

Extraction of agricultural land borders from satellite images using deep learning and convolutional neural networks

Morteza Heidarimozaffar*¹ , Sajjad Yavari² , Zahra Dalvand³ 

1- (*Corresponding author) Assistant professor, Faculty of engineering, Bu-Ali Sina University, Hamedan, Iran.

Email: m.heidarimozaffar@basu.ac.ir

2- M.Sc. Student, Faculty of engineering, Bu-Ali Sina University, Hamedan, Iran..Email: S.yavari@eng.basu.ac.ir

3-PhD Student, Faculty of engineering, Bu-Ali Sina University, Hamedan, Iran. Email: z.dalvand@eng.basu.ac.ir

Article Info

Date of receive:

2024/12/10

Date of last review:

2025/05/23

Date of accept:

2025/07/29

Date of online publication:

2025/07/29

Keywords:

The border of agricultural land,
Remote sensing,
Deep learning,
Automatic boundary extraction algorithms,
Convolutional neural network,
Training dataset

Extended Abstract

Introduction

The purpose of extracting borders is to create a database of agricultural lands. With this information, it is possible to estimate the amount of water consumption and crop harvest and automate agricultural machinery's guidance. The field survey of land borders is time-consuming and expensive. Therefore, remote sensing methods can be used for this. Manually delineating agricultural land boundaries from remote sensing images is still difficult. Thus, using automatic algorithms is a good solution. These algorithms are divided into Traditional algorithms and algorithms based on deep learning. Traditional algorithms have problems such as incorrect positioning and poor detection accuracy. Therefore, researchers have proposed a variety of edge detection algorithms based on deep learning. Convolutional neural networks are among the algorithms used in this research

Materials & Methods

To train convolutional neural networks, the open-access dataset of France and three datasets of Hamadan, Bahar, and Khersan were used. To conduct this research, Global mapper & Adobe Photoshop software was used to prepare images, draw label polygons, and unify the format of labels belonging to different datasets. Python programming language, Anaconda environment, and Cross and Tensor Flow libraries have been used to implement deep learning algorithms. Eight scenarios were tested with different datasets. Five of them were performed without the use of transfer learning and fine-tuning, and the other three were performed using fine-tuning.... ▶ Page 08

How to Cite:

Heidarimozaffar, M. Yavari, S. Dalvand, Z. (2025). Extraction of agricultural land borders from satellite images using deep learning and convolutional neural networks. Scientific-Research Quarterly Geographical Data (SEPEHR). 34(135), 07-26.

By combining U-Net architecture and pre-trained neural networks, five hybrid architecture modes were constructed. The attention mechanism was also used to improve the performance of the models. To evaluate the performance, Dice Score, IoU, Accuracy, Recall, and F1-Score metrics were calculated.

Results & Discussion

In the first scenario, the training and testing of the model was done on the French dataset. The sameness of these datasets in this scenario helps to compare different backbones. In the second scenario, the training and testing were done on the Hamadan dataset. In this scenario, due to the same training and test datasets, the performance of different backbones was compared. In the third scenario, training was done on the French dataset and testing on the Hamadan dataset. The purpose of designing this scenario is to evaluate the performance of the models on the images of different regions, with different spatial resolutions and sensors. In the fourth scenario, training was done on the French dataset and testing on the Bahar dataset. This scenario examines the possibility of using images with a spatial resolution of 10 meters for training and testing models. In the fifth scenario, training was done on the French dataset and testing was done on the Khersan dataset. In this scenario, the generalizability of the model was investigated. In the sixth scenario, training on the French dataset, fine-tuning on the Hamedan dataset, and testing on the Hamedan dataset were done. In this scenario, the effect of transfer learning was investigated. Also, the result of using images of different regions on the performance of the model was evaluated. In the seventh scenario, training on the French dataset, fine-tuning on the Hamadan dataset, and testing on the Khersan dataset were performed. One of the goals of this scenario is to evaluate the generalizability of the model. In the eighth scenario, the model was trained on the French dataset and fine-tuned on the Hamedan dataset. Finally, the test was performed on the Bahar dataset. The purpose of this scenario is to evaluate the effect of the spatial resolution of the test dataset images on the performance of the model.

Conclusion

In the first scenario, the accuracy of detection in the

first, fourth, and fifth architectural states is similar and equal to 0.71. In the IoU metric. The recognition quality of the model is not favorable for small plots. One of the reasons is the low spatial resolution of images. In the second scenario, compared to the first scenario, the first, fourth, and fifth architectural states have suffered a drop in accuracy. Reducing the number of training datasets can be one of the reasons. In the third scenario, the number of Training images increased compared to the second scenario. As a result, the accuracy of the model's performance in the fourth architectural mode increased by 0.03 in the IOU metric compared to the second scenario. However, due to the difference in the resolution of the training and test datasets, the performance of the model was not satisfactory. The accuracy of the model in the fourth scenario decreased by 0.57 compared to the third scenario. The main difference between the third and fourth scenarios is in the spatial resolution of the test images. This shows that to achieve the desired results, the test images should have sufficient spatial resolution. In the fifth scenario, the accuracy of the first architectural mode decreased by 0.10 and the fourth architectural mode decreased by 0.18 in the IOU metric. This decrease in accuracy is due to the difference in topography and the size and shape of agricultural lands in the regions of France and Khersan. It can be concluded that the generalizability of the model is not suitable. The sixth scenario is the same as the third scenario, only fine-tuning on the Hamadan dataset has been added. The detection accuracy of the sixth scenario in the fourth architectural mode reached 0.87 and compared to the third scenario in the same architectural mode, it increased by 0.14. This shows that fine-tuning is effective in increasing model accuracy. The 7th scenario compared to the 5th scenario in the 4th architectural mode had a 0.04 increase in accuracy in the IOU metric due to the use of fine tuning. But still, the detection accuracy in this scenario was not desired. One of the reasons for this problem is the difference between agricultural lands in France and Khersan regions. It can be concluded that the existing models for use in different regions do not have proper generalization capabilities.



صفحات ۲۶ - ۷

فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۴، شماره ۱۳۵، پاییز ۱۴۰۴

مقاله پژوهشی

doi <https://doi.org/10.22131/sepehr.2025.2047383.3108>

استخراج مرز زمین‌های کشاورزی از تصاویر ماهواره‌ای با یادگیری عمیق و شبکه‌های عصبی پیچشی

مرتضی حیدری مظفر*^۱، سجاد یآوری^۲، زهرا دالوند^۳۱- (*نویسنده مسئول) استادیار گروه عمران، دانشکده مهندسی، دانشگاه بوعلی سینا، همدان، ایران m.heidarimozaffr@basu.ac.ir۲- دانشجوی کارشناسی ارشد، گروه عمران، دانشکده مهندسی، دانشگاه بوعلی سینا، همدان، ایران S.yavari@eng.basu.ac.ir۳- دانشجوی دکتری، گروه کامپیوتر، دانشکده مهندسی، دانشگاه بوعلی سینا، همدان، ایران z.dalvand@eng.basu.ac

چکیده

هدف از استخراج اطلاعات مرزی، ایجاد پایگاه اطلاعات زمین‌های کشاورزی است. با داشتن این معلومات می‌توان میزان مصرف آب و برداشت محصول را تخمین زد و هدایت ماشین‌آلات کشاورزی را خودکار نمود. برداشت میدانی مرز زمین‌ها زمان‌بر و پرهزینه است و برای این کار می‌توان روش‌های سنجش از دوری را مورد استفاده قرار داد. اما ترسیم دستی مرز زمین‌های کشاورزی از روی تصاویر سنجش از دوری، همچنان دشوار است. بنابراین استفاده از روش‌های خودکار راه‌حل مناسبی به نظر می‌رسد. این روش‌ها را می‌توان به دو دسته روش‌های مرسوم پردازش تصویر و روش‌های مبتنی بر یادگیری ماشین طبقه‌بندی کرد. روش‌های مرسوم پردازش تصویر مانند تشخیص لبه، مشکلاتی چون موقعیت‌یابی نادرست و دقت تشخیص ضعیف دارند. بنابراین محققان الگوریتم‌های تشخیص لبه نوین را بر اساس یادگیری عمیق، پیشنهاد نموده‌اند. شبکه‌های عصبی پیچشی از جمله آن‌ها هستند که در این پژوهش به کار رفته‌اند. برای پیاده‌سازی روش پیشنهادی، از زبان برنامه‌نویسی پایتون نسخه ۳/۱۱ در چارچوب کتابخانه `keras` استفاده شد. یکی از مشکلات استفاده از شبکه‌های عصبی پیچشی، کمبود مجموعه داده آموزشی مناسب است. در پژوهش حاضر برای حل این مشکل، از فنون انتقال یادگیری و تنظیم دقیق استفاده شد. مجموعه داده دسترسی آزاد فرانسه در کنار سه مجموعه داده همدان، بهار و خراسان، برای آموزش شبکه‌های عصبی پیچشی به کار رفت. هشت سناریوی آزمایشی طراحی شد. پنج مورد از آن‌ها با تنظیم دقیق و سه مورد دیگر بدون تنظیم دقیق انجام گرفت. همچنین پنج حالت معماری مختلف از شبکه `U-Net` با شبکه‌های پایه مختلف پیاده‌سازی شد. برای ارزیابی عملکرد، معیارهای `Recall`، `Accuracy`، `IoU`، `Dice Score` و `F1-Score` محاسبه شدند. در پایان مشخص شد انتقال یادگیری و تنظیم دقیق، روشی برای جبران کمبود داده‌های آموزشی و افزایش دقت هستند. در این پژوهش دقت عملکرد سناریوی سوم آزمایش `T ۰/۷۳` در معیار `IoU` بود. وقتی همین سناریو با استفاده از تنظیم دقیق انجام شد، دقت آن `۰/۱۴` بهبود یافت و به `۰/۸۷` رسید. همچنین مکانیسم `Attention` در ترکیب با معماری‌های شبکه عصبی، دقت استخراج مرز را بهبود داد.

اطلاعات مقاله

تاریخ دریافت:

۱۴۰۳/۰۹/۲۰

تاریخ آخرین بازنگری:

۱۴۰۴/۰۳/۰۲

تاریخ پذیرش:

۱۴۰۴/۰۵/۰۷

تاریخ انتشار:

۱۴۰۴/۰۵/۰۷

واژه‌های کلیدی:

مرز زمین‌های کشاورزی؛

سنجش از دور؛

یادگیری عمیق؛

الگوریتم‌های استخراج

مرز خودکار؛

شبکه عصبی پیچشی؛

مجموعه داده آموزشی

استناد به این مقاله:

حیدری مظفر، م؛ یآوری، س؛ دالوند، ز (۱۴۰۴) استخراج مرز زمین‌های کشاورزی از تصاویر ماهواره‌ای با یادگیری عمیق و شبکه‌های عصبی پیچشی؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۴(۱۳۵)، ۲۶ - ۰۷.

۱- مقدمه

در این پژوهش، مرزهای رسمی و کاداستر نبوده و مالکیت زمین‌ها را نشان نمی‌دهد. این مرزها در واقع عامل ایجاد تمایز بین قطعات مختلف زمین‌های کشاورزی هستند. به منظور استخراج مرز زمین‌های کشاورزی با تصاویر سنجنش از دور، می‌بایست این مرزها را در تصاویر هوابرد و فضابرد رقومی‌سازی و برداری‌سازی نمود.

عوامل متعددی بر استخراج مرز زمین‌های کشاورزی تأثیرگذار است. ویژگی‌های تصویر و مشخصات الگوریتم‌های شناسایی از آن جمله هستند. تصاویر رقومی^۲ و ویژگی‌هایی نظیر وضوح ناشی از اندازه پیکسل (قدرت تفکیک مکانی^۳)، تعداد باندهای طیفی قابل اندازه‌گیری (قدرت تفکیک طیفی^۴) و وضوح رادیومتریک (قدرت تفکیک رادیومتریک^۵) دارند که در پردازش و تجزیه و تحلیل آن‌ها تأثیرگذار است (Richards, 2022). قدرت تفکیک مکانی، معیاری برای نشان دادن کوچک‌ترین هدف قابل مشاهده روی تصویر است (AI-Wassai & Kalyankar, 2013). استخراج مرز زمین‌های کشاورزی، به دو روش رقومی‌سازی دستی توسط انسان و روش‌های نیمه‌خودکار یا تمام‌خودکار مبتنی بر رایانه انجام می‌شود. رقومی‌سازی دستی عبارت است از تفسیر بصری تصاویر با تفکیک مکانی زیاد توسط متخصصان بر اساس دانش قبلی و اصل شباهت پیکسلی که استخراج کامل و دقیق مرز زمین‌های کشاورزی را امکان‌پذیر می‌کند. با این وجود، در مواجهه با حجم وسیعی از داده‌های مرزی، رقومی‌سازی دستی هزینه و زمان زیادی لازم دارد، بنابراین بهتر است این کار به صورت خودکار انجام شود. به این منظور گستره وسیعی از روش‌های خودکار استخراج مرز زمین‌های کشاورزی بر اساس تصاویر سنجنش از دور ابداع شده است. این روش‌ها را می‌توان به دو دسته کلی روش‌های کلاسیک پردازش تصویر^۶ و روش‌های مبتنی بر

سنجنش از دور با قابلیت‌هایی چون توان پایش به موقع مناطق پهناور، صرفه اقتصادی و ماهیت غیر مخرب خود، به یکی از مؤثرترین ابزارهای فنی برای پایش زمین‌های زیر کشت تبدیل شده است. از جمله اطلاعات مهمی که می‌توان از سنجنش از دور به دست آورد، موقعیت مرز زمین‌های کشاورزی است. هدف از استخراج اطلاعات مرزی، بررسی آماری محصولات کشاورزی و ایجاد پایگاه اطلاعات زمین‌های کشاورزی است. با داشتن این معلومات می‌توان مصرف آب را تخمین زد و مقدار برداشت محصول را تعیین نمود. همچنین می‌توان هدایت ماشین‌آلات کشاورزی را به کمک آن خودکار نمود (Wang et al., 2023). تمام این فرایندها با هدف انجام کشاورزی دقیق^۱ صورت می‌گیرد. در این نوع کشاورزی تمامی متغیرها تحت کنترل بوده و میزان مواد مصرفی و محصولات تولیدی برای سیاست‌گذاری صحیح و امنیت غذایی مشخص است. برای استخراج مرز زمین‌های کشاورزی، ابتدا باید این پدیده را در دنیای واقعی تعریف نمود. سپس باید نحوه تفسیر آن را در تصاویر سنجنش از دور مشخص کرد. زمین‌های کشاورزی جزئی از طبیعت هستند که بشر به دلخواه خود آن را تغییر داده است، بنابراین انواع متفاوتی از آن‌ها و مرزهای مابین‌شان در سراسر کره زمین یافت می‌شود. در حال حاضر، تعریفی معتبر از مفهوم مرز زمین‌های کشاورزی وجود ندارد. اما می‌توان مرز زمین‌های کشاورزی را به عنوان مکانی که در آن نوع محصول تغییر می‌کند، در نظر گرفت. همچنین خط اتصال میان دو قطعه زمین را نیز می‌توان مرز قلمداد نمود (Wang et al., 2023). از منظر سنجنش از دور، مرز زمین‌های کشاورزی، مکان‌هایی هستند که در آن‌ها ویژگی‌هایی نظیر ارزش پیکسل، رنگ و بافت دچار تغییر می‌شوند. البته این تغییرات باید در ارتباط با ویژگی‌های درونی تصویر سنجنیده شوند تا در نهایت یک زمین کشاورزی به صورت منطقی مورد استخراج قرارگیرد. باید توجه داشت منظور از مرز

2- Digital Images

3- Spatial resolution

4- Spectral resolution

5- Radiometric resolution

6- Traditional Algorithms

1- Precision Farming

CNN اولین نمونه از معماری شبکه‌های عمیق هستند که با موفقیت به قابلیت تعمیم خوبی روی ورودی‌های تصویری دست یافته‌اند (Arnold, Rebecchi, Chevallier, & Paugam - Moisy, 2011). شبکه‌های رمزگذار- رمزگشا گونه‌ای از شبکه‌های عصبی پیچشی هستند که برای استخراج مرز، تصاویر را قطعه‌بندی^۴ می‌کنند. تحقیق لانگ و همکاران الهام بخش فرایند قطعه‌بندی تصویر با استفاده از CNN است (Long, Shelhamer, & Darrell, 2015). قطعه‌بندی تصویر نوعی طبقه‌بندی در سطح پیکسل است. برای استخراج مرز زمین‌های کشاورزی، الگوریتم مبتنی بر شبکه‌های پیچشی کامل^۵ دارای انبساط چندگانه^۶ در سطح پیکسل مورد استفاده قرار گرفت. انبساط، تکنیکی است که اندازه تصویر ورودی را با قراردادن حفره‌هایی بین پیکسل‌های متوالی آن، گسترش می‌دهد. به عبارت دیگر همان پیچش است اما با پرش پیکسل، منطقه بزرگ‌تری از ورودی را پوشش می‌دهد. داده‌های مورد استفاده این تحقیق تصاویر سنجنش از دور با تفکیک مکانی ۱۰ متر بود. دقت استخراج این روش به ۶۶ درصد رسید (Masoud, Persello, & Tolpekin, 2020). در ترکیب شبکه‌های پیچشی با سایر الگوریتم‌ها، می‌توان دقت و استحکام بالایی به دست آورد. بر این اساس، در روشی از FCN برای تولید خطوط قطعه‌بندی استفاده شد. سپس با استفاده از فرایند OWT-UCM^۷ قطعه‌بندی سلسله‌مراتبی انجام گرفت. در نهایت برای ادغام مناطق در سطوح مختلف، الگوریتم SCG به کار رفت. این الگوریتم از نوع یادگیری نظارت شده^۸ کاملاً خودکار بوده و بدون پارامترهای وابسته به کاربر، از جستجوی خطی وقت‌گیر جلوگیری می‌کند. در ادامه و در صورت لزوم، یک الگوریتم gPb^۹ می‌تواند به فرایند اضافه شود. این روش در تشخیص مرز به دقت خوبی دست یافت (Persello, Tolpekin, Bergado,

یادگیری ماشین^۱ طبقه‌بندی کرد. دسته اول، برای استخراج مرز از فرایند تشخیص لبه^۲ استفاده می‌کنند. دقت استخراج مرز توسط عملگرهای شناسایی لبه مرسوم ایده‌آل نیست. به طور مثال، واتکینز و همکارانش، در تحقیقی با استفاده از عملگرهای Roberts و Sobel، مرز زمین‌های کشاورزی استخراج نمودند، اما مقادیر زیادی نویز برجای ماند که به راحتی با فیلتر کردن از بین نمی‌رفت. با این حال با انجام برخی اصلاحات، توانستند کیفیت تشخیص مرز زمین توسط عملگرهای شناسایی لبه مرسوم را بهبود دهند. به عنوان نمونه، برای اصلاح معایب آن‌ها، عملگرهای Canny و Scharr با مجموع ۲۸ نمودار در چهار باند RGB و NIR و هفت تاریخ نمونه‌برداری ترکیب شدند، تا یک لایه مرز چندزمانی ترکیبی ایجاد شود (Watkins & van Niekerk, 2019). دسته دوم، از تکنیک یادگیری ماشین برای استخراج خودکار مرز زمین‌های کشاورزی بهره می‌برند. یادگیری عمیق زیرمجموعه یادگیری ماشین بوده و یادگیری ماشین زیرمجموعه هوش مصنوعی است (Chollet, 2017). هوش مصنوعی به طراحی و اجرای سامانه‌های رایانه‌ای اطلاق می‌شود که قادر به حل مسائل پیچیده و یا کارهای مشابه فرایندهای زیست‌شناختی همچون دیدن و یا درک زبان هستند. انجام چنین کارهایی معمولاً به توانایی‌های هوش بشری نیاز دارد (Haton, 2006). یادگیری عمیق، بر روی بخش‌های گسترده‌ای از علوم، تأثیری چشمگیر داشته و به طور فزاینده‌ای خود را به عنوان روشی تطبیق‌پذیر برای غلبه بر چالش‌های جدید در زمینه سنجنش از دور معرفی نموده است (Hoese & Kuenzer, 2020). از جمله الگوریتم‌های تشخیص لبه مبتنی بر یادگیری عمیق، می‌توان به شبکه‌های عصبی پیچشی^۳ اشاره نمود (Sun et al., 2022). در سال ۲۰۱۲، سیرسان و کریژوفسکی CNN را که بهترین نمایشگر مدل‌های یادگیری عمیق بودند، به منظور تشخیص عوارض از تصاویر خام معرفی نمودند (Krizhevsky, Sutskever, & Hinton, 2012).

4- Segmentation

5- Fully Convolutional Networks(FCN)

6- Multiple Dilatation FCN(MD-FCN)

7- Oriented Watershed Transform and Ultrametric Contour Map (OWT-UCM)

8- Supervised Learning

9- globalized Probability of boundary

1- Machine Learning

2- Edge Detection

3- Convolutional Neural Networks(CNN)



نگاره ۱: هشت سناریوی آزمایشی طراحی شده

تهیه مجموعه داده‌های مناسب است. در این پژوهش، مجموعه داده‌های مورد نیاز از طریق منابع دسترسی آزاد و نیز برچسب‌گذاری به روش تفسیر بصری تهیه شدند. همچنین به منظور بررسی عملکرد الگوریتم‌های شبکه عصبی مختلف و نیز فن انتقال یادگیری، سناریوهای آزمایشی مختلفی طراحی شدند. این سناریوها در نگاره ۱ نمایش داده شده‌اند. هشت سناریو با مجموعه داده‌های مختلف مورد آزمایش قرار گرفتند. پنج مورد از آن‌ها بدون استفاده از تکنیک انتقال یادگیری و تنظیم دقیق، و سه مورد دیگر با به‌کارگیری تنظیم دقیق انجام شده‌اند. برای انجام آزمایش‌ها از زبان برنامه‌نویسی پایتون نسخه ۳/۱۱ در چارچوب کتابخانه keras استفاده شد. به دلیل تعداد کم تصاویر آموزشی برچسب‌گذاری شده، تصمیم بر آن شد که از شبکه‌های عصبی پیش‌آموزش داده شده در ترکیب با معماری U-Net استفاده شود. این شبکه‌های پیش‌آموزش داده شده روی مجموعه داده ImageNet که شامل حدود ۱۴ میلیون تصویر از ۱۰۰۰ کلاس متفاوت است، آموزش دیده‌اند. از ترکیب معماری U-Net و شبکه‌های پایه پیش‌آموزش داده شده، پنج حالت معماری ترکیبی به وجود آمد.

(Li, & de By, 2019) علاوه بر الگوریتم FCN، الگوریتم CNN نیز می‌تواند به منظور استخراج مرز زمین‌های کشاورزی مورد استفاده قرار گیرد. در این راستا یک الگوریتم ترکیب مرز عمیق^۱ پیشنهاد شد. در این روش، ابتدا برای به دست آوردن نقشه احتمال مرز در تصویر زمین کشاورزی، از یک CNN استفاده شد. سپس الگوریتم OWT-UCM برای تقسیم نقشه احتمال مرز به درخت سلسله‌مراتب مرزی بسته^۲ به کار رفت. در نهایت آستانه مناسب (k) برای به دست آوردن تصویر درخت سلسله‌مراتبی انتخاب شد. با توجه به آزمایش‌ها، این الگوریتم توانست مرز زمین‌های کشاورزی را با دقت زیادی استخراج نماید. میزان دقت و یکپارچگی مرز شناسایی شده توسط آن در دو تصویر، حدود ۹۰ درصد بود. الگوریتم به کاررفته در این روش، از نظر متغیرهایی چون مقایسه، صحت، کامل بودن و کیفیت تشخیص، از الگوریتم‌های مبتنی بر عملگر Canny و نیز از نظر صحت و کیفیت، از الگوریتم‌های مبتنی بر عملگر MCG^۳ برتر است (Li, Xu, Yang, & Pu, 2020).

بهره‌گیری از الگوریتم‌های شبکه عصبی پیچشی، مستلزم

- 1- Deep Boundary Combination(DBC)
- 2- Closed boundary hierarchy tree
- 3- Magnetocardiography based algorithm

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (ص ۳۳)

استخراج مرز زمین‌های کشاورزی از تصاویر ماهواره‌ای با یادگیری عمیق و ... / ۱۳

داده‌های آموزشی، داده‌های اعتبارسنجی و داده‌های تست تقسیم می‌شوند. داده‌های آموزشی برای آموزش مدل به کار می‌روند. داده‌های اعتبارسنجی برای سنجش صحت روند آموزش مدل و داده‌های تست نیز برای ارزیابی دقت مدل به کار می‌روند. ۸۰ درصد داده‌ها برای آموزش، ۱۰ درصد برای اعتبارسنجی و ۱۰ درصد برای آزمون استفاده شده است.

۲-۱-۱- مجموعه داده فرانسه

مجموعه داده فرانسه که Crop_Delineation نام دارد، شامل تصاویر اخذ شده توسط ماهواره Sentinel-2 متعلق به کشور فرانسه بوده و به صورت سالیانه تولید می‌شود. تصاویر ماهواره Sentinel-2 نسبت به ماهواره‌های هم رده قدرت تفکیک مکانی متوسط، به میزان ده متر دارند (Phiri et al., 2020). مجموعه داده فرانسه شامل ۱۹۹۱ نمونه تصویر و دو نوع برچسب متناظر با هر تصویر است. در برچسب‌های نوع اول که masks نام‌گذاری شده‌اند، مرزها به صورت خطوط سفید مشخص شده و مزارع و پس‌زمینه به رنگ مشکی هستند. در برچسب‌های نوع دوم که masks_filled نام دارند، مرزها به صورت خطوط مشکی، مزارع به صورت پلی‌گون‌های سفید توپر داخل آن‌ها و مناطق پس‌زمینه، به رنگ مشکی هستند. این مجموعه داده از منابع دسترسی آزاد تهیه شد.

۲-۱-۲- مجموعه داده همدان

برای تهیه مجموعه داده همدان، از تصاویر ماهواره WorldView-4 استفاده شد. قدرت تفکیک این تصاویر حدود ۳۰ سانتی‌متر بوده و در میان ماهواره‌های غیر نظامی بالاترین مقدار را دارد (Sefercik et al., 2020). وضعیت توپوگرافی و نیز شکل زمین‌ها در این منطقه دقیقاً مشابه زمین‌های موجود در تصاویر مجموعه داده Crop_Delineation کشور فرانسه نیست، اما شباهت‌های زیادی با آن دارد. برای تهیه این مجموعه داده، تصویر ماهواره‌ای موجود به ابعاد ۲۲۴ در

در طراحی مدل، شبکه پایه‌ای^۱ باید انتخاب شود که بین عمق، تعداد پارامترها، هزینه محاسباتی و نیز قابلیت استخراج ویژگی‌ها توسط آن، تعادل برقرار نماید (Hoeseer, Bachofer, & Kuenzer, 2020) به منظور ارزیابی حساسیت نتایج به انتخاب شبکه پایه، این پنج حالت معماری در همه سناریوها مورد آزمایش قرار گرفت. پس از اجرای حالات معماری مختلف، تصاویر ماهواره‌ای به صورت کامل مورد قطعه‌بندی قرار گرفته و طبقه‌بندی در سطح پیکسل‌ها انجام شد. به هر پیکسل یک کلاس منحصر به فرد اختصاص داده شد. باید توجه داشت پس از قطعه‌بندی تصاویر و تشکیل مرز در محیط رستری، می‌توان آن‌ها را به مرزهای وکتوری تبدیل نمود که از اهداف این پژوهش نیست.

۲- داده‌ها و روش‌ها

۲-۱- مناطق مورد مطالعه و مجموعه داده‌ها

به منظور آموزش شبکه‌های عصبی، از مجموعه داده دسترسی آزاد فرانسه در کنار سه مجموعه داده همدان، بهار و خراسان استفاده شد. این سه مجموعه داده به منظور بررسی اثر انتقال یادگیری و نیز قابلیت تعمیم‌پذیری مدل‌ها تهیه و آماده‌سازی شدند. مجموعه داده‌های مورد استفاده در یادگیری عمیق، از دو بخش داده‌ها و برچسب‌های متناظر با آن‌ها تشکیل شده‌اند. برچسب‌ها با فرمت‌های متنوعی تولید می‌شوند. در این پژوهش استخراج مرز از طریق قطعه‌بندی تصویر انجام می‌شود. بنابراین برچسب‌های موجود در مجموعه داده‌های مورد استفاده، به فرمت ماسک‌های قطعه‌بندی تولید شده‌اند. برای هر تصویر دو کلاس در نظر گرفته شده است. کلاس یک به زمین‌های کشاورزی اختصاص داده شده است. کلاس صفر به پس‌زمینه شامل سطوح غیر کشاورزی نظیر بافت شهری، کوهستان، باغات و جنگل تعلق دارد. کلاس یک به رنگ سفید و کلاس صفر به رنگ مشکی، در ماسک برچسب‌گذاری شده است. داده‌های موجود در تمامی مجموعه داده‌ها، به سه بخش

جدول ۱: نام، علامت اختصاری و مشخصات مجموعه داده‌ها

نام مجموعه داده	ماهواره مرجع تصاویر	قدرت تفکیک مکانی تصاویر (متر)	علامت اختصاری
فرانسه	Sentinel-2	۱۰	Fr
همدان	WorldView-4	۰٫۳	H
خرسان	Jilin	۰٫۵	Kh
بهار	Sentinel-2	۱۰	B

تعمیم پذیری روش پیشنهادی برای تشخیص مرز زمین‌های کشاورزی انتخاب شد. به منظور تهیه این مجموعه داده، یک منظره از تصویر ماهواره Jilin به ابعاد ۲۴۰۰ در ۱۹۸۰ متر انتخاب شد. قدرت تفکیک مکانی آن نیم متر بود. سپس این تصویر به ۴۱۴ قطعه تصویر کوچک‌تر ۲۲۴ در ۲۲۴ پیکسل تقسیم شد. از آنجایی که این منطقه از کوه، دره و رودخانه تشکیل شده است، تعداد زمین‌های کشاورزی در آن بسیار کم است بنابراین ۱۸ تصویر که تا حدودی تشخیص مزارع داخل آن‌ها چالش برانگیز بود، انتخاب شد. همانند مجموعه داده بهار، فرایند برچسب‌گذاری آن‌ها با استفاده از نرم‌افزار گلوبال‌میر صورت گرفته و ماسک‌هایی با فرمت PNG تولید شد. این مجموعه داده به دلیل تعداد کم تصاویر، یک مجموعه داده تست محسوب شده و شامل ۱۸ تصویر و ماسک‌های برچسب متناظر با آن‌هاست. نام مجموعه داده‌ها، ماهواره مرجع، قدرت تفکیک تصاویر به‌کار رفته و علامت اختصاری آن‌ها در جدول ۱ نشان داده شده است. همچنین نگاره ۲ موقعیت مکانی مناطق مورد مطالعه و تصاویر مجموعه داده‌های تهیه شده را نشان می‌دهد.

۲۲۴ پیکسل تقسیم شد تا با ساختار بخش ورودی معماری شبکه عصبی پیچشی، هماهنگ شود. این مجموعه داده شامل ۲۰۰ قطعه تصویر است که شامل نمونه‌های هر دو کلاس زمین کشاورزی و غیر آن است. در مرحله بعد با استفاده از نرم‌افزار گلوبال‌میر، فرایند برچسب‌گذاری روی آن‌ها انجام گرفت. در نهایت برچسب‌هایی با فرمت PNG تولید شد.

۲-۱-۳- مجموعه داده بهار

این مجموعه داده شامل مزارع کشاورزی در منطقه غرب استان همدان است. به‌منظور تهیه این مجموعه داده، تصویر ماهواره Sentinel-2 به قطعات کوچک‌تر ۲۲۴ در ۲۲۴ پیکسل تقسیم شد. از میان این تصاویر، پنج قطعه تصویر که شامل نمونه‌های هر دو کلاس بود انتخاب شد. سپس با استفاده از نرم‌افزار گلوبال‌میر فرایند برچسب‌گذاری روی آن‌ها انجام گرفت. در نهایت برچسب‌هایی با فرمت PNG تولید شد. این مجموعه داده به دلیل تعداد کم تصاویر، تنها برای تست مدل مورد استفاده قرار گرفت.

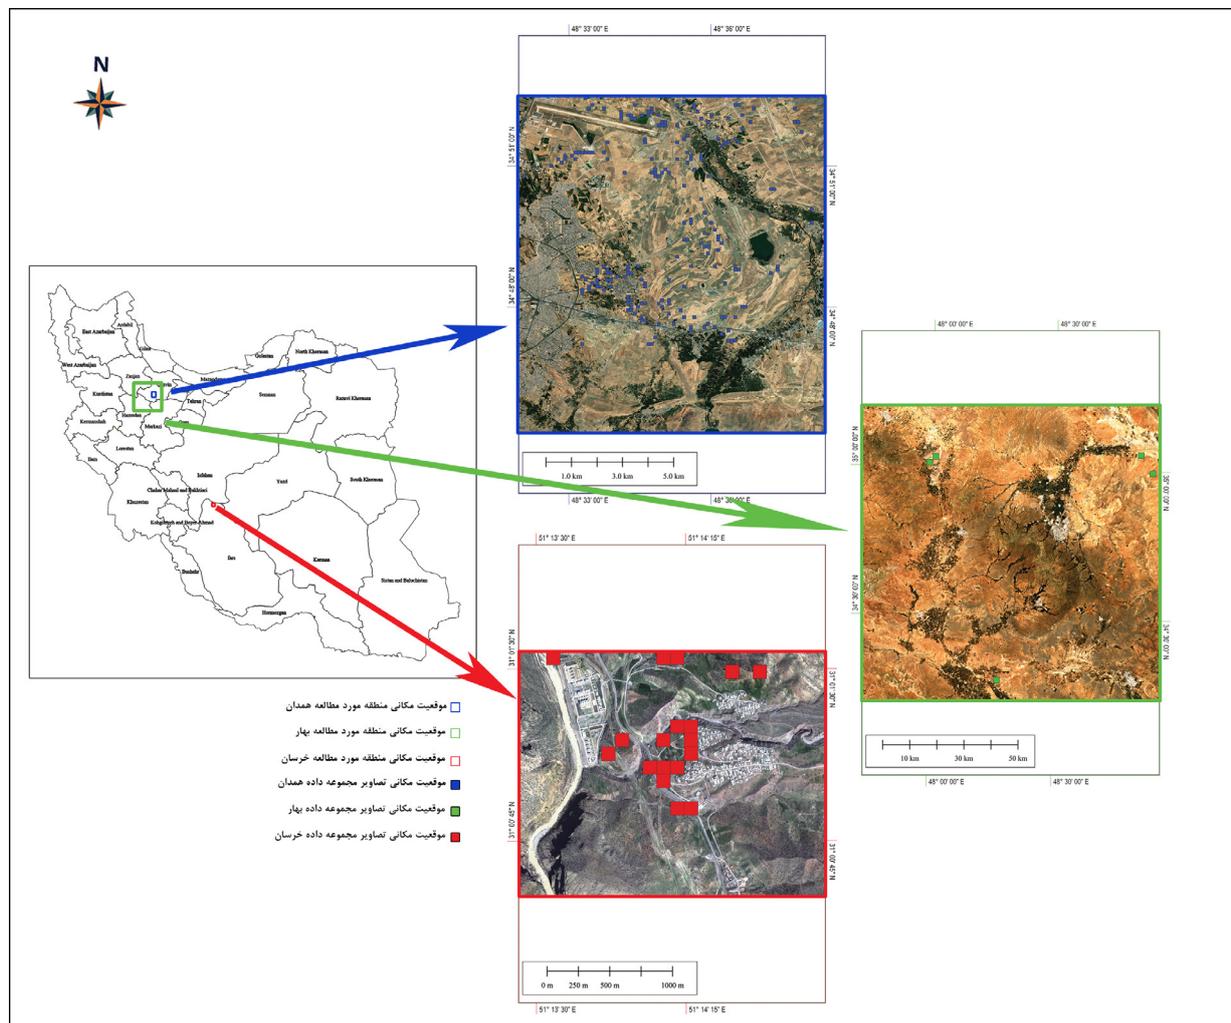
۲-۱-۴- مجموعه داده خرسان

خرسان روستایی از توابع بخش پاتاوه شهرستان دنا در استان کهگیلویه و بویراحمد است. جغرافیای این منطقه کوهستانی بوده و از دره‌های متعدد با رودخانه عبوری از میان آن‌ها تشکیل شده است. این منطقه به سبب داشتن بافت توپوگرافی و محصولات متفاوت با مجموعه داده Crop_Delineation کشور فرانسه، به منظور ارزیابی قابلیت

۲-۲- معماری‌ها و مفاهیم شبکه‌های عصبی به‌کار رفته

۲-۲-۱- مدل U-Net

مدل U-Net که یک معماری رمزگذار-رمزگشا است، در سال ۲۰۱۵ معرفی شد (Ronneberger, Fischer, & Brox, 2015). این مدل از زمان معرفی، در بسیاری از حوزه‌ها به صورت گسترده به کار گرفته شده است. مدل U-Net که در ابتدا برای تجزیه و تحلیل تصاویر پزشکی توسعه یافته است،



نگاره ۲: موقعیت مکانی مناطق مورد مطالعه و تصاویر مجموعه داده‌های تولید شده

ناپدید شدن گرادیان است (Azubaidi et al., 2021). معماری شبکه عصبی ResNet به‌عنوان یک رویکرد نوآورانه برای کاهش مشکلات ناشی از افزایش عمق شبکه‌های عصبی معرفی شده است. مدل ResNet با استفاده از واحدهای باقی‌مانده که اتصالات پرش نام دارند، این مشکل را حل می‌کند. اتصالات پرش، نقشه ویژگی استخراج شده در هر سطح بخش رمزگذار را به صورت مستقیم به همان سطح در بخش رمزگشا منتقل می‌کند. این روش اطلاعات معنایی که در اثر افزایش عمق و اعمال کانولوشن‌های متعدد از دست رفته است را در بخش بازبازی اطلاعات جبران می‌کند.

مشابه مدل‌های SegNet و ConvNet است. در تحقیقی که در زمینه قطعه‌بندی معنایی^۱ صورت گرفت، دقتی برابر با ۷۲/۷ درصد برای مدل گزارش شد که از عملکرد مدل‌های DeconvNet و SegNet، اندکی بهتر است (Zhang, Peng, Cheng, & Sun, 2018).

۲-۲-۲- معماری ResNet

مدل ResNet در اواخر سال ۲۰۱۵ معرفی شد. علت این نام‌گذاری وجود واحدهای باقی‌مانده در بلوک ساختمانی آن است. هدف از معرفی این مدل، مقابله با چالش

۳-۲-۲- معماری Efficientnet B0

است که انسان‌ها تمایلی به پردازش کل اطلاعات به صورت یک‌جا ندارند. در عوض، انسان‌ها تمایل دارند به طور انتخابی روی بخشی از اطلاعات در زمان و مکان مورد نیاز تمرکز کنند. اما در عین حال سایر اطلاعات قابل درک را نادیده می‌گیرند (Niu, Zhong, & Yu, 2021). مکانیسم Attention ابزاری قدرتمند در پردازش تصاویر سنجش از دور با شبکه‌های عصبی است. این مکانیسم به شبکه عصبی اجازه می‌دهد مانند نحوه توجه انسان به جنبه‌های خاص یک سوژه، بر بخش‌های دلخواه از داده ورودی تمرکز کند. اغلب تصاویر سنجش از دور، پیچیده و حاوی اطلاعات زیادی هستند. به طور کلی، مکانیسم Attention توانایی CNN‌ها را برای پردازش تصاویر سنجش از دور با تمرکز بر مرتبط‌ترین ویژگی‌ها و مناطق افزایش می‌دهد که منجر به عملکرد بهتر و نتایج دقیق‌تر خواهد شد.

چند ماه پس از معرفی معماری MobileNet، روش جدیدی برای تعریف معماری CNN یعنی مدل NASNet ابداع شد. در مدل NASNet، مانند شبکه عصبی تکرارشونده^۱، فضای جستجوی تعریف‌شده از بلوک‌های ساختمان CNN وجود دارد. این فضا توسط یک کنترل‌کننده، برای یافتن بهترین معماری شبکه که شبکه فرزند نامیده می‌شود، مورد استفاده قرار می‌گیرد. از همین فضای جستجو در اواخر سال ۲۰۱۹ برای ایجاد مدل پیشرفته EfficientNet استفاده شد (Tan & Le, 2019). از آنجایی که فضای جستجو بدون تغییر باقی مانده و قانون بهینه‌سازی نیز مشابه MnasNet بود، مدل پایه حاصل یعنی EfficientNet-B0، عملکردی مشابه MnasNet داشت. با این وجود، چیزی که موجب موفقیت EfficientNet می‌شود، رویکرد مقیاس‌بندی آن است (Hooser & Kuenzer, 2020).

۶-۲-۲- انتقال یادگیری

انتقال یادگیری یک تکنیک جدید است و اگر با شبکه‌های عصبی ترکیب شود، به بهبود عملکرد مدل کمک می‌کند. هدف انتقال یادگیری، بهبود عملکرد یادگیرندگان در حوزه‌های هدف، با انتقال دانش موجود در منبع متفاوت اما مرتبط است (Zhuang et al., 2021). انتقال یادگیری یک مفهوم گسترده است و به استفاده از یک مدل از پیش آموزش دیده برای یک مسئله جدید اشاره دارد. انتقال یادگیری به روش‌های متفاوتی پیاده‌سازی می‌شود. به‌عنوان مثال، یک مدل CNN که روی مجموعه داده‌ای بزرگ مانند ImageNet آموزش دیده است، می‌تواند برای مسائل جدید تشخیص اشیاء استفاده شود. در این روش، ابتدا لایه‌های شبکه پایه (لایه‌های بالایی)، ثابت نگه داشته شده و لایه‌های پایینی شبکه با مجموعه داده جدید، آموزش داده می‌شوند. سپس یک مرتبه همه لایه‌های شبکه عصبی با مجموعه داده جدید آموزش داده می‌شود. این روش به ویژه زمانی مفید است که داده‌های آموزشی برای مسئله مورد نظر محدود باشند. انتقال یادگیری چندمنطقه‌ای، به‌طور خاص یک روش دیگر انتقال یادگیری

۴-۲-۲- معماری VGG-19

معماری VGG19 دارای ۱۹ لایه وزن‌دار شامل ۱۶ لایه پیچشی و سه لایه تمام متصل^۲ است. ورودی آن تصویری سه کاناله با ابعاد 224×224 است (Lagunas & Garcés, 2018). این شبکه پایه در دسته معماری‌های Vintage جای می‌گیرد. طرح آن شامل پیچش‌ها با توابع غیر خطی و لایه‌های ادغام حداکثری است که پشت سرهم تکرار می‌شوند. به این ترتیب نقشه‌های ویژگی عمیق‌تر با تفکیک کمتر، ویژگی‌های تصویر ورودی را استخراج می‌کنند. پس از آن Head طبقه‌بندی‌کننده تمام متصل قرار دارد. این طبقه‌بندی‌کننده بر اساس ویژگی‌های استخراج‌شده، فرایند پیش‌بینی را انجام داده و احتمال هر کلاس ممکن را ارائه می‌کند. معماری VGG-19 نسبت به انواع مشابه خود، پیشرفت قابل توجهی در زمینه دقت داشت.

۵-۲-۲- مکانیسم Attention

Attention یک عملکرد شناختی پیچیده، مشابه عملکرد ادراکی انسان است. یکی از ویژگی‌های مهم ادراک این

1- Recurrent Neural Network

2- Fully Connected

به دلیل ناکافی بودن داده‌ها در مجموعه داده Delineation، ما به تقویت داده در این مجموعه نیاز داشتیم. از این رو با روش‌های مختلف ۳۰۰۰ داده به مجموعه داده Delineation اضافه کردیم. ما داده‌ها را به روش‌های مختلفی تقویت نمودیم. از جمله به روش‌های: افزودن روشنایی به تصاویر، افزودن نویز گاوسی به تصاویر و آینه کردن تصاویر.

۳-۲- جزئیات پیاده‌سازی

برای انجام این پژوهش نرم‌افزارهای مختلفی مورد استفاده قرار گرفته‌اند. از نرم‌افزار گلوبال‌مپر برای آماده‌سازی تصاویر، تقسیم آن‌ها به ابعاد مناسب و نیز ترسیم پلی‌گن‌های برچسب‌ها استفاده شده است. نرم‌افزار ادوبی فوتوشاپ برای یک‌پارچه‌سازی فرمت برچسب‌های متعلق به مجموعه داده‌های مختلف به کار رفته است. همچنین بسترهای Keras و Tensorflow مربوط به زبان برنامه‌نویسی پایتون در محیط آن‌اکنونا برای پیاده‌سازی الگوریتم‌های یادگیری عمیق استفاده شده‌اند.

به منظور پیاده‌سازی و آموزش شبکه‌های عصبی عمیق پیشنهادی، IDE آن‌اکنونا به دلیل قابلیت‌های فراوان در مدیریت کتابخانه‌ها، قابلیت استفاده از GPU و نیز سهولت در اجرا انتخاب شد. به این منظور کتابخانه‌هایی نظیر Keras و Tensorflow در محیط آن‌اکنونا نصب شده و تنظیمات لازم به منظور اجرای کدها روی سیستم صورت گرفت. مشخصات سیستم رایانه‌ای مورد استفاده در این پژوهش در جدول ۲ نشان داده شده است.

جدول ۲: مشخصات سیستم رایانه‌ای مورد استفاده

(CPU): i9-14900KF 3.20 GHz Core(TM) Intel(R)	واحد پردازنده مرکزی
(RAM): 32 BG	حافظه دسترسی تصادفی
(GPU): Nvidia GeForce RTX 4090 with 24 GB RAM	واحد پردازنده گرافیکی
1 TB SSD & 2 TB HDD	فضای ذخیره‌سازی

است. در این روش، مدل را با استفاده از مجموعه داده برچسب‌دار بزرگ موجود از یک منطقه (Dp) پیش‌آموزش داده و سپس با استفاده از مجموعه داده کوچک‌تر موجود از منطقه دیگر (Df) تنظیم می‌کنیم. در نهایت، مدل با استفاده از یک مجموعه داده کوچک از برچسب‌های موجود برای منطقه هدف (Dt) ارزیابی می‌شود. مجموعه داده تنظیم باید برخی از شباهت‌ها در ظاهر اشیاء با هر دو مجموعه داده پیش‌آموزش و توزیع داده هدف را به اشتراک بگذارد، و بنابراین می‌توان آن را به‌عنوان یک «پل» بین مجموعه داده‌های پیش‌آموزش و هدف تصور کرد.

انتقال یادگیری و تنظیم دقیق در کاربردهای مختلف یادگیری عمیق، به طورگسترده‌ای استفاده شده‌اند و به بهبود دقت و کارایی مدل‌ها کمک می‌کنند.

۳-۲- پیاده‌سازی و نتایج

۳-۱- آماده‌سازی داده‌ها

نرمال‌سازی، به فرآیند تبدیل مقادیر مختلف داده‌ها به یک دامنه مشخص یا مقیاس واحد اشاره دارد. این کار به ویژه در زمینه‌های داده‌کاوی ضروری است، زیرا بسیاری از الگوریتم‌ها و مدل‌ها نسبت به مقیاس و دامنه داده‌ها حساس هستند. پس از نرمال‌سازی، تأثیر مقادیر بزرگ‌تر بر روی نتایج مدل کاهش می‌یابد و تمامی ویژگی‌ها با یک وزن مشابه در فرآیند یادگیری مشارکت می‌کنند. پس از نرمال‌سازی، تمامی ویژگی‌ها بر روی یک مقیاس معین قرار می‌گیرند و این باعث می‌شود که مدل به طور یکنواخت به همه ویژگی‌ها توجه کند. نرمال‌سازی داده‌ها می‌تواند در شبکه‌های عصبی، سرعت همگرایی را افزایش دهد.

در این پژوهش، داده‌ها به روش Min-Max Normalization نرمال‌سازی شده است. رابطه (۱) نرمال‌سازی به روش Min-Max Normalization را نشان می‌دهد. این فرمول داده‌ها را به بازه [۰, ۱] می‌برد.

$$X_{new} = \frac{x^j - \min^j}{\max^j - \min^j}$$

رابطه (۱)

مجموعه داده‌های به کاررفته را نشان می‌دهد. همچنین در نگاره ۱ هشت سناریوی آزمایشی ذکر شده است.

۳-۴-۱- آموزش و تست بدون تنظیم دقیق

به دلیل تعداد کم تصاویر آموزشی برچسب‌گذاری شده، تصمیم بر آن شد که از شبکه‌های عصبی پیش‌آموزش داده شده در ترکیب با معماری U-Net استفاده شود. این شبکه‌های پیش‌آموزش داده شده روی مجموعه داده ImageNet که شامل حدود ۱۴ میلیون تصویر از ۱۰۰۰ کلاس متفاوت است آموزش دیده‌اند. از ترکیب معماری U-Net و شبکه‌های پایه پیش‌آموزش داده شده، پنج حالت معماری ترکیبی به وجود آمد. به منظور ارزیابی حساسیت نتایج به انتخاب شبکه پایه، این پنج حالت معماری در همه سناریوها مورد آزمایش قرار گرفت. این حالت‌ها در جدول ۳ نشان داده شده‌اند.

جدول ۳: پنج حالت معماری ترکیبی مورد استفاده در پژوهش

حالت معماری	ردیف
U-Net (Simple)	حالت اول
U-Net (ResNet 50 Backbone)	حالت دوم
U-Net (EfficientNetB0 Backbone)	حالت سوم
U-Net (Simple) + Attention Mechanism	حالت چهارم
U-Net (VGG19 Backbone) + Attention Mechanism	حالت پنجم

در هر سناریو، یکی از پنج حالت مدل‌های پیش‌آموزش دیده طبق جدول ۳ به‌عنوان شبکه پایه^۱ تعریف شد. در ابتدا وزن‌های لایه‌های شبکه پایه freeze شده و لایه‌های آخر شبکه با مجموعه داده آموزشی سناریوی موردنظر، آموزش داده شد. پس از این‌که مدل به دقت تقریبی ۵۰ درصد رسید، لایه‌های شبکه پایه، unfreeze شده و مجدداً کل شبکه، با همان مجموعه داده آموزش داده شد.

پارامترها و توابع استفاده شده در زمان یادگیری مدل، نرخ یادگیری 10^{-3} ، تابع هزینه Binary Cross-Entropy، تابع بهینه‌ساز Adam است. تعداد تکرار آموزش مدل برابر ۱۰۰ تنظیم شده است. اندازه دسته، از روش جستجوی حریصانه بین مقادیر ۱، ۲، ۴، ۸، ۱۶ و ۳۲ در جهت رسیدن به بالاترین دقت روی نمونه‌های ارزیابی، مقدار ۱۶ انتخاب شد. به‌منظور مقابله با مشکل بیش‌برازش مدل، تکنیک‌های Drop out و نیز L2 norm (regulization) مورد استفاده قرار گرفتند.

۳-۳- معیارهای ارزیابی

متداول‌ترین معیارهای ارزیابی در مسئله قطعه‌بندی تصاویر، میانگین اشتراک اتحادها (IOU) و معیار ضریب شباهت دایس (Dice Score) است. میانگین اشتراک اتحادها، از اشتراک داده‌های واقعیت زمینی با نتیجه پیش‌بینی شده بر اجتماع این دو محاسبه می‌شود. رابطه (۲) روش محاسبه میانگین اشتراک اتحادها را نشان می‌دهد.

$$IOU(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad \text{رابطه (۲)}$$

ضریب شباهت دایس، نتیجه پیش‌بینی شده را با داده‌های واقعیت زمینی مقایسه می‌کند. این شاخص نسبت بین ۲ برابر میزان هم‌پوشانی نتیجه پیش‌بینی شده مدل و داده‌های واقعیت زمینی به مجموع اندازه این دو را محاسبه می‌کند. رابطه (۳) روش محاسبه نمره دایس را نشان می‌دهد.

$$Dice(A, B) = \frac{2(A \cap B)}{|A| + |B|} \quad \text{رابطه (۳)}$$

به‌منظور ارزیابی دقیق‌تر نتایج، معیارهای F1 score، Accuracy و Recall score نیز محاسبه شده است.

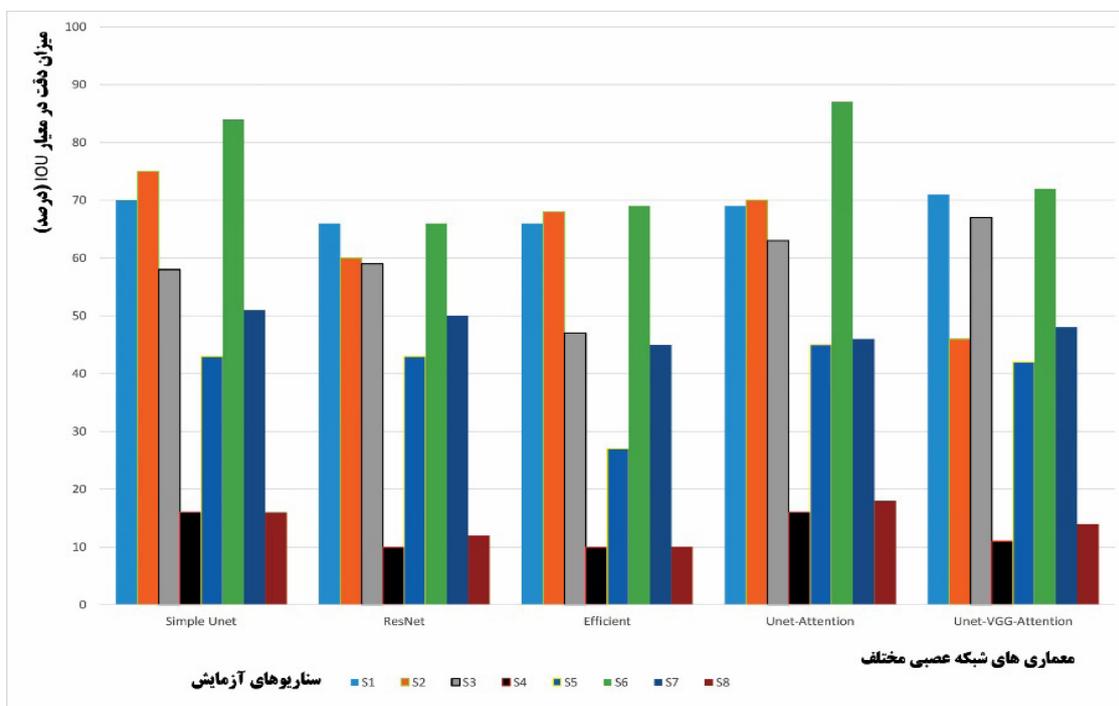
۳-۴- پیاده‌سازی روش‌ها

هشت سناریو با مجموعه داده‌های مختلف مورد آزمایش قرار گرفت. پنج مورد از آن‌ها بدون استفاده از تکنیک انتقال یادگیری و تنظیم دقیق، و سه مورد دیگر با به کارگیری تنظیم دقیق انجام شده‌اند. جدول ۱ نام و علامت اختصاری

۳-۴-۲- آموزش و تست با تنظیم دقیق

سه سناریو آموزش و تست با تنظیم دقیق، به منظور ارزیابی اثر انتقال یادگیری چندمنطقه‌ای طراحی و پیاده‌سازی شد. در هر سناریو مدل شبکه عصبی، با مجموعه داده وسیعی که حاشیه نویسی آنها موجود است و مجموعه داده مرجع (Dp) نام دارد، آموزش داده شده و مدل ذخیره شد. سپس مدل ذخیره شده مجدداً با مجموعه داده منطقه میانی (Df) آموزش دید و تنظیم دقیق شد. مدل نهایی برای انجام تست‌های مختلف روی مجموعه داده منطقه هدف (Dt) تولید شد. در این پژوهش مجموعه داده فرانسه به‌عنوان مجموعه داده مرجع و مجموعه داده سه منطقه همدان، بهار و خرسان به‌عنوان مجموعه داده میانی و هدف استفاده شده‌اند. با توجه به اینکه معیار شاخص در مسائل قطعه بندی تصویر، IoU است، در نگاره ۳ دقت عملکرد سناریوهای مختلف آزمایش بر اساس حالات معماری‌های مختلف شبکه عصبی در معیار IoU نشان داده شده است. همچنین به دلیل این‌که کلاس صفر در مجموعه داده‌های

تهیه شده در پژوهش حاضر به میزان کافی وجود ندارد، مقادیر FN و TN ماتریس خطا از اعتبار کمتری برخوردارند. بنابراین معیارهای ارزیابی که تابعی از این مقادیر هستند، دچار خطا خواهند شد. تقریباً در تمامی حالات معماری، سناریوی ششم در معیار IoU عملکرد بهتری از سایرین دارد. نتایج کمی سناریوهای آزمایش شده، براساس حالات معماری‌های شبکه عصبی مختلف در جدول ۴ نشان داده شده است. در هر معیار ارزیابی، بهترین نتایج به صورت پررنگ علامت‌گذاری شده‌اند. پنج حالت معماری در سناریوی اول مورد آزمایش قرار گرفته‌اند. حالت معماری سوم به دلیل نتایج مشابه با حالت معماری دوم، از آزمایشات بعدی کنار گذاشته شده است. در سناریوی سوم، حالت معماری پنجم به دلیل عملکرد مشابه با حالت معماری چهارم در نتایج ذکر نشده است. در سناریوی چهارم به دلیل ضعیف بودن و تشابه نتایج، بهترین حالت یعنی نتیجه حالت معماری پنجم قرار داده شده است. در سناریوی پنجم مانند سناریوی سوم، حالت معماری پنجم به دلیل عملکرد



نگاره ۳: نمودار دقت عملکرد سناریوهای مختلف بر اساس معماری‌های مختلف شبکه عصبی در معیار IoU

جدول ۴: نتایج کمی سناریوهای متفاوت آزمایش بر اساس حالات معماری‌های شبکه عصبی مختلف

معیارهای ارزیابی					حالات معماری مختلف	سناریو
F1 score	Recall score	Accuracy	IoU	DiceScore		
0.84	0.87	0.83	0.71	0.81	U-Net (Simple)	S1
0.79	0.77	0.78	0.66	0.76	U-Net (ResNet 50 Backbone)	
0.79	0.78	0.79	0.66	0.76	U-Net (EfficientNetB0 Backbone)	
0.84	0.85	0.83	0.71	0.82	U-Net (Simple) + Attention Mechanism	
0.83	0.88	0.81	0.71	0.80	U-Net (VGG19 Backbone) + Attention Mechanism	
0.89	0.93	0.84	0.68	0.86	U-Net (Simple)	S2
0.86	0.92	0.80	0.60	0.81	U-Net (ResNet 50 Backbone)	
0.90	0.95	0.86	0.70	0.88	U-Net (Simple) + Attention Mechanism	
0.73	0.60	0.70	0.58	0.71	U-Net (VGG19 Backbone) + Attention Mechanism	
0.87	0.85	0.80	0.58	0.84	U-Net (Simple)	S3
0.86	0.92	0.79	0.59	0.76	U-Net (ResNet 50 Backbone)	
0.84	0.92	0.76	0.73	0.81	U-Net (Simple) + Attention Mechanism	
0.27	0.86	0.18	0.16	0.24	U-Net (VGG19 Backbone) + Attention Mechanism	S4
0.69	0.84	0.65	0.48	0.59	U-Net (Simple)	S5
0.66	0.82	0.61	0.43	0.64	U-Net (ResNet 50 Backbone)	
0.71	0.82	0.69	0.55	0.70	U-Net (Simple) + Attention Mechanism	
0.91	0.93	0.88	0.84	0.89	U-Net (Simple)	S6
0.88	0.89	0.82	0.66	0.85	U-Net (ResNet 50 Backbone)	
0.93	0.90	0.88	0.87	0.92	U-Net (Simple) + Attention Mechanism	
0.84	0.89	0.73	0.72	0.81	U-Net (VGG19 Backbone) + Attention Mechanism	
0.61	0.52	0.70	0.51	0.58	U-Net (Simple)	S7
0.51	0.36	0.71	0.50	0.41	U-Net (ResNet 50 Backbone)	
0.71	0.72	0.74	0.59	0.70	U-Net (Simple) + Attention Mechanism	
0.23	0.58	0.30	0.18	0.20	U-Net (VGG19 Backbone) + Attention Mechanism	

داده نشدند. می‌توان نتیجه گرفت برای دستیابی مدل به دقت مطلوب، استفاده از تصاویر با قدرت تفکیک مکانی کافی ضروری است.

در سناریوی دوم، آموزش و تست مدل روی مجموعه داده همدان انجام شد. در این سناریو، معماری حالت چهارم بالاترین دقت را نشان داد. تعداد بسیار کم نمونه‌های آموزشی سبب شده است که استفاده از شبکه‌های پایه و تنظیم دقیق به روش شرح داده شده، بی‌تأثیر باشد.

در سناریوی سوم، آموزش روی مجموعه داده فرانسه و تست روی مجموعه داده همدان صورت گرفت. در این سناریو تعداد تصاویر آموزشی نسبت به سناریوی دوم افزایش پیدا نمود. در نتیجه دقت عملکرد مدل در حالت

مشابه با حالت معماری چهارم در نتایج ذکر نشده است. در سناریوی ششم، حالت معماری چهارم بهترین عملکرد را دارد. در سناریوی هفتم، حالت معماری چهارم خوب عمل کرده است. در سناریوی هشتم مانند سناریوی چهارم، به دلیل تشابه نتایج، بهترین حالت یعنی نتیجه حالت معماری پنجم قرار داده شده است.

۴- اعتبارسنجی و مقایسه نتایج

در سناریوی اول، آموزش و تست مدل روی مجموعه داده فرانسه با قدرت تفکیک مکانی ۱۰ متر انجام شد. در نتیجه زمین‌های با وسعت کم، که تشخیص آن‌ها نیازمند وجود تصاویر با قدرت تفکیک مکانی زیاد است، خوب تشخیص

در سناریوی ششم، آموزش روی مجموعه داده فرانسه با تفکیک مکانی ده‌متری انجام شد. سپس روی تصاویر ۳۰ سانتی‌متری همدان تنظیم دقیق صورت گرفت و در نهایت روی تصاویر همدان تست انجام شد. بهترین عملکرد در این سناریو مربوط به حالت معماری چهارم بود. سناریوی ششم همان سناریوی سوم است، تنها تنظیم دقیق روی مجموعه داده همدان به آن اضافه شده است. دقت تشخیص سناریوی ششم در حالت معماری چهارم به ۰/۸۷ رسید و نسبت به سناریوی سوم ۰/۱۴ افزایش داشت. این مسئله نشان می‌دهد تنظیم دقیق در افزایش دقت مدل، مؤثر است. همچنین بیان‌گر این است که قدرت تفکیک مکانی تصاویر با عملکرد مدل، رابطه‌ای مستقیم دارد. تصاویر ماهواره‌ای با قدرت تفکیک مکانی کم، به صورت رایگان و به سادگی قابل تهیه هستند. اما تصاویر با قدرت تفکیک مکانی زیاد، با پرداخت هزینه، و با دشواری بیشتری تهیه می‌شوند. بنابراین می‌توان تصاویر رایگان و دارای قدرت تفکیک مکانی کم را به صورت فراوان تهیه نمود و با استفاده از آن‌ها مدل‌ها را آموزش داد. سپس با به کارگیری تکنیک انتقال یادگیری، مدل‌ها را روی تصاویر دارای قدرت تفکیک مکانی زیاد که به دشواری تهیه شده‌اند و تعداد آن‌ها کم است تنظیم دقیق نمود. در نهایت با مدل به دست آمده، مرز زمین‌های موجود در تصاویر دارای تفکیک مکانی زیاد را استخراج نمود و به نتایج مطلوبی دست یافت. به این ترتیب در هزینه‌ها صرفه‌جویی شده و داده‌های رایگان و عمومی ارزش افزوده پیدا خواهند نمود.

در سناریوی هفتم، آموزش روی مجموعه داده فرانسه، تنظیم دقیق روی مجموعه داده همدان و تست روی مجموعه داده خراسان انجام شد. سناریوی هفتم نسبت به سناریوی پنجم که بدون تنظیم دقیق انجام شده است، بهبود عملکرد نشان داد. دقت تشخیص این سناریو نسبت به سناریوی پنجم در معیار IOU در حالت معماری چهارم ۰/۰۴ افزایش داشت. این موضوع تأثیر مثبت تنظیم دقیق را مجدداً آشکار نمود. اما همچنان دقت تشخیص در این سناریو، کاملاً

معماری چهارم به میزان ۰/۰۳ در معیار IOU نسبت به سناریوی دوم افزایش یافت. قدرت تفکیک مکانی مجموعه داده آموزشی این سناریو ۱۰ متر و قدرت تفکیک مکانی مجموعه داده تست آن ۰/۳ متر بود. نمای کلی زمین‌های کشاورزی در این دو قدرت تفکیک متفاوت است. بنابراین مدل نتوانسته با ویژگی‌هایی که از تصاویر با قدرت تفکیک مکانی کم آموخته، زمین‌های موجود در تصاویر با قدرت تفکیک مکانی زیاد را به صورت مطلوب تشخیص دهد.

در سناریوی چهارم، آموزش روی مجموعه داده فرانسه و تست روی مجموعه داده بهار صورت گرفت. دقت مدل در سناریوی چهارم مطلوب نیست. تفاوت عمده سناریوی سوم و چهارم، در قدرت تفکیک مکانی تصاویر تست است. این موضوع نشان می‌دهد برای رسیدن به نتایج مطلوب، می‌بایست تصاویر تست به اندازه کافی از قدرت تفکیک مکانی برخوردار باشند.

در سناریوی پنجم، آموزش روی مجموعه داده فرانسه و تست روی مجموعه داده خراسان انجام شد. در این سناریو نسبت به سناریوی سوم، دقت حالت معماری اول ۰/۱۰ و حالت معماری چهارم ۰/۱۸ در معیار IOU کاهش یافت. مجموعه داده آموزشی سناریوهای سوم و پنجم یکی است. همچنین قدرت تفکیک مکانی تصاویر تست آن‌ها نیز مشابه است. این کاهش دقت به دلیل تفاوت در توپوگرافی منطقه و وسعت و شکل زمین‌های کشاورزی در مناطق فرانسه و خراسان است. در تمامی مجموعه داده‌ها کلاس یک به زمین‌های کشاورزی و کلاس صفر به پس‌زمینه تعلق دارد. مجموعه داده فرانسه مربوط به منطقه‌ای هموار با زمین‌های منظم است. اما خراسان منطقه‌ای کوهستانی است و زمین‌های آن وسعت کمتر و اشکال نامنظمی دارند. کلاس یک در این دو مجموعه داده با هم متفاوت است. این تفاوت در کلاس صفر بیشتر هم می‌شود. به همین دلیل کلاس یک نسبت به کلاس صفر، اندکی بهتر تشخیص داده شده است.

کافی، در تهیه سه مجموعه داده همدان، بهار و خراسان این ملاحظات به صورت صددرصد رعایت نشده است. این مسئله طبیعتاً مقداری خطا به مسئله اضافه نموده و از دقت می‌کاهد. هدف از تهیه و استفاده از این مجموعه داده‌ها، بررسی اثر تنظیم دقیق و نیز قابلیت تعمیم مدل روی مناطق متنوع است. با این‌که با این مجموعه داده‌ها نمی‌توان به نتایج چشم‌گیر دست یافت، اما به خوبی می‌توان با استفاده از آن‌ها، تأثیر تنظیم دقیق را مشاهده نمود.

نگاره ۴ نتایج کیفی نمونه‌ای از آزمایش‌های انجام شده بر روی هر یک از دیتاست‌ها را نشان می‌دهد. مطابق با نتایج کمی، این نمونه‌ها نشان می‌دهند که انتقال یادگیری چندمنطقه‌ای، تنظیم مدل بر روی دیتاست Df و سپس آزمایش مدل بر روی دیتاست هدف، سبب بهبود نتایج قطعه‌بندی تصاویر هدف شده است.

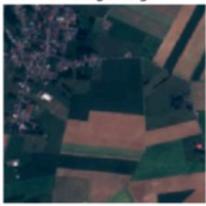
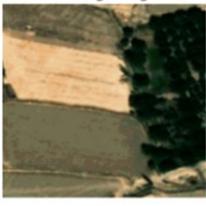
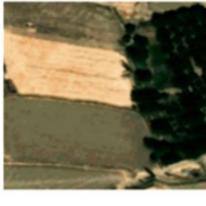
با وجود دقت قابل قبول مدل‌های پیشنهادی و اثربخشی تکنیک انتقال یادگیری چندمنطقه‌ای در بسیاری از موارد، نتایج به‌دست‌آمده نشان می‌دهد که مدل در دو سناریو ۴ و ۸، با شکست مواجه شده است. نمونه‌ای از این موارد شکست در نگاره ۵ نمایش داده شده است. در این حالت مدل به دلیل تفاوت‌های شدید توپولوژیکی میان نواحی آموزشی و آزمون، و نیز کیفیت پایین‌تر تصاویر آزمون از نظر قدرت تفکیک مکانی، نتوانسته است زمین‌های کشاورزی را به‌درستی شناسایی کند. در این موارد، ناهمگونی شدید در ساختار فضایی و هندسی زمین‌ها موجب کاهش قابلیت تعمیم مدل شده است. این موضوع نشان می‌دهد که در شرایطی با تفاوت‌های بنیادین میان مناطق منبع و هدف، حتی روش‌های مبتنی بر انتقال یادگیری نیز نیازمند راهکارهای تطبیقی پیشرفته‌تری برای حفظ دقت هستند.

مطلوب نبود. یکی از دلایل این مسئله، تفاوت در شکل زمین‌ها و توپوگرافی مناطق فرانسه و خراسان است. می‌توان نتیجه گرفت مدل‌های موجود برای استفاده در مناطق با توپولوژی مختلف، قابلیت تعمیم مناسبی ندارند.

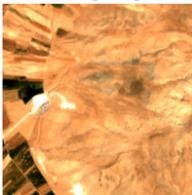
در سناریوی هشتم، مدل روی مجموعه داده فرانسه آموزش دیده و روی مجموعه داده همدان تنظیم دقیق شد. در نهایت تست روی مجموعه داده بهار انجام شد. در سناریوی هشتم دقت کلی مطلوب نبود. یکی از دلایل آن قدرت تفکیک مکانی بسیار کم مجموعه داده تست است. در سناریوی هشتم نسبت به سناریوی چهارم که همین سناریو بدون تنظیم دقیق است، اندکی بهبود در عملکرد مشاهده شد. این موضوع نشان‌دهنده رابطه مستقیم تنظیم دقیق با دقت مدل است. در سناریوی دوم حالت معماری اول یعنی مدل U-Net (Simple) عملکرد بهتری از حالت معماری پنجم داشت که از مکانیسم Attention نیز برخوردار بود. دلیل آن این است که مجموعه داده همدان تنها ۲۰۰ تصویر دارد. اما معماری حالت پنجم حدود ۳۶ میلیون پارامتر دارد. مدلی با این تعداد پارامتر را نمی‌توان با ۲۰۰ تصویر به درستی آموزش داد. همچنین مجموعه داده همدان به منطقه‌ای تعلق دارد که کلاس یک یعنی زمین‌های کشت شده از کلاس صفر بیشتر است. به عبارت دیگر این مجموعه داده متوازن نیست. از طرف دیگر این مجموعه داده به صورت تفسیر بصری ترسیم شده و ممکن است در محل‌هایی مرز نازک‌تر و یا ضخیم‌تر از میزان واقعی در نظر گرفته شده باشد که این مسئله نیز بر نتایج تأثیرگذار است. بنابراین با وجود این‌که معماری حالت پنجم قوی است و روی مجموعه داده فرانسه با حدود ۲۰۰۰ عدد تصویر عملکرد خوبی دارد، اما روی مجموعه داده همدان ضعیف عمل نموده است. این عملکرد ضعیف در مورد کلاس صفر، یعنی پس‌زمینه مشهودتر است. تهیه مجموعه داده حاشیه‌نویسی تصاویر مستلزم رعایت استانداردهای لازم است. اعمال نظر حداقل پنج کارشناس خبره و تحقیقات میدانی منطقه مورد مطالعه در این زمینه ضروری است. به دلیل نبود وقت و امکانات

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (سیر)

استخراج مرز زمین‌های کشاورزی از تصاویر ماهواره‌ای با یادگیری عمیق و ... / ۲۳

Scenario	Best_Model	Output image		
S1	VGG_Attention_unet	<p>Testing Image</p> 	<p>Ground_truth</p> 	<p>Prediction on test image</p> 
S3	Attention U-net	<p>Testing Image</p> 	<p>Testing Label</p> 	<p>Prediction on test image</p> 
S6	Attention U-net	<p>Testing Image</p> 	<p>Testing Label</p> 	<p>Prediction on test image</p> 
S5	Attention U-net	<p>Testing Image</p> 	<p>Ground_truth</p> 	<p>Prediction on test image</p> 
S7	Attention U-net	<p>Testing Image</p> 	<p>Ground_truth</p> 	<p>Prediction on test image</p> 

نگاره ۴: نتایج کیفی سناریوهای آزمایشی شاخص

Scenario	Best_Model	Output image		
S4	VGG_Attention_unet			
S8	VGG_Attention_unet			

نگاره ۵: نتایج کیفی سناریوهای آزمایشی شکست

۵- نتیجه گیری و پیشنهادات

در شرایط مختلف فراهم کرد. به طور خلاصه، این پژوهش نشان داد که ترکیب یادگیری عمیق، انتقال یادگیری و مکانیزم توجه، یک رویکرد مؤثر برای استخراج خودکار و دقیق مرز زمین‌های کشاورزی در مناطق هدف است که در آن‌ها با کمبود داده‌های آموزشی مناسب مواجه هستیم. این روش می‌تواند در ایجاد پایگاه‌های اطلاعات زمین‌های کشاورزی، تخمین میزان مصرف آب و برداشت محصول، و هدایت خودکار ماشین‌آلات کشاورزی نقش مهمی ایفا کند. دسترسی به مجموعه داده مناسب، اساس بهره‌گیری از هوش مصنوعی و یادگیری عمیق است. از جمله ویژگی‌های مجموعه داده‌های مربوط به سنجش از دور، می‌توان به تعداد تصاویر، قدرت تفکیک مکانی و طیفی آن‌ها، پراکنش جغرافیایی و تنوع عوارض موجود در تصاویر اشاره نمود. پیشنهاد می‌شود با رعایت استانداردهای مربوطه، مجموعه داده‌هایی پرتعداد با قدرت تفکیک مکانی مختلف تهیه شود. از نظر قدرت تفکیک طیفی، می‌توان برای تولید مجموعه داده، علاوه بر تصاویر مرئی سه‌باندی، از تصاویر چندطیفی استفاده نمود. در این راستا کاربرد شاخص‌های

این پژوهش با هدف استخراج خودکار و دقیق مرز زمین‌های کشاورزی با استفاده از روش‌های سنجش از دوری و الگوریتم‌های یادگیری عمیق انجام شد. هشت سناریو (پنج مورد از آن‌ها بدون استفاده از تکنیک انتقال یادگیری و تنظیم دقیق، و سه مورد دیگر با به کارگیری تنظیم دقیق) مورد آزمایش و بررسی قرار گرفت. به منظور ارزیابی حساسیت نتایج به انتخاب شبکه پایه، پنج حالت مدل‌های پیش‌آموزش دیده به‌عنوان شبکه پایه تعریف شد و در همه سناریوها مورد آزمایش قرار گرفت. نتایج نشان داد که استفاده از تکنیک انتقال یادگیری با انتقال دانش از مجموعه داده دسترسی آزاد فرانسه در کنار مجموعه داده‌های همدان، بهار و خرسان، امکان آموزش مؤثر شبکه‌های عصبی را فراهم ساخت. تنظیم دقیق شبکه‌های پیش‌آموزش داده شده نیز به انطباق بهتر مدل با ویژگی‌های خاص داده‌های محلی کمک کرد و منجر به افزایش قابل توجه دقت شد. مکانیزم توجه با تمرکز بر نواحی مهم تصویر در ترکیب با معماری‌های مختلف شبکه‌های عصبی، امکان استخراج دقیق‌تر مرزها را

Observation Data: A Review-Part I: Evolution and Recent Trends. *Remote Sensing*, 12(10). doi:10.3390/rs12101667

8- Krizhevsky, A., Sutskever, I., & Hinton, G. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems*, 25. doi:10.1145/3065386

9- Lagunas, M., & Garces, E. (2018). Transfer Learning for Illustration Classification.

10- Li, X., Xu, X., Yang, R., & Pu, F. (2020, 26 Sept.-2 Oct. 2020). DBC: Deep Boundaries Combination for Farmland Boundary Detection Based on UAV Imagery. Paper presented at the IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium.

11- Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation.

12- Masoud, K. M., Persello, C., & Tolpekin, V. A. (2020). Delineation of Agricultural Field Boundaries from Sentinel-2 Images Using a Novel Super-Resolution Contour Detector Based on Fully Convolutional Networks. *Remote Sensing*, 12(1). doi:10.3390/rs12010059

13- Niu, Z., Zhong, G., & Yu, H. (2021). A review on the attention mechanism of deep learning. *Neurocomputing*, 452, 48-62. doi:https://doi.org/10.1016/j.neucom.2021.03.091

14- Persello, C., Tolpekin, V. A., Bergado, J. R., & de By, R. A. (2019). Delineation of agricultural fields in smallholder farms from satellite images using fully convolutional networks and combinatorial grouping. *Remote Sensing of Environment*, 231, 111253. doi:https://doi.org/10.1016/j.rse.2019.111253

15- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14). doi:10.3390/rs12142291

16- Richards, J. (2022). Remote Sensing Digital Image Analysis.

17- Ronneberger, O., Fischer, P., & Brox, T. (2015, 2015//). U-Net: Convolutional Networks for Biomedical Image Segmentation. Paper presented at the Medical

گیاهی مختلف، می‌تواند به آموزش بهتر مدل و شناخت زمین‌های کشاورزی از بافت پس‌زمینه، کمک شایانی نماید. نکته دیگر تولید مجموعه داده برای مناطق جغرافیایی مختلف، وضعیت‌های توپوگرافی متنوع و اشکال زمین‌های کشاورزی متفاوت است. این کار به‌منظور طراحی مدل‌هایی با قابلیت تعمیم بیشتر، ضروری است. درگام بعدی به منظور تکمیل اهداف این پژوهش، ادغام روش‌های استخراج مرز با روش‌های شناسایی نوع محصولات پیشنهاد می‌شود. همچنین تحقیق و توسعه روی طراحی معماری‌های مختلف شبکه عصبی، می‌تواند به پیدایش مدل‌های جدیدی بیانجامد که با هزینه محاسباتی کمتر، عملکرد بهتری داشته باشند.

تعارض منافع

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

References

- 1- Al-Wassai, F., & Kalyankar, N. (2013). Major Limitations of Satellite images.
- 2- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., . . . Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. doi:10.1186/s40537-021-00444-8
- 3- Arnold, L., Rebecchi, S., Chevallier, S., & Paugam-Moisy, H. (2011). *An Introduction to Deep Learning* (Vol. 1).
- 4- Chollet, F. (2017). *Deep learning with python*. New York, NY: Manning Publications. www.github.com
- 5- Haton, J.-P. (2006). *A brief introduction to artificial intelligence* (Vol. 39).
- 6- Hoeser, T., Bachofer, F., & Kuenzer, C. (2020). Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review—Part II: Applications. *Remote Sensing*, 12(18). doi:10.3390/rs12183053
- 7- Hoeser, T., & Kuenzer, C. (2020). Object Detection and Image Segmentation with Deep Learning on Earth

Image Computing and Computer-Assisted Intervention – MICCAI 2015, Cham.

18- Sefercik, U. G., Alkan, M., Atalay, C., Jacobsen, K., Büyüksalih, G., & Karakiş, S. (2020). Optimizing the Achievable Information Content Extraction from WorldView-4 Stereo Imagery. PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science, 88(6), 449-461. doi:10.1007/s41064-020-00127-8

19- Sun, R., Lei, T., Chen, Q., Wang, Z., Du, X., Zhao, W., & Nandi, A. (2022). Survey of Image Edge Detection. Frontiers in Signal Processing, 2, 826967. doi:10.3389/frsip.2022.826967

20- Tan, M., & Le, Q. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks.

21- Wang, X., Shu, L., Han, R., Yang, F., Gordon, T., Wang, X., & Xu, H. (2023). A Survey of Farmland Boundary Extraction Technology Based on Remote Sensing Images. Electronics, 12(5). doi:10.3390/electronics12051156

22- Watkins, B., & van Niekerk, A. (2019). A comparison of object-based image analysis approaches for field boundary delineation using multi-temporal Sentinel-2 imagery. Computers and Electronics in Agriculture, 158, 294-302. doi:https://doi.org/10.1016/j.compag.2019.02.009

23- Zhang, Z., Zhang, X., Peng, C., Cheng, D., & Sun, J. (2018). ExFuse: Enhancing Feature Fusion for Semantic Segmentation.

24- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., . . . He, Q. (2021). A Comprehensive Survey on Transfer Learning. Proceedings of the IEEE, 109(1), 43-76. doi:10.1109/JPROC.2020.3004555

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/)

