

Investigating the Changes in the Major Cultivated Area of Qazvin Plain Using Multi-Temporal Satellite Images

Masoud Soltani¹, Bahareh Bahmanabadi^{2*}, Abbas Kaviani³

1. Department of Water Science and Engineering, Agriculture and Natural Resources Faculty, Imam Khomeini International University, Qazvin, Iran

2. Department of Water Science and Engineering, Agriculture and Natural Resources Faculty, Imam Khomeini International University, Qazvin, Iran

3. Department of Water Science and Engineering, Faculty of Agriculture and Natural Resources, Imam Khomeini International University, Qazvin, Iran.

*Corresponding Author: b.bahmanabadi@gmail.com

Extended abstract

Introduction

Agricultural production is critical to global food security, resource management, and sustainable development. Accurately estimating the cultivated area of crops is essential for optimizing agricultural policies, resource allocation, and climate adaptation strategies. Traditionally, field surveys have been the primary method of estimating cultivated areas, but these approaches are time-intensive, costly, and lack scalability. The advent of remote sensing technology, coupled with machine learning algorithms, offers an efficient alternative for large-scale agricultural monitoring. This study used Sentinel-1 radar and Sentinel-2 optical satellite imagery to assess the potential of combining multi-temporal datasets to classify land cover and changes in cultivation patterns. The study focused on the Qazvin Plain in Iran, an agricultural region highly influenced by climatic variability and resource constraints. By employing the Random Forest (RF) algorithm, we aimed to evaluate its performance in improving classification accuracy for various land-use classes and understanding trends in cultivation over a decade. This investigation addresses the critical gaps in precision agriculture, where integrating multi-source data remains a challenge.

Materials and Methods

The study was conducted in the Qazvin irrigation network, covering approximately 60,000 hectares of farmland. Data acquisition was performed using Sentinel-2 (optical) and Sentinel-1 (radar) satellite imagery spanning ten years (2013–2023). Sentinel-2 imagery provided spectral indices such as NDVI, SAVI, and LAI, while Sentinel-1 data added complementary structural information due to its sensitivity to vegetation morphology. These datasets were pre-processed in Google Earth Engine, including steps such as spatial cropping, temporal filtering, and noise reduction for radar data using a median focal filter. Ground truth data were collected through field surveys, including georeferenced samples for six land-use classes: wheat-barley, alfalfa, maize, bare land, fallow, and urban areas. These data were split into training (70%) and testing (30%) subsets to ensure robust model validation. The RF algorithm, known for its resilience against overfitting and ability to handle high-dimensional data, was applied using 100 trees to classify the datasets. Performance metrics, including overall accuracy, kappa coefficient, and class-specific precision, were derived from confusion matrices. Additionally, the Jeffries-Matusita (JM) separability index was employed to evaluate spectral distinguishability among land-use classes.

Results and Discussion

The RF algorithm demonstrated excellent performance in classifying land-use categories, achieving an overall accuracy of 99.69% for autumn cultivation and 98.93% for spring cultivation. The kappa coefficients, 0.996 and 0.980 for autumn and spring, indicated near-perfect agreement between classified and ground-truth data. Combining Sentinel-1 and Sentinel-2 datasets significantly enhanced classification accuracy, particularly for classes with spectral overlaps, such as alfalfa and fallow land. The JM separability test highlighted that combining optical and radar data

substantially improved the distinguishability of classes, with separability scores for most classes exceeding the threshold of 1.8. Classes such as bare land and maize demonstrated complete separability, whereas alfalfa showed moderate overlap with other categories, emphasizing the importance of radar data in resolving ambiguities. Temporal analysis revealed significant changes in cropping patterns over the decade. Spring cultivation exhibited an increasing trend in maize cultivation due to its resilience to climatic stress and economic viability. Conversely, alfalfa cultivation declined, likely linked to its higher water demand amid diminishing water resources. For autumn cultivation, wheat and barley showed a consistent increase, reflecting their relative tolerance to climate variability and government support for staple crops. The impact of socio-economic factors, such as the COVID-19 pandemic, was also evident in increased fallow land during 2020, attributed to labor shortages and reduced agricultural activity.

Conclusion

This research underscores the utility of combining Sentinel-1 and Sentinel-2 datasets with machine-learning techniques like RF for precision agriculture. The approach enhanced the accuracy of cultivated area estimation and provided actionable insights into land use dynamics in the Qazvin Plain. These findings align with prior studies emphasizing the value of multi-source data integration and machine learning in improving agricultural monitoring. The study recommends exploring additional machine-learning algorithms and integrating complementary data sources, such as high-resolution drone imagery, to enhance classification accuracy further. It also highlights the necessity of adaptive cropping patterns and efficient resource management to mitigate the impacts of climate change. The proposed methodology is a scalable solution for agricultural monitoring, offering the potential for application in similar agroecological contexts worldwide. This work addresses current challenges in land-use monitoring and provides a roadmap for future research in precision agriculture, balancing technological advancements with environmental and socio-economic considerations.

Keywords: Random Forest, Jeffries-Matusita, Kappa coefficient, Machine learning.

بررسی تغییرات سطح زیر کشت غالب دشت قزوین با به‌کارگیری تصاویر چند زمانه ماهواره‌ای

مسعود سلطانی^{۱*}، بهاره بهمن آبادی^۲، عباس کاویانی^۳

- ۱- استادیار گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.
 - ۲- دانش‌آموخته دکتری آبیاری زهکشی، گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.
 - ۳- دانشیار گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران.
- *نویسنده مسئول: b.bahmanabadi@gmail.com

چکیده

برآورد دقیق سطح زیرکشت محصولات کشاورزی برای برنامه‌ریزی و مدیریت منابع آب ضروری است. استفاده از داده‌های سنجش از دور و الگوریتم‌های یادگیری ماشین می‌تواند به بهبود صحت این برآوردها کمک کند. این پژوهش به ارزیابی کارایی الگوریتم جنگل تصادفی در برآورد سطح زیرکشت غالب با استفاده از تلفیق داده‌های ماهواره‌ای سنتینل-۱ و سنتینل-۲ با وضوح ۱۰ متری در سطح شبکه آبیاری دشت قزوین می‌پردازد. ابتدا، آزمون تفکیک‌پذیری جفریس-ماتوسیتا برای ارزیابی قابلیت جداسازی طیفی شش کلاس کاربری (گندم-جو، ذرت، یونجه، آیش، اراضی بایر و مناطق شهری) در دوره‌های کشت پاییزه و بهاره انجام شد، که نتایج آن نشان‌دهنده تفکیک‌پذیری بالای برخی کلاس‌ها و هم‌پوشانی طیفی در برخی دیگر بود. سپس، با ترکیب داده‌های راداری و نوری و استفاده از الگوریتم جنگل تصادفی، صحت طبقه‌بندی به‌طور قابل‌توجهی افزایش یافت؛ به‌طوری‌که در کشت پاییزه، ضریب کاپا ۰/۹۹ و صحت کلی ۹۹/۶۹٪ و در کشت بهاره، ضریب کاپا ۰/۹۸ و صحت کلی ۹۸/۹۳٪ به‌دست آمد. تحلیل روند تغییرات سطح زیرکشت محصولات گندم-جو، ذرت و یونجه در ده سال گذشته نشان داد که در کشت بهاره، سطح زیرکشت ذرت افزایش و یونجه کاهش یافته است. در کشت پاییزه نیز افزایش سطح زیرکشت گندم و جو مشاهده شد که احتمالاً به مقاومت نسبی بالای آن‌ها در برابر نوسانات اقلیمی و حمایت‌های اقتصادی مربوط است. نتایج بررسی تغییرات سطح زیرکشت در سطح شبکه آبیاری نشان داد به‌طور کلی کشاورزان تمایل بیشتری به کشت ذرت علوفه‌ای در منطقه پیدا کردند و کشت بهاره نسبت به کشت پاییزه در حال افزایش است.

واژگان کلیدی: جنگل تصادفی، جفریس-ماتوسیتا، ضریب کاپا، یادگیری ماشین.

مقدمه

اطلاعات دقیق و به موقع از تغییرات سطح زیرکشت و تولیدات کشاورزی نه تنها برای تضمین امنیت غذایی جهانی حیاتی است، بلکه می تواند به عنوان گامی اساسی در مدیریت بهینه منابع و تدوین سیاست های مؤثر کشاورزی نقش کلیدی به شمار رود (Ahmad et al., 2017; Rahimzadegan and Pourgholam, 2020). به طور سنتی، این اطلاعات از طریق سرشماری ها و مطالعات میدانی جمع آوری می شوند. با وجود اینکه، جمع آوری داده های میدانی می تواند متغیرهای مختلفی مانند مالکیت زمین، اندازه مزارع، نیروی کار، سطح زیرکشت، آبیاری و استفاده از کود را در بر بگیرد، اما معمولاً هر ده سال یک بار انجام می شوند و بیشتر برای بررسی جنبه هایی از کشاورزی مناسب هستند که به تدریج تغییر می کنند (FAO, 2015). علاوه بر این، استفاده از داده های سرشماری در مقیاس جهانی با چالش هایی مانند تفاوت در تعریف متغیرها، تغییر واحدهای سیاسی یا نمونه گیری، و تفاوت در پروتکل های گزارش دهی میان کشورها و زمان بندی سرشماری ها همراه است (Portmann et al., 2010).

از سوی دیگر، واکاوی روند کشت با توجه به تغییرات اقلیمی از اهمیت بالایی برخوردار است؛ زیرا تغییرات اقلیمی تأثیرات گسترده ای بر امنیت غذایی، منابع طبیعی و الگوهای کشت دارد. مطالعات نشان می دهند که تغییرات اقلیمی می توانند منجر به کاهش تولید محصولات کشاورزی، افزایش آفات و بیماری ها، و تغییر در الگوهای بارش شوند که همه این عوامل بر امنیت غذایی تأثیر گذاشته و نیاز به بازنگری در الگوهای کشت را دوچندان می کند (Habib-ur-Rahman et al., 2022; Skendžić et al., 2021; Soleymani et al., 2019). به عنوان مثال، تغییر در الگوهای بارش و افزایش دما می تواند منابع آب را کاهش داده و تأمین آب برای کشاورزی را دشوارتر کند، همین امر منجر به کاهش تولید غلات و سایر محصولات کشاورزی شود که تهدیدی جدی برای تأمین غذای جمعیت رو به رشد است (Gitz et al., 2016; Meng et al., 2021; Shayanmehr et al., 2022). اکبری و همکاران (۱۳۹۸) تأثیر تغییرات اقلیمی و خشک سالی را بر الگوی کشت و ریسک درآمدی دشت قزوین بررسی کردند. در این تحقیق، به منظور افزایش تولیدات کشاورزی منطقه، استفاده از واریته های جدید محصولات کشاورزی به منظور بهبود عملکرد، توسعه سطح زیر کشت محصولات با نیاز آبی کمتر نظیر جو آبی در زمان خشک سالی، و محصولات باثبات درآمدی بالاتر مانند جو آبی، ذرت دانه ای، چغندر و گوجه در طی سال های آینده پیشنهاد شده است (Akbari et al., 2019). از طرفی الگوی کشت باید با توجه به تغییرات اقلیمی به گونه ای تنظیم شود که از محصولات مقاوم به شرایط جدید استفاده شود و منابع آب و خاک بهینه مصرف شوند (Baraj et al., 2024). این امر می تواند با انتخاب گیاهان مقاوم به خشکی، تغییر زمان بندی کاشت و برداشت، و استفاده از روش های کشاورزی هوشمند اقلیمی محقق شود (Acevedo et al., 2020). بنابراین، تجزیه و تحلیل روند کشت با توجه به تغییرات اقلیمی می تواند به بهبود امنیت غذایی، حفاظت از منابع طبیعی و بهینه سازی الگوهای کشت کمک کند. با توجه به اینکه پایش تغییرات سطح کشت و الگوی کشت بهینه در منطقه نقشی اساسی در سیاست گذاری ها و تصمیم گیری های کشاورزی دارد، لازم است سری زمانی تغییرات مورد ارزیابی قرار گیرد و سناریوهای بهینه مدیریتی اتخاذ گردد. برای تحقق این امر، نیاز به مجموعه داده های باکیفیت و به روز است.

با پیشرفت و توسعه فناوری های سنجش از دور مانند ماهواره ها، پهپادها و سایر تصاویر هوایی امکان ثبت مناطق وسیع بدون مداخله مستقیم را فراهم آوردند (Ashourloo et al., 2022). داده های ماهواره ای با پیوستگی زمانی و مکانی مناسب، اطلاعات به روز و پیوسته ای درباره رشد محصولات کشاورزی در مقیاس های منطقه ای تا جهانی ارائه می دهند. با این حال، شناسایی نوع محصول از طریق داده های ماهواره ای همچنان به دلیل تنوع سیستم های زراعی، شامل انواع محصولات، واریته ها، شیوه های مدیریتی و اندازه مزارع، یک چالش فنی به شمار می آید (Waldner et al., 2016).

از آنجاکه، اطلاعات مربوط به طبقه بندی محصولات زراعی و توزیع مکانی و زمانی آن ها زیربنای طیف گسترده ای از کاربردها را تشکیل می دهد که می تواند به صورت مؤثری در مدل های گیاهی و هیدرولوژیکی ادغام شود، این مدل ها باعث تسهیل ارزیابی تأثیر کشاورزی بر محیط زیست و متقابلاً محیط زیست بر کشاورزی می شود (Boryan et al., 2011; Gilmanov et al., 2013). چنین مجموعه داده هایی برای سازمان های دولتی، بخش خصوصی، محققان و سایر ذی نفعان اهمیت به سزایی دارد. چراکه امکان درک عمیق تر از پویایی

مکانی و زمانی زمین‌های زراعی را فراهم کرده و امکان اتخاذ تصمیمات آگاهانه در زمینه شیوه‌های کشاورزی و حفاظت از منابع را فراهم می‌کند (Song et al., 2017).

در این میان، الگوریتم‌های یادگیری ماشین^۱ به‌عنوان ابزاری قدرتمند برای تحلیل و تفسیر حجم وسیعی از داده‌های کشاورزی به میدان آمده‌اند. این الگوریتم‌ها، که قادر به تحلیل داده‌های حسگرهای اینترنت اشیا و سایر منابع هستند، با استفاده از مدل‌های آماری و ریاضی، پیش‌بینی‌هایی دقیق از رشد، عملکرد و کیفیت محصولات کشاورزی ارائه می‌دهند (Elbasi et al., 2023). یادگیری ماشین این قابلیت را دارد که داده‌های جمع‌آوری‌شده از مزرعه‌ها مانند شرایط آب‌وهوایی، ویژگی‌های خاک، مراحل رشد محصول و شیوع آفات را تحلیل کرده و به‌کمک مدیریت بهینه زراعی بشتابد (Shahrin et al., 2020). ترکیب فناوری‌های سنجش از دور با الگوریتم‌های یادگیری ماشین، امکان تفسیر دقیق‌تر داده‌ها و ارائه راهکارهایی برای بهبود عملکرد کشاورزی در سطوح مختلف را فراهم می‌کند و افق‌های جدیدی برای پیش‌بینی و مدیریت محصولات باز می‌نماید (Ayoub Shaikh et al., 2022).

الگوریتم‌های یادگیری ماشین با سرعت بخشیدن و افزایش دقت محاسبه بدون دخالت مستقیم انسان می‌توانند به‌طور مؤثری در بسیاری از زمینه‌ها مورد استفاده قرار گیرند. این تکنیک‌ها در کشاورزی به‌ویژه برای بهبود بهره‌وری و پایش محصولات و سطح زیرکشت مورد استفاده قرار گرفته‌اند (Tariq et al., 2023). برای مثال، الگوریتم جنگل تصادفی^۲ یک روش طبقه‌بندی نظارت شده است^۳ (Chen et al., 2018) که نتایج قابل قبولی در نقشه‌برداری زمین‌های زراعی ارائه کرده است (Hou et al., 2019; Novelli et al., 2016; Youssef et al., 2016). در مطالعه تلگونتا^۴ (۲۰۱۸) از داده‌های لندست ۸ و الگوریتم جنگل تصادفی در گوگل ارث انجین^۵، نقشه اراضی کشاورزی با وضوح ۳۰ متری را برای استرالیا و چین تهیه کرد. نتایج صحت کلی ۹۷/۶٪ برای استرالیا و ۹۴٪ برای چین را نشان داد و مساحت اراضی کشاورزی به‌ترتیب ۳۵/۱ و ۱۶۵/۲ میلیون هکتار برآورد شد. (Teluguntla et al., 2018) در ایران نیز رضایی و همکاران (۱۴۰۳)، از روش‌های مختلف یادگیری ماشین به‌منظور برآورد سطح زیر کشت برنج در استان گیلان استفاده کردند که نتایج نشان داد، الگوریتم جنگل تصادفی با ضریب کاپای ۰/۹۴ و صحت کلی ۰/۹۰ بالاترین صحت را در مقایسه با سایر روش‌ها داشته است (Rezaei et al., 2024). در تحقیق ترابی و همکاران (۱۴۰۲)، به بررسی تأثیر تصاویر راداری در بهبود صحت طبقه‌بندی تصاویر ماهواره‌ای اپتیکی سنتینل-۲^۶ با استفاده از الگوریتم‌های یادگیری ماشین (جنگل تصادفی، درخت تصمیم و ماشین بردار پشتیبان) پرداخته است. نتایج نشان داد که افزودن داده‌های راداری تنها در کلاس‌های کشت مجدد، دیم و باغات بهبود قابل توجهی ایجاد کرده و الگوریتم جنگل تصادفی عملکرد بهتری نسبت به سایر روش‌ها نشان داده است (Torabi et al., 2023). عبدی و همکاران (۲۰۲۴) با استفاده از تصاویر ماهواره‌ای لندست ۸ و سنتینل-۱، تغییرات سطح زیرکشت برنج را در منطقه پیرانشهر ایران از سال ۲۰۱۳ تا ۲۰۲۱ بررسی کرده است. نتایج نشان می‌دهد که سطح زیرکشت برنج از ۲۵۶۴ هکتار به ۴۷۷۱ هکتار افزایش یافته و باعث کاهش سطح آب‌های زیرزمینی تا عمق ۱۰ متری در برخی مناطق شده است. نتایج پژوهش بر لزوم محدود کردن کشت برنج و جایگزینی محصولات کم‌آبر برای حفاظت از منابع آبی تأکید داشت (Abdi et al., 2024). با توجه به لزوم پایش تغییرات سطح زیر کشت به دلیل تغییرات اقلیمی و اثرات آن، این مطالعه با هدف ارزیابی تغییرات سطح زیر کشت طی سال‌های ۱۳۹۵-۱۴۰۳ در منطقه شبکه آبیاری قزوین و معرفی روشی سریع، آسان و قابل تکرار برای برآورد سطح اراضی زراعی انجام شد. از طرفی، با توجه به عدم استفاده گسترده از تکنیک یادگیری ماشین در طبقه‌بندی و برآورد سطح زیر کشت در سامانه گوگل ارث انجین در ایران، این پژوهش می‌تواند به بهینه‌سازی مدیریت منابع آب و حفظ امنیت غذایی کمک کند.

¹ Machine Learning

² Random Forest

³ Supervised Classification

⁴ Landsat 8


⁵ Google Earth Engine (GEE)

⁶ Sentinel-2

مواد و روش ها

منطقه مورد مطالعه

شبکه آبیاری دشت قزوین با وسعتی معادل ۸۰۰۰۰ هکتار ناخالص، به صورت نواری است به طول ۹۴ کیلومتر که از محدوده زیاران شروع شده و به اراضی کهک تاکستان منتهی می شود. عرض متوسط این نوار حدود ۸/۷ کیلومتر می باشد. این شبکه به طور عمده اراضی شهرهای قزوین، آبیک و همچنین بخشی از اراضی شهرستان های تاکستان و بوئین زهرا را در بر می گیرد. مساحت خالص اراضی تحت پوشش شبکه آبیاری طالقان (قزوین) ۶۰۰۰۰ هکتار است که حدود ۷۲ درصد آن را اراضی درجه ۱ و ۲ تشکیل می دهد. الگوی کلی کشت منطقه ۵۰ درصد کشت پاییزه می باشد، که بیشتر به محصول گندم و جو اختصاص دارد، ۱۵ درصد کشت بهاره و ۳۵ درصد آیش طبق برنامه رعایت می شود (Darvish Hendi and Amiri Tokaldany, 2024). در شکل ۱، منطقه مورد مطالعه با استفاده از شیب فایل شبکه آبیاری قزوین، مشخص گردید.



شکل ۱. منطقه مطالعاتی و موقعیت شبکه آبیاری دشت قزوین

Fig 1. The study area and the location of Qazvin plain's irrigation network

داده های مورد استفاده

داده های زمینی

با توجه به اهمیت انتخاب دقیق داده های مختصاتی کلاس های مورد بررسی در بخش ورودی داده ها برای آموزش و ارزیابی الگوریتم های طبقه بندی، داده های مربوط کشت و مشخصات زمین ها از کشاورزان و در سال ۱۴۰۳ جمع آوری شد (جدول ۱).

جدول ۱. مشخصات مزارع مورد مطالعه

Table 1. The specifications of the studied fields

کد مزرعه	نام کشاورز	منطقه	نوع محصول
Field's code	Farmer's Name	Region	Cultivated product
۱۰۳۱	جهانگیر شعبانی	یونس آباد	جو- گندم - یونجه
۷۴۲	شرکت پوشوند	زیاران	جو- گندم - یونجه
۵۶۵	شرکت پوشوند	قشلاق	جو- گندم - یونجه
۱۲۰۸	حبیب الله مافی	تازه آباد	جو- گندم- ذرت

داده‌های سنجش از دوری و پردازش آن‌ها

مطالعه کنونی، در گروه علوم و مهندسی آب دانشگاه بین المللی امام خمینی قزوین، به‌منظور برآورد تغییرات سطح زیرکشت محصولات گندم-جو، ذرت و یونجه در منطقه شبکه آبیاری و زهکشی استان قزوین انجام شد. در این پژوهش از ترکیب تصاویر اپتیک سنتینل-۲ و تصاویر راداری سنتینل-۱ در طی سال‌های متوالی (۱۳۹۵-۱۴۰۳) برای کشت‌های بهاره و پاییزه استفاده شد. تصاویر سنتینل-۲ از مجموعه داده‌های "COPERNICUS/S2_HARMONIZED" انتخاب شد. مراحل پردازش شامل فیلتر کردن تصاویر بر اساس محدوده مکانی و زمانی، محاسبه شاخص‌های طیفی مانند شاخص نرمال شده پوشش گیاهی^۷، شاخص تعدیل شده خاک^۸، و شاخص سطح برگ^۹، ترکیب تصاویر با استفاده از مقدار بیشینه و قابل ذکر است که برش تصاویر براساس شیپ فایل محدوده مطالعه بود. داده‌های سنتینل-۱ از مجموعه داده‌های "COPERNICUS/S1_GRD" برای بازه زمانی ۱۰ ساله انتخاب شده و فیلترهایی بر اساس پلاریزاسیون VV و حالت IW اعمال شد. به‌منظور کاهش نویز اسپکل، از فیلتر کانونی میانه با شعاع ۳۰ متر استفاده گردید و تصاویر ترکیب شده با مقدار بیشینه، به منطقه مطالعه برش داده شدند. در نهایت، شاخص‌های محاسبه شده سنتینل-۲ با داده‌های راداری سنتینل-۱ در یک لایه ترکیبی چند زمانه ادغام شدند.

در این مطالعه، پنج کلاس اصلی محصولات زراعی، شامل گندم، یونجه، مناطق شهری، اراضی بایر و آیش در دوره کشت پاییزه و محصولات ذرت، یونجه، مناطق شهری، اراضی بایر و آیش برای دو دوره کشت بهاره تعریف شدند. این کلاس‌ها نمایانگر تنوع پوشش زمین در دشت قزوین بوده و به منظور تحلیل دقیق‌تر، برای هر کلاس نمونه‌های مشخصی براساس نقاط گزارش شده توسط کشاورزان در سامانه گوگل ارث انجین، استخراج شدند. تعداد نمونه‌های هر کلاس در دوره کشت پاییزه به ترتیب عبارت‌اند از: گندم ۲۸۱ نمونه، یونجه ۲۹۹ نمونه، اراضی بایر ۱۴۸ نمونه، مناطق شهری ۱۷۸ نمونه و آیش ۱۰۸ نمونه و در دوره کشت بهاره به ترتیب: ذرت ۸۳۰ نمونه، یونجه ۹۷۷ نمونه، اراضی بایر ۱۵۲ نمونه، مناطق شهری ۱۷۸ نمونه و آیش ۱۰۸ نمونه. در مجموع، ۱۰۱۴ نمونه برای دوره کشت پاییزه و ۲۲۵۴ نمونه برای دوره کشت بهاره در مراحل آموزش و تست مدل جمع‌آوری و مورد استفاده قرار گرفت. این داده‌ها از طریق بازدیدهای میدانی جمع‌آوری شده و به‌عنوان داده‌های آموزشی در طبقه‌بندی استفاده شدند. سپس داده‌های آموزشی با نمونه‌برداری از تصویر ترکیبی به مقیاس مکانی ۱۰ متر استخراج و برای آموزش مدل جنگل تصادفی مورد استفاده قرار گرفتند. این مدل با ۱۰۰ درخت آموزش داده شد، که در نهایت تصویر را طبقه‌بندی و خروجی آن به‌صورت نقشه پوشش زمین با پنج کلاس ارائه شد.

برای ارزیابی عملکرد طبقه‌بندی، از ماتریس درهم‌ریختگی تولید شده طی فرآیند آموزش استفاده و معیارهایی مانند صحت کلی، ضریب کاپا محاسبه شد. همچنین، برای محاسبه مساحت کلاس‌های ذرت، یونجه و آیش، ماسک‌های باینری برای هر کلاس ایجاد شده و مساحت هر کلاس با جمع کردن مساحت پیکسل‌های داخل ماسک‌ها محاسبه شد. این مقادیر با استفاده از مقیاس تبدیل به واحد هکتار گزارش شدند.

این فرآیند برای دوره زمانی (۱۳۹۵-۱۴۰۳) تکرار شد تا تغییرات زمانی مساحت محصولات زراعی در دوره کشت بهاره و پاییزه بررسی و تحلیل شود. تمام تحلیل‌ها با استفاده از پلتفرم GEE که قابلیت پردازش مکانی سریع مبتنی بر فضای ابری را فراهم می‌کند، انجام شد. جدول ۲، نشان دهنده ویژگی‌های تصاویر سنتینل-۲ و ۱ است که در این پژوهش مورد استفاده قرار گرفته‌است.

⁷ NDVI

⁸ SAVI

⁹ LAI

جدول ۲. مشخصات طیفی و مکانی داده‌های سنجنده سنتینل ۱ و ۲

Table 2. Spectral and spatial characteristics of sentinel-2 and sentinel-1 data

Spatial resolution (m)	Central wave length (nm)	Band number	Band name	Satellite
توان تفکیک مکانی به متر	میانگین طول موج	شماره باند	نام باند	ماهواره
10	492.4	2	Blue آبی	Sentinel-2B سنتینل-۲
10	559.8	3	Green سبز	
10	664.6	4	Red قرمز	
20	704.1	5	Red edge لبه قرمز پوشش گیاهی	
20	740.5	6	Red edge لبه قرمز پوشش گیاهی	
20	782.8	7	Red edge لبه قرمز پوشش گیاهی	
10	832.8	8	Near infrared مادون قرمز نزدیک	
20	864.8	8A	Narrow near infrared مادون قرمز نزدیک کم پهنا	
20	1613.7	11	Short-wave infrared مادون قرمز طول موج کوتاه	
20	2202.4	12	Short-wave infrared مادون قرمز طول موج کوتاه	
10	-	-	VV	سنتینل ۱A

برای توزیع نمونه‌ها، از تقسیم‌بندی استاندارد ۷۰ درصد برای آموزش و ۳۰ درصد برای تست استفاده شده است (جدول ۳). این توزیع متوازن به کاهش احتمال بیش‌برازش کمک می‌کند و نتایج حاصل از مدل را قابل اطمینان‌تر می‌سازد (Gholamy et al., 2018). انتخاب این درصدها براساس استانداردهای علمی در مسائل طبقه‌بندی نظارت‌شده انجام شده است. استفاده از این روش موجب می‌شود که مدل نه‌تنها بتواند اطلاعات کافی برای یادگیری داشته باشد، بلکه داده‌های مستقل کافی نیز برای ارزیابی عملکرد آن در اختیار باشد. این رویکرد به ایجاد تعادلی میان صحت مدل و قابلیت تعمیم آن کمک کرده و در نهایت، نتایجی دقیق‌تر و معتبرتر ارائه می‌دهد.

جدول ۳. نمونه‌های آموزشی و ارزیابی مورد استفاده در طبقه‌بندی تصاویر ماهواره‌ای

Table 3. Training examples and evaluation used in the classification of satellite images

Class	Training samples (70%)	Test samples (30%)	Total number of samples
کلاس	۷۰٪ نمونه‌های آموزشی	۳۰٪ نمونه‌های ارزیابی	کل نمونه‌های برداشت‌شده
Wheat-barley	196	85	281
گندم-جو			
Alfalfa	209	90	299

یونجه			
Maize	581	249	830
ذرت			
Fallow	75	33	108
آیش			

طبقه بندی تصاویر ماهواره‌ای

ابتدا نمونه‌های آموزشی به گونه‌ای انتخاب شدند که تعداد و پراکندگی مناسبی برای هر طبقه داشته باشند. سپس، از ۷۰ درصد داده های آموزشی برای ارزیابی اثر تعداد نمونه‌ها استفاده شد و طبقه‌بندی با هر سری داده‌های آموزشی مورد بررسی و مقایسه قرار گرفت. در مرحله بعد، با استفاده از داده‌های باقی‌مانده از برداشت زمینی به عنوان نمونه‌های ارزیابی و ماتریس خطا، اعتبارسنجی طبقه‌بندی انجام شد. تعداد نمونه‌های آموزشی و ارزیابی در جدول ۱ ارائه شده‌اند. برای افزایش صحت طبقه‌بندی، انتخاب نمونه‌ها باید به گونه ای باشد که پوشش متعادلی برای کلاس‌ها ایجاد شود و از شاخص‌های ارزیابی مانند ماتریس خطا و ضریب کاپا استفاده شود. برای ارزیابی کمی تفکیک‌پذیری طبقات در نمونه‌های آموزشی، از آزمون جفریس-ماتوسیتا استفاده شد. در این آزمون، مقادیر تفکیک‌پذیری در بازه‌ای بین ۰ تا ۲ قرار دارند؛ جایی که صفر نشان‌دهنده عدم تفکیک‌پذیری کامل کلاس‌ها و ۲ نشان‌دهنده تفکیک کامل آنها است. برای دستیابی به طبقه‌بندی دقیق، میزان تفکیک‌پذیری باید بالاتر از ۱/۸ باشد (Sen et al., 2019; Wang et al., 2018). در پایان، صحت نقشه‌های طبقه‌بندی با استفاده از مکان‌های آموزشی ارزیابی شد. در پژوهش حاضر، طبقه‌بندی تصاویر با استفاده از جنگل تصادفی انجام شد.

جنگل تصادفی

جنگل تصادفی یکی از الگوریتم‌های پرکاربرد و قدرتمند در حوزه یادگیری ماشین است که در گروه یادگیری نظارت‌شده^{۱۰} قرار دارد. این الگوریتم از ترکیب چندین درخت تصمیم با استفاده از رویکرد جمع‌بندی^{۱۱} و تصادفی‌سازی ویژگی‌ها^{۱۲} ساخته می‌شود. در مرحله آموزش، جنگل تصادفی مجموعه‌ای از درخت‌های تصمیم مستقل ایجاد می‌کند که هر یک بر اساس یک نمونه‌گیری بوت‌استرپ^{۱۳} از داده‌های آموزشی ایجاد شده و از یک زیرمجموعه تصادفی از ویژگی‌ها برای انتخاب بهترین تقسیمات^{۱۴} در هر گره استفاده می‌کند که به صورت معادله ۱ نمایش داده می‌شود. این رویکرد نه تنها باعث کاهش هم‌بستگی میان درخت‌ها و بهبود تعمیم‌پذیری مدل می‌شود، بلکه با ترکیب پیش‌بینی‌های درخت‌های منفرد، صحت پیش‌بینی نهایی را نیز افزایش می‌دهد (Breiman, 2001; Goldblatt et al., 2016).

$$\{DT(x, \theta_k)\}_{k=1}^T \quad (1)$$

که در آن x بردار ورودی، θ_k بردار تصادفی اما به صورت مستقل، اما با توزیع مشابه با بردارهای $\theta_1, \dots, \theta_{k-1}$ نمونه‌برداری می‌شود. در ابتدا، T نمونه بوت‌استرپ از داده‌های آموزشی استخراج می‌شود. برای هر نمونه بوت‌استرپ β ، یک درخت طبقه‌بندی و رگرسیون (CART) بدون هرس ایجاد می‌شود که در هر گره تنها یکی از M ویژگی‌های انتخاب‌شده به صورت تصادفی برای تقسیم هر گره CART انتخاب می‌گردد (Breiman, 2001b).

یکی از مزایای کلیدی الگوریتم جنگل تصادفی، توانایی آن در کاهش بیش‌برازش^{۱۵} است. تصادفی‌سازی در انتخاب داده‌ها و ویژگی‌ها باعث می‌شود مدل به داده‌های خاص وابسته نباشد و عملکرد بهتری روی داده‌های جدید نشان دهد. همچنین، با ترکیب پیش

¹⁰ Supervised Learning

¹¹ Bagging

¹² Feature Randomness

¹³ Bootstrap Sampling

¹⁴ Splits

¹⁵ Overfitting

بینی‌های درخت‌های متعدد، الگوریتم تأثیر نوز در داده‌ها را کاهش داده و پیش‌بینی‌هایی پایدار و قابل اطمینان ارائه می‌کند. این الگوریتم همچنین قادر به مدیریت داده‌های پیچیده و غیرخطی بوده و می‌تواند با تعداد زیادی ویژگی و حتی داده‌های ناقص یا ناکامل کار کند. از دیگر مزایای جنگل تصادفی می‌توان به سادگی در پیاده‌سازی و توانایی آن در کاربردهای گسترده نظیر طبقه‌بندی و رگرسیون اشاره کرد (Neetu and Ray, 2019).

جنگل تصادفی در مسائل طبقه‌بندی، نتیجه نهایی را بر اساس رأی‌گیری اکثریت از درخت‌های تصمیم تعیین می‌کند؛ به این صورت که کلاسی که بیشترین تعداد درخت آن را انتخاب کرده باشد، به‌عنوان خروجی پیش‌بینی می‌شود. در مسائل رگرسیون، پیش‌بینی نهایی با محاسبه میانگین یا میان به‌دست می‌آید. این الگوریتم در کاربردهایی نظیر شناسایی الگوها (مانند شناسایی تصاویر)، تخمین مقادیر عددی (مانند عملکرد محصولات کشاورزی) و مسائل علمی مختلف به‌طور گسترده استفاده می‌شود. توانایی آن در ارائه پیش‌بینی‌های دقیق و تعمیم‌پذیر، همراه با مقاومت در برابر نوز و داده‌های ناقص، باعث شده که به یکی از پرکاربردترین الگوریتم‌ها در یادگیری ماشین تبدیل شود (Ramezani Etedali and Ahmadi, 2024).

ارزیابی صحت‌سنجی روش‌های طبقه‌بندی

صحت کلی یک معیار ارزیابی است که برای بررسی صحت کلی یک طبقه‌بندی به‌کار می‌رود. این شاخص نمایانگر درصد کل داده‌هایی است که به درستی طبقه‌بندی شده‌اند و به‌طور کلی از طریق ماتریس درهم‌ریختگی محاسبه می‌شود. صحت کلی به‌صورت زیر تعریف می‌شود:

$$\text{Overall Accuracy} = \frac{N_{\text{Correct}}}{N_{\text{total}}} \quad (2)$$

که در اینجا:

N_{Correct} : تعداد نمونه‌های درستی است که به درستی طبقه‌بندی شده‌اند.

N_{total} : کل تعداد نمونه‌ها است.

اگرچه صحت کلی یک معیار ساده و کاربردی است، اما ممکن است در مواردی که کلاس‌های نابرابر وجود دارند، گمراه‌کننده باشد. مثلاً، اگر کلاس غالب دارای تعداد بالایی از نمونه‌ها باشد، صحت کلی ممکن است بالاتر از مقدار واقعی صحت در پیش‌بینی‌های جزئی‌تر باشد.

بنابراین، استفاده از شاخص‌های دیگر مانند ضریب کاپا، که صحت را نسبت به طبقه‌بندی‌های تصادفی و نابرابری داده‌ها تعدیل می‌کند، می‌تواند تصویر دقیق‌تری از عملکرد مدل ارائه دهد.

ضریب کاپا^{۱۶}: میزان توافق بین پیش‌بینی‌ها و مقادیر واقعی را با در نظر گرفتن پیش‌بینی‌های تصادفی محاسبه می‌کند (Ghodsi et al., 2021).

نتایج و بحث

آزمون تفکیک‌پذیری

نتایج آزمون تفکیک‌پذیری جفریس-ماتوسیتا (JM) برای ارزیابی توانایی تفکیک طیفی شش کلاس کاربری اراضی، از جمله گندم-جو، یونجه، آیش، مناطق شهری و اراضی بایر در فصل پاییز و شش کلاس مشابه در فصل بهار، استفاده شد. این آزمون با دامنه عددی بین ۰ (عدم جداسازی) تا ۲ (تفکیک کامل) نشان داد که برخی از کلاس‌ها کاملاً از یکدیگر جدا هستند، در حالی که برخی دیگر به دلیل هم‌پوشانی طیفی، جداسازی ضعیف‌تری دارند. تعیین آستانه شاخص‌های طیفی و به‌کارگیری تصاویر راداری می‌تواند در شناسایی و تفکیک بهتر بین کلاس‌های مختلف، به‌ویژه مناطق آیش و بایر، نقش مهمی داشته باشد (Wuyun et al., 2022). جدول ۴، نتایج آزمون تفکیک‌پذیری جفریس-ماتوسیتا را برای هر کلاس در دو دوره کشت بهاره و پاییزه نشان می‌دهد. استفاده از

¹⁶ Kappa coefficient

داده‌های راداری سنتینل-۱ توانست بهبود قابل توجهی در جداسازی این کلاس‌ها ایجاد کند. امواج راداری با نفوذ به سطوح گیاهی و حساسیت به ساختارهای فیزیکی، اطلاعات مکملی را فراهم می‌کنند که در داده‌های نوری موجود نیست (Lu et al., 2023; Snevajs et al., 2022).


جدول ۴. نتایج آزمون تفکیک پذیری جفریس-ماتوسیتا

Table 4. Results of the Jeffries-Matusita separability test

		Wheat-barley	Alfalfa	Fallow	Bare_land	Build_up
		گندم-جو	یونجه	آیش	مناطق بایر	مناطق شهری
کشت پاییزه Winter cultivation	Wheat-barley	0	0.65	2	2	2
	گندم-جو					
	Alfalfa	0.65	0	2	2	2
	یونجه					
	Fallow	2	0.39	0	0.48	1.08
	آیش					
	Bare_land	2	2	0.48	2	2
کشت بهاره Spring cultivation	مناطق بایر					
	Build_up	2	2	1.08	2	0
	مناطق شهری					
		Maize	Alfalfa	Fallow	Bare_land	Build_up
		ذرت	یونجه	آیش	مناطق بایر	مناطق شهری
کشت بهاره Spring cultivation	Maize	0	0.7	1.12	1.54	1.92
	ذرت					
	Alfalfa	0.7	0	2	2	2
	یونجه					
	Fallow	1.12	2	0	2	1.42
	آیش					
	Bare_land	1.54	2	2	0	0.41
	مناطق بایر					
	Build_up	2	2	1.42	0.41	0
	مناطق شهری					

عملکرد جنگل تصادفی


در نتایج ماتریس درهم‌ریختگی نشان داد که الگوریتم جنگل تصادفی عملکرد بسیار دقیقی در طبقه‌بندی کلاس‌های مختلف داشت. برای کشت پاییزه از ۲۶۰ نمونه کلاس گندم-جو، تنها ۲۰ نمونه در کلاس یونجه قرار گرفته‌است. برای کلاس یونجه، از ۲۹۹ نمونه، تنها ۲ نمونه به اشتباه در نظر گرفته شدند، شکل ۲، به نتایج ماتریس درهم‌ریختگی را برای کلاس‌های زراعی و غیر زراعی در فصول کشت بهاره و پاییزه نشان می‌دهد. تمامی نمونه‌های کلاس آیش، مناطق بایر و شهری به درستی طبقه‌بندی شده‌اند. ضریب کاپا ۰/۹۹۶ نشان‌دهنده توانایی بسیار بالای RF در طبقه‌بندی دقیق کلاس‌ها با هم‌پوشانی است. صحت کلی ۹۹/۶۹٪ نشان‌دهنده عملکرد بسیار خوب RF در طبقه‌بندی دقیق و پایدار است.



شکل ۲. نتایج ماتریس درهم ریختگی روش جنگل تصادفی

Fig 2. Random forest confusion matrix

به طور مشابه، در کشت بهاره، جنگل تصادفی با صحت کلی ۹۸/۹۳٪ و ضریب کاپای ۰/۹۸ بهترین عملکرد را در میان سه روش نشان داد. این الگوریتم توانایی بالایی در طبقه بندی داده های پیچیده و مدیریت کلاس های با هم پوشانی طیفی نشان داد. در طبقه بندی کلاس ذرت با ۸۳۰ نمونه تنها ۱۱ نمونه در کلاس یونجه طبقه بندی شدند. برای کلاس یونجه نیز از ۹۷۷ نمونه، ۸ نمونه به اشتباه در کلاس ذرت قرار گرفتند. تمامی نمونه ها در کلاس های آیش، مناطق بایر به درستی انتخاب شده اند، و برای کلاس مناطق شهری تنها ۱ نمونه در کلاس آیش قرار گرفته است. این صحت بالا ناشی از توانایی RF در استفاده از رویکردهای مبتنی بر مجموعه Ensemble و ترکیب چندین مدل درخت تصمیم است که به کاهش واریانس و افزایش پایداری مدل منجر می شود (نتایج در جدول ۵ گزارش شده است). در مطالعه چن و همکاران (۲۰۰۴) بیان شده است که RF به دلیل ساختار مجموعه ای و انتخاب تصادفی ویژگی ها، معمولاً در داده های با نویز یا داده های نامتوازن بهترین عملکرد را دارد (Chen and Breiman, 2004). این الگوریتم با ساختن چندین درخت تصمیم گیری که به صورت همزمان آموزش می بینند و رأی گیری از آن ها برای پیش بینی نهایی، توانایی مقابله با مشکلاتی نظیر خطای نویز و عدم تعادل داده ها را دارد (Aria et al., 2021). شکل ۳، نقشه طبقه بندی تصاویر برای دو دوره کشت بهاره و پاییزه را به روش جنگل تصادفی نشان می دهد.



شکل ۳. نقشه طبقه‌بندی تصاویر برای دو دوره کشت بهاره (A) و پاییزه (B) به روش جنگل تصادفی

Fig 3. Classified maps of images for (a) spring and (b) autumn cultivation periods using the random forest algorithm

جدول ۵. نتایج صحت الگوریتم‌های مختلف طبقه‌بندی داده‌های تست

Table 5. Accuracy Results of Different Classification Algorithms for Test Data

Accuracy_Assessment		RF
ارزیابی صحت		جنگل تصادفی
کشت پاییزه Winter cultivation	Overall_Accuracy	0.99
	صحت کلی	
	Kappa_coefficient	0.99
	ضریب کاپا	
کشت بهاره Spring cultivation	Overall_accuracy	0.98
	صحت کلی	
	Kappa_coefficient	0.98
	ضریب کاپا	

بررسی روند تغییرات سطح زیر کشت

در این تحقیق تغییرات سطح زیر کشت محصولات پاییزه غالب: گندم و جو، یونجه و مناطق آیش و محصولات بهاره غالب: ذرت، یونجه و مناطق آیش مورد بررسی قرار گرفت که نتایج آن به تفکیک برای کشت بهاره و کشت پاییزه در دشت قزوین تحلیل شد.


کشت بهاره

بررسی روند تغییرات سطح زیر کشت محصولات بهاره (شکل ۴a) نشان داد، کشت ذرت در سال‌های اخیر به‌ویژه در سال ۱۴۰۲ روند افزایشی داشته است که دلیل آن می‌تواند به‌خاطر درآمد بیشتر آن نسبت به سایر محصولات و وابستگی کمتر این محصول به شرایط تغییر اقلیمی باشد. از آنجایی که ذرت کشت‌شده در دشت قزوین، در تمام طول فصل رشد آبیاری می‌شود، در صورت وجود منبع آبی مطمئن در مقایسه با کشت دیم و کشت‌های فصل پاییز، کمتر تحت تأثیر تغییر اقلیم قرار می‌گیرد زیرا کشاورز می‌تواند تغییرات نیاز آبی در اثر تغییر اقلیم را با آبیاری جبران می‌کند. ذرت به‌عنوان یک گیاه C4، در شرایط دمایی بالاتر و افزایش CO₂ جوی، کارایی فتوسنتزی و بهره‌وری آب بالاتری دارد که آن را به گزینه‌ای مناسب در مواجهه با گرمایش جهانی تبدیل می‌کند (Fayazi et al., 2022). همچنین، به‌دلیل سود اقتصادی حاصل از کشت ذرت، کشاورزان بیشتری تمایل به کشت ذرت دارند (Ashktorab et al., 2015). خرید تضمینی ذرت علوفه‌ای و نیاز شدید دامداری به این محصول ارزشمند باعث شده است کشت ذرت در منطقه سود بیشتری نسبت به سایر محصولات بهاره از جمله یونجه داشته باشد. مطالعه غلامی و همکاران (۱۳۹۷) برای اولویت بندی کشت چهار محصول مهم در دشت قزوین شامل گندم، یونجه، ذرت و جو نتایج مشابهی را داشت و نشان داد کشت گندم و ذرت در هر دو حالت یارانه‌ای و غیریارانه‌ای، به‌ترتیب برای کشت‌های پاییزه و بهاره در اولویت بوده و دارای بالاترین میزان سود هستند. نتایج به‌دست آمده برای کاهش سطح زیر کشت یونجه نیز با مطالعه غلامی و همکاران مطابقت دارد و دلیل اصلی آن می‌تواند به‌خاطر نسبت کمتر درآمد به هزینه برای این محصول باشد. از طرف دیگر حساسیت یونجه به دسترسی آب، آن را در شرایط گرم‌شونده بدون آبیاری کافی، کمتر قابل دوام می‌کند (Gholami et al., 2018).

افزایش زمین‌های آیش پس از سال ۱۴۰۰ و تثبیت آن تا سال ۱۴۰۲، می‌تواند به عوامل اقتصادی-اجتماعی نظیر پاندمی کووید-۱۹ مرتبط باشد که منجر به کاهش فعالیت‌های کشاورزی و نیروی کار در این دوره شده است (moosazadeh and Tavakkoli, 2023). علاوه بر این، رکود اقتصادی مرتبط با پاندمی، قدرت خرید کشاورزان را کاهش داد و توانایی آن‌ها در سرمایه‌گذاری در نهاده‌های ضروری را محدود کرد که به افزایش زمین‌های آیش و کاهش شدت کشت منجر شد (Tahernia and hasanvand, 2020).

کشت پاییزه


در بررسی روند تغییرات سطح زیر کشت پاییزه (شکل ۴b)، افزایش متوسط کشت گندم و جو تا سال ۱۴۰۲ نشان‌دهنده تغییر به سمت محصولاتی است که در شرایط دمایی پایین‌تر و بارش‌های متغیر، عملکرد بهتری دارند. این غلات به‌عنوان محصولات اصلی، مقاومت نسبی بالایی در برابر نوسانات اقلیمی دارند که آن‌ها را به گزینه‌های مطمئنی برای کشت زمستانه تبدیل می‌کند. همچنین خرید تضمینی گندم در منطقه مورد بررسی، منجر شده که کشاورزان تمایل بیشتری به کشت گندم نسبت به یونجه داشته باشند.



شکل ۴. روند تغییرات سطح زیر کشت بهاره (a) و پاییزه (b) در طی سال‌های ۱۳۹۵-۱۴۰۲

Fig 4. Trend of changes in the area under (a) spring and (b) autumn cultivation during the 2016–2023

مطابق شکل ۵، درصد تغییرات سطح زیر کشت در دوره‌های کشت بهاره و پاییزه نشان داده شده است. در سال ۱۳۹۵ سطح زیر کشت بهاره و پاییزه به ترتیب ۷٪ و ۱۰٪ کاهش یافته که این مقادیر در سال بعد با کاهش ۸٪ و ۱٪ همراه بوده است. به طور مشابه در سال ۱۳۹۷ نیز این درصد برای هر دو فصل کاهش یافته است. در سال ۱۳۹۸ کشت بهاره با تنزل تنها ۰/۴۶٪ همراه بوده و در مقابل کشت پاییزه با افزایش ۱۲/۳۶٪ همراه بوده است. در سال ۱۳۹۹، با توجه به شروع پاندمی کرونا و اعمال قرنطینه در ایران، سطح کشت در هر دو فصل با کاهش بالای ۲۵٪ همراه بوده است و در سال‌های بعد سطح زیر کشت رو به افزایش بوده است. از اصلی‌ترین دلایل کاهش سطح کشت می‌توان به اعمال قوانین رفت و آمد و کاهش کارگران فصلی و دائمی، کاهش دسترسی به بازارهای فروش و کاهش کنترل بر آفات و بیماری‌های مزارع اشاره کرد (Goel et al., 2023; Moradhaseli et al., 2022; Rad et al., 2021).




شکل ۵. بررسی درصد تغییرات سطح زیر کشت در دوره کشت بهاره و پاییزه

Fig 5. Analysis of the percentage changes in the cultivated area during the spring and winter cropping seasons

تأثیر تغییرات اقلیمی بر الگوی کشت

تغییرات اقلیمی، از جمله افزایش دما و کاهش بارش‌ها، تأثیرات چشمگیری بر الگوهای کشت در دشت قزوین داشته است (Mahmoodi and Parhizkari, 2016). شکل ۶، روند تغییرات دما و بارش را در طی سال‌های ۱۳۹۵ تا ۱۴۰۲ را نشان می‌دهد. براساس نتایج دما با نوسانات بسیاری همراه بوده و به طور کلی با توجه به شیب تغییرات، روندی افزایشی داشته است. در مقابل، بارش به طور کلی با شیب نزولی با کاهش ۳۸ درصدی همراه بوده است. این تغییرات منجر به کاهش منابع آب و خاک شده و لزوم استفاده از گیاهان مقاوم به خشکی و مدیریت بهینه منابع را افزایش داده است. مطالعات نشان می‌دهد که تغییر اقلیم موجب افزایش دما، کاهش بارندگی‌ها، تغییرات بیلان آبی و کاهش سطح تولید شده است.

به عنوان مثال، افزایش سطح زیر کشت ذرت نشان‌دهنده‌ی انطباق کشاورزان با تغییرات اقلیمی است. این تغییرات در الگوی کشت می‌تواند به عنوان راهکاری برای مقابله با تغییرات اقلیمی و تضمین امنیت غذایی در نظر گرفته شود. تحقیقات نشان داده‌اند که انتخاب گیاهان مقاوم به شرایط نامساعد اقلیمی می‌تواند به پایداری تولیدات کشاورزی کمک کند (Fayazi et al., 2022).



شکل ۶. روند تغییرات دما و بارش در سال‌های ۱۳۹۵-۱۴۰۲

Fig 6. Trends in temperature and precipitation fluctuations during the years 2016–2023

بررسی شرایط کشت و منابع آبی تخصیص داده شده سال ۱۴۰۳

با توجه به اعمال رویکردهای مدیریتی در منطقه و تخصیص آب به مناطق دیگر، افت سطح زیرکشت در سال ۱۴۰۳ برای محصولات زراعی کشت شده در فصول کشت بهاره (ذرت و یونجه) و پاییزه (گندم و جو و یونجه) به ترتیب با کاهش ۵۸/۰۷٪ و ۴۴/۴۲٪

به‌وضوح قابل درک است. جدول ۶، درصد تغییرات سطح زیر کشت را در مقایسه با میانگین ۱۰ سال اخیر نشان می‌دهد، مشهود است که در هر دو دوره بهاره و پاییزه، سطوح زیر کشت محصولات زراعی در این سال با کاهش چشمگیری همراه بوده‌است. شکل ۷، نیز روند کاهشی میزان آب ورودی و تحویلی به کانال را طبق گزارش سازمان آب منطقه‌ای قزوین تایید می‌کند. نکته قابل توجه اینکه شبکه در سال ۱۴۰۳ با کاهش ۴۱/۸۴٪ در میزان آب تحویلی مواجه بوده است. تفاوت میان درصد کاهش تغییرات سطح زیر کشت در کشت بهاره و پاییزه و آب تحویلی در شبکه، می‌تواند دلالت بر افزایش بهره‌وری در شبکه و یا افزایش میزان برداشت از آب زمینی باشد که در این صورت پایداری شبکه تحت تأثیر قرار گرفته و باید راه‌حل‌های مدیریتی، مانند تغذیه مصنوعی اتخاذ گردد. مقایسه نتایج نشان می‌دهد کاهش سطح زیر کشت متناسب با کاهش میزان آب سطحی تحویل شده در شبکه نیست. روند تغییرات سطح زیرکشت نشان می‌دهد ادامه روند فعلی، فشار مضاعفی بر منابع آب زیرزمینی را در سال‌های آینده در پی خواهد داشت. افزایش میزان تخصیص در سال‌های آینده، کشت گیاهان کم‌آب‌بر، افزایش راندمان توزیع در سطح شبکه و افزایش بهره‌وری آب در سطح مزرعه می‌تواند راه کارهای مؤثری برای مقابله با شرایط ناترازی فعلی باشد.

جدول ۶. بررسی تغییرات سطح زیرکشت محصولات زراعی در سال ۱۴۰۳

Table 6. Analysis of changes in cultivated areas of agricultural products in 2024

Cultivation season	Class	Maize	Alfalfa	Fallow
دوره کشت	کلاس	ذرت	یونجه	آیش
Spring cultivation کشت بهاره	Cultivated area (ha)	20138.62	10219.8	12514.38
	سطح زیر کشت (هکتار)			
	Change percentage of classes	-70.86	-85.21	-81.89
Winter cultivation کشت پاییزه	Class	Wheat-barley	Alfalfa	Fallow
	کلاس	گندم-جو	یونجه	آیش
	Cultivated area (ha)	16307.91	17382.58	16641.52
	سطح زیر کشت (هکتار)			
	Change percentage of classes	-73.09	-71.32	-72.54
	درصد تغییرات سه کلاس			



شکل ۷. روند تغییرات میزان آب ورودی، تحویلی (کانال)، تغذیه و تلفات در طی سال‌های زراعی ۱۳۹۴-۱۴۰۳ (طبق گزارش آب منطقه‌ای استان قزوین)

Fig 7. Trend of changes in the volume of water inflow, delivered water (canal), recharge, and losses over the agricultural years 2015-2024 (based on the report from the Regional Water Organization of Qazvin Province).

نتیجه‌گیری

این پژوهش نشان داد که ترکیب داده‌های سنتینل-۱ و سنتینل-۲ با استفاده از الگوریتم جنگل تصادفی می‌تواند به بهبود صحت برآورد سطح زیرکشت و تحلیل تغییرات زمانی کمک کند. یافته‌ها بر لزوم اتخاذ سیاست‌های کشاورزی هوشمند اقلیمی و مدیریت بهینه منابع در منطقه دشت قزوین تأکید دارند. پیشنهاد می‌شود در پژوهش‌های آتی، استفاده از سایر الگوریتم‌های یادگیری ماشین و داده‌های تکمیلی برای بهبود نتایج مورد بررسی قرار گیرد. همچنین، بررسی اثرات تغییر اقلیم و خشک‌سالی بر الگوی کشت و ریسک درآمدی کشاورزان می‌تواند به تصمیم‌گیری مدیران و برنامه‌ریزی آینده کمک کند. با توجه به تغییرات اقلیمی و نیاز به مدیریت منابع آب، انتخاب الگوهای کشت مناسب و مقاوم به خشکی می‌تواند به پایداری تولیدات کشاورزی کمک کند. بنابراین، برنامه‌ریزی دقیق در تخصیص منابع و انتخاب الگوهای کشت مقاوم ضروری به نظر می‌رسد.

سپاس‌گزاری

نویسندگان از حمایت معاونت پژوهشی دانشگاه بین‌المللی امام خمینی (ره) و بنیاد نخبگان استان قزوین- هیئت اندیشه‌ورز توسعه پایدار با رویکرد حفاظت از منابع آب زیرزمینی برای انجام این مطالعه قدردانی می‌نمایند.

منابع

- Abdi, S., Ahmadee, M., Rustum, R., & Salmanpour, A. (2024). Monitoring Changes in Rice Cultivation Area using Multi-Temporal Satellite images (Case Study: Beiranshahr Region, Iran). *Journal of Drought and climate change Research (JDCR)*, 2(2), 77-92. <https://doi.org/10.22077/jdcr.2023.6743.1040>.
- Acevedo, M., Pixley, K., Zinyengere, N., Meng, S., Tufan, H., Cichy, K., Bizikova, L., Isaacs, K., Gezzi-Kopel, K., & Porciello, J. (2020). A scoping review of adoption of climate-resilient crops by small-scale producers in low- and middle-income countries. *Nature Plants*, 6(10), 1231-1241. <https://doi.org/10.1038/s41477-020-00783-z>.
- Ahmad, I., Singh, A., Fahad, M., & Waqas, M. M. (2020). Remote sensing-based framework to predict and assess the interannual variability of maize yields in Pakistan using Landsat imagery. *Computers and Electronics in Agriculture*, 178, 105732. <https://doi.org/10.1016/j.compag.2020.105732>.
- Akbari, M., Najafi Alamdarlo, H., & moosavi, s. h. (2019). Impacts of Climate Change and Drought on Income Risk and Crop Pattern in Qazvin Plain Irrigation Network. *Journal of Water Research in Agriculture*, 33(2), 265-281. <https://doi.org/10.22092/jwra.2019.119742>.
- Aria, M., Cuccurullo, C., & Gnasso, A. (2021). A comparison among interpretative proposals for Random Forests. *Machine Learning with Applications*, 6, 100094. <https://doi.org/10.1016/j.mlwa.2021.100094>.
- Ashktorab, N., Layani, G., & Soltani, G. R. (2015). Evaluating the Effects of Climate Changes and Government Policies on Yield and Cultivation Area of Maize in Iran: Panel Data Method. *Journal of Agricultural Economics and Development*, 29(1), 31-42. <https://doi.org/10.22067/jead2.v0i0.37268>.
- Ashourloo, D., Nematollahi, H., Huete, A., Aghighi, H., Azadbakht, M., Shahrabi, H. S., & Goodarzashti, S. (2022). A new phenology-based method for mapping wheat and barley using time-series of Sentinel-2 images. *Remote Sensing of Environment*, 280, 113206. <https://doi.org/10.1016/j.rse.2022.113206>.
- Ayoub Shaikh, T., Rasool, T., & Rasheed Lone, F. (2022). Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. *Computers and Electronics in Agriculture*, 198, 107119. <https://doi.org/10.1016/j.compag.2022.107119>.
- Baraj, B., Mishra, M., Sudarsan, D., da Silva, R. M., & Santos, C. A. G. (2024). Climate change and resilience, adaptation, and sustainability of agriculture in India: A bibliometric review. *Heliyon*. <https://doi.org/10.1016/j.heliyon.2024.e29586>.
- Boryan, C., Yang, Z., Mueller, R., & Craig, M. (2011). Monitoring US agriculture: the US Department of Agriculture, National Agricultural Statistics Service, Cropland Data Layer Program. *Geocarto International*, 26(5), 341-358. <https://doi.org/10.1080/10106049.2011.562309>.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>.
- Chen, C., Liaw, A., & Breiman, L. (2004). Using Random Forest to learn imbalanced data. *University of California, Berkeley*.
- Chen, Y., Lu, D., Moran, E., Batistella, M., Dutra, L. V., Sanches, I. D. A., da Silva, R. F. B., Huang, J., Luiz, A. J. B., de Oliveira, M. A. F. (2018). Mapping croplands, cropping patterns, and crop types using MODIS time-series data.

- International Journal of Applied Earth Observation and Geoinformation*, 69, 133-147. <https://doi.org/10.1016/j.jag.2018.03.005>.
- Darvish Hendi, M., & Amiri Tokaldany, E. (2024). Agricultural Water Management Challenges in Qazvin Plain Irrigation Network. *Iranian Journal of Soil and Water Research*, 54(12), 1945-1962. [In Persian]. <https://doi.org/10.22059/ijswr.2023.365841.669581>.
- Elbasi, E., Zaki, C., Topcu, A. E., Abdelbaki, W., Zreikat, A. I., Cina, E., Shedefat, A., Saker, L. (2023). Crop Prediction Model Using Machine Learning Algorithms. *Applied Sciences*, 13(16), 9288. <https://doi.org/10.3390/app13169288>.
- FAO. (2015). World program of the census of agriculture 2020 I: programme, concepts and definitions. *FAO Statistical Development Series*. FAO, Rome., 204.
- Fayazi, H., Zeinali, E., Soltani, A., & Torabi, B. (2022). The Effect of Climate Change on Yield Potential and Water Productivity of Forage Maize in Iran. *Journal of Crops Improvement*, 24(4), 1247-1263. [In Persian]. <https://doi.org/10.22059/jci.2022.334981.2648>.
- Ghods, Z., Kheirkhah Zarkesh, M. M., & Ghermezcheshmeh, B. (2021). Comparison of Accuracy Between Support Vector Machine and Random Forest Classifiers for Land Use and Crop Mapping Using Multi-Temporal Sentinel-2 Images. *Iranian Journal of Remote Sensing & GIS*, 12(4), 73-92. [In Persian]. <https://doi.org/10.52547/gisj.12.4.73>.
- Gholami, Z., Ebrahimian, H., & Noory, H. (2018). Prioritization of Major Agricultural Crops Cultivation Considering the Energy and Water Costs in Qazvin Plain. *Irrigation Sciences and Engineering*, 41(1), 17-30. [In Persian]. <https://doi.org/10.22055/jise.2018.13447>.
- Gholamy, A., Kreinovich, V., & Kosheleva, O. (2018). Why 70/30 or 80/20 Relation Between Training and Testing Sets: A Pedagogical Explanation. *International Journal of Intelligent Technologies and Applied Statistics*, 11(2), 105-111. [https://doi.org/10.6148/IJITAS.201806_11\(2\).0003](https://doi.org/10.6148/IJITAS.201806_11(2).0003).
- Gilmanov, T. G., Wylie, B. K., Tieszen, L. L., Meyers, T. P., Baron, V. S., Bernacchi, C. J., Billesbach, D., Buba, G., Fishcher, M. L., Glenn, A. J., Hanan, N. P., Hatfield, J.L., Heuer, M. W., Hollinger, S.E., Howard, D. M., Matamala, R., Prueger, J. H., Tenuta, M., Young, D. G. (2013). CO₂ uptake and ecophysiological parameters of the grain crops of midcontinent North America: Estimates from flux tower measurements. *Agriculture, Ecosystems & Environment*, 164, 162-175. <https://doi.org/10.1016/j.agee.2012.09.017>.
- Gitz, V., Meybeck, A., Lipper, L., Young, C. D., & Braatz, S. (2016). Climate Change and Food Security: Risks and Responses. *Food and Agriculture Organization of the United Nations (FAO) Report*, 110, 3-36.
- Goel, S., Singh, M., Phaugat, A., Grewal, S., Goel, M., & Mishra, A. K. (2023). Impact of COVID-19 lockdown on Indian agriculture: A review. *Agricultural Reviews*, 44(2), 215-222. <https://doi.org/10.18805/ag.R-2188>.
- Goldblatt, R., You, W., Hanson, G., & Khandelwal, A. K. (2016). Detecting the boundaries of urban areas in india: A dataset for pixel-based image classification in google earth engine. *Remote Sensing*, 8(8), 634. <https://doi.org/10.3390/rs8080634>.
- Habib-ur-Rahman, M., Ahmad, A., Raza, A., Hasnain, M. U., Alharby, H. F., Alzahrani, Y. M., Bamagoos, A., Hakeem, K. R., Ahmad, S., Nasim, W., Ali, S., Mansour, F., El Sabagh, A. (2022). Impact of climate change on agricultural production: Issues, challenges, and opportunities in Asia. *Frontiers in Plant Science*, 13, 925548. <https://doi.org/10.3389/fpls.2022.925548>.
- Hou, H., Wang, R., & Murayama, Y. (2019). Scenario-based modelling for urban sustainability focusing on changes in cropland under rapid urbanization: A case study of Hangzhou from 1990 to 2035. *Science of The Total Environment*, 661, 422-431. <https://doi.org/10.1016/j.scitotenv.2019.01.208>.
- Lu, T., Gao, M., & Wang, L. (2023). Crop classification in high-resolution remote sensing images based on multi-scale feature fusion semantic segmentation model. *Frontiers in Plant Science*, 14, 1196634. <https://doi.org/10.3389/fpls.2023.1196634>.
- Mahmoodi, A., & Parhizkari, A. (2016). Economic Analysis of the Climate Change Impacts on Products Yield, Cropping Pattern and Farmer's Gross Margin (Case Study: Qazvin Plain). *Economic Growth and Development Research*, 5(17(3)), 40-25. [In Persian]
- Meng, X., Zhu, Y., Yin, M., & Liu, D. (2021). The impact of land use and rainfall patterns on the soil loss of the hillslope. *Scientific Reports*, 11(1), 16341. <https://doi.org/10.1038/s41598-021-95819-5>.
- moosazadeh, n., & Tavakkoli, J. (2023). The investigations of the impact of the outbreak of the Covid-19 pandemic on the supply chain of agricultural products in the villages of Kermanshah province. *Economic Geography Research*, 4(12), 25-47. [In Persian]
- Moradhaseli, S., Ataei, P., Karimi, H., & Hajialiani, S. (2022). Typology of Iranian farmers' vulnerability to the COVID-19 outbreak. *Frontiers in Public Health*, 10, 1018406. <https://doi.org/10.3389/fpubh.2022.1018406>.

Neetu, & Ray, S. (2019). Exploring machine learning classification algorithms for crop classification using Sentinel 2 data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 573-578. <https://doi.org/10.5194/isprs-archives-XLII-3-W6-573-2019>.

Novelli, A., Aguilar, M. A., Aguilar, F. J., Nemmaoui, A., & Tarantino, E. (2017). AssesSeg—A Command Line Tool to Quantify Image Segmentation Quality: A Test Carried Out in Southern Spain from Satellite Imagery. *Remote Sensing*, 9(1). <https://doi.org/10.3390/rs9010040>.

Portmann, F. T., Siebert, S., & Döll, P. (2010). MIRCA2000—Global monthly irrigated and rainfed crop areas around the year 2000: A new high-resolution data set for agricultural and hydrological modeling. *Global biogeochemical cycles*, 24(1). <https://doi.org/10.1029/2008GB003435>.

Rad, A. K., Shamshiri, R. R., Azarm, H., Balasundram, S. K., & Sultan, M. (2021). Effects of the COVID-19 Pandemic on Food Security and Agriculture in Iran: A Survey. *Sustainability*, 13(18), 10103. <https://doi.org/10.3390/su131810103>.

Rahimzadegan, M., & Pourgholam, M. (2017). Identification of the area under cultivation of Saffron using Landsat-8 temporal satellite images (Case study: Torbat Heydarieh). *Journal of Applied RS and GIS techniques in natural resources science*, 7(4), 97-115. [In Persian]

Ramezani Etedali, H., & Ahmadi, M. (2024). Investigating the relationship between drought indices and maize yield using random forest method (case study: Qazvin plain irrigation network). *Nivar*, 48(126), 127-137. <https://doi.org/10.30467/nivar.2024.467444.1299>.

Rezaei, M., Amiri, E., & Kamali, M. (2024). Estimating the area under rice cultivation in Guilan province using remote sensing technology and GEE. *Iranian Journal of Soil Research*, 38(2), 113-124. <https://doi.org/10.22092/ijsr.2024.366254.750>.

Sen, R., Goswami, S., & Chakraborty, B. (2019). Jeffries-Matusita distance as a tool for feature selection. *International Conference on Data Science and Engineering (ICDSE)*, 15-20. <https://doi.org/10.1109/ICDSE47409.2019.8971800>.

Shahrin, F., Zahin, L., Rahman, R., Hossain, A. J., Kaf, A. H., & Azad, A. K. M. A. M. (2020). Agricultural Analysis and Crop Yield Prediction of Habiganj using Multispectral Bands of Satellite Imagery with Machine Learning. 11th International Conference on Electrical and Computer Engineering (ICECE), 21-24, <https://doi.org/10.1109/ICECE51571.2020.9393066>.

Shayanmehr, S., Porhajašová, J. I., Babošová, M., Sabouhi Sabouni, M., Mohammadi, H., Rastegari Henneberry, S., & Shahnoushi Foroushani, N. (2022). The Impacts of Climate Change on Water Resources and Crop Production in an Arid Region. *Agriculture*, 12(7). <https://doi.org/10.3390/agriculture12071056>.

Skendžić, S., Zovko, M., Živković, I. P., Lešić, V., & Lemić, D. (2021). The impact of climate change on agricultural insect pests. *Insects*, 12(5), 440. <https://doi.org/10.3390/insects12050440>.

Snevajs, H., Charvat, K., Onckelet, V., Kvapil, J., Zadrazil, F., Kubickova, H., ... Batrlova, I. (2022). Crop Detection Using Time Series of Sentinel-2 and Sentinel-1 and Existing Land Parcel Information Systems. *Remote Sensing*, 14(5), 1095. <https://doi.org/10.3390/insects12050440>.

Soleymani Nejad, S., Dourandish, A., Sabouhi, m., & Banayan Aval, M. (2019). The Effects of Climate Change on Cropping Pattern (Case Study: Mashhad Plain). *Iranian Journal of Agricultural Economics and Development Research*, 50(2), 249-263. [In Persian]. <https://doi.org/10.22059/ijaedr.2019.237998.668461>.

Song, X.-P., Potapov, P. V., Krylov, A., King, L., Di Bella, C. M., Hudson, A., Khan, A., Adusei, B., Steman, S.V., Hansen, M. C. (2017). National-scale soybean mapping and area estimation in the United States using medium resolution satellite imagery and field survey. *Remote Sensing of Environment*, 190, 383-395. <https://doi.org/10.1016/j.rse.2017.01.008>.

Tahernia, M., & hasanvand, a. (2020). Economic consequences of Covid-19 disease on the Iranian economy; With an emphasis on employment [Research]. *Quarterly Journal of Nersing Management*, 9(3), 43-58. [In Persian]

Tariq, A., Yan, J., Gagnon, A. S., Riaz Khan, M., & Mumtaz, F. (2023). Mapping of cropland, cropping patterns and crop types by combining optical remote sensing images with decision tree classifier and random forest. *Geo-Spatial Information Science*, 26(3), 302-320. <https://doi.org/10.1080/10095020.2022.2100287>.

Teluguntla, P., Thenkabail, P. S., Oliphant, A., Xiong, J., Gumma, M. K., Congalton, R. G., Yadav, K., Huete, A. (2018). A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144, 325-340. <https://doi.org/10.1016/j.isprsjprs.2018.07.017>.

Torabi, O., Karimi, N., shesh angosht, s., Rashtbari, M., & Sarbazvatan, A. h. (2023). Investigating the effect of radar images in classifying land use classes in machine learning based algorithms. *Human Ecology*, 2(2), 141-154. <https://doi.org/10.22034/el.2023.392546.1011>. [In Persian]

Waldner, F., Fritz, S., Di Gregorio, A., Plotnikov, D., Bartalev, S., Kussul, N., Gong, P., Thenkabail, P., Gerard, H., Klein, I., Low, F., Miettinen, J., Dadhwal, V. K., Lamarche, C., Bontemps, S., Defourny, P. (2016). A Unified Cropland Layer at 250 m for Global Agriculture Monitoring. *Data*, 1(1), 3. <https://doi.org/10.3390/data1010003>.

Wang, Y., Qi, Q., & Liu, Y. (2018). Unsupervised Segmentation Evaluation Using Area-Weighted Variance and Jeffries-Matusita Distance for Remote Sensing Images. *Remote Sensing*, 10(8), 1193. <https://doi.org/10.3390/rs10081193>.

Youssef, A. M., Pourghasemi, H. R., Pourtaghi, Z. S., & Al-Katheeri, M. M. (2016). Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Region, Saudi Arabia. *Landslides*, 13(5), 839-856. <https://doi.org/10.1007/s10346-015-0614-1>.

مجله علمی پژوهشی
زمین‌شناسی و مهندسی
زمین‌شناسی