



## Strawberry Crop Classification Using Sentinel-2 Satellite Imagery and a CNN Deep Learning Algorithm: A Phenology-Based Local Approach

Amir Aghabalaee<sup>1</sup>, Jahede Tekyeh Khah<sup>2</sup>, Shler Katorani<sup>3</sup>, Ali Mohtadi<sup>4</sup>

1. Corresponding Author, Assistant Professor, Imam Hossein Comprehensive University, Tehran, Iran. E-mail: [remotesensing@ihu.ac.ir](mailto:remotesensing@ihu.ac.ir)
2. Assistant Professor, Jihad University of Kurdistan, Sanandaj, Iran. E-mail: [jahede2007@yahoo.com](mailto:jahede2007@yahoo.com)
3. Ph.D. Student, Shahid Beheshti University, Tehran, Iran. E-mail: [sh.katorani99@gmail.com](mailto:sh.katorani99@gmail.com)
4. M.Sc. in Remote Sensing, Hekmat Higher Educational Institution, Qom, Iran. E-mail: [mohtadi1375@gmail.com](mailto:mohtadi1375@gmail.com)

### Article Info

#### Article type:

Research Article

#### Article history:

Received: 5 June 2025

Revised: 18 October 2025

Accepted: 30 December 2025

Published: 4 January 2026

#### Keywords:

Crop classification,  
Strawberry,  
Convolutional Neural  
Network,  
Time series,  
Deep learning.

### ABSTRACT

**Objective:** The aim of this study is to develop and evaluate a hybrid deep learning-based model for accurate classification of strawberry crops using Sentinel-2 satellite time-series imagery and indigenous phenological data in Kurdistan Province. The primary motivation for designing the model lies in the spatial identification of crops with limited distribution and specific growth cycles. Additionally, the study attempts to assess the model's performance under diverse spatial and regional climatic conditions.

**Methods:** Ground truth data were collected and labeled during the 2022 growing season using GPS and the regional agricultural calendar. Selected Sentinel-2 images temporally aligned with the phenological stages of strawberry growth underwent geometric, radiometric, and atmospheric preprocessing. These data were then fed into a Convolutional Neural Network (CNN) consisting of three convolutional layers, one pooling layer, two fully connected layers, and a Softmax output function. To address class imbalance, class weighting techniques and grid search optimization were employed. Data augmentation was also utilized to enhance the model's generalizability. The training process was conducted using the Adam optimizer with a learning rate of 0.0001 over 150 epochs.

**Results:** The proposed model successfully classified 15 land use/land cover classes with an overall accuracy of 96.57 percent and a Kappa coefficient of 0.8582. For the target class—strawberry—the F1-score reached 86.4 percent, indicating a favorable balance between precision and recall. The model demonstrated strong performance in identifying crops with limited cultivated areas and irregular spatial structures, although accuracy declined in classes such as greenhouses and rangelands due to high spectral heterogeneity. Error analysis revealed that most misclassifications occurred at spectrally similar boundaries and during climatic fluctuations in the growth period.

**Conclusions:** The findings indicate that integrating satellite time-series data with an optimized CNN architecture and local phenological knowledge provides an efficient and generalizable approach for classifying specific agricultural products. This model can be effectively used in smart agricultural monitoring systems, land use planning, geospatial decision-making, and crop pattern analysis. Moreover, it can serve as a foundation for developing advanced tools in data-driven agriculture and contribute to regional policy-making and the sustainable management of natural resources.

**Cite this article:** Aghabalaee, A., Tekyeh Khah, J., Katorani, Sh., & Mohtadi, A. (2026). Strawberry Crop Classification Using Sentinel-2 Satellite Imagery and a CNN Deep Learning Algorithm: A Phenology-Based Local Approach. *Journal of Remote Sensing and GIS Applications in Environmental Sciences*, 6(18), 78-96. <http://doi.org/10.22034/rsgi.2025.67701.1140>



© The Author(s).

DOI: <http://doi.org/10.22034/rsgi.2025.67701.1140>

Publisher: University of Tabriz.



## Introduction

Accurate classification of agricultural crops using remote sensing technologies is a crucial requirement for enhancing land management, optimizing agricultural planning, and ensuring food security. The advent of advanced satellite platforms and artificial intelligence methods—particularly deep learning—has significantly improved land cover mapping capabilities. Nonetheless, certain crops like strawberries, which exhibit short seasonal growth cycles and limited spatial distribution, pose persistent challenges for classification algorithms due to their spectral similarity with other vegetation types and sparse field presence.

Strawberries are a key strategic and export-oriented crop in regions such as Kurdistan Province, Iran. Their precise monitoring and classification have economic, ecological, and policy implications. Conventional classification models, including decision trees and Support Vector Machines (SVM), often underperform when dealing with imbalanced datasets and spectrally similar vegetation classes. These models typically rely on handcrafted features, limited temporal imagery, and fail to incorporate phenological insights, reducing their generalizability and classification accuracy.

Recent advances in deep learning—especially Convolutional Neural Networks (CNNs)—have demonstrated superior performance in extracting spatiotemporal features from satellite imagery. When combined with phenological calendars and domain-specific knowledge, these models provide an opportunity to enhance crop mapping at a regional scale.

The current study addresses these limitations by developing a CNN-based classification framework that leverages Sentinel-2 time-series imagery and local phenological data for the spatial and temporal identification of strawberry fields across four key agricultural districts in Kurdistan Province: Sanandaj, Marivan, Sarvabad, and Kamyaran.

## Materials and Methods

The methodology integrates three core components: high-resolution multi-temporal Sentinel-2 imagery, precise ground-truth data obtained via GPS and field surveys, and a carefully optimized CNN architecture.

- 1. Study Area and Data Collection:** The research area spans four agricultural regions within Kurdistan Province, known for their climatic diversity, topographic complexity, and active strawberry cultivation. Ground samples were collected during the 2022 growing season in coordination with the regional agricultural calendar. These samples were digitized into polygon features and converted into raster labels suitable for model training and evaluation.
- 2. Satellite Imagery Preprocessing:** A total of 54 Sentinel-2 images were selected across the regions, filtered to minimize cloud coverage and maximize overlap with critical phenological phases, such as planting, flowering, and harvesting. Images underwent geometric correction, radiometric normalization, atmospheric correction, and topographic adjustment. Only bands relevant for vegetation monitoring (e.g., red-edge, NIR, and SWIR) were retained.
- 3. Model Architecture and Training:** The CNN model comprises three convolutional layers (kernel size: 3x3, filters: 16, 32, and 64), one max-pooling layer, two fully connected layers (Dense-128), and a Softmax classifier. Activation functions include ReLU and Softmax, and a dropout layer (rate: 0.5) was inserted between fully connected layers to prevent overfitting.
- 4. To tackle class imbalance, especially due to the limited representation of strawberry fields, a class weighting technique was used. Model training employed the Adam optimizer (learning rate: 0.0001) and categorical cross-entropy loss over 150 epochs with a batch size of 32. Early stopping was implemented to enhance generalizability.**
- 5. Validation and Evaluation Metrics:** The model's performance was assessed using metrics such as Overall Accuracy (OA), Kappa coefficient, Precision, Recall, and F1-score. Ground-truth data were divided into 60 percent for training and 40 percent for validation and testing. Stratified random sampling ensured unbiased distribution across all 15 land-use classes.



## Results

The trained CNN model achieved an Overall Accuracy of 96.57 percent and a Kappa coefficient of 0.8582 across all classes. For the strawberry class specifically, the Precision was 88 percent, Recall 85 percent, and F1-score 86.4 percent, indicating robust performance despite the limited and spatially scattered nature of strawberry fields.

The classification results revealed high discriminability for well-defined vegetation types such as irrigated orchards, urban areas, and water bodies ( $F1 > 90$  percent). However, lower classification accuracies were observed for heterogeneous and spectrally overlapping classes like rangelands and greenhouses. These discrepancies highlight the challenge of spectral confusion in fine-scale mixed pixels and suggest a need for multi-source data fusion in future work.

Visual inspection of classification maps for each district confirmed spatial coherence between the predicted and actual land cover. Regions with clear phenological transitions yielded higher classification confidence, whereas visually ambiguous areas such as marginal lands and fragmented plots exhibited increased confusion.

The spatial distribution maps generated through this study offer valuable inputs for crop monitoring and land management programs. Additionally, the derived area estimates for strawberry cultivation align closely with local agricultural records, affirming the model's practical relevance.

## Conclusion

This research successfully demonstrates that integrating time-series Sentinel-2 imagery with a phenology-informed CNN architecture can significantly improve crop classification accuracy, especially for region-specific, low-area crops like strawberries.

The study's key contributions are as follows:

- It bridges the gap between remote sensing data and local agricultural knowledge through phenology-based data selection.
- It proposes a CNN architecture tailored for high-resolution, multi-temporal imagery and optimized through parameter tuning techniques.
- It delivers accurate land cover classification maps that can serve as reliable decision-making tools for local authorities and agribusiness stakeholders.

Despite its success, the study identifies several avenues for improvement. The CNN model struggles with heterogeneous classes and structurally diverse land uses, such as greenhouses, due to spatial fragmentation and spectral noise. Future studies should explore multi-source data integration, including Synthetic Aperture Radar (SAR) and hyperspectral imagery, to mitigate these limitations.

Moreover, the generalizability of the current framework to other regions or crops requires further validation. Incorporating transfer learning or pre-trained models may enhance performance in data-scarce environments. Additionally, the use of attention mechanisms and graph-based neural networks could improve interpretability and contextual awareness in complex landscapes.

Ultimately, this study underscores the potential of AI-driven frameworks in transforming agricultural monitoring practices in Iran and beyond. By aligning technological innovation with local agronomic realities, it paves the way for scalable, precise, and efficient agri-intelligence solutions that address national food security and sustainability goals.

## References

- Ahangarha, M., Saadat Seresht, M., Shahhoseini, R., & Seyyedi, S. (2020). Crop land change monitoring based on deep learning algorithm using multi-temporal hyperspectral images. *Journal of Geomatics Science and Technology*, 10(2), 79–89. (In Persian) <https://dor.isc.ac/dor/20.1001.1.2322102.1399.10.2.6.9>
- Alipour, F., Aghkhani, M., Abbaspour, F. M., & Sepehr, A. (2015). *Demarcation and estimation of agricultural lands using ETM+ imagery data (case study: Astan Ghods Razavi great farm)*. (In Persian). <https://dor.isc.ac/dor/20.1001.1.22286829.1393.4.2.12.8>



- An, Q., Wang, K., Li, Z., Song, C., Tang, X., & Song, J. (2022). Real-time monitoring method of strawberry fruit growth state based on YOLO improved model. *IEEE Access*, 10, 124363–124372. <https://doi.org/10.1109/ACCESS.2022.3220234>
- Anjom, F. K., Vougioukas, S., & Slaughter, D. C. (2018). Development and application of a strawberry yield-monitoring picking cart. *Computers and Electronics in Agriculture*, 155(2), 400–411. <http://dx.doi.org/10.1016/j.compag.2018.10.038>
- Bargiel, D. (2017). A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sensing of Environment*, 198, 369–383. <https://doi.org/10.1016/j.rse.2017.06.022>
- Chang, C.-I. (2007). *Hyperspectral data exploitation: Theory and applications*. John Wiley & Sons. DOI:10.1002/0470124628
- Chen, Y., Wu, X., & Xu, Q. (2024). A hybrid deep learning model based on Bi-LSTM for crop type classification in smallholder farms using multi-temporal satellite data. *PLoS ONE*, 19(3), e0299350. <https://doi.org/10.1371/journal.pone.0299350>
- Constante, P. N., Gordon, A., Chang, O., & Pruna, E. (2016). Artificial vision techniques to optimize strawberry's industrial classification. *IEEE Latin America Transactions*, 14(6), 2576–2581. <http://dx.doi.org/10.1109/TLA.2016.7555221>
- Csillik, O., & Belgiu, M. (2017). Cropland mapping from Sentinel-2 time series data using object-based image analysis. In *Proceedings of the 20th AGILE International Conference on Geographic Information Science Societal Geo-Innovation Celebrating* (Vol. 9, p. 20). Wageningen, The Netherlands.
- Du, X., Cheng, H., Ma, Z., Lu, W., Wang, M., Meng, Z., Jiang, C., & Hong, F. (2023). DSW-YOLO: A detection method for ground-planted strawberry fruits under different occlusion levels. *Computers and Electronics in Agriculture*, 214, 108304. <https://doi.org/10.1016/j.compag.2023.108304>
- Gadiraju, K. K., & Vatsavai, R. R. (2020). Comparative analysis of deep transfer learning performance on crop classification. In *Proceedings of the 9th ACM SIGSPATIAL International Workshop on Analytics for Big Geospatial Data* (pp. 1–8). <https://doi.org/10.1145/3423336.3431369>
- Heidari, M., tashakori, M. and Valipour, A. (2016). Investigating the local utilization of forest in north Zagros (Case study: Baneh Region). *Iranian Journal of Forest*, 8(3), 313-331. (In Persian) [https://www.ijf-isaforestry.ir/article\\_42271.html?lang=en](https://www.ijf-isaforestry.ir/article_42271.html?lang=en)
- Kang, Y., Khan, S., & Ma, X. (2009). Climate change impacts on crop yield, crop water productivity and food security: A review. *Progress in Natural Science*, 19(12), 1665–1674. <https://doi.org/10.1016/j.pnsc.2009.08.001>
- Khatami, R., Mountrakis, G., & Stehman, S. V. (2017). Mapping per-pixel predicted accuracy of classified remote sensing images. *Remote Sensing of Environment*, 191, 156–167. <http://dx.doi.org/10.1016/j.rse.2017.01.025>
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. <https://doi.org/10.48550/arXiv.1412.6980>
- Li, Z., Wang, J., Gao, G., Lei, Y., Zhao, C., Wang, Y., Bai, H., Liu, Y., Guo, X., & Li, Q. (2024). SGSNet: A lightweight deep learning model for fast and accurate detection of strawberry growth stages. *Frontiers in Plant Science*, 15, 1491706. <https://doi.org/10.3389/fpls.2024.1491706>
- Lyu, H., Lu, H., & Mou, L. (2016). Learning a transferable change rule from a recurrent neural network for land cover change detection. *Remote Sensing*, 8(6), 506. <https://doi.org/10.3390/rs8060506>
- Saleem, N., Balu, A., Jubery, T. Z., Singh, A., Singh, S. K., Sarkar, S., & Ganapathysubramanian, B. (2024). Class-specific data augmentation for plant stress classification in soybean. *bioRxiv*. <https://doi.org/10.1101/2024.06.18.549378>
- Wang, C., Wang, H., Han, Q., Zhang, Z., Kong, D., & Zou, X. (2024). Strawberry Detection and Ripeness Classification Using YOLOv8+ Model and Image Processing Method. *Agriculture*, 14(5), 751. <https://doi.org/10.3390/agriculture14050751>



**Journal of Remote Sensing and GIS  
Applications  
in Environmental Sciences**  
[rsgi.tabrizu.ac.ir](http://rsgi.tabrizu.ac.ir)



- Xu, J., et al. (2020). DeepCropMapping: A multi-temporal deep learning approach with improved spatial generalizability for dynamic corn and soybean mapping. *Remote Sensing of Environment*, 247, 111946. <https://doi.org/10.1016/j.rse.2020.111946>
- Zheng, B., Myint, S. W., Thenkabail, P. S., & Aggarwal, R. M. (2015). A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. *International Journal of Applied Earth Observation and Geoinformation*, 34, 103–112. <https://doi.org/10.1016/j.jag.2014.07.002>



## طبقه‌بندی محصول توت‌فرنگی با استفاده از تصاویر ماهواره‌ای سنتینل-۲ و الگوریتم یادگیری عمیق CNN، رویکردی مبتنی بر داده‌های فنولوژیک محل

امیر آقابالائی<sup>۱</sup>، جاهده تکیه‌خواه<sup>۲</sup>، شلیر کاتورانی<sup>۳</sup>، علی مهتدی<sup>۴</sup>

۱. نویسنده مسئول، استادیار، دانشگاه جامع امام حسین (ع)، تهران، ایران. رایانامه: [remotesensing@ihu.ac.ir](mailto:remotesensing@ihu.ac.ir)

۲. استادیار، جهاد دانشگاهی کردستان، سنندج، ایران. رایانامه: [jahede2007@yahoo.com](mailto:jahede2007@yahoo.com)

۳. دانشجوی دکتری، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: [sh.katorani99@gmail.com](mailto:sh.katorani99@gmail.com)

۴. کارشناس ارشد سنجش از دور، موسسه آموزش عالی حکمت، قم، ایران. رایانامه: [mohetadi1375@gmail.com](mailto:mohetadi1375@gmail.com)

### اطلاعات مقاله چکیده

نوع مقاله:

مقاله پژوهشی

**هدف:** هدف این پژوهش، توسعه و ارزیابی یک مدل ترکیبی مبتنی بر یادگیری عمیق جهت طبقه‌بندی دقیق محصول توت‌فرنگی با استفاده از تصاویر سری‌زمانی ماهواره سنتینل-۲ و داده‌های فنولوژیکی بومی در استان کردستان است. تمرکز بر شناسایی مکانی محصولات با پراکنش محدود و چرخه رشد خاص، انگیزه اصلی طراحی مدل در این تحقیق بوده است. علاوه بر این، تلاش شده است تا کارایی مدل در شرایط مکانی متنوع و اقلیمی منطقه‌ای نیز مورد بررسی قرار گیرد.

تاریخ دریافت: ۱۴۰۴/۰۳/۱۵

تاریخ بازنگری: ۱۴۰۴/۰۷/۲۶

تاریخ پذیرش: ۱۴۰۴/۱۰/۰۹

تاریخ انتشار: ۱۴۰۴/۱۰/۱۴

**روش پژوهش:** ابتدا داده‌های زمینی در فصل زراعی ۱۴۰۱ از طریق GPS و تقویم زراعی منطقه گردآوری و برچسب‌گذاری شدند. سپس تصاویر منتخب سنتینل-۲ که از لحاظ زمانی با مراحل فنولوژیکی رشد توت‌فرنگی هم‌پوشانی داشتند، تحت پیش‌پردازش‌های هندسی، رادیومتریکی و اتمسفری قرار گرفتند. این داده‌ها به‌عنوان ورودی به یک شبکه عصبی کانولوشنی با سه لایه کانولوشن، یک لایه Pooling، دو لایه تماماً متصل و تابع خروجی Softmax معرفی شدند. برای مقابله با نامتوانی کلاس‌ها، از تکنیک وزن‌دهی کلاس و بهینه‌سازی پارامترها با روش جستجوی شبکه‌ای استفاده شد. همچنین از داده‌افزایی برای بهبود تعمیم‌پذیری مدل بهره گرفته شد. فرایند آموزش با الگوریتم Adam و نرخ یادگیری ۰/۰۰۰۱ در طی ۱۵۰ اپک انجام شد.

کلیدواژه‌ها:

طبقه‌بندی محصول،

شبکه عصبی کانولوشنی،

توت‌فرنگی،

سری زمانی،

یادگیری عمیق.

**نتایج:** مدل پیشنهادی موفق به طبقه‌بندی ۱۵ کلاس کاربری اراضی با دقت کلی ۹۶/۵۷ درصد و ضریب کاپای ۰/۸۵۸۲ گردید. برای کلاس هدف یعنی توت‌فرنگی، شاخص F1 معادل ۸۶/۴ درصد به‌دست آمد که نشان‌دهنده تعادل مطلوب میان دقت و یادآوری است. همچنین عملکرد مدل در طبقه‌بندی محصولات با سطح زیرکشت محدود و ساختار مکانی غیرمنظم قابل توجه بوده است، اگرچه در کلاس‌هایی مانند گلخانه‌ها و مراتع با ناهمگنی طیفی بالا، دقت کاهش یافته است. تحلیل خطا نیز نشان داد که بخش عمده اشتباهات مربوط به مرزهای طیفی مشابه و نوسانات اقلیمی دوره رشد بوده است.

**نتیجه‌گیری:** یافته‌ها نشان می‌دهند که ترکیب داده‌های سری‌زمانی ماهواره‌ای با معماری بهینه شبکه عصبی کانولوشنی و دانش بومی فنولوژیکی، می‌تواند رویکردی کارآمد و قابل تعمیم برای طبقه‌بندی محصولات کشاورزی خاص فراهم آورد. این مدل، قابلیت استفاده در سامانه‌های پایش هوشمند کشاورزی، آمایش سرزمین، تصمیم‌سازی مکان‌محور و تحلیل الگوی کشت را دارا بوده و می‌تواند به‌عنوان زیربنای طراحی ابزارهای پیشرفته در کشاورزی داده‌محور عمل نماید. همچنین در بهبود سیاست‌گذاری‌های منطقه‌ای و ارتقاء بهره‌وری منابع طبیعی مؤثر خواهد بود.

**استناد:** آقابالائی، امیر؛ تکیه‌خواه، جاهده؛ کاتورانی، شلیر و مهتدی، علی (۱۴۰۵). طبقه‌بندی محصول توت‌فرنگی با استفاده از تصاویر ماهواره‌ای سنتینل-۲ و الگوریتم یادگیری عمیق CNN، رویکردی مبتنی بر داده‌های فنولوژیک محل. کاربرد سنجش از دور و سیستم اطلاعات جغرافیایی در علوم محیطی، ۶ (۱۸)، ۷۸-۹۶.

<http://doi.org/10.22034/rsgi.2025.67701.1140>



© نویسندگان.

ناشر: دانشگاه تبریز.

## مقدمه

طبقه‌بندی دقیق محصولات کشاورزی با استفاده از داده‌های سنجنش‌ازدور، نقشی اساسی در مدیریت منابع، برنامه‌ریزی زراعی و ارتقاء امنیت غذایی ایفا می‌کند. با پیشرفت فناوری‌های ماهواره‌ای و روش‌های هوش مصنوعی، به‌ویژه یادگیری عمیق، امکان تولید نقشه‌های پوشش زمین با دقت بالا فراهم شده است. در مطالعات منابع طبیعی، داده‌های سنجنش‌ازدور علاوه بر پایش تغییرات کاربری اراضی، برای تحلیل اثر فعالیت‌های انسانی نیز به کار می‌رود. حیدری و همکاران (۲۰۱۶) در بررسی جنگل‌های زاگرس شمالی نشان دادند که بهره‌برداری‌های محلی و فشارهای انسانی از عوامل مؤثر بر تغییر پوشش زمین هستند؛ یافته‌ای که ضرورت استفاده از داده‌های مکانی دقیق را برای پایش تغییرات کاربری در اراضی کشاورزی برجسته می‌کند.

با این حال، محصولات توت‌فرنگی که دارای چرخه رشد فصلی، پراکنش مکانی محدود و ویژگی‌های طیفی مشابه با سایر پوشش‌های گیاهی هستند، همچنان چالشی برای الگوریتم‌های طبقه‌بندی محسوب می‌شوند (آهنگرها و همکاران، ۱۳۹۹) و (علیپور و همکاران، ۱۳۹۳). در همین زمینه، مدلی مبتنی بر YOLO برای تشخیص مراحل رشد توت‌فرنگی در محیط‌های طبیعی ارائه شد که دقت بالایی داشت (آن و همکاران، ۲۰۲۲). در حوزه صنعتی نیز، با بهره‌گیری از تکنیک‌های بینایی ماشین، فرایند طبقه‌بندی توت‌فرنگی در خطوط پردازش صنعتی بهبود داده شد (کنستانته و همکاران، ۲۰۱۶).

در بسیاری از مطالعات پیشین، از داده‌های کم‌زمان یا تک‌تصویری استفاده شده که توانایی مدل را در شناسایی مراحل مختلف فنولوژیک کاهش داده است (علیپور و همکاران، ۱۳۹۳) و (ژنگ و همکاران، ۲۰۱۵). همچنین، مدل‌های سنتی مانند ماشین بردار پشتیبان و درخت تصمیم، به دلیل نیاز به مهندسی دستی ویژگی‌ها و عملکرد ضعیف در برابر داده‌های نامتوازن، با محدودیت‌هایی مواجه‌اند (خاتمی، مونتراکیش و استهمن، ۲۰۱۷ و شو و همکاران، ۲۰۲۰). در مقابل، شبکه‌های عصبی کانولوشنی با قابلیت استخراج خودکار الگوهای مکانی و زمانی، رویکردی مؤثر در طبقه‌بندی محصولات کشاورزی پیچیده معرفی شده‌اند (لیو، لو و مو، ۲۰۱۶ و چانگ، ۲۰۰۷). با این حال، کاربرد شبکه عصبی کانولوشنی در طبقه‌بندی دقیق محصولات کشاورزی پیچیده مانند توت‌فرنگی، آن هم مبتنی بر سری‌های زمانی سنتینل-۲ در مقیاس منطقه‌ای، کمتر مورد توجه قرار گرفته است. دوو و همکارانش (۲۰۲۳) نیز مدل DSW-YOLO را برای تشخیص میوه‌های توت‌فرنگی در شرایط انسداد مختلف توسعه دادند که عملکرد بالایی در تشخیص دقیق میوه‌ها در محیط‌های پیچیده مزرعه‌ای نشان داد. انجم، ووگیوکاس و اسلاتر (۲۰۱۸) نیز سیستمی برای برداشت و نقشه‌برداری عملکرد توت‌فرنگی طراحی کرده بودند که از داده‌های GPS و سنسورها استفاده می‌کرد.

در پاسخ به این شکاف، پژوهش حاضر با هدف توسعه یک روش ترکیبی مبتنی بر شبکه عصبی کانولوشنی طراحی شده که از تصاویر سری‌زمانی سنتینل-۲، تقویم زراعی محلی و وزن‌دهی کلاس‌های کم‌نمونه برای استخراج دقیق نقشه توت‌فرنگی بهره می‌گیرد. استفاده از داده‌های میدانی دقیق و بهینه‌سازی معماری شبکه، از نوآوری‌های کلیدی این تحقیق محسوب می‌شود. این مدل می‌تواند پایه‌ای برای توسعه سیستم‌های پایش هوشمند کشاورزی در مقیاس منطقه‌ای فراهم آورد.

## هدف تحقیق

هدف اصلی این پژوهش، طراحی، پیاده‌سازی و ارزیابی یک مدل یادگیری عمیق مبتنی بر شبکه عصبی کانولوشنی برای طبقه‌بندی دقیق محصول توت‌فرنگی با استفاده از تصاویر چندزمانه سنتینل-۲ و داده‌های میدانی مرجع است.

برای دستیابی به این هدف، سه محور کلیدی در نظر گرفته شده است:

۱. استفاده از داده‌های چندزمانه و فنولوژیکی: بهره‌گیری از اطلاعات طیفی سری‌زمانی و شاخص‌های فنولوژیک به منظور بازنمایی دقیق مراحل رشد توت‌فرنگی و تمایز آن از سایر پوشش‌های زمینی، شامل باغات، مراتع، آیش، گلخانه‌ها و سایر محصولات زراعی.

۲. رفع محدودیت‌های روش‌های سنتی: غلبه بر چالش‌هایی نظیر:

- وابستگی شدید به داده‌های محدود زمانی،

- دشواری تشخیص محصولات با سطح زیر کشت کم یا رفتار طیفی مشابه،
- نادیده گرفتن تقویم رشد گیاه در طراحی مدل‌های طبقه‌بندی.

۳. بهینه‌سازی مدل از منظر یادگیری ماشین: تنظیم ساختار شبکه، پارامترهای آموزش، روش‌های نرمال‌سازی و تکنیک‌های مقابله با عدم تعادل کلاس‌ها به گونه‌ای که مدل نهایی از دقت و قابلیت تعمیم بالایی برخوردار باشد.

در نهایت، این پژوهش در پی ارائه مدلی کاربردی و قابل استقرار است که نه تنها در منطقه مورد مطالعه، بلکه به عنوان چارچوبی بومی‌سازی شده و قابل تعمیم در مقیاس محلی و ناحیه‌ای، برای پایش محصولات خاص کشاورزی توسط دستگاه‌های اجرایی، سامانه‌های تصمیم‌یار و مراکز پایش کشاورزی مورد استفاده قرار گیرد.

### پیشینه پژوهش

طبقه‌بندی محصولات کشاورزی با استفاده از تصاویر ماهواره‌ای، به‌ویژه در مناطق با تنوع فنولوژیک بالا، از مسائل پیچیده و چالشی در سنجش‌ازدور محسوب می‌شود. وجود پوشش‌های گیاهی با رفتار طیفی مشابه، پراکنش مکانی محدود برخی محصولات، و فقدان داده‌های زمینی گسترده، دقت طبقه‌بندی را کاهش می‌دهد و نیاز به مدل‌های هوشمند با درک مکانی - زمانی بالا را تشدید می‌کند (بارگیل، ۲۰۱۷؛ خاتمی، مونتراکیش و استهمن، ۲۰۱۷). طبقه‌بندی دقیق محصولات کشاورزی در تصاویر ماهواره‌ای، به‌ویژه در شرایطی که تنوع فنولوژیک بالاست، پراکنش مزارع محدود است یا محصولات رفتار طیفی مشابه دارند، همواره یکی از چالش‌های مهم سنجش‌ازدور در کشاورزی بوده است.

برای پاسخ به این چالش‌ها، پژوهش‌های متعددی طی سال‌های اخیر انجام شده است. در پژوهش علی‌پور و همکاران (۱۳۹۳) از تصاویر اپتیک با الگوریتم شبکه عصبی مصنوعی برای طبقه‌بندی محصولات تابستانه استفاده شد، اما محدود بودن تصاویر به دو تاریخ باعث شد مراحل رشد گیاه به خوبی پوشش داده نشود. به‌طور ترتیب، مطالعه آهنگرها و همکاران (۱۳۹۹) با بهره‌گیری از تصاویر ابرطیفی و یادگیری عمیق، توانست تغییرات سطح زیر کشت را ردیابی کند، اما مدل ارائه شده برای محصولات خاص با پراکنش محدود تعمیم‌پذیر نبود. همچنین بارگیل (۲۰۱۷) با ترکیب داده‌های راداری و اطلاعات فنولوژیکی، طبقه‌بندی محصولات در آلمان را انجام داد، ولی نویز بالای داده‌های راداری مانعی برای پردازش دقیق شد.

در همین راستا، ژبو و همکاران (۲۰۲۰) با توسعه مدل DeepCropMapping و استفاده از شبکه عصبی کانولوشنی بر پایه تصاویر سری‌زمانی، توانستند قابلیت تعمیم مکانی این مدل را در طبقه‌بندی محصولات بزرگی مانند ذرت و سویا نشان دهند. این مطالعه، زمینه‌ساز ورود شبکه‌های عصبی کانولوشنی به حوزه کشاورزی با پوشش‌های پیچیده شد. پژوهش ژنگ و همکاران (۲۰۱۵) نیز با استفاده از ماشین بردار پشتیبان و سری‌های زمانی NDVI، طبقه‌بندی دقیقی از محصولات آبی در مناطق خشک ارائه دادند، اما ضعف در استخراج خودکار ویژگی‌ها همچنان پابرجا بود.

مطالعه ژونگ، هو و ژو (۲۰۱۹) به‌طور خاص نشان داد که ترکیب تصاویر سری‌زمانی سنتینل-۲ با اطلاعات فنولوژیکی بومی می‌تواند دقت مدل‌های یادگیری عمیق در طبقه‌بندی محصولات فصلی را به‌طور چشمگیری ارتقاء دهد. یافته‌های آن‌ها حاکی است که هم‌زمان‌سازی دقیق تصاویر ماهواره‌ای با مراحل کلیدی رشد گیاه، عاملی تعیین‌کننده در عملکرد نهایی مدل‌های طبقه‌بندی محسوب می‌شود. این پژوهش با تمرکز بر مزارع جنوب چین، گامی پیشرو در بهره‌گیری از دانش فنولوژیک در معماری‌های یادگیری عمیق به‌شمار می‌آید و از منظر رویکرد، به‌ویژه در طراحی چارچوب داده‌محور بومی، شباهت‌های قابل توجهی با مطالعه حاضر دارد.

مطالعه گادیرجو و واتساوای (۲۰۲۰) در تحلیل تطبیقی بین مدل‌ها نشان داد که انتخاب ساختار بهینه شبکه عصبی کانولوشنی حتی در شرایط داده‌کم، می‌تواند عملکرد مدل را به‌شدت ارتقاء دهد. از سوی دیگر، چسلیک و بلگیو (۲۰۱۷) با استفاده از روش شیء‌مبنا و داده‌های سنتینل-۲ برای طبقه‌بندی گندم، نشان دادند که در اراضی با قطعات متنوع، مدل دچار بیش‌برازش می‌شود.

در برخی مطالعات اخیر، استفاده از معماری‌های ترکیبی شبکه عصبی کانولوشنی و حافظه بلندمدت دوسویه (Bi-LSTM) به عنوان راهکاری برای ارتقای دقت طبقه‌بندی محصولات کشاورزی مطرح شده است. به‌عنوان نمونه، چن، وو و ژو (۲۰۲۴) در پژوهشی منتشرشده در مجله PLoS ONE، از چنین مدلی برای طبقه‌بندی محصولات در مزارع کوچک‌مقیاس استفاده کردند و دقتی بیش از ۹۴ درصد گزارش کردند. یافته‌های آن‌ها نشان داد که LSTM به‌طور مؤثر می‌تواند روابط زمانی میان مراحل فنولوژیک رشد گیاه را مدل کند و از این منظر، مکمل مناسبی برای استخراج ویژگی‌های مکانی توسط شبکه عصبی کانولوشنی محسوب می‌شود.

همسو با این رویکرد، مطالعات جدیدتر تأکید فزاینده‌ای بر طراحی مدل‌های سبک‌وزن و قابل پیاده‌سازی در محیط‌های عملیاتی در حوزه کشاورزی دیجیتال دارند. برای مثال، لی و همکاران (۲۰۲۴) با ارائه مدل SGSNet، یک معماری کم‌پارامتر مبتنی بر مکانیزم attention برای تشخیص مراحل رشد توت‌فرنگی توسعه دادند. این مدل با تمرکز بر کاهش حجم محاسبات و حفظ دقت بالا، توانست در شرایط واقعی مزرعه عملکردی برجسته ارائه دهد و دقتی بیش از ۹۹ درصد در سطح mAP ثبت کند. در پژوهشی دیگر وانگ و همکاران (۲۰۲۴) با به‌کارگیری نسخه بهینه‌شده YOLOv8+ و افزودن مکانیزم attention، موفق به طبقه‌بندی بلادرنگ رسیدگی میوه‌های توت‌فرنگی در محیط‌های مزرعه‌ای شدند. آن‌ها با دستیابی به دقتی بیش از ۹۷ درصد در تشخیص سطوح مختلف رسیدگی، گامی مهم در جهت عملیاتی‌سازی مدل‌های یادگیری عمیق در فعالیتهای روزمره کشاورزی برداشتند.

در کنار این دستاوردها، حوزه یادگیری عمیق برای داده‌های نامتوازن نیز با پیشرفت‌هایی همراه بوده است. به‌عنوان مثال، سلیم و همکاران (۲۰۲۴) در پژوهشی برای تشخیص تنش‌های گیاهی در سویا، نشان دادند که استفاده از داده‌افزایی اختصاصی برای هر کلاس می‌تواند عملکرد مدل را در کلاس‌های دشوار از حدود ۸۳ درصد به بیش از ۹۴ درصد ارتقاء دهد. این رویکرد برای محصولاتی با پراکنش محدود یا ویژگی‌های طیفی مبهم (مانند گلخانه‌ها یا توت‌فرنگی) بسیار کاربردی است.

در جمع‌بندی این مسیر مطالعاتی، می‌توان سه شکاف عمده را شناسایی کرد: نخست، استفاده ناکافی از داده‌های فنولوژیکی بومی؛ دوم، ضعف در معماری‌های بهینه برای کلاس‌های کم‌نمونه یا ناهمگون؛ و سوم، کم‌توجهی به شرایط اقلیمی خاص همچون مناطق کوهستانی. پژوهش حاضر با تلفیق داده‌های سری‌زمانی سنتینل-۲، دانش فنولوژیکی بومی و شبکه‌های عصبی کانولوشنی، در پی ارائه پاسخی به این خال‌هاست و گامی نوآورانه در کشاورزی دقیق و داده‌محور محسوب می‌شود.

### آمایش سرزمین کشاورزی و تعیین الگوی کشت

آمایش سرزمین فرایندی برنامه‌محور و داده‌مبنا است که هدف آن شناسایی مناسب‌ترین نوع کاربری برای هر منطقه با در نظر گرفتن ظرفیت‌های اکولوژیکی، اقتصادی و اجتماعی آن است. در زمینه کشاورزی، آمایش سرزمین به معنای تعیین بهینه‌ترین نوع محصولات زراعی با اتکا بر ترکیبی از شاخص‌های زیست‌محیطی، اقتصادی و اجتماعی است؛ رویکردی که در نهایت به افزایش بهره‌وری اقتصادی، پایداری محیط‌زیست، و ارتقاء سطح رفاه جوامع محلی منجر می‌شود.

با توسعه فناوری‌های سنجش‌ازدور و سامانه‌های اطلاعات مکانی، امکان دسترسی به اطلاعات مکانی-زمانی دقیق از متغیرهای کلیدی در فرایند آمایش کشاورزی فراهم شده است. در این چارچوب، پارامترهایی نظیر توپوگرافی (شامل شیب، جهت جغرافیایی، ارتفاع)، اقلیم و الگوهای بارندگی، ویژگی‌های زمین‌شناسی و خاک‌شناسی، منابع و کیفیت آب، نوع پوشش گیاهی و میزان فرسایش یا رسوب‌گذاری، به‌صورت کمی و مکانی استخراج و تحلیل می‌شوند. این داده‌ها اغلب با استفاده از تصاویر ماهواره‌ای چندزمانه، عکس‌های هوایی، و داده‌های زمینی گردآوری می‌گردند.

در گام نهایی، توان بوم‌شناختی (اکولوژیکی) منطقه از طریق تلفیق این داده‌ها با متغیرهای اقتصادی (مانند هزینه و سود محصول)، شاخص‌های اجتماعی (نظیر اشتغال و امنیت غذایی)، و سیاست‌های کلان توسعه روستایی استخراج می‌شود. خروجی این فرایند، طراحی الگوی کشت بهینه و متناسب با ویژگی‌های بومی هر منطقه است؛ الگویی که هم با ظرفیت‌های طبیعی منطقه سازگار است و هم در مسیر توسعه پایدار کشاورزی قرار دارد.

### نقش یادگیری عمیق در کشاورزی داده‌محور

با پیشرفت‌های چشمگیر در توسعه مدل‌های یادگیری عمیق و به‌موازات آن، ارتقای قابلیت‌های سنجنده‌های فضایی و زمینی، کاربرد این روش‌ها در حوزه کشاورزی اهمیت روزافزونی یافته است. یادگیری عمیق به‌عنوان زیرمجموعه‌ای از هوش مصنوعی، امکان تحلیل پیشرفته داده‌های پیچیده، حجیم و چندبعدی را فراهم می‌سازد و می‌تواند نقشی کلیدی در پایش وضعیت محصولات، پیش‌بینی عملکرد، تشخیص بیماری‌ها، و بهینه‌سازی الگوی مصرف منابع ایفا کند. در چارچوب کشاورزی پایدار، این فناوری به‌ویژه در تجزیه و تحلیل داده‌های چندمنبعی (مانند داده‌های سنجش‌ازدور، داده‌های هواشناسی، اطلاعات خاک و...) به کشاورزان و برنامه‌ریزان این امکان را می‌دهد که تصمیمات‌شان بهینه‌تر و مبتنی بر داده‌ها باشند. پژوهش‌ها نشان می‌دهند که بهره‌گیری از مدل‌های یادگیری عمیق می‌تواند در بهبود کارایی منابع، کاهش ضایعات، و ارتقاء بهره‌وری در کشاورزی نقش مؤثری داشته باشد.

آمایش سرزمین فرایندی برنامه‌محور و داده‌مبنا است که هدف آن شناسایی مناسب‌ترین نوع کاربری برای هر منطقه با در نظر گرفتن ظرفیت‌های اکولوژیکی، اقتصادی و اجتماعی آن است. در زمینه کشاورزی، آمایش سرزمین به معنای تعیین بهینه‌ترین نوع محصولات زراعی با اتکا بر ترکیبی از شاخص‌های زیست‌محیطی، اقتصادی و اجتماعی است؛ رویکردی که در نهایت به افزایش بهره‌وری اقتصادی، پایداری محیط‌زیست، و ارتقاء سطح رفاه جوامع محلی منجر می‌شود.

با توسعه فناوری‌های سنجش‌ازدور و سامانه‌های اطلاعات مکانی، امکان دسترسی به اطلاعات مکانی-زمانی دقیق از متغیرهای کلیدی در فرایند آمایش کشاورزی فراهم شده است. در این چارچوب، پارامترهایی نظیر توپوگرافی (شامل شیب، جهت جغرافیایی، ارتفاع)، اقلیم و الگوهای بارندگی، ویژگی‌های زمین‌شناسی و خاک‌شناسی، منابع و کیفیت آب، نوع پوشش گیاهی، و میزان فرسایش یا رسوب‌گذاری، به‌صورت کمی و مکانی استخراج و تحلیل می‌شوند. این داده‌ها اغلب با استفاده از تصاویر ماهواره‌ای چندزمانه، عکس‌های هوایی، و داده‌های زمینی گردآوری می‌گردند.

در گام نهایی، توان بوم‌شناختی (اکولوژیکی) منطقه از طریق تلفیق این داده‌ها با متغیرهای اقتصادی (مانند هزینه و سود محصول)، شاخص‌های اجتماعی (نظیر اشتغال و امنیت غذایی)، و سیاست‌های کلان توسعه روستایی استخراج می‌شود. خروجی این فرایند، طراحی الگوی کشت بهینه و متناسب با ویژگی‌های بومی هر منطقه است؛ الگویی که هم با ظرفیت‌های طبیعی منطقه سازگار است و هم در مسیر توسعه پایدار کشاورزی قرار دارد.

### شبکه عصبی کانولوشنی

شبکه‌های عصبی کانولوشنی به‌عنوان یکی از پرکاربردترین ساختارهای یادگیری عمیق، کاربرد گسترده‌ای در تحلیل تصاویر سنجش‌ازدور دارند (لیو، لو و مو، ۲۰۱۶). این شبکه‌ها که عمدتاً بر پایه یادگیری نظارت‌شده عمل می‌کنند، در مقایسه با دیگر معماری‌های یادگیری، عملکرد بهتری در طبقه‌بندی تصاویر پیچیده با رزولوشن مکانی و زمانی بالا ارائه می‌دهند. شبکه عصبی کانولوشنی تصاویر ورودی را از طریق مجموعه‌ای از لایه‌های کانولوشنی، پولینگ و کاملاً متصل تحلیل می‌کند که هر کدام به‌منظور استخراج ویژگی‌های مختلف از تصویر طراحی شده‌اند.

ساختار شبکه عصبی کانولوشنی مورد استفاده در این پژوهش از سه لایه اصلی تشکیل شده است:

(الف) لایه کانولوشن: در این لایه، کرنل‌ها (هسته‌های پردازشی کوچک) با حرکت روی تصویر و اعمال وزن‌های متناسب، ویژگی‌های مکانی و طیفی مختلف را استخراج می‌کنند. ساختار حاضر شامل سه لایه کانولوشنی متوالی است که به افزایش توانایی مدل در تشخیص الگوهای ظریف کمک می‌کند.

(ب) لایه پولینگ: این لایه با هدف کاهش ابعاد مکانی داده‌ها و تعداد پارامترهای مدل عمل می‌کند که منجر به افزایش سرعت محاسبات و جلوگیری از بیش‌برازش می‌شود. در این پژوهش از Max Pooling برای حفظ ویژگی‌های شاخص استفاده شده است.

ج) لایه کاملاً متصل: در انتهای شبکه، لایه‌های استخراج ویژگی به یک بردار یک‌بعدی تبدیل شده و از طریق این لایه، فرایند تصمیم‌گیری نهایی و تخصیص کلاس انجام می‌پذیرد.

ترکیب این لایه‌ها بستر مناسبی برای تشخیص الگوهای پیچیده در تصاویر فراهم می‌آورد و امکان طبقه‌بندی دقیق محصولات کشاورزی در مقیاس مکانی بالا را فراهم می‌کند.

### توجیه انتخاب شبکه عصبی کانولوشنی در این پژوهش

در انتخاب الگوریتم طبقه‌بندی مناسب برای این پژوهش، روش‌های متعددی نظیر ماشین بردار پشتیبان، جنگل تصادفی و الگوریتم‌های یادگیری آماری مورد بررسی قرار گرفتند. با این حال، شبکه عصبی کانولوشنی به دلیل توانایی منحصربه‌فرد در استخراج خودکار ویژگی‌های مکانی و زمانی از داده‌های سری زمانی تصاویر ماهواره‌ای، و قابلیت تعمیم بالا در مواجهه با داده‌های نامتوازن و نویزی، به‌عنوان مدل پایه انتخاب شد. برخلاف روش‌های سنتی که نیاز به مهندسی ویژگی دستی دارند، شبکه عصبی کانولوشنی قادر است الگوهای پیچیده رشد، تفاوت‌های فنولوژیکی و تغییرات طیفی ظریف بین محصولات کشاورزی را به‌صورت عمیق فراگیرد. همچنین، ساختار چندلایه شبکه عصبی کانولوشنی امکان مدل‌سازی سلسله‌مراتبی از اطلاعات سطح پیکسل تا سطح قطعه زراعی را فراهم می‌کند که در طبقه‌بندی محصولات با پراکنش محدود (مانند توت‌فرنگی) مزیت ویژه‌ای ایجاد می‌نماید. این ویژگی‌ها در پژوهش‌های متعددی نیز مورد تأیید قرار گرفته است و به همین دلیل، معماری شبکه عصبی کانولوشنی به‌عنوان هسته اصلی طبقه‌بندی در این پژوهش انتخاب گردید.

### تنظیم و بهینه‌سازی پارامترهای مدل شبکه عصبی کانولوشنی

فرایند بهینه‌سازی پارامترها یکی از مراحل حیاتی در طراحی و پیاده‌سازی مدل‌های یادگیری ماشین محسوب می‌شود؛ چرا که عملکرد نهایی الگوریتم‌های طبقه‌بندی تا حد زیادی به نحوه تنظیم دقیق این پارامترها وابسته است. پارامترهای انتخابی، در صورت تعیین غیربهینه، می‌توانند منجر به کاهش دقت مدل، بیش‌برازش یا کم‌برازش، و کاهش قابلیت تعمیم آن به داده‌های جدید شوند. از این‌رو، تاکنون رویکردهای متعددی برای انتخاب بهینه این پارامترها پیشنهاد شده‌اند.

در این پژوهش، به‌منظور بهینه‌سازی پارامترهای مدل طبقه‌بندی‌کننده شبکه عصبی کانولوشنی، از روش «جستجوی شبکه‌ای» استفاده شده است. این روش یکی از رایج‌ترین و معتبرترین رویکردها در انتخاب ترکیب بهینه پارامترها به شمار می‌رود و در بسیاری از مطالعات حوزه یادگیری ماشین کاربرد دارد. در این روش، ابتدا مجموعه‌ای از مقادیر قابل قبول برای هر پارامتر کلیدی (مانند نرخ یادگیری، تعداد دوره‌های آموزشی، اندازه دسته‌ها و...) در محدوده‌ای مشخص تعیین می‌گردد. سپس، از طریق یک جستجوی جامع در فضای پارامتری حاصل از این ترکیب‌ها، مدلی که بالاترین دقت یا بهترین معیار عملکرد را در داده‌های اعتبارسنجی ارائه دهد، به‌عنوان مدل نهایی انتخاب می‌شود (چانگ، ۲۰۰۷).

### روش پژوهش

#### منابع داده و اطلاعات پایه

تصاویر ماهواره‌ای با فراهم‌کردن اطلاعات طیفی، مکانی و زمانی از سطح زمین، ابزار قدرتمندی برای شناسایی و تفکیک محصولات کشاورزی محسوب می‌شوند. در این میان، سه ویژگی کلیدی تصاویر ماهواره‌ای شامل قدرت تفکیک مکانی، طیفی و زمانی، نقش تعیین‌کننده‌ای در دقت طبقه‌بندی محصولات ایفا می‌کنند.

قدرت تفکیک مکانی بیانگر میزان جزئیاتی است که تصویر می‌تواند از سطح زمین ثبت کند. در طبقه‌بندی محصولات زراعی که دارای تفاوت‌های پوششی ظریف هستند، استفاده از تصاویری با وضوح مکانی بالا، اهمیت بسزایی دارد. قدرت تفکیک طیفی

به توانایی تصویر در تمایز بین اشیاء مختلف بر اساس پاسخ بازتاب طیفی آن‌ها اشاره دارد؛ عاملی کلیدی در تمایز بین پوشش‌های گیاهی گوناگون. همچنین، قدرت تفکیک زمانی بیانگر توانایی سامانه در تهیه تصاویر از یک منطقه در فواصل زمانی منظم است که در پیگیری تغییرات فنولوژیکی محصولات نقشی اساسی دارد.

با توجه به نیازهای خاص تفکیک محصولاتی مانند توت‌فرنگی، استفاده از داده‌های ماهواره‌ای سنتینل-۲ نسبت به داده‌های ماهواره لندست ارجحیت دارد. ماهواره سنتینل-۲ با برخورداری از وضوح مکانی بالا، ۱۳ باند طیفی با تنوع مناسب، و قدرت تفکیک زمانی بهبودیافته، گزینه‌ای ایده‌آل برای پایش و طبقه‌بندی محصولات کشاورزی به شمار می‌آید. این ماهواره توانایی ثبت تصاویر با بازه زمانی حدود ۳ تا ۵ روز را دارد که امکان تولید سری‌های زمانی دقیق و پُربسامد را فراهم می‌کند. البته در مقاطع خاصی از سال، به‌ویژه در شرایط جوی نامساعد نظیر ابرناکی یا برف، این تداوم زمانی ممکن است با اختلالاتی مواجه شود.

## داده‌های ماهواره‌ای سنتینل-۲

با توجه به تفاوت‌های اقلیمی، توپوگرافی، و الگوهای متغیر پوشش ابری در نواحی مختلف منطقه مورد مطالعه، استفاده از تعداد یکسانی از تصاویر ماهواره‌ای برای همه شهرستان‌ها امکان‌پذیر نبود. بنابراین، برای هر منطقه، مجموعه‌ای از تاریخ‌های منتخب با تأکید بر هم‌پوشانی زمانی با مراحل کلیدی رشد توت‌فرنگی، کیفیت طیفی و مکانی مناسب، و حداقل میزان پوشش ابری استخراج شد (جدول ۱). این راهبرد مبتنی بر بیشینه‌سازی داده‌های مؤثر و حذف تصاویر دارای نویز یا اختلال جوی بوده است. تحلیل داده‌ها نشان داد که کیفیت و فراوانی تصاویر قابل‌استفاده در مناطق مختلف یکسان نبوده و متأثر از شرایط جوی محلی است (شکل ۱). با این حال، اختلاف موجود در تعداد تصاویر با بهره‌گیری از تکنیک‌های نرمال‌سازی و تنظیم ساختاری داده‌ها، در فرایند آموزش مدل مدیریت شده است؛ به‌گونه‌ای که مدل نهایی توانسته عملکرد باثباتی را در سراسر نواحی مورد مطالعه ارائه دهد. در مجموع، این انتخاب هدفمند و کیفیت‌محور در گردآوری داده‌های ورودی، موجب ارتقاء دقت مدل یادگیری عمیق و افزایش توان آن در تمایز دقیق محصول توت‌فرنگی از سایر پوشش‌های زمین شد.

جدول ۱. تعداد تصاویر قابل استفاده به تفکیک منطقه مورد مطالعه

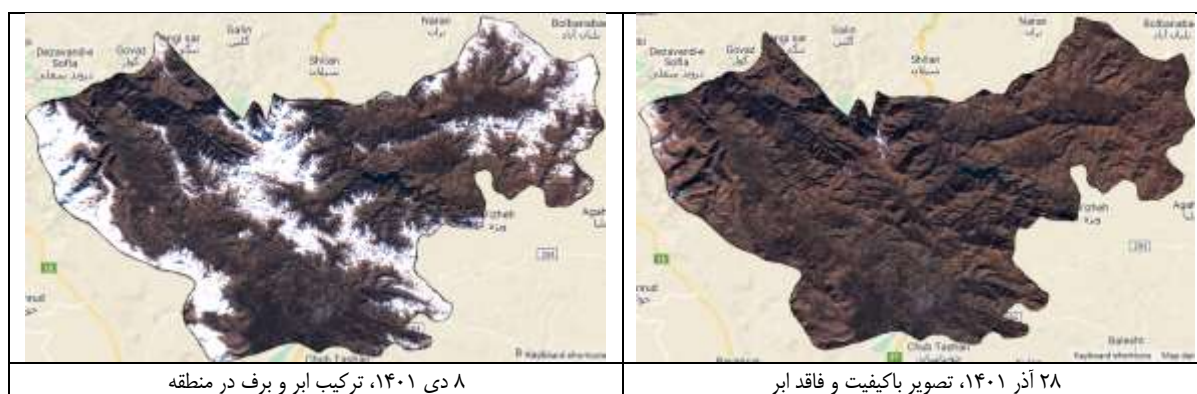
مناطق مورد مطالعه استان کردستان	تعداد تصاویر قابل استفاده	کل تصاویر موجود در بازه رشد محصول توت‌فرنگی
سنندج	۲۰	۶۵
کامیاران	۱۲	۳۳
مریوان	۸	۲۱
سروآباد	۱۴	۲۵

در شکل ۱ وضعیت برخی از تصاویر به صورت رنگی در تاریخ‌های مختلف نمایش داده شده است.



۲۰ آذر ۱۴۰۱، عدم برخورداری هم‌پوشانی کامل تصویر

۱۸ آذر ۱۴۰۱، تصویر با کیفیت و فاقد ابر



شکل ۱. نمونه‌ای از تصاویر اخذ شده در تاریخ‌های مختلف

Fig. 1. A sample of images captured on different dates

### داده‌های زمینی و میدانی

پس از انتخاب تصاویر ماهواره‌ای مناسب، فرایند جمع‌آوری نمونه‌های آموزشی به‌منظور آموزش الگوریتم طبقه‌بندی آغاز شد. این نمونه‌ها با دقت بالا و از طریق بازدیدهای میدانی و بهره‌گیری از سامانه موقعیت‌یاب جهانی برداشت شدند (شکل ۲). هدف از این مرحله، ایجاد پایگاه داده‌ای معتبر برای آموزش و ارزیابی مدل‌های طبقه‌بندی بود.



شکل ۲. جمع‌آوری نمونه‌ها از طریق بازدیدهای میدانی

Fig. 2. Sample collection through field visits

به‌منظور تطبیق داده‌های میدانی با ساختار موردنیاز الگوریتم‌های یادگیری ماشین، محدوده‌های برداشت‌شده در تصاویر شناسایی و به‌صورت پلیگون‌های رقومی استخراج گردیدند. این داده‌ها سپس به فرمت رستری تبدیل شدند تا برای پردازش و تحلیل توسط الگوریتم‌ها قابل‌استفاده باشند. به‌منظور تضمین بی‌طرفی در ارزیابی عملکرد مدل‌ها، از مجموعه یکسانی از داده‌های آموزشی و آزمایشی برای تمامی الگوریتم‌های مقایسه‌شده استفاده شد. این رویکرد موجب می‌گردد که تفاوت‌های مشاهده‌شده در نتایج، صرفاً ناشی از تفاوت در توانایی طبقه‌بندی الگوریتم‌ها باشد و نه از تفاوت در داده‌های ورودی. نمونه‌ای از پلیگون‌های استخراج‌شده از مناطق برداشت‌شده، که برای آموزش مدل شبکه عصبی مورد استفاده قرار گرفته‌اند، در شکل ۳ نمایش داده شده است.



شکل ۳. نمونه پلیگون‌های برداشت‌شده جهت آموزش مدل شبکه

Fig. 3 - Sample polygons collected for training the network model


### نواحی مورد مطالعه

پژوهش حاضر بر چهار منطقه جغرافیایی و اقلیمی استان کردستان شامل شهرستان‌های سنندج، مریوان، سروآباد و کامیاران متمرکز است. این مناطق به دلیل موقعیت جغرافیایی ویژه، تنوع اقلیمی و ظرفیت بالای کشت محصول راهبردی توت‌فرنگی، بستری مناسب برای مطالعات سنجش‌ازدور کشاورزی فراهم کرده‌اند. محدوده‌های یادشده در نواحی غربی و جنوب‌غربی استان واقع شده و از منظر پیوستگی فضایی، مجموعه‌ای یکپارچه را برای تشکیل یک واحد مطالعاتی جامع پدید آورده‌اند.

مطابق آخرین تقسیمات سیاسی، شهرستان سنندج که مرکز استان نیز هست، با مساحت تقریبی ۳۶۳۷ کیلومتر مربع، بزرگ‌ترین محدوده مطالعه را تشکیل می‌دهد. پس از آن، شهرستان مریوان با حدود ۲۲۳۳ کیلومتر مربع وسعت، در مجاورت مرز غربی کشور با عراق قرار گرفته است. کامیاران در جنوب استان و با وسعتی در حدود ۲۰۳۵ کیلومتر مربع واقع شده و شهرستان سروآباد با مساحتی نزدیک به ۱۰۸۷ کیلومتر مربع، کوچک‌ترین ناحیه مطالعاتی محسوب می‌شود.

استان کردستان به دلیل ویژگی‌های توپوگرافی کوهستانی، تنوع ارتفاعی قابل توجه و اقلیم‌های متغیر از نیمه‌مرطوب تا سرد کوهستانی، بستری مناسب برای کشت انواع محصولات فصلی، از جمله توت‌فرنگی، فراهم کرده است. چهار شهرستان سنندج، مریوان، کامیاران و سروآباد که به ترتیب در نواحی مرکزی، غربی، جنوبی و جنوب‌غربی استان واقع‌اند، به دلیل وجود اراضی شیب‌دار قابل کشت، سابقه تاریخی در تولید توت‌فرنگی و حضور قابل توجه بهره‌برداران خرد، به‌عنوان مناطق اصلی مطالعه انتخاب شده‌اند.

در تعیین این محدوده‌ها، معیارهایی مانند تنوع ساختار پوشش گیاهی، پراکنش مکانی معنادار مزارع در واحدهای مختلف ارتفاعی، دسترسی نسبی به داده‌های میدانی معتبر و همخوانی با تقویم فنولوژیک رشد توت‌فرنگی در نواحی کوهستانی، مد نظر قرار گرفته‌اند. انتخاب این شهرستان‌ها نه تنها امکان آزمون‌پذیری دقیق مدل‌های مکانی-زمانی را فراهم کرده، بلکه از منظر سنجش قابلیت تعمیم‌پذیری نتایج به دیگر نواحی مشابه کشور نیز ارزشمند است. موقعیت نسبی این شهرستان‌ها در نقشه ارائه‌شده در شکل ۴ نشان داده شده است.



شکل ۴. مرزبندی و موقعیت مناطق مورد مطالعه

Fig. 4. Delineation and location of the study areas

## آماده‌سازی و پیش‌پردازش داده‌ها

داده‌های میدانی این پژوهش از طریق پیمایش‌های صحرایی در فصل رشد سال ۱۴۰۱ و با بهره‌گیری از گیرنده‌های GPS دستی جمع‌آوری شدند. موقعیت مکانی قطعات زراعی هدف ثبت و با استفاده از سامانه اطلاعات جغرافیایی به صورت مرزهای مزرعه‌ای (پلیگون) بازسازی گردید. این داده‌ها پس از تطبیق با نقشه‌های مبنای، به عنوان برچسب‌های مکانی جهت آموزش مدل شبکه عصبی کانولوشنی به کار گرفته شدند.

فرایند آماده‌سازی داده‌ها شامل مراحل متعددی بود که از ترکیب تصاویر سنتینل-۲ در تاریخ‌های متناظر با مراحل کلیدی فنولوژیکی رشد توت‌فرنگی آغاز شد. در این راستا، تصاویر مورد استفاده ابتدا تحت پیش‌پردازش‌های فنی از جمله تصحیح هندسی، تصحیح توپوگرافی، تصحیح رادیومتریکی و تصحیح اتمسفری قرار گرفتند. پس از آن، نرمال‌سازی طیفی، حذف داده‌های پرنویز و جداسازی مجموعه داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمون انجام شد.

برای تعیین بازه‌های زمانی بهینه تصویربرداری، از اطلاعات محلی ارائه‌شده توسط کارشناسان جهاد دانشگاهی استان کردستان و تقویم زراعی منطقه بهره گرفته شد. تاریخ‌های انتخابی با در نظر گرفتن نقاط عطف فنولوژیکی نظیر زمان کاشت، رشد رویشی، گل‌دهی و برداشت محصول تعیین گردیدند. جدول ۲، بازه زمانی کاشت و برداشت محصول توت‌فرنگی را در مشخصات جغرافیایی و اقلیمی مناطق مطالعه نمایش می‌دهد. همچنین، جهت ارتقاء کیفیت داده‌ها، تنها تصاویر با ابر کمتر از ۱۰ درصد وارد فرایند تحلیل شدند.

برچسب‌گذاری کلاس‌ها نیز با ترکیب اطلاعات تقویم فنولوژی منطقه، داده‌های میدانی، و تطابق زمانی کاشت-برداشت در سری‌های زمانی NDVI انجام گرفت. هرچند داده‌های فنولوژیکی دقیق برای تمامی زیرگونه‌ها و کلاس‌های محصول در دسترس نبود، اما تفاوت‌های زمانی در منحنی‌های رشد از طریق تحلیل نسبی شاخص پوشش گیاهی NDVI لحاظ گردید.

جدول ۲. فنولوژی رشد محصول توت‌فرنگی

منطقه مورد مطالعه	تاریخ کاشت	تاریخ برداشت
سنندج	۱۵ مهر تا ۲۰ آبان	۲۰ اردیبهشت تا ۱۰ تیر
کامیاران	۱۰ تا ۱۵ آذر	۱۵ اردیبهشت تا ۳۰ خرداد
مریوان	۱۰ تا ۱۵ آذر	۱۵ اردیبهشت تا ۳۰ خرداد
سروآباد	۱۵ آبان تا ۱۰ آذرماه	۱۵ اردیبهشت تا ۳۰ خرداد

## شرح الگوریتم پیشنهادی و پایگاه دانش

روش پیشنهادی این پژوهش مبتنی بر یک مدل دانش‌محور برای شناسایی نوع محصول زراعی با استفاده از تحلیل داده‌های ماهواره‌ای و اطلاعات زمین‌مرجع است. این مدل از سه دسته معیار اصلی شامل شروط مکانی، طیفی و زمانی بهره می‌برد و فرایند تصمیم‌گیری آن بر پایه استخراج دانش از ترکیب سابقه کشت، سری‌زمانی تصاویر ماهواره‌ای و تقویم زراعی منطقه طراحی شده است.

ساختار کلی روش پیشنهادی در قالب سه گام اصلی سازمان‌دهی شده است:

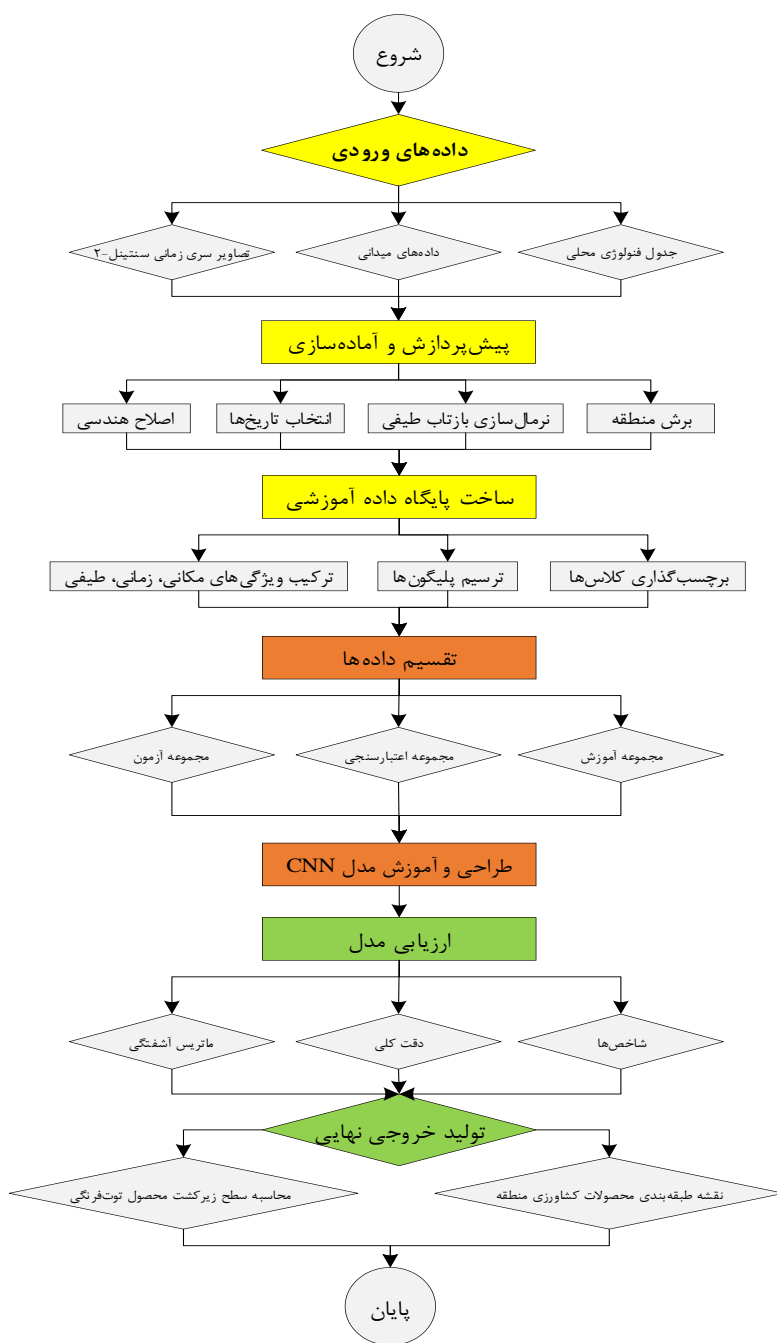
(الف) استخراج دانش پایه و تشکیل پایگاه دانش مکانی: در این مرحله، داده‌های مکانی، اطلاعات تاریخی کشت، و تحلیل سری‌زمانی شاخص‌های طیفی استخراج شده و به صورت ساختار یافته در قالب یک پایگاه دانش مکانی ذخیره می‌شوند.

(ب) استنتاج و تمایز محصولات زراعی: با بهره‌گیری از قواعد زمانی و ویژگی‌های طیفی استخراج‌شده از تصاویر چندزمانی، فرایند استنتاج برای تمایز بین محصولات مختلف انجام می‌گیرد. در این گام، شاخص‌های کلیدی رشد گیاه و روند تغییرات

فنولوژیکی به‌عنوان معیارهای تشخیص به‌کار گرفته می‌شوند.

ج) برآورد سطح زیر کشت: پس از طبقه‌بندی موفق محصولات، سطح زیر کشت هر یک از محصولات زراعی با استفاده از داده‌های پیکسلی حاصل از طبقه‌بندی محاسبه شده و به‌صورت آماری گزارش می‌گردد.

روندنمای کلی این فرایند در شکل ۵ ارائه شده است که مراحل اجرایی مدل، جریان داده‌ها و نحوه تعامل میان پایگاه داده و فرایندهای تحلیلی را به‌صورت سلسله‌وار نمایش می‌دهد.



شکل ۵. روندنمای روش پیشنهادی

Fig. 5. Flowchart of the proposed method

### مراحل اجرایی روش پیشنهادی و پیاده‌سازی شبکه عصبی کانولوشنی

فرایند شناسایی نوع محصول کشاورزی در این مطالعه با مرحله پیش‌پردازش آغاز می‌شود. در این مرحله، تصحیحات هندسی و رادیومتریک (طیفی) بر روی تصاویر سری‌زمانی ماهواره‌ای اعمال گردید تا اثرات مخرب ناشی از زاویه تابش خورشید، شرایط جوی و خطاهای کالیبراسیون سنجنده حذف شوند. انتخاب تصاویر مورد استفاده نیز با در نظر گرفتن دو معیار اصلی انجام می‌شود: قدرت تفکیک زمانی بالا (برای پوشش کامل چرخه فنولوژیکی) و قدرت تفکیک مکانی مناسب (برای کاهش پیکسل‌های مختلط). نوع تصحیحات، بسته به هدف کاربرد، به صورت مطلق یا نسبی انجام می‌شود؛ به‌گونه‌ای که پس از اعمال اصلاحات، تغییرات مشاهده‌شده در تصاویر صرفاً ناشی از تغییرات پدیده مورد مطالعه باشد.

در ادامه، سه دسته شرط مکانی، طیفی و زمانی به‌منظور تدوین پایگاه دانش محصول مورد بررسی قرار می‌گیرند. شروط زمانی برگرفته از مراحل فنولوژیکی محصولات و بر مبنای سابقه کشت، تاریخ شخم‌زنی، و مدت‌زمان رشد هر مرحله تعیین می‌شود. شروط طیفی، ویژگی‌های بازتابی خاص هر محصول را در دوره‌های مختلف رشد بازنمایی می‌کند و شروط مکانی شامل مختصات، مساحت و دیگر ویژگی‌های جغرافیایی پیکسل‌های کشاورزی است که برای برآورد سطح زیرکشت مورد استفاده قرار می‌گیرد.


جهت آموزش مدل طبقه‌بندی، داده‌های زمینی با دقت بالا از طریق تیم‌های نقشه‌برداری جمع‌آوری شده‌اند. از این مجموعه داده، ۶۰ درصد برای آموزش و ۴۰ درصد برای ارزیابی دقت مدل استفاده شده است. الگوریتم شبکه عصبی کانولوشنی ابتدا با داده‌های آموزشی و پارامترهای اولیه آموزش می‌بیند. سپس با ارزیابی روی داده‌های آزمایشی و تحلیل شاخص‌هایی چون صحت کلی و ضریب کاپا، کیفیت عملکرد مدل سنجیده می‌شود. در صورتی که دقت حاصله کمتر از آستانه موردنظر باشد، پارامترها از طریق جستجوی شبکه‌ای مجدداً بهینه‌سازی شده و فرآیند یادگیری تکرار می‌شود.

ساختار شبکه عصبی کانولوشنی طراحی‌شده در این پژوهش شامل سه لایه کانولوشنی متوالی با تعداد فیلتر افزایشی، یک لایه Pooling جهت کاهش ابعاد، و دو لایه کاملاً متصل برای تصمیم‌گیری نهایی است. برای مقابله با عدم تعادل داده‌ها به‌ویژه در کلاس‌هایی با نمونه‌های کمتر مانند توت‌فرنگی، از تکنیک وزن‌دهی استفاده شده که ماتریس وزن آن با روش Glorot Normal Initializer محاسبه گردیده است تا وزن نوروها بر اساس تعداد ورودی و خروجی بهینه‌سازی شود.

در نهایت، مدل آموزش‌دیده برای تولید نقشه‌های طبقه‌بندی محصولات کشاورزی به‌کار گرفته شده و دقت خروجی‌ها با داده‌های زمینی اعتبارسنجی گردیده است. معماری کامل شبکه در شکل ۶ و جزئیات فنی لایه‌ها در جدول ۳ ارائه شده است.

جدول ۳. جزئیات فنی لایه‌ها

لایه	نوع عملیات	اندازه کرنل	تعداد فیلتر	تابع فعال‌سازی	خروجی تقریبی
Conv1	کانولوشن	۳×۳	۱۶	ReLU	۶۴×۶۴×۱۶
Conv2	کانولوشن	۳×۳	۳۲	ReLU	۶۴×۶۴×۳۲
Conv3	کانولوشن	۳×۳	۶۴	ReLU	۶۴×۶۴×۶۴
MaxPooling	پولینگ	۲×۲	-	-	۳۲×۳۲×۶۴
Flatten	تبدیل به بردار	-	-	-	۶۵۵۳۶
Dense1	کاملاً متصل	-	۱۲۸	ReLU	۱۲۸
Output	کاملاً متصل	-	۱۵ کلاس	Softmax	۱۵ کلاس



شکل ۶. معماری شبکه عصبی کانولوشنی روش پیشنهادی

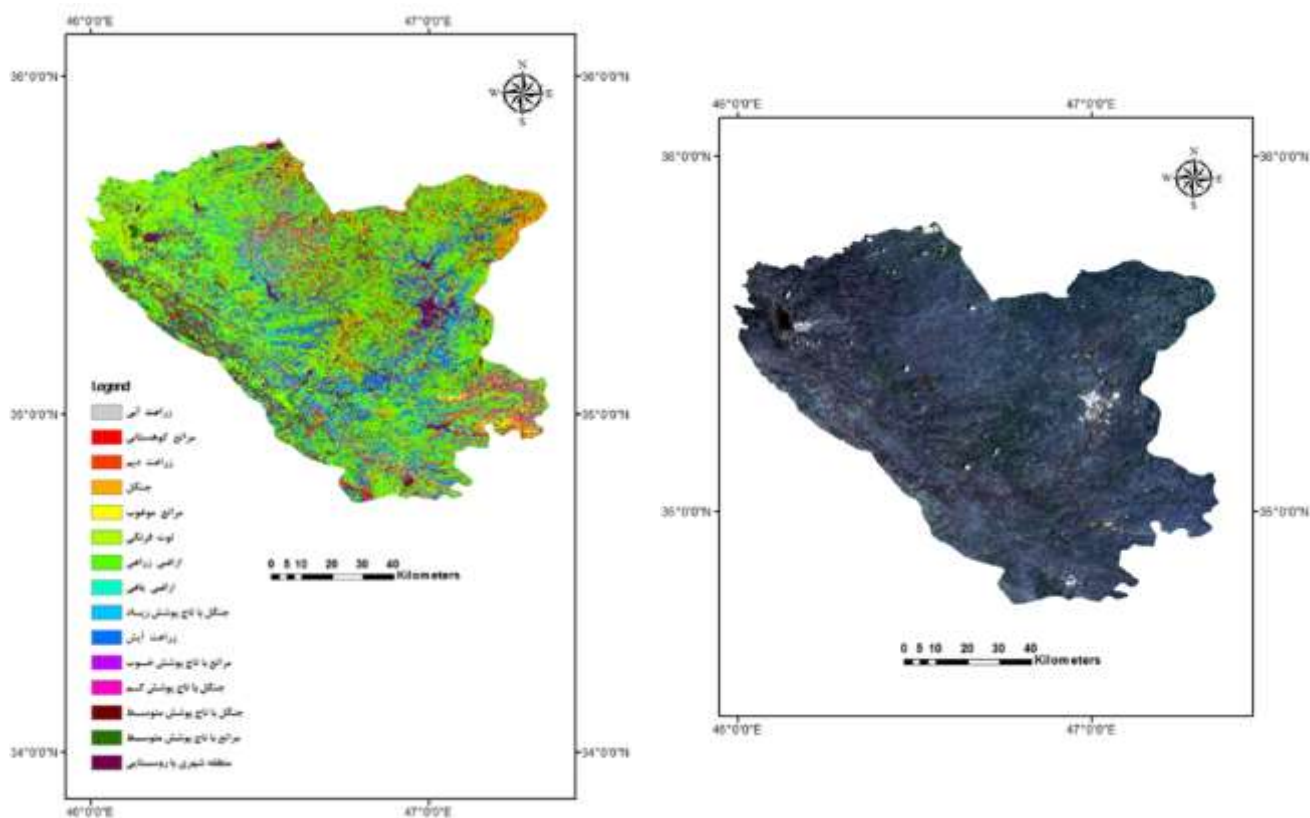
Fig. 6. Convolutional Neural Network architecture of the proposed method

برای فعال‌سازی لایه‌ها از تابع ReLU استفاده شد و خروجی شبکه با استفاده از تابع Softmax بر روی ۱۵ کلاس نهایی شده است. اندازه کرنل در تمام لایه‌های کانولوشنی برابر با  $3 \times 3$  در نظر گرفته شد. به منظور جلوگیری از بیش‌برازش، از لایه Dropout با نرخ  $0.5$  بین لایه‌های کاملاً متصل استفاده شد. همچنین، برای کلاس‌های دارای تعداد نمونه کمتر (مانند توت‌فرنگی)، از تکنیک وزن‌دهی کلاس‌ها بهره گرفته شد تا تعادل در فرآیند یادگیری حفظ شود. وزن‌ها با استفاده از Glorot Normal Initializer مقداردهی اولیه شدند.

فرآیند آموزش شبکه با استفاده از الگوریتم بهینه‌سازی Adam و نرخ یادگیری اولیه  $0.001$  انجام شد. تابع زیان (loss function) انتخابی Categorical Cross-Entropy بوده و شبکه طی ۱۵۰ دوره با اندازه دسته (batch size) برابر ۳۲ آموزش دید. همچنین، از روش Early Stopping برای جلوگیری از بیش‌برازش استفاده گردید. ساختار سه‌لایه کانولوشنی با افزایش تدریجی پیچیدگی (از ۱۶ تا ۶۴ فیلتر) پس از آزمون اولیه چند ساختار مختلف، بهترین تعادل را میان دقت، سرعت آموزش و کنترل خطا فراهم نمود.


## نتایج و بحث

در این مطالعه، ارزیابی و تحلیل نتایج از طریق تحلیل‌های بصری و کمی انجام شد. تحلیل کمی با بهره‌گیری از شاخص‌های استاندارد مانند صحت کلی و ضریب کاپا صورت گرفت که دقت و قابلیت تکرارپذیری الگوریتم‌های پیشنهادی را نشان می‌دهند. پردازش‌های مورد نیاز با استفاده از یک سیستم رایانه‌ای مجهز به پردازنده ۵ هسته‌ای Intel، حافظه رم ۴ گیگابایت، کارت گرافیک با حافظه ۲ گیگابایت و سیستم عامل ویندوز ۶۴ بیتی انجام شدند. نتایج طبقه‌بندی‌های انجام شده بر روی تصاویر ماهواره‌ای سنتینل-۲ مربوط به مناطق مورد مطالعه در تاریخ ۱۲ اردیبهشت ۱۴۰۲ به دست آمد و در شکل ۷ نمایش داده شده‌اند.




شکل ۷. تصویر اخذ شده از ماهواره سنتینل ۲ از مناطق مورد مطالعه (سمت راست) به همراه نتایج طبقه‌بندی (سمت چپ)  
 Fig. 7. Sentinel-2 satellite image of the study areas (right) along with the classification results (left)


در ادامه تصاویر طبقه‌بندی برای مناطق مطالعاتی به طور جداگانه در شکل‌های ۸، ۹، ۱۰ و ۱۱ نمایش داده شده است.



شکل ۹. نتایج طبقه‌بندی به‌دست‌آمده مریوان  
 Fig. 9. Classification results obtained for Marivan




شکل ۸. نتایج طبقه‌بندی به‌دست‌آمده کامیاران  
 Fig. 8. Classification results obtained for Kamyaran



شکل ۱۱. نتایج طبقه‌بندی به‌دست‌آمده سرآباد

Fig. 11. Classification results obtained for Sarvabad



شکل ۱۰. نتایج طبقه‌بندی به‌دست‌آمده سنندج

Fig. 10. Classification results obtained for Sanandaj

بر اساس نتایج حاصل از پیاده‌سازی روش پیشنهادی، الگوریتم توسعه‌یافته توانست با دقت بالایی، تفکیک ۱۵ کلاس متفاوت از کاربری‌های اراضی و محصولات کشاورزی را انجام دهد. این طبقه‌بندی شامل کلاس‌هایی چون زراعت آبی، زراعت دیم، زراعت آیش، توت‌فرنگی، اراضی باغی، اراضی زراعی، جنگل با سطوح مختلف تاج‌پوشش (کم، متوسط، زیاد)، مراتع با درجات مختلف پوشش گیاهی (مرغوب، با پوشش خوب، متوسط، کوهستانی) و مناطق شهری بوده است. نکته حائز اهمیت در عملکرد مدل، توانایی بالای آن در شناسایی کلاس‌هایی با پراکندگی کم و وسعت محدود، نظیر «توت‌فرنگی»، است که معمولاً توسط الگوریتم‌های سنتی با خطای بالا تشخیص داده می‌شوند.

تحلیل کیفی نقشه‌های طبقه‌بندی خروجی نیز بیانگر آن است که الگوریتم پیشنهادی در بازسازی واقعیت مکانی کلاس‌ها، به‌ویژه در نواحی مرزی و کلاس‌های با پوشش محدود، دقت بالایی دارد. به‌منظور ارزیابی کمی مدل، شاخص‌های صحت کلی و ضریب کاپا مورد استفاده قرار گرفتند. بر اساس نتایج به‌دست‌آمده، صحت کلی مدل برابر با ۹۶/۵۷ درصد و مقدار ضریب کاپا معادل ۸۵/۸۲ درصد بوده که نشان از عملکرد قابل‌اطمینان و قوی الگوریتم پیشنهادی در طبقه‌بندی دقیق اراضی دارد.

در ارزیابی عملکرد تفصیلی برای هر کلاس، از شاخص‌های Precision، Recall و F1-Score استفاده شد (جدول ۴). نتایج مربوط به کلاس «توت‌فرنگی» به‌عنوان کلاس هدف در این پژوهش، به ترتیب برابر با ۸۸ درصد، ۸۵ درصد و ۸۶/۴ درصد گزارش گردید که بیانگر تعادل مناسب بین دقت تشخیص و شناسایی جامع این کلاس می‌باشد. همچنین، میانگین عملکرد مدل برای تمام کلاس‌ها به‌صورت کلی شامل Precision برابر با ۸۱/۲ درصد، Recall برابر با ۷۹/۳ درصد و F1-Score معادل ۸۰/۲ درصد برآورد شده است. این شاخص‌ها در کنار صحت کلی و ضریب کاپا، حاکی از توانمندی روش پیشنهادی در استفاده ترکیبی از اطلاعات زمانی، مکانی و طیفی موجود در داده‌های ورودی جهت ارائه طبقه‌بندی دقیق و کارآمد می‌باشد.

جدول ۴. ارزیابی عملکرد برای هر کلاس

F1-Score (percent)	Recall (percent)	Precision (percent)	کلاس محصول
۸۶/۴	۸۵	۸۸	توت‌فرنگی
۸۰/۲	۷۸	۸۲/۵	گندم
۷۶/۹	۷۵	۷۹	جو
۷۵	۷۴	۷۶	ذرت
۸۲/۲	۸۳	۸۱/۵	یونجه
۷۱	۷۲	۷۰	مراتع طبیعی

۸۶/۴	۸۸	۸۵	باغات آبی
۷۱/۹	۷۰	۷۴	باغات دیم
۸۱	۸۲	۸۰	جنگل پهن‌برگ
۷۵/۵	۷۴	۷۷	جنگل سوزنی‌برگ
۹۰/۵	۹۱	۹۰	اراضی بایر
۹۲/۵	۹۲	۹۳	مناطق شهری
۹۵/۵	۹۵	۹۶	مناطق آبی
۶۴/۸	۶۲	۶۸	مراکز گلخانه‌ای
۶۲/۴	۶۰	۶۵	سایر

مطابق جدول ارزیابی عملکرد مدل، کلاس‌های «توت‌فرنگی»، «باغات آبی» و «مناطق آبی» دارای بالاترین شاخص F1 (بیش از ۸۶ درصد) بوده‌اند که نشان‌دهنده قابلیت بالای مدل در تشخیص محصولات با ویژگی‌های طیفی و ساختاری متمایز است. در مقابل، کلاس‌هایی نظیر «مراعات طبیعی»، «گلخانه‌ها» و دسته «سایر»، عملکرد ضعیف‌تری از خود نشان داده‌اند. علت این موضوع را می‌توان در ناهمگنی فضایی، پراکندگی زیاد، و هم‌پوشانی طیفی این کلاس‌ها دانست. کلاس هدف پژوهش یعنی «توت‌فرنگی» با شاخص F1 برابر با ۸۶/۴ درصد دقت بالا و یادآوری قابل قبول، به‌عنوان یکی از دقیق‌ترین خروجی‌های مدل شناسایی شد. این امر نشان‌دهنده توانایی مدل در شناسایی محصولات با پراکنش محدود و فنولوژی خاص است؛ توانمندی‌ای که در تحقیقات پیشین همواره به‌عنوان یک چالش اساسی مطرح بوده است.

در مقایسه با مطالعه‌ی چن، وو و شو (۲۰۲۴) که از مدل ترکیبی Bi-LSTM برای طبقه‌بندی محصولات فصلی در مزارع کوچک مقیاس استفاده کرده بودند، نتایج پژوهش حاضر از منظر دقت شناسایی محصول هدف کاملاً رقابتی ارزیابی می‌شود. اگرچه در آن پژوهش حداکثر شاخص F1 برای کلاس‌های غالب تا ۹۴ درصد گزارش شد، اما دقت طبقه‌بندی برای کلاس‌های کم‌نمونه کاهش یافته بود. این در حالی است که در مطالعه حاضر، کلاس «توت‌فرنگی» علی‌رغم هم‌پوشانی طیفی و وسعت محدود، با دقتی بالا شناسایی شده است. این مقایسه نشان می‌دهد که ترکیب داده‌های سری‌زمانی، شاخص‌های فنولوژیکی و معماری شبکه عصبی کانولوشنی بهینه‌شده، می‌تواند در شرایط پیچیده فضایی و اقلیمی نیز، عملکردی در سطح مدل‌های پیشرفته ترکیبی ارائه دهد.

## نتیجه‌گیری

پژوهش حاضر گامی نوآورانه در بهره‌گیری تلفیقی از فناوری‌های سنجش از دور پیشرفته و الگوریتم‌های یادگیری عمیق برای حل یکی از چالش‌های اساسی کشاورزی کشور، یعنی شناسایی دقیق و پایش بهنگام محصولات کشاورزی حساس و صادرات محور نظیر توت‌فرنگی، محسوب می‌شود. در این راستا، با طراحی و پیاده‌سازی یک مدل طبقه‌بندی مبتنی بر شبکه عصبی کانولوشنی و به‌کارگیری سری‌زمانی تصاویر ماهواره‌ای سنتینل-۲ به همراه داده‌های میدانی دقیق و دانش بومی فنولوژیکی، امکان تولید نقشه‌های پوشش گیاهی با دقت بالا فراهم گردید.

یافته‌های پژوهش نشان داد که مدل پیشنهادی قادر است با صحت کلی ۹۶/۵۷ درصد و ضریب کاپای ۰/۸۵۸۲، طیف گسترده‌ای از کلاس‌های پوشش گیاهی را به‌درستی طبقه‌بندی کند. این سطوح از دقت، به‌ویژه در شناسایی کلاس‌های با پراکندگی مکانی محدود همچون توت‌فرنگی، حاکی از عملکرد پیشرفته‌تر این مدل نسبت به روش‌های سنتی نظیر جنگل تصادفی یا ماشین بردار پشتیبان باشد. وجه تمایز کلیدی این پژوهش در استفاده از تقویم فنولوژیکی بومی به‌منظور تعیین تاریخ‌های کلیدی رشد و طراحی هدفمند معماری مدل متناسب با ویژگی‌های محلی است که نقش مهمی در افزایش دقت طبقه‌بندی ایفا نموده است.

در عین حال، تحلیل نتایج نشان داد که در برخی کلاس‌های با تنوع طیفی بالا یا ساختارهای ریزمقیاس مکانی، از جمله

گلخانه‌ها یا مراتع، دقت طبقه‌بندی با افت نسبی مواجه بوده که لزوم توسعه مدل‌های ترکیبی چندمقیاسی، تقویت پایگاه‌های داده آموزشی و توجه بیشتر به ناهمگنی‌های فضایی را برجسته می‌سازد. با این حال، عملکرد مدل در سایر کلاس‌ها نظیر اراضی زراعی، مناطق شهری، باغات آبی و اراضی بایر، سطح بالایی از دقت را نشان داد و قابلیت اتکا برای بهره‌برداری عملیاتی را اثبات کرد.

از منظر کاربردی، مدل توسعه‌یافته در این پژوهش می‌تواند به‌عنوان پایه‌ای برای طراحی سامانه‌های هوشمند پایش کشاورزی، تدوین سیاست‌های مکان‌محور در مدیریت منابع، و تحلیل اقتصادی الگوهای کشت مورد استفاده قرار گیرد. همچنین، در چارچوب تحولات جهانی حوزه کشاورزی دیجیتال و امنیت غذایی، این مدل می‌تواند نقش مهمی در ارتقای بهره‌وری، کاهش اتلاف منابع و تسهیل فرآیند تصمیم‌سازی برای نهادهای اجرایی ایفا کند.

بر اساس نتایج این پژوهش، چند توصیه کلیدی مدیریتی ارائه می‌شود:

۱. طراحی سامانه‌های بومی پایش محصولات کشاورزی خاص در استان‌هایی مانند کردستان، مبتنی بر الگوریتم‌های یادگیری عمیق و داده‌های سنجنش‌ازدور.
  ۲. تلفیق تقویم فنولوژیکی محلی با داده‌های مکانی در تصمیم‌گیری‌های اجرایی، به‌ویژه در زمان‌بندی دقیق نهاده‌ها و برداشت محصول.
  ۳. حمایت از ایجاد و توسعه پایگاه‌های داده ملی و منطقه‌ای با برچسب‌های دقیق زمینی، جهت آموزش مدل‌های پیشرفته طبقه‌بندی.
  ۴. ایجاد زیرساخت نرم‌افزاری و سخت‌افزاری مناسب برای پیاده‌سازی مدل‌های هوشمند در سطح مزارع کوچک‌مقیاس و گلخانه‌ای.
  ۵. تمرکز بر مناطق با الگوهای پوشش پیچیده و پراکندگی بالا (نظیر گلخانه‌ها و مراتع) از طریق توسعه معماری‌های ترکیبی چندمقیاسی و داده‌افزایی هدفمند.
  ۶. افزایش همکاری میان نهادهای علمی، اجرایی و کشاورزان محلی به منظور توسعه پایش مشارکتی و ارتقاء سواد دیجیتال کشاورزی.
- در جمع‌بندی، نتایج این مطالعه نشان می‌دهد که هم‌افزایی مؤثر میان فناوری‌های نوین، دانش بومی و داده‌های دقیق، می‌تواند مبنای طراحی مدل‌های داده‌محور بومی در کشاورزی ایران قرار گیرد؛ مدل‌هایی که نه تنها از نظر علمی قابل استناد، بلکه از نظر اجرایی نیز قابل تعمیم، به‌روزرسانی و پیاده‌سازی در مقیاس‌های منطقه‌ای و ملی خواهند بود.

## References

- Ahangarha, M., Saadat Seresht, M., Shahhoseini, R., & Seyyedi, S. (2020). Crop land change monitoring based on deep learning algorithm using multi-temporal hyperspectral images. *Journal of Geomatics Science and Technology*, 10(2), 79–89. (In Persian) <https://dor.isc.ac/dor/20.1001.1.2322102.1399.10.2.6.9>
- Alipour, F., Aghkhani, M., Abbaspour, F. M., & Sepehr, A. (2015). *Demarcation and estimation of agricultural lands using ETM+ imagery data (case study: Astan Ghods Razavi great farm)*. (In Persian). <https://dor.isc.ac/dor/20.1001.1.22286829.1393.4.2.12.8>
- An, Q., Wang, K., Li, Z., Song, C., Tang, X., & Song, J. (2022). Real-time monitoring method of strawberry fruit growth state based on YOLO improved model. *IEEE Access*, 10, 124363–124372. <https://doi.org/10.1109/ACCESS.2022.3220234>

- Anjom, F. K., Vougioukas, S., & Slaughter, D. C. (2018). Development and application of a strawberry yield-monitoring picking cart. *Computers and Electronics in Agriculture*, 155(2), 400–411. <http://dx.doi.org/10.1016/j.compag.2018.10.038>
- Bargiel, D. (2017). A new method for crop classification combining time series of radar images and crop phenology information. *Remote Sensing of Environment*, 198, 369–383. <https://doi.org/10.1016/j.rse.2017.06.022>
- Chang, C.-I. (2007). *Hyperspectral data exploitation: Theory and applications*. John Wiley & Sons. DOI:10.1002/0470124628
- Chen, Y., Wu, X., & Xu, Q. (2024). A hybrid deep learning model based on Bi-LSTM for crop type classification in smallholder farms using multi-temporal satellite data. *PLoS ONE*, 19(3), e0299350. <https://doi.org/10.1371/journal.pone.0299350>
- Constante, P. N., Gordon, A., Chang, O., & Pruna, E. (2016). Artificial vision techniques to optimize strawberry's industrial classification. *IEEE Latin America Transactions*, 14(6), 2576–2581. <http://dx.doi.org/10.1109/TLA.2016.7555221>
- Csillik, O., & Belgiu, M. (2017). Cropland mapping from Sentinel-2 time series data using object-based image analysis. In *Proceedings of the 20th AGILE International Conference on Geographic Information Science Societal Geo-Innovation Celebrating* (Vol. 9, p. 20). Wageningen, The Netherlands.
- Du, X., Cheng, H., Ma, Z., Lu, W., Wang, M., Meng, Z., Jiang, C., & Hong, F. (2023). DSW-YOLO: A detection method for ground-planted strawberry fruits under different occlusion levels. *Computers and Electronics in Agriculture*, 214, 108304. <https://doi.org/10.1016/j.compag.2023.108304>
- Gadiraju, K. K., & Vatsavai, R. R. (2020). Comparative analysis of deep transfer learning performance on crop classification. In *Proceedings of the 9th ACM SIGSPATIAL International Workshop on Analytics for Big Geospatial Data* (pp. 1–8). <https://doi.org/10.1145/3423336.3431369>
- Heidari, M., tashakori, M. and Valipour, A. (2016). Investigating the local utilization of forest in north Zagros (Case study: Baneh Region). *Iranian Journal of Forest*, 8(3), 313-331. (In Persian) [https://www.ijf-isaforestry.ir/article\\_42271.html?lang=en](https://www.ijf-isaforestry.ir/article_42271.html?lang=en)
- Kang, Y., Khan, S., & Ma, X. (2009). Climate change impacts on crop yield, crop water productivity and food security: A review. *Progress in Natural Science*, 19(12), 1665–1674. <https://doi.org/10.1016/j.pnsc.2009.08.001>
- Khatami, R., Mountrakis, G., & Stehman, S. V. (2017). Mapping per-pixel predicted accuracy of classified remote sensing images. *Remote Sensing of Environment*, 191, 156–167. <http://dx.doi.org/10.1016/j.rse.2017.01.025>
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. <https://doi.org/10.48550/arXiv.1412.6980>
- Li, Z., Wang, J., Gao, G., Lei, Y., Zhao, C., Wang, Y., Bai, H., Liu, Y., Guo, X., & Li, Q. (2024). SGSNet: A lightweight deep learning model for fast and accurate detection of strawberry growth stages. *Frontiers in Plant Science*, 15, 1491706. <https://doi.org/10.3389/fpls.2024.1491706>
- Lyu, H., Lu, H., & Mou, L. (2016). Learning a transferable change rule from a recurrent neural network for land cover change detection. *Remote Sensing*, 8(6), 506. <https://doi.org/10.3390/rs8060506>
- Saleem, N., Balu, A., Jubery, T. Z., Singh, A., Singh, S. K., Sarkar, S., & Ganapathysubramanian, B. (2024). Class-specific data augmentation for plant stress classification in soybean. *bioRxiv*. <https://doi.org/10.1101/2024.06.18.549378>

- Wang, C., Wang, H., Han, Q., Zhang, Z., Kong, D., & Zou, X. (2024). Strawberry Detection and Ripeness Classification Using YOLOv8+ Model and Image Processing Method. *Agriculture*, 14(5), 751. <https://doi.org/10.3390/agriculture14050751>
- Xu, J., et al. (2020). DeepCropMapping: A multi-temporal deep learning approach with improved spatial generalizability for dynamic corn and soybean mapping. *Remote Sensing of Environment*, 247, 111946. <https://doi.org/10.1016/j.rse.2020.111946>
- Zheng, B., Myint, S. W., Thenkabail, P. S., & Aggarwal, R. M. (2015). A support vector machine to identify irrigated crop types using time-series Landsat NDVI data. *International Journal of Applied Earth Observation and Geoinformation*, 34, 103–112. <https://doi.org/10.1016/j.jag.2014.07.002>