Journal of Remote Sensing and GIS Applications in Environmental Sciences
rsgi.tabrizu.ac.ir

Classification of Agricultural Crops Using the Ensemble Structure of Machine learning Models and Time Series of Remote Sensing Data

Mohammad Javad Valadan Zouj[1], **Esmaiel Abdalli**[2]✉

1. Corresponding Author, Full Professor, Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics, Khajeh Nasiraddin Toosi University of Technology, Tehran, Iran. E-mail: valadanzouj@kntu.ac.ir
2. Master's student, Department of Photogrammetry and Remote Sensing, Faculty of Geodesy and Geomatics, Khajeh Nasiraddin Toosi University of Technology, Tehran, Iran. E-mail: e.abdalli@email.kntu.ac.ir

Article Info

Article type:
Research Article

Article history:
Received: 21 May 2025
Revised: 9 July 2025
Accepted: 7 June 2026
Published: 7 June 2026

Keywords:
Remote sensing,
Machine learning,
classification,
Ensemble models.

ABSTRACT

Effective identification of crop types is fundamental for safeguarding food security. In this context, satellite-based remote sensing (RS) data has emerged as a promising tool, offering wide spatial coverage and high temporal frequency. However, due to the significant intra- and inter-class variability among crop types, there remains a growing need for more precise classification methods using RS data. This study proposes a novel supervised parallel-cascaded architecture (Ensemble models) targeting seven crop classes. The parallel component consists of five independent branches, each generating probability maps for different target classes using multi-temporal Sentinel-1 and Landsat-8/9 imagery. These maps were produced through various machine learning and deep learning classification models. Subsequently, the generated probability maps from the parallel branches were stacked and used as a new feature set fed into a meta-model in the cascaded structure. The results demonstrated that the Convolutional Neural Network (CNN) algorithm achieved superior performance in both parallel and cascaded components, making it the optimal choice for both the base and meta models. The proposed architecture achieved an overall accuracy (OA) of 94.79% and a Kappa coefficient of 0.937. These results highlight the significant advantage of the parallel-cascaded structure over conventional classification methods that simply stack RS data and feed it into a single model leading to a 6% increase in overall accuracy. Future research could use higher-resolution distance assessments and more accurate synthetic hybrid models.

Cite this article: Valadan zouj, M.J. & Abdalli, E. (2026). Classification of Agricultural Crops Using the Ensemble Structure of Machine learning Models and Time Series of Remote Sensing Data. *Journal of Remote Sensing and GIS Applications in Environmental Sciences*, 6 (20), 1-22. http//doi.org/10.22034/rsgi.2026.67397.1139

© The Author(s).
Publisher: University of Tabriz.
DOI: http//doi.org/10.22034/rsgi.2026.67397.1139

Journal of Remote Sensing and GIS Applications in Environmental Sciences
rsgi.tabrizu.ac.ir

Introduction

Climate change and human activities have caused significant changes in the spatial distribution of agricultural crops. Accurate and timely mapping of agricultural crops is essential for food security, optimal farm management, and sustainable development goals. Remote sensing (RS) data have emerged as an efficient alternative to traditional methods such as field monitoring because they offer wide spatial coverage, high temporal frequency, and diverse spatial resolution. These data are divided into two categories: multispectral (MS) and synthetic aperture radar (SAR). In this study, a combination of Sentinel-1 (SAR), Sentinel-2 (MS), and Landsat 8/9 (MS) satellite data was used to improve crop classification accuracy. Accurate mapping of agricultural crops using RS data is a challenging task due to the high intra- and inter-class variability caused by crop diversity. To address this challenge, machine learning and supervised deep learning algorithms were used in this study. However, it is important to remember that some machine learning models used in this approach may perform better than others, leading to serious uncertainty. Hence, in this paper, a new structure called the parallel-cascade structure is used.

Data and Proposed Method

Study Area: Agricultural lands of Mahabad city in northwest Iran, with a variety of crops such as wheat, corn, beet, onion and alfalfa and orchard.

Utilized datasets:

- Satellite Data: Sentinel-1 (SAR), Sentinel-2 (MS) and Landsat 8/9 (MS) multi-temporal images
- Ground Reality Data (GT): collected through field surveys in 2023, including 345 training polygons.

Proposed method:

1. Data preprocessing: cloud removal, generation of monthly composites and sampling at 30 m resolution.
2. Parallel structure: using five feature collections (FC) including spectral bands and vegetation indices (NDVI, NDWI, NDBI, EVI, SAVI) and VV and VH bands of Sentinel-1 satellite as input to machine learning models.
3. Base model selection: evaluating CNN, RF and SVM models in each branch of the parallel structure with 5-fold cross-validation.
4. Cascade structure: combining the output probability maps from the parallel structure and evaluating CNN, RF and SVM models for final classification.

Discussion and Results

- The base model selection: CNN performed best in all branches (OA = 81-76%). Selecting the best machine learning model in each branch of the parallel structure reduces any negative impact of low-performing models when combined in the cascade section.
- In terms of overall accuracy and kappa coefficient, branches based on vegetation indices performed better than branches based on spectral bands as well as VV and VH bands from Sentinel-1.
- The meta model selection: CNN outperformed RF and SVM models with OA = 91.43% and Kappa = 0.901 and was selected as the meta model.
- The effect of data fusion: The simultaneous use of SAR and MS data improved the accuracy compared to three-source, two-source and one-source methods, respectively.
- Once again, the feature set based on vegetation indices outperformed Sentinel-1 over spectral bands and VV and VH bands.
- Parallel-cascade model and its comparison with the conventional method: The conventional method consists of stacking spectral bands and vegetation indices and VV and VH bands. The proposed method, which is the result of stacking the probability maps of each branch, showed 6% higher overall

accuracy (OA) than the feature stacking method. The superior performance of the proposed set structure can be attributed to several reasons, which are explained below. First, the parallel part consisted of five parallel branches, each corresponding to a specific FC. These parallel branches produce PMs for each target class and provide a multi-view representation of the data. Second, the classifier in the cascade structure directly identifies the target classes from the output probability maps produced by the parallel part. Third, the meta-model in the cascade structure used the collective knowledge of the parallel branches in the parallel structure to make the final classification decision.

- Uncertainty reduction: The output probability maps of the proposed method had a significant difference between the first and second maximum values. So that the Skewness values obtained from the histogram of the conventional structure and the proposed structure were equal to 0.22 and 1.81 respectively.
- From the viewpoints of producer accuracy (UA) and user accuracy (PA), the proposed method generally outperformed the conventional method, and achieved the highest improvement in the onion class, 10.96 and 8 percent, respectively.

Conclusion

This study proposes a machine learning-based parallel-cascade hybrid method for classifying agricultural crops using multi-source satellite data from Sentinel-1, Sentinel-2, and Landsat8/9. The proposed method outperforms conventional methods with an accuracy of 91.43% and, by reducing the uncertainty in classification, enables the production of accurate crop maps at different scales. This approach can be used as an effective solution for crop monitoring and agricultural management.

Keywords: Remote sensing, machine learning, supervised classification, ensemble model

References

Alizadeh, N., Maghsoudi, Y., Managhebi, T., & Azadnejad, S. (2024). Collapse Hotspot Detection in Urban Area Using Sentinel-1 and TerraSAR-X Dataset with SBAS and PSI Techniques. *Land (2012)*, 13(12).

Alizadeh, N., Mahdianpari, M., Hemmati, E., & Marjani ,M. (2025). FusionFireNet: A CNN-LSTM model for short-term wildfire hotspot prediction utilizing spatio-temporal datasets. *Remote Sensing Applications: Society and Environment*, 37, 101436.

Asam, S., Gessner, U., Almengor González, R., Wenzl, M., Kriese ,J., & Kuenzer, C. (2022). Mapping crop types of Germany by combining temporal statistical metrics of Sentinel-1 and Sentinel-2 time series with LPIS data. *Remote sensing*, 14(13), 298.

Asgari, S., & Hasanlou, M. (2023). A Comparative Study of Machine Learning Classifiers for Crop Type Mapping Using Vegetation Indices. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10, 79-85.

Blickensdörfer, L., Schwieder, M., Pflugmacher, D., Nendel, C., Erasmi, S., & Hostert, P. (2022). Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany. *Remote Sensing of Environment*, 269, 112831.

Cheng, G., Ding, H., Yang, J., & Cheng, Y. (2023). Crop type classification with combined spectral, texture, and radar features of time-series Sentinel-1 and Sentinel-2 data. *International Journal of Remote Sensing*, 44(4), 1215-1237.

Eimanifar, A., & Mohebbi, F. (2007). Urmia Lake (northwest Iran): a brief review. *Saline systems*, 5, 3(1). Erdanaev, E., Kappas, M., & Wyss, D. (2022). Irrigated crop types mapping in Tashkent province of Uzbekistan with remote sensing-based classification methods. *Sensors*, 22(15), 5683.

Feng, S., Zhao, J., Liu, T., Zhang, H., Zhang, Z., & Guo, X. (2019). Crop type identification and mapping using machine learning algorithms and sentinel-2 time series data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(9), 3295-3306.

Hemmati, E., & Sahebi, M. R. (2024). Surface soil moisture retrieval based on transfer learning using SAR data on a local scale. *International Journal of Remote Sensing*, 45(7), 2374-2406.

Hu, J., Chen, Y., Cai, Z., Wei, H., Zhang, X., Zhou, W., Wang, C., You, L., & Xu, B. (2023). Mapping diverse paddy rice cropping patterns in South China using harmonized Landsat and Sentinel-2 data. *Remote sensing*, 15(4), 1034.

Hu, Y., Zeng, H., Tian, F., Zhang, M., Wu, B., Gilliams, S., Li, S., Li, Y., Lu, Y., & Yang, H. (2022). An interannual transfer learning approach for crop classification in the Hetao Irrigation district, China. *Remote sensing*, 14(5), 1208.

Ibrahim, E. S., Rufin, P., Nill, L., Kamali, B., Nendel, C., & Hostert, P. (2021). Mapping crop types and cropping systems in Nigeria with Sentinel-2 imagery. *Remote sensing*, 13(17), 3523.

Jafarzadeh, H., Mahdianpari, M., Gill, E., Mohammadimanesh, F., & Homayouni, S. (2021). Bagging and boosting ensemble classifiers for classification of multispectral, hyperspectral and PolSAR data: a comparative evaluation. *Remote sensing*, 13(21), 4405.

Kadri, N., Jebari, S., Augusseau, X., Mahdhi, N., Lestrelin, G., & Berndtsson, R. (2023). Analysis of four decades of land use and land cover change in semiarid Tunisia using Google Earth engine. *Remote Sensing*, 15(13), 3257.

Karimi, N., Sheshangosht, S., & Eftekhari, M. (2022). Crop type detection using an object-based classification method and multi-temporal Landsat satellite images. *Paddy and Water Environment*, 20(3), 395-412.

Kobayashi, N., Tani, H., Wang, X & ,.Sonobe, R. (2020). Crop classification using spectral indices derived from Sentinel-2A imagery. *Journal of Information and Telecommunication*, 4(1), 67-90.

Komura, N., Matsumoto, K., Igari, S., Ogawa, T., Fujita, S., & Nakamoto, K. (2023). Computer aided process planning for rough machining based on machine learning with certainty evaluation of inferred results. *International Journal of Automation Technology*, 17(2), 120-127.

Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782.

Kwak, G.-H., Park, C.-w., Lee, K.-d., Na, S.-i., Ahn, H.-y., & Park, N.-W. (2021). Potential of hybrid CNN-RF model for early crop mapping with limited input data. *Remote sensing*, 13(9), 1629.

Lin, C., Zhong, L., Song, X.-P., Dong, J., Lobell, D. B., & Jin, Z. (2022). Early-and in-season crop type mapping without current-year ground truth: Generating labels from historical information via a topology-based approach. *Remote Sensing of Environment*, 274, 112994.

Liu, X., Hu, G., Chen, Y., Li, X., Xu, X., Li, S., Pei, F., & Wang, S. (2018). High-resolution multi-temporal mapping of global urban land using Landsat images based on the Google Earth Engine Platform. *Remote Sensing of Environment*, 209, 227-239.

Liu, X., Xie, S., Yang, J., Sun, L., Liu, L., Zhang, Q., & Yang, C. (2023). Comparisons between temporal statistical metrics, time series stacks and phenological features derived from NASA Harmonized Landsat Sentinel-2 data for crop type mapping. *Computers and Electronics in Agriculture*, 211, 108015.

Luo, K., Lu, L., Xie, Y., Chen, F., Yin, F., & Li, Q. (2023). Crop type mapping in the central part of the North China Plain using Sentinel-2 time series and machine learning. *Computers and Electronics in Agriculture*, 205, 107577.

Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817.

Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., & Reiche, J. (2021). Sentinel-1 sar backscatter analysis ready data preparation in google earth engine. *Remote Sensing*, 13(10), 1954.

Nabil, M., Farg, E., Arafat, S. M., Aboelghar, M., Afify, N. M., & Elsharkawy, M. M. (2022). Tree-fruits crop type mapping from Sentinel-1 and Sentinel-2 data integration in Egypt's New Delta project. *Remote Sensing Applications: Society and Environment*, 27, 100776.

Ofori-Ampofo, S., Pelletier, C., & Lang, S. (2021). Crop type mapping from optical and radar time series using attention-based deep learning. *Remote sensing*, 13(22), 4668.

Panjala, P., Gumma, M. K., & Teluguntla, P. (2022). Machine learning approaches and sentinel-2 data in crop type mapping. *Data science in agriculture and natural resource management*, 161-180.

Phinzi, K., Abriha, D., & Szabó, S. (2021). Classification efficacy using k-fold cross-validation and bootstrapping resampling techniques on the example of mapping complex gully systems. *Remote sensing*, 13(15), 2980.

Pott, L. P., Amado, T. J. C., Schwalbert, R. A., Corassa, G.M., & Ciampitti, I.A. (2022). Crop type classification in Southern Brazil: Integrating remote sensing, crop modeling and machine learning. *Computers and Electronics in Agriculture*, 201, 107320.

Rahman, M. M., & Robson, A. (2020). Integrating landsat-8 and sentinel-2 time series data for yield prediction of sugarcane crops at the block level. *Remote sensing*, 12(8), 1313.

Soltani, M., Rahmani, O., Ghasimi, D. S., Ghaderpour, Y., Pour, A. B., Misnan, S. H., & Ngah, I. (2020). Impact of household demographic characteristics on energy conservation and carbon dioxide emission: Case from Mahabad city, Iran. *Energy*, 194, 116916.

Song, X.-P., Huang, W., Hansen, M. C., & Potapov, P. (2021). An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping. *Science of Remote Sensing*, 3, 100018.

Stournaras, S., Loukatos, D ,.Arvanitis, K. G., & Kalatzis, N. (2022). Crop identification by machine learning algorithm and sentinel-2 data. *Chemistry Proceedings*, 10(1), 20.

Sun, C., Bian, Y., Zhou, T., & Pan, J. (2019). Using of multi-source and multi-temporal remote sensing data improves crop-type mapping in the subtropical agriculture region. *Sensors*, 19(10), 2401.

Sun, L., Chen, J., Guo, S., Deng, X., & Han, Y. (2020). Integration of time series sentinel-1 and sentinel-2 imagery for crop type mapping over oasis agricultural areas. *Remote sensing*, 12(1), 158.

Tariq, A., Yan, J., Gagnon, A. S., Riaz Khan, M., & Mumtaz, F. (2023). Mapping of cropland, cropping patterns and crop types by combining optical remote sensing images with decision tree classifier and random forest. *Geo-Spatial Information Science*, 26(3), 302-320.

Topaloğlu, R. H., Sertel, E., & Musaoğlu, N. (2016). Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover/use mapping. *The International archives of the photogrammetry, remote sensing and spatial information sciences*, 41, 1055-1059.

Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Floury, N., & Brown, M. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9-24.

Tufail, R., Ahmad, A., Javed, M. A., & Ahmad, S. R. (2022). A machine learning approach for accurate crop type mapping using combined SAR and optical time series data. *Advances in Space Research*, 69(1), 331-346.

Wei, P., Ye, H., Qiao, S., Liu, R., Nie, C., Zhang, B., Song, L., & Huang, S. (2023). Early crop mapping based on Sentinel-2 time-series data and the random forest algorithm. *Remote sensing*, 15(13), 3212.

Woźniak, E., Rybicki, M., Kofman, W., Aleksandrowicz, S., Wojtkowski, C., Lewiński, S ,.Bojanowski, J., Musiał, J., Milewski, T., & Slesiński, P. (2022). Multi-temporal phenological indices derived from time series Sentinel-1 images to country-wide crop classification. *International Journal of Applied Earth Observation and Geoinformation*, 107, 102683.

Xiang, J., Liu, J., Chen, D., Xiong, Q., & Deng, C. (2023). CTFuseNet: A multi-scale CNN-transformer feature fused network for crop type segmentation on UAV remote sensing imagery. *Remote sensing*, 15(4), 1151 .

Xu, D., & Zhang, M. (2022). Mapping paddy rice using an adaptive stacking algorithm and Sentinel-1/2 images based on Google Earth Engine. *Remote Sensing Letters*, 13(4), 373-382.

Zhang, B., Wu, Y., Zhao, B., Chanussot, J., Hong, D., Yao, J., & Gao, L. (2022). Progress and challenges in intelligent remote sensing satellite systems. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 1814-1822.

Zhang, C., Di, L., Lin, L., Li, H., Guo, L., Yang, Z., Yu, E. G., Di, Y., & Yang, A. (2022). Towards automation of in-season crop type mapping using spatiotemporal crop information and remote sensing data. *Agricultural Systems*, 201, 103462.

Zhang, J., He, Y., Yuan, L., Liu, P., Zhou, X., & Huang, Y. (2019). Machine learning-based spectral library for crop classification and status monitoring. *Agronomy*, 9(9), 496.

Zhang, P., Hu, S., Li, W., Zhang, C., & Cheng, P. (2021). Improving parcel-level mapping of smallholder crops from vhsr imagery: An ensemble machine-learning-based framework. *Remote sensing*, *13*(11), 2146.

Zhang, Y., Liu, J., & Shen, W. (2022). A review of ensemble learning algorithms used in remote sensing applications. *Applied Sciences*, 12(17), 8654.

نشریه کاربرد سنجش از دور و سیستم اطلاعات جغرافیایی در علوم محیطی
rsgi.tabrizu.ac.ir

طبقه‌بندی نوع محصولات کشاورزی با استفاده از ساختار جمعی مدل‌های یادگیری ماشین و سری زمانی داده‌های سنجش از دور (اراضی کشاورزی بالادست شهر مهاباد)

محمدجواد ولدان زوج[1]✉، اسماعیل عبدالی[2]

۱. نویسنده مسئول، استاد تمام، گروه فوتوگرامتری و سنجش از دور، دانشکده ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران. رایانامه: valadanzouj@kntu.ac.ir

۲. دانشجوی کارشناسی ارشد، گروه فوتوگرامتری و سنجش از دور، دانشکده ژئودزی و ژئوماتیک ، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران. رایانامه: e.abdalli@email.kntu.ac.ir

اطلاعات مقاله

نوع مقاله:
مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۰۲/۳۱
تاریخ بازنگری: ۱۴۰۴/۰۴/۱۸
تاریخ پذیرش: ۱۴۰۵/۰۳/۱۷
تاریخ انتشار: ۱۴۰۵/۰۳/۱۷

کلیدواژه‌ها:
سنجش از دور،
یادگیری ماشین،
طبقه بندی،
مدل جمعی.

چکیده

نقشه‌برداری دقیق از انواع محصولات کشاورزی نقش حیاتی در تضمین امنیت غذایی ایفا می‌کند. در این راستا، داده‌های ماهواره‌ای سنجش از دور (RS) به عنوان ابزاری نویدبخش مطرح شده‌اند که قادر به ارائه پوشش فضایی گسترده و بازه‌های زمانی مکرر هستند. با این حال، به دلیل تنوع بالا بین انواع محصولات، هنوز چالش‌هایی در زمینه طبقه‌بندی دقیق نوع محصول با استفاده از این داده‌ها وجود دارد. در این مطالعه، یک ساختار نوآورانه به‌صورت ترکیبی از معماری موازی و آبشاری (مدل جمعی) به صورت نظارت‌شده پیشنهاد شده است که هفت محصول کشاورزی را هدف قرار می‌دهد. بخش موازی شامل پنج شاخه مجزاست که هر یک با استفاده از تصاویر چندزمانی Sentinel-1/2 و Landsat-8/9، نقشه‌های احتمال تعلق پیکسل به طبقه مورد نظر را برای طبقات مختلف تولید می‌کنند. این نقشه‌ها با بهره‌گیری از الگوریتم‌های یادگیری ماشین و یادگیری عمیق تولید می‌شوند. در گام بعد، نقشه‌های احتمال حاصل از شاخه‌های موازی با یکدیگر ترکیب و به عنوان مجموعه ویژگی جدید به مدل متا در ساختار آبشاری وارد شدند. نتایج نشان داد که الگوریتم شبکه عصبی CNN در هر دو بخش موازی و آبشاری عملکرد برتری نسبت به سایر الگوریتم‌ها داشته و به عنوان مدل پایه و مدل متا انتخاب شده است. ساختار پیشنهادی با دقت کلی (Overall Accuracy) ۹۴/۷۹ درصد و ضریب کاپا (Kappa index) معادل ۰/۹۳۷ دقت مطلوبی را نشان داد. این نتایج نشان‌دهنده برتری قابل توجه ساختار موازی–آبشاری نسبت به روش‌های مرسوم طبقه‌بندی است که صرفاً داده‌های سنجش از دور را ادغام کرده و به یک مدل واحد وارد می‌کنند؛ به‌طوری‌که مدل پیشنهادی موجب افزایش شش درصدی در دقت کلی شده است. در تحقیقات آینده می‌توان با استفاده از داده‌های سنجش از دوری با قدرت تفیک بالاتر و مدل‌های ترکیبی هوش مصنوعی به دقت بالاتر نیز رسید.

استناد: ولدان زوج، محمدجواد و عبدالی، اسماعیل (۱۴۰۵). طبقه‌بندی نوع محصولات کشاورزی با استفاده از ساختار جمعی مدل‌های یادگیری ماشین و سری زمانی داده‌های سنجش از دور (اراضی کشاورزی بالادست شهر مهاباد). *کاربرد سنجش از دور و سیستم اطلاعات جغرافیایی در علوم محیطی*، ۶ (۲۰)، ۱–۲۲.
http//doi.org/10.22034/rsgi.2026.67397.1139

ناشر: دانشگاه تبریز.
© نویسندگان.

مقدمه

تغییرات قابل توجهی در توزیع فضایی محصولات کشاورزی به دلیل تأثیرات ترکیبی تغییرات آب و هوا و فعالیت‌های انسانی رخ داده است، به طوری که این تغییرات در سطح جهانی، ملی و منطقه‌ای مشاهده می‌شود. به همین دلیل، اهمیت بسیاری به نقشه‌برداری دقیق و به موقع انواع محصولات کشاورزی داده می‌شود (C. Zhang et al., 2022)؛ زیرا این موضوع برای تضمین امنیت غذایی، مدیریت بهینه مزارع کشاورزی و دستیابی به اهداف توسعه پایدار اساسی است. علاوه بر این، نقشه‌های انواع محصولات کشاورزی ورودی‌های ارزشمندی برای مدل‌های زیست‌محیطی فراهم می‌کنند، تا بتوان پاسخ‌های کشاورزی نسبت به عوامل زیست‌محیطی را بررسی کرد (Lin et al., 2022). برخلاف روش‌های سنتی مانند نظارت‌های مزرعه‌ای که زمان‌بر و نیازمند زحمت هستند، داده‌های ماهواره‌ای سنجش از دوری (RS) به عنوان یک ابزار پیشنهادی در نقشه‌برداری انواع محصولات کشاورزی ظاهر شده‌اند که پوشش مکانی گسترده، تکراری، فرکانس زمانی بالا و وضوح مکانی متنوع را فراهم می‌کنند (Ibrahim et al., 2021).

داده‌های ماهواره‌ای سنجش از دوری را می‌توان به دو دسته اصلی تقسیم کرد: داده‌های نوری (Optic) و داده‌های رادار (Radar) با روزنه مصنوعی (SAR) (Alizadeh et al., 2024; B. Zhang et al., 2022). بسیاری از روش‌های نقشه‌برداری انواع محصولات کشاورزی به طور اصلی بر داده‌های نوری به دلیل توانایی بالای آن‌ها در ضبط ویژگی‌های طیفی محصولات و پیگیری فنولوژی گیاهان تکیه کرده‌اند (Ofori-Ampofo et al., 2021; Tariq et al., 2023). منابع داده‌های نوری که به طور گسترده استفاده می‌شوند شامل MODIS (Song et al., 2021)، سری Landsat (L) (به ویژه L۴، ۵، ۸، و ۹) (Karimi et al., 2022; Song et al., 2021; C. Zhang et al., 2022) و Sentinel-2 (S۲) می‌شوند (B. Zhang et al., 2022). از سوی دیگر، برخی از مطالعات تنها بر داده‌های SAR برای نقشه‌برداری انواع محصولات کشاورزی تمرکز کرده‌اند که Sentinel-1 (S۱) به عنوان یکی از پراستفاده‌ترین‌ها به دلیل دسترسی عمومی آن شناخته شده است (Song et al., 2021). دلیل این موضوع آن است که داده‌های SAR امکان ارائه داده در شرایط آب و هوایی و نوری متنوع را دارند (Cheng et al., 2023). علاوه بر این، سیگنال بازتابی SAR حساس به پارامترهای سطحی مانند رطوبت محصولات (Hemmati & Sahebi, 2024)، ساختار فیزیکی محصولات، شرایط خاک و زبری سطح است (B. Zhang et al., 2022). لازم به ذکر است که در پژوهش‌های پیشین، اغلب از داده‌های چند زمانه نوری یا SAR برای پوشش یک سال زراعی کامل کشت استفاده شده است (Ofori-Ampofo et al., 2021). این روش، درک جامع‌تری از تغییرات فنولوژیکی در طول فصل رشد گیاهان را فراهم می‌کند که منجر به شناسایی دقیق‌تر انواع مختلف محصولات کشاورزی می‌شود.

در طبقه‌بندی محصولات کشاورزی، رویکردهای هماهنگ که از منابع مختلف داده‌های نوری استفاده می‌کنند، دقت کلی بالاتری را نسبت به رویکردهای تک‌منبعی نشان داده‌اند. دلیل این امر این است که ماهواره‌های داده‌های نوری وضوح‌های زمانی مختلفی دارند که اطلاعات فنولوژیکی بهبود یافته‌ای را فراهم می‌کنند و بنابراین منجر به افزایش دقت طبقه‌بندی می‌شوند (Hu et al., 2023; Song et al., 2021). ترکیب رایج‌ترین داده‌های نوری شامل استفاده همزمان از S۲ و L۸/۹ به دلیل ویژگی‌های مشابه آن‌ها می‌باشد . علاوه بر این، اضافه کردن تصاویر S۱ به همراه داده‌های نوری در مدل‌های طبقه‌بندی، قابلیت افزایش دقت نقشه‌برداری محصولات کشاورزی را دارد (Nabil et al., 2022). همان‌طور که اشاره شد، داده‌های SAR ویژگی‌های فیزیکی و ساختاری محصولات کشاورزی را ضبط می‌کنند که اطلاعات طیفی حاصل از حسگرهای نوری را تکمیل می‌کنند. در این زمینه، محققان به طور معمول از ترکیب S۱ ، S۲ و L۸ استفاده کرده‌اند (Asam et al., 2022). با این حال، تعداد محدودی مطالعه وجود دارد که انواع محصولات کشاورزی را با استفاده از ترکیب چند منبعی داده‌های چند زمانه S۱/۲ و L۸/۹ طبقه‌بندی کرده‌اند، که در این مطالعه از این رویکرد استفاده می‌شود (Sun et al., 2019).

توسعه رویکردهای چندزمانه و چندمنبعی در سنجش از دور نیازمند روش‌هایی است که بتوانند به‌طور مؤثر حجم بالای داده‌ها

را پردازش و تحلیل کنند. در این راستا، زبان برنامه‌نویسی پایتون به عنوان یکی از ابزارهای کلیدی شناخته می‌شود، چرا که با کتابخانه‌های قدرتمندی مانند GDAL، Rasterio، NumPy، Pandas و Scikit-learn، امکان پردازش، تحلیل و مدل‌سازی داده‌های مکانی و زمانی را فراهم می‌کند (Stournaras et al., 2022). پایتون در کاربردهایی نظیر طبقه‌بندی پوشش زمین، تحلیل تغییرات زمانی، مدل‌سازی پدیده‌های محیطی و توسعه الگوریتم‌های یادگیری ماشین برای تحلیل‌های پیشرفته سنجش از دور به‌طور گسترده مورد استفاده قرار گرفته است. یکی از مزایای اصلی پایتون، انعطاف‌پذیری بالا و توانایی ادغام آسان با سایر پلتفرم‌ها و API ها از جمله Sentinel Hub است که باعث می‌شود پژوهشگران بتوانند رویکردهای نوآورانه‌تری را برای تحلیل‌های دقیق‌تر و نزدیک به زمان واقعی توسعه دهند (Stournaras et al., 2022; Sun et al., 2019).

نقشه‌برداری دقیق انواع محصولات کشاورزی با استفاده از داده‌های سنجش از دور به دلیل تنوع بالای داخل و بین طبقاتی که ناشی از تنوع محصولات، شرایط زیست محیطی و روش‌های کشاورزی می‌باشد، یک امر چالش‌برانگیز است. برای حل این چالش، بیشتر مقالات از الگوریتم‌های طبقه‌بندی یادگیری ماشین نظارت شده مبتنی بر پیکسل استفاده کردند که توانایی حل ارتباطات غیرخطی در داده‌ها را دارند (Pott et al., 2022). بخش قابل توجهی از ادبیات در این زمینه بر روی یک طبقه‌بندی تکی برای پیش‌بینی طبقه هدف تمرکز می‌کند. مدل‌های یادگیری ماشین مورد استفاده معمولا شامل ماشین‌های بردار پشتیبان (SVM) (Erdanaev et al., 2022)، جنگل تصادفی (RF) (Wei et al., 2023)، و شبکه‌های عصبی مصنوعی (ANN) (Luo et al., 2023) است. با این حال، برخی از محققان ساختار تجمعی از مدل‌های یادگیری ماشین را پیشنهاد دادند که از اطلاعات تکمیلی از طبقه‌بندهای مختلف بهره برده و برای حل چالش‌های فوق الذکر و دستیابی به سطوح دقت بهبود یافته استفاده کرده‌اند (Zhang et al., 2021).

این ساختارهای تجمعی پیشنهادی می‌توانند به دو دسته ساختارهای موازی و آبشاری تقسیم شوند. در ساختارهای موازی، چندین شاخه وجود دارد، هرکدام شامل یک مدل یادگیری ماشین است (Tufail et al., 2022; Zhang et al., 2021). برای پیش‌بینی طبقه نهایی یک نمونه، پیش‌بینی‌ها از هر مدل یادگیری ماشین با استفاده از تکنیک‌های ساده مانند رأی اکثریت ترکیب می‌شوند. در ادبیات موجود، ساختارهای موازی اصولاً در سطح مدل یا سطح داده‌های آموزش پیاده‌سازی شده‌اند (Y. Zhang et al., 2022). در سطح مدل، مدل‌های یادگیری ماشین در انواع شاخه‌ها متفاوت هستند، اما دادهٔ ورودی برای هر مدل پایه در هر شاخه یکسان است. با این حال، مهم است به یاد داشت که برخی از مدل‌های یادگیری ماشین مورد استفاده در این رویکرد ممکن است بهتر از دیگران عمل کنند که منجر به عدم قطعیت جدی می‌شود زمانی که آن‌ها در ساختار موازی ترکیب می‌شوند (Tufail et al., 2022; Y. Zhang et al., 2022). محققان قبلی ساختار موازی را در سطح داده ورودی در نظر نگرفتند، که در آن نه تنها کل داده‌های آموزشی در هر شاخه استفاده می‌شود، بلکه ترکیبی از منابع داده‌های مختلف سنجش از دور نیز می‌تواند دقت طبقه‌بندی را افزایش دهد (Sun et al., 2019).

در پژوهش‌های پیشین مرور شده، ساختار موازی بر روی تکنیک‌های ساده مانند رأی اکثریت برای پیش‌بینی طبقه یک نمونه اعتماد می‌کرد (Erdanaev et al., 2022; Tariq et al., 2023). با این حال، این رویکردهای ساده هنگام مقابله با وظایف طبقه‌بندی پیچیده با چالش‌هایی روبه‌رو می‌شوند. برای حل این مسئله، از ساختار آبشاری استفاده می‌شود، جایی که خروجی‌های ساختار موازی به صورت نقشه‌های احتمال که بیانگر احتمال تعلق پیکسل به طبقات مختلف است، به طور مستقیم توسط یک مدل دیگر تحت عنوان مدل متا استفاده می‌شود. از آنجا که مدل متا خود یک مدل یادگیری ماشین است، فرایند انتخاب ویژگی برای افزایش دقت نهایی بسیار حائز اهمیت است (Y. Zhang et al., 2022). در پژوهش حاضر، یک چارچوب مجموعه جدید، یعنی یک ساختار جمعی موازی برای نقشه‌برداری نوع محصول با کل روش توسعه و پیاده سازی در Python پیشنهاد شده است. در چارچوب پیشنهادی، خروجی‌های یک ساختار موازی در سطح داده‌های ورودی، در ساختار آبشاری توسط یک متا مدل استفاده می‌شوند. مدل‌های یادگیری ماشین مانند RF و SVM و مدل یادگیری عمیق CNN (Xiang et al., 2023)، در روش پیشنهادی مورد استفاده قرار گرفتند. پژوهش حاضر در منطقه مهاباد به دلیل چالش‌های مرتبط با طبقه‌بندی

دقیق انواع محصولات کشاورزی و بهبود نقشه‌برداری آن‌ها انجام می‌شود. این منطقه، واقع در استان آذربایجان غربی در شمال غرب ایران، دارای تنوع بالایی از محصولات کشاورزی است، و طبقه‌بندی صحیح آن‌ها از طریق داده‌های ماهواره‌ای اهمیت بالایی در مدیریت منابع طبیعی، بهینه‌سازی کشاورزی و برنامه‌ریزی منطقه‌ای دارد. روش پیشنهادی از منابع مختلف تصاویر ماهواره‌ای برای نقشه‌برداری از انواع مختلف محصولات در در این منطقه استفاده می‌کند. هدف اصلی این پژوهش، توسعه و ارزیابی یک چارچوب نوآورانه مبتنی بر مدل‌های یادگیری ماشین و یادگیری عمیق با ساختار موازی–آبشاری است که با بهره‌گیری هم‌زمان از داده‌های ماهواره‌ای چندمنبعی (تصاویر نوری و SAR) و اطلاعات واقعیت زمینی حاصل از بررسی‌های میدانی، دقت طبقه‌بندی انواع محصولات زراعی را در منطقه مهاباد، ایران بهبود می‌بخشد. این چارچوب همچنین با روش متداول طبقه‌بندی مورد مقایسه قرار گرفته تا اثربخشی آن به‌صورت کمی تحلیل شود.

منطقه مورد مطالعه و داده‌ها

در این بخش به معرفی منطقه مورد مطالعه و منابع داده‌ای استفاده شده شامل تصاویر ماهواره‌ای RS و داده‌های GT پرداخته شد.

منطقه مورد مطالعه

در این پژوهش، اراضی کشاورزی بالادست شهر مهاباد برای ارزیابی روش پیشنهادی انتخاب شدند. منطقه مورد مطالعه در شمال غرب ایران واقع شده و در جنوب شهر ارومیه در یک دشت حاصلخیز با متوسط ارتفاع تقریبی ۱۴۰۰ متر از سطح دریا قرار دارد (شکل ۱). دمای میانگین سالانه و بارندگی این منطقه به ترتیب ۱۲ درجه سانتیگراد و ۳۹۰ میلی‌متر است (Soltani et al., 2020). با توجه به جمعیتی که در مناطق اطراف منطقه مورد مطالعه زندگی می‌کنند، حدود ۲۰۰،۰۰۰ نفر تحت تأثیر محصولات کشاورزی این منطقه قرار دارند. به علاوه، اراضی کشاورزی این منطقه بر پویایی آب دریاچه ارومیه تأثیر دارند و به خشک شدن تدریجی آن منجر می‌شوند (Eimanifar & Mohebbi, 2007). مناطق اصلی اطراف این منطقه توسط صخره‌ها و کوهستان‌ها پوشانده شده‌اند. بیشتر اراضی کشاورزی در نواحی مرکزی قرار دارند، در حالی که مناطق اطراف، به‌طور عمده با اراضی بایر و مناطق شهری مرتبط هستند. بنابراین، درون این منطقه، یک سیستم اکولوژی متنوع وجود دارد که شامل اراضی کشاورزی با انواع محصولات مختلف، خاک‌های خالی و مناطق شهری است. محصولات کشاورزی مختلفی در این منطقه کشت می‌شوند که شامل محصولات پاییزی و بهاری هستند. گندم محصول اصلی پاییزی است، در حالی که چغندر، یونجه، ذرت و پیاز محصولات اصلی بهاری هستند. به علاوه، اراضی گلخانه‌های گسترده سیب در این منطقه وجود دارد. طبق تقویم کشاورزی، کشت محصولات پاییزی از اواسط آبان آغاز می‌شود، در حالی که برداشت محصولات بهاری تا اوایل آذر ادامه دارد. بنابراین، سال کشاورزی در این منطقه از آبان سال قبل تا آذر سال بعد است.

داده‌های مورد استفاده

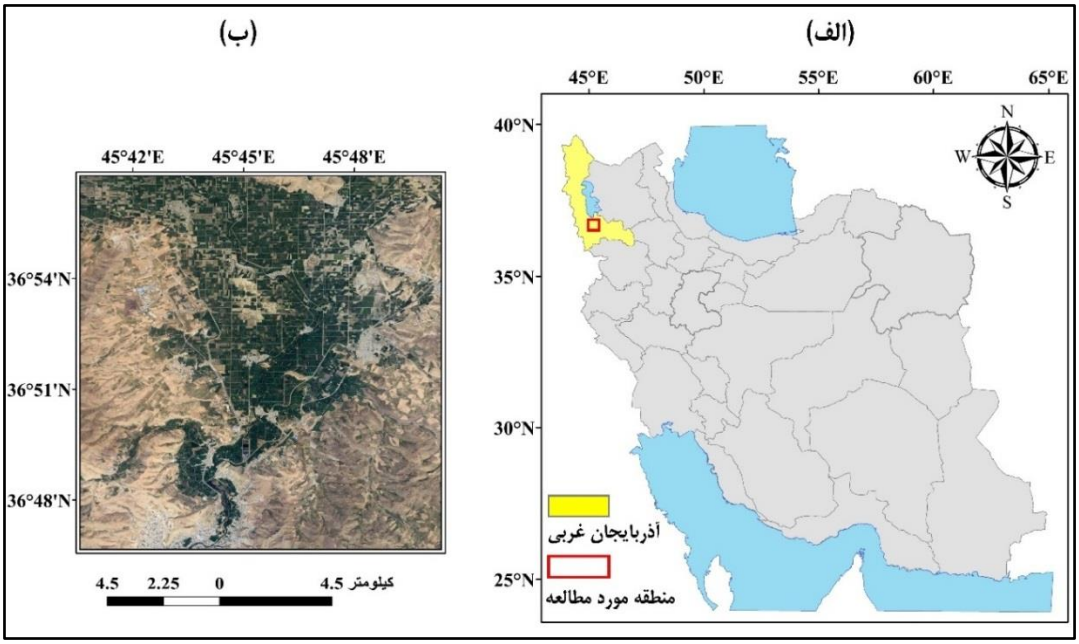
داده‌های مورد استفاده در این تحقیق شامل مجموعه داده‌های سنجش از دور و مجموعه دادهٔ واقعیت زمینی یا GT می‌باشد که در زیر به معرفی آن‌ها پرداخته می‌شود.

مجموعه داده سنجش از دور

تصاویر ماهواره‌ای از دو ماموریت لندست L۸/۹ یکی از منابع داده ماهواره‌ای نوری مورد استفاده در این مطالعه بود. هنگام انجام این تحقیق، تنها ماهواره‌های L۸ و L۹ فعال بودند که به ترتیب در ۱۱ فوریه ۲۰۱۳ و ۲۷ سپتامبر ۲۰۲۱ پرتاب شدند . این مطالعه از محصولات بازتاب سطحی L۸ و L۹ استفاده کرده است که پس از تصحیح بازتاب سطحی زمین که شامل اصلاحات رادیومتری، زمین و جو می‌شود (Liu et al., 2018)، موجود است. وضوح فضایی ماموریت های L۸ و L۹ در محدوده‌ای بین ۱۵

تا ۱۰۰ متر متغیر است که در این میان بیشتر باندهای طیفی دارای تفکیک‌پذیری ۳۰ متری هستند. علاوه بر این، هر دو شامل هفت باند طیفی هستند که مناطق مرئی، مادون قرمز نزدیک و موج کوتاه مادون قرمز را با محدوده طیفی از ۴۸۲ تا ۲۲۰۰ نانومتر در بر می‌گیرند (جدول۱). هر یک از این ماموریت ها وضوح زمانی ۱۶ روزه را ارائه می‌دهند که در صورت ترکیب به ۸ روز کاهش می‌یابد. بنابراین، در نتیجه ویژگی های مکانی، طیفی و زمانی مشابه آن‌ها، ترکیب آن‌ها به عنوان یک مجموعه داده واحد در نظر گرفته شد که از این به بعد (L۸/۹) نامیده می شود. محل مطالعه توسط دو صحنه L۸/۹ (با شماره مسیر(path) ۱۳۵ و ردیف (row) شماره‌های ۳۴ و ۳۵) پوشیده شده است.

در این مقاله، تصاویر S۲ عنوان منبع دیگری از داده‌های ماهواره‌ای نوری استفاده شده‌اند. ماموریت S۲ شامل دو ماهواره یکسان، S2-A و S2-B است که در ۲۳ ژوئن ۲۰۱۵ و ۷ مارس ۲۰۱۷ پرتاب شدند. هر ماهواره دارای یک چرخه تکرار ۱۰ روزه است که در صورت استفاده از هر دو به ۵ روز کاهش می‌یابد. این ماهواره دارای ۱۳ باند طیفی است که سه باند آن به کاربردهای جوی (با وضوح مکانی ۶۰ متر) اختصاص داده شده است. ده باند دیگر مناطق مرئی، مادون قرمز نزدیک و مادون قرمز موج کوتاه را پوشش می‌دهند که از ۴۹۶ تا ۲۲۰۰ نانومتر را با وضوح مکانی ۱۰ و ۲۰ متر پوشش می‌دهند (Feng et al., 2019). این مطالعه از داده‌هایS2 level-2A استفاده کرده که مقادیر بازتاب سطحی را پس از تصحیحات رادیومتری، زمینی و جوی ارائه می‌دهد (Panjala et al., 2022). منطقه مورد مطالعه به طور کامل توسط یک صحنه S2 با شماره گرانول ۳۹ پوشانده شده است.



شکل ۱. (الف) موقعیت جغرافیایی منطقه مورد مطالعه در ایران، (ب) منطقه مورد مطالعه (مهاباد)
Figure 1. (a) Location of the study area in Iran, (b) Study site (Mahabad)

جدول ۱. باندهای طیفی سنجنده‌های S۲ و L۸/۹ مورد استفاده در این تحقیق
Table 1. Spectral bands of S2 and L8/9 satellites used in this study

مجموعه	نام باند	طول موج (nm)	وضوح (m)	توضیحات
S۲	B2	۴۹۶/۶	۱۰	Blue (B)
	B3	۵۶۰	۱۰	Green (G)
	B4	۶۶۴/۵	۱۰	Red (R)
	B5	۷۰۳/۹	۲۰	Red Edge ۱ (RE1)

	B6	۷۴۰/۲	۲۰	Red Edge ۲ (RE2)
	B7	۷۸۲/۵	۲۰	Red Edge ۳ (RE3)
	B8	۸۳۵/۱	۱۰	NIR
	B8A	۸۶۴/۸	۲۰	Red Edge ۴ (RE4)
	B11	۱۶۱۳/۷	۲۰	SWIR ۱
	B12	۲۲۰۲/۴	۲۰	SWIR ۲
L۸/۹	B2	۴۸۲	۳۰	Blue (B)
	B3	۵۶۱/۵	۳۰	Green (G)
	B4	۶۵۴/۵	۳۰	Red (R)
	B5	۸۶۵	۳۰	NIR
	B6	۱۶۰۸/۵	۳۰	SWIR ۱
	B7	۲۲۰۰/۵	۳۰	SWIR ۲

این مطالعه همچنین از ماهواره S۱ به عنوان منبع داده SAR استفاده کرده ا ست. S۱ اولین ماموریت برنامه کوپرنیکوس است که توسط آژانس فضایی اروپا توسعه یافته است. این ماموریت شامل یک صورت فلکی از دو ماهواره یکسان است: S1-A (پرتاب در ۳ آوریل ۲۰۱۴) و S1-B (پرتاب در ۲۶ آوریل ۲۰۱۶). صورت فلکی دو ماهواره یک چرخه تکرار ۶ روزه را فراهم می کند. ماهواره‌های S1 مجهز به یک باند C (۵,۴۰۵ گیگاهرتز) هستند که می تواند در هر شرایط آب و هوایی و در هر زمانی از شبانه روز، داده ها را جمع آوری کند (Torres et al., 2012). محصول S1 (GRD) برای این مطالعه استفاده می شود که دو قطبش را ارائه می‌دهد: عمودی–عمودی (VV) و عمودی– افقی (VH) که در حالت تداخل سنجی گسترده (IW) است. این محصول وضوح فضایی ۱۰ متر را ارائه می دهد (Mullissa et al., 2021). پیش پردازش شامل حذف نویز حرارتی، کالیبراسیون رادیومتری و تصحیح زمین است. از آنجایی که اکثر تصاویر S۱ موجود بر روی منطقهٔ مورد مطالعه در یک مدار صعودی به دست آمدند، این مطالعه تنها از داده های S۱ به دست آمده در یک مدار صعودی استفاده کرده است. محل مطالعه به طور کامل توسط دو مدار صعودی با اعداد مدار نسبی ۷۲ و ۱۷۴ پوشیده شده است که در نتیجه چندین صحنه S۱ محل مطالعه را در بر می‌گرفت.

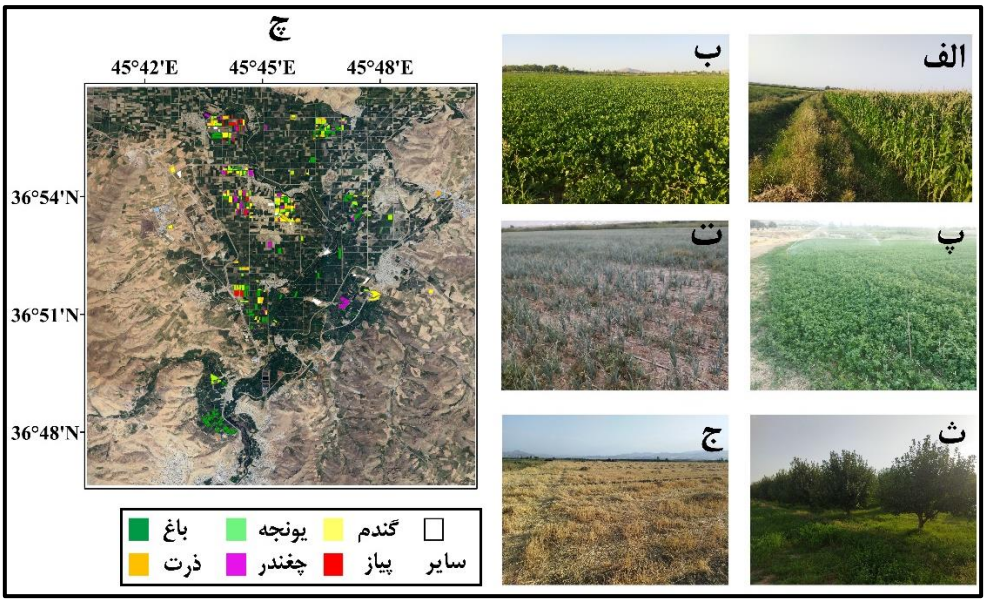
مجموعه دادهٔ واقعیت زمینی

روش پیشنهادی بر طبقه‌بندی نظارت شده متکی است که به داده‌های آموزشی با قابلیت اطمینان بالا نیاز دارد. بررسی‌های میدانی متعددی در منطقه مورد مطالعه بین مرداد و شهریور ۱۴۰۲ برای جمع آوری داده های GT قابل اعتماد برای اعتبارسنجی و کالیبراسیون مدل انجام شد. این دوره مصادف با دوره اوج رشد محصولات پاییزی و بهاری در سایت مورد مطالعه است. توزیع نمونه‌های GT و برخی از تصاویر در حین بررسی‌های میدانی را می توان در شکل ۲ مشاهده کرد. بازدیدهای میدانی به صورت تصادفی انجام شد که داده های زمینی دارای توزیع مناسب در محل مطالعه باشد. طی بررسی‌های میدانی، ۳۴۵ زمین کشاورزی (بسته به شکل زمین) ثبت شد که مربوط به طبقات مختلف گندم، ذرت، چغندر، پیاز، یونجه، باغ و طبقه سایر بود. طبقه «سایر» شامل خاک برهنه، مناطق شهری و آب است، در حالی که طبقه «باغ» بیشتر باغ‌های سیب را شامل می‌شود. برای هر چند ضلعی، مختصات گوشه‌های هر زمین با استفاده از دستگاه GPS دستی (Garmin eTrex 20x) با دقت مکانی کمتر از ۵ متر ثبت شد. برای جلوگیری از اثر پیکسل‌های مختلط، پیکسل‌های گوشه با حداقل فاصله ۳۰ متری از طبقات پوشش زمین اطراف ثبت شدند. جدول ۲ تعداد نقاط نمونه (در وضوح ۳۰ متر) را در هر طبقه نشان می‌دهد که از بررسی‌های میدانی به دست آمده است. شکل ۲ (ج) رفتار NDVI نمونه‌های انتخاب شده تصادفی از هر طبقه هدف را نشان می‌دهد که از میانه‌های ماهانه L۸/۹ (همانطور که در بخش مجموعه داده سنجش از دور ذکر شد) به دست آمده است. مجموعه داده مرجع زمینی به دو بخش ۷۰ درصد به عنوان آموزش و ۳۰ درصد به عنوان اعتبار سنجی تقسیم شد. داده‌های آموزشی برای آموزش مدل استفاده شد، در حالی

که داده‌های اعتبارسنجی در ارزیابی دقت بدون استنتاج در مرحله آموزش استفاده شد.

جدول ۲. تعداد نقاط (پیکسل) واقعیت زمینی براساس برداشت میدانی به ازای هر طبقه
Table 2. Number of specific points (pixels) of the field survey per class

نام طبقه	آموزشی	ارزیابی	مجموع
گندم	۶۵۴	۲۸۱	۹۳۵
ذرت	۳۷۴	۱۶۰	۵۳۴
چغندر	۴۷۲	۱۸۴	۶۵۶
پیاز	۲۳۵	۱۰۰	۳۳۵
یونجه	۷۴۹	۳۲۱	۱۰۷۰
باغ	۱۰۰۸	۴۳۱	۱۴۳۹
سایر	۴۵۶	۱۹۵	۶۵۱
مجموع	۳۹۴۸	۱۶۷۲	۵۶۲۰



شکل ۲. انواع طبقات منطقه مورد مطالعه: (الف) ذرت، (ب) چغندر، (پ) یونجه، (ت) پیاز، (ث) باغ و (ج) گندم. (چ) پراکنش نمونه‌های واقعیت زمینی
Figure 2. Different classes of the study area: (a) Corn, (b), Sugar beet, (c) Alfalfa, (d) Onion, (e) Garden and (f) Wheat. (g) Distribution of Ground Truth samples

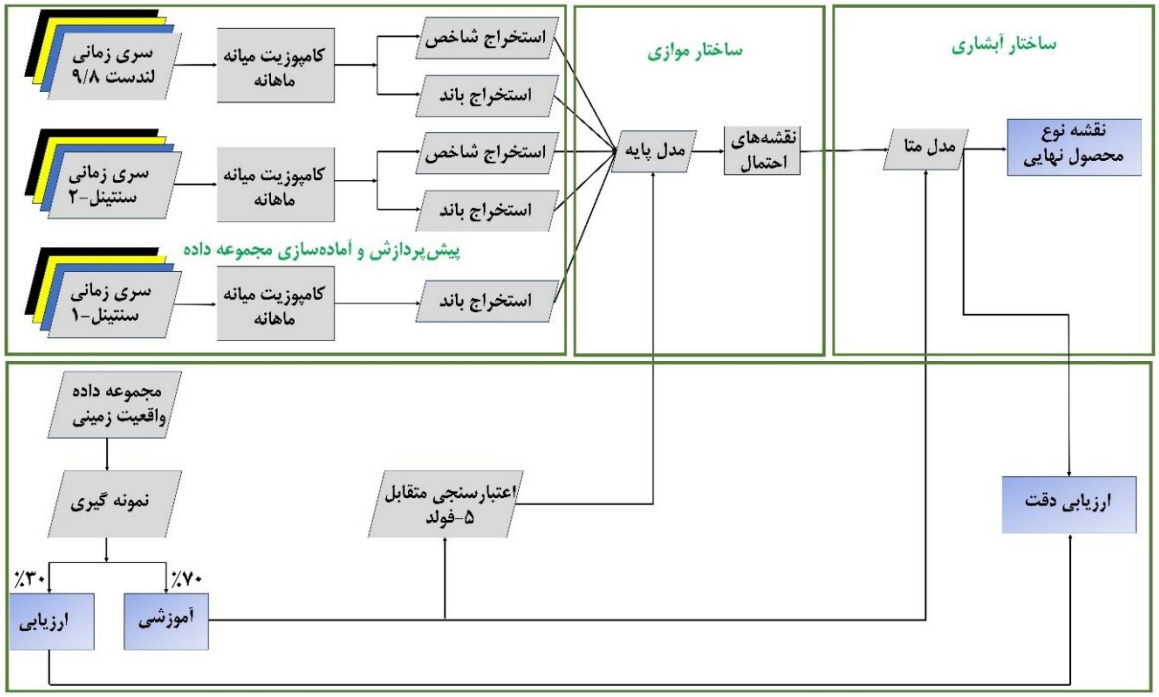
روش پژوهش

همانطور که در بخش قبل ذکر شد، این مطالعه با هدف ارائه یک ساختار جدید موازی–آبشاری برای طبقه‌بندی نوع محصول در داده‌های ماهواره‌ای سنجش از دوری انجام شد. طرح کلی روش پیشنهادی را می‌توان در شکل ۳ مشاهده کرد که شامل چهار مرحله اصلی است: ۱) پیش پردازش و آماده‌سازی مجموعه داده، ۲) ساختار موازی، ۳) ساختار آبشاری ، ۴) ارزیابی دقت. هر یک از مراحل در بخش‌های بعد به طور کامل توضیح داده شد.

پیش پردازش و آماده‌سازی مجموعه داده‌ها

همانطور که قبلا ذکر شد، از سه منبع داده های ماهواره‌ای در این مطالعه استفاده شد: S۱ و S۲ و L۸/۹. تصاویر S۲ و L۸/۹

متعلق به نوع نوری داده‌های ماهواره‌ای هستند که به دلیل پوشش ابری که مانع رصد کامل منطقه مورد مطالعه می‌شود، با محدودیت‌هایی مواجه هستند. در نتیجه، تصاویر با پوشش ابری بیش از ۱۰ درصد حذف شد. علاوه بر این، ابرها و سایه‌های ابری با استفاده از ویژگی‌های کیفیت پیکسلی که در کنار هر تصویر سنتینل۲ و لندست ۹/۸ موجود است (باند QA60 برای S۲ و QA_PIXEL برای L۸/۹) از هر صحنه حذف شدند. در نتیجه به ترتیب ۱۴، ۱۱، ۳۸ و ۷۹ صحنه از L۸، L۹، S۲ و S۱ انتخاب شدند. با این حال، حذف پیکسل‌های ابری منجر به شکاف داده ها در برخی از تصاویر در سراسر سایت مطالعه شد. علاوه بر این، ذکر این نکته حائز اهمیت است که منطقه مورد مطالعه در برخی از ماموریت‌های ماهواره‌ای مانند S۱ و L۸/۹ با صحنه‌های تصویری متعدد پوشیده شده است. در نتیجه، در این مطالعه از یک رویکرد کامپوزیت میانه ماهانه برای تولید تصاویر ماهواره‌ای ورودی برای مدل‌های یادگیری ماشین استفاده کرد. موثر بودن این رویکرد در مطالعات مشابه ثابت شده است (Hu et al., 2022). کامپوزیت‌های ماهانه تصاویر بدون شکاف منطقهٔ مورد مطالعه را تضمین می‌کند و همچنین به کاهش نویزهای احتمالی مرتبط با حسگر در مجموعه داده های نوری و نویز لکه (Speckle) در داده های SAR کمک می‌کند.



شکل۳. فلوچارت مراحل انجام تحقیق

Figure 3. Outline of the proposed framework

لازم به ذکر است که تصاویر ماهواره‌ای چند زمانی عمدتاً در ادبیات برای طبقه‌بندی نوع محصول استفاده شد. این به این دلیل است که داده‌های چند زمانی الگوهای رشد محصول و اطلاعات فنولوژیکی را در نظر می گیرند (Kadri et al., 2023). بنابراین، تصاویر از تاریخ '۲۰۲۳-۱۰-۲۳' تا '۲۰۲۴-۱۰-۲۳' برای سال ۱۴۰۲ (بر اساس شرایط ذکر شده) انتخاب شدند. این دوره‌ها کل سال زراعی ۱۴۰۲ منطقهٔ مورد مطالعه را در بر می‌گیرد که سال جمع آوری داده‌های واقعیت زمینی هستند. در نتیجه، ۱۲ کامپوزیت میانه ماهانه برای هر مجموعه داده (S۱، S۲ و L۸/۹) تولید شد. با در نظر گرفتن دقت‌های مکانی متفاوت در بین منابع داده‌های ماهواره‌ای، همه کامپوزیت‌های میانه با استفاده از تکنیک دوخطی (Bilinear technique) به وضوح فضایی ۳۰ متر بر اساس کمترین وضوح فضایی ارائه‌شده توسط L۸/۹ نمونه‌برداری شدند (Topaloğlu et al., 2016).

همانطور که ذکر شد، این مطالعه ساختار موازی را در سطح داده پیشنهاد می‌کند. این بدان معنی است که هر ترکیب چند زمانی آماده شده از داده های S۱، S۲ و L۸/۹ به طور جداگانه در مدل‌های یادگیری ماشین وارد شده است. با این حال، برای

مجموعه داده های نوری (S۱ و L۸/۹)، علاوه بر باندهای طیفی، شاخص‌های طیفی نیز برای افزایش دقت طبقه‌بندی استفاده شد. این به این دلیل است که مطالعات قبلی نشان داده‌اند که شاخص های طیفی می‌توانند شناسایی طبقات نوع محصول پیچیده را بهبود بخشند (Kobayashi et al., 2020; Zhang et al., 2019)، زیرا برای برجسته کردن ویژگی‌های خاص در داده‌های نوری طراحی شده‌اند (Asgari & Hasanlou, 2023). در این راستا، پنج مورد از متداول‌ترین شاخص‌های طیفی مورد استفاده در ادبیات مورد استفاده قرار گرفتند: NDVI (Normalized Difference Vegetation Index)، NDWI (Normalized Difference Water Index)، NDBI (Normalized Difference Built-up Index)، SAVI (Soil-Adjusted Vegetation Index)، EVI (Enhanced Vegetation Index) . همه این شاخص ها از هر دو مجموعه ماهانه داده های S۱ و L۸/۹ استخراج شدند. لازم به ذکر است که هیچ ویژگی اضافی از باندهای VV و VH (سنجندهٔ S۱) استخراج نشد. این به این دلیل است که مطالعات متعدد نشان داده‌اند که این نوارهای خاص حاوی اطلاعات کافی برای نقشه‌برداری پوشش زمین هستند و استخراج ویژگی‌های اضافی از آن‌ها را غیر ضروری می‌سازد (Sun et al., 2020). به طور خلاصه، پنج مجموعه ویژگی (FC) به عنوان ورودی برای مدل‌های یادگیری ماشین تولید شدند که در جدول۳ ارائه شده‌اند.

جدول ۳. مجموعه ویژگی‌های مختلف استفاده شده در ساختار موازی
Table 3. Five different FCs used in the Pa structure

مجموعه ویژگی (FC)	شمارهٔ شاخه	توضیحات
FC_1	۱	فقط باندهای طیفی S۲ جدول۱
FC_2	۲	فقط شاخص‌های طیفی: NDVI, NDBI, NDWI, SAVI, EVI از S۲
FC_3	۳	فقط باندهای طیفی L۸/۹ جدول۱
FC_4	۴	فقط شاخص‌های طیفی NDVI, NDBI, NDWI, SAVI, EVI از L۸/۹
FC_5	۵	فقط باندهای VV و VH

ساختار موازی

این مطالعه یک ساختار موازی را در سطح داده معرفی کرده است. این بدان معناست که بر خلاف مطالعات قبلی، هر FC تهیه شده در جدول ۳، به یک مدل یادگیری ماشین داده شد. این رویکرد امکان استفاده از نقاط قوت مجموعه داده های مختلف را به طور همزمان فراهم می‌کند. علاوه بر این، از آنجایی که در هر شاخه یک FC خاص وجود دارد، ساختار موازی می‌تواند دقت بالاتری در مقایسه با رویکرد مرسوم انباشتن FC ها به دست آورد، که باعث ایجاد افزونگی غیر ضروری و کاهش کارایی محاسباتی در طول فرآیند طبقه‌بندی می‌شود (Y. Zhang et al., 2022). در مجموع ۵ FC مختلف وجود دارد که در نتیجه ۵ شاخه در ساختار موازی وجود دارد. در این مطالعه، دو مدل یادگیری ماشین پرکاربرد در طبقه‌بندی محصولات، شامل جنگل تصادفی و ماشین بردار پشتیبان و یک مدل یادگیری عمیق CNN برای یافتن مدل‌های بهینه در هر شاخه از ساختار موازی مورد ارزیابی قرار گرفتند.

به منظور انتخاب بهترین مدل در هر شاخه از ساختار موازی، هر یک از مدل‌های یادگیری ماشین فوق‌الذکر به طور جداگانه در هر شاخه ارزیابی می شود. مدلی که بالاترین دقت را به دست آورد به عنوان مدل پایه برای آن شاخه خاص انتخاب می شود. این رویکرد به این دلیل اتخاذ شده است که برخی از مدل‌های یادگیری ماشین عملکرد ضعیف‌تری نسبت به سایرین نشان می‌دهند (Zhang et al., 2021; Y. Zhang et al., 2022). در نتیجه، استفاده همزمان آنها در کنار سایر مدل‌های یادگیری ماشین می‌تواند بر نتایج مدلسازی، تأثیر منفی بگذارد. برای این منظور، پارامترهای هر مدل یادگیری ماشین در هر شاخه ابتدا با استفاده از یک رویکرد اعتبار سنجی متقابل k–فولد (K-fold Cross validation) (Phinzi et al., 2021)، با K=۵ به کمک تکنیک جستجوی شبکه‌ای تعیین شد. این شامل تقسیم تصادفی داده‌های آموزشی به پنج دسته است. در طول هر تکرار اگر

تعداد کل دسته برابر k باشد، یک دسته برای اعتبار سنجی نگه داشته می شود، در حالی که ۱–k دسته باقی مانده برای آموزش الگوریتم ها در هر شاخه با استفاده از پارامترهای فضای جستجو استفاده می‌شود. این فرآیند، k بار تکرار می شود و بهترین پارامترها بر اساس میانگین دقت طبقه‌بندی انتخاب می‌شوند. مدلی که بالاترین دقت طبقه‌بندی را در اعتبارسنجی متقابل ۵–فولد به دست آورد، همراه با پارامترهای (Hyperparameter) بهینه آن، به عنوان مدل پایه در هر شاخه انتخاب می شود. ذکر این نکته حائز اهمیت است که همان داده های آموزشی ۵–فولد انتخاب شده به صورت تصادفی در هر پنج شاخه ساختار موازی مورد استفاده قرار گرفت. جدول۴ یک نمای کلی از پارامترهای مدل‌ها و فضای جستجوی مربوطه آنها را ارائه می دهد.

پس از انتخاب بهترین مدل در هر شاخه، هر مدل با همان مجموعه داده آموزشی، آموزش داده می‌شود که ۷۰ درصد از مجموعه داده مرجع را تشکیل می‌دهد. نتیجه هر شاخه در فرآیند طبقه‌بندی یک نقشه احتمال برای هر طبقه است. این ها دارای باندهایی برابر با تعداد طبقات هستند (۷ در این مطالعه). مقادیر پیکسل در نقشه‌های احتمال، تعلق آن پیکسل به طبقات مختلف را نشان می‌دهد. از آنجایی که در ساختار موازی پیشنهادی پنج شاخه وجود دارد، پنج مجموعه نقشه احتمال وجود دارد که هر کدام از هفت باند تشکیل شده است. در مرحله بعد، این نقشه‌ها در ساختار آبشاری برای طبقه‌بندی نهایی استفاده می‌شوند.

ساختار آبشاری

در این مطالعه، نقشه‌های احتمال تعلق پیکسل به طبقات مختلف (که از این به بعد نقشه احتمال نامیده می‌شود) حاصل از خروجی طبقه‌بندی (شاخه‌ها) روی هم چیده می‌شوند، که منجر به تشکیل مکعب احتمال می‌شود که به عنوان ورودی مدل متا، به نام ساختار آبشاری، برای طبقه‌بندی انواع مختلف محصول استفاده می‌شود (Zhang et al., 2021). همان روشی که در ساختار موازی اعمال شد، برای انتخاب بهترین متا مدل نیز استفاده شد. به طور خاص، نقشه‌های احتمال از پنج شاخه موازی به سه مدل مذکور داده شدند. با استفاده از روش یکسانی که در ساختار موازی توضیح داده شد، پارامترهای هر مدل با استفاده از تکنیک اعتبارسنجی متقابل ۵–فولد و رویکرد جستجوی شبکه‌ای با فضای جستجوی شبکه‌ای که در جدول۴ آمده است، تعیین شد. مدلی که بالاترین میانگین دقت طبقه‌بندی را به دست آورد، به عنوان مدل متا انتخاب می‌شود. هنگامی که بهترین مدل انتخاب شد، مدل متا با استفاده از کل مجموعه داده آموزشی، که ۷۰٪ از مجموعه داده مرجع را تشکیل می دهد، آموزش داده شد. تاکید بر این نکته ضروری است که مدل متا نیز با استفاده از داده های آموزشی مشابه شاخه‌ها آموزش داده شده است.

جدول ٤. پارامترهای بهینه شده در این مطالعه

Table 4. Hyperparameters tuned in this study

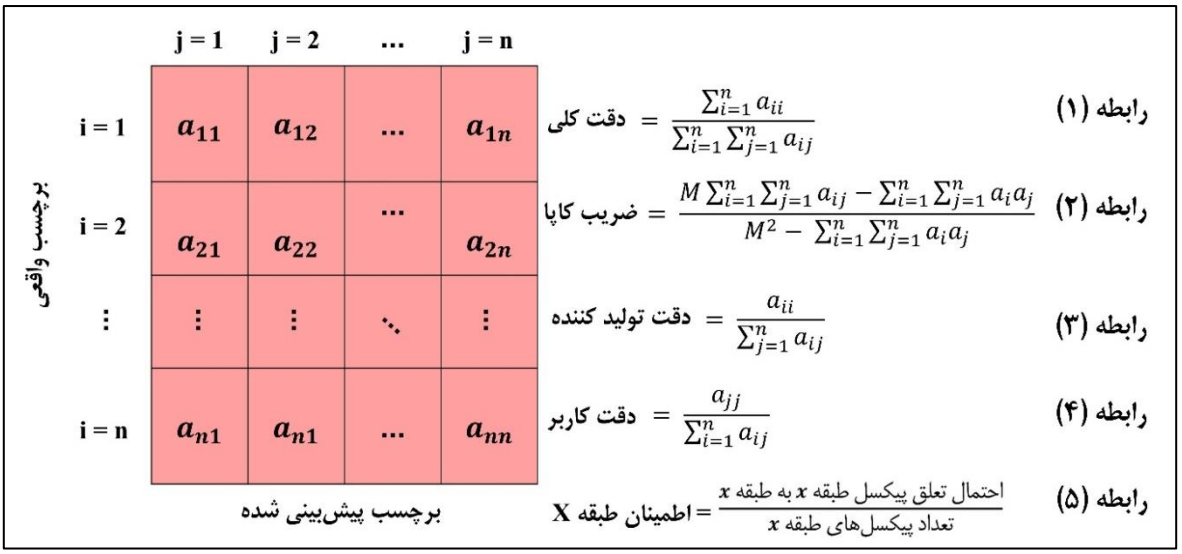
مدل	پارامتر	فضای جستجوی شبکه ای
SVM	G	[۰/۰۱ ، ۰/۰۰۱ ، ۰/۰۰۰۱ ، ۰/۰۰۰۰۵ ، ۰/۰۰۰۰۱]
	C	[۰/۰۰۱ ،۰/۰۱ ،۰/۱ ، ۱ ،۱۰]
RF	NT	[۱۰ ،۵۰ ،۱۰۰ ،۲۰۰ ،۳۰۰]
	MD	[۲ = فاصله ، ۱۰–۱]
	MSS	[۲ = فاصله ، ۱۰–۲]
CNN	Learning Rate	[۰/۰۰۱ ،۰/۰۱ ،۰/۱]
	NO Filters	[۳۲ ، ۶۴ ،۱۲۸]
	Kernel size	[(۳ × ۳) ، (۵ × ۵)]

مهم است که تأکید شود که این مطالعه ۲ ساختار مدل‌های مختلف را برای نشان دادن عملکرد برتر روش پیشنهادی ارزیابی می‌کند. این ۲ ساختار عبارت‌اند از مدل مرسوم و مدل موازی–آبشاری. مدل مرسوم یک رویکرد مرسوم طبقه‌بندی نوع محصول را نشان می‌دهد، که در آن تمام FCهای ورودی (FC۵–FC۱) به سادگی روی هم چیده شده‌اند و یک مدل یادگیری ماشین واحد برای طبقه‌بندی استفاده شده است (Blickensdörfer et al., 2022; Rahman & Robson, 2020). مدل موازی–

آبشاری ساختار پیشنهادی ما است که در آن ابتدا بهترین مدل‌ها به عنوان مدل پایه در شاخه‌ها و مدل متا در ساختار آبشاری شناسایی شده‌اند. علاوه بر این، ترکیبات مختلفی از FCهای ورودی (FC1-FC5) برای این معماری خاص آزمایش شدند.

ارزیابی دقت

برای ارزیابی عملکرد روش پیشنهادی، از ماتریس ابهام (Confusion Matrix) یا ماتریس خطای طبقه‌بندی و معیارهای مختلف مشتق‌شده از آن استفاده شد. این معیارها عبارت‌اند از: دقت کلی (OA)، ضریب کاپا (Kappa)، دقت تولیدکننده (PA) و دقت کاربر (UA). مهم است که تاکید شود که ارزیابی دقت با استفاده از مجموعه داده اعتبارسنجی (۳۰٪ از مجموعه داده مرجع) انجام شده است. مجموعه داده اعتبارسنجی در مرحله آموزش یا توسعه مدل استفاده نشد. علاوه براین در بین مدل‌های یادگیری ماشین رایج است که طبقه‌بندی پیکسل‌ها با استفاده از بالاترین احتمال تعلق پیکسل به طبقات به عنوان نتیجه‌ی طبقه‌بندی آن پیکسل در نظر گرفته می‌شود. در این راستا مدلی بالاترین احتمال آن بیشتر باشد دارای اطمینان بیشتری است. به این مفهوم، اطمینان مدل گفته می‌شود (Komura et al., 2023). در این مطالعه از این معیار نیز برای درک بهتر عملکرد روش پیشنهادی استفاده می‌شود. شکل ۴ روابط مربوط معیارهای مستخرج از ماتریس ابهام به تعداد n طبقه و همچنین معیار محاسبه‌ی اطمینان برای یک طبقه دلخواه را نشان می‌دهد.



شکل ٤. یک نمونه از ماتریس ابهام با تعداد طبقه n. رابطه ۵، فرمول اطمینان مدل برای طبقه x است.

Figure 4. A sample Confusion Matrix with n classes. equation 5 is model certainity formula for a class x

نتایج و بحث

در این بخش نتایج حاصل از روش‌های مختلف آورده و مقایسه شدند سپس در قسمت بعد به تجزیه و تحلیل این نتایج پرداخته شد.

نتایج

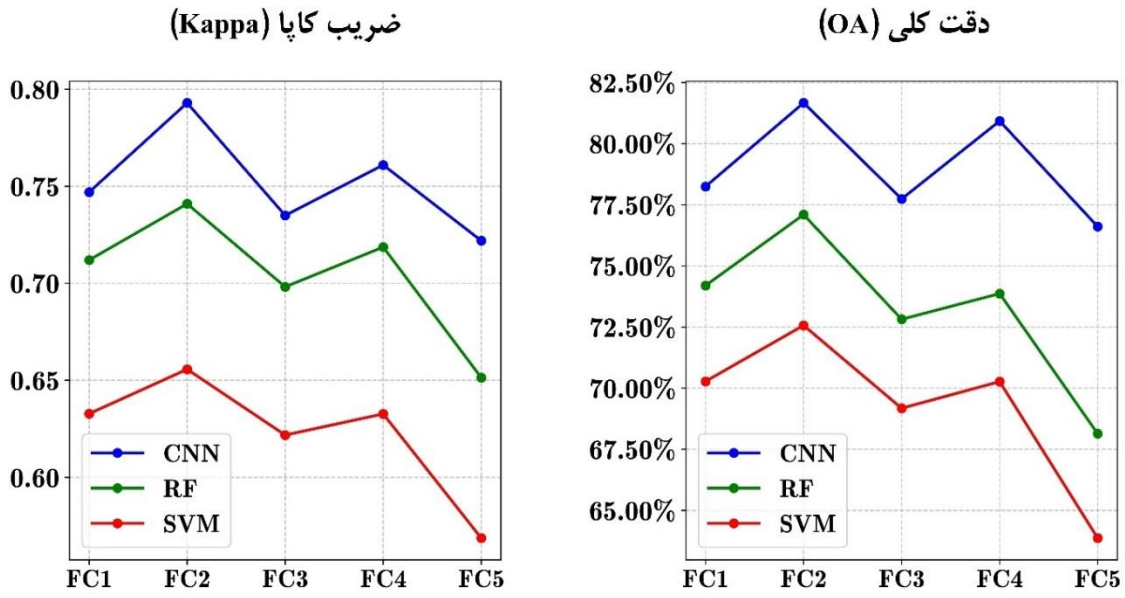
انتخاب مدل پایه در ساختار موازی

همانطور که در بخش ساختار موازی ذکر شد، بهترین مدل پایه در هر شاخه از ساختار موازی از طریق اعتبارسنجی متقابل ۵-فولد با استفاده از داده‌های آموزشی تعیین شد. شکل ۵ مقادیر میانگین OA و Kappa را برای مدل های مختلف یادگیری ماشین نشان می دهد. پارامترهای بهینه هر مدل با استفاده از رویکرد توصیف شده در بخش ساختار موازی پیدا شد. می توان

مشاهده کرد که مدل CNN از سایر مدل ها در همه شاخه‌ها بهتر عمل کرده است. بـه عنـوان مثـال، CNN مقـادیر ۷۸/۲۵٪، ۸۱/۶۷٪، ۷۷/۷۴٪، ۸۰/۹۳٪ و ۷۶/۶۱٪ شاخه‌های FC۵–۱ را به دست آورد. به طور مشابه، مقادیر Kappa بـه ترتیـب ۰/۷۴۷، ۰/۷۹۳، ۰/۷۳۵، ۰/۷۶۱ و ۰/۷۲۲ بودند. بنابراین، CNN به عنوان مدل پایه برای تمام شاخه‌های ساختار موازی انتخاب شد. پس از CNN، مدل های RF، SVM در رتبه‌های بعدی قرار گرفتند. علاوه بر این، در بین شاخه‌ها، FC۲ بـالاترین دقـت را از نظـر OA و Kappa برای هر مدل نشان داد. FC۴، FC۱، FC۳ و FC۵ در رتبه‌های بعدی قرار گرفتند. نتایج همچنین نشان داد که FCهای مربوط به داده‌های نوری (FC۴–۱) در مقایسه با FC۵ که مربوط به SAR است بهتر عمل کردند. به طور مشابه، FC ۱–۲ که مربوط به S۲ است عملکرد بهتری نسبت به FC۳،۴ که مربوط به L۸/۹ است از خود نشان دادند. عـلاوه بـر ایـن، FC های مبتنی بر شاخص (FC۲ و FC۴) عملکرد برتر را در مقایسه با FC های مبتنی بر طیـف (FC۱ و FC۳) در داده هـای RS نوری نشان دادند. لازم به ذکر است که فراپارامترهای بهینه CNN در هر شاخه به شرح زیر بود:

FC۱ [Learning Rate: ۰/۰۱ ، NO Filters: ۳۲ ، Kernel size: (۵×۵)] ، FC۲ [Learning Rate: ۰/۱ ، NO Filters: ۶۴ ، Kernel size: (۳×۳)] ، FC۳ [Learning Rate: ۰/۰۱ ، NO Filters: ۶۴ ، Kernel size: (۵×۵)]

FC۴ [Learning Rate: ۰/۰۱ ، NO Filters: ۳۲ ، Kernel size: (۳×۳)]، FC۵ [Learning Rate: ۰/۰۱ ، NO Filters: ۶۴ ، Kernel size: (۵×۵)]



شکل ۵. عملکرد مدل‌های یادگیری ماشین در شاخه‌های مختلف ساختار موازی بر حسب OA و Kappa با استفاده از اعتبارسنجی متقابل ۵-فولد داده‌های آموزشی.

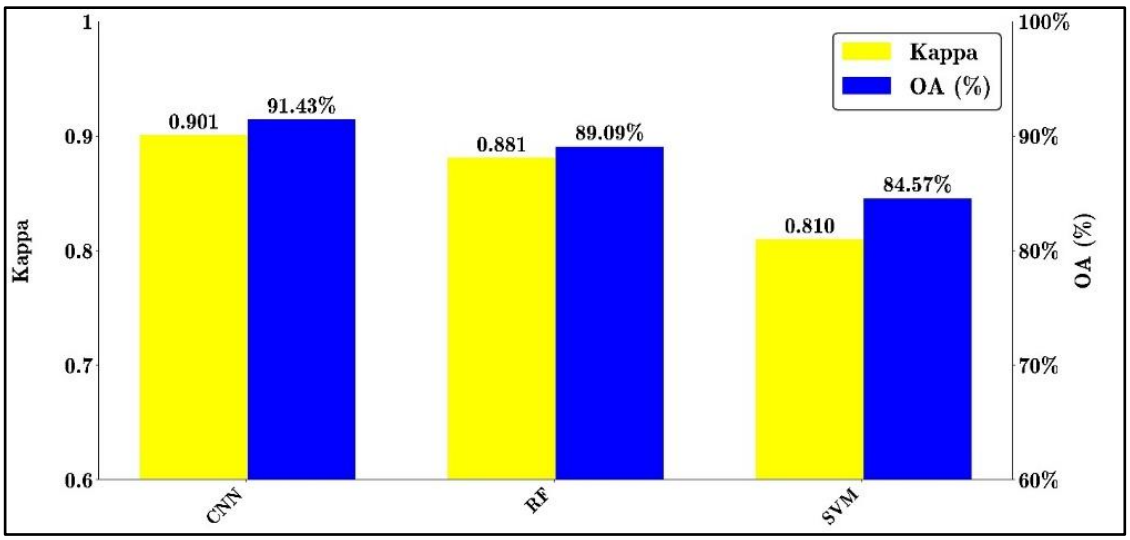
Figure 4. Performance of Machine learning models in different branches of Parallel structure in terms of OA and Kappa using 5-fold cross validation of training data.

انتخاب مدل متا در ساختار آبشاری

پس از انتخاب مدل پایه برای هر شاخه، مدل متا در ساختار آبشاری با استفاده از همـان رویکـرد ذکـر شـده در بخـش مـوازی–آبشاری تعیین شد. نقشه‌های احتمال همه شاخه‌ها مستقیماً به مدل‌ها تغذیه شدند. شـکل ۶ عملکـرد مـدل هـای مختلـف را در ساختار آبشاری بر حسب OA و Kappa نشان می دهد. پارامترهای بهینه هر مدل با اسـتفاده از روش توصـیف شـده در بخـش موازی–آبشاری پیدا شد. الگوریتم CNN از سایر مدل‌ها به عنوان مدل متا در ساختار آبشاری بهتر عمل کرد و بـه OA ۹۱٪/۴۳ و Kappa ۰/۹۰۱ دست یافت. طبقه‌بندی‌کننده‌های RF و SVM با مقادیر OA به ترتیب ۸۹/۰۹٪ و ۸۴/۵۷٪ و مقادیر Kappa

۰/۸۸۱و ۰/۸۱۰ در رتبه های دوم و سوم قرار گرفتند. بنابراین، CNN به عنوان متا مدل در ساختار مجموعه پیشنهادی این پژوهش انتخاب شد. لازم به ذکر است که پارامترهای بهینه CNN به عنوان مدل متا برابر شدند با:

Learning Rate: ۰/۰۱ ، NO Filters: ۶۴ ، Kernel size: (۵×۵)

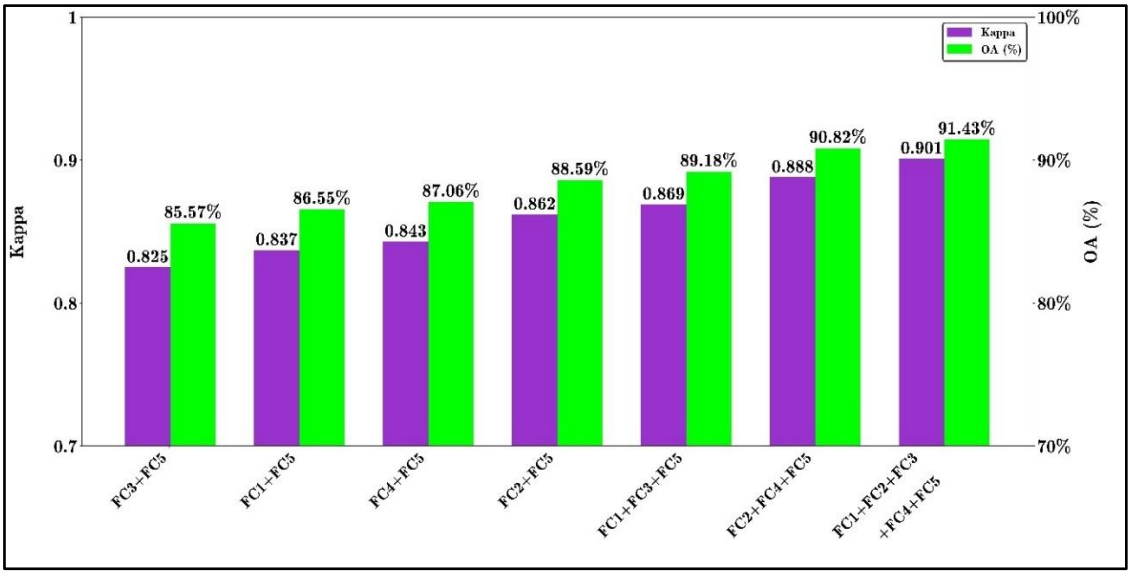


شکل ٦. عملکرد مدل های مختلف به عنوان مدل متا در ساختار آبشاری بر حسب OA و Kappa با استفاده از اعتبار سنجی متقابل ۵- فولد داده های آموزشی.

Figure 6. Performance of different models as the Meta-model in the Cascaded structure in terms of OA and Kappa using 5-fold cross validation of training data.

تاثیر مجموعه ویژگی ها در دقت طبقه‌بندی

همانطور که در بخش موازی-آبشاری ذکر شد، روش پیشنهادی از پنج FC (FC۱-FC۵) در ساختار موازی استفاده کرد. شکل ۷ عملکرد ساختار موازی-آبشاری را برای FC های مختلف بر اساس مجموعه داده اعتبارسنجی مقایسه می کند. لازم به ذکر است که بر اساس نتایج انتخاب مدل ساختار موازی و ساختار آبشاری، CNN به عنوان مدل پایه و مدل متا در ساختار موازی-آبشاری انتخاب شد. تمام موارد FC تنها از مدل CNN برای طبقه‌بندی استفاده می‌کنند. در شکل ۷ مشاهده می‌شود که وقتی FC های بیشتری در ساختار موازی-آبشاری استفاده می شود، مقادیر OA و Kappa پیشرفت‌های قابل توجهی را نشان داده اند. این کارایی ساختار موازی-آبشاری پیشنهادی را ثابت می‌کند، که از استفاده از منابع داده ماهواره‌ای مختلف در هر شاخه برای طبقه‌بندی نوع محصول سود می‌برد. با ثابت نگه داشتن FC۵ و ترکیب آن با سایر FC ها، ترکیب FC ۲+ FC۵ در ساختار موازی-آبشاری با OA ۸۸٪/۵۹ و Kappa ۰/۸۶۲ به بالاترین دقت دست یافت. همچنین نتایج نشان می‌دهد که با استفاده از رویکرد موازی-آبشاری با هر پنج شاخه طراحی‌شده، بالاترین OA (۹۱/۴۳ درصد) و Kappa (۰/۹۰۱) به دست آمد. در نتیجه، بهترین حالت (FC۱ + FC۲ + FC۳ + FC۴ + FC۵) به عنوان ویژگی های ورودی ساختار مجموعه موازی-آبشاری پیشنهادی در بقیه پژوهش انتخاب می‌شود.



شکل 7. تأثیر استفاده از منابع داده های مختلف بر اساس مجموعه داده اعتبارسنجی. CNN به عنوان مدل یادگیری ماشین در ساختارهای موازی و آبشاری انتخاب شده است.

Figure 7. Effect of using different data sources based on the validation dataset. CNN is selected as the Machine learning model in Parallel and Cascaded structures.

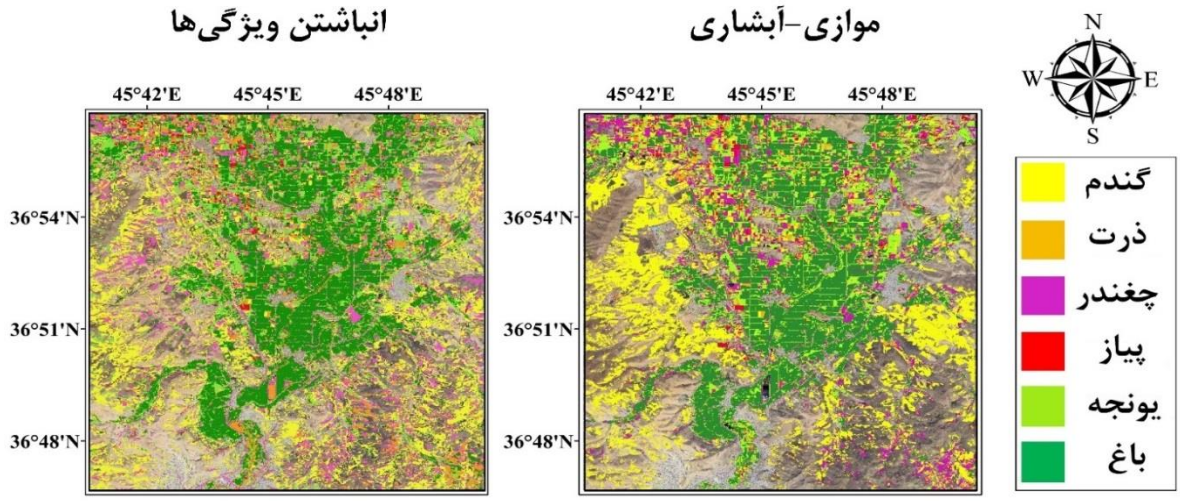
مدل موازی–آبشاری و مقایسهٔ آن با مدل مرسوم

در این مطالعه سعی بر آن شد که اطمینان مدل‌ها نیز برای نشان دادن عملکرد بهتر مدل پیشنهادی مقایسه شوند. جدول ۵ نسبت مجموع اطمینان پیکسل‌های مشترک به تعداد پیکسل ها را به ازای هر طبقه بین دو مدل را نشان می‌دهد. همانطور که مشاهده می‌شود روش پیشنهادی در همه‌ی طبقات اطمینان بیشتری را حاصل کرده است. بیشترین درصد اطمینان حاصل مربوط به طبقه باغ است که به ترتیب در مدل موازی–آبشاری و روش مرسوم برابر با ۷۳/۱۴ درصد و ۵۹/۱۱ درصد و کمترین اطمینان حاصل شده مربوط به طبقه پیاز است که به ترتیب برابر است با ۶۰/۲۵ درصد و ۴۳/۴۶ درصد است. این در حالی است که میانگین اطمینان همه‌ی طبقات ۱۶/۴۳ درصد افزایش یافته است. این نتایج نشان دهنده‌ی عملکرد بهتر روش پیشنهادی در مقابل سایر روش‌ها است.

جدول۵. اطمینان طبقات بین روش پیشنهادی و مدل انباشتن ویژگی‌ها

Table 5. Certainity per class of proposed framework and stacking features model.

نام طبقه	موازی–آبشاری	انباشتن ویژگی‌ها
گندم	٪ ۶۴/۹۰	٪ ۴۸/۵۴
ذرت	٪ ۶۴/۷۸	٪ ۴۹/۶۱
چغندر	٪ ۶۷/۴۵	٪ ۵۰/۷۲
پیاز	٪ ۶۰/۲۵	٪ ۴۳/۴۶
یونجه	٪ ۶۰/۸۴	٪ ۴۸/۴۸
باغ	٪ ۷۳/۱۴	٪ ۵۹/۱۱
سایر	٪ ۶۸/۸۹	٪ ۴۵/۳۳
میانگین	٪ ۶۵/۷۵	٪ ۴۹/۳۲

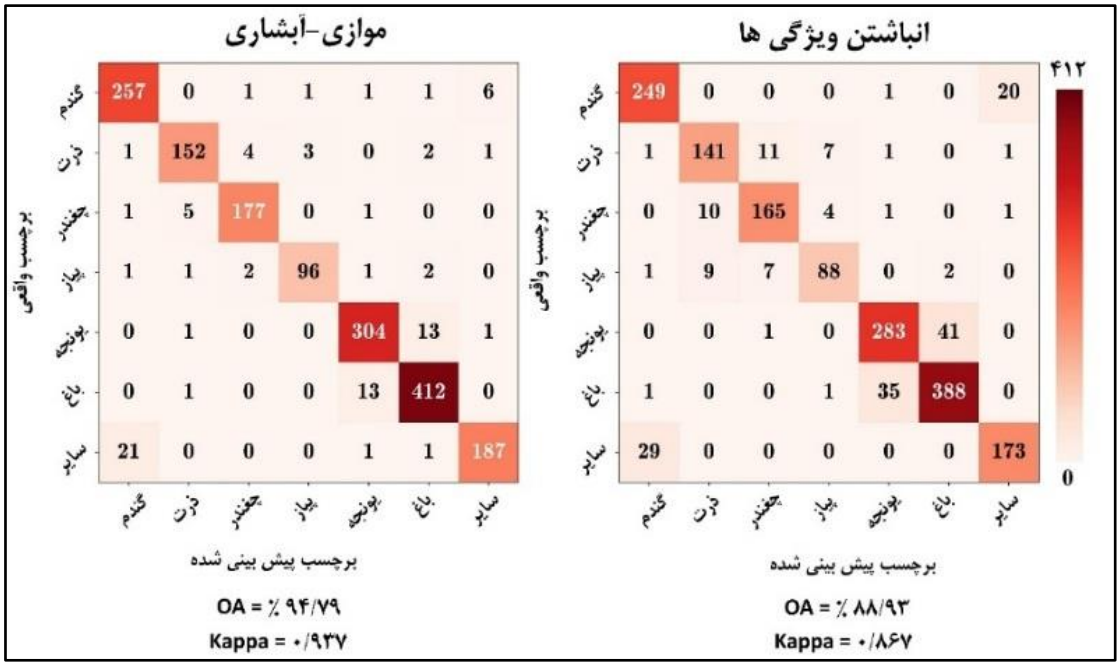


شکل ۸. مقایسه نقشه‌های طبقه‌بندی نوع محصول منطقه مورد مطالعه برگرفته از روش پیشنهادی (موازی - آبشاری) در مقایسه با ساختار انباشتن ویژگی‌ها.

Figure 8. Comparison of crop type classification maps of the study site derived from the proposed methodology (Parallel-Cascaded) compared to the Stacking structure.

نقشه‌های نوع محصول نهایی سایت مورد مطالعه در شکل ۸ ارائه شده است که نتایج روش پیشنهادی (موازی-آبشاری) و مدل مرسوم را نشان داد. تجزیه و تحلیل کمی نشان داد که روش پیشنهادی به دلیل ساختار به خصوص آن از ساختار مرسوم انباشتن از نظر دقت بهتر عمل می‌کند. نمایش‌های بصری در جدول ۵ نیز یافته‌های عددی را تایید می‌کنند و اثربخشی روش پیشنهادی (موازی-آبشاری) را در تولید نقشه‌های طبقه‌بندی دقیق‌تر در مقایسه با ساختار انباشتن FC ها نشان می‌دهند. با استفاده از این ساختار، حضور پیکسل‌های با نویز بالا در نتایج طبقه‌بندی مبتنی بر پیکسل به طور قابل توجهی کاهش یافت، که می‌توان آن را به کاهش عدم قطعیت، همانطور که در جدول۵ نشان داده شده است، نسبت داد.

همانطور که در بخش موازی-آبشاری ذکر شد، یک ساختار مدل مرسوم انباشتن برای اثبات عملکرد برتر روش پیشنهادی استفاده شد. در این مدل ها، CNN به عنوان مدل یادگیری ماشین برای طبقه‌بندی انتخاب شد. شکل ۸ ماتریس‌های ابهام این دو ساختار را نشان می‌دهد. بدیهی است که روش پیشنهادی به OA (۹۴٪/۷۹) دست یافت که تقریباً ۶٪ بیشتر در مقایسه با روش انباشتگی ویژگی معمولی بود. نتایج نشان داد که روش پیشنهادی با طبقه‌بندی صحیح تعداد بیشتری از نمونه‌های اعتبارسنجی در هر طبقه (تشخیص داده‌شده توسط عناصر قطر اصلی ماتریس خطا در مقایسه با روش دیگر، دقت بیشتری را بدست آورد. این نشان می‌دهد که روش پیشنهادی روش مؤثری برای تغییرات درون‌طبقه‌ای انواع مختلف محصولات زراعی به حساب می‌آید که منجر به عملکرد برتر آن می‌شود.

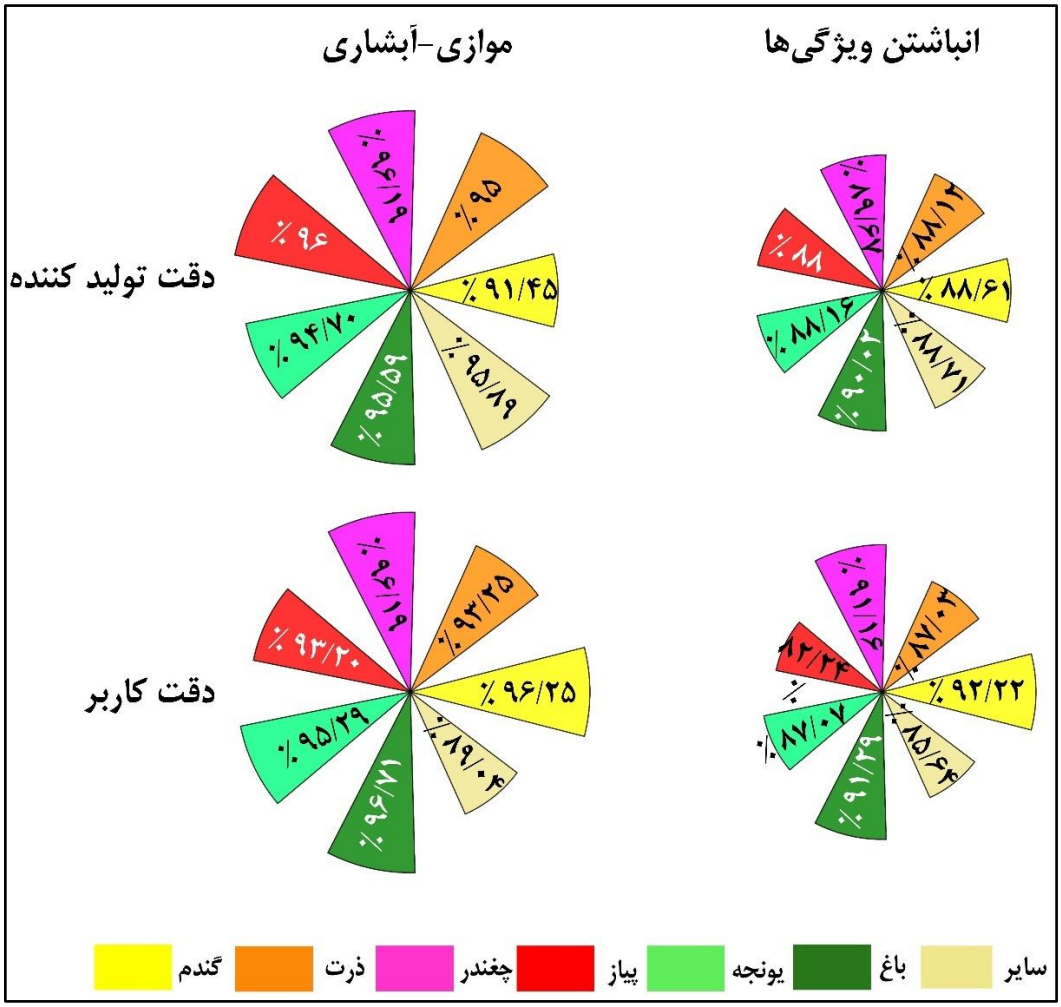


شکل ۹. ماتریس های ابهام مدل انباشتن ویژگی ها و ساختار موازی-آبشاری

Figure 9. Confusion matrixs of stacking model and Parallel-Cascaded structurs

شکل ۱۰، UA و PA طبقات هدف مختلف را برای روش پیشنهادی با ساختار مرسوم مقایسه می‌کند. همانطور که مشاهده می‌شود، با در نظر گرفتن معیار UA، در مدل مرسوم، طبقات «گندم» با ۹۲/۲۲ درصد بالاترین UA را به دست آورد، در حالی که طبقه «پیاز» کمترین UA را با ۸۲/۲۴ درصد به دست آورد. با این حال، استفاده از تکنیک ما منجر به افزایش قابل توجهی در دقت برای همه طبقات شد، به طوری که طبقه «باغ» بالاترین UA را با ۹۶/۷۱ درصد به دست آورد، در حالی که طبقه «سایر» کمترین UA را با ۸۹/۰۴ درصد به دست آورد. بیشترین افزایش در طبقه «پیاز» با بهبود ۱۰/۹۶ درصد از ۸۲/۲۴ درصد به ۹۳/۲۰ درصد مشاهده شد (شکل ۱۰).

همین نتایج را می‌توان برای معیار PA نیز مشاهده کرد (شکل ۱۰). استفاده از رویکرد پیشنهادی منجر به بهبود قابل توجهی در دقت برای همه طبقات شد، با طبقه «پیاز» که بالاترین بهبود را با ۸ درصد از ۸۸ درصد به ۹۶ درصد نشان داد. نتایج نشان می‌دهد که تکنیک موازی-آبشاری به طور موثری عملکرد مدل متا را در ساختار آبشاری بهبود می‌بخشد که می‌تواند توسط مقادیر OA و Kappa به‌دست‌آمده با استفاده از اعتبارسنجی متقابل ۵-فولد داده‌های آموزشی در شکل ۶ نیز پشتیبانی شود.



شکل ۱۰. مقایسه UA و PA طبقات هدف مختلف در روش پیشنهادی (موازی-آبشاری) و ساختار انباشتن ویژگی‌ها با استفاده از مجموعه داده اعتبارسنجی.

Figure 10. Comparison of the UA and PA of different target classes in the proposed method (Parallel-Cascaded) and stacking structure using the validation dataset.

بحث

مدل های پایه و مدل متا

نتایج این مطالعه نشان‌دهنده عملکرد بهینه ساختار پیشنهادی در طبقه‌بندی انواع محصولات زراعی با استفاده از داده‌های ماهواره‌ای چند منبع و چند زمانی است. ترکیب مدل‌های یادگیری ماشین در این ساختار باعث کاهش تأثیر مدل‌های با عملکرد پایین شده و دقت کلی طبقه‌بندی را بهبود بخشیده است. یافته‌ها نشان می‌دهند که مدل CNN در تمامی شاخه‌ها از سایر مدل‌ها عملکرد بهتری دارد و می‌تواند به عنوان گزینه‌ای مؤثر برای طبقه‌بندی انواع محصول در بین داده‌های نوری و مبتنی بر SAR مورد استفاده قرار گیرد. همچنین، این نتایج با مطالعات قبلی که CNN را به‌عنوان بهترین مدل برای این کاربرد معرفی کرده‌اند، سازگار است (Jafarzadeh et al., 2021; Tariq et al., 2023). این تحقیق مسیر جدیدی را برای بهبود طبقه‌بندی محصولات زراعی با بهره‌گیری از داده‌های متنوع و ترکیب مدل‌های قدرتمند یادگیری ماشین فراهم می‌کند.

علاوه بر این، مدل متا در ساختار آبشاری مستقیماً نتایج طبقه‌بندی نهایی را ایجاد کرد. مشابه بخش موازی، بهترین مدل در ساختار آبشاری از بین CNN، RF و SVM انتخاب شد. مدل CNN همچنین عملکرد برتر را در بین این مدل‌ها در ساختار

آبشاری نیز نشان داد(شکل ۶). در نتیجه، CNN به عنوان مدل پایه در ساختار آبشاری و به عنوان مدل متا در ساختار آبشاری انتخاب شد. همین نتیجه توسط پژوهشگران دیگر در این زمینه برای انتخاب مدل متا ذکر شده است (Alizadeh et al., 2025; Jafarzadeh et al., 2021; Xu & Zhang, 2022). عملکرد برتر CNN در مقایسه با سایر مدل‌ها در این مطالعه را می‌توان به دلایل مختلفی نسبت داد. اولاً، ساختار لایه‌ای و سلسله‌مراتبی CNN این امکان را فراهم می‌کند که ویژگی‌های سطح پایین تا سطح بالا را از داده‌ها (به‌ویژه داده‌های تصویری و مکانی) به‌صورت خودکار استخراج نماید (Sun et al., 2020). ثانیاً، CNN قادر است الگوهای فضایی و روابط محلی در داده‌ها را به خوبی شناسایی کند که این امر برای بسیاری از مسائل شامل داده‌های مکانی یا تصویری بسیار حیاتی است (Maxwell et al., 2018). در نهایت، استفاده از تکنیک‌هایی مانند عادی‌سازی، و داده‌افزایی در آموزش CNN به کاهش بیش‌برازش و افزایش تعمیم‌پذیری مدل کمک می‌کند (Kussul et al., 2017).

ساختار موازی–آبشاری پیشنهادی

چارچوب مجموعه پیشنهادی با مقادیر OA و Kappa بالاتر در مقایسه با رویکرد مرسوم که از انباشته کردن FC ها برای طبقه‌بندی استفاده می‌کنند، دقت بیشتری را نشان داد (شکل ۹). عملکرد برتر ساختار مجموعه پیشنهادی را می توان به دلایل مختلفی نسبت داد که در زیر توضیح داده شده است.

اولاً، قسمت موازی شامل پنج شاخه موازی بود که هر کدام مربوط به یک FC خاص بود (FC۱–۵ در جدول ۳). این شاخه‌های موازی PM ها را برای هر طبقه هدف تولید می‌کنند و نمایشی چند نما از داده‌ها ارائه می‌دهند. این به مدل اجازه می‌دهد تا از اطلاعات تکمیلی موجود در هر FC استفاده کند (Kussul et al., 2017). علاوه بر این، مدل را قادر می‌سازد تا به طور بالقوه طیف گسترده‌تری از الگوها و ویژگی‌های مرتبط با مشکل طبقه‌بندی را به تصویر بکشد (Hu et al., 2022). این یافته توسط نتایج در شکل ۷ نیز پشتیبانی می‌شود، جایی که استفاده همزمان از پنج FC به عنوان پنج شاخه مجزا در ساختار موازی بالاترین دقت را در مقایسه با سناریوهای دیگر به همراه داشت. لازم به ذکر است که FCهای مبتنی بر شاخص بهتر از FCهای مبتنی بر باند و همینطور FC مبتنی بر SAR عمل کردند. شاخص‌های طیفی عملکرد بهتری نسبت به باندهای منفرد دارند، زیرا با ترکیب اطلاعات طیفی، تفکیک‌پذیری بالاتری از ویژگی‌های گیاه ارائه می‌دهند و تأثیر عوامل مزاحم را کاهش می‌دهند. همچنین، داده‌های نوری در مقایسه با داده‌های SAR دقت بیشتری در تحلیل پوشش گیاهی دارند، زیرا اطلاعات زیستی و طیفی گیاه را ثبت می‌کنند، در حالی که SAR عمدتاً بر ساختار فیزیکی و بازتاب امواج راداری تمرکز دارد و حساسیت کمتری نسبت به پوشش گیاهی دارد (Song et al., 2021). بنابراین، ترکیب شاخص‌های طیفی و داده‌های نوری می‌تواند به بهبود دقت طبقه‌بندی محصولات کشاورزی کمک کند. با استفاده از داده‌های چند منبعی، تعداد مشاهدات ماهواره‌ای در هر زمین زراعی افزایش می یابد و اطلاعات بیشتری در مورد محصولات ارائه می دهد (Liu et al., 2023). به عبارت دیگر، داده‌های چند منبعی شامل جنبه‌های مختلفی از انواع محصولات، از جمله ویژگی‌های طیفی، فنولوژیکی، فیزیکی و ساختاری است (Woźniak et al., 2022). همه این مزایا توانایی مدل را برای تمایز بین طبقات مختلف و بهبود دقت طبقه‌بندی افزایش می‌دهد. بهبود دقت طبقه‌بندی با ترکیب سری‌های زمانی نوری و SAR نیز در مطالعات دیگر گزارش شده است (Cheng et al., 2023; Sun et al., 2020).

ثانیا، مدل متا در ساختار آبشاری از دانش جمعی از شاخه‌های موازی در ساختار موازی برای تصمیم‌گیری طبقه‌بندی نهایی استفاده کرده است. علاوه بر این، مدل CNN در ساختار آبشاری می‌تواند روابط زیربنایی بین ورودی‌ها را در نظر بگیرد، برخلاف روش‌های ساده مانند رأی اکثریت که به طور گسترده در ادبیات استفاده می‌شود (Kwak et al., 2021; Xu & Zhang, 2022). اهمیت استفاده از یک مدل متا نیز در شکل ۶ مشهود است، جایی که کمترین دقت طبقه‌بندی زمانی به دست آمد که تنها یک FC بدون ساختار آبشاری مورد استفاده قرار گرفت. با بهره‌گیری از مدل‌های یادگیری ماشین و عمیق و ترکیب داده‌های نوری و SAR، این روش توانست نقشه‌های دقیق‌تری از نوع محصولات تولید کند. این بهبود در طبقه‌بندی،

تصمیم‌گیری بهتر در مدیریت کشاورزی، پیش‌بینی عملکرد محصول، و تخصیص بهینه منابع را امکان‌پذیر ساخت. در نتیجه، این روش جدید می‌تواند نقشی کلیدی در تضمین امنیت غذایی، بهینه‌سازی تولیدات کشاورزی، و برنامه‌ریزی استراتژیک در سطح منطقه‌ای ایفا کند. با در نظر گرفتن مجموع نتایج به‌دست‌آمده، می‌توان گفت که ساختار موازی–آبشاری پیشنهادی، با توجه به دقت بالای طبقه‌بندی و کاهش عدم‌قطعیت، راهکاری مؤثر برای بهبود نقشه‌برداری از محصولات زراعی در شمال‌غرب ایران ارائه می‌دهد. این منطقه به دلیل تنوع اقلیمی، کشت مختلط، و استفاده هم‌زمان از سیستم‌های آبی و دیم، همواره یکی از چالش‌برانگیزترین نواحی برای تفکیک محصولات بوده است. نتایج این پژوهش می‌تواند در تفکیک دقیق‌تر این طبقات زراعی، به‌ویژه در شرایط تغییرپذیر پوشش گیاهی و ویژگی‌های فنولوژیکی، نقش کلیدی ایفا کند. از منظر اجرایی، این چارچوب می‌تواند به‌عنوان ابزاری کاربردی برای نهادهای متولی کشاورزی در پایش سطح زیرکشت، تخصیص بهینه منابع آب، و پیش‌بینی عملکرد محصولات مورد استفاده قرار گیرد. همچنین با توجه به بهره‌گیری از داده‌های عمومی و قابل دسترس (مانند Sentinel و Landsat) و ساختار قابل تعمیم مدل، امکان بسط آن به سایر مناطق ایران با شرایط کشاورزی متنوع وجود دارد و می‌تواند در مقیاس منطقه‌ای برای ارتقاء دقت نقشه‌های کشت و توسعه سامانه‌های پایش کشاورزی به‌کار گرفته شود.

نتیجه‌گیری

نقشه برداری از نوع محصول برای تضمین امنیت غذایی و مدیریت موثر کشاورزی ضروری است. داده‌های ماهواره‌ای سنجش از دوری به‌عنوان یک جایگزین امیدوارکننده برای روش‌های سنتی، مانند بررسی‌های میدانی زمان‌بر، برای تولید نقشه‌های نوع محصول پدید آمده‌اند. با این حال، شناسایی دقیق محصولات مختلف در داده‌های ماهواره‌ای چالش‌هایی را به دلیل تغییرات درون و بین طبقات محصول ناشی از عواملی مانند تنوع محصول، شرایط محیطی و شیوه‌های کشاورزی ایجاد می‌کند. در نتیجه، تقاضای فزاینده ای برای شناسایی و توسعه الگوریتم های طبقه‌بندی دقیق تر وجود دارد. این مقاله یک ساختار جدیدی از مدل‌های یادگیری ماشین، به نام ساختار موازی–آبشاری را برای طبقه‌بندی نوع محصول با استفاده از زبان برنامه نویسی پایتون (Python) پیشنهاد کرد. ساختار موازی شامل سه منبع داده بود: S۱، S۲ و L۸/۹. در ساختار موازی، نقشه احتمال برای طبقات هدف مختلف تولید شد. این نقشه ها روی هم انباشته شدند و در نتیجه، مکعب جدید داده حاصل به ساختار آبشاری وارد شدند. ساختار آبشاری از مدل یادگیری ماشین دیگری برای تصمیم گیری طبقه‌بندی نهایی استفاده کرد. روش پیشنهادی نتایج امیدوارکننده‌ای را نشان داد که به رویکردهای طبقه‌بندی نوع محصول معمولی برتری داشت. همچنین نتایج حاکی از کاهش قابل توجه عدم قطعیت طبقه‌بندی طبقات هدف در مقایسه با سایر سازه‌ها بود. ساختار مجموعه پیشنهادی را می‌توان در سطح منطقه‌ای برای تولید نقشه‌های بسیار دقیق محصول افزایش داد. این مدل می‌تواند در سامانه‌های تصمیم‌گیری کشاورزی ادغام شود تا با تحلیل دقیق داده‌های ماهواره‌ای با قدرت تفکیک بالاتر، به کشاورزان در برنامه‌ریزی کشت، مدیریت منابع آب، و پیش‌بینی عملکرد محصولات کمک کند. برای ارزیابی قابلیت انتقال مکانی و زمانی مدل، می‌توان آن را در مناطق جغرافیایی و شرایط اقلیمی مختلف آزمایش کرد (بسته به نوع محصولات رایج آن منطقه) تا میزان عمومی‌سازی آن بررسی شود و امکان به‌کارگیری آن در مطالعات گسترده‌تر و سیاست‌گذاری‌های کشاورزی فراهم گردد.

منابع

Alizadeh, N., Maghsoudi, Y., Managhebi, T., & Azadnejad, S. (2024). Collapse Hotspot Detection in Urban Area Using Sentinel-1 and TerraSAR-X Dataset with SBAS and PSI Techniques. *Land (2012)*, 13(12).

Alizadeh, N., Mahdianpari, M., Hemmati, E., & Marjani ,M. (2025). FusionFireNet: A CNN-LSTM model for short-term wildfire hotspot prediction utilizing spatio-temporal datasets. *Remote Sensing Applications: Society and Environment*, 37, 101436.

Asam, S., Gessner, U., Almengor González, R., Wenzl, M., Kriese ,J., & Kuenzer, C. (2022). Mapping crop types of Germany by combining temporal statistical metrics of Sentinel-1 and Sentinel-2 time series with LPIS data. *Remote sensing*, 14(13), 298.

Asgari, S., & Hasanlou, M. (2023). A Comparative Study of Machine Learning Classifiers for Crop Type Mapping Using Vegetation Indices. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 10, 79-85.

Blickensdörfer, L., Schwieder, M., Pflugmacher, D., Nendel, C., Erasmi, S., & Hostert, P. (2022). Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany. *Remote Sensing of Environment*, 269, 112831.

Cheng, G., Ding, H., Yang, J., & Cheng, Y. (2023). Crop type classification with combined spectral, texture, and radar features of time-series Sentinel-1 and Sentinel-2 data. *International Journal of Remote Sensing*, 44(4), 1215-1237.

Eimanifar, A., & Mohebbi, F. (2007). Urmia Lake (northwest Iran): a brief review. *Saline systems*, 5, 3(1). Erdanaev, E., Kappas, M., & Wyss, D. (2022). Irrigated crop types mapping in Tashkent province of Uzbekistan with remote sensing-based classification methods. *Sensors*, 22(15), 5683.

Feng, S., Zhao, J., Liu, T., Zhang, H., Zhang, Z., & Guo, X. (2019). Crop type identification and mapping using machine learning algorithms and sentinel-2 time series data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(9), 3295-3306.

Hemmati, E., & Sahebi, M. R. (2024). Surface soil moisture retrieval based on transfer learning using SAR data on a local scale. *International Journal of Remote Sensing*, 45(7), 2374-2406.

Hu, J., Chen, Y., Cai, Z., Wei, H., Zhang, X., Zhou, W., Wang, C., You, L., & Xu, B. (2023). Mapping diverse paddy rice cropping patterns in South China using harmonized Landsat and Sentinel-2 data. *Remote sensing*, 15(4), 1034.

Hu, Y., Zeng, H., Tian, F., Zhang, M., Wu, B., Gilliams, S., Li, S., Li, Y., Lu, Y., & Yang, H. (2022). An interannual transfer learning approach for crop classification in the Hetao Irrigation district, China. *Remote sensing*, 14(5), 1208.

Ibrahim, E. S., Rufin, P., Nill, L., Kamali, B., Nendel, C., & Hostert, P. (2021). Mapping crop types and cropping systems in Nigeria with Sentinel-2 imagery. *Remote sensing*, 13(17), 3523.

Jafarzadeh, H., Mahdianpari, M., Gill, E., Mohammadimanesh, F., & Homayouni, S. (2021). Bagging and boosting ensemble classifiers for classification of multispectral, hyperspectral and PolSAR data: a comparative evaluation. *Remote sensing*, 13(21), 4405.

Kadri, N., Jebari, S., Augusseau, X., Mahdhi, N., Lestrelin, G., & Berndtsson, R. (2023). Analysis of four decades of land use and land cover change in semiarid Tunisia using Google Earth engine. *Remote Sensing*, 15(13), 3257.

Karimi, N., Sheshangosht, S., & Eftekhari, M. (2022). Crop type detection using an object-based classification method and multi-temporal Landsat satellite images. *Paddy and Water Environment*, 20(3), 395-412.

Kobayashi, N., Tani, H., Wang, X & ,.Sonobe, R. (2020). Crop classification using spectral indices derived from Sentinel-2A imagery. *Journal of Information and Telecommunication*, 4(1), 67-90.

Komura, N., Matsumoto, K., Igari, S., Ogawa, T., Fujita, S., & Nakamoto, K. (2023). Computer aided process planning for rough machining based on machine learning with certainty evaluation of inferred results. *International Journal of Automation Technology*, 17(2), 120-127.

Kussul, N., Lavreniuk, M., Skakun, S., & Shelestov, A. (2017). Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778-782.

Kwak, G.-H., Park, C.-w., Lee, K.-d., Na, S.-i., Ahn, H.-y., & Park, N.-W. (2021). Potential of hybrid CNN-RF model for early crop mapping with limited input data. *Remote sensing*, 13(9), 1629.

Lin, C., Zhong, L., Song, X.-P., Dong, J., Lobell, D. B., & Jin, Z. (2022). Early-and in-season crop type mapping without current-year ground truth: Generating labels from historical information via a topology-based approach. *Remote Sensing of Environment*, 274, 112994.

Liu, X., Hu, G., Chen, Y., Li, X., Xu, X., Li, S., Pei, F., & Wang, S. (2018). High-resolution multi-temporal mapping of global urban land using Landsat images based on the Google Earth Engine Platform. *Remote Sensing of Environment*, 209, 227-239.

Liu, X., Xie, S., Yang, J., Sun, L., Liu, L., Zhang, Q., & Yang, C. (2023). Comparisons between temporal statistical metrics, time series stacks and phenological features derived from NASA Harmonized Landsat Sentinel-2 data for crop type mapping. *Computers and Electronics in Agriculture*, 211, 108015.

Luo, K., Lu, L., Xie, Y., Chen, F., Yin, F., & Li, Q. (2023). Crop type mapping in the central part of the North China Plain using Sentinel-2 time series and machine learning. *Computers and Electronics in Agriculture*, 205, 107577.

Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817.

Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., & Reiche, J. (2021). Sentinel-1 sar backscatter analysis ready data preparation in google earth engine. *Remote Sensing*, 13(10), 1954.

Nabil, M., Farg, E., Arafat, S. M., Aboelghar, M., Afify, N. M., & Elsharkawy, M. M. (2022). Tree-fruits crop type mapping from Sentinel-1 and Sentinel-2 data integration in Egypt's New Delta project. *Remote Sensing Applications: Society and Environment*, 27, 100776.

Ofori-Ampofo, S., Pelletier, C., & Lang, S. (2021). Crop type mapping from optical and radar time series using attention-based deep learning. *Remote sensing*, 13(22), 4668.

Panjala, P., Gumma, M. K., & Teluguntla, P. (2022). Machine learning approaches and sentinel-2 data in crop type mapping. *Data science in agriculture and natural resource management*, 161-180.

Phinzi, K., Abriha, D., & Szabó, S. (2021). Classification efficacy using k-fold cross-validation and bootstrapping resampling techniques on the example of mapping complex gully systems. *Remote sensing*, 13(15), 2980.

Pott, L. P., Amado, T. J. C., Schwalbert, R. A., Corassa, G.M., & Ciampitti, I.A. (2022). Crop type classification in Southern Brazil: Integrating remote sensing, crop modeling and machine learning. *Computers and Electronics in Agriculture*, 201, 107320.

Rahman, M. M., & Robson, A. (2020). Integrating landsat-8 and sentinel-2 time series data for yield prediction of sugarcane crops at the block level. *Remote sensing*, 12(8), 1313.

Soltani, M., Rahmani, O., Ghasimi, D. S., Ghaderpour, Y., Pour, A. B., Misnan, S. H., & Ngah, I. (2020). Impact of household demographic characteristics on energy conservation and carbon dioxide emission: Case from Mahabad city, Iran. *Energy*, 194, 116916.

Song, X.-P., Huang, W., Hansen, M. C., & Potapov, P. (2021). An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping. *Science of Remote Sensing*, 3, 100018.

Stournaras, S., Loukatos, D ,.Arvanitis, K. G., & Kalatzis, N. (2022). Crop identification by machine learning algorithm and sentinel-2 data. *Chemistry Proceedings*, 10(1), 20.

Sun, C., Bian, Y., Zhou, T., & Pan, J. (2019). Using of multi-source and multi-temporal remote sensing data improves crop-type mapping in the subtropical agriculture region. *Sensors*, 19(10), 2401.

Sun, L., Chen, J., Guo, S., Deng, X., & Han, Y. (2020). Integration of time series sentinel-1 and sentinel-2 imagery for crop type mapping over oasis agricultural areas. *Remote sensing*, 12(1), 158.

Tariq, A., Yan, J., Gagnon, A. S., Riaz Khan, M., & Mumtaz, F. (2023). Mapping of cropland, cropping patterns and crop types by combining optical remote sensing images with decision tree classifier and random forest. *Geo-Spatial Information Science*, 26(3), 302-320.

Topaloğlu, R. H., Sertel, E., & Musaoğlu, N. (2016). Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover/use mapping. *The International archives of the photogrammetry, remote sensing and spatial information sciences*, 41, 1055-1059.

Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., Potin, P., Rommen, B., Floury, N., & Brown, M. (2012). GMES Sentinel-1 mission. *Remote Sensing of Environment*, 120, 9-24.

Tufail, R., Ahmad, A., Javed, M. A., & Ahmad, S. R. (2022). A machine learning approach for accurate crop type mapping using combined SAR and optical time series data. *Advances in Space Research*, 69(1), 331-346.

Wei, P., Ye, H., Qiao, S., Liu, R., Nie, C., Zhang, B., Song, L., & Huang, S. (2023). Early crop mapping based on Sentinel-2 time-series data and the random forest algorithm. *Remote sensing*, 15(13), 3212.

Woźniak, E., Rybicki, M., Kofman, W., Aleksandrowicz, S., Wojtkowski, C., Lewiński, S ,. Bojanowski, J., Musiał, J., Milewski, T., & Slesiński, P. (2022). Multi-temporal phenological indices derived from time series Sentinel-1 images to country-wide crop classification. *International Journal of Applied Earth Observation and Geoinformation*, 107, 102683.

Xiang, J., Liu, J., Chen, D., Xiong, Q., & Deng, C. (2023). CTFuseNet: A multi-scale CNN-transformer feature fused network for crop type segmentation on UAV remote sensing imagery. *Remote sensing*, 15(4), 1151 .

Xu, D., & Zhang, M. (2022). Mapping paddy rice using an adaptive stacking algorithm and Sentinel-1/2 images based on Google Earth Engine. *Remote Sensing Letters*, 13(4), 373-382.

Zhang, B., Wu, Y., Zhao, B., Chanussot, J., Hong, D., Yao, J., & Gao, L. (2022). Progress and challenges in intelligent remote sensing satellite systems. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 1814-1822.

Zhang, C., Di, L., Lin, L., Li, H., Guo, L., Yang, Z., Yu, E. G., Di, Y., & Yang, A. (2022). Towards automation of in-season crop type mapping using spatiotemporal crop information and remote sensing data. *Agricultural Systems*, 201, 103462.

Zhang, J., He, Y., Yuan, L., Liu, P., Zhou, X., & Huang, Y. (2019). Machine learning-based spectral library for crop classification and status monitoring. *Agronomy*, 9(9), 496.

Zhang, P., Hu, S., Li, W., Zhang, C., & Cheng, P. (2021). Improving parcel-level mapping of smallholder crops from vhsr imagery: An ensemble machine-learning-based framework. *Remote sensing*, *13*(11), 2146.

Zhang, Y., Liu, J., & Shen, W. (2022). A review of ensemble learning algorithms used in remote sensing applications. *Applied Sciences*, 12(17), 8654.