change Prediction via Self-Adaptive Cellular Based Deep Learning with Multisource Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12), 5233-5247.

DOI: 10.1109/JSTARS.2019.2956318

[5] Zhang, X., Han, L., Han, L., & Zhu, L. (2020). How Well Do Deep Learning-Based Methods for Land Cover Classification and Object Detection Perform on High Resolution Remote Sensing Imagery? *Remote Sensing*, 12(3), 417.

<https://doi.org/10.3390/rs12030417>

[6] Zhang, C., Harrison, P. A., Pan, X., Li, H., Sargent, I., & Atkinson, P. M. (2020). Scale Sequence Joint Deep Learning (SS-JDL) for land use and land cover classification. *Remote Sensing of Environment*, 237, 111593.

<https://doi.org/10.1016/j.rse.2019.111593>

[7] Li, C., & Shao, G. (2012). Object-oriented classification of land use/cover using digital aerial orthophotography. *International journal of remote sensing*, 33(4), 922-938.

<https://doi.org/10.1080/01431161.2010.536183>

[8] Mustafa Atasoy, Fevzi Karslı, Cemal Bıyık, & Demir, O. (2006). Determining Land Use Changes with Digital Photogrammetric Techniques. *Environmental Engineering Science*, 23(4), 712-721. <https://doi.org/10.1089/ees.2006.23.712>

[9] Mondal, Md., Sharma, N., Kappas, M., & Garg, P. (2015). Critical Assessment of Land Use Land Cover Dynamics Using Multi-Temporal Satellite Images. *Environments*, 2(4), 61-90. <https://doi.org/10.3390/environments2010061>

[10] Luo, M., & Ji, S. (2022). Cross-spatiotemporal land-cover classification from VHR remote sensing images with deep learning-based domain adaptation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 191, 105-128.

<https://doi.org/10.1016/j.isprsjprs.2022.07.011>

[11] Lee, S.-H., Han, K.-J., Lee, K., Lee, K.-J., Oh, K.-Y., & Lee, M.-J. (2020). Classification of Landscape Affected by Deforestation Using High-Resolution Remote Sensing Data and Deep-Learning Techniques. *Remote Sensing*, 12(20), 3372.

<https://doi.org/10.3390/rs12203372>

[12] Li, W., Fu, H., Yu, L., Gong, P., Feng, D., Li, C., & Clinton, N. (2016). Stacked Autoencoder-based deep learning for remote-sensing image classification: a case study of African land-cover mapping. *International Journal of Remote Sensing*, 37(23), 5632-5646. <https://doi.org/10.1080/01431161.2016.1246775>

[13] Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-

- [36] Alem, A., & Kumar, S. (2022). Transfer learning models for land cover and land use classification in remote sensing image. *Applied Artificial Intelligence*, 36(1), 2014192. <https://doi.org/10.1080/08839514.2021.2014192>
- [37] Khan, S. D., & Basalamah, S. (2023). Multi-Branch Deep Learning Framework for Land Scene Classification in Satellite Imagery. *Remote Sensing*, 15(13), 3408. <https://doi.org/10.3390/rs15133408>
- [38] Stivaktakis, R., Tsagkatakis, G., & Tsakalides, P. (2019). Deep Learning for Multilabel Land Cover Scene Categorization Using Data Augmentation. *IEEE Geoscience and Remote Sensing Letters*, 16(7), 1031–1035. DOI: 10.1109/LGRS.2019.2893306
- [39] Naushad, R., Kaur, T., & Ghaderpour, E. (2021). Deep Transfer Learning for Land Use and Land Cover Classification: A Comparative Study. *Sensors*, 21(23), 8083. <https://doi.org/10.3390/s21238083>
- [40] Rangel, A., Terven, J., Cordova-Esparza, D. M., & Chavez-Urbiola, E. A. (2024). Land Cover Image Classification. *arXiv preprint arXiv:2401.09607*. <https://doi.org/10.48550/arXiv.2401.09607>
- [41] Zhang, W., Tang, P., & Zhao, L. (2019). Remote Sensing Image Scene Classification Using CNN-CapsNet. *Remote Sensing*, 11(5), 494. <https://doi.org/10.3390/rs11050494>
- [42] Fayaz, M., Nam, J., Dang, L. M., Song, H.-K., & Moon, H. (2024). Land-Cover Classification Using Deep Learning with High-Resolution Remote-Sensing Imagery. *Applied Sciences*, 14(5), 1844. <https://doi.org/10.3390/app14051844>
- [43] Albarakati, H. M., Khan, M. A., Hamza, A., Khan, F., Naoufel, K., Jamel, L., Almuqren, L., & Alrooba, R. (2024). A Novel Deep Learning Architecture for Agriculture Land Cover and Land Use Classification from Remote Sensing Images Based on Network-Level Fusion of Self-Attention Architecture. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 1–16. DOI: 10.1109/JSTARS.2024.3369950
- [44] Hatef Dastour, & Hassan, Q. K. (2023). A Comparison of Deep Transfer Learning Methods for Land Use and Land Cover Classification. *Sustainability*, 15(10), 7854–7854. <https://doi.org/10.3390/su15107854>
- [45] Pedrayes, O. D., Lema, D. G., García, D. F., Rubén Usamentiaga, & Alonso, Á. (2021). Evaluation of Semantic Segmentation Methods for Land Use with Spectral Imaging Using Sentinel-2 and PNOA Imagery. *Remote Sensing*, 13(12), 2292–2292. <https://doi.org/10.3390/rs13122292>
- [46] Cheng, G., Xie, X., Han, J., Guo, L., & Xia, G. S. (2020). Remote sensing image scene classification meets deep learning: Challenges, methods, benchmarks, and opportunities. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 3735–3756. DOI: 10.1109/JSTARS.2020.3005403
- [47] Rousset, G., Despinoy, M., Schindler, K., & Mangeas, M. (2021). Assessment of deep learning techniques for land use land cover classification in southern New Caledonia. *Remote Sensing*, 13(12), 2257. <https://doi.org/10.3390/rs13122257>
- classification using convolutional neural networks. *Remote Sensing*, 11(3), 274. <https://doi.org/10.3390/rs11030274>
- [25] Rehmer, A., & Kroll, A. (2020). On the vanishing and exploding gradient problem in Gated Recurrent Units. *IFAC-PapersOnLine*, 53(2), 1243–1248. <https://doi.org/10.1016/j.ifacol.2020.12.1342>
- [26] Simon, J. B., Karkada, D., Ghosh, N., & Belkin, M. (2023). More is better in modern machine learning: when infinite overparameterization is optimal and overfitting is obligatory. *arXiv preprint arXiv:2311.14646*. <https://doi.org/10.48550/arXiv.2311.14646>
- [27] Li, Y., Zhang, H., Xue, X., Jiang, Y., & Shen, Q. (2018). Deep learning for remote sensing image classification: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(6). <https://doi.org/10.1002/widm.1264>
- [28] Marschner, F. J., & Anderson, J. R. (1967). Major land uses in the United States. *US Geological Survey*. DOI: 10.3133/70046790
- [29] Vali, A., Comai, S., & Matteucci, M. (2020). Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sensing*, 12(15), 2495. <https://doi.org/10.3390/rs12152495>
- [30] Jozdani, S. E., Johnson, B. A., & Chen, D. (2019). Comparing Deep Neural Networks, Ensemble Classifiers, and Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification. *Remote Sensing*, 11(14), 1713. <https://doi.org/10.3390/rs11141713>
- [31] Ali, K., & Johnson, B. A. (2022). Land-Use and Land-Cover Classification in Semi-Arid Areas from Medium-Resolution Remote-Sensing Imagery: A Deep Learning Approach. *Sensors*, 22(22), 8750. <https://doi.org/10.3390/s22228750>
- [32] Li, W., Wang, Z., Wang, Y., Wu, J., Wang, J., Jia, Y., & Gui, G. (2020). Classification of High-Spatial-Resolution Remote Sensing Scenes Method Using Transfer Learning and Deep Convolutional Neural Network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1986–1995. DOI: 10.1109/JSTARS.2020.2988477
- [33] Yu, X., Wu, X., Luo, C., & Ren, P. (2017). Deep learning in remote sensing scene classification: a data augmentation enhanced convolutional neural network framework. *GIScience & Remote Sensing*, 54(5), 741–758. <https://doi.org/10.1080/15481603.2017.1323377>
- [34] Shawky, O. A., Hagag, A., El-Dahshan, E.-S. A., & Ismail, M. A. (2020). Remote sensing image scene classification using CNN-MLP with data augmentation. *Optik*, 221, 165356. <https://doi.org/10.1016/j.ijleo.2020.165356>
- [35] Zhang, Z., Mi, X., Yang, J., Wei, X., Liu, Y., Yan, J., Liu, P., Gu, X., & Yu, T. (2023). Remote Sensing Image Scene Classification in Hybrid Classical–Quantum Transferring CNN with Small Samples. *Sensors*, 23(18), 8010. <https://doi.org/10.3390/s23188010>

- TensorFlow Deep Neural Networks with ADAM Optimizer and GIS for Spatial Prediction of Forest Fire Danger in Tropical Areas. *Remote Sensing*, 15(14), 3458. <https://doi.org/10.3390/rs15143458>
- [60] Reyad, M., Sarhan, A. M., & Arafa, M. (2023). A modified Adam algorithm for deep neural network optimization. *Neural Computing and Applications*, 35(23), 17095-17112. <https://doi.org/10.1007/s00521-023-08568-z>
- [61] Macarringue, L. S., Bolfe, É. L., & Pereira, P. R. M. (2022). Developments in Land Use and Land Cover Classification Techniques in Remote Sensing: A Review. *Journal of Geographic Information System*, 14(01), 1–28. DOI: 10.4236/jgis.2022.141001
- [62] Abdu, H. A. (2018). Classification accuracy and trend assessments of land cover- land use changes from principal components of land satellite images. *International Journal of Remote Sensing*, 40(4), 1275–1300. <https://doi.org/10.1080/01431161.2018.1524587>
- [63] HAY, A. M. (1988). The derivation of global estimates from a confusion matrix. *International Journal of Remote Sensing*, 9(8), 1395–1398. <https://doi.org/10.1080/01431168808954945>
- [64] Layati, E., & El Ghachi, M. (2024). Oued Lakhdar watershed (Morocco), monitoring land use/cover changes: Remote sensing and GIS approach. *Geology, Ecology, and Landscapes*, 1-13. <https://doi.org/10.1080/24749508.2024.2395204>
- [65] Fan, F., Wang, Y., & Wang, Z. (2007). Temporal and spatial change detecting (1998–2003) and predicting of land use and land cover in Core corridor of Pearl River Delta (China) by using TM and ETM+ images. *Environmental Monitoring and Assessment*, 137(1-3), 127–147. <https://doi.org/10.1007/s10661-007-9734-y>
- [66] Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
- [67] Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy Assessment of Land Use/Land Cover Classification Using Remote Sensing and GIS. *International Journal of Geosciences*, 08(04), 611–622. DOI: 10.4236/ijg.2017.84033
- [68] Zhou, Y., Zhang, R., Wang, S., & Wang, F. (2018). Feature Selection Method Based on High-Resolution Remote Sensing Images and the Effect of Sensitive Features on Classification Accuracy. *Sensors*, 18(7), 2013. <https://doi.org/10.3390/s18072013>
- [69] Temenos, A., Temenos, N., Kaselimi, M., Doulamis, A., & Doulamis, N. (2023). Interpretable Deep Learning Framework for Land Use and Land Cover Classification in Remote Sensing Using SHAP. *IEEE Geoscience and Remote Sensing Letters*, 20, 1–5. DOI: 10.1109/LGRS.2023.3251652
- [70] Moradi, R., Berangi, R., & Minaei, B. (2019). A survey of regularization strategies for deep models. *Artificial Intelligence Review*, 53(6), 3947–3986. <https://doi.org/10.1007/s10462-019-09784-7>
- [48] Helber, P., Bischke, B., Dengel, A., & Borth, D. (2019). Eurosat: A novel dataset and deep learning benchmark for land use and land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(7), 2217–2226. DOI: 10.1109/JSTARS.2019.2918242
- [49] Cheng, X., Li, B., Deng, Y., Tang, J., Shi, Y., & Zhao, J. (2024). MMDL-Net: Multi-Band Multi-Label Remote Sensing Image Classification Model. *Applied Sciences*, 14(6), 2226. <https://doi.org/10.3390/app14062226>
- [50] Stoimchev, M., Kocev, D., & Džeroski, S. (2023). Deep Network Architectures as Feature Extractors for Multi-Label Classification of Remote Sensing Images. *Remote Sensing*, 15(2), 538. <https://doi.org/10.3390/rs15020538>
- [51] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770–778). <https://doi.org/10.48550/arXiv.1512.03385>
- [52] Wang, L., Wang, J., Liu, Z., Zhu, J., & Qin, F. (2022). Evaluation of a deep-learning model for multispectral remote sensing of land use and crop classification. *The Crop Journal*, 10(5), 1435–1451. <https://doi.org/10.1016/j.cj.2022.01.009>
- [53] Hosseiny, B., Abdi, A. M., & Jamali, S. (2022). Urban land use and land cover classification with interpretable machine learning – A case study using Sentinel-2 and auxiliary data. *Remote Sensing Applications: Society and Environment*, 28, 100843. <https://doi.org/10.1016/j.rsase.2022.100843>
- [54] Shehab, L. H., Fahmy, O. M., Gasser, S. M., & El-Mahallawy, M. S. (2021). An efficient brain tumor image segmentation based on deep residual networks (ResNets). *Journal of King Saud University - Engineering Sciences*, 33(6), 404–412. <https://doi.org/10.1016/j.jksues.2020.06.001>
- [55] Wang, Y., Li, K., Xu, L., Qian, W., Wang, F., & Chen, Y. (2021). A Depthwise Separable Fully Convolutional ResNet With ConvCRF for Semisupervised Hyperspectral Image Classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 4621–4632. DOI: 10.1109/JSTARS.2021.3073661
- [56] Safari, M. M., Sharifi, A., Mahmoodi, J., & Dariush Abbasi-Moghadam. (2024). Mesoscale eddy detection and classification from sea surface temperature maps with deep neural networks. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 10279–10290. DOI: 10.1109/JSTARS.2024.3402823
- [57] Nava, L., Monserrat, O., & Catani, F. (2022). Improving Landslide Detection on SAR Data Through Deep Learning. *IEEE Geoscience and Remote Sensing Letters*, 19, 1–5. DOI: 10.1109/LGRS.2021.3127073
- [58] 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. <https://doi.org/10.1080/01431161.2019.1694725>
- [59] Truong, T. X., Nhu, V.-H., Phuong, D. T. N., Nghi, L. T., Hung, N. N., Hoa, P. V., & Bui, D. T. (2023). A New Approach Based on



طبقه بندی تصاویر سنجش از دور، ادغام تصاویر و کاربردهای یادگیری ماشین و یادگیری عمیق در حوزه سنجش از دور شده‌اند.

Heidari, P., M.Sc. Student in Photogrammetry, Faculty of Civil, Water, and Environmental Engineering, Shahid

Beheshti University, Tehran, Iran.

✉ po_heidari@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 نقشه‌برداری- فتوگرامتری می‌باشد. ایشان تا کنون موفق به چاپ مقالات متعدد در مجلات و کنفرانس‌های داخلی و بین‌المللی معتبر شده‌اند. زمینه‌های تخصصی ایشان عبارتند از: فتوگرامتری، سنجش از دور، کاداستر و پردازش تصاویر می‌باشد.

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

✉ a_milan@sbu.ac.ir



علیرضا قراگوزلو دانشیار گروه مهندسی نقشه برداری در دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی می‌باشند. ایشان عضو کمیسیون تخصصی سنجش از دور و سیستم اطلاعات جغرافیایی وزارت علوم، تحقیقات و فناوری و همچنین از اعضای هیئت مدیره انجمن محیط زیست ایران هستند. تا کنون بیش از ۵ دوره به عنوان پژوهشگر برگزیده کشوری انتخاب شده و مولف بیش از ۱۵ عنوان کتاب و نویسنده مقالات بین‌المللی و علمی پژوهشی متعددی هستند. زمینه‌های تخصصی ایشان سیستم اطلاعات مکانی، سنجش از دور، آمایش سرزمین و محیط زیست می‌باشد.

Gharagozlou, A. Associate Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

✉ a_gharagozlou@sbu.ac.ir

[71] Salehin, I., & Kang, D.-K. (2023). A Review on Dropout Regularization Approaches for Deep Neural Networks within the Scholarly Domain. *Electronics*, 12(14), 3106. <https://doi.org/10.3390/electronics12143106>

[72] Piotrowski, A. P., Napiorkowski, J. J., & Piotrowska, A. E. (2020). Impact of deep learning-based dropout on shallow neural networks applied to stream temperature modelling. *Earth-Science Reviews*, 201, 103076. <https://doi.org/10.1016/j.earscirev.2019.103076>

[73] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), 1-48. <https://doi.org/10.1186/s40537-019-0197-0>

[74] Hao, X., Liu, L., Yang, R., Yin, L., Zhang, L., & Li, X. (2023). A Review of Data Augmentation Methods of Remote Sensing Image Target Recognition. *Remote Sensing*, 15(3), 827. <https://doi.org/10.3390/rs15030827>

[75] Ceni, A. (2022). Random orthogonal additive filters: a solution to the vanishing/exploding gradient of deep neural networks. *arXiv preprint arXiv:2210.01245*. DOI: 10.1109/TNNLS.2025.3538924

[76] Li, P., Han, L., Tao, X., Zhang, X., Grecos, C., Plaza, A., & Ren, P. (2020). Hashing Nets for Hashing: A Quantized Deep Learning to Hash Framework for Remote Sensing Image Retrieval. *IEEE Transactions on Geoscience and Remote Sensing*, 58(10), 7331–7345. DOI: 10.1109/TGRS.2020.2981997

[77] Lei, S., Shi, Z., & Zou, Z. (2017). Super-Resolution for Remote Sensing Images via Local-Global Combined Network. *IEEE Geoscience and Remote Sensing Letters*, 14(8), 1243–1247. DOI: 10.1109/LGRS.2017.2704122

[78] Anam, M. K., Defit, S., Haviluddin, H., Efrizoni, L., & Firdaus, M. B. (2024). Early Stopping on CNN-LSTM Development to Improve Classification Performance. *Journal of Applied Data Sciences*, 5(3), 1175–1188. <https://doi.org/10.47738/jads.v5i3.312>

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES

پویا حیدری دانشجوی ورودی ۱۴۰۱ کارشناسی ارشد فتوگرامتری دانشگاه شهید بهشتی می‌باشند. ایشان تاکنون موفق به چاپ مقالات متعدد در مجلات و کنفرانس‌های داخلی و بین‌المللی در زمینه‌های

Citation (Vancouver): Heidari P, Milan A, Gharagozlou A. [Object detection and classification with Sentinel-2 imagery using ResNet]. *J. RS. GEOINF. RES.* 2025; 3(1): 15-36

doi <https://doi.org/10.22061/jrsgr.2025.11719.1094>



COPYRIGHTS

© 2025 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/>)