

Original Article



Iranian Remote Sensing GIS
Journal of Sensing

Potato Fields Mapping Based on the Phenology Feature and Support Vector Machine Utilizing Google Earth Engine Platform

Salman Goodarzashti*, Mohamad Seifi, Mahshid Kohandel, Davoud Ashourloo, Hossein Aghighi

Affiliation

Center for Remote Sensing and GIS Research, Faculty of Earth Sciences, Shahid Beheshti University, Tehran, Iran

ABSTRACT

Introduction: Potato is the fourth most cultivated crop worldwide. In terms of its strategic role in food security, accurate potato mapping provides essential information for national crop censuses and potato yield estimation and prediction at any scale. Although remote sensing (RS) approaches based on optical and/or microwave sensors have been widely employed to monitor cultivated lands (including crop area, conditions, and yield forecasting), the identification of potato planting areas using RS data and machine learning has not been much addressed. As a result, the present research addresses the literature gap by suggesting an effective potato mapping approach in Iran's main production center and tries to provide accurate information on the cultivated areas of this crop for the field of agricultural management.

Material and Methods: Since most crops have specific spectral and temporal characteristics during their cultivation period, this research has presented a method to discriminate potato fields from other crops using time series images without explicit thresholding. This method identified this product by using layers based on potato phenology and machine learning. We employed the ground truth data of the crop types from the studied site, which included a total of 1648 samples of potato fields and other crops, to optimize the internal parameters of the algorithm, train, and evaluate the model. A handheld GPS receiver was used to collect this data. This research employed Sentinel-2 satellite images and the Support Vector Machine (SVM) algorithm to map potato fields. To accurately identify potato fields, we prepared appropriate input layers, including the phenological index of the potato crop and the median statistical index of NDVI (time series of Sentinel-2 satellite images) at specific intervals. We used these layers as inputs to the SVM. We optimized the gamma and C values using the 5-fold cross-validation method to train the optimal model for SVM using the RBF kernel. We then used these values in the algorithm implementation process under the Google Earth Engine cloud computing platform. We assessed the efficacy of the suggested approach in the Iranian cities of Hamedan and Bahar, key sites for the cultivation of this particular crop.

Results and Discussion: Based on the results, the optimal values for the internal parameters of the model ($C = 70$ and $\gamma = 0.3$) were calculated. We included these values in the RBF function to identify the cultivated areas of the potato crop. By implementing the classification algorithm and then applying the majority filter, a map of the areas under potato cultivation was prepared for the study area. This map showed the highest density of potato cultivation in the border area of two cities (northwest of Hamedan city and east of Bahar city). The calculated total area for potato farming was 4527.1 hectares in Hamedan city and 6088.3 hectares in Bahar city. The estimated overall accuracy and Kappa coefficient are 90.9% and 0.82 for Hamedan and 93.3% and 0.87 for Bahar, respectively. The present research's results demonstrate the effectiveness of the SVM algorithm in detecting potato cultivation areas, highlighting the potential of using indicators corresponding to potato phenology as distinguishing features for improved identification.

Conclusion: By employing the SVM method, we effectively identified potato fields by utilizing layers of indicators that correspond to crop phenology. At the trial stage, it was demonstrated that this method can improve the potato acreage mapping process. Therefore, a similar approach can be evaluated for identifying other important crops in other regions. It is also suggested that the efficiency of microwave data and other machine learning algorithms be considered in future research.

Keywords: Crop mapping, Potato, Sentinel-2 Time Series, Google Earth Engine Platform, Support Vector Machine.

Citation:

Goodarzashti, S., Seifi, M., Kohandel, M., Ashourloo, D., Aghighi, H., Potato Fields Mapping Based on the Phenology Feature and Support Vector Machine Utilizing Google Earth Engine Platform, Iran J Remote Sens GIS. 17(1):1-22.

* Corresponding Author: s.goodarzashti@alumni.sbu.ac.ir
DOI: <https://doi.org/10.48308/GISJ.2023.103148>

Received: 2022.12.05
Accepted: 2023.02.01





شناسایی مزارع سیب‌زمینی بر مبنای شاخص فنولوژی و الگوریتم ماشین بردار پشتیبان با استفاده از سامانه رایانش ابری Google Earth Engine

سلیمان گودرزدشتی^{۱*}، محمد سیفی، مهشید کهندل، داود عاشورلو، حسین عقیقی

سمت

مرکز مطالعات سنجش از دور و GIS،

دانشکده علوم زمین، دانشگاه شهید

بهشتی، تهران، ایران

چکیده

سابقه و هدف: سیب‌زمینی چهارمین محصول کشت‌شده در جهان است. با توجه به اهمیت استراتژیک این محصول در تأمین امنیت غذایی، تهیه نقشه‌های دقیق از سطوح زیرکشت آن اطلاعات ضروری برای تخمین و پیش‌بینی میزان عملکرد محصول در مقیاس‌های متفاوت را فراهم می‌کند. اگرچه تا کنون رویکردهای متفاوت سنجش از دور، مبتنی بر سنجنده‌های اپتیکی یا مایکروویو، به‌طور گسترده برای پایش مزارع گوناگون (شامل سطح زیرکشت محصولات، شرایط و پیش‌بینی عملکرد آنها) به کار رفته، با استفاده از داده‌های سنجش از دور و یادگیری ماشین کمتر برای شناسایی مزارع سیب‌زمینی اقدام شده است. در این راستا، پژوهش حاضر به شناسایی و نگاشت محصول سیب‌زمینی در قطب تولید آن در کشور پرداخته است و سعی در مهیاسازی اطلاعات دقیق سطوح زیرکشت این محصول، برای حوزه مدیریت کلان کشاورزی را دارد.

مواد و روش‌ها: از آنجاکه بیشتر محصولات کشاورزی، در طول دوره کشت، ویژگی‌های طیفی- زمانی منحصربه‌فردی دارند، این پژوهش با استفاده از تصاویر سری زمانی و بدون آستانه‌گذاری صریح، روشی را برای تمایز دادن مزارع سیب‌زمینی از سایر محصولات مطرح کرده است. طبق این روش، با استفاده از لایه‌های مبتنی بر فنولوژی محصول سیب‌زمینی و نیز یادگیری ماشین، به شناسایی این محصول روی آورده شد. به‌منظور بهینه‌سازی پارامترهای داخلی الگوریتم، براساس داده‌های زمینی نوع محصول در سایت مورد مطالعه که مجموعاً شامل ۱۶۴۸ نمونه از مزارع سیب‌زمینی و سایر محصولات می‌شود، آموزش و ارزیابی مدل انجام شد. این داده‌ها با استفاده از گیرنده GPS دستی نمونه‌برداری شد. در این پژوهش، نگاشت مزارع سیب‌زمینی با استفاده از تصاویر ماهواره سنتینل-۲ و الگوریتم ماشین بردار پشتیبان انجام شد. با تهیه لایه‌های ورودی مناسب که شامل شاخص فنولوژیکی محصول سیب‌زمینی و شاخص آماری میانه NDVI (سری زمانی تصاویر ماهواره سنتینل-۲) در بازه‌های مشخص می‌شود، مزارع سیب‌زمینی با دقت شناسایی شد. در ادامه، این لایه‌ها به‌منزله ورودی‌های ماشین بردار پشتیبان به کار رفت. به‌منظور آموزش مدل بهینه برای ماشین بردار پشتیبان با استفاده از کرنل RBF، مقادیر γ و C با روش 5-fold cross validation بهینه‌سازی شد. سپس این مقادیر، در فرایند اجرای الگوریتم، با استفاده از سامانه رایانش ابری گوگل ارث انجامید به کار رفت. کارایی روش پیشنهادی در شهرستان‌های همدان و بهار که بیشترین میزان کشت این محصول را در ایران دارند، ارزیابی شد.

نتایج و بحث: براساس نتایج، مقادیر بهینه برای پارامترهای داخلی مدل $C=70$ و $\gamma=0.3$ محاسبه شد. این مقادیر در تابع RBF، به‌منظور شناسایی سطوح زیرکشت محصول سیب‌زمینی، در نظر گرفته شد. با اجرای الگوریتم طبقه‌بندی و سپس اعمال فیلتر Majority، نقشه سطوح زیرکشت سیب‌زمینی برای منطقه مورد مطالعه تهیه شد. این نقشه بیشترین تراکم کشت محصول سیب‌زمینی را در محدوده مرزی دو شهرستان (شمال غرب شهرستان همدان و شرق شهرستان بهار) نشان داد. سطح زیرکشت سیب‌زمینی برای سال زراعی ۱۳۹۹-۱۴۰۰، در شهرستان همدان، برابر ۴۵۲۷/۱ هکتار و در شهرستان بهار، برابر ۶۰۸۸/۳ هکتار به دست آمد. در ارزیابی نتایج، صحت کلی و ضریب کاپا به‌ترتیب برای همدان، ۰/۹۰/۹ و ۰/۸۲ و برای بهار، ۰/۹۳/۳ و ۰/۸۷ براساس ماتریس خطا برآورد شد. نتایج پژوهش حاضر به کارایی الگوریتم ماشین بردار پشتیبان در شناسایی سطوح زیرکشت محصول سیب‌زمینی اشاره دارد و همچنین نشان داده است که شاخص‌های منطبق بر فنولوژی سیب‌زمینی را می‌توان، به‌منزله ویژگی‌های متمایزکننده در شناسایی بهتر مزارع این محصول، استفاده کرد.

نتیجه‌گیری: شناسایی مزارع سیب‌زمینی، با استفاده از لایه‌های ورودی شاخص‌های منطبق بر فنولوژی محصول در الگوریتم ماشین بردار پشتیبان، نشان داد این روش می‌تواند صحت شناسایی سطوح زیرکشت این محصول را در سطح پالوت بهبود بخشد. از این رو می‌توان، برای شناسایی سایر محصولات مهم کشاورزی و نیز در دیگر مناطق، رویکردی مشابه را پیش گرفت و نتایج را ارزیابی کرد. همچنین پیشنهاد می‌شود کارایی داده‌های مایکروویو و سایر الگوریتم‌های یادگیری ماشین در پژوهش‌های آینده مورد توجه قرار گیرد.

واژه‌های کلیدی: شناسایی محصول، سیب‌زمینی، سری زمانی تصاویر ماهواره سنتینل-۲، سامانه گوگل ارث انجین، ماشین بردار پشتیبان.

استناد: گودرزدشتی، س.، سیفی، م.،

کهندل، م.، عاشورلو، د.، عقیقی، ح.،

شناسایی مزارع سیب‌زمینی بر مبنای

شاخص فنولوژی و الگوریتم ماشین بردار

پشتیبان با استفاده از سامانه رایانش

ابری Google Earth Engine، نشریه

سنجش از دور و GIS ایران، سال ۱۷،

شماره ۱، بهار ۱۴۰۴: ۱-۲۲.



۱- مقدمه

روند رشد جمعیت و مصرف به افزایش میزان تقاضای جهانی برای غذا منجر خواهد شد (Godfray et al., 2010)؛ بنابراین امنیت غذایی به مفهوم دسترسی پیوسته همه افراد جامعه به غذای کافی، سالم و همچنین وجود اولویت‌های غذایی برای زندگی باکیفیت (Bazgã, 2015)، به‌منزله دومین هدف توسعه پایدار سازمان ملل متحد، با چشم‌انداز حل مشکل گرسنگی تا سال ۲۰۳۰ معرفی شده است. علاوه بر این جهانی شدن بخش عظیمی از جمعیت جهان را به تغییر الگوهای مصرف، تولید و تجارت فزاینده سوق داده است که این چالش باید در تمامی سطوح مدنظر قرار گیرد (Mergos & Papanastassiou, 2017). وسعت سطوح زیرکشت محصولات، نحوه توزیع آنها، تعداد دفعات برداشت و نوع محصول مزارع، در مسیر توسعه کشاورزی و سناریوهای امنیت غذایی طی طولانی‌مدت، نقش پررنگی دارند (Jayne et al., 2014). از این رو تهیه نقشه دقیق و به‌روز سطوح زیرکشت محصولات کشاورزی، در برنامه‌ریزی، مدیریت و امنیت غذایی اهمیتی محوری خواهد داشت. روش‌های رایج و قدیمی در کسب اطلاعات پیشی سطح زمین، به‌علت پرهزینه و زمان‌بر بودن، دارای محدودیت‌هایی است (Atzberger, 2013). افزون‌بر این تغییرات مناطق کشاورزی در طول زمان و مکان، هم‌سو با سایر تغییرات، سرعت گرفته است؛ از این رو استفاده از قابلیت‌های سنجش از دور برای نگاشت محدوده جغرافیایی مزارع کشاورزی، به‌منظور مدیریت سیستم‌های تولید مواد غذایی و مطالعه ارتباط بین آنها با سایر اطلاعات کمکی در مسائل جغرافیای سیاسی، اجتماعی، اقتصادی، سلامت، محیطی و اکولوژیکی را می‌توان به‌منزله راهکاری مناسب و با مشکلاتی به‌مراتب کمتر از روش‌های قدیمی و نقشه‌برداری زمینی، مدنظر قرار داد (Xiong et al., 2017) با این کار می‌توان، علاوه بر کاهش هزینه‌ها و تهیه نقشه سطوح زیرکشت در زمان مورد نظر، محدودیت‌های موجود در به‌روزرسانی نقشه‌ها و تعمیم‌پذیری نتایج را نیز تا حد بسیاری رفع کرد (Li et al., 2019).

سیب‌زمینی پایه غذایی بسیاری از مردم جهان را تشکیل می‌دهد و سازمان خواربار جهانی این محصول را یکی از مهم‌ترین گیاهان در تأمین امنیت غذایی^۱ جهان معرفی کرده است (Devaux et al., 2014). در حال حاضر، سرعت رشد تولید و مصرف این محصول در کشورهای در حال توسعه بسیار افزایش یافته و متوسط سرانه مصرف در این کشورها، طی چند سال، بیش از دو برابر شده است. این میزان مصرف همچنان از یک‌چهارم متوسط سرانه کشورهای اروپایی کمتر است (FAO, 2016). این مسئله می‌تواند دورنمای روند افزایش مصرف سیب‌زمینی و فراورده‌های آن را در کشور ایران نیز نشان دهد.

طبقه‌بندی مزارع کشاورزی روش‌ها و تکنیک‌های متعددی دارد که شامل الگوریتم‌های مبتنی بر فنولوژی^۲ (Jeganathan et al., 2014; Dong et al., 2015; Pan et al., 2015; Hu et al., 2019; Ashourloo et al., 2022 Egorov et al., 2015;)^۳ درختان رگ‌سیون^۳ (Shao & Lunetta, 2020b), درخت تصمیم^۴ (Liu et al., 2020b), تحلیل هارمونیک سری فوریه^۵ (Mingwei et al., 2008), تطبیق طیفی^۶ (Dheeravath et al., 2010), ماشین بردار پشتیبان^۷ (Mountrakis et al., 2011; Vimodkar et al., 2020;)^۸ جنگل تصادفی^۸ (Rao et al., 2021) و سایر الگوریتم‌های یادگیری ماشین^۹ (Lary et al., 2015; Feng et al., 2019; Adrian et al., 2021) می‌شود.

روش‌های مبتنی بر فنولوژی از سری زمانی داده‌های سنجش از دور بهره می‌گیرند. این داده‌ها منبع

1. Food Security
2. Phenology Based Algorithms
3. Classification Regression Trees (CRT)
4. Decision Tree Algorithms
5. Fourier Harmonic Analysis
6. Spectral Matching Techniques
7. Support Vector Machines (SVM)
8. Random Forest (RF) Algorithms
9. Machine Learning Algorithms

کاربرد گسترده‌ای در داده‌کاوی و مدل‌سازی دارند (Das et al., 2022; Lary et al., 2016). در این روش، رایانه الگوهای موجود در داده‌ها و باندهای ورودی را بر اساس نمونه‌های آموزشی می‌آموزد و از آن، برای طبقه‌بندی کل فضای تصویر معرفی شده، استفاده می‌کند. ویژگی اصلی این تکنیک‌ها یادگیری بدون برنامه‌نویسی صریح^۴ است. فراهم شدن سری زمانی تصاویر ماهواره‌ای، در کنار بهبود توان تفکیک مکانی این داده‌ها، امکان استفاده از روش‌های یادگیری ماشین در مطالعات سطح زیرکشت را توسعه داده است. طبقه‌بندی‌کننده‌های بیشترین شباهت^۵ (Wang et al., 2019)، زاویه طیفی^۶ (Yan & Roy, 2018) و شبکه عصبی^۷ (Sun et al., 2020) از جمله روش‌های به‌کاررفته در شناسایی سطوح زیرکشت محصولات کشاورزی محسوب می‌شوند. ماشین بردار پشتیبان یک الگوریتم یادگیری ماشین نظارت‌شده است که در طبقه‌بندی و رگرسیون کاربرد دارد (Vapnik, 2000). این الگوریتم به‌منزله یکی از روش‌های ناپارامتریک شناخته می‌شود که در مطالعاتی در زمینه موضوعات گوناگون سنجش از دور، نظیر تشخیص، طبقه‌بندی و تلفیق داده‌ها به‌منظور استخراج اطلاعات متفاوت، به کار می‌رود. ماشین بردار پشتیبان، داده‌ها را با عبور یک صفحه^۸ جداکننده خطی، با بیشترین مقدار حاشیه^۹ و با استفاده از باندها و یک الگوریتم بهینه‌سازی، طبقه‌بندی می‌کند؛ بدین‌صورت که ابتدا نمونه‌های مرزی کلاس‌ها شناسایی می‌شود و سپس بردار پشتیبان، از طریق تعدادی نقاط آموزشی با کمترین فاصله از مرز جداکننده تصمیم‌گیری، تشکیل می‌شود.

ارزشمندی برای پایش پیوسته و به‌هنگام مزارع کشاورزی شمرده می‌شوند (da Silva Junior et al., 2017; Mohammadi et al., 2020; Kidane, 2022). تغییرات در امضای طیفی محصولات طی دوره رشد را می‌توان برای شناسایی و جداسازی خودکار محصولات استفاده کرد (Ashourloo et al., 2018; Mhango et al., 2021). برای نمونه، عاشورلو^۱ و همکاران (۲۰۱۸) شاخصی برای شناسایی مزارع یونجه بر اساس تغییرات باندهای طیفی قرمز و فروسرخ نزدیک در طول فصل رشد، با استفاده از سری زمانی داده‌های لندست^۲ - ۸، توسعه داده‌اند. شاخص پیشنهادی این محصول بیشترین مقادیر پیکسلی را برای یونجه، در مقایسه با سایر محصولات دارد. این شاخص برای نگاشت مزارع یونجه با دقت کلی بیش از ۹۰٪، در چهار سایت مطالعاتی در ایران و ایالات متحده، ارزیابی شده است. در مطالعه دیگری، شناسایی محصولات ذرت و سویا با استفاده از سری زمانی تصاویر مادیس با موفقیت بررسی شد که نشان می‌دهد پروفایل‌های زمانی EVI دو محصول متفاوت است و با استفاده از شاخص‌های توسعه‌یافته از طریق منحنی‌های رشد و اعمال آستانه‌ها روی شاخص‌ها، می‌توان بین محصولات تمایز مؤثری ایجاد کرد (Zhong et al., 2016). در تحقیق دیگری که جولین^۳ و همکاران (۲۰۱۱) انجام دادند، سری زمانی NDVI و دمای سطح زمین (LST)، برای تمایز محصولات، با یکدیگر ترکیب شدند.

این مطالعات نشان داد که سری زمانی داده‌های سنجش از دور می‌تواند برای تمایز محصولات گوناگون، با استفاده از اطلاعات فنولوژیکی، مفید باشد (Htitiou et al., 2014; Misra et al., 2020; Zhang et al., 2014). از دیگر سو، تفاوت ژنوتیپ‌ها و فنوتیپ‌های محصولات متفاوت و تقویم زراعی آنها باعث می‌شود بیشتر محصولات، در برخی مقاطع دوره رشد، ویژگی‌هایی منحصر به فرد داشته باشند که می‌توان این نکته را در تمایز دادن آنها از سایر محصولات، به کار برد. طبقه‌بندی‌کننده‌های مبتنی بر روش‌های یادگیری ماشین، به‌منزله زیرمجموعه‌ای از هوش مصنوعی،

1. Ashourloo
2. Landsat
3. Julien
4. Explicit Programming
5. Maximum Likelihood (ML)
6. Spectral Angle Mapper (SAM)
7. Neutral Network
8. Hyperplane
9. Margin

شناسایی مزارع سیب‌زمینی استفاده شده است. اهداف این پژوهش عبارت است از:

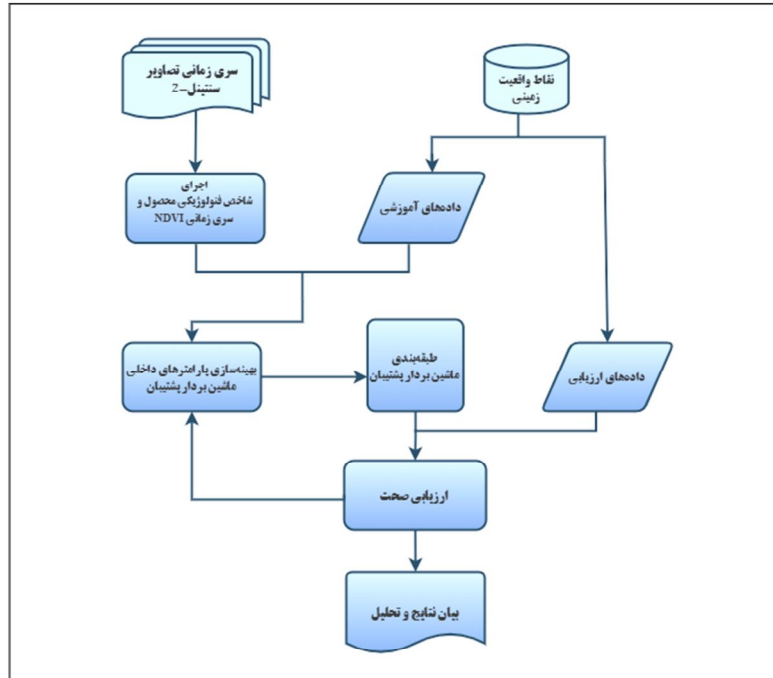
- استفاده از شاخص فنولوژیکی محصول سیب‌زمینی به‌منزله ورودی الگوریتم ماشین بردار پشتیبان و ارزیابی کارایی آن؛
- بهره‌گیری از قابلیت تصمیم‌گیری ماشین بردار پشتیبان در شناسایی مزارع سیب‌زمینی، به‌جای آستانه‌گذاری باندی؛
- بهینه‌سازی و تنظیم پارامترهای الگوریتم ماشین بردار پشتیبان برای بهبود کارایی مدل و دستیابی به بیشینه صحت.

۲- مواد و روش‌ها

شکل ۱ روند پژوهش حاضر را در شناسایی سطوح مزارع سیب‌زمینی نشان می‌دهد.

در صورتی که در فضای طیفی، طبقات با یکدیگر تداخل داشته باشند، داده‌ها با انتقال به فضایی با بعد بالاتر، قابلیت متمایز شدن می‌یابند. هدف اصلی این الگوریتم یافتن بیشترین فاصله بین دو کلاس و در نتیجه، افزایش صحت طبقه‌بندی در عین کاهش خطای تعمیم تا حد امکان است.

تولید نقشه محصولات مزارع کشاورزی، با استفاده از تحلیل سری زمانی تصاویر ماهواره‌ای، نیازمند حجم بالای داده و پردازش تصاویری است که در تاریخ‌های متفاوت دوره رشد محصول، برای شناسایی محصولات، دریافت شده‌اند. به همین دلیل، بهره‌گیری از قابلیت‌های پلتفرم رایانش ابری گوگل ارث انجین^۱ می‌تواند پیش‌برد پژوهش را ارتقا بخشد (Saad El Imanni et al., 2022; Liu et al., 2020a). بنابراین، با توجه به مطالب بیان‌شده و قابلیت‌های شاخص فنولوژی محصول و ماشین بردار پشتیبان، از تلفیق آنها به‌منظور



شکل ۱. روندنمای پژوهش حاضر در شناسایی مزارع سیب‌زمینی

1. Google Earth Engine

۱-۲- منطقه مورد مطالعه

طبق تقسیمات کشوری، استان همدان دارای نه شهرستان است و با مساحتی بالغ بر ۱۹۴۹۳ کیلومترمربع، در غرب ایران و بین عرض جغرافیایی ۳۳ درجه و ۵۹ دقیقه تا ۳۵ درجه و ۴۸ دقیقه شمالی و طول جغرافیایی ۴۷ درجه و ۳۴ دقیقه تا ۴۹ درجه و ۳۶ دقیقه شرقی قرار گرفته است. این استان جزء مناطق مرتفع و کوهستانی کشور محسوب می‌شود. قله الوند در زیر رشته‌کوه زاگرس، با ارتفاع ۳۵۷۴ از سطح دریا، بلندترین نقطه استان و رودخانه گاماسیاب در شهرستان نهاوند، با ارتفاع ۱۴۲۰ متر از سطح دریا، کم‌ارتفاع‌ترین منطقه در استان است (Ja'fari, 2005).

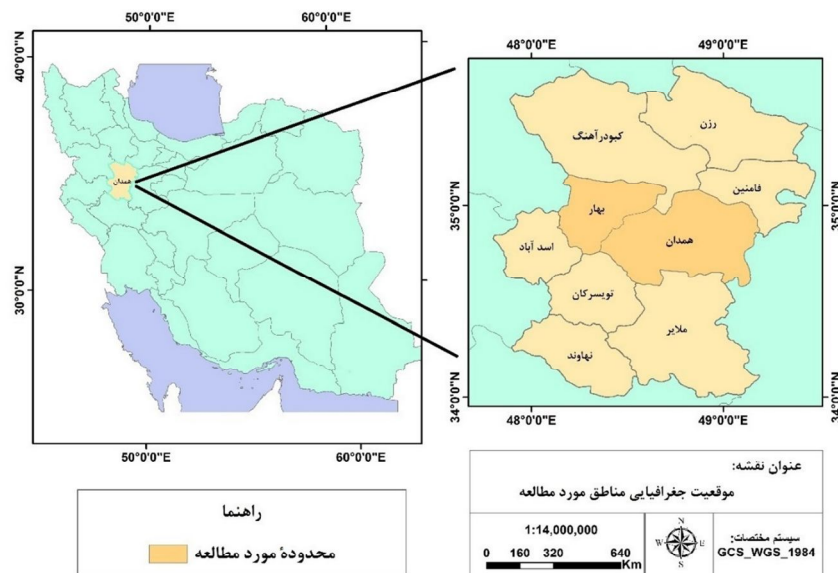
بنابه گزارش‌های ایستگاه‌های سینوپتیک، متوسط دمای سالیانه استان ۹/۶ درجه سانتی‌گراد است. تطابق شرایط اقلیمی منطقه این استان را به بزرگ‌ترین مرکز تولید محصول سیب‌زمینی در کشور تبدیل کرده است (Abdolmaleky et al., 2022; Hamedani et al., 2011). طبق آمار وزارت جهاد کشاورزی، استان همدان با تولید سالیانه بیش از نهصد هزار تن سیب‌زمینی، یک‌پنجم

تولید کشور را به خود اختصاص داده است و بین شهرستان‌های این استان، شهرستان‌های همدان و بهار بیشترین میزان تولید و سطح زیرکشت محصول را در استان دارند (گزیده آمار پایه‌ای کشاورزی همدان، ۱۳۹۸). این شهرستان‌ها در کمربند میانی استان و در مجاور یکدیگر قرار دارند و به ترتیب، ۱۴/۵ و ۰/۷٪ مساحت استان را تشکیل می‌دهند. شکل ۲ موقعیت جغرافیایی شهرستان‌های همدان و بهار را نشان می‌دهد.

۲-۲- داده‌ها

۱-۲-۲- داده‌های ماهواره‌ای مورد استفاده

در پژوهش حاضر، از تصاویر ماهواره سنتینل-۲ استفاده شده و این ماهواره از سوی آژانس فضایی اروپا^۱ طراحی و عملیاتی شده است. تا کنون پنج سری از ماهواره سنتینل به فضا پرتاب شده که هر یک فناوری خاص خود را برای نظارت بر زمین، اقیانوس‌ها و اتمسفر با ابزارهای راداری و تصویربرداری چندطیفی داراست. بر اساس اطلاعات مورد نیاز فنولوژی، از تصاویر ماهواره سنتینل-۲ که خود شامل دو ماهواره سنتینل-۲A و



شکل ۲. موقعیت منطقه مورد مطالعه، به منظور پایش سطح زیرکشت محصول سیب‌زمینی

1. European Space Agency (ESA)

کالیبراسیون دریافت شده‌اند و به ترتیب، داده‌های خام فشرده‌سازی شده و غیرفشرده را نشان می‌دهند. Level-1B اولین محصول عمومی است که تصحیح رادیومتریک روی تصاویر اعمال شده است. تصحیحات این سطح شامل سیگنال تاریک^۱، نبود یکنواختی^۲ پاسخ پیکسل‌ها، تداخل^۳، پیکسل‌های معیوب^۴ و دیگر موارد می‌شود. در سطح بعدی، تصاویر در چارچوب مرجع UTM/WGS84^۵ موزاییک می‌شوند و مدل هندسی پیشرفته‌ای بر تصاویر اعمال می‌شود. این سطح از تصویر با نام Level-1C شناخته می‌شود و بازتابندگی ثبت‌شده بالای اتمسفر^۶ را نشان می‌دهد. با اعمال تصحیح اتمسفری، تصاویر در Level-2A قرار می‌گیرند. مقادیر پیکسل‌های تصویر در این سطح، به صورت پایین اتمسفر^۷ است. امکان دسترسی به تصاویر Level-1C از اواسط سال ۲۰۱۵ میلادی به بعد در سامانه گوگل ارث انجین فراهم شده است. همچنین تصاویر Level-2A از سال ۲۰۱۷ به تدریج در این سامانه بارگذاری شده (Gorelick et al., 2017; Baillarin et al., 2012;) (ESA, 2022) و در سال مورد مطالعه پژوهش حاضر، برای منطقه مطالعاتی، در دسترس قرار دارد و به کار می‌رود. به منظور کسب اطمینان از صحت موارد یادشده، این تصحیحات با استفاده از پردازشگر Sen2Cor در ابزار SNAP، روی تعدادی از تصاویر در بازه زمانی کشت محصول بررسی شد. این تصاویر از سایت رسمی ارائه‌دهنده تصاویر سنتینل-۲ دریافت و تاریخ‌ها به صورت تصادفی انتخاب شد. در این حالت، پارامترهای تصحیح به شکل دستی معرفی می‌شوند؛ باین حال بین مقادیر پیکسل‌های تصاویر خروجی

سنتینل-۲B می‌شود، در این تحقیق استفاده شده است. سنتینل-۲A در ۲۳ ژوئن ۲۰۱۵ و سنتینل-۲B در ۷ مارس ۲۰۱۷ راه‌اندازی شده‌اند. مدار این ماهواره‌ها قطبی است و تصاویر رایگان چندطیفی با توان تفکیک مکانی ۱۰ تا ۶۰ متر را در سیزده باند طیفی و با توان تفکیک زمانی ده‌روزه ارائه می‌دهند (Kaplan & Avdan, 2017). مشخصات باندهای طیفی این ماهواره‌ها در جدول ۱ نشان داده شده است.

جدول ۱. ویژگی‌های سنجنده سنتینل-۲

| باند | ویژگی باند | طول موج مرکزی (میکرومتر) | توان تفکیک مکانی (متر) |
|---------|---------------------|--------------------------|------------------------|
| Band 1 | Coastal aerosol | 0/443 | 60 |
| Band 2 | Blue | 0/490 | 10 |
| Band 3 | Green | 0/560 | 10 |
| Band 4 | Red | 0/665 | 10 |
| Band 5 | Vegetation red edge | 0/705 | 20 |
| Band 6 | Vegetation red edge | 0/740 | 20 |
| Band 7 | Vegetation red edge | 0/783 | 20 |
| Band 8 | NIR | 0/842 | 10 |
| Band 8A | Vegetation red edge | 0/865 | 20 |
| Band 9 | Water vapor | 0/945 | 60 |
| Band 10 | SWIR-cirrus | 1/375 | 60 |
| Band 11 | SWIR | 1/610 | 20 |
| Band 12 | SWIR | 2/190 | 20 |

ویژگی‌های طیفی محصولات کشاورزی، در طول چرخه رشد، به طور مداوم دستخوش تغییرات می‌شود و به همین دلیل، توان تفکیک زمانی داده‌ها در شناسایی و تفکیک نوع محصولات از طریق فنولوژی بسیار مهم تلقی می‌شود (Wardlow & Egbert, 2008). استفاده هم‌زمان از تصاویر این دو ماهواره امکان بهبود بعد زمانی داده‌ها به پنج روز را فراهم آورد. تصاویر ماهواره سنتینل-۲ دارای سطوح متفاوتی بر مبنای تصحیحات اعمال شده است. در این بین، تصاویر Level-0 و Level-1A محصولات سیستمی‌اند که با هدف

1. Dark Signal
2. Non Uniformity
3. Crosstalk
4. Defective
5. Universal Transverse Mercator/ World Geodetic System 1984
6. TOA
7. BOA

۲-۲-۲- داده‌های میدانی


داشتن اطلاعات دقیق از شرایط واقعی زمین، امکان تفسیر صحیح و استخراج اطلاعات مدنظر از داده‌های سنجش از دور را فراهم می‌کند. داده‌های واقعیت زمینی در زمینه آموزش مدل و نیز ارزیابی نتایج به کار می‌روند. بدین منظور، در پژوهش حاضر، ابتدا اطلاعات کلی منطقه شامل مهم‌ترین محصولات کشاورزی در منطقه مطالعاتی، تقویم زراعی آنها، محدوده کاربری کشاورزی و راه‌های دسترسی با استفاده از منابع سازمان جهاد کشاورزی استان همدان، منابع اینترنتی و همچنین تصاویر ماهواره‌ای، از جمله تصاویر سنتینل-۲ و گوگل ارث استخراج شد. اغلب محصولات زراعی منطقه، علاوه بر سیب‌زمینی شامل گندم، جو، سیر، چغندر قند و یونجه می‌شود.

نرم‌افزاری با تصاویر Level-2A دریافت‌شده از سامانه گوگل ارث انجین اختلاف معناداری مشاهده نشد. این موضوع، در بررسی تغییرات نسبی مقادیر پیکسل‌ها در سری زمانی تصاویر، نشان‌دهنده هم‌خوانی کامل داده‌های ماهواره‌ای مورد استفاده بود.

با توجه به عرض جغرافیایی نزدیک دو شهرستان و اشتراک کاشی‌های تصاویر در محدوده مطالعاتی و نیز لزوم استفاده از تصاویر بدون ابر، فیلتر ابرناکی و برش مکانی مرز منطقه روی تصاویر Level-2A اعمال شد. تاریخ تصاویر مورد استفاده در جدول ۲ نشان آمده است. همچنین توزیع زمانی تصاویر مورد استفاده برای شناسایی مزارع سیب‌زمینی، بر مبنای تقویم زراعی این محصول در منطقه مورد مطالعه براساس روز از سال^۱، در شکل ۳ آورده شده است.

جدول ۲. مشخصات تصاویر مورد استفاده

| SQD - STU | | | | | | | کاشی تصویر سنتینل-۲ |
|-----------|---------|-------|-------|-----|----|-------|---------------------|
| ۲۰۲۱ | | | | | | | سال |
| اکتبر | سپتامبر | اگوست | جولای | جون | می | آوریل | ماه |
| ۲ | ۲ | ۸ | ۴ | ۴ | ۱۵ | ۳۰ | روز |
| ۷ | ۱۲ | ۱۳ | ۹ | ۹ | ۲۰ | | |
| ۱۷ | ۱۷ | ۱۸ | ۱۴ | ۱۴ | ۳۰ | | |
| | ۲۲ | ۲۸ | ۱۹ | ۱۹ | | | |
| | ۲۷ | | ۲۴ | ۲۴ | | | |
| | | | ۲۹ | | | | |



شکل ۳. توزیع زمانی تصاویر سنتینل به منظور پایش سیب‌زمینی براساس روز از سال

1. Day of Year (DOY)

مهم‌ترین گیاهان در تأمین امنیت غذایی معرفی کرده است (Devaux et al., 2014) و حتی، به‌منظور تأکید بر اهمیت و احیای این محصول در سطح جهان، سازمان خواربار و کشاورزی سال ۲۰۰۸ میلادی را سال جهانی سیب‌زمینی معرفی کرد.

رشد سیب‌زمینی را می‌توان به پنج مرحله تقسیم کرد. در مرحله اول، جوانه‌ها از بذر بیرون می‌آیند و رشد ریشه شروع می‌شود. در مرحله دوم، با رشد برگ‌ها و شاخه‌های سطح زمین، عمل فتوسنتز آغاز می‌شود و دستک‌ها، از زیر برگ‌های پایینی و ساقه زیرزمینی، رشد می‌کند. مرحله سوم شامل ایجاد غده‌های جدید از نوک دستک‌هاست و در این مرحله، رشد شاخه‌ها همچنان ادامه دارد و گل‌ها نیز خیلی زود پدیدار می‌شوند. این گل‌ها پنج‌قسمتی و به رنگ سفید یا بنفش‌اند. در مرحله چهارم، گیاه بیشتر منابع خود را در اختیار غده‌های تازه‌شکل‌گرفته قرار می‌دهد و حجیم شدن غده در این مرحله اتفاق می‌افتد. مرحله پنجم شامل بلوغ غده‌هاست که سایبان گیاه از بین می‌رود، پوست غده سخت می‌شود و قندهای موجود در غده‌ها به نشاسته تبدیل می‌شود (Jefferies & Lawson, 1991; Christensen et al., 2013). مراحلی که بر شمرده‌ایم در شکل ۵ نشان داده شده است. این گیاه ارقام متفاوتی، شامل زودرس و میانه‌رس و دیررس، دارد. سیب‌زمینی، علاوه بر کاربرد خوراکی، به‌منزله علوفه و نیز در صنعت استفاده می‌شود.

نقاط نمونه‌برداری با استفاده از GPS دستی و با دقت بهتر از پنج متر، از مرکز مزارع برداشت شد. در این فرایند، موقعیت جغرافیایی حدود مرکز مزارع و نوع محصول آنها ثبت شده است. در مجموع، ۱۶۴۸ نمونه واقعیت زمینی از سطح دو شهرستان همدان و بهار تهیه شد که شامل ۸۸۲ نمونه از محصول سیب‌زمینی، به‌منزله محصول هدف شناسایی و ۷۶۶ نمونه از سایر محصولات است. از این تعداد نمونه، ۷۰٪ در آموزش مدل و ۳۰٪ در مرحله ارزیابی به کار رفت. توزیع نقاط واقعیت زمینی، بر مبنای سیستم تصویر UTM، در شکل ۴ نشان داده شده است.

۳-۲- روش کار

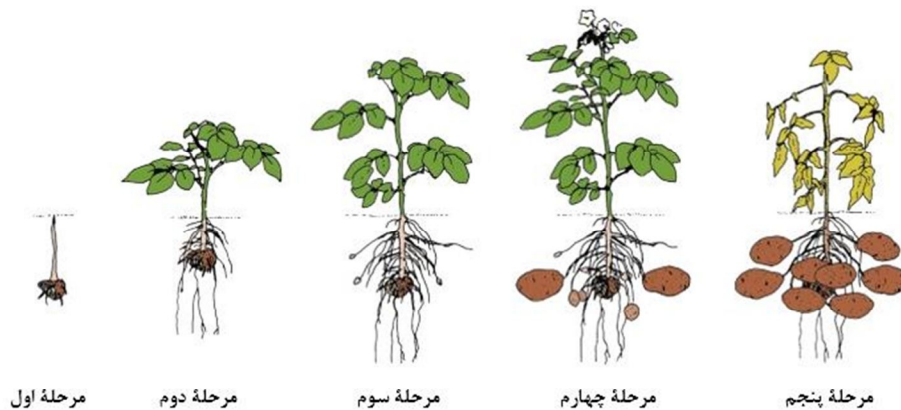
۳-۲-۱- معرفی محصول سیب‌زمینی

سیب‌زمینی در زمرة سبزیجات ریشه‌ای و از نظر گیاه‌شناسی، متعلق به خانواده سولاناسه^۱ است. این محصول در مناطق نسبتاً سرد، که متوسط دما در گرم‌ترین ماه سال ۲۵ درجه سانتی‌گراد یا کمتر است، به‌خوبی رشد می‌کند. سیب‌زمینی از نظر سطح زیرکشت در جهان پس از گندم، برنج و ذرت، در رتبه چهارم قرار دارد (Mohammadi et al., 2008). سیب‌زمینی ریشه در امریکای جنوبی دارد و اولین بار در جنوب پرو و شمال غرب بولیوی بومی شد (Spooner et al., 2005). سازمان خواربار جهانی این محصول زراعی را یکی از



شکل ۴. نحوه توزیع نقاط: در مزارع شهرستان بهار روی تصویر گوگل ارث (الف)؛ مرزبندی شهرستان‌ها (ب)

1. Solanaceae



شکل ۵. مراحل رشد محصول سیب‌زمینی

۲-۳-۲- شاخص پوشش گیاهی تفاضلی نرمال شده^۱
این شاخص از پرکاربردترین شاخص‌های پوشش گیاهی است و طبق رابطه (۱) محاسبه می‌شود. در این رابطه، NIR میزان بازتابندگی در باند فرورسرخ و Red بازتابندگی در باند قرمز است (Mather, ۲۰۰۴).

$$\text{NDVI} = (\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red}) \quad (1) \text{ رابطه (۱)}$$

NDVI شکلی تبدیل یافته از شاخص گیاهی نسبتی^۲ $\text{RVI} = \text{NIR} / \text{R}$ است و برخلاف RVI که می‌تواند دامنه‌ای نامحدود، از صفر تا بی‌نهایت را شامل شود، مقداری متغیر در محدوده +۱ و -۱ دارد. برای همه کلاس‌های گیاهان سبز، مانند جنگل‌ها، مراتع، اراضی کشاورزی، مقداری بالا دارد و برای مناطق بدون پوشش گیاهی، برف، ماسه و غیره، مقدار این شاخص پایین و کمتر از ۰/۱ خواهد بود؛ از طرفی، افزایش تراکم پوشش گیاهی باعث افزایش مقدار آن خواهد شد. بنابراین تغییرات شاخص در مراحل متفاوت رشد گیاهان، با افزایش تاج پوشش^۳ و با رشد محصول تا میانه مرحله رویشی، روندی افزایشی خواهد داشت و از مرحله بلوغ محصول تا برداشت و یا ریختن برگ‌ها و

روند معمول کشت سیب‌زمینی، در منطقه مورد مطالعه، به این ترتیب است که با توجه به شرایط جوی، کاشت آن در مزارع شخم‌خورده از نیمه دوم اسفند آغاز و تا اواخر فروردین ادامه می‌یابد. پس از گذشت حدود یک ماه، گیاه جوانه می‌زند و سبزینگی را می‌توان مشاهده کرد. تا دو ماه بعد از آن، برگ‌های گیاه همچنان رشد می‌کند و با افزایش فتوسنتز، شرایط برای تشکیل و حجیم شدن غده‌ها فراهم می‌شود. در انتهای این دوره، حداکثر سبزینگی در مزارع به وجود می‌آید و مرحله بعدی چرخه زیستی گیاه آغاز می‌شود. در این مرحله، گیاه بیشتر منابع را صرف حجیم شدن بیشتر غده‌ها می‌کند. پس از گذشت حدود ۴۵ روز، برگ‌های گیاه رو به پژمردن می‌آورند و پوسته غده‌ها سخت‌تر می‌شود. با توجه به پارامترهای متغیر مزارع و نیز محدودیت ماشین‌آلات مورد نیاز کشاورزان، بیشتر برداشت محصول سیب‌زمینی در بازه مرداد تا اواسط مهر انجام می‌شود. شایان ذکر است که در زمان برداشت محصول، همچنان سبزینگی اندکی در مزارع مشاهده می‌شود. بدین ترتیب بازه زمانی اردیبهشت تا مهر می‌تواند مراحل آغاز سبزینگی تا برداشت در منطقه مورد مطالعه را پوشش دهد.

1. Normalized Difference Vegetation Index (NDVI)

2. Ratio Vegetation Index (RVI)

3. Canopy

تفاضل باندی، با برقراری سه شرط زیر، زمان برداشت (t_H) تعیین می‌شود (Ashourloo et al., 2020):

(۱) مقدار $\rho_{NIR_t} - \rho_{red_t}$ در زمان t کمینه است؛

(۲) $(\rho_{NIR_t} - \rho_{red_t}) < (\rho_{NIR_{t-1}} - \rho_{red_{t-1}})$

(۳) $(\rho_{NIR_{t-1}} - \rho_{red_{t-1}}) < (\rho_{NIR_{t-2}} - \rho_{red_{t-2}})$

به منظور طبقه‌بندی تصاویر با استفاده از الگوریتم یادگیری ماشین، لایه حاصل از اجرای ویژگی طیفی توسعه داده شده محصول سیب‌زمینی به منزله یکی از لایه‌های ورودی به مدل استفاده شده است.

۴-۳-۲- استفاده از یادگیری ماشین در شناسایی نوع محصول

برای استخراج اطلاعات از تصاویر ماهواره‌ای، روش‌های رقمی متنوعی وجود دارد و همواره تلاش بر این بوده است که بتوان، با بیان روش‌های کارآمد، این فرایند را بهبود بخشید. طبقه‌بندی، به منزله فرایند تصمیم‌گیری، داده‌ها را به فضای کلاس‌های مشخص انتقال می‌دهد و در حقیقت، نگاشتی از فضای چندطیفی به فضای عوارض است. اصولاً استفاده از الگوریتم‌های طبقه‌بندی برای استخراج اطلاعات، به ویژه در مواردی که حجم زیادی از داده پردازش می‌شود، اهمیت دوچندان می‌یابد. به منظور رسیدن به روش‌هایی با ضریب اطمینان بالاتر، می‌توان از تصاویر چندباندی و نیز داده‌هایی با منابع متفاوت استفاده کرد.

با پیشرفت فناوری در سال‌های اخیر، روش‌های هوش مصنوعی^۳ و بینایی ماشین^۴ به منزله ابزارهایی قدرتمند در تشخیص، طبقه‌بندی و تلفیق داده‌ها در حوزه سنجش از دور شناخته می‌شود. یادگیری ماشین از زیرمجموعه‌های هوش مصنوعی است که عملکرد آن، در زمینه تحلیل داده‌ها و محاسبات، هوشمندانه است و توانایی یادگیری و ارتقای تجربه را به‌طور خودکار و بدون برنامه‌ریزی خاص نیز فراهم می‌کند (Ma et al., 2019; Shi et al., 2020).

1. Peak of Greenness
2. Harvest
3. Artificial Intelligence
4. Computer Vision

کم شدن سبزی‌نگی، این مقدار، متناسب با سطح تاج‌پوشش گیاه، کاهش می‌یابد. بدین ترتیب این تغییرات می‌تواند بیانگر مراحل متفاوت حیات گیاه باشد (Myneni et al., 1995).

۳-۳-۲- شاخص محصول سیب‌زمینی

شناسایی و تفکیک مزارع سیب‌زمینی از سایر مزارع را می‌توان با بررسی منحنی طیفی باندهای قرمز و فروسرخ، در مراحل خاص رویشی انجام داد. با توجه به اینکه مقدار تغییرات باند فروسرخ تا زمان رسیدن گیاه به اوج سبزی‌نگی^۱ و نیز در زمان اوج سبزی‌نگی بیشینه است و همچنین مقادیر باند قرمز در زمان اوج سبزی‌نگی و باند فروسرخ در زمان برداشت^۲ محصول کمتر از دیگر محصولات است، رابطه (۲) اجرا شده است که به منزله ویژگی طیفی شناسایی محصول سیب‌زمینی شناخته می‌شود. مقدار این رابطه، در مورد محصول سیب‌زمینی، بیشتر از دیگر محصولات است و می‌توان آن را به منظور تفکیک این محصول از سایر محصولات، به کار برد.

$$\text{Potato feature} = \frac{(\sum_{t=1}^{N-1} (\rho_{(t+1)NIR} - \rho_{tNIR})) \times (\rho_{NIR_{PG}})}{(\rho_{red_{PG}})(\rho_{NIR_h})}$$

رابطه (۲)

در این رابطه، ρ_{tNIR} مقدار بازتابندگی در باند فروسرخ در زمان t ، در طول بازه رسیدن به حداکثر سبزی‌نگی است. $\rho_{NIR_{PG}}$ مقدار بازتابندگی در باند فروسرخ در زمان اوج سبزی‌نگی و $\rho_{red_{PG}}$ مقدار بازتابندگی در باند قرمز در زمان اوج سبزی‌نگی است. این مقادیر از باندهای فروسرخ و قرمز در زمان اوج سبزی‌نگی استخراج می‌شوند. همچنین ρ_{NIR_h} مقدار بازتابندگی باند فروسرخ در زمان برداشت محصول است. پارامتر N نیز تعداد تصاویر مورد استفاده در طول دوره رشد را نشان می‌دهد.

$\rho_{NIR} - \rho_{red}$ ، در زمان اوج سبزی‌نگی، دارای بیشترین مقدار است و بدین صورت زمان اوج سبزی‌نگی را نشان می‌دهد. همچنین با توجه به الگوی مقدار این

x_i ، با استفاده از تابع Φ ، به فضای ویژگی انتقال می‌یابد. $K(x_i, x_j) = \Phi(x_i)^T \Phi(x_j)$ تابع هسته^۱ نامیده می‌شود. هسته‌های گوناگونی برای اجرای مدل ماشین بردار پشتیبان به کار می‌رود که از بین آنها، کاربرد این هسته‌ها متداول است: خطی^۲:

$$K(x_i, x_j) = x_i^T x_j$$

چندجمله‌ای^۳:

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$$

تابع پایه شعاعی^۴:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$$

سیگموئید^۵:

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$$

در روابط بالا، T ترانهاده ماتریس، γ پارامتر گاما، r بایاس و d درجه چندجمله‌ای و x_i, x_j نشان‌دهنده بردار مؤلفه T ام و T ام است.

ماشین بردار پشتیبان می‌تواند، با استفاده از توابع هسته غیرخطی، توزیع های کلاس چندوجهی را در فضاهای ویژگی دارای ابعاد بالا جدا کند. بر این اساس، فضای ورودی n بعدی به فضای ویژگی با ابعاد بالاتر نگاشت می‌شود (Vapnik, 1999). در این شیوه، ابتدا فاصله نزدیک‌ترین نمونه‌های تعلیمی دو کلاس در راستای عمود بر مرزها به دست می‌آید و با حل مسئله بهینه‌سازی، مرز بهینه که بیشترین حاشیه را داراست، مشخص می‌شود. سپس دو صفحه موازی در دو طرف مرز تصمیم‌گیری تعریف می‌شود. اگر صفحه مرز دارای بیشترین فاصله مساوی بین دو صفحه موازی باشد، دقت طبقه‌بندی افزایش خواهد یافت (Boser et al., 1992).

در صورتی که داده‌ها تداخل زیادی داشته باشند، استفاده از هسته غیرخطی پایه شعاعی می‌تواند راهگشا باشد. قابلیت اطمینان و صحت بالاتر این تابع هسته

در حوزه سنجش از دور، روش‌های طبقه‌بندی نظارت‌شده علاوه بر تصاویر ورودی، نیازمند مجموعه‌ای از اطلاعات جانبی درباره کلاس‌های موجود است؛ از این رو دخالت عامل انسانی، در روش‌های طبقه‌بندی نظارت‌شده، اجتناب‌ناپذیر است. این اطلاعات جانبی معمولاً به صورت معرفی تعدادی پیکسل معلوم به الگوریتم است. الگوریتم‌های طبقه‌بندی، با استفاده از این پیکسل‌های معلوم، در مورد سایر پیکسل‌های تصویر تصمیم‌گیری و آنها را به کلاس‌های مدنظر منتسب می‌کند (Maxwell et al., 2018). نگاشت سطوح زیرکشت محصول مبنای برنامه‌ریزی‌های کلان و نیز سایر تحقیقات، همچون برآورد میزان تولید، شمرده می‌شود. در پژوهش حاضر، قابلیت استفاده از ماشین بردار پشتیبان با ورودی‌های غیر از باندهای اولیه تصاویر ماهواره سنتینل-۲ ارزیابی می‌شود.

۵-۳-۲- ماشین بردار پشتیبان و بهینه‌سازی پارامترها

ماشین بردار پشتیبان الگوریتمی است که در مطالعات درباره موضوعات گوناگون در حوزه سنجش از دور به کار می‌رود؛ همچون تشخیص، طبقه‌بندی و تلفیق داده‌ها به منظور استخراج اطلاعات گوناگون (Foody & Mathur, 2004). این روش، بدون هیچ پیش‌فرضی در مورد توزیع داده‌ها، روی توزیع طبقات عمل می‌کند (Burgess, 1998) و ویژگی اصلی آن توانایی طبقه‌بندی، با استفاده از نمونه‌های آموزشی محدود و رسیدن به دقت بالاتر، در مقایسه با سایر روش‌های طبقه‌بندی است (Basak et al., 2007). سرعت بالا، انعطاف‌پذیری و مقیاس‌پذیری الگوریتم ماشین بردار پشتیبان، در زمانی که ویژگی‌های مجموعه داده‌ها زیاد باشد، از قابلیت‌های این الگوریتم طبقه‌بندی است (Shin et al., 2005). الگوریتم ماشین بردار پشتیبان کاربردی گسترده در طبقه‌بندی موضوعی تصاویر ماهواره‌ای داشته است.

خروجی ماشین بردار پشتیبان یک طبقه‌بندی است که به هر پیکسل، یکی از k کلاس را اختصاص می‌دهد (Tarabalka et al., 2010). در اینجا بردارهای آموزشی

1. Kernel
2. Linear
3. Polynomial
4. Radial Basis Function (RBF)
5. Sigmoid

شرکت‌های قدرتمندی همچون گوگل به این فناوری، بسیاری از این مشکلات برطرف شده و همچنین امکانات و قابلیت‌های متعددی در اختیار کاربران رشته‌های گوناگون قرار گرفته است؛ به‌ویژه، متخصصان دانش‌هایی که با حجم بالای داده و پردازش سروکار دارند. این دستاورد باعث افزایش کاربران متصل به این سامانه‌ها شده است. در رایانش ابری خدمات متنوعی در اختیار کاربران قرار می‌گیرد؛ از جمله در اختیار گذاری امکانات پردازشی سرورها، امکانات ذخیره‌سازی داده‌ها و اطلاعات، پایگاه داده، شبکه و نرم‌افزارهای تحلیل در کنار منابع گوناگون اطلاعاتی.

GEE از سامانه‌های رایانش ابری است که از قابلیت‌های گسترده گوگل بهره می‌برد. این سامانه برای ذخیره‌سازی، پردازش، تحلیل و تصمیم‌گیری در مجموعه داده‌های عظیم و تصاویر ماهواره‌ای تا حد پتانسیت طراحی شده است. دسترسی رایگان تحقیقاتی و متن‌باز^۵ بودن از قابلیت‌های برجسته این سامانه است (Gorelick et al., 2017). پایگاه داده این سامانه ابری شامل آرشیو کامل و به‌روز سال‌ها داده و تصاویر ماهواره‌های گوناگون است. از این جمله، می‌توان داده‌های ماهواره‌های لندست ۱ تا ۸، سنتینل ۱ و ۲، مادیس و نوآ را برشمرد. علاوه‌براین، مجموعه‌ای از نقشه‌ها و اطلاعات زمین‌شناسی و اقلیمی نیز در این سامانه در دسترس قرار گرفته است. این اطلاعات، در کنار انبوهی از داده‌های چندزمانی در مقیاس منطقه‌ای و جهانی، فرصت مناسبی فراهم کرده است تا، با صرف تجهیزات محدود و زمان کمتر، تحلیل مکانی انجام شود. نیاز نداشتن به دانلود داده‌ها پیش از پردازش و قابلیت پردازشی عظیم این سامانه، امکان پردازش انواع داده‌های برداری و رستری را بدون نیاز به ذخیره‌سازی

پر کاربرد در طبقه‌بندی با هدف شناسایی نوع محصول، در مطالعات گزارش شده است (James et al., 2013). آموزش ماشین بردار پشتیبان در بردارنده تعیین پارامترهای هسته است. این پارامترها شامل γ و C می‌شوند. γ تعیین‌کننده عرض هسته و C پارامتر جریمه، مرتبط با نمونه‌های آموزش نادرست را کنترل می‌کند. هر دو پارامتر در صحت نتایج طبقه‌بندی تأثیرگذارند و بهینه‌سازی مقادیر آنها می‌تواند صحت نتایج را بهبود بخشد. برآورد پارامترها بر مبنای نمونه‌ها In-sample Estimation نامیده می‌شود. افزایش پارامترها اغلب افزایش کارایی مدل را به همراه خواهد داشت زیرا میانگین مربعات برای نمونه‌ها کاهش خواهد یافت. اما نکته مهم، در این فرایند، جلوگیری از بیش‌برازش^۲ است. بیش‌برازش باعث کاهش کارایی مدل در مورد سایر نمونه‌های طبقه خواهد شد. راه‌حل چنین مسئله‌ای استفاده از اعتبارسنجی متقاطع^۳ است. بر این مبنای مقادیر بهینه برای پارامترهای ماشین بردار پشتیبان به‌گونه‌ای تعیین شده است که بتواند حداکثر صحت کلی را برای طبقه‌بندی موجب شود.

۶-۳-۲- سامانه گوگل ارث انجین و نقش آن در پژوهش حاضر

فناوری مبتنی بر رایانش ابری^۴ به‌سرعت در حال تکامل و پیشرفت است. تا پیش از این، بهره‌برداران مجبور بودند با صرف هزینه‌های هنگفت، سرورها و تجهیزات سخت‌افزاری و نرم‌افزاری مورد نیاز را به‌طور مستقل خریداری کنند و داده‌ها و اطلاعات را نیز در هارد دیسک‌های متعدد ذخیره و بایگانی کنند. علاوه‌براین سامان‌دهی، دسترسی به این تجهیزات و نگهداری از آنها دشوار بود و آسیب‌های زیادی نیز، از جمله مخدوش شدن و از دست رفتن اطلاعات، آنها را تهدید می‌کرد. از این رو بسیاری از شرکت‌ها به استفاده مشترک از تجهیزات روی آوردند و این اشتراک‌گذاری تجهیزات شروع عملکردی مشابه با سرویس‌های رایانش ابری شد. با پیدایش سرویس‌های ابری و ورود

1. Gamma
2. Overfitting
3. Cross Validation
4. Cloud computing
5. Open Source
6. NOAA

مستقیم روی هارد دیسک، فراهم می‌سازد. فرایند تولید نقشه سطح زیرکشت محصولات کشاورزی، با استفاده از تصاویر ماهواره‌ای، نیازمند حجم بالای داده‌هایی است که در زمان‌های متفاوت دوره رشد محصول دریافت شده‌اند. بهره‌گیری از این سامانه در آماده‌سازی و پردازش داده‌ها بسیار کارگشا بوده است.

۳- نتایج

۳-۱- لایه‌های ورودی مدل

طبق تقویم زراعی محصول سیب‌زمینی در منطقه مورد مطالعه، سبزی‌نگی مزارع این محصول را می‌توان معمولاً از اواخر ماه آوریل مشاهده کرد و برداشت نیز از اواخر ژوئیه تا اکتبر ادامه دارد. بر این مبنای باندهای ورودی آماده و به طبقه‌بند معرفی شد. لایه شاخص فنولوژیکی توسعه داده شده برای شناسایی محصول سیب‌زمینی و لایه‌های میانه NDVI منطبق بر چرخه قابل رصد رشد. این محصول از تصاویر سنتینل-۲ تشکیل و بهینه‌سازی پارامترهای مدل و ارزیابی نتایج بر این مبنای انجام می‌شود. مشخصات لایه‌های ورودی به الگوریتم ماشین بردار پشتیبان در جدول ۳ نشان داده شده است.

جدول ۳. لایه‌های ورودی به ماشین بردار پشتیبان

| سال | بازه زمانی | لایه ورودی |
|------|-----------------------|--------------------------------|
| ۲۰۲۱ | آوریل تا اکتبر | شاخص فنولوژیکی محصول سیب‌زمینی |
| ۲۰۲۱ | Late April – Late May | Median ₁ (NDVI) |
| ۲۰۲۱ | Late May – Late June | Median ₂ (NDVI) |
| ۲۰۲۱ | Late June – Late July | Median ₃ (NDVI) |
| ۲۰۲۱ | Late July – Mid Oct | Median ₄ (NDVI) |

۳-۲- بهینه‌سازی پارامترها با کمک اعتبارسنجی متقاطع

هدف از اعتبارسنجی متقاطع دستیابی به مدلی است که دچار بیش‌برازش نباشد. در روش اعتبارسنجی متقاطع، طی فرایندی تکرارشونده بخش‌های داده‌های آموزشی که به منظور مدل‌سازی به کار می‌رود، خود به

دو بخش تفکیک می‌شود. در هر بار تکرار فرایند اعتبارسنجی، بخشی از داده‌ها برای آموزش و بخشی دیگر برای آزمایش مدل به کار می‌رود. به این ترتیب، این فرایند یک روش بازنمونه‌گیری به‌منظور برآورد خطای مدل محسوب می‌شود. باید توجه داشت که داده‌های آزمایشی در این فرایند ممکن است، در تکرار بعدی، به‌منزله داده‌های آموزشی به کار روند؛ در نتیجه، ماهیت آنها با داده‌هایی که در بخش پیشین به‌منزله داده‌های آزمایشی معرفی شد، متفاوت است. در رویکرد پایه، که K-fold Cross Validation نامیده می‌شود، مجموعه آموزشی به K مجموعه کوچک‌تر تقسیم می‌شود و مدل بر مبنای K-1 بخش آموزش داده می‌شود. سپس مدل به دست‌آمده روی بخش باقی‌مانده از داده‌ها اعتبارسنجی می‌شود.

در پژوهش حاضر، برای اجتناب از بیش‌برازش مدل و نیز کاهش هرگونه بایاس در ترتیب داده‌های مشاهداتی، این داده‌ها یک مرحله پیش‌پردازش را پشت سر گذاشتند و قبل از اجرای طبقه‌بندی یادگیری ماشین نظارت‌شده، چندین بار ترکیب شدند. قبل از هر اجرا، نمونه‌ها از طریق ارزیابی متقاطع 5-fold cross validation به داده‌های آموزشی^۱، اعتبارسنجی^۲ و تست^۳ تقسیم شدند. در هر مرتبه و به‌طور هم‌زمان، تقسیم مجموعه داده‌ها به پنج بخش با تعداد مساوی انجام شد؛ یک بخش برای تست کنار گذاشته شد و از چهار بخش باقی‌مانده، سه بخش برای آموزش و باقی برای اعتبارسنجی مدل به کار رفت. ارزیابی نهایی در مورد مقادیر بهینه پارامترهای گاما و C با معیار صحت کلی^۴ و در حدود مقادیر پیش‌فرض نرم‌افزارهای سنسج از دور، همچون ENVI صورت پذیرفت (Sebbar et al., 2020). جدول ۴ مقادیر بررسی شده و نتایج ارزیابی را نشان می‌دهد.


1. Training Data
2. Validation Data
3. Test Data
4. Overall Accuracy (OA)

زیرکشت محصول سیب‌زمینی در شهرستان‌های همدان و بهار، برای سال زراعی ۱۴۰۰-۱۳۹۹، برآورد شد. پس از اجرای طبقه‌بندی روی تصاویر با قدرت تفکیک مکانی بالا، مانند سنتینل-۲، ممکن است در این کلاس‌ها پلی‌گون‌هایی ریز، در حد یک تا چند پیکسل، به صورت پراکنده به وجود بیاید که احتمال اشتباه بودن طبقه‌بندی آنها بیشتر از سایر پیکسل‌های همگن است. علت این مسئله در وجود نوعی همبستگی بین پیکسل‌های مجاور است. برای افزایش صحت طبقه‌بندی تصاویر، می‌توان از روش‌هایی همچون فیلتر پس از طبقه‌بندی استفاده کرد (Rouzbahani et al., 2014). نمونه‌ای معمول از این فیلترها، فیلتر Majority است (Akçay & Avsar, 2017). این فیلتر از اطلاعات همسایگی مکانی پیکسل‌ها استفاده می‌کند و پیکسل‌های منفرد را به کلاسی که شباهت بیشتری به آن دارد، اختصاص می‌دهد (Fatemi et al., 2014). ابزار فیلتر Majority برای جایگزینی مقادیر پیکسل‌ها براساس شباهت بیشترین سلول‌های همسایه عمل می‌کند. برای این منظور، پنجره‌ای متحرک با ابعاد و شکلی که چگونگی این همسایگی را پیرامون سلول میانی تعیین می‌کند، از روی تصویر طبقه‌بندی شده می‌گذرد و پیکسل میانی پنجره، با کلاسی که بیشترین فراوانی را درون پنجره همسایگی دارد، جایگزین می‌شود. در این پژوهش، ابعاد پنجره و روش‌های گوناگون جایگزینی پیکسل میانی با فیلتر Majority بررسی شد و طبق ارزیابی بصری، تعداد همسایگی هشت‌تایی در پنجره ۳*۳ به کار رفت. در نهایت، نقشه سطح زیرکشت محصول سیب‌زمینی در شهرستان‌های همدان و بهار، برای سال زراعی ۱۳۹۹-۱۴۰۰، تهیه شد. شکل ۷ نقشه‌های خروجی سطوح زیرکشت سیب‌زمینی در شهرستان‌های همدان و بهار را نشان می‌دهد.

جدول ۴. ارزیابی مقادیر گوناگون پارامترهای RBF

| شماره طبقه‌بندی | C | Gamma | OA (%) |
|-----------------|-----|-------|--------|
| 1 (Default) | 100 | 0/25 | 90/7 |
| 2 | 90 | 0/25 | 90/9 |
| 3 | 80 | 0/25 | 91/3 |
| 4 | 70 | 0/25 | 90/2 |
| 5 | 70 | 0/2 | 91/2 |
| 6 | 70 | 0/3 | 91/6 |
| 7 | 70 | 0/4 | 91/2 |
| 8 | 70 | 0/01 | 91 |
| 9 | 85 | 0/27 | 91/6 |
| 10 | 85 | 0/32 | 91/6 |
| 11 | 75 | 0/27 | 91/6 |
| 12 | 75 | 0/32 | 91/6 |

به منظور بصری‌سازی روند تأثیرگذاری این مقادیر در صحت کلی، نمودار روند تغییرات در شکل ۶ نشان داده شده است.

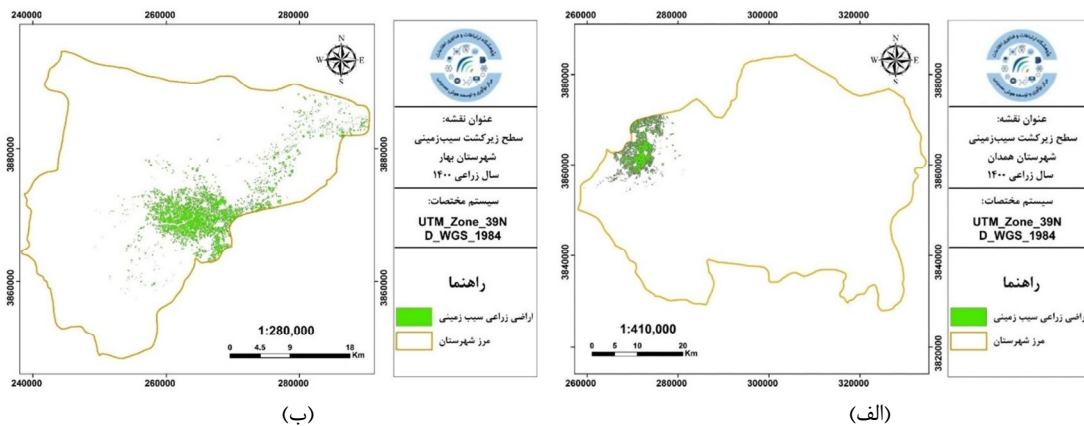


شکل ۶. نمودار روند تغییرات دقت کلی براساس طبقه‌بندی‌های متفاوت

همان‌طور که نشان داده شده است، در محدوده پارامترهای طبقه‌بندی شماره ۶، صحت کلی روندی ثابت و بهینه دارد و در نتیجه، از مقادیر $C=70$ و $\gamma=0.3$ در تابع RBF، به منظور شناسایی محصول سیب‌زمینی در شهرستان‌های همدان و بهار استفاده شد.

۳-۳- خروجی‌ها و ارزیابی نتایج

براساس الگوریتم مورد استفاده در پژوهش، سطح



شکل ۷. نقشه سطح زیر کشت سیب‌زمینی: شهرستان همدان (الف)؛ شهرستان بهار (ب)

زمینی، از نمونه‌های مرجع زمینی در این کار استفاده می‌شود. نتایج این مقایسه در قالب ماتریس خطا^۱ ارائه می‌شود. بر این اساس، اطلاعات ماتریس خطا برای دو شهرستان همدان و بهار به صورت مجزا تشکیل شد که در جدول ۵ نشان داده شده است. دقت کلی و ضریب کاپا^۲، برای طبقه‌بندی تفکیک محصول سیب‌زمینی از سایر محصولات در دو شهرستان همدان و بهار، محاسبه شد.

بر اساس نتایج، سطح زیر کشت سیب‌زمینی طی سال زراعی ۱۳۹۹-۱۴۰۰، در شهرستان همدان، ۴۵۲۷/۱ هکتار و در شهرستان بهار، ۶۰۸۸/۳ هکتار محاسبه شد. ارزیابی صحت، بخش جدایی‌ناپذیر تحلیل اطلاعات و فرایند طبقه‌بندی است. با توجه به اینکه نتایج سنجش از دور در موضوعات مهمی، از جمله تصمیم‌گیری‌های کلان به کار می‌روند، ارزیابی صحت برای اطمینان از صحت نتایج حیاتی است (Navulur, 2006). به دلیل نبود امکان مقایسه تک‌تک پیکسل‌های طبقه‌بندی شده با واقعیت

جدول ۵. ماتریس خطا: شهرستان همدان (الف)؛ شهرستان بهار (ب)

| شناسایی محصول سیب‌زمینی مبتنی بر ویژگی‌های فنولوژیکی و یادگیری ماشین شهرستان همدان | واقعیت زمینی | | | صحت کاربر |
|---|--------------|--------------|--------|-----------|
| | سیب‌زمینی | سایر محصولات | جمع کل | |
| سیب‌زمینی | ۱۰۷ | ۹ | ۱۱۶ | ۹۲/۲٪ |
| سایر محصولات | ۱۳ | ۱۱۲ | ۱۲۵ | ۸۹/۰۶٪ |
| جمع کل | ۱۲۰ | ۱۲۱ | ۲۴۱ | |
| صحت تولیدکننده | ۸۹/۰۲٪ | ۹۲/۰۶٪ | | |

(الف)

| شناسایی محصول سیب‌زمینی مبتنی بر ویژگی‌های فنولوژیکی و یادگیری ماشین شهرستان بهار | واقعیت زمینی | | | صحت کاربر |
|--|--------------|--------------|--------|-----------|
| | سیب‌زمینی | سایر محصولات | جمع کل | |
| سیب‌زمینی | ۱۳۷ | ۷ | ۱۴۴ | ۹۵/۰۱٪ |
| سایر محصولات | ۱۱ | ۱۱۴ | ۱۲۵ | ۹۱/۰۲٪ |
| جمع کل | ۱۴۸ | ۱۲۱ | ۲۶۹ | |
| صحت تولیدکننده | ۹۲/۰۶٪ | ۹۴/۰۲٪ | | |

(ب)

1. Error (Confusion) Matrix
2. Kappa Coefficient

بر اساس ماتریس‌های خطا، صحت کلی برای شهرستان همدان ۹۰/۹٪ و ضریب کاپا ۰/۸۲ محاسبه شد. برای شهرستان بهار نیز صحت کلی ۹۳/۳٪ با ضریب کاپای ۰/۸۷ به دست آمد.

۴- بحث و نتیجه‌گیری

با توجه به اهمیت محصول سیب‌زمینی و نقش آن در تأمین امنیت غذایی، در این پژوهش، شناسایی این محصول با استفاده از سری زمانی تصاویر ماهواره‌ای مطالعه شد. در دسترس بودن سری زمانی تصاویر ماهواره‌ای، با توان تفکیک زمانی مناسب، امکان بهره‌گیری از داده‌هایی را فراهم آورده است که چرخه رشد این محصول را نمایان کند. در روش پیشنهادی، شاخص طیفی فنولوژیکی سیب‌زمینی و شاخص NDVI برای تفکیک این محصول از سایر محصولات به کار رفت. شاخص طیفی فنولوژیکی یک لایه رستری است که در آن پیکسل‌های مربوط به مزارع سیب‌زمینی مقادیری بیشتر از پیکسل‌های سایر محصولات دارند. علاوه بر این، از شاخص NDVI در بازه‌های زمانی منطبق بر چرخه فنولوژی محصول، به‌منزله ورودی‌های ماشین بردار پشتیبان، استفاده شد. پارامترهای ماشین بردار پشتیبان در صحت نتایج نهایی طبقه‌بندی تأثیرگذارند و از این‌رو، برای رسیدن به حداکثر صحت الگوریتم، بهینه‌سازی شدند. نتایج پژوهش حاضر، در مقایسه با نتایج پژوهش عاشورلو و همکاران (۲۰۲۰)، به‌منظور توسعه روش شناسایی مزارع سیب‌زمینی با استفاده از شاخص فنولوژی محصول با صحت کلی حدود ۹۰٪ و ضریب کاپای ۰/۸، نشان می‌دهد که استفاده از الگوریتم ماشین بردار پشتیبان می‌تواند صحت شناسایی این مزارع را بهبود بخشد. همچنین با توجه به نتایج، این رویکرد ضمن تأیید کارایی شاخص فنولوژیکی محصول به‌منزله لایه‌ای ورودی به الگوریتم یادگیری ماشین، توانست قابلیت تصمیم‌گیری ماشین بردار پشتیبان را به‌جای آستانه‌گذاری تک‌باندی شاخص فنولوژی در شناسایی

محصول سیب‌زمینی نشان دهد. با توجه به موفقیت این مدل در شناسایی محصول سیب‌زمینی در سطح پایلوت، در آینده می‌توان عملکرد این رویکرد را برای سایر محصولات و نیز در دیگر مناطق ارزیابی کرد. از آنجاکه شاخص فنولوژی محصول به تصاویر ماهواره‌ای اپتیکی در مراحل اساسی دوره رشد بازمی‌گردد، ممکن است این نکته، در مناطقی با تعداد روز ابری زیاد، مانعی محسوب شود و از این‌رو استفاده از داده‌های مایکروویو و ارزیابی کارایی آن در این مناطق می‌تواند در پژوهش‌های آتی مدنظر قرار بگیرد. محدودیت دیگر را می‌توان تفکیک تصاویر ماهواره سنتینل-۲ دانست که برای شناسایی محصولات، در مناطقی با کشاورزی سنتی و مزارع کوچک یا نامنتظم، مناسب نیست و می‌توان آن را با استفاده از نقشه‌های کاداستر کشاورزی و یا تصاویر دارای توان تفکیک مکانی بهتر، بهبود بخشید.

۵- تشکر و قدردانی

پژوهشگران این تحقیق لازم می‌دانند مراتب قدردانی صمیمانه خود را از پژوهشگاه ارتباطات و فناوری اطلاعات، مرکز تحقیقات مخابرات ایران و مرکز نوآوری و توسعه هوش مصنوعی در مقام حامی مالی و نیز ناظران پروژه، خانم دکتر گودرزی، آقای دکتر حاجی پور و آقای دکتر رحیم زادگان، اعلام کنند که با دقت نظر و راهنمایی‌های خود، ما را در انجام دادن و ارتقای کیفی این پژوهش یاری کردند. همچنین از همراهی و مشارکت فعال معاونت بهبود تولیدات گیاهی سازمان جهاد کشاورزی استان همدان و تعاونی سیب زمینی کاران همدان و بهار صمیمانه سپاسگزاری می‌کنیم.

۶- منابع

Abdolmaleky, M., Mahdei, K.N. & Nejatian, P., 2022, *Environmental Sustainability Assessment: Potato Production in Western Iran, Process Integration and Optimization for Sustainability*, 6(4), PP. 1063-1073, <https://doi.org/10.1007/s41660-022-00262-2>.

- Adrian, J., Sagan, V. & Maimaitijiang, M., 2021, **Sentinel SAR-Optical Fusion for Crop Type Mapping Using Deep Learning and Google Earth Engine**, ISPRS Journal of Photogrammetry and Remote Sensing, 175, PP. 215-235, <https://doi.org/10.1016/j.isprs.2021.02.018>.
- Agricultural jihad of Hamedan Province., 2019, **Agricultural Statistics of Hamedan**, <http://hm.agri-jahad.ir>, Hamadan (In Persian).
- Akçay, O. & Avsar, E.O., 2017, **The Effect of Image Enhancement Methods during Feature Detection and Matching of Thermal Images**, The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 42, P. 575, <https://doi.org/10.5194/isprs-archives-XLII-1-W1-575-2017>.
- Ashourloo, D., Shahrabi, H.S., Azadbakht, M., Aghighi, H., Matkan, A.A. & Radiom, S., 2018, **A Novel Automatic Method for Alfalfa Mapping Using Time Series of Landsat-8 Oli Data**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 11, PP. 4478-4487, <https://doi.org/10.1109/JSTARS.2018.2874726>.
- Ashourloo, D., Shahrabi, H.S., Azadbakht, M., Rad, A.M., Aghighi, H. & Radiom, S., 2020, **A Novel Method for Automatic Potato Mapping Using Time Series of Sentinel-2 Images**, Computers and Electronics in Agriculture, 175, <https://doi.org/10.1016/j.compag.2020.105583>.
- Ashourloo, D., Nematollahi, H., Huete, A., Aghighi, H., Azadbakht, M., Shahrabi, H.S. & Goodarzdahsti, S., 2022, **A New Phenology-Based Method for Mapping Wheat and Barley Using Time-Series of Sentinel-2 Images**, Remote Sensing of Environment, 280, P. 113206, <https://doi.org/10.1016/j.rse.2022.113206>.
- Atzberger, C., 2013, **Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and major Information Needs**, Remote Sensing, 5, PP. 949-981, <https://doi.org/10.3390/rs5020949>.
- Baillarin, S.J., Meygret, A., Dechoz, C., Petrucci, B., Lacherade, S., Trémas, T., Isola, C., Martimort, P. & Spoto, F., 2012, **Sentinel-2 Level 1 Products and Image Processing Performances, 2012 IEEE International Geoscience and Remote Sensing Symposium**, IEEE, PP. 7003-7006, <https://doi.org/10.1109/IGARSS.2012.6351959>.
- Basak, D., Pal, S., Ch, D. & Patranabis, R., 2007, **Support Vector Regression**, Neural Inf. Process, 11, PP. 203-225.
- Bazgã, B., 2015, **Food Security Component of Sustainable Development – Prospects and Challenges in the Next Decade**, Procedia Economics and Finance, 32, PP. 1075-1082, [https://doi.org/10.1016/S2212-5671\(15\)01570-1](https://doi.org/10.1016/S2212-5671(15)01570-1).
- Boser, B.E., Guyon, I.M. & Vapnik, V.N., 1992, **Training Algorithm for Optimal Margin Classifiers**, Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory, PP. 144-152, <https://doi.org/10.1145/130385.130401>.
- Burges, C.J.C., 1998, **A Tutorial on Support Vector Machines for Pattern Recognition**, Data Mining and Knowledge Discovery, 2, PP. 121-167, <https://doi.org/10.1023/A:1009715923555>.
- Christensen, C.T., Rens, L.R., Pack, J.E., Zotarelli, L., Hutchinson, C., Dahl, W., Gergela, D. & White, J.M., 2013, **Growing Potatoes in the Florida Home Garden**, HS933/HS183, 4/2013, EDIS, 2013.
- da Silva Junior, C.A., Leonel-Junior, A.H.S., Rossi, F.S., Correia Filho, W.L.F., de Barros Santiago, D., de Oliveira-Júnior, J.F., Teodoro, P.E., Lima, M. & Capristo-Silva, G.F., 2020, **Mapping Soybean Planting Area in Midwest Brazil with Remotely Sensed Images and Phenology-Based Algorithm Using the Google Earth Engine Platform**, Computers and Electronics in Agriculture, 169, P. 105194, <https://doi.org/10.1016/j.compag.2019.105194>.
- Das, M., Ghosh, S.K., Chowdary, V.M., Mitra, P. & Rijal, S., 2022, **Statistical and Machine Learning Models for Remote Sensing Data Mining-Recent Advancements**, Remote Sensing, 14(8), P. 1906, <https://doi.org/10.3390/rs14081906>.
- Devaux, A., Kromann, P. & Ortiz, O., 2014, **Potatoes for Sustainable Global Food Security**, Potato Research 57(3), PP. 185-199, <https://doi.org/10.1007/s11540-014-9265-1>.

- Dheeravath, V., Thenkabail, P.S., Chandrakantha, G., Noojipady, P., Reddy, G.P.O., Biradar, C.M., Gumma, M.K. & Velpuri, M., 2010, **Irrigated Areas of India Derived Using MODIS 500 m Time Series for the Years 2001-2003**, ISPRS Journal of Photogrammetry and Remote Sensing, 65, PP. 42-59, <https://doi.org/10.1016/j.isprsjprs.2009.08.004>.
- Dong, J., Xiao, X., Kou, W., Qin, Y., Zhang, G., Li, L., Jin, C., Zhou, Y., Wang, J. & Biradar, C., 2015, **Tracking the Dynamics of Paddy Rice Planting Area in 1986-2010 through Time Series Landsat Images and Phenology-Based Algorithms**, Remote Sensing of Environment, 160, PP. 99-113, <https://doi.org/10.1016/j.rse.2015.01.004>.
- Egorov, A.V., Hansen, M.C., Roy, D.P., Kommareddy, A. & Potapov, P. V., 2015, **Image Interpretation-Guided Supervised Classification Using Nested Segmentation**, Remote Sensing of Environment, 165, PP. 135-147, <https://doi.org/10.1016/j.rse.2015.04.022>.
- ESA., 2022, **User Guides**, <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi>.
- FAO, 2016, **FAOSTAT. 2016. FAO Satisfical Database**, fao.org/publications.
- Fatemi, S.B., Mubasheri, M.R. & Abkar, A.A., 2014, **The Effect of Using Spatial Neighborhood Information on the Accuracy of Satellite Image Clustering**, Journal of Geomatics Science and Technology, 3(4), P. 77 (In Persian).
- Feng, S., Zhao, J., Liu, T., Zhang, H., Zhang, Z. & Guo, X., 2019, **Crop Type Identification and Mapping Using Machine Learning Algorithms and Sentinel-2 Time Series Data**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 12, PP. 3295-3306, <https://doi.org/10.1109/JSTARS.2019.2922469>.
- Foody, G.M. & Mathur, A., 2004, **Toward Intelligent Training of Supervised Image Classifications: Directing Training Data Acquisition for SVM Classification**, Remote Sensing of Environment, 93, PP. 107-117, <https://doi.org/10.1016/j.rse.2004.06.017>.
- Godfray, H.C.J., Beddington, J.R., Crute, I.R., Haddad, L., Lawrence, D., Muir, J.F., Pretty, J., Robinson, S., Thomas, S.M. & Toulmin, C., 2010, **Food Security: The Challenge of Feeding 9 Billion People**, Science, 327, PP. 812-818, <https://doi.org/10.1126/science.1185383>.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D. & Moore, R., 2017, **Google Earth Engine: Planetary-Scale Geospatial Analysis for Everyone**, Remote Sensing of Environment, 202, PP. 18-27, <https://doi.org/10.1016/j.rse.2017.06.031>.
- Hamedani, S.R., Shabani, Z. & Rafiee, S., 2011, **Energy Inputs and Crop Yield Relationship in Potato Production in Hamadan Province of Iran**, Energy, 36(5), PP. 2367-2371, <https://doi.org/10.1016/j.energy.2011.01.013>.
- Hitiou, A., Boudhar, A., Lebrini, Y., Hadria, R., Lionboui, H. & Benabdellouahab, T., 2022, **A Comparative Analysis of Different Phenological Information Retrieved from Sentinel-2 Time Series Images to Improve Crop Classification: A Machine Learning Approach**, Geocarto International, 37(5), PP. 1426-1449, <https://doi.org/10.1080/10106049.2020.1768593>.
- Hu, Q., Sulla-Menashe, D., Xu, B., Yin, H., Tang, H., Yang, P. & Wu, W., 2019, **A Phenology-Based Spectral and Temporal Feature Selection Method for Crop Mapping from Satellite Time Series**, International Journal of Applied Earth Observation and Geoinformation, 80, PP. 218-229, <https://doi.org/10.1016/j.jag.2019.04.014>.
- Ja'fari, A., 2005, **Gitā-Šenāsi-e-Irān I: Kuhhā va Kuh-Nāma-ye Irān**, Gitashenasi Institute Tehran (In Persian).
- James, G., Witten, D., Hastie, T. & Tibshirani, R., 2013, **Bias-Variance Trade-Off for k-Fold Cross-Validation**, An Introduction to Statistical Learning - with Applications in R, 7, P. 24. <https://doi.org/10.1080/22797254.2017.1297540>.
- Jayne, T.S., Chamberlin, J. & Headey, D.D., 2014, **Land Pressures, the Evolution of Farming Systems, and Development Strategies in Africa: A Synthesis**, Food Policy, 48, PP. 1-17, <https://doi.org/10.1016/j.foodpol.2014.05.014>.
- Jefferies, R.A. & Lawson, H.M., 1991, **A Key**

- for the Stages of Development of Potato (*Solatum Tuberosum*)**, *Annals of Applied Biology*, 119, PP. 387-399, <https://doi.org/10.1111/j.1744-7348.1991.tb04879.x>.
- Jeganathan, C., Dash, J. & Atkinson, P.M., 2014, **Remotely Sensed Trends in the Phenology of Northern High Latitude Terrestrial Vegetation, Controlling for Land Cover Change and Vegetation Type**, *Remote Sensing of Environment*, 143, PP. 154-170, <https://doi.org/10.1016/j.rse.2013.11.020>.
- Julien, Y., Sobrino, J.A. & Jiménez-Muñoz, J.-C., 2011, **Land Use Classification from Multitemporal Landsat Imagery Using the Yearly Land Cover Dynamics (YLCD) Method**, *International Journal of Applied Earth Observation and Geoinformation*, 13(5), PP. 711-720, <https://doi.org/10.1016/j.jag.2011.05.008>.
- Kaplan, G. & Avdan, U., 2017, **Object-Based Water Body Extraction Model Using Sentinel-2 Satellite Imagery**, *European Journal of Remote Sensing*, 50, PP. 137-143, <https://doi.org/10.1080/22797254.2017.1297540>.
- Kidane, Y., 2022, **Vegetation Diversity and Distribution along the Bale Mountains Afroalpine Hotspot of Biodiversity in the Face of a Fast-Changing World**, Doctoral Dissertation, https://doi.org/10.15495/Epub_UBT_00006510.
- Lary, D.J., Alavi, A.H., Gandomi, A.H. & Walker, A.L., 2016, **Machine Learning in Geosciences and Remote Sensing**, *Geoscience Frontiers*, 7, PP. 3-10, <https://doi.org/10.1016/j.gsf.2015.07.003>.
- Li, C., Li, H., Li, J., Lei, Y., Li, C., Manevski, K. & Shen, Y., 2019, **Using NDVI Percentiles to Monitor Real-Time Crop Growth**, *Computers and Electronics in Agriculture*, 162, PP. 357-363, <https://doi.org/10.1016/j.compag.2019.04.026>.
- Liu, L., Xiao, X., Qin, Y., Wang, J., Xu, X., Hu, Y. & Qiao, Z., 2020a, **Mapping Cropping Intensity in China Using Time Series Landsat and Sentinel-2 Images and Google Earth Engine**, *Remote Sensing of Environment*, 239, P. 111624, <https://doi.org/10.1016/j.rse.2019.111624>.
- Liu, X., Zhai, H., Shen, Y., Lou, B., Jiang, C., Li, T., Hussain, S.B. & Shen, G., 2020b, **Large Scale Crop Mapping From Multisource Remote Sensing Images in Google Earth Engine**, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, PP. 414-427, <http://doi.org/10.1109/JSTARS.2019.2963539>.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G. & Johnson, B.A., 2019, **Deep Learning in Remote Sensing Applications: A Meta-Analysis and Review**, *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, PP. 166-177, <https://doi.org/10.1016/j.isprsjprs.2019.04.015>.
- Massey, R., Sankey, T.T., Congalton, R.G., Yadav, K., Thenkabail, P.S., Ozdogan, M. & Sánchez Meador, A.J., 2017, **MODIS Phenology-Derived, Multi-Year Distribution of Conterminous U.S. Crop Types**, *Remote Sensing of Environment*, 198, PP. 490-503, <https://doi.org/10.1016/j.rse.2017.06.033>.
- Mather, P.M., 2004, **Computer Processing of Remotely-Sensed Images: An Introduction**, John Wiley & Sons, Inc., Hoboken, NJ, USA.
- Maxwell, A.E., Warner, T.A. & Fang, F., 2018, **Implementation of Machine-Learning Classification in Remote Sensing: An Applied Review**, *International Journal of Remote Sensing*, 39, PP. 2784-2817, <https://doi.org/10.1080/01431161.2018.1433343>.
- Mergos, G. & Papanastassiou, M., 2017, **Food Security and Sustainability: Globalisation, Investment and Financing**, *Food Security and Sustainability*, PP. 1-34, https://doi.org/10.1007/978-3-319-40790-6_1.
- Mhango, J.K., Harris, W.E. & Monaghan, J.M., 2021, **Relationships between the Spatio-Temporal Variation in Reflectance Data from the Sentinel-2 Satellite and Potato (*Solanum Tuberosum* L.) Yield and Stem Density**, *Remote Sensing*, 13(21), P. 4371, <https://doi.org/10.3390/rs13214371>.
- Mingwei, Z., Qingbo, Z., Zhongxin, C., Jia, L., Yong, Z. & Chongfa, C., 2008, **Crop Discrimination in Northern China with Double Cropping Systems Using Fourier Analysis of Time-Series MODIS Data**, *International Journal of Applied Earth Observation and Geoinformation*, 10, PP. 476-485, <https://doi.org/10.1016/j.jag.2007.11.002>.
- Misra, G., Cawkwell, F. & Wingler, A., 2020,

- Status of Phenological Research Using Sentinel-2 Data: A Review, Remote Sensing**, 12(17), P. 2760, <https://doi.org/10.3390/rs12172760>.
- Mohammadi, A., Tabatabaeefar, A., Shahin, S., Rafiee, S. & Keyhani, A., 2008, **Energy Use and Economical Analysis of Potato Production in Iran a Case Study: Ardabil Province**, Energy Conversion and Management, 49, PP. 3566-3570, <https://doi.org/10.1016/j.enconman.2008.07.003>.
- Mohammadi, A., Costelloe, J.F. & Ryu, D., 2017, **Application of Time Series of Remotely Sensed Normalized Difference Water, Vegetation and Moisture Indices in Characterizing Flood Dynamics of Large-Scale Arid Zone Floodplains**, Remote Sensing of Environment, 190, PP. 70-82, <https://doi.org/10.1016/j.rse.2016.12.003>.
- Mountrakis, G., Im, J. & Ogole, C., 2011, **Support Vector Machines in Remote Sensing: A Review**, ISPRS Journal of Photogrammetry and Remote Sensing, 66, PP. 247-259, <https://doi.org/10.1016/j.isprsjprs.2010.11.001>.
- Myneni, R.B., Maggion, S., Jaquinta, J., Privette, J.L., Gobron, N., Pinty, B., Kimes, D.S., Verstraete, M.M. & Williams, D.L., 1995, **Optical Remote Sensing of Vegetation: Modeling, Caveats, and Algorithms**, Remote Sensing of Environment, 51, PP. 169-188, [https://doi.org/10.1016/0034-4257\(94\)00073-V](https://doi.org/10.1016/0034-4257(94)00073-V).
- Navulur, K., 2006, **Multispectral Image Analysis Using the Object-Oriented Paradigm**, Multispectral Image Analysis Using the Object-Oriented Paradigm, PP. 1-155, <https://doi.org/10.1201/9781420043075>.
- Pan, Z., Huang, J., Zhou, Q., Wang, L., Cheng, Y., Zhang, H., Blackburn, G.A., Yan, J. & Liu, J., 2015, **Mapping Crop Phenology Using NDVI Time-Series Derived from HJ-1 A/B Data**, International Journal of Applied Earth Observation and Geoinformation, 34, PP. 188-197, <https://doi.org/10.1016/j.jag.2014.08.011>.
- Rao, P., Zhou, W., Bhattarai, N., Srivastava, A.K., Singh, B., Poonia, S., Lobell, D.B. & Jain, M., 2021, **Using Sentinel-1, Sentinel-2, and Planet Imagery to Map Crop Type of Smallholder Farms**, Remote Sensing, 13(10), P. 1870, <https://doi.org/10.3390/rs13101870>.
- Rouzbahani, M., Farsizadeh, N., Fathian, V. & Hajeb, M., 2014, **Automatic Mapping of Urban Objects Using Remote Sensing Data**, The 1st National Conference on Modern Studies and Research in Geography, Architecture and Urban Development of Iran, Tehran (In Persian).
- Saad El Imanni, H., El Harti, A., Hssaisoune, M., Velastegui-Montoya, A., Elbouzidi, A., Addi, M., El Iysaouy, L. & El Hachimi, J., 2022, **Rapid and Automated Approach for Early Crop Mapping Using Sentinel-1 and Sentinel-2 on Google Earth Engine; A Case of a Highly Heterogeneous and Fragmented Agricultural Region**, Journal of Imaging, 8(12), P. 316, <https://doi.org/10.3390/jimaging8120316>.
- Sebbar, B.E., Moumni, A. & Lahrouni, A., 2020, **Impact of Internal Parameterization on the Performance of Support Vector Machines for Crop Mapping Sentinel-2 NDVI Time Series**, International conference on Advanced Technologies for Humanity, 1.
- Shao, Y. & Lunetta, R.S., 2012, **Comparison of Support Vector Machine, Neural Network, and CART Algorithms for the Land-Cover Classification Using Limited Training Data Points**, ISPRS Journal of Photogrammetry and Remote Sensing, 70, PP. 78-87, <https://doi.org/10.1016/j.isprsjprs.2012.04.001>.
- Shi, W., Zhang, M., Zhang, R., Chen, S. & Zhan, Z., 2020, **Change Detection Based on Artificial Intelligence: State-of-the-Art and Challenges**, Remote Sensing, 12, P. 1688, <https://doi.org/10.3390/rs12101688>.
- Shin, K.S., Lee, T.S. & Kim, H.J., 2005, **An Application of Support Vector Machines in Bankruptcy Prediction Model**, Expert Systems with Applications, 28, PP. 127-135, <https://doi.org/10.1016/j.eswa.2004.08.009>.
- Spooner, D.M., McLean, K., Ramsay, G., Waugh, R. & Bryan, G.J., 2005, **A Single Domestication for Potato Based on Multilocus Amplified Fragment Length Polymorphism Genotyping**, Proceedings of the National Academy of Sciences, 102, PP. 14694-14699, <https://doi.org/10.1073/pnas.050740010>.

- Sun, Z., Di, L., Fang, H. & Burgess, A., 2020, **Deep Learning Classification for Crop Types in North Dakota**, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 13, PP. 2200-2213, <https://doi.org/10.1109/JSTARS.2020.2990104>.
- Tarabalka, Y., Fauvel, M., Chanussot, J. & Benediktsson, J.A., 2010, **SVM- and MRF-Based Method for Accurate Classification of Hyperspectral Images**, IEEE Geoscience and Remote Sensing Letters, 7, PP. 736-740, <https://doi.org/10.1109/LGRS.2010.2047711>.
- Tatsumi, K., Yamashiki, Y., Torres, M.A.C. & Taïpe, C.L.R., 2015, **Crop Classification of Upland Fields Using Random Forest of Time-Series Landsat 7 ETM+ Data**, Computers and Electronics in Agriculture, 115, PP. 171-179, <https://doi.org/10.1016/j.compag.2015.05.001>.
- Vapnik, V.N., 1999, **The Nature of Statistical Learning Theory**, Springer Science & Business Media.
- Vapnik, V.N., 2000, **The Nature of Statistical Learning Theory**, Springer Science & Business Media .
- Virnodkar, S.S., Pachghare, V.K., Patil, V.C. & Jha, S.K., 2020, **Application of Machine Learning on Remote Sensing Data for Sugarcane Crop Classification: A Review BT - ICT Analysis and Applications**, In: Fong, S., N. Dey & A. Joshi (eds.), Springer Singapore, Singapore, PP. 539-555, https://doi.org/10.1007/978-981-15-0630-7_55.
- Wang, L., Dong, Q., Yang, L., Gao, J. & Liu, J., 2019, **Crop Classification Based on a Novel Feature Filtering and Enhancement Method**, Remote Sensing, 11(4), P. 455, <https://doi.org/10.3390/rs11040455>.
- Wardlow, B.D. & Egbert, S.L., 2008, **Large-Area Crop Mapping Using Time-Series MODIS 250 m NDVI Data: An Assessment for the U.S. Central Great Plains**, Remote Sensing of Environment, 112, PP. 1096-1116, <https://doi.org/10.1016/j.rse.2007.07.019>.
- Xiong, J., Thenkabail, P.S., Gumma, M.K., Teluguntla, P., Poehnelt, J., Congalton, R.G., Yadav, K. & Thau, D., 2017, **Automated Cropland Mapping of Continental Africa Using Google Earth Engine Cloud Computing**, ISPRS Journal of Photogrammetry and Remote Sensing, 126, PP. 225-244, <https://doi.org/10.1016/j.isprsjprs.2017.01.019>.
- Yan, L. & Roy, D.P., 2018, **Large-Area Gap Filling of Landsat Reflectance Time Series by Spectral-Angle-Mapper Based Spatio-Temporal Similarity (SAMSTS)**, Remote Sensing, 10 (4), P. 609, <https://doi.org/10.3390/rs10040609>.
- Zhang, J., Feng, L. & Yao, F., 2014, **Improved Maize Cultivated Area Estimation over a Large Scale Combining MODIS-EVI Time Series Data and Crop Phenological Information**, ISPRS Journal of Photogrammetry and Remote Sensing, 94, PP. 102-113, <https://doi.org/10.1016/j.isprsjprs.2014.04.023>.
- Zhong, L., Hu, L., Yu, L., Gong, P. & Biging, G. S., 2016, **Automated Mapping of Soybean and Corn Using Phenology**, ISPRS Journal of Photogrammetry and Remote Sensing, 119, PP. 151-164, <https://doi.org/10.1016/j.isprsjprs.2016.05.014>.