Vol 16, No. 3, Autumn 2026

University of Tehran Press

Journal of Water and Irrigation Management Online ISSN: 2382-9931

Homepage: https://jwim.ut.ac.ir/

Identification Current Crop Pattern in Qazvin Irrigation Network Using Sentinel Imagery and Machine Learning Algorithms

Mina Torkaman[1] | Farhad Mirzayi Shirkoohi[2]✉ | Javad Bazr Afshan[3]

1. Department of Irrigation and Reclamation Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. Email: minatorkaman@ut.ac.ir
2. Corresponding Author, Department of Irrigation and Reclamation Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. Email: fmirzaei@ut.ac.ir
3. Department of Irrigation and Reclamation Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. Email: jbazr@ut.ac.ir

Article Info

Article type:
Research Article

Article history:
Received 21 June 2026
Received in revised form
12 July 2026
Accepted 19 August 2026
Published online 26 October 2026

Keywords:
CatBoost
Crop Area Estimation
Crop Classification
LightGBM
Optical and Radar Data

ABSTRACT

Monitoring agricultural lands and estimating crop area are essential components of water resources management and agricultural planning in semi-arid regions. This study aimed to evaluate the capability of multi-temporal optical and radar satellite data for classifying summer and autumn crops in the Qazvin irrigation network. For this purpose, time-series satellite images corresponding to key crop growth stages were processed, and the performance of five machine learning classification algorithms—CatBoost, LightGBM, Random Forest, XGBoost, and Support Vector Machine (SVM)—was compared for mapping major crops including corn, tomato, alfalfa, rapeseed, wheat, and barley. The classification outputs were assessed using overall accuracy and the Kappa coefficient. The results indicated that boosting-based methods, particularly CatBoost with a Kappa coefficient of 0.83 in summer and LightGBM with 0.85 in autumn, provided superior performance in crop discrimination and reducing pixel-level noise. In contrast, SVM, despite its acceptable statistical accuracy, showed lower spatial coherence due to its sensitivity to noise and over-estimation along field boundaries. The resulting crop maps illustrated well-structured spatial patterns and enabled reliable estimation of crop-specific cultivated areas. Overall, the findings demonstrate that integrating multi-temporal radar and optical data with advanced machine learning algorithms offers an effective and scalable approach for regional crop mapping and agricultural monitoring.

Cite this article: Torkaman, M., Mirzayi Shirkoohi, F., & Bazr Afshan, J. (2026). Identification Current Crop Pattern in Qazvin Irrigation Network Using Sentinel Imagery and Machine Learning Algorithms. *Journal of Water and Irrigation Management*, 16 (3), 559-580. DOI: https://doi.org/10.22059/jwim.2026.416921.1315

© The Author(s).
Publisher: University of Tehran Press.
DOI: https://doi.org/10.22059/jwim.2026.416921.1315

دوره شانزدهم، شماره سوم، پاییز ۱۴۰۵

انتشارات دانشگاه تهران

مدیریت آب و آبیاری

Homepage: https://jwim.ut.ac.ir/

شاپا الکترونیکی: ۹۹۳۱-۲۳۸۲

شناسایی الگوی فعلی کشت شبکه آبیاری قزوین با تصاویر سنتینل و الگوریتم‌های یادگیری ماشین

مینا ترکمان[۱] | فرهاد میرزایی[۲]✉ | جواد بذرافشان[۳]

۱. گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: minatorkaman@ut.ac.ir

۲. نویسنده مسئول، گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: fmirzaei@ut.ac.ir

۳. گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: jbazr@ut.ac.ir

اطلاعات مقاله

نوع مقاله: مقالهٔ پژوهشی

تاریخ دریافت: ۱۴۰۵/۰۳/۳۱

تاریخ بازنگری: ۱۴۰۵/۰۴/۲۱

تاریخ پذیرش: ۱۴۰۵/۰۵/۲۸

تاریخ انتشار: ۱۴۰۵/۰۸/۰۴

کلیدواژه‌ها:

برآورد سطح زیرکشت

داده‌های راداری و اپتیکی

طبقه‌بندی محصولات زراعی

CatBoost

LightGBM

چکیده

پایش اراضی زراعی و برآورد سطح زیرکشت محصولات از مؤلفه‌های مهم مدیریت منابع آب و برنامه‌ریزی کشاورزی در مناطق نیمه‌خشک است. هدف این پژوهش، ارزیابی قابلیت داده‌های راداری و اپتیکی چندزمانه در تفکیک محصولات زراعی تابستانه و پاییزه در محدوده دشت قزوین بود. بدین منظور، داده‌های ماهواره‌ای متناظر با مراحل رشد محصولات پردازش شد و عملکرد پنج روش طبقه‌بندی شامل CatBoost، LightGBM، Random Forest، XGBoost و Support Vector Machine (SVM) برای تفکیک محصولات اصلی منطقه شامل ذرت، گوجه‌فرنگی، یونجه، کلزا، گندم و جو مقایسه شد. ارزیابی نتایج با استفاده از شاخص‌های دقت کلی و ضریب کاپا انجام گرفت. نتایج نشان داد که روش‌های مبتنی بر تقویت، به‌ویژه CatBoost با ضریب کاپای ۰/۸۳ در تابستان و LightGBM با ضریب کاپای ۰/۸۵ در پاییز، عملکرد مناسب‌تری در تفکیک کلاس‌های زراعی و کاهش نویزهای پیکسلی داشتند. در مقابل، SVM با وجود دقت آماری قابل‌قبول، به‌دلیل حساسیت به نویز و بیش‌برآوردی مرز مزارع، پیوستگی مکانی کم‌تری نشان داد. نقشه‌های طبقه‌بندی‌شده، پراکنش مکانی محصولات را با انسجام مناسبی نمایش دادند و امکان برآورد سطح زیرکشت را فراهم کردند. یافته‌ها نشان می‌دهد که ادغام داده‌های راداری و اپتیکی با روش‌های نوین طبقه‌بندی، رویکردی کارآمد برای تحلیل مکانی محصولات زراعی در مقیاس منطقه‌ای است.

استناد: ترکمان، مینا؛ میرزایی، فرهاد و بذرافشان، جواد (۱۴۰۵). شناسایی الگوی فعلی کشت شبکه آبیاری قزوین با تصاویر سنتینل و الگوریتم‌های یادگیری ماشین. *نشریه مدیریت آب و آبیاری*، ۱۶ (۳)، ۵۵۹-۵۸۰. DOI: https://doi.org/10.22059/jwim.2026.416921.1315

ناشر: مؤسسه انتشارات دانشگاه تهران.

© نویسندگان.

۱. مقدمه

بخش کشاورزی بزرگ‌ترین مصرف‌کننده منابع آب شیرین در ایران به‌شمار می‌رود و سهم قابل‌توجهی از برداشت آب‌های سطحی و زیرزمینی را به خود اختصاص داده است. در شرایط اقلیمی خشک و نیمه‌خشک کشور، مدیریت بهینه مصرف آب در این بخش از اهمیت ویژه‌ای برخوردار است. یکی از مهم‌ترین ابزارهای مدیریت آب در کشاورزی، برنامه‌ریزی مناسب الگوی کشت است. الگوی کشت به ترکیب و توزیع مکانی محصولات زراعی در یک منطقه اشاره دارد و تعیین صحیح آن می‌تواند نقش مؤثری در افزایش بهره‌وری آب، کاهش فشار بر منابع آبی و ارتقای پایداری تولیدات کشاورزی ایفا کند.

برای برنامه‌ریزی و به‌روزرسانی الگوی کشت، آگاهی دقیق از وضعیت موجود کشت محصولات در سطح اراضی کشاورزی ضروری است. روش‌های سنتی پایش الگوی کشت که بیش‌تر مبتنی بر آمارهای ثبتی یا برداشت‌های میدانی هستند، معمولاً زمان‌بر، پرهزینه و در مقیاس‌های وسیع با محدودیت‌هایی همراه‌اند. در سال‌های اخیر، فناوری سنجش از دور به‌دلیل قابلیت پوشش وسیع مکانی، تکرار زمانی مناسب و دسترسی به داده‌های چندطیفی، به‌عنوان ابزاری کارآمد برای پایش اراضی کشاورزی و شناسایی محصولات زراعی موردتوجه قرار گرفته است.

پیشرفت‌های اخیر در حوزه تحلیل داده‌ها نیز زمینه استفاده گسترده از روش‌های هوشمند و الگوریتم‌های یادگیری ماشین را در پردازش داده‌های سنجش از دور فراهم کرده است. این روش‌ها با بهره‌گیری از ویژگی‌های طیفی، زمانی و مکانی تصاویر ماهواره‌ای قادرند دقت طبقه‌بندی کاربری اراضی و شناسایی محصولات کشاورزی را به‌طور قابل‌توجهی افزایش دهند. مطالعات متعددی در نقاط مختلف جهان نشان داده‌اند که ترکیب داده‌های ماهواره‌ای با روش‌های یادگیری ماشین می‌تواند نتایج قابل اعتمادی در تهیه نقشه‌های الگوی کشت ارائه دهد.

در سال‌های اخیر، توسعه فناوری سنجش از دور و دسترسی به تصاویر ماهواره‌ای با قدرت تفکیک مکانی و زمانی مناسب، امکان پایش دقیق اراضی کشاورزی و شناسایی محصولات زراعی را در مقیاس‌های منطقه‌ای و ملی فراهم کرده است. به‌ویژه با در دسترس قرارگرفتن داده‌های ماهواره‌های برنامه کوپرنیکوس از جمله Sentinel-1 و Sentinel-2، مطالعات متعددی در زمینه استخراج الگوی کشت و طبقه‌بندی محصولات کشاورزی انجام شده است. این داده‌ها به‌دلیل تناوب زمانی بالا، پوشش گسترده و دسترسی آزاد، به یکی از مهم‌ترین منابع اطلاعاتی برای پایش کشاورزی تبدیل شده‌اند.

در بسیاری از پژوهش‌ها نشان داده شده است که استفاده از الگوریتم‌های یادگیری ماشین در کنار داده‌های سنجش از دور می‌تواند دقت طبقه‌بندی محصولات کشاورزی را افزایش دهد. در یک مطالعه مروری جامع نیز مشخص شد که روش‌های یادگیری ماشین، به‌ویژه روش‌های مبتنی بر درخت تصمیم، عملکرد قابل‌توجهی در طبقه‌بندی تصاویر سنجش از دور دارند و در بسیاری از کاربردهای کشاورزی نسبت به روش‌های سنتی از دقت بالاتری برخوردارند (Belgiu & Drăguţ, 2016). در ادامه این روند، طبقه‌بندی محصولات کشاورزی با استفاده از سری زمانی تصاویر Sentinel-2 و الگوریتم‌های یادگیری ماشین انجام شد و نتایج نشان داد که استفاده از اطلاعات زمانی تصاویر ماهواره‌ای می‌تواند نقش مهمی در بهبود تفکیک محصولات مختلف داشته باشد (Pelletier *et al*., 2019).

در پژوهشی دیگر، با استفاده از داده‌های چندزمانه ماهواره‌ای و روش‌های یادگیری ماشین، نقشه محصولات کشاورزی در مقیاس منطقه‌ای تهیه شد و نتایج نشان داد که ترکیب ویژگی‌های طیفی و زمانی تصاویر ماهواره‌ای دقت طبقه‌بندی محصولات را به‌طور قابل‌توجهی افزایش می‌دهد (Zhong *et al*., 2019). هم‌چنین شناسایی محصولات کشاورزی با بهره‌گیری از سری زمانی تصاویر سنتینل و روش‌های پیشرفته تحلیل داده انجام شد و نتایج بیانگر آن بود که داده‌های چندزمانه ماهواره‌ای ابزار قدرتمندی برای پایش پویایی‌های کشاورزی در مقیاس وسیع محسوب می‌شوند (Waldner & Diakogiannis, 2020).

با پیشرفت الگوریتم‌های یادگیری ماشین، استفاده از ترکیب داده‌های اپتیکی و راداری نیز در مطالعات اخیر موردتوجه قرار گرفته است. نتایج برخی مطالعات نشان داده است که ترکیب داده‌های Sentinel-1 و Sentinel-2 می‌تواند دقت طبقه‌بندی محصولات کشاورزی را نسبت به استفاده از هرکدام از این داده‌ها به‌صورت مجزا افزایش دهد (Fan *et al*., 2024). هم‌چنین تهیه نقشه محصولات کشاورزی در مقیاس وسیع با استفاده از داده‌های چندزمانه ماهواره‌ای و روش‌های یادگیری ماشین انجام شده و نتایج حاکی از کارایی بالای این روش‌ها در پایش الگوی کشت بوده است (Van Tricht *et al*., 2021).

در سال‌های اخیر مطالعات متعددی نیز بر استفاده از داده‌های سری زمانی ماهواره‌ای برای پایش الگوی کشت تأکید کرده‌اند. برای مثال، تهیه نقشه محصولات کشاورزی با دقت بالا با استفاده از سری زمانی تصاویر سنتینل و الگوریتم‌های یادگیری ماشین انجام شده و نتایج نشان داده است که اطلاعات فنولوژیکی استخراج‌شده از تصاویر چندزمانه نقش مهمی در تفکیک محصولات مختلف دارد (Yi *et al*., 2020). هم‌چنین گزارش شده است که ترکیب داده‌های سنجش از دور و الگوریتم‌های یادگیری ماشین می‌تواند ابزار مؤثری برای پایش پویایی کشت محصولات در مناطق کشاورزی باشد (Raab *et al*., 2026).

براساس مطالعات مروری جامع Soomro *et al*. (2026)، الگوریتم‌های LightGBM و CatBoost به‌دلیل سرعت بالا، دقت پیش‌بینی مناسب و توانایی کار با داده‌های متنوع، از بهترین گزینه‌ها برای کاربردهای کشاورزی محسوب می‌شوند.

در ایران نیز پژوهش‌های متعددی در زمینه استفاده از سنجش از دور برای شناسایی محصولات کشاورزی و تهیه نقشه الگوی کشت انجام شده است. نتایج یک مطالعه نشان داد که استفاده از تصاویر Sentinel-2 و روش‌های طبقه‌بندی می‌تواند به شناسایی مناسب محصولات کشاورزی در بخشی از اراضی کشاورزی کشور منجر شود و داده‌های چندطیفی این ماهواره قابلیت مناسبی برای تفکیک محصولات زراعی دارند (Khosravi, 2024). هم‌چنین تهیه نقشه محصولات کشاورزی در مقیاس منطقه‌ای با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های یادگیری ماشین انجام شد و دقت قابل‌قبول این روش‌ها گزارش گردید (Taheri *et al*., 2021).

در پژوهشی دیگر، تهیه نقشه محصولات کشاورزی با استفاده از داده‌های ماهواره‌ای سنتینل و روش‌های طبقه‌بندی هوشمند انجام شد و نتایج نشان داد که استفاده از داده‌های چندزمانه می‌تواند به‌طور قابل‌توجهی دقت شناسایی محصولات را افزایش دهد (Asadi *et al*., 2024). هم‌چنین پایش الگوی کشت در اراضی کشاورزی با استفاده از تصاویر سنتینل و روش‌های یادگیری ماشین انجام شد و نتایج این مطالعه برای برنامه‌ریزی و مدیریت منابع آب و کشاورزی مفید ارزیابی شد (Soltani *et al*., 2025).

رویکرد غالب در پژوهش‌های نوین، بهره‌گیری از سری‌های زمانی داده‌های تلفیقی Sentinel-1 (راداری) و Sentinel-2 (اپتیکی) به‌همراه الگوریتم‌های یادگیری ماشین است که به‌عنوان روشی قدرتمند برای استخراج دقیق اطلاعات الگوی کشت، به‌ویژه در مناطق آبیاری شده خشک و نیمه‌خشک تثبیت شده است (Yu *et al*., 2025). مزیت کلیدی این رویکرد تلفیقی، توانایی آن در غلبه بر محدودیت‌های هر یک از سنجنده‌ها به‌تنهایی است؛ داده‌های راداری اطلاعات ساختاری (مانند بیومس و ارتفاع گیاه) و داده‌های اپتیکی اطلاعات طیفی (مانند کلروفیل و سلامت گیاه) را فراهم می‌کنند که این امر به‌ویژه در مناظر کشاورزی ناهمگون با تنوع کشت و ابعاد متفاوت مزارع، منجر به افزایش چشمگیر دقت طبقه‌بندی می‌شود (Chabalala *et al*., 2022). در امتداد این پیشرفت‌ها، تمرکز پژوهش‌ها از صرفاً استفاده از یادگیری ماشین به سمت ارزیابی و انتخاب بهینه‌ترین الگوریتم سوق یافته است. مطالعات اخیر به‌طور مشخص به تحلیل مقایسه‌ای الگوریتم‌های مختلف یادگیری ماشین در یک چارچوب شی‌مبنا پرداخته‌اند تا کاراترین مدل‌ها برای طبقه‌بندی محصولات شناسایی شوند (Be *et al*., 2024).

مروری بر پیشینه پژوهش نشان می‌دهد که اگرچه مطالعات ارزشمندی در زمینه پایش اراضی کشاورزی با استفاده از تصاویر ماهواره‌ای (به‌ویژه Landsat و Sentinel-2) و الگوریتم‌های یادگیری ماشین مانند جنگل تصادفی (RF) و ماشین بردار پشتیبان (SVM) در ایران و جهان انجام شده است، اما در شبکه‌های آبیاری استراتژیک و پیچیده‌ای مانند شبکه آبیاری قزوین، همچنان یک خلأ مطالعاتی در زمینه ارزیابی جامع و مقایسه‌ایِ نسل جدید الگوریتم‌های یادگیری ماشین مبتنی بر تقویت گرادیان (مانند CatBoost، LightGBM و XGBoost) وجود دارد. علاوه بر این، بیش‌تر مطالعات پیشین تنها بر داده‌های اپتیکی متمرکز بوده و از پتانسیل ترکیب داده‌های راداری (Sentinel-1) و اپتیکی (Sentinel-2) برای بهبود تفکیک‌پذیری کلاس‌های کشت در فصول مختلف کم‌تر بهره برده‌اند. بر این اساس، نوآوری اصلی پژوهش حاضر، مقایسه سیستماتیک الگوریتم‌های نوین Boosting با روش‌های مرسوم جهت شناسایی الگوی کشت پاییزه و تابستانه در شبکه آبیاری قزوین است. این مطالعه با بهره‌گیری از تلفیق داده‌های چندزمانه راداری و اپتیکی در سامانه گوگل ارث انجین، تلاش می‌کند تا دقیق‌ترین و پیوسته‌ترین مدل مکانی را برای برآورد سطح زیرکشت در این منطقه کلیدی معرفی نماید.

با وجود انجام مطالعات متعدد در زمینه شناسایی محصولات کشاورزی با استفاده از سنجش از دور، بررسی الگوی کشت در برخی از مناطق مهم کشاورزی کشور از جمله شبکه آبیاری قزوین همچنان نیازمند مطالعات دقیق‌تر است. این منطقه به‌عنوان یکی از قطب‌های مهم کشاورزی کشور نقش قابل‌توجهی در تولید محصولات زراعی دارد و شناخت دقیق توزیع مکانی محصولات در آن می‌تواند اطلاعات ارزشمندی برای برنامه‌ریزی کشاورزی و مدیریت منابع آب فراهم کند. از این‌رو، استفاده از داده‌های ماهواره‌ای و روش‌های نوین تحلیل داده برای تهیه نقشه الگوی کشت در این منطقه می‌تواند گامی مهم در جهت پایش وضعیت موجود و فراهم‌سازی اطلاعات موردنیاز برای برنامه‌ریزی‌های آتی باشد. در این راستا، پژوهش حاضر به دنبال پاسخگویی به سوالات اصلی زیر است: ۱- کدام یک از الگوریتم‌های یادگیری ماشین پیشرفته (CatBoost, LightGBM, XGBoost, Random Forest, SVM) بالاترین دقت را در تفکیک و طبقه‌بندی محصولات کشاورزی غالب (پاییزه و تابستانه) در شبکه آبیاری قزوین با استفاده از داده‌های ترکیبی Sentinel-1 و Sentinel-2 ارائه می‌دهند؟، ۲- آیا عملکرد الگوریتم‌های برتر در فصول کشت مختلف (تابستانه و پاییزه) با توجه به تفاوت در نوع و فنولوژی محصولات، متفاوت است؟، ۳- الگوی کشت مکانی و سطح زیرکشت برآوردی محصولات اصلی در منطقه موردمطالعه چگونه است و نقشه‌های حاصل تا چه حد می‌توانند ابزار مناسبی برای پایش کشاورزی باشند؟

۲. روش‌شناسی پژوهش

۲. ۱. منطقه موردمطالعه

دشت قزوین یکی از مهم‌ترین مناطق کشاورزی ایران است که در شمال‌غرب فلات مرکزی ایران و در استان قزوین واقع شده است. این دشت با وسعتی در حدود ۴۰۰۰ کیلومترمربع، از جمله مناطق مستعد کشاورزی کشور محسوب می‌شود و به‌دلیل وجود اراضی حاصلخیز، سابقه طولانی فعالیت‌های کشاورزی و دسترسی به منابع آب سطحی و زیرزمینی، نقش مهمی در تولید محصولات زراعی ایفا می‌کند (Abdoli *et al*., 2017; Ministry of Energy, 2019).

شبکه آبیاری و زه‌کشی قزوین به‌منظور تأمین و توزیع آب موردنیاز اراضی کشاورزی این دشت طراحی و احداث شده است و یکی از بزرگ‌ترین شبکه‌های آبیاری کشور به‌شمار می‌رود. این شبکه بیش‌تر از طریق سد طالقان و سامانه انتقال آب مربوطه تغذیه می‌شود و آب موردنیاز بخش قابل‌توجهی از اراضی کشاورزی منطقه را تأمین می‌کند (Zare Abyane *et al*., 2019). توسعه این شبکه نقش مهمی در افزایش بهره‌وری کشاورزی و گسترش اراضی آبی در منطقه داشته است.

از نظر اقلیمی، دشت قزوین دارای اقلیم نیمه‌خشک است و میانگین بارندگی سالانه در این منطقه حدود ۳۰۰

میلی‌متر گزارش شده است. توزیع نامناسب زمانی و مکانی بارش‌ها در کنار افزایش برداشت از منابع آب زیرزمینی، باعث شده است که مدیریت منابع آب در این منطقه از اهمیت ویژه‌ای برخوردار باشد (Madani *et al*., 2018).

اراضی کشاورزی واقع در شبکه آبیاری قزوین بیش‌تر به کشت محصولات زراعی مختلف اختصاص دارند که از مهم‌ترین آن‌ها می‌توان به گندم، جو، یونجه، کلزا، ذرت، سیب‌زمینی، پیاز، هندوانه و گوجه‌فرنگی اشاره کرد. تنوع محصولات زراعی در این منطقه در کنار محدودیت منابع آب، ضرورت پایش دقیق الگوی کشت و برنامه‌ریزی مناسب برای مدیریت منابع آب و خاک را بیش از پیش نمایان می‌سازد (Polus & Taati, 2022).

با توجه به اهمیت کشاورزی در دشت قزوین و نقش شبکه آبیاری این منطقه در تأمین امنیت غذایی و مدیریت منابع آب، شناخت دقیق توزیع مکانی محصولات کشاورزی و تهیه نقشه الگوی کشت می‌تواند اطلاعات ارزشمندی برای برنامه‌ریزی کشاورزی، مدیریت منابع آب و تصمیم‌گیری‌های مدیریتی در سطح منطقه فراهم سازد. در این پژوهش محدوده شبکه آبیاری قزوین به‌عنوان منطقه موردمطالعه انتخاب شد و فرایند تهیه نقشه الگوی کشت در این محدوده انجام گرفت. در شکل (۱) موقعیت جغرافیایی شبکه آبیاری قزوین نشان داده شده است.

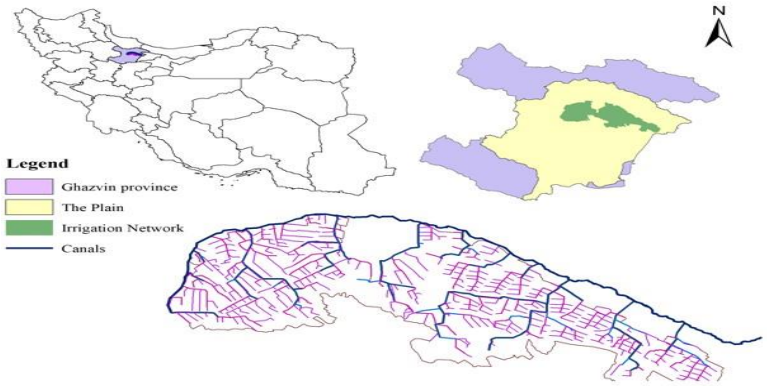


Figure 1. Geographic location of Qazvin province, irrigation network, and irrigation canals

۲. ۲. داده‌های مورداستفاده

۲. ۲. ۱. نمونه‌برداری میدانی

به‌منظور تهیه داده‌های مرجع برای آموزش و ارزیابی الگوریتم‌های طبقه‌بندی، عملیات نمونه‌برداری میدانی در منطقه موردمطالعه انجام شد. داده‌های میدانی در مطالعات سنجش از دور کشاورزی از اهمیت بالایی برخوردار هستند، زیرا اطلاعات دقیق مربوط به نوع محصول و موقعیت مکانی مزارع را فراهم کرده و به‌عنوان داده‌های آموزشی و داده‌های اعتبارسنجی در فرایند طبقه‌بندی مورداستفاده قرار می‌گیرند (Congalton & Green, 2019; Foody, 2002).

براساس بررسی‌های پیشین، مطالعات انجام‌شده در منطقه و هم‌چنین بازدیدهای میدانی، مشخص شد که شش محصول عمده شامل گندم، جو، کلزا، یونجه، ذرت و گوجه‌فرنگی به‌عنوان کشت‌های غالب در شبکه آبیاری قزوین شناخته می‌شوند. این محصولات به‌دلیل سطح زیر کشت قابل‌توجه و نقش مهم در تولیدات کشاورزی منطقه، به‌عنوان کلاس‌های اصلی در فرایند طبقه‌بندی انتخاب شدند. با توجه به تقویم زراعی محصولات منطقه، عملیات نمونه‌برداری میدانی در بازه زمانی اردیبهشت‌ماه تا شهریورماه سال ۱۴۰۳ انجام گرفت تا مراحل مختلف رشد محصولات زراعی در دوره تهیه تصاویر ماهواره‌ای پوشش داده شود. در این مرحله، مناطقی در سطح شبکه آبیاری قزوین به‌صورت تصادفی

انتخاب شدند و پس از مراجعه میدانی به مزارع و شناسایی نوع محصول زراعی از طریق مشاهده مستقیم، اطلاعات مربوط به هر مزرعه ثبت گردید. موقعیت مکانی مزارع با استفاده از دستگاه GPS دستی برداشت و مختصات جغرافیایی آن‌ها ثبت شد. هم‌چنین کلاس‌های مکمل شامل اراضی بایر، باغات و پهنه‌های آبی جهت آموزش مدل لحاظ گردید.

در ادامه، محدوده مزارع نمونه به‌صورت نقاط یا پلیگون‌های مرجع استخراج و به محیط پردازشی منتقل شد. این داده‌ها به‌عنوان اطلاعات مرجع (Ground Truth) در فرایند تحلیل مورداستفاده قرار گرفتند. بخشی از داده‌های برداشت‌شده برای آموزش الگوریتم‌های طبقه‌بندی و بخشی دیگر برای ارزیابی دقت نتایج طبقه‌بندی مورداستفاده قرار گرفتند. استفاده از داده‌های مرجع معتبر و برداشت‌شده در میدان، نقش مهمی در افزایش دقت طبقه‌بندی محصولات کشاورزی و ارزیابی صحیح نتایج حاصل از تحلیل داده‌های سنجش از دور دارد (Belgiu & Drăguţ, 2016; Maxwell *et al*., 2018).

در شکل (۲)، پراکنش مکانی نمونه‌های برداشت‌شده در محدوده شبکه آبیاری قزوین نمایش داده شده است که نشان‌دهنده توزیع مناسب داده‌های مرجع در سطح منطقه موردمطالعه می‌باشد.

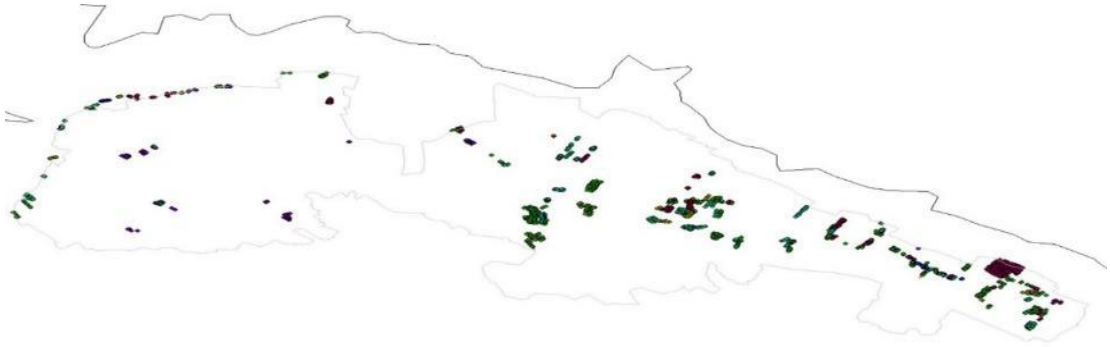


Figure 2. Spatial distribution of ground-sampled agricultural fields

۲. ۲. ۲. داده‌های ماهواره‌ای

در این پژوهش به‌منظور تهیه نقشه الگوی کشت منطقه موردمطالعه، از داده‌های ماهواره‌ای برنامه کوپرنیکوس شامل تصاویر Sentinel-1 و Sentinel-2 استفاده شد. این داده‌ها به‌دلیل دسترسی آزاد، پوشش زمانی مناسب و قدرت تفکیک مکانی قابل‌قبول، به‌طور گسترده در مطالعات پایش کشاورزی و شناسایی محصولات زراعی مورداستفاده قرار می‌گیرند (Drusch *et al*., 2012; Torres *et al*., 2012).

ماهواره Sentinel-2 یک سامانه سنجش از دور اپتیکی با قدرت تفکیک مکانی ۱۰ تا ۶۰ متر است که دارای ۱۳ باند طیفی در محدوده مرئی، فروسرخ نزدیک و فروسرخ کوتاه‌موج می‌باشد. این ویژگی‌ها امکان پایش دقیق پوشش گیاهی، استخراج شاخص‌های طیفی و تفکیک انواع محصولات کشاورزی را فراهم می‌کند (Drusch *et al*., 2012).

در کنار آن، ماهواره Sentinel-1 یک سامانه راداری با فناوری Synthetic Aperture Radar (SAR) است که قادر به تصویربرداری مستقل از شرایط ابری و روشنایی بوده و اطلاعات ارزشمندی درباره ساختار سطح زمین و پوشش گیاهی ارائه می‌دهد. استفاده از داده‌های راداری در کنار داده‌های اپتیکی می‌تواند دقت طبقه‌بندی محصولات کشاورزی را افزایش دهد (Torres *et al*., 2012; Veloso *et al*., 2017).

در این پژوهش تصاویر ماهواره‌ای مورداستفاده مربوط به دوره رشد محصولات زراعی در سال زراعی ۲۰۲۳–۲۰۲۴ بوده است. به این منظور داده‌های ماهواره‌ای در طول فصل‌های بهار و تابستان سال ۲۰۲۴ جمع‌آوری شدند تا تغییرات

فنولوژیکی محصولات مختلف در طول فصل رشد در فرایند طبقه‌بندی مورداستفاده قرار گیرد. استفاده از داده‌های چندزمانه یکی از روش‌های مؤثر برای تفکیک محصولات کشاورزی محسوب می‌شود، زیرا هر محصول در طول فصل رشد دارای الگوی زمانی متفاوتی از نظر بازتاب طیفی و ویژگی‌های راداری است (Belgiu & Csillik, 2018).

مشخصات داده‌های ماهواره‌ای Sentinel-1 و Sentinel-2 مورداستفاده در این پژوهش، که خلاصه‌ی آن در جدول (۱) آمده است، براساس مستندات فنی آژانس فضایی اروپا ارائه شده است (Drusch *et al*., 2012; ESA, 2024; Torres *et al*., 2012).

Table 1. Technical specifications of the Sentinel-1 and Sentinel-2 missions used in this study

Satellite / Sensor	Spectral / Polarization Capabilities	Spatial Resolution	Temporal Resolution (Revisit Time)
Sentinel-1 (SAR)	C-band (VV and VH polarizations)	10 m (IW GRD mode)	6–12 days
Sentinel-2 (MSI)	13 Spectral Bands (Visible, NIR, and SWIR)	10, 20, and 60 m	5 days (constellation)

۲. ۲. ۲. ۱. پیش‌پردازش داده‌های ماهواره‌ای و پردازش در بستر Google Earth Engine

مراحل دریافت داده‌ها و پیش‌پردازش تصاویر، در محیط پردازش ابری Google Earth Engine (GEE) انجام شد. Google Earth Engine یک سکو پردازش ابری برای تحلیل داده‌ها در مقیاس بزرگ است که امکان دسترسی مستقیم به آرشیو گسترده‌ای از داده‌های سنجش از دور را فراهم می‌کند. این سامانه با فراهم‌کردن زیرساخت محاسباتی قدرتمند و مجموعه‌ای از ابزارهای پردازشی، امکان پردازش و تحلیل سریع حجم زیادی از داده‌های ماهواره‌ای را بدون نیاز به دانلود آن‌ها فراهم می‌سازد (Gorelick *et al*., 2017). علاوه بر این، قابلیت اجرای الگوریتم‌های مختلف پردازش تصویر، استخراج شاخص‌های طیفی، تحلیل‌های زمانی و پیاده‌سازی روش‌های یادگیری ماشین در این محیط وجود دارد که موجب شده است استفاده از این پلتفرم در مطالعات کشاورزی و پایش پوشش زمین در سال‌های اخیر به‌طور چشمگیری افزایش یابد (Gorelick *et al*., 2017; Tamiminia *et al*., 2020).

در این مطالعه از تصاویر Sentinel-2 سطح پردازشی Level-2A که شامل بازتاب سطحی (Surface Reflectance) هستند، استفاده شد. تصاویر مربوط به دوره زمانی زمستان ۱۴۰۲ و بهار و تابستان سال ۱۴۰۳ انتخاب گردید تا مراحل مختلف رشد فنولوژیکی محصولات کشاورزی در منطقه موردمطالعه پوشش داده شود.

به‌منظور افزایش توان تفکیک محصولات کشاورزی، علاوه بر باندهای طیفی اصلی Sentinel-2، مجموعه‌ای از شاخص‌های طیفی نیز استخراج گردید. این شاخص‌ها شامل شاخص تفاضل نرمال‌شده پوشش گیاهی (NDVI)[۱]، شاخص تفاضل نرمال‌شده آب (NDWI)[۲]، شاخص پوشش گیاهی بهبود یافته (EVI)[۳]، شاخص تفاضل نرمال‌شده اراضی ساخته‌شده (NDBI)[۴]، شاخص پوشش گیاهی تعدیل‌شده با خاک (SAVI)[۵]، شاخص کلروفیل (GNDVI)[۶] و شاخص تفاضل نرمال‌شده زردی (NDYI)[۷] بودند. فرمول‌های محاسباتی این شاخص‌ها در جدول (۲) ارائه شده است. این شاخص‌ها اطلاعات ارزشمندی درباره ویژگی‌های طیفی و فنولوژیکی پوشش گیاهی فراهم می‌کنند و در بسیاری از مطالعات سنجش از دور برای پایش رشد گیاهان، ارزیابی وضعیت رطوبت پوشش گیاهی و تفکیک محصولات کشاورزی مورداستفاده قرار گرفته‌اند.

در کنار داده‌های اپتیکی، از تصاویر راداری Sentinel-1 نیز استفاده شد. داده‌های Sentinel-1 به‌دلیل قابلیت تصویربرداری مستقل از شرایط جوی و نور خورشید، امکان پایش مداوم سطح زمین را فراهم می‌کنند و می‌توانند اطلاعات مفیدی درباره ساختار پوشش گیاهی و ویژگی‌های سطح زمین ارائه دهنددر این پژوهش از تصاویر راداری با قطبش‌های VV و VH در مد پهنه گسترده تداخل‌سنجی (IWS)[۸] استفاده شد.

Table 2. Vegetation indices derived from Sentinel-2 imagery and used in the present study

Index	Formula	Application / Description	Reference
NDVI	$\frac{NIR-Red}{NIR+Red}$	The most common index for detecting vegetation health and density; used to estimate agricultural crops and separate vegetation-related variability.	Rouse *et al.*, 1973
NDWI	$\frac{Green-NIR}{Green+NIR}$	Used to monitor surface moisture, distinguish water bodies, and estimate water content in plants; useful for moisture-sensitive crops.	McFeeters, 1996
SAVI	$\frac{NIR-Red}{NIR+6*Red-7.5*Blue+1}*2.5$	Suitable for areas with sparse vegetation and exposed soil because it reduces soil effects and improves monitoring accuracy in growing crops.	Huete, 1988
EVI	$\frac{(1+L)(NIR-Red)}{NIR+Red+L}$	More sensitive than NDVI to dense vegetation; does not saturate easily in high-cover areas and is sensitive to chlorophyll changes.	Huete *et al.*, 2002
NDBI	$\frac{SWIR-NIR}{SWIR+NIR}$	Useful for identifying built-up areas and land-use changes; effective in separating agricultural land from urban areas.	Zha *et al.*, 2003
NDYI	$\frac{Green-Blue}{Green+Blue}$	Used for monitoring flowering vegetation in some plants such as canola and some crops like corn/maize.	Sulik & Long., 2016
GNDVI	$\frac{NIR-Green}{NIR+Green}$	More sensitive than NDVI for detecting plant health and chlorophyll content; used for precise monitoring of crop health.	Gitelson *et al.*, 1996

در نهایت تمامی لایه‌های اطلاعاتی شامل باندهای طیفی Sentinel-2، شاخص‌های طیفی استخراج‌شده و باندهای راداری Sentinel-1 در قالب یک مجموعه داده چندمنبعی ترکیب شدند و به‌عنوان متغیرهای ورودی الگوریتم‌های یادگیری ماشین برای طبقه‌بندی محصولات کشاورزی مورداستفاده قرار گرفتند. ترکیب داده‌های اپتیکی و راداری به‌دلیل ارائه اطلاعات مکمل از ویژگی‌های طیفی و ساختاری پوشش گیاهی می‌تواند دقت شناسایی و تفکیک محصولات کشاورزی را به‌طور قابل‌توجهی افزایش دهد.

۲. ۳. قطعه‌بندی[۹] و بهینه‌سازی کلاس‌ها

به‌منظور انتقال از تحلیل پیکسل‌پایه به شی‌پایه، از الگوریتم Simple Non-Iterative Clustering (SNIC) استفاده شد. این الگوریتم با گروه‌بندی پیکسل‌های مشابه براساس شاخص‌های طیفی و مکانی، قطعات همگنی را ایجاد کرد. جهت کاهش خطای طبقه‌بندی و پوشش کامل منطقه، از الگوریتم نظارت‌نشده K-means برای شناسایی مناطقی که در نمونه‌برداری اولیه لحاظ نشده بودند استفاده شد. این مناطق تحت عنوان کلاس «سایر» به مجموعه داده‌های آموزشی اضافه شدند تا مدل توانایی تشخیص اراضی غیرهدف را پیدا کرده و دقت تفکیک کلاس‌های اصلی افزایش یابد.

۲. ۴. انتخاب ویژگی (Feature Selection)

با توجه به حجم بالای شاخص‌های استخراج‌شده (شامل شاخص‌های مشتق‌شده از Sentinel-2 و شاخص‌های راداری)، فرایند انتخاب ویژگی در محیط Google Colab با استفاده از ۱۰ روش مختلف از جمله Variance Threshold، Mutual Information، L1/L2 Logistic Regression، Random Forest Importance، Extra Trees، Permutation Importance، ANOVA F-test، XGboost Importance و LightGBM Importance انجام گرفت. در نهایت، ۲۵ ویژگی برتر که بیش‌ترین نقش را در جداسازی کلاس‌ها داشتند، انتخاب شدند.

۲. ۵. الگوریتم‌های طبقه‌بندی

به‌منظور تهیه نقشه الگوی کشت منطقه موردمطالعه، از الگوریتم‌های یادگیری ماشین برای طبقه‌بندی داده‌های

ماهواره‌ای استفاده شد. الگوریتم‌های یادگیری ماشین به‌دلیل توانایی بالا در تحلیل داده‌های چندبعدی و استخراج روابط پیچیده میان متغیرها، در سال‌های اخیر به‌طور گسترده در مطالعات سنجش از دور و شناسایی محصولات کشاورزی مورداستفاده قرار گرفته‌اند (Maxwell *et al*., 2018). در این پژوهش پنج الگوریتم پرکاربرد شامل Random Forest، CatBoost، LightGBM، XGBoost و SVM برای طبقه‌بندی داده‌ها به‌کار گرفته شد. ویژگی‌های کلیدی و مزایای استفاده از هر یک از این الگوریتم‌ها در جدول (۳) خلاصه شده است.

Table 3. Characteristics and advantages of the classification algorithms used in the study

Algorithm	Key Features	Advantages in this Research	Reference
Random Forest	Ensemble of decision trees; Majority voting; Random feature and sample selection	Reduces overfitting; robust to non-linear data and multiple features	Breiman (2001)
SVM	Optimal hyperplane for class separation; Kernel functions usage	Effective with limited training samples and complex decision boundaries	Cortes & Vapnik (1995)
XGBoost	Gradient boosting with sequential tree building and error correction	High accuracy; regularization control; handles complex non-linear relations	Chen & Guestrin (2016)
LightGBM	Gradient boosting with leaf-wise tree growth	High training speed; lower memory usage; suitable for large datasets	Ke *et al*. (2017)
CatBoost	Gradient boosting based on Ordered Boosting mechanism	Minimizes prediction shift and overfitting; stable performance on complex data	Prokhorenkova *et al*. (2018)

در این پژوهش، این پنج الگوریتم با استفاده از داده‌های آموزشی حاصل از نمونه‌های میدانی اجرا شدند و از باندهای طیفی، شاخص‌های طیفی و داده‌های راداری به‌عنوان متغیرهای ورودی مدل‌ها استفاده شد. نتایج حاصل از اجرای الگوریتم‌ها با استفاده از معیارهای ارزیابی دقت موردبررسی قرار گرفت تا عملکرد آن‌ها در شناسایی محصولات کشاورزی منطقه موردمطالعه مقایسه شود.

۲. ۶. پارامترهای ارزیابی دقت

در این پژوهش، جهت سنجش کیفیت طبقه‌بندی محصولات زراعی از مهم‌ترین شاخص‌های ارزیابی در حوزه سنجش‌ازدور استفاده شد. مبنای محاسبه تمام این شاخص‌ها، ماتریس خطا (Confusion Matrix) است که تقابل میان کلاس‌های پیش‌بینی‌شده توسط مدل و کلاس‌های واقعی (داده‌های مرجع زمینی) را نشان می‌دهد. براساس این ماتریس، شاخص‌های ارزیابی به شرح زیر تعریف می‌شوند:

- دقت مثبت (Precision): نشان‌دهنده نسبت پیکسل‌های به‌درستی طبقه‌بندی‌شده در یک کلاس خاص به کل پیکسل‌هایی است که مدل به آن کلاس تخصیص داده است. این معیار قابلیت اطمینان مدل را ارزیابی می‌کند.
- حساسیت (Recall): بیانگر نسبت پیکسل‌های به‌درستی تشخیص‌داده‌شده یک کلاس به کل پیکسل‌های واقعی آن کلاس در داده‌های مرجع است.
- معیار F1 (F1-Score): میانگین همساز (Harmonic Mean) بین شاخص‌های دقت مثبت و حساسیت است و تعادلی بین این دو ایجاد می‌کند؛ این معیار به‌ویژه در شرایطی که مساحت کلاس‌های زراعی نامتوازن باشد، عملکرد مدل را به شکل دقیق‌تری ارزیابی می‌کند.
- دقت کلی (Overall Accuracy): نسبت کل پیکسل‌های به‌درستی طبقه‌بندی‌شده به کل نمونه‌های موردارزیابی در تمام کلاس‌ها را نشان می‌دهد.

- ضریب کاپا (Kappa Coefficient): معیاری آماری است که میزان توافق بین نقشه طبقه‌بندی‌شده و داده‌های مرجع را با حذف اثر توافقات تصادفی می‌سنجد.

جزئیات تکمیلی شامل فرمول‌های محاسباتی، هدف دقیق از کاربرد در این مطالعه و منابع علمی مرجع برای هر یک از این شاخص‌ها در جدول (۴) ارائه شده است. این معیارها بر پایه مطالعات مرجع نظیر Congalton (1991) و Cohen (1960) هستند و از پرکاربردترین روش‌های ارزیابی در حوزه سنجش از دور محسوب می‌شوند.

Table 4. Accuracy assessment metrics used for evaluating crop classification results

Evaluation Metric	Symbol / Formula	Purpose in This Study	Reference
Overall Accuracy (OA)	OA = (TP + TN) / (Total Samples)	Measures the overall proportion of correctly classified crop pixels.	Congalton (1991)
Precision	Precision = TP / (TP + FP)	Evaluates the reliability of positive crop class predictions.	Powers (2011)
Recall (Sensitivity)	Recall = TP / (TP + FN)	Measures the ability of the model to correctly detect each crop class.	Powers (2011)
F1-Score	F1 = 2 × (Precision × Recall) / (Precision + Recall)	Provides a balanced measure combining Precision and Recall.	Dice (1945)
Confusion Matrix	Matrix of Actual vs. Predicted Classes	Displays class-wise agreement and misclassification patterns.	Stehman (1997)
Kappa Coefficient	$\kappa = (Po - Pe) / (1 - Pe)$	Assesses classification agreement adjusted for random chance.	Cohen (1960)

۳. یافته‌های پژوهش و بحث

۳. ۱. ارزیابی عملکرد مدل‌های طبقه‌بندی محصولات تابستانه و پاییزه

در این پژوهش، به‌منظور شناسایی و پایش الگوی کشت در محدوده شبکه آبیاری قزوین، عملکرد پنج الگوریتم یادگیری ماشین شامل CatBoost، XGBoost، LightGBM، Random Forest و SVM موردارزیابی قرار گرفت. ارزیابی مدل‌ها به‌صورت جداگانه برای دو فصل تابستانه و پاییزه انجام شد تا توانایی هر الگوریتم در تفکیک کلاس‌های زراعی و غیرزراعی در شرایط فنولوژیکی متفاوت بررسی شود.

در طبقه‌بندی تابستانه، کلاس‌های موردبررسی شامل ذرت، یونجه، گوجه‌فرنگی، بایر، باغ و سایر بودند. در طبقه‌بندی پاییزه نیز کلاس‌ها شامل بایر، باغ، کلزا، گندم، جو، یونجه و سایر در نظر گرفته شدند. با توجه به تفاوت الگوی رشد، تراکم پوشش گیاهی و رفتار طیفی محصولات در دو فصل، انتظار می‌رود میزان تفکیک‌پذیری کلاس‌ها و خطاهای طبقه‌بندی نیز در تابستان و پاییز متفاوت باشد.

برای ارزیابی عملکرد مدل‌ها، سه شاخص اصلی Precision، Recall و F1-score برای هر کلاس محاسبه شد. نتایج مربوط به شاخص‌های ارزیابی در جدول (۵) آورده شده است.

براساس نتایج به‌دست‌آمده، مدل CatBoost در هر دو فصل عملکرد مطلوب‌تری نسبت به سایر الگوریتم‌ها نشان داد. برتری این مدل به‌ویژه در کلاس‌هایی قابل‌مشاهده بود که از نظر طیفی با سایر کلاس‌ها هم‌پوشانی بیش‌تری داشتند. این موضوع نشان می‌دهد که CatBoost توانسته است روابط غیرخطی موجود میان باندهای طیفی، شاخص‌های گیاهی و ویژگی‌های راداری را بهتر از سایر مدل‌ها شناسایی کند.

در فصل تابستان، به‌دلیل وجود تنوع بیش‌تر محصولات زراعی، تفاوت در زمان کاشت و برداشت و هم‌چنین تفاوت در تراکم پوشش گیاهی، تفکیک برخی کلاس‌ها نسبت به پاییز پیچیده‌تر بود. به‌طور خاص، کلاس‌هایی مانند گوجه‌فرنگی، یونجه

و سایر می‌توانند در برخی مراحل رشد، رفتار طیفی نزدیک‌تری با یکدیگر داشته باشند. هم‌چنین، وجود پیکسل‌های ترکیبی در حاشیه مزارع، کانال‌های آبیاری و قطعات کوچک کشاورزی می‌تواند باعث کاهش Precision یا Recall در برخی کلاس‌ها شود.

Table 5. Performance evaluation metrics of machine learning models for crop classification

Model	Summer crops				Autumn crops			
	Class	Precision	Recall	F1	Class	Precision	Recall	F1
Random Forest	Corn	0.8	0.92	0.85	Canola	0.945	0.942	0.943
	Alfalfa	1	0.83	0.91	Alfalfa	0.958	0.95	0.954
	Tomato	0.79	0.73	0.76	Wheat / Barley	0.978	0.971	0.974
	Bare land	0.91	0.91	0.91	Bare land	0.958	0.962	0.96
	Orchard	0.93	0.85	0.89	Orchard	0.965	0.97	0.967
	Other	0.94	0.79	0.86	Other	0.955	0.945	0.95
CatBoost	Corn	0.84	0.93	0.88	Canola	0.962	0.958	0.96
	Alfalfa	0.86	1	0.92	Alfalfa	0.971	0.965	0.968
	Tomato	0.88	0.73	0.8	Wheat / Barley	0.985	0.978	0.981
	Bare land	0.91	0.91	0.91	Bare land	0.968	0.972	0.97
	Orchard	0.94	0.88	0.91	Orchard	0.975	0.98	0.977
	Other	0.94	0.79	0.86	Other	0.965	0.96	0.962
LightGBM	Corn	0.82	0.9	0.86	Canola	0.95	0.948	0.949
	Alfalfa	1	1	1	Alfalfa	0.96	0.952	0.956
	Tomato	0.78	0.7	0.74	Wheat / Barley	0.975	0.97	0.972
	Bare land	0.91	0.91	0.91	Bare land	0.955	0.96	0.957
	Orchard	0.94	0.88	0.91	Orchard	0.968	0.968	0.968
	Other	0.88	0.79	0.83	Other	0.952	0.948	0.95
XGBoost	Corn	0.85	0.92	0.88	Canola	0.955	0.95	0.952
	Alfalfa	0.86	1	0.92	Alfalfa	0.964	0.958	0.961
	Tomato	0.81	0.7	0.75	Wheat / Barley	0.979	0.972	0.975
	Bare land	0.91	0.91	0.91	Bare land	0.96	0.965	0.962
	Orchard	0.94	0.91	0.92	Orchard	0.97	0.972	0.971
	Other	0.94	0.79	0.86	Other	0.958	0.952	0.955
SVM	Corn	0.8	0.88	0.84	Canola	0.91	0.905	0.907
	Alfalfa	1	1	1	Alfalfa	0.925	0.918	0.921
	Tomato	0.78	0.7	0.74	Wheat / Barley	0.942	0.935	0.938
	Bare land	0.83	0.91	0.87	Bare land	0.92	0.928	0.924
	Orchard	0.94	0.88	0.91	Orchard	0.938	0.94	0.939
	Other	0.94	0.84	0.89	Other	0.915	0.91	0.912

در طبقه‌بندی پاییزه، محصول غالب منطقه، یعنی گندم و جو، به‌دلیل سطح زیرکشت گسترده‌تر و الگوی فنولوژیکی نسبتاً مشخص، با دقت مناسبی شناسایی شد. با این‌حال، در مراحل اولیه رشد، امکان شباهت طیفی میان گندم و جو، کلزا و یونجه وجود دارد، زیرا این کلاس‌ها در بخشی از دوره رشد دارای پوشش سبز، رطوبت نسبی خاک و شاخص‌های گیاهی نزدیک به هم هستند. بنابراین، بخشی از خطاهای طبقه‌بندی پاییزه را می‌توان ناشی از هم‌پوشانی زمانی و طیفی میان محصولات سبز پاییزه دانست.

۳. ۲. مقایسه دقت کلی و ضریب کاپا در مدل‌های مختلف

علاوه بر شاخص‌های سطح کلاس، عملکرد کلی مدل‌ها با استفاده از دو شاخص دقت کلی (Overall Accuracy) و ضریب کاپا (Kappa coefficient) نیز ارزیابی شد. دقت کلی نشان‌دهنده نسبت کل نمونه‌های درست طبقه‌بندی‌شده به کل نمونه‌های ارزیابی است. با این‌حال، ازآنجاکه دقت کلی می‌تواند تحت تأثیر کلاس‌های غالب قرار گیرد، شاخص کاپا نیز محاسبه شد. ضریب کاپا میزان توافق میان طبقه‌بندی مدل و داده‌های مرجع را با در نظرگرفتن توافق تصادفی بیان می‌کند و بنابراین معیار قوی‌تری برای ارزیابی کیفیت طبقه‌بندی محسوب می‌شود. مقادیر دقت کلی و ضریب کاپا برای طبقه‌بندی پاییزه و تابستانه در جدول (۶) آورده شده است.

Table 6. Comparison of overall accuracy and Kappa values for different models in summer and autumn

Model	Autumn crops		Summer crops	
	Overal Accuracy	Kappa Coefficient	Overal Accuracy	Kappa Coefficient
Random Forest	0.87	0.84	0.85	0.81
CatBoost	0.87	0.84	0.87	0.83
LightGBM	0.88	0.85	0.85	0.81
XGBoost	0.85	0.81	0.86	0.83
SVM	0.86	0.83	0.85	0.81

نتایج مقایسه الگوریتم‌های یادگیری ماشین نشان داد که عملکرد مدل‌ها در دو فصل زراعی تابستانه و پاییزه تفاوت‌هایی دارد. در فصل پاییز، مدل LightGBM بهترین عملکرد را در میان الگوریتم‌های موردبررسی نشان داد و به دقت کلی برابر با ۸۸ درصد، ضریب کاپا برابر با ۰/۸۵ دست یافت. عملکرد برتر این مدل را می‌توان به ساختار رشد درختی leaf-wise و بهینه‌سازی مبتنی بر گرادیان نسبت داد که امکان شناسایی الگوهای پیچیده و روابط غیرخطی میان ویژگی‌های طیفی و کلاس‌های محصول را فراهم می‌کند. در این فصل، محصولات زراعی مانند گندم و جو، کلزا و یونجه در مراحل فنولوژیکی متفاوتی قرار دارند و این تفاوت‌ها موجب ایجاد تمایز قابل‌توجه در شاخص‌های پوشش گیاهی مانند NDVI و SAVI در تصاویر Sentinel-2 می‌شود. هم‌چنین استفاده از داده‌های راداری Sentinel-1 و ویژگی‌های پس‌پراکندگی[۱۰] به تفکیک بهتر ساختار پوشش گیاهی کمک می‌کند. مدل LightGBM با توانایی بالا در بهره‌گیری از این الگوهای طیفی–زمانی، توانسته است مرز بین کلاس‌های مختلف محصولات پاییزه را با دقت بیش‌تری تشخیص دهد.

در مقابل، در فصل تابستان مدل CatBoost بهترین عملکرد را در میان الگوریتم‌های موردبررسی نشان داد و به دقت کلی برابر با ۸۷ درصد، ضریب کاپا برابر با ۰/۸۳ دست یافت. برتری این مدل را می‌توان به مکانیزم بوستینگ ترتیبی[۱۱] و توانایی آن در کاهش سوگیری پیش‌بینی و جلوگیری از بیش‌برازش نسبت داد. در فصل تابستان، محصولات زراعی مانند ذرت و گوجه‌فرنگی در بسیاری از مراحل رشد دارای ویژگی‌های طیفی نسبتاً مشابهی هستند و به‌ویژه در شرایط پوشش گیاهی متراکم، تمایز طیفی میان آن‌ها در تصاویر اپتیکی کاهش می‌یابد. این مسئله می‌تواند موجب افزایش تداخل طبقه‌بندی بین کلاس‌ها شود. الگوریتم CatBoost به‌دلیل توانایی بالا در مدل‌سازی تعاملات پیچیده بین ویژگی‌ها و مدیریت داده‌های ناهمگن، قادر است تغییرات ظریف زمانی در شاخص‌های پوشش گیاهی و سیگنال‌های راداری را بهتر شناسایی کند. در نتیجه این مدل در تفکیک محصولات تابستانه پایداری و دقت بیش‌تری نشان داده است.

در این پژوهش، الگوریتم LightGBM با ضریب کاپای ۰/۸۵ به‌عنوان بهترین عملکرد شناسایی شد. این یافته با نتایج سایر مطالعات مقایسه‌ای در زمینه طبقه‌بندی محصولات هم‌راستا است. به‌عنوان مثال، Be *et al.* (2025) در پژوهش خود که به تحلیل مقایسه‌ای الگوریتم‌های یادگیری ماشین برای طبقه‌بندی شی‌مبنای محصولات پرداختند، نیز به برتری الگوریتم‌های گروهی مبتنی بر درخت اشاره کردند. هرچند مقادیر دقیق دقت ممکن است به‌دلیل تفاوت در شرایط اقلیمی منطقه، پیچیدگی الگوی کشت و نوع داده‌های ماهواره‌ای متفاوت باشد، اما روند کلی برتری این دسته از الگوریتم‌ها در هر دو پژوهش مشهود است. به‌طور خاص، استفاده از داده‌های راداری در پژوهش حاضر می‌تواند یکی از دلایل دست‌یابی به دقت بالا در تفکیک محصولات با ساختارهای فیزیکی متفاوت باشد.

البته، برخی مطالعات ممکن است به دقت‌های بالاتری (مثلاً کاپای بالای۰/۹۰) دست یافته باشند. این تفاوت غالباً به‌دلیل شرایط ساده‌تر منطقه موردمطالعه، مانند وجود مزارع بزرگ و یکپارچه، یا تعداد کم‌تر کلاس‌های زراعی است. منطقه شبکه آبیاری قزوین به‌دلیل ناهمگونی، تنوع کشت و وجود قطعات زراعی کوچک، چالش طبقه‌بندی پیچیده‌تری را ارائه می‌دهد که دست‌یابی به دقت بالای ۰/۸۵ در چنین شرایطی، یک یافته قابل‌توجه محسوب می‌شود.

نتایج به‌دست‌آمده در این پژوهش که نشان‌دهنده برتری الگوریتم‌های LightGBM و CatBoost با ضریب کاپای

بالای ۰/۸ است، با یافته‌های کلی در این حوزه همخوانی دارد. به‌عنوان مثال، Soomro و همکاران (۲۰۲۶) در تحلیل جامع خود بر روی ۴۵ پژوهش نشان دادند که الگوریتم‌هایی نظیر LightGBM و CatBoost به‌طور پیوسته در کاربردهای مختلف کشاورزی، از جمله طبقه‌بندی کاربری اراضی و محصولات، به دقت‌های بالایی دست می‌یابند و کارایی آن‌ها نسبت به روش‌های سنتی‌تر اثبات شده است. بنابراین، یافته‌های این پژوهش، کاربرد موفقیت‌آمیز این الگوریتم‌های نوین را در شرایط بومی شبکه آبیاری قزوین تأیید می‌کند.

به‌طورکلی، نتایج این پژوهش نشان می‌دهد که الگوریتم‌های مبتنی بر گرادیان بوستینگ از جمله LightGBM و CatBoost عملکرد بسیار مناسبی در طبقه‌بندی محصولات کشاورزی در شبکه آبیاری قزوین دارند. با این‌حال، انتخاب مدل بهینه می‌تواند به شرایط فصلی، پویایی فنولوژیکی محصولات و ویژگی‌های طیفی–زمانی داده‌های ورودی وابسته باشد. درحالی‌که LightGBM توانایی بیش‌تری در تفکیک محصولات پاییزه نشان داد، CatBoost در طبقه‌بندی محصولات تابستانه عملکرد بهتری ارائه کرد. این نتایج اهمیت درنظرگرفتن ویژگی‌های فنولوژیکی محصولات و ساختار داده‌های سنجش از دور را در انتخاب الگوریتم مناسب برای پایش الگوی کشت نشان می‌دهد.

۳. ۳. تحلیل فضایی و بصری نقشه‌های الگوی کشت پاییزه

بررسی بصری نقشه‌های الگوی کشت پاییزه حاصل از پنج الگوریتم یادگیری ماشین (شکل ۳) نشان می‌دهد که تمامی مدل‌ها توانسته‌اند ساختار کلی توزیع کلاس‌های other، bareland، orchard، canola، wheat/barley و alfalfa را بازنمایی کنند، اما میزان پیوستگی فضایی، تراکم لکه‌های منفرد و وضوح مرزهای قطعات زراعی در میان مدل‌ها متفاوت است. به‌طورکلی، کلاس wheat/barley در بخش‌های وسیعی از منطقه غالب است و بیش‌ترین تداوم فضایی را نشان می‌دهد، درحالی‌که کلاس‌های canola و alfalfa به‌صورت لکه‌های پراکنده‌تر و خردشده‌تری ظاهر شده‌اند.

در مقایسه مدل‌ها، Random Forest بیش‌ترین میزان پراکندگی پیکسلی و نویز فضایی را تولید کرده است، به‌طوری‌که مرز میان قطعات زراعی در بسیاری از نواحی به‌صورت ناپیوسته و خردشده مشاهده می‌شود. این رفتار نشان‌دهنده محدودیت این الگوریتم در بازسازی ساختار فضایی یکنواخت‌تر در داده‌های پیچیده سنجش‌ازدوری است. مدل SVM نیز اگرچه در برخی نواحی تفکیک قابل‌قبولی ارائه داده، اما همچنان در نمایش پیوسته کلاس‌های زراعی، به‌ویژه در قطعات کوچک‌تر، با پراکندگی قابل‌توجه همراه بوده است.

در میان مدل‌های مبتنی بر Boosting، CatBoost و LightGBM نقشه‌هایی با انسجام فضایی بیش‌تر و نویز کم‌تر تولید کرده‌اند. به‌ویژه خروجی LightGBM، علاوه بر انطباق بهتر با الگوی غالب فضایی منطقه، مرزهای منظم‌تری میان کلاس‌های زراعی و غیرزراعی نمایش می‌دهد. این موضوع با نتایج کمی عملکرد مدل‌ها نیز همخوان است، به‌طوری‌که LightGBMدر فصل پاییز بالاترین دقت کلی و کاپای طبقه‌بندی را کسب کرده و از نظر بصری نیز منسجم‌ترین نقشه را ارائه کرده است. CatBoost نیز عملکردی نزدیک به LightGBM دارد و در نمایش بهتر قطعات زراعی خردتر، به‌ویژه در نواحی مرکزی و شرقی منطقه، برتری نسبی نشان می‌دهد.

از نظر توزیع مکانی، در بخش‌های شرقی و مرکزی منطقه غلبه کلاس wheat/barley کاملاً مشهود است، درحالی‌که نواحی حاشیه‌ای و غربی بیش‌تر تحت سلطه کلاس‌های other و bareland قرار دارند. کلاس orchard نیز به‌صورت لکه‌های محدود و پراکنده ظاهر شده و در برخی مدل‌ها با کلاس‌های مجاور دچار اختلاط پیکسلی شده است. این الگوی فضایی نشان می‌دهد که شرایط فنولوژیک فصل پاییز، همراه با یکنواختی نسبی برخی سطوح زراعی و وجود قطعات کوچک و ناهمگون، طبقه‌بندی را دشوارتر کرده است.

در مجموع، مقایسه نقشه‌های پاییزه نشان می‌دهد که الگوریتم‌های Boosting، به‌ویژه LightGBM و CatBoost نه‌تنها از نظر شاخص‌های آماری عملکرد بهتری دارند، بلکه از نظر بصری نیز نقشه‌هایی با انسجام فضایی بالاتر، نویز کم‌تر و قابلیت تفسیر بهتر تولید می‌کنند. بنابراین، این مدل‌ها برای استخراج الگوی کشت پاییزه در شبکه آبیاری قزوین گزینه‌های مناسب‌تری نسبت به Random Forest، XGBoost و SVM محسوب می‌شوند.

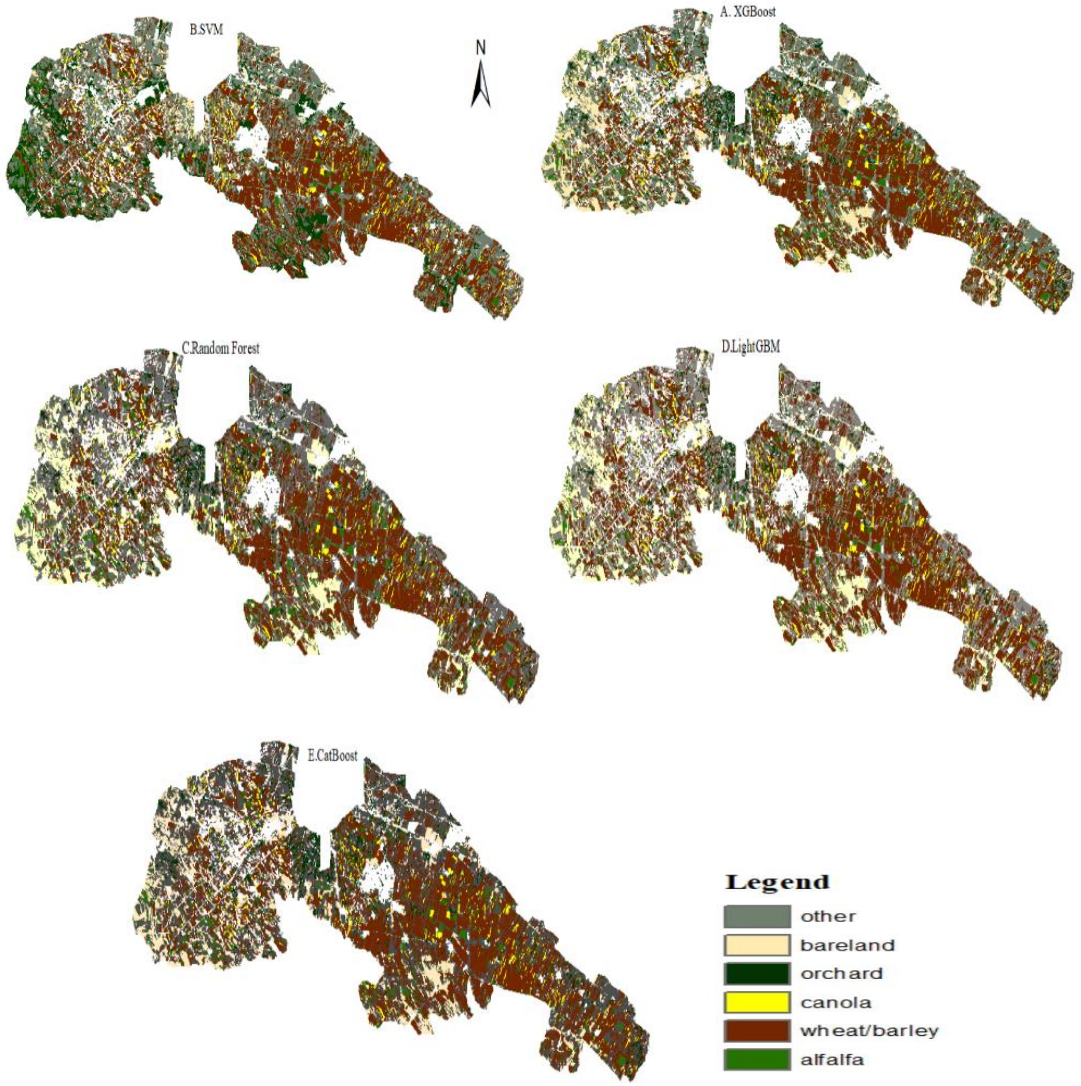


Figure 3. Autumn crop pattern maps generated by different machine learning algorithms in the Qazvin irrigation network

۳. ۴. تحلیل فضایی و بصری نقشه‌های الگوی کشت تابستانه

بررسی بصری نقشه‌های تولیدشده توسط پنج الگوریتم یادگیری ماشین (شکل ۴) نشان‌دهنده توانمندی متفاوت این مدل‌ها در بازنمایی واقع‌گرایانه الگوی کشت در شبکه آبیاری قزوین است. تمامی مدل‌ها موفق به شناسایی ساختار کلی توزیع کلاس‌های ذرت، گوجه‌فرنگی، یونجه، باغ، اراضی بایر و سایر شدند، با این‌حال، تفاوت‌های معناداری در میزان پیوستگی قطعات[۱۲] و نویزهای پیکسلی[۱۳] میان خروجی‌ها مشاهده گردید.

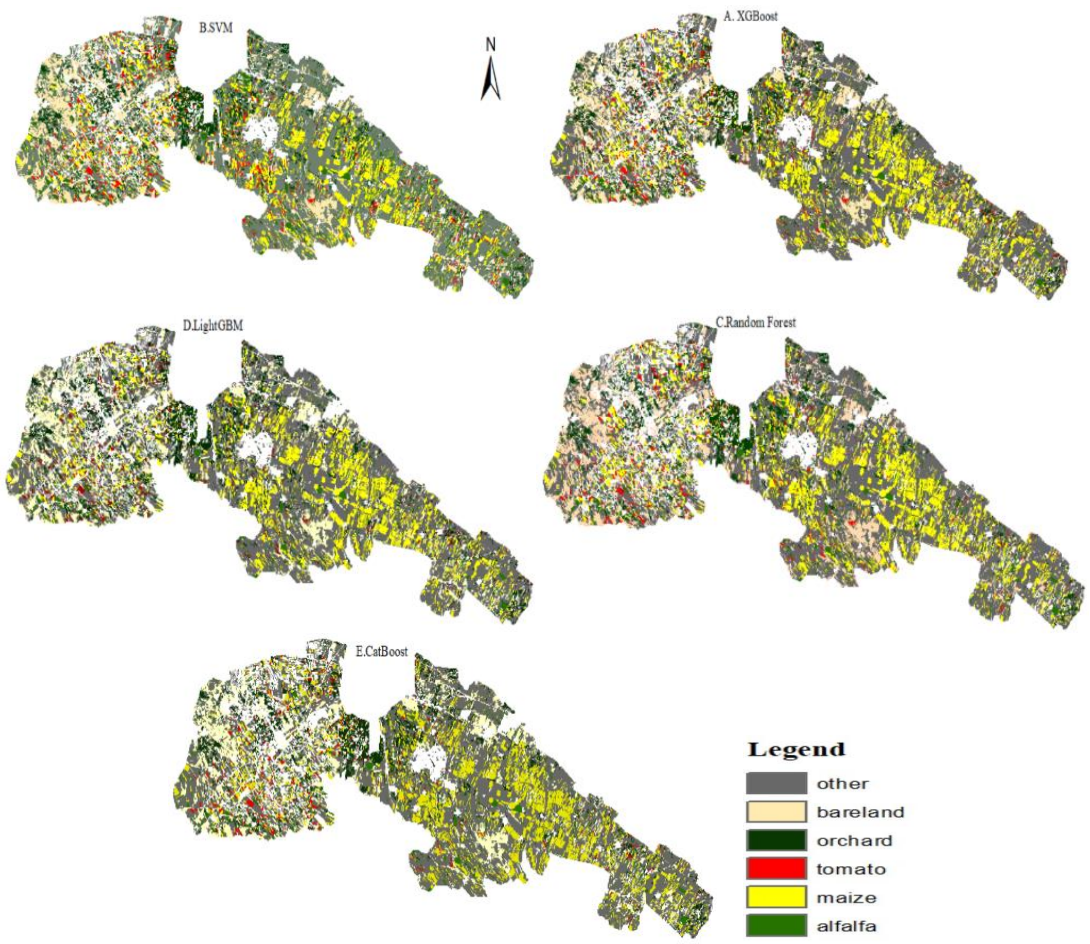


Figure 4. Summer crop pattern maps generated by different machine learning algorithms in the Qazvin irrigation network

در تمامی نقشه‌ها، محصولات ذرت و کلاس سایر به‌عنوان کاربری‌های غالب فضایی ظاهر شدند. کلاس ذرت (رنگ زرد) به‌ویژه در بخش‌های مرکزی و شرقی شبکه، پهنه‌های نسبتاً پیوسته و وسیعی را به خود اختصاص داده است. در مقابل، محصولات گوجه‌فرنگی (رنگ قرمز) و یونجه (رنگ سبز تیره) در تمامی مدل‌ها دارای پراکندگی پیکسلی بالا و لکه‌های کوچک و منفصل هستند. این ناپیوستگی مکانی می‌تواند ناشی از کوچک‌بودن قطعات اراضی زیرکشت این محصولات و هم‌چنین تشابه رفتار طیفی آن‌ها در اواسط فصل رشد باشد که منجر به افزایش خطاهای طبقه‌بندی در سطح پیکسل شده است.

مقایسه تطبیقی نقشه‌ها نشان می‌دهد که مدل Random Forest (RF) نسبت به سایر مدل‌ها، بیش‌ترین میزان تفرق فضایی و نویزهای پراکنده را تولید کرده است که این امر باعث کاهش وضوح مرز بین قطعات زراعی شده است. مدل SVM نیز اگرچه در تفکیک کلاس‌های غیرکشاورزی عملکرد مناسبی داشت، اما در شناسایی دقیق و پیوسته محصولات زراعی با چالش روبه‌رو بوده و قطعات را به‌صورت خردشده نمایش داده است.

در میان مدل‌های مبتنی بر تقویت گرادیان (Gradient Boosting)، مدل CatBoost و پس از آن LightGBM بهترین عملکرد بصری را ارائه دادند. نقشه حاصل از CatBoost با نتایج عددی (دقت کلی ۸۷ درصد) انطباق بالایی دارد، به‌طوری‌که در این مدل، کلاس ذرت با انسجام فضایی بالاتری استخراج شده و میزان پیکسل‌های منفرد در کلاس‌های

گوجه‌فرنگی و یونجه به حداقل رسیده است. این انسجام بصری نشان‌دهنده توانایی برتر الگوریتم CatBoost در مدیریت داده‌های ناهمگن سنجش از دوری و کاهش خطاهای طبقه‌بندی در محیط‌های پیچیده زراعی است.

از منظر توزیع مکانی، الگوی کلی نشان‌دهنده تمرکز فعالیت‌های زراعی متراکم در نیمه شرقی و مرکزی منطقه است، درحالی‌که بخش غربی به‌طورعمده با غلبه اراضی بایر و پهنه‌های پراکنده باغ مشخص شده است. این تحلیل بصری تأیید می‌کند که استفاده از مدل‌های پیشرفته یادگیری ماشین، به‌ویژه مدل‌های تقویت‌شده[۱۴]، نه‌تنها از نظر آماری دقت بالاتری فراهم می‌کنند، بلکه از نظر مکانی نیز نقشه‌هایی با قابلیت اطمینان بیش‌تر برای مدیریت منابع آب و خاک در شبکه‌های آبیاری تولید می‌نمایند.

۳. ۵. تحلیل مقایسه‌ای عملکرد الگوریتم‌ها در فصل‌های تابستان و پاییز

مقایسه نتایج طبقه‌بندی در دو فصل تابستان و پاییز نشان داد که عملکرد الگوریتم‌های یادگیری ماشین تحت تأثیر نوع محصولات، شرایط فنولوژیک، ساختار قطعات زراعی و میزان تشابه طیفی کلاس‌ها قرار دارد. تفاوت عملکرد مدل‌ها در دو فصل را می‌توان ناشی از تفاوت در ویژگی‌های فنولوژیک محصولات دانست. در فصل تابستان، محصولات زراعی مانند ذرت، گوجه‌فرنگی و یونجه در مراحل مختلف رشد قرار دارند و همین موضوع موجب تنوع طیفی بیش‌تر در سطح منطقه می‌شود. این شرایط باعث می‌شود الگوریتمی مانند CatBoost که توانایی بالایی در مدیریت داده‌های ناهمگون دارد، عملکرد بهتری ارائه کند. در مقابل، در فصل پاییز، کشت‌هایی مانند گندم/جو و کلزا الگوهای رشد منظم‌تری دارند و الگوریتم LightGBM با ساختار یادگیری سریع و کارآمد خود توانسته است این الگوهای طیفی و مکانی را با دقت بیش‌تری تفکیک کند.

در مجموع، نتایج این پژوهش نشان می‌دهد که انتخاب مدل بهینه برای استخراج الگوی کشت، وابسته به فصل، نوع محصولات و شرایط طیفی منطقه است. با این‌حال، عملکرد کلی مدل‌های Boosting در هر دو فصل برتری محسوسی نسبت به سایر الگوریتم‌ها داشته است. این موضوع نشان می‌دهد که استفاده از الگوریتم‌های پیشرفته یادگیری ماشین می‌تواند دقت پایش محصولات کشاورزی را افزایش داده و اطلاعات قابل اعتمادتری برای مدیریت منابع آب، برنامه‌ریزی کشت و تصمیم‌گیری‌های مدیریتی در شبکه‌های آبیاری فراهم کند.

۳. ۶. برآورد سطح زیرکشت محصولات در فصل‌های تابستان و پاییز

برآورد سطح زیرکشت محصولات، یکی از خروجی‌های کلیدی این پژوهش به‌شمار می‌رود و امکان ارزیابی کمّی الگوی استقرار محصولات در منطقه مطالعه را فراهم می‌کند. نتایج حاصل از نقشه‌های طبقه‌بندی‌شده نشان داد که مدل‌های مختلف، در برآورد سطح زیرکشت محصولات هدف شامل ذرت، گوجه‌فرنگی، کلزا، گندم، جو و یونجه عملکرد متفاوتی داشته‌اند. این اختلاف‌ها بیانگر حساسیت مدل‌ها به ویژگی‌های طیفی و مکانی کلاس‌های زراعی و نیز تأثیر ساختار فضایی قطعات کشاورزی در منطقه است.

در فصل پاییز، کلاس ترکیبی گندم/جو به‌عنوان غالب‌ترین کلاس زراعی شناسایی شد و در تمام مدل‌ها بیش‌ترین سطح زیرکشت را به خود اختصاص داد. این الگو با ماهیت کشت‌های پاییزه منطقه سازگار است. در مقابل، کلزا و یونجه سهم کم‌تری از سطح زیرکشت پاییزه داشتند. دامنه تغییرات برآوردی برای کلزا نسبتاً محدودتر بود، درحالی‌که یونجه در برخی مدل‌ها نوسان بیش‌تری نشان داد که می‌تواند به پراکندگی قطعات و همپوشانی طیفی آن با سایر پوشش‌های گیاهی مربوط باشد. مساحت‌های برآوردشده توسط هر یک از مدل‌ها برای کلاس‌های گندم و جو، کلزا و یونجه در طبقه‌بندی پاییزه در جدول (۷) آورده شده است.

Table 7. Comparison of official crop plan areas and estimated crop areas for major autumn crops

Model	Wheat + Barley (ha)	Canola (ha)	Alfalfa (ha)
CatBoost	27205	2254	3369
LightGBM	28048	2098	3548
Random Forest	26087	2001	4562
SVM	29328	2294	2648
XGBoost	27787	2166	4070

در فصل تابستان، نتایج نشان داد که ذرت بیش‌ترین سهم را در میان محصولات زراعی هدف داشته است. برآورد مدل‌ها برای این محصول در مقایسه با گوجه‌فرنگی و یونجه، مقادیر بالاتری را نشان داد که بیانگر غالب‌بودن این محصول در الگوی کشت تابستانه منطقه است. در مقابل، گوجه‌فرنگی و یونجه سطح محدودتری را به خود اختصاص داده‌اند، هرچند میزان برآورد آن‌ها در میان مدل‌ها دارای نوسان بود. این نوسان می‌تواند ناشی از پراکندگی مکانی قطعات، تفاوت مراحل رشد گیاه و شباهت طیفی برخی کلاس‌های زراعی باشد. مساحت‌های برآورد شده توسط هر یک از مدل‌ها برای کلاس‌های گوجه فرنگی، یونجه و ذرت در طبقه‌بندی تابستانه در جدول (۸) آورده شده است.

Table 8. Comparison of official crop plan areas and estimated crop areas for major summer crops

Model	Tomato (ha)	Alfalfa (ha)	Maize (ha)
CatBoost	1693	2408	12800
LightGBM	1911	2719	12349
Random Forest	1906	2543	13001
SVM	3335	4935	10451
XGBoost	2179	3159	13057

نتایج مساحت‌های برآوردی قطعا با مقادیر مندرج در طرح الگوی کشت متفاوت است که بخشی از این تفاوت را می‌توان ناشی از تفاوت ماهوی میان طرح الگوی کشت و وضعیت واقعی کشت دانست. طرح الگوی کشت، یک چارچوب برنامه‌ریزی‌شده براساس سیاست‌های مدیریتی، منابع آب و ظرفیت شبکه آبیاری است، درحالی‌که الگوی واقعی کشت تحت تأثیر تصمیم کشاورزان، شرایط بازار، دسترسی به آب، تغییرات اقلیمی و محدودیت‌های اجرایی قرار می‌گیرد. بنابراین، عدم تطابق کامل میان مقادیر رسمی و برآوردهای سنجش‌ازدور الزاماً نشان‌دهنده خطای مدل نیست، بلکه می‌تواند بازتابی از انحراف واقعی کشت انجام‌شده از برنامه مصوب باشد.

از سوی دیگر، بخشی از اختلاف‌ها می‌تواند به محدودیت‌های فنی فرایند طبقه‌بندی مربوط باشد. تشابه طیفی محصولات، خردبودن قطعات زراعی، آمیختگی پیکسل‌ها در مرز مزارع، تفاوت تاریخ تصویربرداری با تقویم کشت و تغییرات فنولوژیک گیاهان، از عوامل مؤثر بر دقت برآورد سطح زیرکشت هستند. این عوامل به‌ویژه در تفکیک محصولاتی مانند گندم و جو یا در شناسایی دقیق سطوح پراکنده یونجه می‌توانند نقش قابل‌توجهی داشته باشند.

در میان محصولات بررسی‌شده، یونجه بیش‌ترین نوسان را میان برآوردهای تابستانه و پاییزه نشان داد. این موضوع را می‌توان با توجه به ماهیت چندچین و چندساله این محصول تبیین کرد. یونجه معمولاً به‌صورت چندساله کشت می‌شود و طی چند سال متوالی موردبهره‌برداری قرار می‌گیرد، با این‌حال، در سال پایانی چرخه تولید، تراکم پوشش گیاهی و شاخص‌های سبزینگی آن ممکن است کاهش یابد. در مقابل، مزارع تازه‌کاشت یونجه در سال اول استقرار، الگوی رشد و بازتاب طیفی متفاوتی نسبت به مزارع بالغ دارند.

بنابراین، این احتمال وجود دارد که بخشی از اراضی شناسایی‌شده به‌عنوان یونجه در یک فصل، مربوط به مزارع در سال پایانی بهره‌برداری بوده باشند، درحالی‌که در فصل بعدی بخشی از این اراضی تغییر کاربری داده یا دوباره کشت شده باشند. هم‌چنین، مزارع تازه‌کاشت ممکن است در مراحل اولیه رشد شباهت طیفی بیش‌تری با سایر پوشش‌های علفی داشته باشند و در نتیجه با عدم قطعیت بیش‌تری در فرایند طبقه‌بندی همراه شوند. از این‌رو، اختلاف مشاهده‌شده در

برآورد مساحت یونجه بین دو فصل، علاوه بر محدودیت‌های ذاتی طبقه‌بندی مبتنی بر سنجش‌ازدور، می‌تواند بازتابی از پویایی زمانی، چرخه بهره‌برداری چندساله و تغییرات مدیریتی این محصول در سطح مزرعه باشد.

در مجموع، نتایج این بخش نشان می‌دهد که داده‌های سنجش‌ازدور تلفیق‌شده با الگوریتم‌های یادگیری ماشین، قابلیت مناسبی برای پایش الگوی کشت و برآورد سطح زیرکشت محصولات غالب دارند. با این‌حال، تفسیر کمی نتایج باید با درنظرگرفتن تفاوت میان داده‌های برنامه‌ای و وضعیت واقعی مزرعه، ساختار طبقه‌بندی محصولات و محدودیت‌های طیفی و مکانی تصاویر انجام شود. این رویکرد می‌تواند به‌عنوان ابزاری مکمل برای ارزیابی میزان تحقق طرح الگوی کشت و پشتیبانی از مدیریت منابع آب و برنامه‌ریزی کشاورزی در شبکه آبیاری قزوین مورداستفاده قرار گیرد.

۳. ۷. محدودیت‌های پژوهش

باوجود یافته‌های قابل‌توجه این پژوهش در شناسایی الگوی کشت شبکه آبیاری قزوین، اذعان به برخی محدودیت‌ها که می‌توانند راه‌گشای پژوهش‌های آتی باشند، ضروری است.

۱. محدودیت تفکیک‌پذیری مکانی (Spatial Resolution): این پژوهش بر پایه تصاویر ماهواره‌ای سنتینل با تفکیک‌پذیری مکانی ۱۰ متر استوار بود. درحالی‌که این دقت برای بسیاری از مزارع مناسب است، در مناطق با قطعات کشاورزی بسیار کوچک و خرد، پدیده پیکسل‌های مختلط (Mixed Pixels) در مرز مزارع می‌تواند منجر به کاهش دقت طبقه‌بندی شود. پژوهش‌های آتی می‌توانند با استفاده از تصاویر با تفکیک‌پذیری بالاتر مانند PlanetScope یا به‌کارگیری تکنیک‌های پیشرفته ترکیب تصاویر (Image Fusion) این محدودیت را برطرف نمایند.

۲. شباهت طیفی برخی محصولات: برخی از محصولات زراعی، به‌ویژه گندم و جو، به‌دلیل ساختار گیاهی و چرخه فنولوژیکی بسیار مشابه، دارای بازتاب طیفی نزدیکی در تصاویر ماهواره‌ای هستند. این امر تفکیک دقیق این دو محصول از یکدیگر را حتی با استفاده از سری زمانی تصاویر دشوار می‌سازد. در این پژوهش، این دو محصول در یک کلاس واحد ادغام شدند که می‌تواند برآورد سطح زیر کشت هر یک به‌تنهایی را با چالش مواجه کند. استفاده از داده‌های ابرطیفی (Hyperspectral) یا تصاویر راداری با پلاریزاسیون‌های مختلف در آینده می‌تواند به تفکیک بهتر این محصولات کمک کند.

۳. تک‌ساله‌بودن دوره مطالعه: مدل‌های توسعه‌یافته در این پژوهش براساس داده‌های یک سال زراعی (مثلاً ۱۴۰۲–۱۴۰۳) آموزش دیده‌اند. با توجه به اینکه الگوی کشت در یک منطقه ممکن است تحت تأثیر عواملی مانند سیاست‌های تخصیص آب، قیمت محصولات و تناوب زراعی در سال‌های مختلف تغییر کند، قابلیت تعمیم‌پذیری مدل به سال‌های دیگر باید با احتیاط صورت گیرد. برای ساخت مدل‌های پایدارتر، انجام مطالعات چندساله توصیه می‌شود.

۴. محدودیت داده‌های زمینی: اگرچه تلاش شد تا داده‌های زمینی با پراکندگی مناسب در سطح منطقه جمع‌آوری شود، اما محدودیت‌های دسترسی به برخی مزارع و هزینه‌های نمونه‌برداری میدانی، می‌تواند بر توزیع و تعداد نمونه‌های آموزشی تأثیر گذاشته باشد. افزایش تعداد و تنوع نمونه‌های زمینی در مطالعات آینده، به افزایش اعتبار و دقت مدل‌ها کمک شایانی خواهد کرد.

۴. نتیجه‌گیری و جمع‌بندی

پژوهش حاضر با هدف استخراج دقیق الگوی کشت در شبکه آبیاری قزوین از طریق تلفیق داده‌های سری زمانی Sentinel-1 و Sentinel-2 و الگوریتم‌های یادگیری ماشین انجام شد. از منظر یافته‌های کمّی، ارزیابی مدل‌ها نشان داد که خانواده الگوریتم‌های مبتنی بر تقویت گرادیان (Gradient Boosting) برتری محسوسی نسبت به سایر روش‌ها دارند. به‌طور خاص،

الگوریتم LightGBM در فصل پاییز (با دقت کلی ۸۸ درصد و ضریب کاپای ۰/۸۵) و الگوریتم CatBoost در فصل تابستان (با دقت کلی ۸۷ درصد و ضریب کاپای ۰/۸۳) بالاترین عملکرد را در تفکیک کلاس‌های زراعی پیچیده نشان دادند. هم‌چنین، برآوردهای مساحتی نشان داد که گندم/جو در پاییز و ذرت در تابستان محصولات غالب منطقه هستند.

از منظر کاربردی، نتایج این پژوهش نشان می‌دهد که چارچوب پیشنهادی ابزاری عملیاتی، سریع و مقرون‌به‌صرفه است که می‌تواند جایگزین پایش‌های پرهزینه و زمان‌برِ میدانی شود. ازآنجاکه اختلاف میان الگوهای کشت مصوب و واقعیت میدانی یکی از چالش‌های اساسی در مدیریت دشت قزوین است، نقشه‌های تولیدشده با این روش امکان پایش مستمر و ارزیابی میزان تحقق برنامه‌های الگوی کشت را فراهم می‌آورند. آگاهی از توزیع مکانی دقیق محصولات و سطح زیرکشت آن‌ها به مدیران و تصمیم‌گیران حوزه منابع آب اجازه می‌دهد تا برآورد واقع‌بینانه‌تری از نیاز آبی شبکه داشته باشند، تخصیص آب را در شرایط نیمه‌خشک منطقه بهینه‌سازی کنند و کنترل مؤثرتری بر توسعه کشت‌های پرمصرف اعمال نمایند.

۵. پی‌نوشت‌ها

1. Normalized Difference Vegetation Index (NDVI)
2. Normalized Difference Water Index (NDWI)
3. Enhanced Vegetation Index (EVI)
4. Normalized Difference Built-up Index (NDBI)
5. Soil Adjusted Vegetation Index (SAVI)
6. Green Normalized Difference Vegetation Index (GNDVI)
7. Normalized Difference Yellow Index (NDYI)
8. Interferometric Wide Swath
9. Segmentation
10. Backscatter
11. Ordered Boosting
12. Spatial Continuity
13. Salt-and-pepper noise
14. Boosted Models

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

Asadi, B., & Shamsoddini, A. (2024). Crop classification using a combination of Sentinel-1 and Sentinel-2 images in Ardabil Province. *Iranian Journal of Remote Sensing & GIS*, *16*(3), 25–46. https://doi.org/10.48308/gisj.2023.103095 (In Persian)

Be, M. C., Randrianantenaina, A. S., Kanneh, J. E., Han, Y., Lei, Y., Zhi, X., Xiong, S., Jiao, Y., Shang, S., Ma, Y., Yang, B., Tao, L., & Li, Y. (2025). Comparative analysis of machine learning algorithms for object-based crop classification using multispectral imagery. *Drones*, *9*(11), 763. https://doi.org/10.3390/drones9110763

Belgiu, M., & Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, *204*, 509–523. https://doi.org/10.1016/j.rse.2017.10.005

Belgiu, M., & Drăguţ, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, *114*, 24–31. https://doi.org/10.1016/j.isprsjprs.2016.01.011

Breiman, L. (2001). Random forests. *Machine Learning*, *45*(1), 5–32. https://doi.org/10.1023/A:1010933404324

Chabalala, Y., Adam, E., & Ali, K. A. (2022). Machine learning classification of fused Sentinel-1 and Sentinel-2 image data towards mapping fruit plantations in highly heterogenous landscapes. *Remote Sensing*, *14*(11), 2621. https://doi.org/10.3390/rs14112621

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). https://doi.org/10.1145/2939672.2939785

Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, *20*(1), 37–46. https://doi.org/10.1177/001316446002000104

Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, *37*(1), 35–46. https://doi.org/10.1016/0034-4257(91)90048-B

Congalton, R. G., & Green, K. (2019). *Assessing the accuracy of remotely sensed data: Principles and practices* (3rd ed.). CRC Press. https://doi.org/10.1201/9780429052729

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, *20*(3), 273–297. https://doi.org/10.1007/BF00994018

Dice, L. R. (1945). Measures of the amount of ecologic association between species. *Ecology*, *26*(3), 297–302. https://doi.org/10.2307/1932409

Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., …, & Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, *120*, 25–36. https://doi.org/10.1016/j.rse.2011.11.026

European Space Agency (ESA). (2024). *Sentinel-1 and Sentinel-2 user guides*. https://sentinels.copernicus.eu

Fan, L., Xia, L., Yang, J., Sun, X., Wu, S., Qiu, B., Chen, J., Wu, W., & Yang, P. (2024). A temporal-spatial deep learning network for winter wheat mapping using time-series Sentinel-2 imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, *214*, 48–64. https://doi.org/10.1016/j.isprsjprs.2024.06.005

Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, *80*(1), 185–201. https://doi.org/10.1016/S0034-4257(01)00295-4

Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, *58*(3), 289–298. https://doi.org/10.1016/S0034-4257(96)00072-7

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, *202*, 18–27. https://doi.org/10.1016/j.rse.2017.06.031

Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, *25*(3), 295–309. https://doi.org/10.1016/0034-4257(88)90106-X

Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, *83*(1–2), 195–213. https://doi.org/10.1016/S0034-4257(02)00096-2

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. In *Advances in Neural Information Processing Systems* (Vol. 30, pp. 3146–3154).

Khosravi, I. (2024). Agricultural crop type mapping from Landsat-8 time-series images using machine learning methods (Case study: Marvdasht, Fars Province). *Geography and Environmental Planning*, *35*(2), 45–66. https://doi.org/10.22108/gep.2024.138615.1601 (In Persian)

Madani, K., AghaKouchak, A., & Mirchi, A. (2018). Iran's water crisis: A case of mismanagement and unsustainable use. *Journal of Environmental Studies*, *44*(1), 1–10.

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. https://doi.org/10.1080/01431161.2018.1433343

McFeeters, S. K. (1996). The use of the normalized difference water index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, *17*(7), 1425–1432. https://doi.org/10.1080/01431169608948714

Ministry of Energy. (2019). *Report on the Qazvin Plain irrigation and drainage network project*. Ministry of Energy, Iran. (In Persian)

Pelletier, C., Webb, G. I., & Petitjean, F. (2019). Temporal convolutional neural network for the classification of satellite image time series. *Remote Sensing*, *11*(5), 523. https://doi.org/10.3390/rs11050523

Polous, A., & Taati, A. (2022). *Investigation of land use changes in a part of the Qazvin Plain using remote sensing technique* [Paper presentation]. 4th National Congress on Development and Promotion of Agricultural Engineering and Soil Sciences of Iran, Tehran, Iran. https://civilica.com/doc/1661812 (In Persian)

Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, *2*(1), 37–63.

Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A., & Gulin, A. (2018). CatBoost: Unbiased boosting with categorical features. In *Advances in Neural Information Processing Systems* (Vol. 31, pp. 6638–6648).

Raab, C., Nguyen, V. D., Barrett, B., Zakirova, A., Zuberi, M., Alff, H., & Spies, M. (2026). Crop type classification in smallholder agriculture of central and South Asia using Sentinel-1/2 data fusion. *Remote Sensing Applications: Society and Environment*, *42*, 102007. https://doi.org/10.1016/j.rsase.2026.102007

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring vegetation systems in the Great Plains with ERTS. In *Third Earth Resources Technology Satellite-1 Symposium* (NASA SP-351, pp. 309–317).

Soltani, M., Bahmanabadi, B., & Mokhtaran, A. (2025). Agricultural crop classification and acreage estimation at basin scale using a machine learning approach. *Iranian Journal of Soil and Water Research*, *56*(11), 3129–3156. https://doi.org/10.22059/ijswr.2025.402830.670012 (In Persian)

Soomro, A., Rahu, M. A., Ali, S. M., & Karim, S. (2026). A comparative review of boosting algorithms for agricultural applications: Performance analysis, algorithm selection framework, and future directions. *International Journal of Agriculture Innovations and Cutting-Edge Research*, *4*(2), 96–110. https://jai.bwo-researches.com/index.php/jwr/article/view/242

Stehman, S. V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*, *62*(1), 77–89. https://doi.org/10.1016/S0034-4257(97)00083-7

Sulik, J. J., & Long, D. S. (2016). Spectral considerations for modeling yield of canola. *Remote Sensing of Environment*, *184*, 161–174. https://doi.org/10.1016/j.rse.2016.06.016

Taheri Dehkordi, A., & Valadan Zoej, M. J. (2021). Agricultural land use classification using Sentinel satellite imagery and deep 3D convolutional neural network (Case study: Shahrekord). *Iranian Journal of Soil and Water Research*, *52*(7), 1941–1953. https://doi.org/10.22059/ijswr.2021.320850.668956 (In Persian)

Tamiminia, H., Salehi, B., Mahdianpari, M., Quackenbush, L., Adeli, S., & Brisco, B. (2020). Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, *164*, 152–170. https://doi.org/10.1016/j.isprsjprs.2020.04.001

Van Tricht, K., Gobin, A., Gilliams, S., & Piccard, I. (2018). Synergistic use of radar Sentinel-1 and optical Sentinel-2 imagery for crop mapping: A case study for Belgium. *Remote Sensing*, *10*(10), 1642. https://doi.org/10.3390/rs10101642

Veloso, A., Mermoz, S., Bouvet, A., Le Toan, T., Planells, M., Dejoux, J., & Ceschia, E. (2017). Understanding the temporal behavior of crops using Sentinel-1 and Sentinel-2 data. *Remote Sensing of Environment*, *199*, 415–426. https://doi.org/10.1016/j.rse.2017.07.015

Waldner, F., & Diakogiannis, F. (2020). Deep learning on edge: Extracting field boundaries from satellite images with a convolutional neural network. *Remote Sensing of Environment*, *245*, 111741. https://doi.org/10.1016/j.rse.2020.111741

Yi, Z., Jia, L., & Chen, Q. (2020). Crop classification using multi-temporal Sentinel-2 data in the Shiyang River Basin of China. *Remote Sensing*, *12*(24), 4052. https://doi.org/10.3390/rs12244052

Yu, L., Tao, H., Li, Q., Xie, H., Xu, Y., Mahemujiang, A., & Jiang, Y. (2025). Research on machine learning-based extraction and classification of crop planting information in arid irrigated areas using Sentinel-1 and Sentinel-2 time-series data. *Agriculture*, *15*(11), 1196. https://doi.org/10.3390/agriculture15111196

Zare Abyaneh, H., Heydari, A., & Daneshkar Arasteh, P. (2019). Performance evaluation of water management in the Qazvin Plain irrigation network. *Journal of Irrigation and Water Engineering*, *10*(2), 76–88. https://doi.org/10.22125/iwe.2019.100726 (In Persian)

Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing*, *24*(3), 583–594. https://doi.org/10.1080/01431160304987

Zhong, L., Hu, L., & Zhou, H. (2019). Deep learning-based multi-temporal crop classification. *Remote Sensing of Environment*, *221*, 430–443. https://doi.org/10.1016/j.rse.2018.11.032