



Distinguishing Rain-fed and Irrigated Crops in Hamadan Province Using Spectral Indices of Satellite Images

H. Mohamadi Monavar^{1*}, S. Zibazadeh²

1- Assistant Professor, Department of Bio-system Engineering, Faculty of Agriculture, Bu-ali Sina University, Hamadan, Iran

2- MSc graduate, Department of Bio-system Engineering, Faculty of Agriculture, Bu-ali Sina University, Hamadan, Iran

(*- Corresponding Author Email: hosna.mohamadi@basu.ac.ir)

<https://doi.org/10.22067/jam.2021.69074.1022>

Received: 24-02-2021

Revised: 21-09-2021

Accepted: 03-10-2021

Available Online: 04-10-2021

How to cite this article:

Mohamadi Monavar, H., & Zibazadeh, S. (2022). Distinguishing Rain-fed and Irrigated Crops in Hamadan Province Using Spectral Indices of Satellite Images. *Journal of Agricultural Machinery*, 12(4), 529-542. (in Persian with English abstract). <https://doi.org/10.22067/jam.2021.69074.1022>

Introduction

Remote sensing methods for mapping farms and crops have been widely used in the last three decades. This method is applied to identify irrigated areas around the world (Alipour *et al.*, 2014), although most of these studies are in areas with semi-arid climates and low rainfall or lack of rainfall which has a significant effect on the spectral characteristics of plants. In this study, Landsat 8 and MODIS satellite images were used to identify and separate two irrigated and rain-fed wheat farms in Hamadan province. Two algorithms of support vector machine (SVM) and minimum distance (MD) were used simultaneously to classify irrigated and rain-fed farms. In the next step, the area under cultivation of rain-fed and irrigated wheat was predicted in the whole cultivated area of Hamadan province. Finally, the cultivation area of rain-fed and irrigated crops was calculated in the province using Sentinel 3 satellite images based on the random forest algorithm in 2016.

Materials and Methods

The study area is Hamedan province, which is located between 59° 33' and 49° 35' north latitude and also from 34° 47' to 34° 49' east longitude of the Greenwich meridian. A 50-hectare rain-fed wheat farm in Amzajerd was used as a sample to extract the properties of rain-fed wheat. Also, irrigated indices were extracted from a 100-hectare irrigated wheat farm located in Kaboudrahang. Satellite images were applied to separate irrigated and rain-fed wheat in Hamadan province. NDVI, EVI and NDWI indices were extracted from 16-day images of Landsat, MODIS, and Sentinel 3 sensors in the five-year period (2015-2019). Google Earth Engine (GEE) system was the environment for performing image processing calculations and extracting indices and maps.

Results and Discussion

The NDVI and EVI of irrigated and rain-fed wheat farms were calculated in 2015-2019. A small peak was observed in the rain-fed and irrigated NDVI trend in November due to the early germination of wheat leaves in winter, and the larger peak in May and June showed the maximum greenness of irrigated and rain-fed wheat, respectively. The ascending or descending trend of NDVI / EVI had no constant slope. This can be due to changes in meteorological parameters, which sometimes cause a sudden increase or decrease in the values of these indices. Despite the non-linearity of the NDVI / EVI trend over time, the maximum greenness was recorded just a month before the wheat harvest, which was seen in the third decade of May to the first decade of June. One of the cases is the sharp drop of NDVI / EVI after its final peak, which was definitely due to yellowing wheat and harvesting. Since the distinction between rain-fed and irrigated crops was difficult only based on NDVI, NDWI was also used to determine the water content of wheat so that irrigated wheat could be identified. However, the difference between rain-fed and irrigated wheat in terms of NDWI spectral density was insignificant; the maximum and minimum occurrence times of NDWI and NDVI of rain-fed and irrigated wheat were chosen for their separation. In order to map the cultivation area, in addition to the MODIS sensor, Sentinel 3 was used due to its ability to detect chlorophyll accurately. Due to the fact that the imaging of the Sentinel 3 satellite started since 2016, the map of rain-fed and irrigated cultivation as well as the cultivation area and their separation was done based on the random forest algorithm in 2016.

Conclusion

The results of this study showed that the appropriate method for distinguishing between rain-fed and irrigated wheat is the simultaneous use of several indices. Also, the greatest difference is in the maximum greenness, which happened almost one month before harvest. MD and SVM classification algorithms could distinguish irrigated and rain-fed wheat from other crops with 90% and 80% accuracy, respectively. Distinguished maps of irrigated and rain-fed crops based on the random forest algorithm were obtained using Sentinel 3 satellite imagery which can show the fertility of agricultural lands in the province.

Keywords: Distinguishing of rainfed and irrigated, Satellite images, Vegetation indices, Wheat

مقاله پژوهشی

جلد ۱۲، شماره ۴، زمستان ۱۴۰۱، ص ۵۲۹-۵۴۲

تفکیک مزارع کشت دیم و آبی در استان همدان با استفاده از شاخص‌های طیفی تصاویر

ماهواره‌ای

حسنا محمدی منور^{۱*}، سمانه زیبازاده^۲

تاریخ دریافت: ۱۳۹۹/۱۲/۰۶

تاریخ پذیرش: ۱۴۰۰/۰۷/۱۱

چکیده

استفاده از تکنیک سنجش از دور امروزه در کشاورزی کاربردهای فراوانی دارد از جمله تعیین سطح زیر کشت و پیش‌بینی عملکرد محصول. در این پژوهش از تصاویر ماهواره‌ای جهت تفکیک گندم آبی و دیم در استان همدان استفاده شد. شاخص‌های NDVI، EVI و NDWI از تصاویر ۱۶ روزه سنجنده‌های لندست، مادیس و سنتینل ۳ در بازه پنج ساله مورد مطالعه (۲۰۱۵-۲۰۱۹) استخراج گردید. نتایج شاخص‌ها نشان داد کاهش شدید EVI/NDVI بعد از نقطه اوج به دلیل آن است که زمان زرد شدن و یا برداشت محصول فرا رسیده است. به علاوه NDWI به ترتیب در بیشینه سبزیگی گندم در کشت آبی و دیم ۰/۷۶۷ و ۰/۷۳۶ دیده شد. سامانه Google Earth Engine محیط انجام محاسبات پردازش تصاویر و استخراج شاخص‌ها و نقشه‌ها بود و نرم‌افزار R نیز برای آنالیزهای طبقه‌بندی و تفکیک کشت دیم و آبی به کار رفت. نتایج نشان داد نقشه استان بر اساس سطح زیر کشت دیم و آبی ماهواره سنتینل ۳ جزئیات بیشتری را نشان داد. همچنین استفاده هم‌زمان از چند شاخص NDVI، EVI و NDWI توانست قدرت تفکیک را افزایش دهد. علی‌رغم شباهت‌های موجود، الگوریتم‌های SVM و MD نیز با دقت قابل قبولی تفکیک کشت دیم و آبی استان را ارائه دادند. نتایج نشان داد کشت دیم و آبی گندم استان با دقت ۰/۷۳۷ تفکیک شد و تفکیک گندم از سایر کشت‌ها با دقت ۰/۹۴۵ انجام گردید.

واژه‌های کلیدی: تصاویر ماهواره‌ای، تفکیک کشت دیم و آبی، شاخص‌های سبزیگی، گندم

مقدمه

وسیع، یک مسئله اساسی است که روش‌های متعارف زمینی می‌توانند فقط یک راه‌حل جزئی ارائه دهند. در واقع، چنین روش‌هایی نیروی کار و زمان طولانی می‌طلبند و بنابراین فقط برای ارزیابی آبیاری محصول در مناطق نسبتاً کوچک زمین و دوره‌های زمانی کوتاه استفاده می‌شوند (Giannini & Bagnoni, 2000). روش‌های سنجش از دور برای تهیه نقشه مزارع و محصولات کشاورزی در سه دهه اخیر به‌طور گسترده مورد استفاده قرار گرفته‌اند. این روش برای تشخیص مناطق آبی در سراسر دنیا به کار می‌رود (Alipour, Agh-Khani, Abbaspour-Fard, & Sepehr, 2014; Alexandridis, Zalidis, & Silleos, 2008; Wardlow, Egbert, & Kastens, 2006; Akbari et al., 2007). اگرچه اکثر این مطالعات در مناطقی با اقلیم نیمه‌خشک و کم بارش انجام شده است و کمبود بارش در خصوصیات طیفی گیاه تاثیر قابل توجهی دارد. در مقایسه با کشت‌های آبی در مناطق خشک و نیمه‌خشک، کشت دیم در مناطقی با رطوبت بالا که ممکن است حتی در تابستان هم بارش‌های طولانی را تجربه کنند، خصوصیات طیفی گیاه تغییر چندانی نخواهد داشت (Shamal & Weatherland, 2014). از طرفی نقشه‌برداری از محصولات آبی در آب و هوای مرطوب یا معتدل با استفاده از تکنیک‌های سنجش از

آب اصلی‌ترین منبع طبیعی است که به دلیل تغییرات اقلیمی و مصارف بی‌رویه انسانی مقدار آن به‌خصوص در مناطق خشک و نیمه‌خشک محدود می‌شود. (Drusch et al., 2013). افزایش دما به‌خصوص در منطقه مدیترانه و در نتیجه افزایش نیاز به مصرف آب در صنعت و کشاورزی و همچنین کاهش نزولات جوی سبب کمتر شدن آب در دسترس شده است (Hartmann et al., 2013). در این منطقه کشاورزی اصلی‌ترین مصرف‌کننده آب می‌باشد به‌خصوص در کشت‌های تابستانه (ذرت، گندم، محصولات جالیزی و غیره) که میزان بارندگی محدود و نیاز آبی شدید می‌باشد (Guzinski & Nieto, 2019). در نتیجه تخمین آبیاری محصولات در زمین‌های

۱- استادیار، گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

۲- دانش‌آموخته کارشناسی ارشد، گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

*- نویسنده مسئول: (Email: hosna.mohamadi@basu.ac.ir)

<https://doi.org/10.22067/jam.2021.69074.1022>

شده، الگوریتم نظارت شده جنگل تصادفی^۴ به دلیل عدم وابستگی به پارامترها به کار رفت.

مواد و روش‌ها

منطقه مورد مطالعه

محدوده‌ی مورد مطالعه استان همدان است که بین مدارهای ۵۹ درجه و ۳۳ دقیقه تا ۴۹ درجه و ۳۵ دقیقه عرض شمالی و ۳۴ درجه و ۴۷ دقیقه تا ۳۴ درجه و ۴۹ دقیقه طول شرقی از نصف‌النهار گرینویچ قرار گرفته است (شکل ۱). استان همدان با مساحت ۲۰/۱۷۳ کیلومتر مربع در ناحیه‌ی غربی کشور واقع شده و از غرب به استان سندج و کرمانشاه و از جنوب به استان لرستان و از قسمت شرق به استان مرکزی و در قسمت شمال به استان زنجان محدود می‌شود. هوای همدان سرد و خشک می‌باشد و حداکثر دمای آن در تابستان ۳۶/۸ درجه سانتی‌گراد و حداقل در زمستان ۲۹/۶ - درجه سانتی‌گراد می‌رسد و میزان بارش سالیانه‌ی آن به‌طور متوسط ۳۴۳/۱ میلی‌متر است. گندم یکی از اصلی‌ترین محصولات مورد کشت کشاورزان استان همدان می‌باشد و ۴۰۰ هزار هکتار از مزارع استان به این محصول اختصاص دارد. پژوهش حاضر به تغییرات سطوح زیر کشت دیم و آبی در طی سال‌های ۲۰۱۵ تا ۲۰۱۹ می‌پردازد. مزرعه ۵۰ هکتاری گندم دیم (34.93N, 48.53E) واقع در امارجد استان همدان به‌عنوان نمونه برای استخراج خواص طیفی کشت دیم گندم به کار رفت. همچنین از مزرعه ۱۰۰ هکتاری گندم آبی (35.21N, 48.72E) واقع در کبودرآهنگ شاخص‌های پوشش‌های گیاهی کشت آبی استخراج گردید (شکل ۱-الف).

سنسورهای تصویربرداری

در پژوهش حاضر از تصاویر سنجنده‌های با توان تفکیک مکانی بالا مانند لندست به‌منظور استخراج انواع کشت‌های دیم و آبی و سپس با استفاده از تصاویر سنجنده‌هایی با توان تفکیک زمانی بالا مانند مادیس به‌منظور استخراج سیکل رشد محصول در بازه زمانی مورد مطالعه استفاده شد. با توجه به مشکلات موجود در روند تحقیق که از جمله مهم‌ترین آن‌ها کوچک بودن مزارع کشاورزی بود از شاخص‌های NDVI و EVI استخراج شده از تصاویر سنجنده‌هایی با توان تفکیک مکانی و زمانی بالا برای کل استان همدان استفاده شد. از طرفی، به دلیل ابری بودن برخی از روزهایی که تصویربرداری ماهواره‌ای انجام می‌شد از داده‌های TM^۵ و ETM^۶ سنجنده لندست

دور نیاز به دقت زیادی دارد و به آسانی آب و هوای خشک یا نیمه‌خشک نیست (Droogers, 2002). در مناطق معتدل تعیین نقشه کشت آبی مشکل است زیرا تفاوت بسیار اندکی در فنولوژی گیاهان دیم و آبی وجود دارد که به دلیل شرایط آب و هوایی و اقلیم مرطوب رخ می‌دهد (Peña-Arancibia et al., 2014).

استفاده از ماهواره‌ها موقعیت جدیدی برای نقشه‌برداری از مزارع کشاورزی مهیا نموده است (Drusch et al., 2012). مطالعات بسیاری از تصاویر ماهواره‌ای و سری زمانی جهت تهیه نقشه مزارع بهره‌جسته‌اند. استفاده از الگوریتم‌های سری زمانی سبب کاهش خطای استخراج شاخص‌ها از تصاویر ابرآلود ماهواره‌ای می‌شود (Vuolo, Neuwirth, Immitzer, Atzberger, & Ng, 2018) برای مثال تصاویر اپتیکی سنتینل ۲ در منطقه گرمسیری افریقا برای تهیه نقشه محصول استفاده شده است (Vogel et al., 2019) اگرچه دقت تصاویر در مناطق معتدل استوایی به‌علت غلظت ابر کاهش می‌یابد. برخی از مطالعات نشان می‌دهند که ترکیب تصاویر اپتیکی و راداری اعتبار نقشه‌ها را بهبود می‌بخشد. استفاده همزمان ماهواره‌های سنتینل ۱ و سنتینل ۲ برای تعیین مساحت کشت آبی به‌منظور تخمین آب‌های زیر زمینی (Ferrant et al., 2017)، استفاده همزمان از ماهواره لندست ۸ و سنتینل ۱ برای نقشه‌برداری مزارع آبی (Demarez, Helen, Marais-Sicre, & Baup, 2019) استفاده از سری زمانی و تصاویر راداری سنتینل ۱ (Bazzi et al., 2019) مثال‌هایی برای افزایش دقت نقشه‌برداری می‌باشند. باوجود مطالعات فراوان برای تشخیص کشت آبی در مناطق خشک و نیمه‌خشک، اطلاعات کافی برای تفکیک مزارع دیم و آبی در مناطق معتدل یا با آبیاری نسبتاً بالا وجود ندارد. ترکیب تصاویر اپتیکی مکانی و زمانی لندست ۸ و تصاویر SAR^۱ سنتینل ۱ قابلیت تشخیص مزارع آبی را در منطقه معتدل جنوب فرانسه فراهم نمود (Demarez et al., 2019). اگرچه در این مطالعه عامل محدودکننده وضوح مکانی تصاویر ماهواره لندست ۸ بیان شد.

در این پژوهش از تصاویر ماهواره لندست ۸ و مادیس برای شناسایی و تفکیک دو مزرعه کشت آبی و دیم گندم در استان همدان استفاده گردید. در تفکیک مزارع از دو الگوریتم ماشین بردار پشتیبان^۲ (svm) و حداقل فاصله^۳ (MD) به‌طور همزمان استفاده شد. استفاده همزمان از شاخص‌های گیاهی و اقلیمی در سال‌های متمادی دقت این مطالعه را افزایش داد. در نهایت با استفاده از تصاویر ماهواره سنتینل ۳ و شاخص‌های آب و هوایی، مساحت زیر کشت دیم و آبی محصولات کل استان بر اساس مقایسه نقشه مینا در سال‌های ۲۰۱۶ و ۲۰۱۹ محاسبه و مقایسه شد. علاوه بر الگوریتم‌های طبقه‌بندی ذکر

4- Random Forest

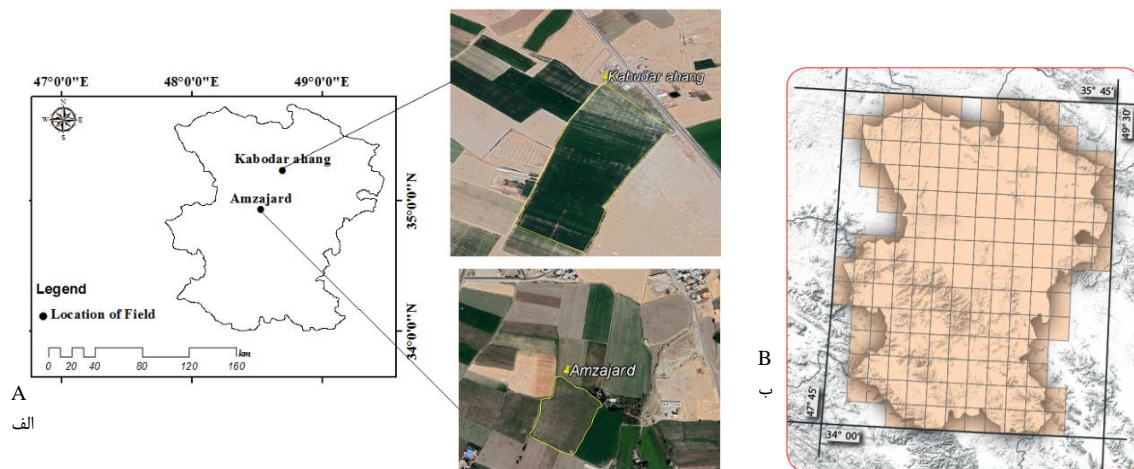
5- Thematic Mapper

6- Enhanced Thematic Mapper

1- Synthetic Aperture Radar

2- Support Vector Machine

3- Minimum Distance



شکل ۱- الف- مزارع مورد مطالعه و ب- طول و عرض جغرافیایی استان همدان
Fig.1. A- Studied fields, B-Latitude and longitude of the study area of Hamadan province

نانومتر) (Vuolo, Dash, Curran, Lajas, & Kwiatkowska, 2012) WorldView-2 (۷۲۵ نانومتر) (Heenkenda, Joyce, 2015) Sentinel-2 و (Maier, & De Bruin, 2015) و (۷۴۰، ۷۸۲، ۷۰۴) (Delloye, Weiss, & Defourny, 2018). با این حال، این سیستم عامل‌ها فاقد بایگانی طولانی مدت تاریخی هستند و محصولات متغیر بیوفیزیکی عملیاتی تولید نمی‌کنند. سنتینل ۳ (۲۰۱۶ تا کنون) با مشخصات مکانیکی و نوری مشابه طیف‌سنج تصویربرداری با وضوح متوسط^۳ (MERIS) (۲۰۱۲-۲۰۰۲) برای اطمینان از تداوم تولید و بررسی محصولات بیوفیزیکی زمینی و دریایی طراحی شد. شاخص کلروفیل زمینی (OTCI) شاخصی از میزان کلروفیل کانوپی است و برای ادامه بررسی شاخص کلروفیل زمینی سنجنده Envisat MERIS در نظر گرفته شده است.

شاخص‌های طبقه‌بندی

فرضیه اساسی در روش آماری تجربی اندازه‌گیری میزان سبزیگی می‌باشد. شاخص طیفی NDVI و EVI به‌طور مستقیم با تخمین محصول در ارتباط هستند زیرا شرایط مثبت و منفی محیط روی رشد گیاه تاثیرگذار است و مسئول افزایش و کاهش فعالیت‌های فتوسنتزی گیاه می‌باشد که با اندازه‌گیری طیفی این شاخص‌ها می‌توان سلامت و کیفیت گندم را پایش نمود. موقعیت مهم شاخص NDVI به‌خاطر ارتباط نزدیک بین شاخص سطح برگ (LAI) و تشعشع فعال فتوسنتزی جذب شده می‌باشد که منجر به ایجاد یک رابطه‌ی خطی شده که با استفاده از آن نوع و میزان محصول قابل

سنسورهای تصویرگر عمیاتی زمین (OLI) و سنسور مادون قرمز حرارتی (TIRS) نسبت سیگنال به نویز (SNR) را در عملکرد رادیومتری لندست ۸ بهبود بخشیده‌اند و در نتیجه کمی کردن داده‌ها امکان توصیف بهتری از پوشش گیاهی را فراهم می‌سازد (Morfitt *et al.*, 2015). سنجنده‌ی مادیس نواحی طیف مرئی (VIS)، مادون قرمز نزدیک (NIR)، مادون قرمز با طول موج کوتاه (SIR) و یا مادون قرمز میانی (MIR) و مادون قرمز با طول موج‌های بلند (LIR) را پوشش می‌دهد و برای اندازه‌گیری شاخص‌هایی مانند پوشش گیاهی (VI)، شاخص سطح برگ (LAI)، شاخص انحصار تابش فعال فتوسنتزی (FRAR)، شاخص تابع توزیع انعکاس دو محوری (BRDF) و پوشش برف، یخ، دریا و درجه حرارت سطح زمین (LST) به‌کار می‌رود (Gao *et al.*, 2005). در نهایت به‌منظور تایید نتایج سنجنده مادیس از ماهواره سنتینل ۳ برای تعیین مساحت مناطق کشت دیم و آبی کل استان همدان استفاده گردید. سنسور اندازه‌گیری شاخص کلروفیل زمینی^۱ (OTCI) در ماهواره سنتینل ۳ می‌تواند محتوای کلروفیل گیاهان را تشخیص دهد (Pastor-Guzman *et al.*, 2020). تصاویر OTCI با وضوح ۳۰۰ متر در سایت کوپرنیکوس در دسترس عموم می‌باشد. برای محاسبه آن از باندهای بازتابی ۱۰، ۱۱ و ۱۲ قرمز، لبه قرمز و مادون قرمز نزدیک به‌ترتیب با طول موج‌های ۶۸۱/۲۵، ۷۰۸/۷۵ و ۷۳۵/۷۵ نانومتر سنسور تغییر رنگ زمین و اقیانوس^۲ (OLCI) سنتینل ۳ استفاده شد. چندین ماهواره چند طیفی امکان تخمین LCC و CCC را دارند زیرا در نواحی لبه قرمز مجهز به باند هستند. به‌عنوان مثال می‌توان به RapidEye (۷۱۰

1- OLCI Terrestrial Chlorophyll Index
 2- Ocean and Land Colour Instrument

3- Medium Resolution Imaging Spectrometer

اطلاعاتی در مورد میزان فتوسنتز و محتوای کلروفیل فراهم می‌کند، از NDWI می‌توان به‌عنوان شاخص محتوای آب گیاه استفاده کرد. NDWI به‌طور گسترده‌ای جهت مطالعه محتوای آب پوشش‌های گیاهی مورد استفاده قرار گرفته است (Cheng, Zarco-Tejada, Riaño, Rueda, & Ustin, 2006) و برای نقشه‌برداری از مناطق آبیاری (Alexandridis et al., 2008). NDWI به‌عنوان نسبت بین بازتابش مادون قرمز نزدیک (NIR) و مادون قرمز میانه (MIR) از طریق رابطه (۳) محاسبه می‌شود (Gao, 1996).

$$NDWI = \frac{NIR - MIR}{NIR + MIR} \quad (3)$$

طبقه‌بندی تصاویر

طبقه‌بندی را می‌توان یک فرآیند تصمیم‌گیری دانست که در آن داده‌های تصویری به فضای کلاس‌های مشخص انتقال می‌یابد. در حقیقت طبقه‌بندی یک نگاشت از فضای چندطیفی به فضای عوارض است (Arkhi & Adib-nejad, 2011). در پژوهش حاضر از طبقه‌بندی با ماشین‌های بردار پشتیبان^۱ (SVM) استفاده شد. دلیل عمده‌ی برتری نتایج SVM در مقایسه با سایر روش‌های طبقه‌بندی استفاده از ویژگی‌های هندسی داده‌های آموزشی به‌جای ویژگی آماری آن‌هاست. هدف SVM یافتن ابر صفحه‌ای است که به بهترین شکل هر دو کلاس ممکن را از یکدیگر جدا کند (Tso & Mather, 2009). در داده‌های تفکیک‌پذیر دو کلاس با قابلیت تفکیک‌پذیری خطی وجود دارد و داده‌های آموزشی برای این دو کلاس به‌صورت زوج‌های مرتب $\{x_i, y_i\}, i=1, \dots, n, y_i \in \{-1, +1\}, x_i \in R^d$ قابل بیان هستند. در این نوع نمایش x_i ویژگی‌های نقطه‌ی x_i و y_i برچسب کلاس برای این داده است. هدف SVM یافتن ابر صفحه بهینه‌ای است که دو کلاس را به گونه‌ای از هم جدا کند که فاصله نزدیک‌ترین نمونه‌های آموزشی از دو کلاس به این ابر صفحه، از یکدیگر بیشینه گردد، این فاصله اصطلاحاً حاشیه نامیده می‌شود (Tso & Mather, 2009). می‌توان هدف SVM را تعیین پارامترهای ابر صفحه به منظور بیشینه کردن این حاشیه دانست (Borges, 1998). از آنجا که کلاس در داده‌های سنجش از دور قابلیت تفکیک‌پذیری خطی ندارند باید از الگوریتم‌های غیر خطی برای تفکیک آن‌ها استفاده نمود. داده‌های گندم و آبی مزارع امزاجرد و کبودآهنگ به‌عنوان داده‌ی آموزشی الگوریتم SVM به‌کار رفت و سپس داده‌های ده ساله‌ی ماهواره‌های لندست و مادیس به‌عنوان داده‌ی آزمون به‌منظور طبقه‌بندی گندم و آبی وارد نرم‌افزار R گردید.

پیش‌بینی است. با توجه به این که با افزایش فعالیت گیاه میزان NDVI در سطح برگ تقریبی خواهد بود، شاخص EVI با توجه به در دسترس بودن آن در تصاویر ماهواره‌ای با دقت بالایی می‌تواند به تفکیک گندم آبی و دیم بپردازد.

شاخص پوشش گیاهی نرمال شده تفاضلی (NDVI)

در بین شاخص‌های سبزیگی‌های موجود، شاخص پوشش گیاهی نرمال شده تفاضلی (NDVI) بیشتر مورد استفاده قرار می‌گیرد این شاخص پاسخ گیاهان سالم و سبز را باند فروسرخ نزدیک و قرمز محاسبه می‌کند (Matsushita, Wei, Jin, Yuyichi, & Guoyn, 2007). دلیل این امر، خاصیت جذب نور قرمز توسط رنگدانه‌های موجود در کلروفیل است، که باعث می‌شود گیاهان انعکاس کمتری در این باند داشته باشند و انعکاس شدید NDVI گیاهان در بخش مادون قرمز طیف الکترومغناطیس است (Farjazadeh et al., 2005). شاخص از طریق رابطه (۱) محاسبه می‌گردد.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

مقادیر NDVI بین $[-1, 1]$ متغیر است. مقدار کلی این شاخص برای پوشش گیاهی تنک در محدوده 0.1 تا 0.5 ، معمولی و نیمه‌متراکم 0.1 تا 0.5 ، متراکم و غنی 0.5 به بالا، آب، برف و یخ دارای مقادیر منفی، خاک دارای مقادیر کمتر از 0.5 در مناطق پوشیده از ابر تقریباً برابر با صفر است (Schucknecht, Erasmi, Niemeier, & Matschullat, 2013). NDVI اثرات توپوگرافی و جوی را به حداقل می‌رساند (Mahmoud, Hasmadi, Alias, & Alias, 2016).

شاخص پوشش گیاهی بهبودیافته (EVI)

پوشش گیاهی بهبودیافته با استفاده از سیگنال‌های پوشش گیاهی در دامنه‌ی نمایه‌ی سطح برگ به‌وسیله‌ی استفاده از بازتاب طیف آبی برای تصحیح کاهش اثر جو و سیگنال‌های پس‌زمینه خاک برای افزایش دقت شاخص NDVI گسترش یافته است (Carlson, Gillies, & Perry, 1994). این شاخص برای شناسایی تغییرات ساختار گیاهان شامل شاخص سطح برگ، نوع و ساختار تاج پوششی گیاه بسیار کارآمد است (Huete et al., 2002). مقدار شاخص پوشش گیاهی بهبودیافته در محدوده $(+1)$ تا (-1) می‌باشد. شاخص از طریق رابطه (۲) محاسبه می‌گردد.

$$EVI = 2.5 * \frac{NIR - RED}{NIR + (6 * RED) + (7.5 * BLUE) + 1} \quad (2)$$

شاخص تفاضل آبی نرمال شده (NDWI)

این شاخص به دلیل حساس بودن به خصوصیات مختلف مانند محتوای آبی گیاه انتخاب شد (Gao, 1996). در حالی که NDVI

ندارد، زیرا حتی بدون مقیاس‌بندی داده، دقت خوبی باقی خواهد ماند. حتی در صورت فقدان بخش بزرگی از داده، الگوریتم‌های جنگل تصادفی دقت بالایی خواهند داشت.

نتایج و بحث

میزان NDVI و EVI مزرعه کشت آبی و دیم گندم در سال‌های ۲۰۱۵ تا ۲۰۱۹ محاسبه شد. شکل ۲ تا ۴ روند به‌دست آمده از تغییرات هر دو شاخص را توسط ماهواره‌های لندست ۸ و مادیس نشان می‌دهد. در زمستان ۲۰۱۶ و ۲۰۱۸ مقدار منفی شاخص‌ها در هر دو تصاویر لندست ۸ و مادیس مشاهده شد که به‌علت بارش برف طولانی مدت و یخبندان زمستانه بود. پیک کوچکی در نمودار NDVI دیم و آبی در ماه نوامبر مشاهده شد که به‌علت جوانه‌زدن اولیه برگ‌های گندم در زمستان می‌باشد و پیک بزرگ‌تر زمان بیشینه سبزی‌نگی را نشان می‌دهد که به‌ترتیب برای گندم آبی و دیم در ماه‌های مه و ژوئن اتفاق می‌افتد (برای نمونه عدد یکی از قله‌های NDVI در شکل‌های ۲ و ۳ نشان داده شده است). در مزرعه دیم نسبت به کشت آبی روند به‌دست آمده در دو ماهواره شیف‌ت داده شده و پیک‌های بلندتری را نشان می‌دهد. از طرف دیگر وضوح طیف در ماهواره لندست بیش از نتایج ماهواره مادیس بود که نتایج مشابه برای تفکیک مزارع دیم و آبی سیب‌زمینی تاییدی بر آن می‌باشد (Shamal & Weatherhead, 2014). نتایج کلی به‌دست آمده از شکل ۲ تا ۴ عبارتند از:



- ۱- روند افزایشی یا کاهش NDVI و EVI با توجه به زمان اخذ تصویر لزوماً روندی خطی با شیبی ثابت نیست. این مسئله می‌تواند به دلایلی مانند تغییرات پارامترهای هواشناسی باشد که گاهی موجب افزایش یا کاهش ناگهانی در مقادیر این شاخص‌ها می‌شود.
- ۲- با وجود غیرخطی بودن روند NDVI و EVI در طول زمان تقریباً در همه‌ی اراضی بیشینه‌ی سبزی‌نگی و توده‌ی گیاهی مطابق انتظار درست در زمان قبل از برداشت گندم یعنی دهه‌ی سوم اردیبهشت تا دهه‌ی اول خرداد ثبت شده است.
- ۳- یکی از مواردی که مطابق انتظار در همه‌ی نمودارها آمده است افت شدید NDVI و EVI بعد از اوج نهایی آن است که دلیل آن قطعاً زرد شدن و یا برداشت محصول است.
- در شکل ۵ بیشینه NDVI محاسبه شده از تصاویر ماهواره لندست و مادیس برای مزارع گندم دیم و آبی برای هر سال در بازه مورد مطالعه نشان داده شده است. از تصاویر Thematic Mapper (TM) لندست ۸ برای مقایسه مشخصات NDVI مزارع گندم آبی و دیم استفاده شد. زیرا اطلاعات مربوط به NDVI را با وضوح مکانی بالاتر (۳۰ متر) از MODIS (۲۵۰ متر) فراهم می‌کند. از طرف دیگر به‌دلیل پوشش ابر تصاویر لندست ۸ هم‌زمان از تصاویر مادیس هم

روش حداقل فاصله^۱ به‌عنوان روش دیگری برای طبقه‌بندی تصاویر مورد آزمون قرار گرفت. طبقه‌بندی حداقل فاصله برای طبقه‌بندی داده‌های تصویر ناشناخته به کلاس‌هایی که فاصله بین داده‌های تصویر و کلاس را در فضای چند ویژگی به حداقل می‌رساند، استفاده می‌شود. فاصله به‌عنوان شاخص شباهت تعریف می‌شود به‌طوری که حداقل فاصله با حداکثر شباهت یکسان است. استفاده از روش‌های طبقه‌بندی حداقل فاصله در مسائل سنجش از دور، مانند شناسایی گونه‌های زراعی، در نظر گرفته شده است. به‌طور خاص در طبقه‌بندی حداقل فاصله، یک نمونه (یعنی گروهی از بردارها) در گروهی طبقه‌بندی می‌شود که توزیع شناخته شده یا برآورد شده آن شباهت زیادی به توزیع تخمینی نمونه برای طبقه‌بندی دارد. اندازه‌گیری شباهت، اندازه‌گیری فاصله در فضای توابع توزیع است (Wacker & Landgrebe, 1972).

روش نظارت شده جنگل تصادفی در طبقه‌بندی فاکتورهای بیولوژیک عملکرد قابل قبولی ارائه می‌دهد (Pelletier et al., 2017). عملکرد این الگوریتم با شبیه‌سازی داده‌ها با درختان جنگل به‌دست می‌آید و درختان بیشتر به معنای جنگل مقاوم‌تر است. جنگل تصادفی یک الگوریتم یادگیری نظارت شده محسوب می‌شود. همانطور که از نام آن مشهود است، این الگوریتم جنگلی را به‌طور تصادفی می‌سازد. «جنگل» ساخته شده، در واقع گروهی از درخت‌های تصمیم^۲ است. کار ساخت جنگل با استفاده از درخت‌ها اغلب اوقات به روش کیسه‌گذاری^۳ انجام می‌شود. ایده اصلی روش کیسه‌گذاری آن است که ترکیبی از مدل‌های یادگیری، نتایج کلی مدل را افزایش می‌دهد. به‌طور مشابه، الگوریتم درخت تصادفی روی نمونه‌های داده، درختان تصمیم‌گیری می‌سازد و سپس از هر کدام از آن‌ها پیش‌بینی می‌گیرد و در نهایت به‌واسطه رای‌گیری، بهترین راه حل را انتخاب می‌کند. این یک روش گروهی است که از یک درخت تصمیم‌گیری مجزا بهتر است، زیرا با میانگین‌گیری در نتیجه، بیش برآزش^۴ را کاهش می‌دهد (Immitzer et al., 2016). جنگل تصادفی، تصادفی بودن افزوده‌ای را ضمن رشد درختان به مدل اضافه می‌کند. این الگوریتم، به جای جست‌وجو به دنبال مهم‌ترین ویژگی‌ها هنگام تقسیم کردن یک گره^۵، به دنبال بهترین ویژگی‌ها در میان مجموعه تصادفی از ویژگی‌ها می‌گردد. این امر منجر به تنوع زیاد و در نهایت مدل بهتر می‌شود. جنگل‌های تصادفی برای بازه وسیعی از عناصر داده، نسبت به درخت تصمیم‌گیری مجزا، عملکرد بهتری دارند. در الگوریتم جنگل تصادفی نیازی به مقیاس‌پذیری داده وجود



- 1- Minimum Distance
- 2- Decision Trees
- 3- Bagging
- 4- over-fitting
- 5- Node

واقع در کبودرآهنگ و مزرعه دیم واقع در امزاجرد نشان می‌دهد. مطابق شکل ۶ در زمستان‌های یخبندان میزان NDWI به ۰/۸ و بیشتر رسیده است (در شکل ۶ در ماه ژانویه برای کشت آبی NDWI=0.767 و در کشت دیم NDWI=0.736 دیده می‌شود).




شکل ۲- مقدار NDVI محاسبه شده از تصاویر ماهواره لندست ۸ در ۲۰۱۵-۲۰۱۹ مزرعه کشت گندم الف- دیم و ب- آبی

Fig.2. Calculated NDVI value from Landsat 8 satellite images in 2019-2015 A- Rainfed and B- Irrigated wheat farms



شکل ۳- مقدار NDVI محاسبه شده از تصاویر سنجنده مادیس در ۲۰۱۵-۲۰۱۹ مزرعه کشت گندم الف- دیم و ب- آبی

Fig.3. Calculated NDVI value from MODIS images in 2019-2015 A- Rainfed and B- Irrigated wheat farms



شکل ۴- مقدار EVI محاسبه شده از تصاویر سنجنده مادیس در ۲۰۱۵-۲۰۱۹ مزرعه کشت گندم الف- دیم و ب- آبی


Fig.4. Calculated EVI value from MODIS images in 2019-2015 A- Rainfed and B- Irrigated wheat farms

گرفت. همچنین استفاده از تصاویر طیفی (نوری و راداری) و تصاویر چند زمانه منجر به افزایش تعداد ویژگی‌ها در پردازش و در نتیجه افزایش دقت تحلیل نتایج گردید و از طرف دیگر سبب افزونگی اطلاعات طیفی و افزایش زمان محاسبه فرآیند طبقه‌بندی شد. برای جلوگیری از این تأثیر شاخص‌های ماهانه تجمعی محاسبه شد. استفاده از شاخص‌های تجمعی نشان‌دهنده عملکرد گیاه است و ارتباط


استفاده شد. همان‌طور که انتظار می‌رفت تفاوت آشکاری در شاخص‌های سبزیگی محاسبه شده مشاهده نشد و تفکیک کشت دیم و آبی تنها بر مبنای NDVI مشکل می‌باشد. بنابراین از NDWI برای تعیین محتوای آبی گندم استفاده شد تا از این طریق بتوان گندم آبی را تشخیص داد. شکل ۶ شاخص محاسبه شده را برای مزرعه آبی

تفاوت معنی‌داری در نمودار در دوره رشد کامل مشاهده می‌شود (NDWI < 0.40). این تفاوت در سال‌های ۲۰۱۵ و ۲۰۱۷ بیشتر است و پس از آن با زرد شدن گندم مقدار NDWI کاهش می‌یابد. اما تفاوت گندم دیم و آبی از نظر چگالی طیفی NDWI چندان محسوس نبود اگرچه زمان وقوع بیشینه و کمینه شاخص‌های NDWI و NDVI گندم دیم و آبی متفاوت می‌باشد که مبنای تفکیک آن‌ها قرار



رشد گندم در بیشینه سبزی‌نگی بین گندم آبی و دیم متفاوت است.



بین رشد گیاه و شاخص‌های طیفی تجمعی توسط داده‌های سنجش از دور به اثبات رسیده است (Myneni & Williams, 1994). مطابق مطالعات پیشین (Dong et al., 2003) فرض شد که سرعت و دامنه



شکل ۵- مقدار NDVI بیشینه محاسبه شده از تصاویر الف- سنجنده مادیس و ب- ماهواره لندست ۸ در ۲۰۱۵-۲۰۱۹
Fig.5. Calculated maximum NDVI from images of A- MODIS and B- Landsat 8 satellite in 2019-2015



شکل ۶- مقدار NDVI محاسبه شده از تصاویر ماهواره لندست در ۲۰۱۵-۲۰۱۹ مزرعه کشت گندم الف- دیم و ب- آبی
Fig.6. Calculated NDVI from Landsat satellite images in 2019-2015 A- Rainfed and B- Irrigated wheat farms

در این پژوهش از تابع هسته RBF به‌عنوان تابع هسته پایه ماشین بردار پشتیبان استفاده شد. در توابع RBF تنها پارامترهایی که باید تعیین شود، پارامتر C و γ است. هدف این است که مقادیر بهینه دو پارامتر C و γ برای کاربرد مورد نظر مشخص شود به گونه‌ای که ماشین بتواند داده‌های تست را با دقت خوبی پیشگویی کند و از بیش برآزش جلوگیری کند. یکی از روش‌های ساده برای انتخاب پارامترهای مناسب تابع هسته با استفاده از روش اعتبارسنجی متقابل است. در این پژوهش برای تعمیم طبقه‌بندی سه ماشین بردار پشتیبان از روش یکی در مقابل همه استفاده و ۷۰٪ داده‌ها جهت آموزش و ۳۰٪ داده‌ها جهت آزمایش در نظر گرفته شده است (Gupta, Das, Hellerstein, & Raskar, 2018). مقادیر C و γ به ترتیب ۲ و 2^{-2} در نظر گرفته شد. طبقه‌بندی‌کننده حداقل فاصله از میانگین (MD) نیز برای جداسازی و تفکیک دو کلاس گندم آبی و دیم به کار رفت. در این تکنیک ابتدا میانگین همه طبقه‌ها که قبلاً با استفاده از روش تعیین نواحی تعلیمی از همدیگر تفکیک گردیده‌اند، تعیین و سپس فاصله اقلیدسی بازتاب هر پیکسل را از میانگین تمام طبقه‌ها محاسبه می‌کنند. سپس هر پیکسل به طبقه‌ای تعلق می‌گیرد که کمترین مقدار فاصله را تا میانگین آن طبقه داشته باشد.

تفکیک کشت گندم دیم و آبی از سایر محصولات

بر اساس اطلاعات به‌دست آمده از تصاویر مزارع گندم دیم و آبی، لایه وکتوری استان همدان به‌عنوان ورودی سامانه GEE در نظر گرفته شد. سپس از تصاویر ماهواره لندست در سال‌های ۲۰۱۵-۲۰۱۹ مجموعه شاخص‌ها استخراج شد و در نتیجه کل استان به سه منطقه زیر کشت گندم دیم، گندم آبی و پوشش گیاهی غیر از دو کلاس قبلی (سایر محصولات و باغات) تقسیم گردید. با استفاده از الگوریتم SVM تفکیک این سه کلاس انجام شد. اساساً طبقه‌بندی‌کننده ماشین بردار پشتیبان یک جداکننده دودویی است. رهیافت کلی کاهش مسئله سه کلاسه در این پژوهش به چندین مسئله دودویی برای مسائل سه کلاسه است. هر یک از مسائل با یک جداکننده دودویی حل شد. سپس خروجی جداکننده‌های دودویی ماشین بردار پشتیبان با هم ترکیب شده و به این ترتیب مسئله سه کلاسه حل شد. یکی از مسائلی که در ماشین بردار پشتیبان غیرخطی با آن مواجه هستیم، نحوه تعریف هسته و پارامترهای مرتبط با آن است. دسته شناخته شده‌ای از توابع هسته چون هسته چندجمله‌ای، RBF معرفی شده‌اند که نیازمند تنظیم شدن پارامترها جهت کارایی مطلوب است.

می‌باشد، با این وجود برای اطمینان بیشتر چگونگی انطباق عوارض بدون تغییر تصویر با تصویر ETM بررسی شد. محاسبه سطح زیر کشت گیاه زعفران نشان داد که دقت این روش نسبت به سایر روش‌های طبقه‌بندی مورد تایید می‌باشد و میزان خطای آن پایین است (Rahimzadegan & Pourgholam, 2016). جدول ۱ و ۲ نتایج ماتریس اغتشاش الگوریتم SVM و MD را برای سال‌های مورد مطالعه به ترتیب در دو گندم دیم و آبی و سه کلاس (گندم دیم و آبی و سایر کشت‌ها) نشان می‌دهد. همانطور که مشاهده می‌شود (جدول ۱) ۱۰٪ کلاس گندم دیم در هیچ‌یک از دو کلاس نمی‌گنجد. به همین دلیل سه کلاس تعریف شد تا ۱۰۰٪ محصولات در طبقه‌بندی قرار بگیرد. نتایج قدرت تفکیک مناسبی با دقت ۰/۷۳۷ و ۰/۹۴۵ را به ترتیب در دو و سه کلاس نشان می‌دهند.

در این مطالعه برای ثبت تصاویر مزارع به تعداد قابل قبول و با پراکنش مناسب نقاط کنترل روی تصویر انتخاب شد. برای یافتن رابطه مختصاتی بین نقاط کنترل زمینی و پیکسل‌های تصویر از معادله چند جمله‌ای درجه اول و نمونه‌برداری مجدد به روش نزدیک‌ترین همسایه استفاده شد. در طبقه‌بندی تصویر، استفاده از روش نزدیک‌ترین همسایه که کمترین اثر را روی درجات خاکستری دارد، می‌تواند انتخاب مناسب‌تری نسبت به روش‌های دیگر باشد. چرا که ایجاد درجات خاکستری غیر واقعی گاه روش‌های طبقه‌بندی را به اشتباه می‌اندازد. در این روش عملاً هیچ‌گونه محاسبه‌ای انجام نمی‌پذیرد و از مقادیر حقیقی موجود در تصویر استفاده می‌شود، بنابراین ارقام جدیدی که گاه ممکن است غیر واقعی باشند را تولید نمی‌نماید (Fatemi & Rezaee, 2005). هرچند خطای میانگین مربعات کمتر از یک پیکسل مقدار قابل قبولی

جدول ۱- ماتریس اغتشاش تفکیک گندم دیم و آبی در کل استان همدان

Table 1- Confusion matrix of separation of rainfed and irrigated wheat in the whole province of Hamadan

ماتریس اغتشاش Confusion matrix	گندم آبی Irrigated wheat	گندم دیم Rainfed wheat
گندم آبی Irrigated wheat	70%	30%
گندم دیم Rainfed wheat	20%	70%

جدول ۲- ماتریس اغتشاش تفکیک گندم دیم و آبی و سایر محصولات در کل استان همدان

Table 2- Confusion matrix of separation of rainfed and irrigated wheat from other crops in the whole province of Hamadan

ماتریس اغتشاش Confusion matrix	گندم آبی Irrigated wheat	گندم دیم Rainfed wheat	سایر محصولات Other crops
گندم آبی Irrigated wheat	90%	10%	0
گندم دیم Rainfed wheat	10%	80%	10%
سایر محصولات Other crops	0	10%	90%

۲۰۱۶ آغاز شده است تهیه نقشه کشت دیم و آبی و همچنین محاسبه سطح زیر کشت در سال ۲۰۱۶ انجام شد. شکل‌های ۷ نقشه مزارع زیرکشت دیم و آبی بر اساس الگوریتم‌های جنگل تصادفی را نشان می‌دهد. تغییرات رنگ‌ها در نقشه‌ها حاکی از آن است که در نقشه پایه رنگ سبز کشت دیم و رنگ نارنجی تا قهوه‌ای کشت آبی را نشان می‌دهد. در نقشه grayscale رنگ سفید مناطق کشت دیم و مناطق خاکستری مناطق تحت کشت آبی را فارغ از نوع محصول نشان می‌دهد. در نقشه به‌دست‌آمده از ماهواره‌ها مینا محاسبه NDVI بود و همانطور که مشاهده می‌شود دقت پیکسل‌ها نسبت به نقشه مینا

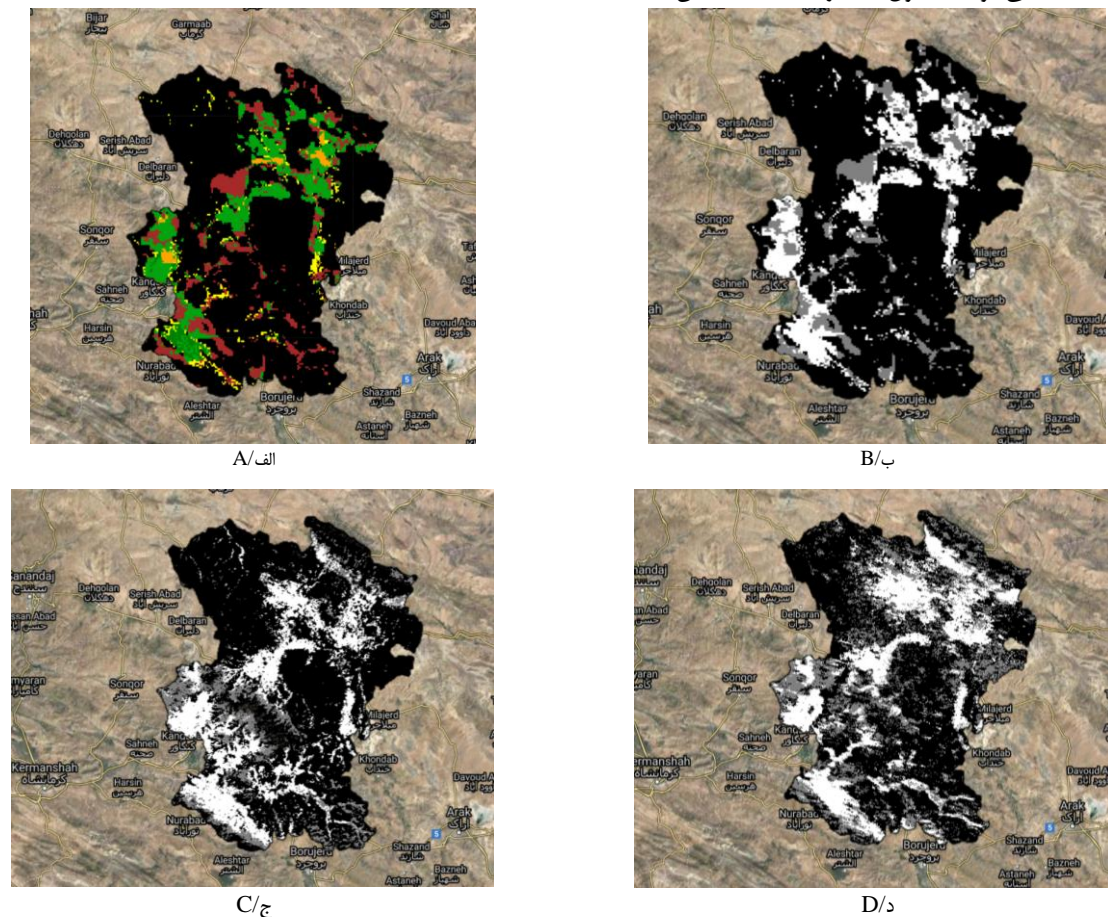
با توجه به شباهت گندم دیم و آبی، رشد فنولوژیکی سبزیگی در گندم دیم و آبی ملاک عمل قرار گرفت. در مرحله بعدی با استخراج ویژگی‌های تصاویر از مزارع مورد مطالعه، سطح زیر کشت گندم دیم و آبی در کل سطح استان همدان پیش‌بینی شد.

محاسبه مساحت زیرکشت دیم و آبی گندم استان همدان

به‌منظور محاسبه مساحت زیرکشت گندم علاوه بر سنجنده مادیس، ماهواره سنتینل ۳ با توجه به توانایی تشخیص دقیق کلروفیل به کار رفت. با توجه به این‌که تصویربرداری ماهواره سنتینل ۳ از سال

سنتینل ۳ می‌باشد که مساحت بیشتری برای محصولات دیم و آبی پیش‌بینی می‌کند.

افزایش یافته است. به‌علاوه در نقشه به‌دست آمده از تصاویر ۱۶ روزه ماهواره سنتینل ۳ به‌علت توانایی تشخیص کلروفیل و توان تفکیک طیفی در ۲۱ باند در محدوده مرئی تا مادون قرمز نزدیک، کشت‌های پراکنده نیز مشاهده می‌شوند. جدول ۳ نیز تاییدکننده این قابلیت



شکل ۷- تفکیک کشت دیم و آبی در استان همدان الف- نقشه RGB پایه ب- نقشه Grayscale پایه، ج- تصویر سنجنده مادیس، د- تصویر ماهواره سنتینل

Fig. 7. Separation of rainfed and irrigated crops in Hamedan province A- Basic RGB map B- Grayscale basic map, C- MODIS image, D- Sentinel satellite image

تفکیک محصولات زراعی و باغی را انجام داد و یا مساحت زیر کشت هر کدام را محاسبه نمود (Ajadi et al., 2021; Nguyen et al., 2020). علت دیگر تفاوت تصاویر با داده‌های زمینی می‌تواند بازه طولانی مدت برداشت با توجه به شرایط اقلیمی حاکم در کل استان باشد به این ترتیب که گندم شهرستان‌های جنوبی زودتر برداشت می‌شوند که در مقایسه با مزارع گندم شمال استان همدان بازه برداشت به حدود ۴۵ تا ۵۰ روز می‌رسد. در نتیجه تصویری که برای مثال در اردیبهشت ماه برداشت می‌شود بازتاب رنگ زرد خوشه‌های رسیده گندم جنوب استان را نشان می‌دهد در حالی که در همین تاریخ گندم‌های شمال استان هنوز سبز هستند و یک ماه یا بیشتر تا زمان

جدول ۳ مساحت زیر کشت کل محصول را در ۲۰۱۶ نشان می‌دهد. با توجه به این که احتمال دیده شدن مزارع با وسعت پایین در تصاویر ماهواره سنتینل ۳ با قدرت تفکیک مکانی ۵۰۰ و سنجنده مادیس با توان ۲۵۰ متر کمتر می‌باشد و از طرف دیگر آمار کشت خرده مالکان در مرکز تحقیقات کشاورزی و سازمان جهاد کشاورزی استان ثبت نشده است امکان بررسی دقیق داده‌های زمینی با نتایج به‌دست آمده وجود ندارد. در بسیاری از مقالات (Pageot et al., 2020; Sepulcre-Canto et al., 2008) موجود در مراکز کشاورزی می‌توان حتی با تصاویر به‌دست آمده از یک سنجنده و تنها یکی از الگوریتم‌های موجود با دقت قابل قبولی

برداشت آن‌ها باقی است. این تفاوت‌ها در مزارع استان قدس رضوی به‌منظور تفکیک غلات، محصولات جالیزی و باغات دیده شد (Alipour et al., 2014).

جدول ۳- مساحت زیرکشت محصولات دیم و آبی در کل استان همدان

Table 3. Area of cultivation of rainfed and irrigated crops in the whole province of Hamadan

مساحت Area (km ²)	محصولات آبی irrigated crops	محصولات دیم Rainfed crops
ماهواره سنتینل ۳ Sentinel 3	4700.7020	4219.0875
سنجنده مادیس Modis	4265.1152	4157.1207

نتیجه‌گیری

نتایج این پژوهش نشان داد روش مناسب برای تفکیک گندم دیم و آبی استفاده همزمان از چند شاخص می‌باشد. همچنین بیشترین تمایز در بیشینه سبزینه‌گی یعنی حدود یک ماه پیش از برداشت می‌باشد. الگوریتم‌های طبقه‌بندی MD و SVM می‌تواند با دقت ۹۰٪ و ۸۰٪ (جدول ۲) به‌ترتیب گندم آبی و دیم را از سایر محصولات تشخیص دهد. از قابلیت سنجنده‌های مختلف برای این جداسازی استفاده شد و درنهایت مساحت زیر کشت محصولات آبی و دیم استان استخراج گردید. این اطلاعات برای برآورد میزان مصرف انرژی

و استفاده از نهاده‌ها و میزان نیاز به ماشین‌های کشاورزی مفید می‌باشند. نقشه تفکیک محصولات آبی و دیم استان بر اساس الگوریتم جنگل تصادفی با استفاده از تصاویر ماهواره سنتینل ۳ به‌دست آمد که می‌تواند میزان باروری زمین‌های کشاورزی استان را نشان می‌دهد. پیشنهاد می‌گردد این نقشه‌ها به تفکیک محصولات استراتژیک و در سال‌های مختلف استان تهیه شود تا بتوان میزان تولید خالص استان همدان از هر محصول را برآورد نمود. همچنین می‌توان توانایی سایر سنجنده‌ها و ماهواره‌ها و یا سایر شاخص‌های گیاهی را در تفکیک کشت گندم دیم و آبی مطالعه نمود.

References

- Ajadi A. O., Barr, J., Liang, S. Z., Ferreira, R., Kumpatla, S. P., Patel, R., & Swatantran, A. (2021). Large-scale crop type and crop area mapping across Brazil using synthetic aperture radar and optical imagery. *International Journal of Applied Earth Observations and Geoinformation*, 97, 1-16. <https://doi.org/10.1016/j.jag.2020.102294>
- Akbari, M., Mamanpoush, A. R., Gieske, A., Miranzadeh, M., Torabi, M., & Salemi, H. R. (2006). Crop and land cover classification in Iran using Landsat 7 imagery. *International Journal of Remote Sensing*, 27(19), 4117-4135. <https://doi.org/10.1080/01431160600784192>
- Alexandridis, T. K., Zalidis, G. C., & Silleos, N. G. (2008). Mapping irrigated area in Mediterranean basins using low cost satellite Earth Observation. *Computers and Electronics in Agriculture*, 64(2), 93-103. <https://doi.org/10.1016/j.compag.2008.04.001>
- Alipour, F., Agh-Khani, M. H., Abbaspour-Fard, M. H., & Sepehr, A. (2014). Limiting and estimating the area under cultivation of agricultural products to help satellite images (Case study: Astan Quds Razavi sample farm). *Journal of Agricultural Machinery*, 4(2), 244-254. (in Persian). <https://doi.org/10.22067/jam.v4i2.34827>
- Arekhi, S., & Adib-nejad, M. (2011). Evaluating the efficiency of support vector machine algorithms for land use classification using Landsat + ETM satellite data (Case study: Ilam area). *Iranian Range and Desert Research*, 3(44), 420-440. (in Persian).
- Bazzi, H., Baghdadi, N., Ienco, D., El Hajj, M., Zribi, M., Belhouchette, H., Escorihuela, M. J., & Demarez, V. (2019). Mapping Irrigated Areas Using Sentinel-1 Time Series in Catalonia, Spain. *Remote Sensing*, 11, 1836. <https://doi.org/10.3390/rs11151836>
- Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2, 121-167.
- Carlson, T. N., Gillies, R. R., & Perry, E. M. (1994). A method to make use of thermal infrared temperature and NDVI measurements to infer surface soil water content and fractional vegetation cover. *Remote Sensing Reviews*, 9(1-2), 161-173. <https://doi.org/10.1080/02757259409532220>
- Cheng, Y. B., Zarco-Tejada, P. J., Riaño, D., Rueda, C. A., & Ustin, S. L. (2006). Estimating vegetation water content with hyperspectral data for different canopy scenarios: Relationships between AVIRIS and MODIS indexes. *Remote Sensing of Environment*, 105(4), 30 2006, 354-366
- Delloye, C., Weiss, M., & Defourny, P. (2018). Retrieval of the canopy chlorophyll content from Sentinel-2

- spectral bands to estimate nitrogen uptake in intensive winter wheat cropping systems. *Remote Sensing of Environment*, 216, 245-261. <https://doi.org/10.1016/j.rse.2018.06.037>
11. Demarez, V., Helen, F., Marais-Sicre, C., & Baup, F. (2019). In-Season Mapping of Irrigated Crops Using Landsat 8 and Sentinel-1 Time Series. *Remote Sensing*, 11(2), 118. <https://doi.org/10.3390/rs11020118>
 12. Dong, J., Kaufmann, R. K., Myneni, R. B., Tucker, C. J., Kauppi, P. E., Liski, J., Buermann, W., Alexeyev, V., & Hughes, M. K. (2003). Hughes. Remote sensing estimates of boreal and temperate forest woody biomass: Carbon pools, sources, and sinks. *Remote Sensing of Environment*, 84, 393-410. [https://doi.org/10.1016/S0034-4257\(02\)00130-X](https://doi.org/10.1016/S0034-4257(02)00130-X)
 13. Droogers, P. 2002. Global irrigated area mapping: overview and recommendations, Working Paper 36, International Water Management Institute. Colombo, Sri Lanka.
 14. Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Famiglietti, J. S., & Rodell, M. (2013). Water in the balance. *Science* 340(6138), 1300-1301. <https://doi.org/10.1126/science.1236460>
 15. Farajzadeh, M. (2005). *Drought from Concept to Solutions*. National Geographical Organization Publication.
 16. Fatemi, S. B., & Rezaee, F. (2005). *Fundamental of Remote Sensing*. 1st Pub, Azade Publication. Tehran.
 17. Ferrant, S., Selles, A., Le Page, M., Herrault, P. A., Pelletier, C., Al-Bitar, A., Mermoz, S., Gascoin, S., Bouvet, A., & Saqalli, M. (2017). Detection of irrigated crops from Sentinel-1 and Sentinel-2 data to estimate seasonal groundwater use in south India. *Remote Sensing*, 9, 11-19. <https://doi.org/10.3390/rs9111119>
 18. Gao, B. C. (1996). NDWI-A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing Environment*, 58, 257-266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
 19. Gao, F., Schaaf, C. B., Strahler, A. H., Roesch, A., Lucht, W., & Dickinson R. (2005). MODIS bidirectional reflectance distribution function and albedo climate modeling grid products and the variability of albedo for major global vegetation types. *Journal of Geophysical Research Atmospheres*, 110, 1-13. <https://doi.org/10.1029/2004JD005190>
 20. Giannini, A., & Bagnoni, V. (2000). Schede di tecnica irrigua per l'agricoltura toscana. ARSIA- Servizio Telematico Irrigazione. Regione Toscana, EFFEMME Lito, Firenze, pp. 66-97 ISBN 88-8295-015-018.
 21. Gupta, O., Das, A. J., Hellerstein, J., & Raskar, R. (2018). Machine Learning approaches for large scale classification of produce, Scientific Reports Massachusetts Institute of Technology, Cambridge, MA, 02139, USA. pp. 8:5226. DOI: <https://doi.org/10.1038/s41598-018-23394-3>
 22. Guzinski, R., & Nieto, H. (2019). Evaluating the feasibility of using Sentinel-2 and Sentinel-3 satellites for high-resolution evapotranspiration estimations. *Remote Sensing of Environment*, 221, 157-172. <https://doi.org/10.1016/j.rse.2018.11.019>
 23. Hartmann, D. L., Tank, A. M. K., Rusticucci, M., Alexander, L. V., Brönnimann, S., Charabi, Y. A. R., Dentener, F. J., Dlugokencky, E. J., Easterling, D. R., & Kaplan, A. (2013). Observations: atmosphere and surface. Climate Change 2013 the Physical Science Basis: Working Group I Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, UK.
 24. Heenkenda, M. K., Joyce, K. E., Maier, S. W., & De Bruin, S. (2015). Quantifying mangrove chlorophyll from high spatial resolution imagery. *ISPRS Photogrammetry of Remote Sensing*, 108, 234-244. <https://doi.org/10.1016/j.isprsjprs.2015.08.003>
 25. Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213.
 26. Immitzer, M., Vuolo, F., Atzberger, C., Immitzer, M., Vuolo, F., & Atzberger, C. (2016). First experience with Sentinel-2 data for crop and tree species classifications in central Europe. *Remote Sensing*, 8, 166. <https://doi.org/10.3390/rs8030166>
 27. Mahmoud, A. M. A., Hasmadi, M., Alias, M. S., & Alias, M. A. (2016). Rangeland degradation assessment in the south slope of the Al-Jabal Al-Akhdar, northeast Libya using remote sensing technology. *Rangeland Science*, 6(1), 73-81.
 28. Martimort, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25-36.
 29. Matsushita, B., Wei, Y., Jin, C., Yuyichi, O., & Guoyn, Q. (2007). Sensivity of the enhanced vegetation index (EVI) and NDVI to topographic effects: A case study in high-density Cypress forest. *Sensors*, 7(11), 2636-2651. <https://doi.org/10.3390/s7112636>
 30. Morfitt, R., Barsi, J., Levy, R., Markham, B., Micijevic, E., Ong, L., Scaramuzza, P., & Vanderwerff, K. (2015). Landsat-8 operational land imager (OLI) radiometric performance on-orbit. *Remote Sensors*, 7, 2208-2237.
 31. Myneni, R., & Williams, D. (1994). On the relationship between FAPAR and NDVI. *Remote Sensing of Environment*, 49, 200-211. [https://doi.org/10.1016/0034-4257\(94\)90016-7](https://doi.org/10.1016/0034-4257(94)90016-7)
 32. Nguyen, T. T., Hoang, T. D., Pham, M. T., Vu, T. T., Nguyen, T. H., Huynh, Q. T., & Jo, J. (2020). Monitoring agriculture areas with satellite images and deep learning. *Applied Soft Computing*, 95, 1-16. <https://doi.org/10.1016/j.asoc.2020.106565>

33. Pageot, Y., Bau, 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, 1-19. <https://doi.org/10.3390/rs12183044>
34. Pastor-Guzman, J., Brown, L., Morris, H., Bourg, L., Goryl, P., Dransfeld, S., & Dash, J. (2020). The sentinel-3 OLCI terrestrial chlorophyll index (OTCI): algorithm improvements, spatiotemporal consistency and continuity with the MERIS archive. *Remote Sensing*, 12, 2652-2674. <https://doi.org/10.3390/rs12162652>
35. Pelletier, C., Valero, S., Inglada, J., Champion, N., Marais Sicre, C., & Dedieu, G. (2017). Effect of Training Class Label Noise on Classification Performances for Land Cover Mapping with Satellite Image Time Series. *Remote Sensing*, 9, 173. <https://doi.org/10.3390/rs9020173>
36. Peña-Arancibia, J. L., McVicar, T. R., Paydar, Z., Li, L., Guerschman, J. P., Donohue, R. J., Dutta, D., Podger, G. M., van Dijk, A. I. J. M., & Chiew, F. H. S. (2014). Dynamic identification of summer cropping irrigated areas in a large basin experiencing extreme climatic variability. *Remote Sensing of Environment*, 154, 139-152. <https://doi.org/10.1016/j.rse.2014.08.016>
37. Rahimzadegan, M., & Pourgholam, M. (2016). Determining the area under saffron cultivation using Landsat images (Case study: City Torbat Heydariyeh). *Remote Sensing and GIS in Natural Resource*, 7(4), 97-115. (in Persian). <https://doi.org/10.22048/jsat.2017.48518.1194>
38. Schucknecht, A., Erasmi, S., Niemeyer, I., & Matschullat, J. (2013). Assessing vegetation variability and trends in north-eastern Brazil using AVHRR and MODIS NDVI time series. *Remote Sensing*, 46, 40-59. <https://doi.org/10.5721/EuJRS20134603>
39. Sepulcre-Canto, G., Zarco-Tejada, P. J., Sobrino, J. A., Berni, J. A. J., Jimenez-Munoz, J. C., & Gastellu-Etchegorry, J. P. (2008). Discriminating irrigated and rainfed olive orchards with thermal ASTER imagery and DART 3D simulation. *Agricultural and Forest Meteorology*, 149, 962-975. <https://doi.org/10.1016/j.agrformet.2008.12.001>
40. Shamal, S. A. M., & Weatherhead, K. (2014). Assessing spectral similarities between rainfed and irrigated croplands in a humid environment for irrigated land mapping. *IP Publication Ltd*, 43(2), 109-114. <https://doi.org/10.5367/oa.2014.0168>
41. Tso, B., & Mather, P. (2009). *Support Vector machines, in Classification Methods for Remotely sensed Data*. 1st ed: CRC Press: 125-153.
42. Vogel, E., Donat, M. G., Alexander, L. V., Meinshausen, M., Ray, D. K., Karoly, D., Meinshausen, N., & Frieler, K. (2019). The effects of climate extremes on global agricultural yields. *Environmental Research Letters*, 14(5), 1-13. <https://doi.org/10.1088/1748-9326/ab154b>
43. Vuolo, F., Dash, J., Curran, P. J., Lajas, D., & Kwiatkowska, E. (2012). Methodologies and uncertainties in the use of the terrestrial chlorophyll index for the Sentinel-3 mission. *Remote Sensing*, 4, 1112-1133. <https://doi.org/10.3390/rs4051112>
44. Vuolo, F., Neuwirth, M., Immitzer, M., Atzberger, C., & Ng, W. T. (2018). How much does multi-temporal Sentinel-2 data improve crop type classification? *Applied Earth Observation and Geo-information*, 72, 122-130. <https://doi.org/10.1016/j.jag.2018.06.007>
45. Wacker, A. G., & Landgrebe, D. A. (1972). *Minimum Distance Classification in Remote Sensing*. LARS Technical Reports. Paper 25. <https://docs.lib.purdue.edu/larstech/25>
46. Wardlow, B. D., Egbert, S. L., & Kastens, J. H. (2007). Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains. *Remote Sensing of Environment*, 108(3), 290-310. <https://doi.org/10.1016/j.rse.2006.11.021>