



Evaluation of Efficiency of Classification Methods and Spectral Indices in Cropped Area Estimation of Shush County

M. Abiyat¹, M. Abiyat^{2*}, M. Abiyat³

Received: 08-06-2022

Revised: 03-09-2022

Accepted: 17-09-2022

Available Online: 21-11-2022

How to cite this article:

Abiyat, M., Abiyat, M., & Abiyat, M. (2022). Evaluation of Efficiency between Classification Methods and Spectral Indices in Cropped Area Estimation of Shush County. *Journal of Water and Soil* 36(4): 493-509. (In Persian with English abstract)

DOI: [10.22067/JSW.2022.76746.1167](https://doi.org/10.22067/JSW.2022.76746.1167)

Introduction

Agriculture is the essential sector for promoting food security. Crop area estimation (CAE) can meet the requirements of the crop monitoring plan. The organizing basis of the cultivation pattern is recognizing the types of crops and examining the condition of their crop area. Shush county in Khuzestan province has 300,000 hectares of the crop area. It is one of the agricultural hubs of Iran because it has a record annual production of more than two million tons of strategic crops such as wheat, sugar beet, and corn. CAE affects the amount of net production and shortage or surplus of produce for market steadiness. Traditional approaches for CAE are time-consuming and costly and are not widely enforceable. Remote sensing (RS) data provide good information for decision-makers by determining the crop type and the crop area. RS data has made it possible to avoid continuous reference to agricultural lands with less time and cost than another usual method and accurate CAE. Also, the use of multi-time images during the growing season of agricultural products allows the use of spectral curves when related to the crop calendar of each crop. This spectral curve is almost separate for each product and increases the ability to distinguish between products. Therefore, multi-temporal images support segregation based on multispectral images of products. The current study follows a speedy method with appropriate accuracy established on satellite image classification algorithms and spectral indices to identify and separate crops with RS data in Shush County.

Materials and Methods

Landsat-8 data with path/row coordinates 166/38 extracted from the USGS website were used to identify and separate the cultivated lands of the region. The reason for choosing Landsat images is the relatively suitable temporal and spatial resolution, availability, and the appropriate time distribution with the product growth period. The Landsat 8 carries 2-sensors, OLI (Operational Land Imager) and TIRS (Thermal Infrared Sensor). The OLI sensor with a spatial resolution of 30 meters has 8-bands in the visible spectrum, near-infrared (NIR), short-wavelength infrared (SWIR), and a panchromatic band with a spatial resolution of 15 meters. The TIRS sensor can record thermal infrared radiation with a spatial resolution of 100 meters with the help of 2-bands in atmospheric windows of 10.6 to 11.2 micrometers for band 10 and 11.5 to 12.5 micrometers for band 11. This research used bands 1-7 of the Landsat-8 OLI sensor with a spatial resolution of 30 meters after the initial corrections of satellite images. The spectral similarity between the region's dominant crops has made it impossible to select a single image to differentiate and extract the cultivation pattern. Wheat and barley have a high spectral similarity. The peak of the greenness of these products is in the first four months of the year, which has high NDVI values at this time. Therefore, choosing a good time to separate the crops was feasible by referring to the Khuzestan Organization Agriculture-Jihad (KOAJ) and receiving the regional crops calendar in

1- Ph.D. Student in Soil Resource Management, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran
2 and 3- Ph.D. Students in Geography and Rural Planning, Faculty of Geographical Sciences and Planning, Isfahan University, Isfahan, Iran

(*- Corresponding Author Email: morteza.abiyat@yahoo.com)

2018-19. Then, the low-level cloud cover images on April 24, June 27, and August 30, 2019, were selected for classification based on the crop calendar. Planting, harvesting, maximum greenness, and ripening information of the dominant crops in the area were pivotal in obtaining image dates. In dates selected related to the images were considered planting, harvesting, maximum greenery, and ripening information of the region's dominant crops.

Results and Discussion

According to the results, from total crop area in Shush county (163313.7 hectares) is allocated about 103513.2 hectares (63.4% of the county's crop area) to the ANN, about 102875.1 hectares (63.0% of the county's crop area) to the SVM, and about 102,277.3 hectares (62.6% of the county's crop area) to the NDVI, which in comparison with the KOAJ statistics, has an error of 0.11, 6.2 and 1.8%, respectively.

This difference is the similarity of the reflective spectrum in some places, which affects the separability and recognition of phenomena and increases the error in estimating the area under cultivation of different crops. The highest and lowest errors in estimating the area under cultivation in the artificial neural network method were in barley and rice crops, respectively, in the support vector machine method were in wheat and rice crops, respectively, and in NDVI index were in wheat and barley crops, respectively. The difference between the cropped area obtained from classification methods and NDVI index with cropped area statistics of Agricultural-Jihad Organization may be due to the following: First, the cultivation history of different has caused problems such as reflections of diverse agricultural lands in one image. Second, the agricultural lands in this area are small. Most of them are under one hectare. Also, the crops in this area are diverse. Third, the smallest region that the image used in the present study can distinguish is about 900 square meters, which is a large number for the agricultural lands of the study area and causes errors.

Conclusion

The study results showed that the support vector machine method had the lowest error in CAE than the artificial neural network method, which indicates the higher accuracy of the support vector method in identifying and separating crops in the region. Comparing the area obtained from the NDVI index with the statistics of the Agricultural-Jihad Organization of Khuzestan province and evaluating the accuracy of this method indicated the higher efficiency of spectral indices in CAE for the region compared to classification methods. The NDVI index minimizes the error values of the results due to having a threshold and better identification of vegetation density. Therefore, based on the accuracy assessment results and comparing the cropped area with the KOAJ statistics, the utilization of the NDVI index provides the best CAE in the region.

Keywords: Agriculture, Artificial neural network, NDVI, Shush, Support vector machine

مقاله پژوهشی

جلد ۳۶، شماره ۴، مهر-آبان ۱۴۰۱، ص. ۵۰۹-۴۹۳

بررسی کارایی روش‌های طبقه‌بندی و شاخص‌های طیفی در برآورد سطح زیرکشت محصولات زراعی شهرستان شوش

محمد عیبات^۱ - مرتضی عیبات^{۲*} - مصطفی عیبات^۳

تاریخ دریافت: ۱۴۰۱/۰۳/۱۸

تاریخ پذیرش: ۱۴۰۱/۰۶/۲۶

چکیده

برآورد سطح زیرکشت محصول، گامی اساسی در تعیین میزان تولیدات زراعی و لازمه تصمیم‌گیری در انجام مبادلات اقتصادی است. هدف این پژوهش، ارزیابی کارایی روش‌های طبقه‌بندی و شاخص‌های طیفی در برآورد سطح زیرکشت محصولات زراعی شهرستان شوش در طول دوره رشد است. ابتدا تصاویر OLI ماهواره لندست ۸ با توجه به تقویم زراعی سال ۹۸-۱۳۹۷ و دوره رویشی محصولات غالب منطقه، انتخاب شدند. برای شناسایی و تفکیک محصولات زراعی در رویکرد اول، از روش‌های طبقه‌بندی شبکه عصبی مصنوعی و ماشین بردار پشتیبان و در رویکرد دوم، از شاخص NDVI استفاده شد. برای مقایسه نتایج، از آمار سطح زیرکشت سازمان جهاد کشاورزی در سال ۱۳۹۸ استفاده شد. براساس نتایج بدست آمده، سطح زیرکشت گندم، جو، برنج و ذرت در روش شبکه عصبی مصنوعی، در مقایسه با آمار سازمان جهاد کشاورزی به ترتیب خطای ۱/۷، ۱۲/۱، ۶/۱ و ۶/۷ درصد و در روش ماشین بردار پشتیبان به ترتیب خطای ۸/۹، ۶/۶، ۴/۲ و ۵/۱ درصد داشته است. اما شاخص NDVI بهترین روش برآورد سطح زیرکشت منطقه در مقایسه با آمار سازمان جهاد کشاورزی به ترتیب دارای خطای ۴/۲، ۱/۲، ۲/۷ و ۱/۵ درصد بوده که نشان‌دهنده قابلیت بالا و دقت شاخص‌های طیفی در برآورد سطح زیرکشت محصولات زراعی منطقه با توجه به دوره رشد آن‌ها است. لذا پیشنهاد شد تا برای تعیین سطح زیرکشت محصولات شهرستان شوش از پیاده‌سازی شاخص‌های طیفی استفاده شود.

واژه‌های کلیدی: کشاورزی، شبکه عصبی مصنوعی، شوش، ماشین بردار پشتیبان، NDVI

مقدمه

مشکلی مهم، اما پیچیده بوده که برای افزایش سطح پایداری و استفاده کارآمد از منابع طبیعی الزامی است (Paudel et al., 2021). شالوده اصلی تنظیم الگوی کشت، شناخت انواع محصولات و بررسی وضعیت سطح زیرکشت آن‌ها می‌باشد (Chen et al., 2018). برآورد سطح زیرکشت محصولات زراعی بر میزان تولید خالص و کمبود یا مازاد تولیدات جهت ثبات بازار اثرگذار می‌باشد (Deng and Gibson, 2019). برآوردهای سنتی سطح زیر کشت محصولات بسیار زمان‌بر و پرهزینه بوده و در مقیاس وسیع قابل اجرا نیست؛ اما داده‌های سنجنش از دور با تعیین نوع و سطح زیرکشت محصولات، اطلاعات مناسبی را نزد تصمیم‌گیران بخش‌های مرتبط قرار خواهد داد (Liaquat et al., 2017). در روش برآورد از طریق فهرست‌برداری، هر چند سطح زیرکشت محصولات

کشاورزی، منبع اساسی امنیت غذایی در یک جامعه به حساب می‌آید (Viana et al., 2022; Martínez, et al., 2021). از طریق برآورد سطح زیرکشت محصولات زراعی می‌توان به نیاز برنامه پایش محصول پاسخ داد (Wang et al., 2022). تخمین عملکرد محصول

۱- دانشجوی دکتری مدیریت منابع خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران

۲ و ۳- دانشجویان دکتری جغرافیا و برنامه‌ریزی روستایی، دانشکده علوم جغرافیایی و برنامه‌ریزی، دانشگاه اصفهان، اصفهان، ایران

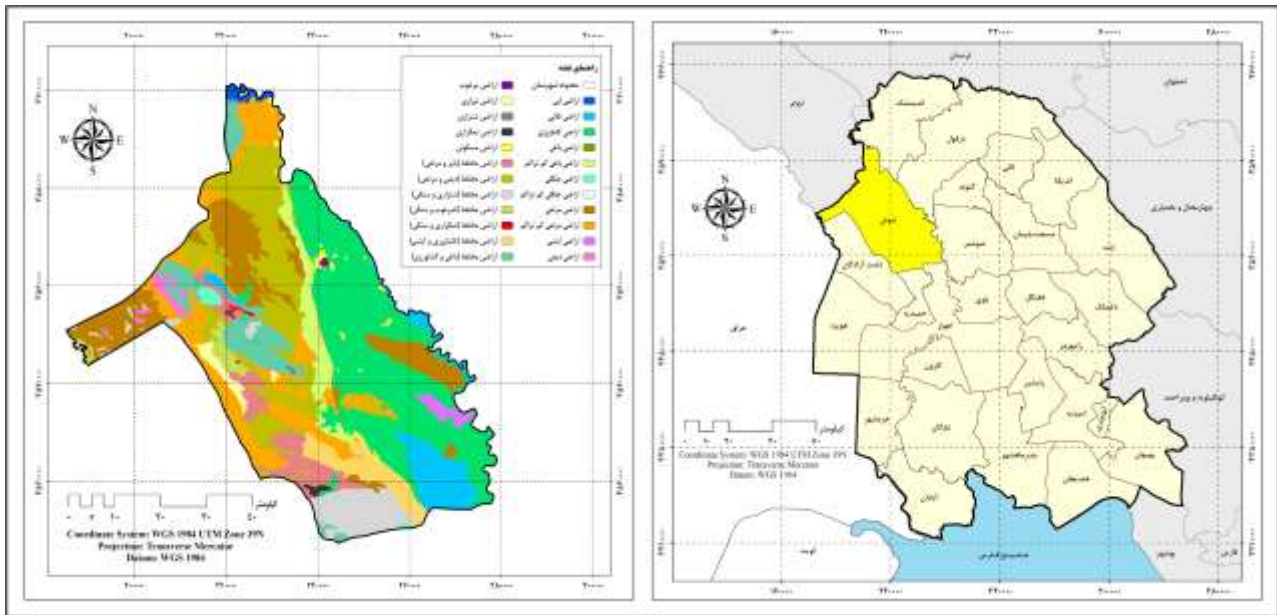
(*- نویسنده مسئول: Email: morteza.abiyat@yahoo.com

DOI: 10.22067/JSW.2022.76746.1167

به نقشه‌برداری نوع محصولات و برآورد سطح زیرکشت در قطعه‌های کوچک برای منطقه بنگال غربی با بهره‌گیری از تصاویر ماهواره‌ای و الگوریتم‌های یادگیری ماشین پرداختند. نتایج مطالعه نشان می‌دهد که با استفاده از تصاویر چندطیفی Sentinel-2 و الگوریتم‌های K نزدیکترین همسایه (KNN) و جنگل تصادفی (RF)، سطح زیرکشت محصولات زراعی تابستانی را نیز می‌توان به طور دقیق برآورد نمود. گونزالس و همکاران (Gonzalez et al., 2022)، در پژوهشی با عنوان تکنیک‌های یادگیری ماشین و سنجش از دور برای تخمین شاخص‌های خاک از طریق مرور مطالعات اخیر در این زمینه به این نتیجه دست یافتند که این ابزار در تخمین کیفیت خاک، تنظیم شیوه‌های مدیریت کشاورزی و بهبود عملکرد محصول اثرگذار هستند. وانکلومپنبرگ و همکاران (Van-Klompenburg et al., 2020)، در یک مطالعه به بررسی سیستماتیک ادبیات موضوع پیش‌بینی عملکرد محصول با استفاده از یادگیری ماشین پرداختند و به این نتیجه رسیدند که شبکه عصبی مصنوعی (ANN)، پرکاربردترین الگوریتم استفاده شده در مطالعات مربوط به تخمین عملکرد محصولات زراعی است. موسوی و همکاران (Moussavi et al., 2020)، به منظور برآورد سطح زیرکشت گندم دیم در منطقه خدابنده استان زنجان از تصاویر ماهواره‌ای Sentinel-2 و دو روش ماشین بردار پشتیبان و حداکثر احتمال استفاده کردند. نتایج نشان داد، روش ماشین بردار پشتیبان با دقت کلی و ضریب کاپای مناسب، نسبت به روش حداکثر احتمال از دقت بالاتری برخوردار است و جهت تعیین سطح زیرکشت محصول، روش ماشین بردار پشتیبان مناسب است. مقایسه نتایج سطح زیرکشت با آمار جهاد کشاورزی انحراف ۱۸ درصد را نشان داد. میزان محصول گندم نیز با استفاده از سطح زیرکشت بدست آمده از روش طبقه‌بندی، با آمار سازمان تعاونی روستایی مقایسه گردید که میزان انحراف ۱۷ درصدی را نمایان کرد.

پژوهش حاضر با انگیزه یافتن روشی سریع همراه با دقتی مناسب برای تعیین و تفکیک اراضی زیرکشت با استفاده از داده‌های سنجش از دور به انجام رسیده و در نظر دارد با تمرکز بر مناطق جنوب غربی ایران، بهترین روش را جهت تهیه نقشه اراضی زیرکشت محصولات معرفی کند. این مطالعه، برآورد اراضی زیرکشت محصولات زراعی بر پایه الگوریتم‌های طبقه‌بندی تصاویر ماهواره‌ای و شاخص‌های طیفی در شهرستان شوش با توجه به دوره رویشی آن‌ها پیگیری می‌نماید.

تخمین زده می‌شود، اما پراکندگی آن را نشان نمی‌دهد، ضمن اینکه هزینه بالای نیروی انسانی عامل مهم محدودکننده این روش است (Ziaiean et al., 2010). داده‌های سنجش از دور، امکان عدم مراجعه مستمر به اراضی کشاورزی با صرف زمان و هزینه کمتر نسبت به سایر روش‌های معمول و برآورد دقیق سطح زیرکشت محصولات را میسر می‌سازد (Dong et al., 2017). علاوه بر آن، استفاده از تصاویر چندزمانه در دوره رشد محصولات، امکان استفاده از منحنی طیفی زمانی، که با تقویم زراعی هر محصول ارتباط دارد، را می‌دهد (Yi et al., 2020). این منحنی طیفی برای محصولات تقریباً مجزا بوده و قابلیت تمایزبخشی میان انواع آن‌ها را بالا می‌برد (Zhang et al., 2019). بنابراین، تصاویر چندزمانه امکان تشخیص و تفکیک محصولات زراعی بر پایه تصاویر چندطیفی را فراهم خواهد آورد (Hedayati et al., 2022; Solano-Correa et al., 2018). در میان شاخص‌های پوشش گیاهی استخراج یافته از داده‌های ماهواره‌ای، شاخص نرمال شده تفاوت پوشش گیاهی (NDVI) یکی از پرکاربردترین آن‌ها در مطالعات مربوط به بخش کشاورزی و پایش محصول است (Phan et al., 2020; Ouzemou et al., 2018). روزنیک و همکاران (Roznik et al., 2022)، در یک پژوهش با عنوان بهبود تخمین عملکرد محصول برای ۴۸ ایالت آمریکا بر مبنای تصاویر ماهواره‌ای NDVI و ماسک‌های زمین زراعی با وضوح بالا به این نتیجه رسیدند که تصاویر ماهواره‌ای، منبع بزرگ داده و کاربردی در کشاورزی بوده و شاخص NDVI در برآورد دقیق عملکرد و تمایز محصولات اثرگذار است. ریاحی و همکاران (Riahi et al., 2019)، نقشه الگوی کشت محصولات زراعی را برای ناحیه لنجان اصفهان با استفاده از تصاویر Landsat-8 و شاخص NDVI با توجه به تقویم زراعی آن‌ها تهیه کردند. نتایج نشان داد که سطح زیرکشت محصولات در شاخص NDVI نسبت به آمار جهاد کشاورزی خطایی بین ۳ تا ۶ درصد بوده که بیان‌کننده کارایی مناسب شاخص گیاهی در برآورد سطح زیرکشت محصولات با توجه به فنولوژی آن‌ها است. ژانگ و همکاران (Zhang et al., 2017)، در پژوهشی به طبقه‌بندی محصولات و برآورد سطح زیرکشت برای کره شمالی با استفاده از ویژگی‌های فنولوژی پرداختند و به این نتیجه رسیدند که دقت طبقه‌بندی تصاویر لندست در سال‌های نمونه انتخاب شده، درصد بالایی از مناطق مورد بررسی را تحت پوشش قرار داده است. این امر نشان می‌دهد که ویژگی‌های مشتق شده از پروفایل‌های NDVI قادر به توصیف محصولات اصلی بودند و رویکردهای توسعه یافته در این زمینه برای نقشه‌برداری محصولات زراعی و برآورد سطح زیرکشت در مناطق با داده‌های واقعیت زمینی محدود ممکن است. علاوه بر شاخص NDVI، برآورد سطح زیرکشت محصولات زراعی با انواع روش‌ها و داده‌های سنجش از دور در تحقیقات مختلفی انجام شده است. حدیت و همکاران (Hudait and Patel, 2022)، در پژوهشی



شکل ۱- موقعیت محدوده مورد مطالعه
Figure 1- Location of the study area

داده‌های مورد استفاده

برای شناسایی و تفکیک اراضی زیرکشت شهرستان شوش، از داده‌های Landsat-8 با شماره ردیف و گذر ۳۸ و ۱۶۶ مستخرج از وبسایت USGS استفاده شد. علت انتخاب تصاویر لندست، قدرت تفکیک زمانی و مکانی نسبتاً مناسب، در دسترس و رایگان بودن آن‌ها و پراکنش زمانی مناسب با دوره رشد محصولات کشاورزی است. لندست ۸ دو سنجنده (Operational Land Imager) OLI و نیز (Thermal Infrared Sensor) TIRS را حمل می‌نماید. سنجنده OLI با قدرت تفکیک مکانی ۳۰ متر دارای ۸ باند در محدوده‌های طیفی مرئی، مادون قرمز نزدیک، مادون قرمز طول موج کوتاه و یک باند پانکروماتیک با قدرت تفکیک مکانی ۱۵ متر است. سنجنده TIRS به کمک دو باند در پنجره‌های جوی ۱۰/۶ تا ۱۱/۲ میکرومتر برای باند ۱۰ و ۱۱/۵ تا ۱۲/۵ میکرومتر برای باند ۱۱ قادر به ثبت تابش‌های مادون قرمز حرارتی با قدرت تفکیک مکانی ۱۰۰ متر است (Li et al., 2013). در این مطالعه، از باندهای ۱ تا ۷ سنجنده OLI لندست ۸ با قدرت تفکیک مکانی ۳۰ متر، پس از اعمال تصحیحات اولیه تصاویر استفاده شد. بدلیل تشابه طیفی محصولات عمده منطقه، نمی‌توان از یک تصویر برای تفکیک و استخراج الگوی کشت غالب استفاده نمود (Khodakarami and Soffianian, 2012). لذا برای تعیین بهترین زمان در تفکیک محصولات، ابتدا تقویم زراعی منطقه مربوط به سال ۹۸-۱۳۹۷ از سازمان جهاد کشاورزی استان خوزستان^۱

مواد و روش‌ها

محدوده مورد مطالعه

شهرستان شوش با وسعتی معادل ۳۵۷۷ کیلومترمربع، بین مدار $32^{\circ} 12' 22''$ طول شرقی از نصف‌النهار گرینویچ و $48^{\circ} 15' 12''$ عرض شمالی از خط استوا و نیز در ۱۱۵ کیلومتری شمال غربی اهواز قرار داشته است (شکل ۱)، و نیز جمعیتی بالغ بر ۱۳۶۳۸۹ نفر براساس سرشماری عمومی نفوس و مسکن ۱۳۹۵ را پوشش می‌دهد. این شهرستان از اقلیم گرم و خشک برخوردار بوده که دامنه دما در سال بین ۱۲ تا ۴۸ درجه سانتیگراد، متوسط بارندگی سالانه حدود ۲۵۰ میلی‌متر و رطوبت نسبی در فصول بارانی و گرم به ترتیب بین ۴۵-۵۲ درصد و ۱۹-۳۴ درصد را تجربه می‌نماید. زمین‌های مستعد کشاورزی، رودخانه‌های پرآب دائمی، سفره‌های آب زیرزمینی، سطح نسبتاً گسترده جنگلی در حواشی رودخانه، سواحل و آب‌بند‌های متعدد، مراتع و مراکز کشت و صنعت در شوش موجب شده است تا فعالیت کشاورزی، به مهم‌ترین فعالیت‌های اقتصادی منطقه تبدیل گردد. بر مبنای اطلاعات آمارنامه محصولات زراعی استان خوزستان در سال ۱۳۹۸ نیز از مجموع ۱۶۳۳۱۳/۷ هکتار اراضی زیرکشت در شهرستان شوش، سه محصول گندم با مساحت ۵۸۷۴۱/۷۵ هکتار، شلتوک با مساحت ۲۶۵۰۰ هکتار و ذرت دانه‌ای با مساحت ۱۵۹۳۲ هکتار، بیشترین سطح زیرکشت را به خود اختصاص داده‌اند.

دریافت شد و طبق اطلاعات این تقویم (جدول ۱) تصاویر سه تاریخ ۴ اردیبهشت (۲۴ آوریل)، ۶ تیر (۲۷ ژوئن) و ۸ شهریور (۳۰ اوت) سال ۱۳۹۸ (۲۰۱۹ میلادی) با پوشش کم ابری برای طبقه‌بندی انتخاب شد. تاریخ‌های آخذ تصاویر طبق اطلاعات کاشت، برداشت، حداکثر سبزی‌نگی و رسیدگی کامل محصولات غالب منطقه انتخاب شده‌اند. دقت هندسی تصاویر ماهواره‌ای آخذ شده با استفاده از بردارهای جاده و رودخانه کنترل شد و با توجه به دقت بالای تصاویر لندست ۸، تصحیح هندسی انجام نشد. به منظور تصحیح اتمسفری تصاویر از الگوریتم FLAASH در نرم‌افزار ENVI 5.2 استفاده شد. الگوریتم تصحیح اتمسفری FLAASH با فرض حضور پیکسل‌های تیره است که می‌تواند به عنوان پیکسل مرجع با بازتاب سطحی مشخص لحاظ شود، انجام می‌شود (Garain et al., 2021; Yopez et al., 2018).

پارامترهای موجود در مدل تصحیح اتمسفری FLAASH با توجه به شرایط منطقه و ماه‌های آخذ تصاویر انتخاب شد. پارامتر قابلیت دید در تمام تصاویر ۴۰ کیلومتر در نظر گرفته شد. جهت دستیابی به بهترین ترکیب باندی برای طبقه‌بندی نیز از ضریب شاخص مطلوبیت (OIF) استفاده شد. انتخاب ترکیب باندی مناسب به روش‌های مختلفی انجام می‌پذیرد. یک روش، با استفاده از مقایسه چشمی تصاویر بدست آمده از ترکیب رنگی مختلف بوده که بسیار مشکل و وقت‌گیر است. روش دیگر، استفاده از کمیت‌های آماری فاکتور شاخص بهینه (OIF) است که به منظور تعیین بهترین ترکیب رنگی کاذب سه باندی از داده‌های ماهواره‌ای بکار می‌آید. این شاخص بر پایه کمیت‌های آماری، انحراف معیار (SD) و ضریب همبستگی (Cc) بین باندهای مختلف برای به حداقل رساندن داده‌های کم ارزش و حداکثر استفاده از اطلاعات مفید در انتخاب باندهای مناسب برای ساخت تصاویر رنگی کاذب (FCC) می‌باشد (Alavipanah, 2015). در این روش، با ترکیب داده‌های ۳ باند از ۷ باند انعکاسی و چندمنظوره سنجنده OLI لندست ۸ یک تصویر رنگی کاذب در اختیار کاربر قرار می‌گیرد که به تصویر رنگی

$$N_{RGB/LC8_OLI} = \left(\frac{7!}{(7-3)! \times 3!} \right) \quad (1)$$

$$OIF = \frac{\sum_{i=1}^3 SD}{\sum_{i=1}^3 Cc} \quad (2)$$

در رابطه ۲، OIF ضریب شاخص بهینه است، SD انحراف باند k استاندارد و Cc مقدار ماتریس همبستگی می‌باشد. پس از انتخاب تصاویر و انجام تصحیحات اولیه، برآورد سطح زیرکشت محصولات زراعی با دو رویکرد صورت گرفت؛ طبقه‌بندی تصاویر ماهواره‌ای و استفاده از شاخص‌های طیفی. برای ارزیابی نتایج دو رویکرد، از آمار سطح زیرکشت جهاد کشاورزی خوزستان در سال ۱۳۹۸ استفاده شد.

طبقه‌بندی تصاویر ماهواره‌ای

به منظور طبقه‌بندی تصاویر ماهواره‌ای، نیاز به نمونه‌های تعلیمی است. لذا، نخست اقدام به برداشت نمونه‌های تعلیمی به عنوان الگوی مشخصات طیفی طبقات از منطقه شد. نمونه‌های تعلیمی از منطقه با استفاده از بازدید میدانی و GPS برداشت شده و برای تعلیم روش‌های طبقه‌بندی استفاده شد.

جدول ۱- اطلاعات دوره رشد (تقویم زراعی) محصولات عمده منطقه در سال زراعی ۱۳۹۷-۹۸

Table 1- Growth period data (Crop calendar) of the region's principal crops in the crop year 2019-2020

محصول Crop	وضعیت رویشی در تصاویر ماهواره‌ای منتخب Growth status in selected satellite imagery		
	۴ اردیبهشت (April 24)	۶ تیر (June 27)	۸ شهریور (August 30)
گندم Wheat	اوج سبزی‌نگی Peak greenness	زرد شده یا برداشت شده Yellowed or harvested	هنوز کشت نشده Not yet cultivated
جو Barley	کمی قبل از اوج سبزی‌نگی Before the peak of greenness	برداشت شده Harvested	هنوز کشت نشده Not yet cultivated
برنج Rice	هنوز کشت نشده Not yet cultivated	مراحل اولیه خوشه‌دهی Early stages of product clustering	رسیدگی کامل Full ripening
ذرت Corn	هنوز کشت نشده Not yet cultivated	اوایل دوره رویشی و بازتاب خاک غالب است Early stages of growth and soil reflection	اوج سبزی‌نگی Peak greenness

جدول ۲- نمونه‌های تعلیمی و ارزیابی مورد استفاده در طبقه‌بندی تصاویر ماهواره‌ای

Table 2- Training examples and evaluation used in the classification of satellite images

کلاس Class	۵۰٪ نمونه‌های تعلیمی 50% Training samples (I)	کل نمونه‌های تعلیمی Total training samples (II)	نمونه‌های ارزیابی Samples evaluation	نمونه‌های برداشت‌شده Samples taken
گندم Wheat	72	144	48	192
جو Barley	18	36	12	48
برنج Rice	39	78	26	104
ذرت Corn	36	72	24	96
سایر اراضی Other lands	45	90	30	120

است. زیرا محاسبات پیکسل‌منا می‌باشند (Derksen et al., 2020). شبکه‌های عصبی مصنوعی با ساختار نقشه‌سازی غیرخطی و برای مدل‌سازی سیستم‌های متصل به یکدیگر مانند مغز متشکل از نرون‌ها توسعه داده شده‌اند. شبکه‌های عصبی پرسپترون چندلایه (MLP)، از پرکاربردترین شبکه‌های عصبی هستند (Martínez et al., 2021). در این پژوهش، برای طبقه‌بندی شبکه عصبی مصنوعی، از پرسپترون چندلایه استفاده شد. برای اجرای شبکه عصبی پرسپترون چندلایه، از نرم‌افزار MATLAB استفاده گردید. اجرای شبکه نیازمند ورودی (Input)، خروجی (Output) و انتخاب تعداد لایه‌های میانی یا پنهان خواهد بود (شکل ۲).

ورودی شبکه، باندهای تصاویر مورد استفاده در طبقه است. تعداد هفت نرون ورودی شامل ۷ باند طیفی (باندهای ۱ تا ۷ ماهواره لندست ۸) مدنظر می‌باشد. به منظور تسهیل در همگرایی شبکه عصبی مصنوعی، باید مقادیر نرون‌های ورودی نرمال گردد. زیرا، وارد کردن داده‌ها به طور خام موجب کاهش سرعت و دقت شبکه می‌شود. جهت نرمال‌سازی داده‌ها در این پژوهش از رابطه ۳ استفاده شد.

$$X_y = \frac{(X_i - X_{\min})}{(X_{\max} - X_{\min})} \quad (3)$$


X_y ارزش (مقدار) استاندارد شده لایه مورد نظر، X_i ارزش لایه ورودی، X_{\min} کمترین ارزش لایه و X_{\max} بیشترین ارزش لایه مورد نظر است. خروجی شبکه شامل دو پارامتر کدگذاری و استخراج کلاس می‌باشد. به منظور کدگذاری کلاس‌های خروجی از یک گره خروجی برای هر کلاس استفاده شد. نرون‌های خروجی با تعداد پنج عدد به منزله تعداد کلاس‌های طبقه‌بندی در نظر گرفته می‌شوند. بر مبنای یافته‌های قبلی، شبکه‌های دارای یک لایه پنهان جهت انجام عمل طبقه‌بندی مناسب‌تر خواهند بود و تعداد نرون‌های پنهان با آزمون و خطا تعیین و غالباً سه برابر تعداد نرون‌های ورودی انتخاب می‌شوند (Parmar et al., 2021; Mirzaei et al., 2020).

با توجه به وسعت (مساحت) هر یک از طبقات محصولات زراعی، نمونه‌های تعلیمی به گونه‌ای انتخاب شدند که از تعداد و پراکنش مناسب در هر طبقه برخوردار باشند. در این پژوهش، ابتدا جهت ارزیابی اثر تعداد نمونه‌های تعلیمی بر نتایج طبقه‌بندی، از ۵۰ درصد نمونه‌های تعلیمی در هر یک از کلاس‌ها (I) استفاده شد. سپس، نتایج طبقه‌بندی با هر سری از داده‌های تعلیمی مورد بررسی و مقایسه قرار گرفت. در مرحله بعد، با استفاده از یک سوم داده‌های باقیمانده از برداشت زمینی (نمونه‌های ارزیابی) و ماتریس خطا، اعتبار سنجی طبقه‌بندی انجام گردید. تعداد نمونه‌های تعلیمی و ارزیابی در جدول ۲ آورده شده است.

برای ارزیابی کمی تفکیک‌پذیری طبقات در نمونه‌های تعلیمی، از شاخص واگرایی (Divergence index) استفاده شده است. نسبت تفکیک‌پذیری در این شاخص از ۰ الی ۲ بیان شده که صفر معادل عدم تفکیک‌پذیری کلاس‌ها و ۲ مبین تفکیک کامل کلاس‌ها است. برای اجرای طبقه‌بندی دقیق، باید میزان تفکیک‌پذیری از ۱/۸ بالاتر باشد (Ebodé et al., 2022; Poursanidis et al., 2018). در پایان به ارزیابی صحت نقشه‌های طبقه‌بندی تهیه شده با مکان‌های تعلیمی پرداخته شد. در پژوهش حاضر، طبقه‌بندی تصاویر با استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان انجام شد.

شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی، ابزار محاسباتی توانمند و کارآمدی است که در ساماندهی و ایجاد رابطه بین اطلاعات گوناگون نیز قابلیت مناسبی دارند (Cabaneros et al., 2019). شبکه عصبی مصنوعی، مستقل از توزیع آماری داده‌ها است و به متغیرهای آماری ویژه‌ای نیاز ندارد. بنابراین، این ویژگی امکان ترکیب داده‌های سنجش از دور و سیستم اطلاعات جغرافیایی را تسهیل می‌کند. علاوه بر این، تجزیه و تحلیل دقت، حتی با گروه داده آموزشی اندک از منطقه امکان‌پذیر



شکل ۲- ساختار شبکه عصبی پرسپترون چندلایه

Figure 2- MLP neural network Structure

برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم از روش حاشیه بهینه استفاده می‌شود. این حاشیه به گونه‌ای محاسبه شده که نمونه‌های کلاس +1 در یک طرف مرز و تمام نمونه‌های کلاس -1 در طرف دیگر مرز واقع می‌شوند و مرز تصمیم‌گیری به گونه‌ای بوده که فاصله نزدیک‌ترین نمونه‌های آموزشی دو کلاس از یکدیگر نیز در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است، حداکثر گردد (Kim et al., 2020). اگر مرز تصمیم‌گیری به طور موازی به وسیله دو خط از دو طرف گسترش یابد و از نزدیک‌ترین نمونه‌های دو کلاس عبور کند، مرز تصمیم‌گیری بهینه ایجاد می‌شود که حداکثر فاصله میان نمونه‌های دو کلاس را نشان می‌دهد. آن دو خط موازی نیز مرز حاشیه‌ای نامیده می‌شوند. برای آن دسته از پیکسل‌هایی که در بیرون مرزهای حاشیه‌ای قرار گرفته‌اند، رابطه ۵ برقرار می‌گردد (Ramírez et al., 2019).

$$\text{for class 1 pixels } w^T x + w_{N+1} = -1 \quad (5)$$


در این تحقیق برای استفاده از شبکه عصبی مصنوعی از یک لایه پنهان استفاده شد. کارکرد این روش براساس رابطه ۴ است:

$$g = f(Wx^T + \theta) \quad (4)$$

در این رابطه θ حد آستانه، W^T بردار وزنی ضرایب و X بردار ورودی هستند. جهت ایجاد شبکه بهینه در طبقه‌بندی تصاویر مطالعه حاضر، سرعت یادگیری ۰/۲ و گشتاور ۰/۵ برای شبکه لحاظ شد.

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یک روش طبقه‌بندی باینری می‌باشد که با تعیین یک ابر صفحه تفکیک‌کننده بهینه در فضای ویژگی داده‌های آموزشی، کلاس‌های مختلف را با حداکثر جدایی بین آن‌ها، تفکیک می‌کند. ابر صفحه‌ای که حداکثر حاشیه را بین دو کلاس فراهم کرده، ابر صفحه بهینه و داده‌های نزدیک‌تر به ابر صفحه، بردارهای پشتیبان نیز نامیده می‌شوند (Rienow et al., 2021; Jain et al., 2018). با توجه به شکل ۳ به نمونه‌های مرزی بردارهای پشتیبان گفته شده و



شکل ۳- بردارهای پشتیبان به همراه حاشیه بهینه (Ramírez et al., 2019)

Figure 3- Support vectors with optimal margin

اعتبارسنجی روش‌ها از دو پارامتر صحت کلی (Overall accuracy) و ضریب کاپا (Kappa coefficient) استفاده شد. صحت کلی، از ساده‌ترین پارامترهای دقت است که نیاز به عملیات پیچیده برای محاسبه نداشته و برآوردی کلی از دقت طبقه‌بندی یا به تعبیر دقیق‌تر، میانگینی از دقت طبقه‌بندی است. صحت کلی از جمع عناصر قطر اصلی ماتریس خطا تقسیم بر تعداد کل پیکسل‌ها طبق رابطه ۷ محاسبه شد.

$$\sum P_{ij} OA = \frac{1}{N} \quad (7)$$

در این رابطه، OA دقت کلی؛ N تعداد پیکسل‌های آزمایشی و $\sum P_{ij}$ جمع عناصر قطر اصلی ماتریس خطا است. چنانچه صحت کلی در نقشه‌های تولید شده بیش از ۷۰ درصد باشد، صحت نقشه‌های تولیدی قابل اعتماد است. از پارامترهای دقت دیگر که از ماتریس خطا استخراج می‌شود، ضریب کاپا است که دقت طبقه‌بندی را نسبت به یک طبقه‌بندی کاملاً تصادفی محاسبه می‌کند. دامنه ضریب کاپا بین ۰ و ۱ است که عدد ۱ بیانگر توافق قطعی طبقه‌بندی با واقعیت زمینی است. برای محاسبه ضریب کاپا از رابطه ۸ استفاده شد.

$$Kappa = \frac{[(P_0 - P_c)]}{[(1 - P_c)]} \times 100 \quad (8)$$

در این رابطه، P_0 درستی مشاهده شده و P_c توافق مورد انتظار را نشان می‌دهند (Pageot et al., 2020).

نتایج و بحث

ایجاد تصاویر رنگی

انتخاب ترکیب باندی مناسب برای تفسیر و طبقه‌بندی تصاویر منتخب در جدول ۳ آورده شد. طبق OIF ترکیبات سه‌تایی که دارای انحراف معیار بالا، همبستگی کم و در نتیجه OIF بالا بودند، برای ایجاد تصاویر رنگی انتخاب شدند. اعمال این ترکیبات باندی موجب شد تا طبقات اراضی زراعی با حداکثر تفکیک‌پذیری دیده شوند.

نتایج طبقه‌بندی تصاویر ماهواره‌ای

در طبقه‌بندی تصاویر، پس از معرفی نمونه‌های تعلیمی، نقشه پوشش اراضی منطقه تهیه شد و اراضی زیر کشت محصولات غالب شامل گندم، جو، برنج و ذرت با توجه به تغییرات بازتاب محصولات در چرخه رشد گیاهان زراعی، تفکیک شد (اشکال ۴ و ۵). مقادیر نسبت تفکیک‌پذیری این شاخص در جدول ۴ آورده شده است.

انتخاب کرنل، از مهم‌ترین مسائل در اجرا و عملکرد طبقه‌بندی کننده ماشین بردار پشتیبان است. در پژوهش، کرنل شعاعی (RBF) با توجه به استفاده وسیع در طبقه‌بندی اراضی با داده‌های ماهواره‌ای مختلف و نیز عملکرد بهتر نسبت به دیگر کرنل‌های مورد استفاده قرار گرفت (Razaque et al., 2021; Zafari et al., 2019). علاوه بر این، کرنل پارامتر شعاعی فقط به یک از پیش تعریف شده نیاز دارد، که در پیاده‌سازی، آن را در مقایسه با کرنل‌های دیگر کارتر می‌سازد (Wang et al., 2020). به منظور پیاده‌سازی ماشین بردار پشتیبان، از برنامه MATLAB استفاده شد.

شاخص‌های طیفی

شاخص‌های طیفی (گیاهی) محاسباتی ریاضی، حاصل ترکیب باندهای مختلف هستند (Manickam et al., 2021). در بکارگیری شاخص‌های طیفی به منظور برآورد زیر کشت محصولات زراعی، از شاخص NDVI استفاده گردید. شاخص پوشش گیاهی تفاضلی نرمال شده (NDVI)، یک شاخص گیاهی کلیدی و کاربردی معروف است (Huang et al., 2020). این شاخص از رابطه ۶ محاسبه می‌شود:

$$NDVI = \frac{(NIR - RED)}{(NIR + RED)} \quad (6)$$

این شاخص، دارای مقادیر نرمال در دامنه بین -۱ و +۱ است که بررسی و نمایش مقادیر را به راحتی امکان‌پذیر می‌سازد. مقادیر منفی در آن حکایت از عدم حضور پوشش گیاهی و مقادیر مثبت مناطقی با پوشش گیاهی را نشان می‌دهد (Zare et al., 2020). برای تعیین و تفکیک اراضی زیر کشت محصولات زراعی در این رویکرد، به دلیل تمایز محصولات غالب از نظر دوران رشد و اوج سبزیگی از یکدیگر و سایر گیاهان منطقه در تصاویر منتخب، شاخص NDVI در نرم‌افزار TerrSet بر روی این تصاویر محاسبه شده و از طریق بومی‌سازی حد آستانه‌های شاخص مذکور متناسب با انواع محصولات زراعی غالب و نیز تحلیل مؤلفه‌های اصلی (PCA)، اراضی زیر کشت شناسایی و تفکیک شد.

اعتبارسنجی روش‌ها

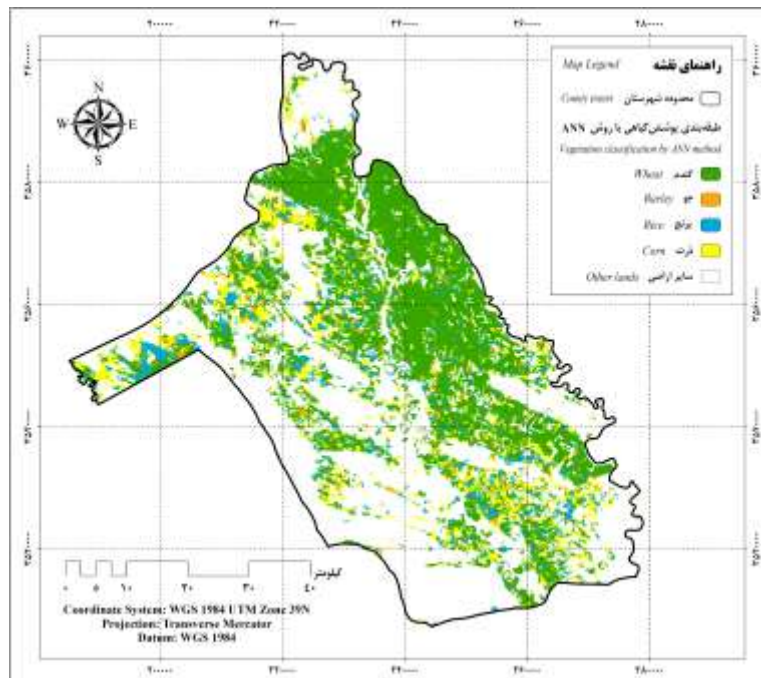
به منظور ارزیابی دقیق طبقه‌بندی‌های انجام شده با روش‌های مختلف، ماتریس خطا محاسبه می‌شود تا دقت کلی طبقه‌بندی‌ها با واقعیت زمینی مشخص شود (Tomala et al., 2020). از مهم‌ترین پارامترهای ارزیابی صحت در بررسی صحت الگوریتم‌ها می‌توان به دقت کلی، ضریب کاپا، صحت کاربر، صحت تولیدشده اشاره کرد (Verma et al., 2020; Lyons et al., 2018). در این راستا، برای

جدول ۳- مقادیر OIF برای ترکیبات رنگی قابل استفاده در تصاویر منتخب
 Table 3- OIF values for color combinations usable in selected images

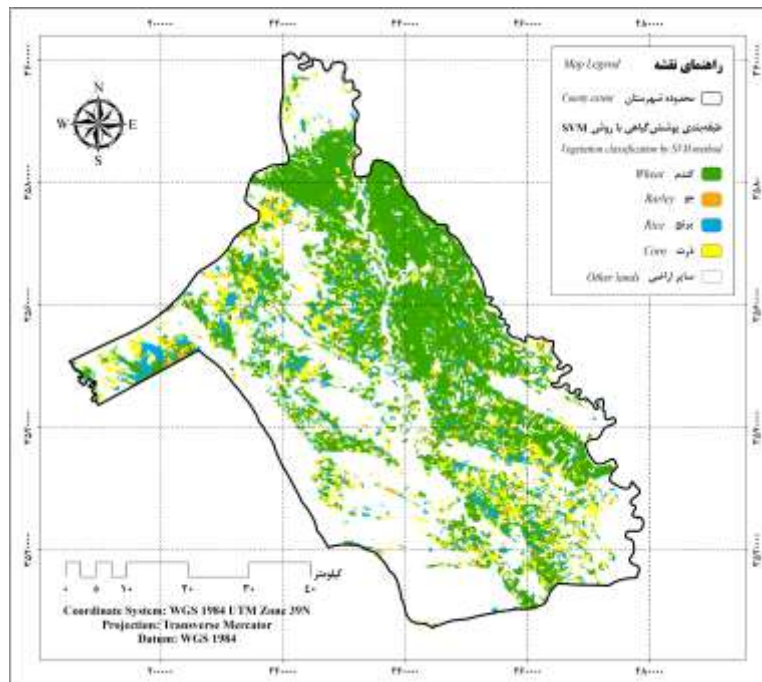
تصاویر ماهواره‌ای منتخب Selected satellite images	RGB	OIF
۴ اردیبهشت April 24	2-5-6	77.18
۶ تیر June 27	2-4-7	75.79
۸ شهریور August 30	1-5-6	78.10

جدول ۴- نتایج محاسبه شاخص واگرایی برای نمونه‌های تعلیمی
 Table 4- Results of divergence index calculation for the training samples

کلاس Class	گندم Wheat	جو Barley	برنج Rice	ذرت Corn	سایر اراضی Other lands
گندم Wheat	0	1.93	1.97	1.99	2
جو Barley	1.93	0	1.98	1.96	1.99
برنج Rice	1.97	1.98	0	1.99	2
ذرت Corn	1.99	1.96	1.99	0	2
سایر اراضی Other lands	2	1.99	2	2	0




شکل ۴- اراضی زیرکشت در روش شبکه عصبی مصنوعی
 Figure 4- Cultivated lands in ANN method



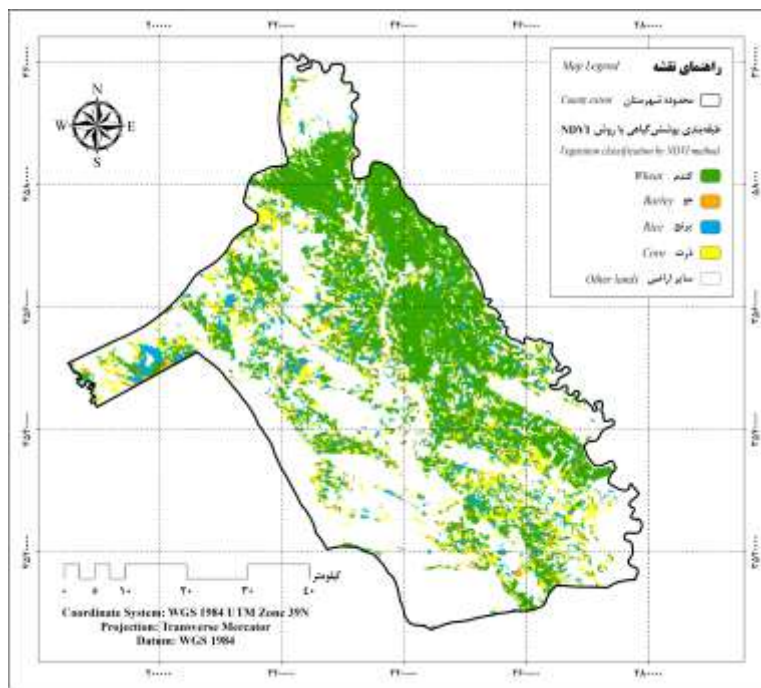
شکل ۵- اراضی زیر کشت در روش ماشین بردار پشتیبان
Figure 5- Cultivated lands in SVM method

براساس شکل ۶، گندم و جو دارای شباهت طیفی بالایی بوده و اوج سبزی‌نگی این محصولات در چهار ماه اول سال است که از مقادیر NDVI بالایی در این زمان برخوردار است. پس از برداشت این دو محصول، مقادیر NDVI آن‌ها در چهار ماه دوم سال کاهش می‌یابد. در چهار ماه اول سال، دو محصول برنج و ذرت هنوز کشت نشده‌اند، بنابراین مقادیر NDVI آن‌ها پایین است. پس از آغاز دوره رویشی این محصولات در چهار ماه دوم سال، نمودار NDVI آن‌ها صعودی شده و به حداکثر رشد خود می‌رسند. همان‌گونه که مشاهده شد رفتار طیفی هر یک از محصولات زراعی در طول دوره رشد متفاوت است و در زمانی خاص نمی‌توان تمامی محصولات را در وضعیت یکسان از دوره رشد، در تصویر مشاهده کرد و زمان اوج سبزی‌نگی هر محصول زراعی با سایر محصولات منطقه متفاوت است. همچنین نتایج تحلیل طیفی نمودار NDVI نشان داد که زمان اوج سبزی‌نگی تشخیص داده شده از روش حد آستانه‌های شاخص NDVI با تقویم زراعی آن‌ها نیز تأیید می‌شود. از نتایج می‌توان دریافت که با نزدیک شدن به پایان فصل رشد میزان ارتباط شاخص استخراج شده از تصاویر با متغیرهای گیاهی کم می‌شود. با توجه به تقویم زراعی منطقه، محصولات گندم و جو دوره شخم و کاشت یکسان، اما دوره اوج سبزی‌نگی متفاوتی دارند و همین امر باعث عدم به وجود آمدن مشکلاتی نظیر بازتاب متفاوت مزارع محصولات مختلف در یک تصویر شده است.

مطابق با نتایج جدول ۴، شاخص واگرایی به منظور ارزیابی تفکیک‌پذیری طبقات محصولات زراعی در نمونه‌های تعلیمی بالاتر از ۱/۸ بوده که نشانگر انتخاب مناسب طبقات پوششی بوده است. بیشترین مقدار این شاخص (مقدار ۲) مربوط به تفکیک‌پذیری کامل سه کلاس گندم، برنج و ذرت از سایر اراضی و کمترین مقدار آن (مقدار ۱/۹۳) برای تفکیک‌پذیری کلاس گندم از جو بوده است. در مرحله بعد، پس از محاسبه شاخص NDVI، پوشش گیاهی منطقه از طریق حد آستانه حداقل و حداکثر طبقه‌بندی گردید. با توجه به آن که طبقه اراضی زراعی از سایر طبقات در شاخص مورد بررسی به راحتی قابل جداسازی نبود، بنابراین از تکنیک متراکم‌سازی داده‌ها که در تفسیر اطلاعات کمک‌کننده است، مانند آنالیز مؤلفه‌های اصلی (PCA) استفاده شد. در این مطالعه مؤلفه اصلی دوم، حداکثر اطلاعات را جهت جداسازی اراضی زراعی دارا بوده است، لذا به منظور جداسازی اطلاعات پوشش اراضی زراعی از آن استفاده شد. سپس طبقه اراضی زراعی با سایر طبقات حاصل از شاخص گیاهی ترکیب و نقشه نهایی تهیه شد. در مرحله بعدی، با کمک اطلاعات تقویم زراعی منطقه، هر یک از محصولات به وسیله تفسیر بصری تصویر و نیز تحلیل طیفی شاخص NDVI، در نمودار تغییرات رشد محصولات شناسایی شدند (شکل ۶). با توجه به این که محصولات زراعی در طول سال دارای مراحل رشد و مقادیر شاخص گیاهی می‌باشند، حد آستانه‌های شاخص NDVI متناسب با نوع هر یک از محصولات زراعی نظیر گندم، جو، برنج و ذرت، تنظیم شدند (شکل ۷).



شکل ۶- تغییرات مقادیر NDVI محصولات غالب در مراحل رشد
Figure 6- NDVI changes for major crops in growth stages



شکل ۷- نقشه اراضی زیرکشت در شاخص NDVI
Figure 7- Cultivated lands map in NDVI index

دقت سه روش طبقه‌بندی محصولات زراعی با توجه به طیف انعکاسی هر محصول بوده است. بر این اساس، میزان صحت تعلق هر یک از پیکسل‌های تصاویر ماهواره‌ای به طبقات مختلف گروه‌های گیاهی موجود در منطقه، مقادیر صحت کلی و ضریب کاپا برای الگوریتم‌های طبقه‌بندی و شاخص‌های طیفی را مشخص می‌کند.

طبق نقشه‌های حاصل آمده، اراضی زراعی منطقه بیشتر در امتداد رودخانه بوده و آب رودخانه نیز اولین منبع تأمین آب برای زراعت این زمین‌ها است. با فاصله‌گیری از رودخانه، کشت گندم و جو بیشتر شده و این اراضی در نواحی شمالی و شرقی منطقه بیشتر دیده می‌شوند. نتایج اعتبارسنجی روش‌ها، طبق شاخص‌های صحت کلی، ضریب کاپا و پارامترهای دقت کاربر و تولیدکننده در جدول ۵ آمده است که تفاوت مقادیر صحت کلی و ضریب کاپای بدست آمده، ناشی از تفاوت

جدول ۵- اعتبارسنجی روش‌های طبقه‌بندی مورد استفاده

Table 5- The accuracy evaluation of classification methods

کلاس Class	ANN accuracy		SVM accuracy		NDVI accuracy	
	Producer	User	Producer	User	Producer	User
گندم Wheat	0.78	0.80	0.77	0.82	0.89	0.91
جو Barley	0.83	0.76	0.84	0.76	0.88	0.90
برنج Rice	0.90	0.94	0.92	0.93	0.99	0.98
ذرت Corn	0.88	0.91	0.89	0.95	0.98	0.97
سایر اراضی Other lands	0.96	0.98	0.97	0.94	0.95	0.93
صحت کلی Overall accuracy	0.89		0.92		0.97	
ضریب کاپا Kappa coefficient	0.82		0.90		0.93	

داشته است. بنابراین، نتایج صحت شاخص NDVI، قابلیت و توانایی بالاتر شاخص‌های طیفی را نسبت به روش‌های طبقه‌بندی نشان داد. در نهایت، مساحت اراضی زیرکشت محصولات زراعی بدست آمده از تصاویر ماهواره‌ای (نتایج دو رویکرد)، با آمار سطح زیرکشت سازمان جهاد کشاورزی خوزستان در سال زراعی ۹۸-۱۳۹۷ مقایسه شده و درصد خطای آن‌ها برآورد گردید (جدول ۶). بر پایه نتایج بدست آمده، از کل اراضی زیرکشت محصولات زراعی شهرستان شوش به مقدار ۱۶۳۳۱۳/۷ هکتار حدود ۱۰۳۵۱۳/۲ هکتار یا ۶۳/۴ درصد از مجموع اراضی زیرکشت منطقه به نسبت روش شبکه عصبی مصنوعی، حدود ۱۰۲۸۷۵/۱ هکتار یا ۶۳/۰ درصد از کل اراضی زیرکشت منطقه برای روش ماشین بردار پشتیبان و حدود ۱۰۲۲۷۷/۳ هکتار یا ۶۲/۶ درصد از مجموع اراضی زیرکشت منطقه به شاخص NDVI اختصاص یافت که مقادیر در مقایسه با آمار سطح زیرکشت سازمان جهاد کشاورزی استان خوزستان به ترتیب خطاهای ۱۱/۰، ۶/۲ و ۱/۸ درصد را نشان دادند. علت این اختلاف، شباهت طیف انعکاسی در برخی از نقاط بوده که بر توان تفکیک و تشخیص پدیده‌ها اثر گذاشته و موجب افزایش خطا در برآورد سطح زیرکشت محصولات مختلف می‌شود. بیشترین کمترین خطا در برآورد سطح زیرکشت برای روش شبکه عصبی مصنوعی به ترتیب در اراضی محصولات جو و برنج و در روش ماشین بردار پشتیبان به ترتیب در اراضی محصولات گندم و برنج بوده است. در مجموع، روش ماشین بردار پشتیبان، خطای برآورد سطح زیرکشت کمتری نسبت به روش شبکه عصبی مصنوعی داشته که این تداعی کننده قابلیت و توانایی بالای روش ماشین بردار پشتیبان در شناسایی و تفکیک محصولات زراعی منطقه بوده است.

مطابق با نتایج جدول ۵، در رویکرد طبقه‌بندی تصاویر ماهواره‌ای، روش ماشین بردار پشتیبان با صحت کلی و ضریب کاپای ۰/۹۲ و ۰/۹۰، دقت بیشتری را نسبت به روش شبکه عصبی مصنوعی داشته است. لذا در این رویکرد، روش ماشین بردار پشتیبان در تفکیک پدیده‌هایی که رفتار طیفی نزدیک به هم دارند، موفق‌تر عمل کرده و تفکیک مناسب‌تری روی محصولات زراعی مورد مطالعه نشان داده است. در نقشه حاصل از روش شبکه عصبی مصنوعی، به دلیل تشابه طیفی محصولات در برخی نقاط گیاهان به خوبی از هم تفکیک نشده بودند و در این مکان‌ها پیکسل‌هایی دیده می‌شد که مربوط به یک گیاه بودند، اما در طبقه سایر گیاهان که با این گیاه هم‌زمانی دوره رشد داشتند، در نظر گرفته شده بود. در پژوهش حاضر، ابتدا روش‌های طبقه‌بندی با ۵۰ درصد نمونه‌های تعلیمی برای هر کلاس اجرا شدند. مقادیر صحت کلی و ضریب کاپای نقشه‌های بدست آمده در این مرحله برای روش شبکه عصبی مصنوعی به ترتیب ۰/۸۰ و ۰/۷۲ و برای روش ماشین بردار پشتیبان به ترتیب ۰/۹۰ و ۰/۸۹ بدست آمد. لذا، با کاهش تعداد نمونه‌های تعلیمی، صحت نقشه‌های حاصل روش شبکه عصبی مصنوعی کاهش یافته و در نتیجه تا حد امکان باید از نمونه‌های بیشتری استفاده شود تا تغییرات بسیاری از ویژگی‌های طیفی در این گستره پیوسته نیز قرار گیرد. اما در روش ماشین بردار پشتیبان، با استفاده از نیمی از داده‌های تعلیمی نیز می‌توان به دقتی معادل استفاده از کل نمونه‌های تعلیمی رسید و دقت بیشتری نسبت به روش شبکه عصبی مصنوعی ارائه نمود. در رویکرد دوم، شاخص NDVI با صحت کلی و ضریب کاپای ۰/۹۷ و ۰/۹۳، دقت بالاتری نسبت به روش‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان

جدول ۶- مقایسه نتایج برآورد سطح زیرکشت محصولات زراعی روش‌های طبقه‌بندی با آمار سازمان جهاد کشاورزی در سال زراعی ۹۸-۱۳۹۷

Table 6- Comparison of crop area estimation of classification methods with OAJ Statistics in the crop year 2019-2020

محصول Crop	KOAJ		ANN		SVM		NDVI	
	Crop area (Ha)	Crop area (Ha)	(%) Error	Crop area (Ha)	(%) Error	Crop area (Ha)	(%) Error	
گندم Wheat	49982	55829.8	+11.7	54430.4	+8.9	52081.2	+4.2	
جو Barley	1533	1718.4	+12.1	1634.1	+6.6	1514.6	-1.2	
برنج Rice	26820	25183.9	-6.1	25693.5	-4.2	26095.8	-2.7	
ذرت Corn	22252	2076.1	-6.7	21117.1	-5.1	22585.7	+1.5	
مجموع Total	100587	103512.2	11.0	102875.1	6.2	102277.3	1.8	

بحث

طبقه‌بندی، بهترین دقت مربوط به روش ماشین بردار پشتیبان است. خطای نسبی این روش در قیاس با آمار سازمان جهاد کشاورزی استان خوزستان، نسبت به روش شبکه عصبی مصنوعی پایین‌ترین مقادیر را نشان داد. این مورد با یافته‌های مطالعات گونزالس و همکاران (Gonzalez et al., 2022) و نیز موسوی و همکاران (Moussavi et al., 2020) همخوانی دارد. در رویکرد دوم، مقایسه مساحت بدست آمده با استفاده از شاخص‌های گیاهی، با آمار سطح زیرکشت سازمان جهاد کشاورزی استان خوزستان و نیز ارزیابی دقت این روش، نشانگر کارایی مناسب شاخص NDVI در برآورد سطح زیرکشت محصولات منطقه نسبت به روش‌های طبقه‌بندی است. این مطلب با نتایج مطالعات روزنیک و همکاران (Roznik et al., 2022)، ریاحی و همکاران (Riahi et al., 2019) و نیز ژانگ و همکاران (Zhang et al., 2017) که توان بالاتر شاخص طیفی مورد بررسی را در برآورد سطح زیرکشت نشان دادند، مطابقت دارد.

نتیجه‌گیری

برآورد سطح زیرکشت محصولات زراعی، از مهم‌ترین موضوعات در مدیریت کشاورزی می‌باشد که در برنامه‌ریزی‌های دولت‌ها از جمله تدوین سیاست‌های غذایی، تنظیم قیمت بازار، مدیریت واردات، توسعه صادرات و انبارداری مناسب محصولات مفید است. داده‌های سنجنش از دور به منظور تعیین سطح زیرکشت محصول، بهبود اداره اراضی و تسهیل در اجرای تکنیک‌های کشاورزی دقیق اثرگذار هستند. هدف اصلی برآورد دقیق سطح زیرکشت محصولات، دسترسی به حداکثر عملکرد محصول و حداقل هزینه در یک اکوسیستم سالم با استفاده ترکیبی از فناوری‌ها است. با توجه به نتایج پژوهش در صورت انتخاب

بیشتر مطالعاتی که در زمینه مقایسه روش‌های طبقه‌بندی تصاویر ماهواره‌ای انجام شده‌اند، ماشین بردار پشتیبان به عنوان روشی موفق در زمینه استخراج اراضی زراعی معرفی شده است. بیشترین و کمترین خطای برآورد سطح زیرکشت در شاخص NDVI به ترتیب در اراضی محصولات گندم و جو بوده است. بنابراین، در مقایسه نتایج دو رویکرد با آمار سطح زیرکشت جهاد کشاورزی، شاخص NDVI کمترین خطا را داشته که نشان‌دهنده قابلیت بالای شاخص‌های طیفی در برآورد سطح زیرکشت محصولات زراعی منطقه با توجه به چرخه رشد آن‌ها بوده است. شاخص NDVI بواسطه داشتن حد آستانه و شناسایی بهتر تراکم پوشش گیاهی، مقادیر خطای نتایج را به حداقل رسانیده است. لذا بر پایه نتایج ارزیابی صحت و مقایسه سطح زیرکشت محصولات زراعی با آمار سازمان جهاد کشاورزی، استفاده از شاخص NDVI، بهترین تخمین از سطح زیرکشت محصولات زراعی غالب منطقه را ارائه می‌دهد. به طور کلی، تفاوت مساحت‌های بدست آمده از روش‌های مورد استفاده با آمار و اطلاعات سطح زیرکشت سازمان جهاد کشاورزی، ممکن است از مواردی نشأت گرفته باشد؛ مورد اول، تفاوت تاریخ کشت و عوامل بعدی برگرفته از آن، که خود باعث ایجاد مشکلاتی نظیر بازتاب متفاوت مزارع محصولات مختلف در یک تصویر شده است. مورد دوم، اراضی زراعی این منطقه کوچک بوده و مساحت اغلب آن‌ها زیر یک هکتار است. همچنین، محصولات زراعی منطقه بسیار متنوع هستند. مورد سوم، کوچک‌ترین گستره‌ای که تصویر استفاده شده در این مطالعه قادر است تفکیک کند، حدود ۹۰۰ مترمربع است که برای اراضی زراعی محدوده مورد مطالعه، عدد بزرگی است و باعث خطا می‌شود. نتایج نشان داد، از میان روش‌های

نزدیکی آمار سازمان جهاد کشاورزی خوزستان به نتایج بدست آمده از طبقه‌بندی این شاخص کارایی و عملکرد مناسب‌تری داشته است. لذا برای تحقیقات آتی در این زمینه پیشنهاد می‌گردد که در تعیین سطح زیر کشت محصولات زراعی برای سایر مناطق کشور با حداکثر تشابه اقلیمی و تجانس جغرافیایی با شهرستان شوش، از پیاده‌سازی شاخص‌های طیفی استفاده شود.

تصاویر ماهواره‌ای مناسب نظیر تصاویر لندست هشت بر پایه مراحل رویشی گیاهان زراعی می‌توان عمل شناسایی، تفکیک محصولات زراعی و برآورد سطح زیر کشت را با دقت بالایی انجام داد. با توجه به نتایج سه روش طبقه‌بندی مورد استفاده در پژوهش، جهت استخراج سطح زیر کشت محصولات زراعی شهرستان شوش، شاخص NDVI با مقادیر صحت کلی و ضریب کاپای بالاتر نسبت به دو روش دیگر و

منابع

- Alavipanah, K. (2015). *Application of remote sensing in earth sciences (Soil sciences)*. University of Tehran Press: Tehran. (In Persian). https://press.ut.ac.ir/book_765_2640.html.
- Asming, M.A., Ibrahim, A.M., & Abir, I.M. (2022). Processing and classification of landsat and sentinel images for oil palm plantation detection. *Remote Sensing Applications: Society and Environment* 26: 100747. <https://doi.org/10.1016/j.rsase.2022.100747>.
- Cabaneros, S.M., Calautit, J.K., & Hughes, B.R. (2019). A review of artificial neural network models for ambient air pollution prediction. *Environmental Modelling and Software* 119: 285-304. <https://doi.org/10.1016/j.envsoft.2019.06.014>.
- Chanu, C.S., Elango, L., & Shankar, G.R. (2021). A geospatial approach for assessing the relation between changing land use/land cover and environmental parameters including land surface temperature of Chennai metropolitan city, India. *Arabian Journal of Geosciences* 14(2): 1-16. <https://doi.org/10.1007/s12517-020-06409-0>.
- Chen, Y., Lu, D., Moran, E., Batistella, M., Dutra, L.V., Sanches, I., Da Silva, R., Huang, J., Luiz, A.J., & De Oliveira, M. (2018). Mapping croplands, cropping patterns, and crop types using MODIS time series data. *Journal of Applied Earth Observation and Geoinformation* 69: 133-147. <https://doi.org/10.1016/j.jag.2018.03.005>.
- Deng, X., & Gibson, J. (2019). Improving eco-efficiency for the sustainable agricultural production: A case study in Shandong, China. *Technological Forecasting and Social Change* 144: 394-400. <https://doi.org/10.1016/j.techfore.2018.01.027>.
- Derksen, D., Inglada, J., & Michel, J. (2020). Geometry aware evaluation of handcrafted superpixel-based features and convolutional neural networks for land cover mapping using satellite imagery. *Remote Sensing* 12(3): 513. <https://doi.org/10.3390/rs12030513>.
- Dong, Q., Liu, J., Wang, L., Chen, Z., & Gallego, J. (2017). Estimating crop area at county level on the North China Plain with an indirect sampling of segments and an adapted regression estimator. *Sensors* 17(11): 2638. <https://doi.org/10.3390/s17112638>.
- Ebodé, V., Braun, J.J., Nnomo, B.N., Mahé, G., Nkiaka, E., & Riotte, J. (2022). Impact of rainfall variability and land use change on river discharge in South Cameroon. *Water* 14(6): 941. <https://doi.org/10.3390/w14060941>.
- Garain, S., Mitra, D., & Das, P. (2021). Mapping hydrocarbon microseepage prospect areas by integrated studies of Aster processing, geochemistry and geophysical surveys in Assam-Arakan Fold Belt, NE India. *Applied Earth Observation and Geoinformation* 102: 102432. <https://doi.org/10.1016/j.jag.2021.102432>.
- García, J.A., Ouhbi, S., Benmouna, B., Garcia-Mateos, G., Fernández-Alemán, J.L., & Molina-Martínez, J.M. (2020). Systematic mapping study on remote sensing in agriculture. *Applied Sciences* 10(10): 1-29. <https://doi.org/10.3390/app10103456>.
- Gonzalez, F.A., Vuelvas, J., Correa, C.A., Vallejo, V.E., & Patino, D. (2022). Machine learning and remote sensing techniques applied to estimate soil indicators, Review. *Ecological Indicators* 135: 108517. <https://doi.org/10.1016/j.ecolind.2021.108517>.
- Hedayati, A., Vahidnia, M.H., & Behzadi, S. (2022). Paddy lands detection using Landsat-8 satellite images and object-based classification in Rasht City, Iran. *Remote Sensing & Space Science* 25(1): 73-84. <https://doi.org/10.1016/j.ejrs.2021.12.008>.
- Huang, S., Tang, L., Hupy, J.P., Wang, Y., & Shao, G. (2021). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Forestry Research* 32(1): 1-6. <https://doi.org/10.1007/s11676-020-01155-1>.
- Hudait, M., & Patel, P.P. (2022). Crop-type mapping and acreage estimation in smallholding plots using Sentinel-2 images and machine learning algorithms: Some comparisons. *Remote Sensing and Space Science* 25(1): 147-156. <https://doi.org/10.1016/j.ejrs.2022.01.004>.
- Jain, D.K., Dubey, S.B., Choubey, R.K., Sinhal, A., Arjaria, S.K., Jain, A., & Wang, H. (2018). An approach for hyperspectral image classification by optimizing SVM using self organizing map. *Computational Science* 25: 252-259. <https://doi.org/10.1016/j.jocs.2017.07.016>.

17. Khodakarami, L., & Soffianian, A. (2012). Application of multi temporal remote sensing for precision farming. *Water and Soil Science* 16(59): 215-231. (In Persian with English abstract) [20.1001.1.24763594.1391.16.59.16.9](https://doi.org/10.1001.1.24763594.1391.16.59.16.9).
18. Khuzestan Organization Agricultural-Jihad. (2019). Crop statistics of Khuzestan Province in 2019-2020.
19. Kim, D., Kang, S., and Cho, S. 2020. Expected margin-based pattern selection for support vector machines. *Expert Systems with Applications* 139: 112865. <https://doi.org/10.1016/j.eswa.2019.112865>.
20. Kundu, A., Denis, D.M., Patel, N.R., & Dutta, D. (2018). A Geo - spatial study for analysing temporal responses of NDVI to rainfall. *Tropical Geography* 39(1): 107-116. <https://doi.org/10.1111/sjtg.12217>.
21. Li, P., Jiang, L., & Feng, Z. (2013). Cross-comparison of vegetation indices derived from Landsat-7 enhanced thematic mapper plus (ETM+) and Landsat-8 operational land imager (OLI) sensors. *Remote Sensing* 6(1): 310-329. <https://doi.org/10.3390/rs6010310>.
22. Liaqat, M.U., Cheema, M.J.M., Huang, W., Mahmood, T., Zaman, M., & Khan, M. (2017). Evaluation of MODIS and Landsat multiband vegetation indices used for wheat yield estimation in irrigated Indus Basin. *Computers and Electronics in Agriculture* 138: 39-47. <https://doi.org/10.1016/j.compag.2017.04.006>.
23. Lyons, M.B., Keith, D.A., Phinn, S.R., Mason, T.J., & Elith, J. (2018). A comparison of resampling methods for remote sensing classification and accuracy assessment. *Remote Sensing of Environment* 208: 145-153. <https://doi.org/10.1016/j.rse.2018.02.026>.
24. Manickam, L., Subramanian, D., Khandal, S., & Hegde, R. (2021). Modeling and mapping of salt-affected soils through spectral indices in land plains of semi-arid agro-sociological region. *Indian Society of Remote Sensing* 49(6): 1475-1481. <https://doi.org/10.1007/s12524-021-01321-w>.
25. Martínez, J.B.G., Brown, M.M., Christodoulou, X., Alvarado, K.A., & Denckenberger, D.C. (2021). Potential of microbial electrosynthesis for contributing to food production using CO₂ during global agriculture inhibiting disasters. *Cleaner Engineering and Technology* 4: 1-10. <https://doi.org/10.1016/j.clet.2021.100139>.
26. Martínez2021, M., Ogando-Martínez, A., Troncoso-Pastoriza, F., López-Gómez, J., Febrero-Garrido, L., & Granada-Álvarez, E. (2021). Use of optimised MLP neural networks for spatiotemporal estimation of indoor environmental conditions of existing buildings. *Building and Environment* 205: 108243. <https://doi.org/10.1016/j.buildenv.2021.108243>.
27. Mirzaei, M., Jafari, A., Gholamalifard, M., Azadi, H., Shoostari, S.J., Moghaddam, S.M., Gebrehiwot, K., & Witlox, F. (2020). Mitigating environmental risks: Modeling the interaction of water quality parameters and land use cover. *Land Use Policy* 95: 103766. <https://doi.org/10.1016/j.landusepol.2018.12.014>.
28. Moussavi, S.A., Abbaszadeh Tehrani, N., & Janalipour, M. (2020). Estimation of wheat area cultivation using Sentinel 2 satellite images, Case study: Sojasroud Region, Khodabandeh City, Zanjan Province. *Environmental Research and Technology* 7(7): 77-90. <https://doi.org/10.29252/5.7.77>.
29. Ouzemou, J.E., El Harti, A., Lhissou, R., El Moujahid, A., Bouch, N., El Ouazzani, R., El Mostafa, B., & El Ghmari, A. (2018). Crop type mapping from pansharpened Landsat 8 NDVI data: A case of a highly fragmented and intensive agricultural system. *Remote Sensing Applications: Society and Environment* 11: 94-103. <https://doi.org/10.1016/j.rsase.2018.05.002>.
30. Pageot, Y., Baup, F., Inglada, J., Baghdadi, N., & Demarez, V. (2020). Detection of irrigated and rainfed crops in temperate areas using Sentinel-1 and Sentinel-2 time series. *Remote Sensing* 12(18): 3044. <https://doi.org/10.3390/rs12183044>.
31. Parmar, J., Das, P., & Dave, S.M. (2021). A machine learning approach for modelling parking duration in urban land-use. *Physica A: Statistical Mechanics and its Applications* 572: 125873. <https://doi.org/10.1016/j.physa.2021.125873>.
32. Paudel, D., Boogaard, H., de Wit, A., Janssen, S., Osinga, S., Pylianidis, C., & Athanasiadis, I.N. (2021). Machine learning for large-scale crop yield forecasting. *Agricultural Systems* 187: 103016. <https://doi.org/10.1016/j.agsy.2020.103016>.
33. Phan, P., Chen, N., Xu, L., & Chen, Z. (2020). Using multi-temporal MODIS NDVI data to monitor tea status and forecast yield: A case study at Tanuyen, Laichau, Vietnam. *Remote Sensing* 12(11): 1814. <https://doi.org/10.3390/rs12111814>.
34. Poursanidis, D., Topouzelis, K., & Chrysoulakis, N. (2018). Mapping coastal marine habitats and delineating the deep limits of the Neptune's seagrass meadows using very high resolution Earth observation data. *Remote Sensing* 39(23): 8670-8687. <https://doi.org/10.1080/01431161.2018.1490974>.
35. Ramírez, J.C., Restrepo-Girón, A.D., & Nope-Rodríguez, S.E. (2019). Detection of internal defects in carbon fiber reinforced plastic slabs using background thermal compensation by filtering and support vector machines. *Nondestructive Evaluation* 38(1): 1-11. <https://doi.org/10.1007/s10921-019-0569-6>.
36. Razaque, A., Benhajfrej, M., Almiani, M., Alotaibi, M., & Alotaibi, B. (2021). Improved support vector machine enabled radial basis function and linear variants for remote sensing image classification. *Sensors* 21(13): 4431. <https://doi.org/10.3390/s21134431>.
37. Riahi, V., Zeaiean, P., Azizpour, F., & Darouei, P. (2019). Identification and investigation of the area under cultivation in Lenjanat using Landsat 8 satellite images. *Applied Researches in Geographical Sciences* 19(52):

- 147-169. (In Persian with English abstract) <https://doi.org/10.29252/jgs.19.52.147>.
38. Rienow, A., Mustafa, A., Krelaus, L., & Lindner, C. (2021). Modeling urban regions: Comparing random forest and support vector machines for cellular automata. *Transactions in GIS* 25(3): 1625-1645. <https://doi.org/10.1111/tgis.12756>.
 39. Roznik, M., Boyd, M., & Porth, L. (2022). Improving crop yield estimation by applying higher resolution satellite NDVI imagery and high-resolution cropland masks. *Remote Sensing Applications: Society and Environment* 25: 100693. <https://doi.org/10.1016/j.rsase.2022.100693>.
 40. Solano-Correa, Y.T., Bovolo, F., & Bruzzone, L. (2018). An approach for unsupervised change detection in multitemporal VHR images acquired by different multispectral sensors. *Remote Sensing* 10(4): 533. <https://doi.org/10.3390/rs10040533>.
 41. Teffera, Z.L., Li, J., Debsu, T.M., & Menegesa, B.Y. (2018). Assessing land use and land cover dynamics using composites of spectral indices and principal component analysis: A case study in middle Awash subbasin, Ethiopia. *Applied Geography* 96:109-129. <https://doi.org/10.1016/j.apgeog.2018.05.015>.
 42. Tomala, A.S, Raczko, E., & Zagajewski, B. (2020). Comparison of support vector machine and random forest algorithms for invasive and expansive species classification using airborne hyperspectral data. *Remote Sensing* 12(3): 516. <https://doi.org/10.3390/rs12030516>.
 43. Van-Klompenburg, T., Kassahun, A., & Catal, C. (2020). Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture* 177: 105709. <https://doi.org/10.1016/j.compag.2020.105709>.
 44. Verma, P., Raghubanshi, A., Srivastava, P.K., & Raghubanshi, A.S. (2020). Appraisal of kappa-based metrics and disagreement indices of accuracy assessment for parametric and nonparametric techniques used in LULC classification and change detection. *Modeling Earth Systems and Environment* 6(2): 1045-1059. <https://doi.org/10.1007/s40808-020-00740-x>.
 45. Viana, C.M., Freire, D., Abrantes, P., Rocha, J., & Pereira, P. (2022). Agricultural land systems importance for supporting food security and sustainable development goals: A systematic review. *Science of The Total Environment* 806: 150718. <https://doi.org/10.1016/j.scitotenv.2021.150718>.
 46. Wang, F., Qin, Z., Song, C., Tu, L., Karnieli, A., & Zhao, S. (2015). An improved mono-window algorithm for land surface temperature retrieval from Landsat 8 thermal infrared sensor data. *Remote Sensing* 7(4): 4268-4289. <https://doi.org/10.3390/rs70404268>.
 47. Wang, K., Cheng, L., & Yong, B. (2020). Spectral similarity based kernel of SVM for hyperspectral image classification. *Remote Sensing* 12(13): 2154. <https://doi.org/10.3390/rs12132154>.
 48. Wang, M., Wander, M., Mueller, S., Martin, N., & Dunn, J.B. (2022). Evaluation of survey and remote sensing data products used to estimate land use change in the United States: Evolving issues and emerging opportunities, *Environmental Science and Policy* 129: 68-78. <https://doi.org/10.1016/j.envsci.2021.12.021>.
 49. Yopez, S., Laraque, A., Martinez, J.M., De Sa, J., Carrera, J.M., Castellanos, B., Gallay., M., & Lopez, J.L. (2018). Retrieval of suspended sediment concentrations using Landsat-8 OLI satellite images in the Orinoco River, Venezuela. *Comptes Rendus Geoscience* 350(1-2): 20-30. <https://doi.org/10.1016/j.crte.2017.08.004>.
 50. 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>.
 51. Zafari, A., Zurita-Milla, R., & Izquierdo-Verdiguier, E. (2019). Evaluating the performance of a random forest kernel for land cover classification. *Remote Sensing* 11(5): 575. <https://doi.org/10.3390/rs11050575>.
 52. Zare, M., Drastig, K., & Zude-Sasse, M. (2020). Tree water status in apple orchards measured by means of land surface temperature and vegetation index (LST-NDVI) trapezoidal space derived from Landsat 8 satellite images. *Sustainability* 12(1): 70. <https://doi.org/10.3390/su12010070>.
 53. Zhang, H., Li, Q., Liu, J., Shang, J., Du, X., Zhao, L., Wang, N., & Dong, T. (2017). Crop classification and acreage estimation in North Korea using phenology features. *GIScience & Remote Sensing* 54(3): 381-406. <https://doi.org/10.1080/15481603.2016.1276255>.
 54. Zhang2019, L., Liu, Z., Liu, D., Xiong, Q., Yang, N., Ren, T., Zhang, C., Zhang, X., & Li, S. (2019). Crop mapping based on historical samples and new training samples generation in Heilongjiang Province, China. *Sustainability* 11(18): 5052. <https://doi.org/10.3390/su11185052>.
 55. Ziaiean, P., Bidhendi, S.L., & Eskandari Nodeh, M. (2010). Mapping and acreage estimating of rice agricultural land using radarsat a satellite images. *Physical Geography Research Quarterly* 41(68): 45-58. (In Persian with English abstract) https://jphgr.ut.ac.ir/article_21495.html?lang=fa.