



Comparison of different classification methods in estimating sugar beet canopy cover fraction using drone images

Seyed Reza Haddadi¹ | Masoud Soltani² | Abbas Kaviani³

1. Department of Water Science and Engineering, Faculty of Agricultural and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: seyedreza13753019@gmail.com
2. Corresponding Author, Department of Water Science and Engineering, Faculty of Agricultural and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: msoltani@eng.ikiu.ac.ir
3. Department of Water Science and Engineering, Faculty of Agricultural and Natural Resources, Imam Khomeini International University, Qazvin, Iran. E-mail: kaviani@eng.ikiu.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 9 October 2024

Received in revised form

10 November 2024

Accepted 16 December 2024

Published online 10 February 2025

Keywords:

Maximum Likelihood

Mahalanobis Distance

Minimum Distance

Support Vector Machine

Neural Network

ABSTRACT

Canopy cover fraction (CCF) is one of vital parameters to determine crop appearance and stress detection. Recent advancement in technologies and availability of digital camera with high quality provide suitable condition for monitoring and determining canopy cover fraction during whole growing season without disturbing. In this study sugar beet aerial photos taken from research field of science institute in Switzerland was used. A number of 481 images were taken in the visible spectrum band at an average height of 10 meters above the ground using a DJI MATRICE 100 drone on four different dates. To determine the canopy cover fraction, five supervised classification methods, including Mahalanobis distance (MahD), maximum likelihood (MaxLh), minimum distance (MinD), neural network (NN) and support vector machine (SVM) were evaluated. The results showed that SVM and MaxLh methods with an overall accuracy (OA) of 99% had the best results in image classification and CCF calculation. The comparison of the obtained results for all imaging dates showed that in terms of processing time, the MaxLh method with a relatively simple mechanism is the most appropriate method in estimating the sugar beet CCF and compared to the methods based on machine learning, like NN and SVM, it is faster and can be used as an alternative method with high accuracy and very close to machine learning methods.

Cite this article: Haddadi, S. R., Soltani, M., & Kaviani, A. (2025). Comparison of different classification methods in estimating sugar beet canopy cover fraction using drone images. *Journal of Water and Irrigation Management*, 14 (4), 989-1004. DOI: <https://doi.org/10.22059/jwim.2024.383445.1181>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2024.383445.1181>

Publisher: University of Tehran Press.



مقایسه روش‌های مختلف طبقه‌بندی در برآورد کسر پوشش گیاهی چغندر قند با استفاده از تصاویر پهپادی

سید رضا حدادی^۱ | مسعود سلطانی^۲ | عباس کاویانی^۳

۱. گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه: seyedreza13753019@gmail.com
۲. نویسنده مسئول، گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه: msoltani@eng.ikiu.ac.ir
۳. گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه بین‌المللی امام خمینی (ره)، قزوین، ایران. رایانامه: kaviani@eng.ikiu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	کسر پوشش گیاهی (CCF) یکی از شاخص‌های مهم در تعیین وضعیت ظاهری گیاه و تشخیص وضعیت گیاه از نظر وجود و یا عدم وجود تنش در گیاه محسوب می‌شود. امروزه با پیشرفت فن‌آوری و در دسترس بودن دوربین‌های دیجیتالی با کیفیت بالا، امکان تعیین و پایش کسر پوشش گیاهی در تمام طول فصل رشد و بدون تخریب گیاه وجود دارد. در این پژوهش برای تعیین کسر پوشش گیاهی چغندر قند، از تصاویر هوایی مزرعه پژوهشگاه علوم گیاهی در سوئیس استفاده شد. تعداد ۴۸۱ تصویر در باند طیف مرئی و در ارتفاع متوسط ۱۰ متری از سطح زمین با استفاده از پهپاد DJI MATRICE 100 در چهار تاریخ مختلف برداشت شد. برای تعیین کسر پوشش گیاهی پنج روش طبقه‌بندی نظارت‌شده، شامل فاصله ماهالانویسی (MahD)، حداکثر احتمال (MaxLh)، حداقل فاصله (MinD)، شبکه عصبی (NN) و ماشین بردار پشتیبان (SVM) مورد بررسی و ارزیابی قرار گرفتند. نتایج نشان داد دو روش SVM و MaxLh با مقدار دقت کلی (OA) ۹۹ درصد بهترین نتیجه را در طبقه‌بندی تصویر و محاسبه کسر پوشش گیاهی داشتند. مقایسه نتایج به‌دست‌آمده برای تمام تاریخ‌های تصویربرداری نشان داد از نظر زمان پردازش‌ها روش MaxLh با سازوکار نسبتاً ساده به‌عنوان مناسب‌ترین روش در برآورد پوشش سایه‌انداز چغندر قند هست و نسبت به روش‌های مبتنی بر یادگیری ماشین مانند NN و SVM سریع‌تر بوده و می‌تواند به‌عنوان روش جایگزین با دقت بالا و بسیار نزدیک به روش‌های یادگیری ماشین، مورد استفاده قرار گیرد.
تاریخ دریافت: ۱۴۰۳/۰۷/۱۸	
تاریخ بازنگری: ۱۴۰۳/۰۸/۲۰	
تاریخ پذیرش: ۱۴۰۳/۰۹/۲۶	
تاریخ انتشار: ۱۴۰۳/۱۱/۲۲	
کلیدواژه‌ها: حداکثر احتمال حداقل فاصله فاصله ماهالانویسی شبکه عصبی ماشین بردار پشتیبان	

استناد: حدادی، سیدرضا؛ سلطانی، مسعود و کاویانی، عباس (۱۴۰۳). مقایسه روش‌های مختلف طبقه‌بندی در برآورد کسر پوشش گیاهی چغندر قند با استفاده از تصاویر پهپادی. نشریه مدیریت آب و آبیاری، ۱۴ (۴)، ۹۸۹-۱۰۰۴. DOI: <https://doi.org/10.22059/jwim.2024.383445.1181>



۱. مقدمه

کشاورزی به‌عنوان تأمین‌کننده اصلی نیاز غذایی تحت تأثیر عوامل مخاطره‌ای، نظیر چالش‌های افزایش فزاینده نرخ جمعیت، تغییرات آب‌وهوایی، سلامت و امنیت غذایی، مسائل زیست‌محیطی و پایداری منابع آب‌و خاک قرار دارد (Friha *et al.*, 2021; Inoue, 2020). از این رو، برنامه‌ریزی برای تحقق نیازهای اولیه غذایی در راستای توسعه پایدار کشاورزی است. چغندر قند با نام علمی *Beta vulgaris L.* گیاهی دوساله است که به‌صورت گیاهی یک‌ساله، زراعت می‌شود و در تولید قند ساکارز مورد استفاده قرار می‌گیرد. چغندر قند در جهان، به‌طور عمده در کمربندی از ۶۰ درجه عرض جغرافیایی شمال تا ۳۰ درجه عرض جغرافیایی جنوب کشت می‌شود. رشد پوشش سایه‌انداز (CC) به‌طور عمده وابسته به دما است و اغلب مقدار CC پس از حدود هشت تا ۱۰ هفته به بیشینه خود (CCx) می‌رسد (Steduto *et al.*, 2012). این مدت‌زمان در روز تخمینی است و دما و دسترسی به آب می‌تواند بر طول هر فاز تأثیر بگذارد. از طریق نظارت مستمر بر وضعیت گیاه در دوره رشد می‌توان به بهبود عملکرد نهایی گیاه کمک کرد و با تشخیص به‌موقع نشانه‌های تنش نظیر تنش‌های کود و آب می‌توان در جهت جبران تنش تلاش کرد و بهره‌وری آب و کود را ارتقا بخشید. بهره‌بردن از فناوری‌های جدید، نظیر پردازش تصاویر و سنجش‌ازدور می‌تواند باعث افزایش سرعت و دقت در برآورد سطح پوشش گیاهی شود. شاخص‌های مختلفی برای برآورد وضعیت رشد گیاه، نظیر شاخص سطح برگ و پوشش سایه‌انداز مورد استفاده قرار می‌گیرند.

شاخص سطح برگ (LAI) و پوشش سایه‌انداز دو پارامتر مهم گیاهی برای نظارت بر رشد گیاه به‌شمار می‌روند. شاخص سطح برگ (LAI) یک ویژگی بیوفیزیکی است که منعکس‌کننده وضعیت سلامت محصول است (Bryson *et al.*, 1997). این شاخص تا حد زیادی به مرحله رشد محصول، ارتفاع محصول، ساختمان برگ‌ها و تراکم گیاهان بستگی دارد (Vose *et al.*, 1994)، اما هم‌چنین می‌تواند از تنش آبی کوتاه‌مدت ناشی از چرخش برگ نیز تأثیر پذیرد (Chen *et al.*, 1992). یک نکته مهم این است که LAI نشان‌دهنده افزایشی در سطح روزنه‌های برگ و در نتیجه تبادل گازی بین محصول و پوشش گیاهی است (Patan'e, 2011). بر این اساس، مدل‌های مختلف گیاهی از LAI برای محاسبه راندمان مصرف نور پوشش گیاهی، برای شبیه‌سازی معادلات بیلان انرژی و فراهم‌سازی امکان درک فرایندهای فیزیکی که بین گیاهان و محیط‌زیست اتفاق می‌افتد، استفاده می‌کنند (Bonan *et al.*, 1993; Running *et al.*, 1988; Qu *et al.*, 2016; Drewry *et al.*, 2010; Haddadi, *et al.*, 2024). پوشش سایه‌انداز (CC) یک متغیر پیش‌بینی‌کننده خوب برای رشد گیاه نظیر پارامترهای دیگری مانند شاخص سطح برگ (LAI) و زیست‌توده بالای سطح زمین است (Behrens and Richardson *et al.*, 2001; Diepenbrock 2006; Li *et al.*, 2010; Pan *et al.*, 2007). کسر پوشش سایه‌انداز (CCF) که به‌عنوان نسبت سطح زمین اشغال‌شده از طریق پوشش سبز گیاهی شناخته می‌شود (Purevdorj *et al.*, 1998)، یکی از پرکاربردترین ویژگی‌های ساختاری گیاه است و از نقش مهمی در نظارت بر وضعیت رشد گیاه و تخمین عملکرد محصول برخوردار است (De La casa *et al.*, 2018). رویکردهای بسیاری برای اندازه‌گیری LAI و CCF محصولات مختلف در مطالعات مختلف وجود دارد که به‌طور کلی در دو دسته رویکردهای مبتنی بر اندازه‌گیری‌های مستقیم زمینی و رویکردهای غیرمستقیم سنجش‌ازدوری تقسیم می‌شود. رویکردهای مستقیم مبتنی بر اندازه‌گیری‌های زمینی، معمولاً پرزحمت، زمان‌بر و با هزینه فراوان هستند. این به‌دلیل‌دلیل وجود نیاز برای تعداد نمونه‌برداری بالاست که بتوان به کمک آن‌ها یک محدوده بزرگی را تحت پوشش قرار داد. یکی از مزایای کاربرد CCF نسبت به سایر روش‌های اندازه‌گیری رشد گیاه، مانند شاخص سطح برگ (LAI)، این است که مقدار آن از طریق تصاویر دیجیتال (مرئی) قابل برآورد است (Lee and Lee, 2011; Coy *et al.*, 2016). برای این منظور، می‌توان از تصاویر دوربین‌های دیجیتال و بدون آسیب‌زدن به بوته گیاه مقدار دقیق CCF را تعیین و از روابط ریاضی موجود، مقدار LAI را تخمین زد.

فناوری سنجش‌ازدور برای نتیجه‌گیری از اطلاعات رشد گیاه، از اندازه‌گیری‌های طیفی دوربین‌های مختلف استفاده می‌کند. برای مثال، ماهواره‌های مجهز به دوربین‌های چند طیفی می‌تواند اطلاعات مفیدی در مورد برآورد LAI با استفاده از باند مادون‌قرمز نزدیک (NIR) ارائه کنند. اگرچه سنجش‌ازدور مبتنی بر ماهواره برای کاربردهای مساحت بزرگ مناسب هستند، باید توجه نیز داشت که معایبی برای سنجش‌ازدور مبتنی بر ماهواره وجود دارد. هزینه سنجش‌ازدور ماهواره‌ای معمولاً بالاست. درجه تفکیک مکانی تصاویر ماهواره‌ای معمولاً پایین است و به‌سادگی تحت تأثیر عوامل محیطی نظیر وجود ابر قرار می‌گیرد. زمان بازدید ماهواره‌ها و تصویربرداری دوباره آن‌ها معمولاً ثابت بوده و انعطاف‌پذیر نیست. در مقابل، سنجش‌ازدور مبتنی بر پرنده‌های بدون سرنشین هدایت‌پذیر از دور (پهپاد) قرار دارد که تفکیک مکانی-زمانی آن توسط کاربر تعیین می‌شود. از مزایای این وسیله، هزینه کم و کاربری آسان بوده که باعث شده تا علاقه به استفاده از آن در حال افزایش باشد و تکمیل‌کننده خوبی برای سنجش‌ازدور ماهواره‌ای یا مبتنی بر هواپیمای سرنشین‌دار باشد. در این رویکرد، دوربین‌های طیفی متفاوتی (نظیر RGB، چندطیفی، فرا طیفی، حرارتی) می‌تواند بر پهپاد نصب شود تا برای کاربردهای مختلفی نظیر ارزیابی تنش آبی مورد استفاده قرار گیرد. پهپادها می‌توانند تصاویر با کیفیت و وضوح بالا در روزهای ابری فراهم کنند (Manfreda *et al.*, 2018). هم‌چنین در دسترس بودن و سرعت انتقال آن‌ها نیز از مزایای دیگر آن‌ها است (Radoglou-Grammatikis *et al.*, 2020). پهپادها را می‌توان در چندین فعالیت کشاورزی، از جمله نظارت بر محصول و رشد، برآورد عملکرد، ارزیابی تنش آبی و تشخیص و آشکارسازی علف‌هرز، آفات و بیماری‌ها استفاده کرد (Inoue, 2020; Panday *et al.*, 2020). از سوی دیگر، پهپادها نیز با محدودیت‌هایی مواجه هستند. مشارکت هدایت‌کننده، قدرت موتور، پایداری و اطمینان‌پذیری، کیفیت حسگرها به‌دلیل محدودیت‌های بار وزنی، هزینه‌های اجرا و مقررات پرواز از جمله این محدودیت‌ها هستند (Zhang and Kovacs, 2012). در پژوهشی شاخص سطح برگ برای مزرعه ذرت علوفه‌ای با استفاده از تصاویر پهپادی تهیه شد و توزیع مکانی آن مورد ارزیابی قرار گرفت. نتایج این پژوهش نشان داد ۹۶/۶ درصد از تغییرات شاخص سطح برگ در سطح مزرعه، توسط دو متغیر کسر پوشش گیاهی و باند مادون‌قرمز نزدیک وارد شده به مدل قابل تبیین بود (Gooyandeh *et al.*, 2019). در پژوهش دیگری با استفاده از داده‌های طیفی برداشت‌شده با پهپاد، آشکارسازی درختان پرتقال و تشخیص تنش گیاهی را مورد مطالعه قرار دادند. نتایج پژوهش نشان داد، الگوریتم‌های طبقه‌بندی برای تشخیص درختان دارای تنش با صحت کلی ۶۹ درصد، کارایی پهپادها برای آگاهی‌دادن به بهره‌برداران را نشان داد (Miraki *et al.*, 2022). هم‌چنین در پژوهشی به‌کارگیری تصاویری پهپادی در برآورد پوشش سایه‌انداز گیاه ذرت با استفاده از الگوریتم‌های پردازش تصویر بررسی شد. هر دو روش جداسازی و طبقه‌بندی دقت بالایی در برآورد سطح سایه‌انداز ذرت داشتند، اما روش جداسازی درصد پوشش گیاهی را ۱۰ درصد کمتر از الگوریتم‌های طبقه‌بندی به دست آورد (Soltani, 2024). در پژوهش دیگری که باهدف بررسی تغییرات کاربری اراضی/پوشش زمین در حیرت صورت پذیرفت، از روش‌های مبتنی بر پیکسل فاصله‌ماهلانویسی، حداکثر احتمال، شبکه عصبی و ماشین بردار پشتیبان برای طبقه‌بندی تصاویر ماهواره‌ای استفاده شد. نتایج نشان داد که روش‌های شبکه عصبی و ماشین بردار پشتیبان تا حدودی عملکرد بهتری داشتند (به‌ترتیب ۹۳ درصد و ۹۲ درصد صحت کل) اما از نظر زمان اجرا روش حداکثر احتمال، بهترین روش است (Eslami *et al.*, 2022).

بررسی پژوهش‌های پیشین نشان می‌دهد، به‌کارگیری فناوری سنجش‌ازدور و الگوریتم‌های پردازش تصویر در محدوده‌ی وسیعی از موضوعات در علوم کشاورزی کاربرد دارند. اگرچه تصاویر ماهواره‌ای به‌عنوان داده‌های ارزشمند در این زمینه محسوب می‌شوند اما دارای محدودیت‌هایی از قبیل وجود ابرناکی در تصویر و هزینه بالای پرتاب و استقرار ماهواره در مدار هستند. در مقابل تصاویر پهپادی با دقت مکانی بسیار بالا در اختیار پژوهش‌گران قرار دارد. پیش‌تر از

این، دقت روش‌های مختلف طبقه‌بندی برای تصاویر ماهواره‌ای مورد بررسی و ارزیابی قرار گرفته است اما با افزایش روزافزون به‌کارگیری پهپادهای کشاورزی، لازم است بررسی مشابهی برای این تصاویر نیز انجام شود. هدف از انجام این پژوهش مقایسه روش‌های مختلف طبقه‌بندی نظارت‌شده تصاویر پهپادی در برآورد کسر پوشش گیاهی چغندر قند بر اساس شاخص‌های ارزیابی و سرعت پردازش در مراحل مختلف رشد گیاه است.

۲. مواد و روش‌ها

در این مطالعه از مجموعه تصاویر پهپادی محصول چغندر قند در محدوده طیفی مرئی اخذ شده توسط دانشگاه بُن آلمان استفاده شده است. تصاویر با همکاری دانشگاه بُن توسط Raghav Khanna *et al.* (2016) در مزرعه پژوهشگاه علوم گیاهی به وسعت ۳/۶۴ هکتار، با استفاده از پهپاد DJI MATRICE 100 در Lindau در سوئیس (۴۷/۴۵ درجه عرض شمالی و ۸/۶۸ درجه طول شرقی) تهیه شده است (Lottes *et al.*, 2017). شکل (۱)، محل مورد مطالعه را نشان می‌دهد. اقلیم‌نمای این منطقه نشان‌دهنده زمستان و تابستان‌های معتدل با دمای میانگین سالانه ۹/۴ درجه سانتی‌گراد و بارش متوسط سالانه ۱۲۸۰ میلی‌متر است. تصاویر در چهار تاریخ ۱۳۹۵/۰۲/۳۱ (۲۰۱۶/۰۵/۲۰)، ۱۳۹۵/۰۳/۰۷ (۲۰۱۶/۰۵/۲۷)، ۱۳۹۵/۰۳/۲۸ (۲۰۱۶/۰۶/۱۷) و ۱۳۹۵/۰۴/۰۲ (۲۰۱۶/۰۶/۲۲) تهیه شدند. در تاریخ اول، ۴۵ تصویر، در تاریخ دوم، ۱۷۵ تصویر، در تاریخ سوم، ۱۲۱ تصویر و در تاریخ چهارم ۱۴۰ تصویر برداشت شد. تصاویر با استفاده از دوربین Zenmuse X3 با ابعاد ۴۰۰×۲۲۵۰ پیکسل و قدرت تفکیک مکانی ۴ میلی‌متر در هر پیکسل در ارتفاع متوسط ۱۰ متر تصویربرداری شدند. تعداد تصاویر کل در هر تاریخ تصویربرداری متفاوت است. تصاویر تهیه‌شده در دوره رشد محصول چغندر قند از ابتدای مرحله چهاربرگی تا انتهای مرحله شش‌برگی شدن گیاه بود. سطح برگ از ۱۵۰ سانتی‌متر مربع در تاریخ اول تا ۴۳۰ سانتی‌متر مربع در تاریخ چهارم تغییر می‌کند (Chebroly *et al.*, 2018). فاصله ردیف‌ها از یکدیگر حدود ۳۹ سانتی‌متر و فاصله هر گیاه در ردیف حدود ۱۸ سانتی‌متر است.

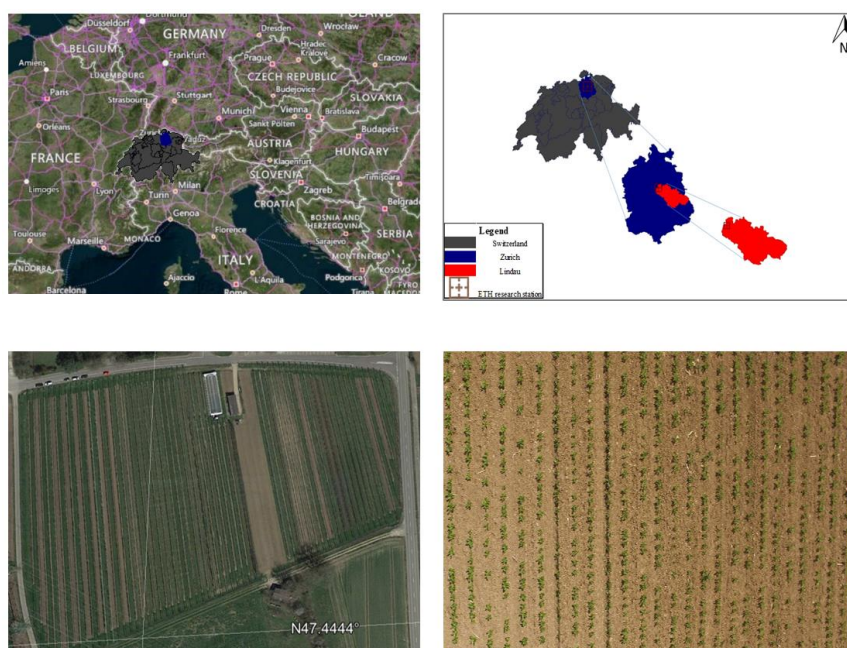


Figure 1. Plant Science Research Institute farm located in Switzerland, Lindau Eschikon

۱.۲. ارتوموزایک^۲ تصاویر

برای موزایک کردن تصاویر، از نرم افزار Image Composite Editor (ICE) استفاده شد و تصاویر نهایی برای همسان بودن با ابعاد تصویر موزایک تاریخ اول، برش داده شد. تصاویر خروجی برای بررسی عملکرد روش های طبقه بندی نظارت شده در تشخیص پوشش سایه انداز چغندر قند استفاده شد، که در چهار تاریخ در مکان های مختلفی از مزرعه مطالعاتی است. در این مطالعه، در ابتدا درصد پوشش سایه انداز توسط روش های طبقه بندی نظارت شده با مشخص کردن نمونه های آموزشی محاسبه و سپس با مقدار واقعیت زمینی مقایسه و ارزیابی شد.

۲.۲. طبقه بندی نظارت شده

طبقه بندی فرایند دسته بندی پیکسل های یک تصویر در دسته های مختلف است که به روش نظارت نشده و یا نظارت شده قابل به کارگیری است. در روش های نظارت نشده، نیازی به در نظر گرفتن نمونه های آموزشی نیست در صورتی که روش های نظارت شده با استفاده از نمونه های آموزشی، طبقه پیکسل های دیگر را حدس می زند. با توجه به پدیده های مختلف موجود در تصویر می توان تعداد دسته های مختلف با حداقل دو دسته را در نظر گرفت. نمونه های آموزشی توسط کاربر از محدوده مورد نظر (ROI) او برای هر دسته مشخص و باید برای تشخیص سایر پیکسل های تصویر در روش طبقه بندی معرفی شود.

در این مطالعه، از داده های آموزشی برای تعیین سه دسته پوشش گیاهی، خاک لخت و سایه (سایه زیر برگ ها) که دسته های غالب موجود در تصاویر بودند برای محصول چغندر قند و در چهار مرحله زمانی استفاده شد. همچنین برای طبقه بندی تصاویر از روش های طبقه بندی نظارت شده فاصله ماها لانویسی، حداکثر احتمال، حداقل فاصله، شبکه عصبی و ماشین بردار پشتیبان در نرم افزار Envi 5.6 استفاده شد.

۳.۲. طبقه بندی فاصله ماها لانویسی (MahD)

طبقه بندی فاصله ماها لانویسی یک روش طبقه بندی کننده فاصله حساس به جهت است که از آمار برای هر کلاس استفاده می کند. این روش شبیه به طبقه بندی حداکثر احتمال است، اما فرض می کند که همه کوواریانس های طبقه برابر هستند و بنابراین روش سریع تری است. همه پیکسل ها به نزدیک ترین دسته ROI طبقه بندی می شوند، مگر این که آستانه فاصله تعریف شود، در این صورت ممکن است برخی از پیکسل ها اگر آستانه را برآورده نکنند، طبقه بندی نشوند (Richards, 1999). طبقه بندی فاصله ماها لانویسی، فاصله را برای هر پیکسل در تصویر تا هر کلاس به صورت زیر تعیین می کند (رابطه ۱).

$$D_i(x) = \sqrt{(x - m_i)^T \Sigma_i^{-1} (x - m_i)} \quad \text{رابطه ۱}$$

که در این رابطه، D ، فاصله ماها لانویسی، i ، هر طبقه، x ، داده n بعدی که n نشان دهنده تعداد باندها است، Σ_i^{-1} ماتریس کوواریانس معکوس یک دسته و m_i ROI متوسط یک کلاس است. در این مطالعه، برای بررسی این روش، از نام اختصاری MahD استفاده شده است.

۴.۲. طبقه بندی حداکثر احتمال (MaxLh)

طبقه بندی حداکثر احتمال فرض می کند که آمار برای هر طبقه در هر باند به طور نرمال توزیع شده است و احتمال تعلق یک پیکسل معین به یک طبقه خاص را محاسبه می کند. اگر آستانه احتمالی انتخاب شود، همه پیکسل ها طبقه بندی

می‌شوند. هر پیکسل به طبقه‌ای اختصاص داده می‌شود که بیش‌ترین احتمال (یعنی حداکثر احتمال) را دارد. اگر بالاترین احتمال، کوچکتر از آستانه تعیین شده باشد، پیکسل موردنظر طبقه‌بندی نشده در نظر گرفته می‌شود. طبقه‌بندی حداکثر احتمال با محاسبه توابع متمایز زیر برای هر پیکسل از رابطه (۲) به دست می‌آید (Richards, 1999):

$$g_i(x) = \ln p(\omega_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad \text{رابطه (۲)}$$

که در این رابطه، i هر طبقه، x داده n بعدی که n نشان‌دهنده تعداد باندهاست، $P(\omega_i)$ احتمال رخداد کلاس ω_i در تصویر و برای همه طبقه‌ها یکسان فرض می‌شود، $|\Sigma_i|$ دترمینان ماتریس کوواریانس داده در کلاس ω_i ، Σ_i^{-1} ماتریس کوواریانس معکوس یک دسته و m_i بردار ROI متوسط یک کلاس است. در این مطالعه، برای بررسی این روش، از نام اختصاری MaxLh استفاده شده است.

۲.۵. طبقه‌بندی حداقل فاصله (MinD)

تکنیک حداقل فاصله از بردارهای میانگین هر عضو انتهایی استفاده می‌کند و فاصله اقلیدسی از هر پیکسل ناشناخته (طبقه‌بندی نشده) تا بردار میانگین برای هر طبقه را محاسبه می‌کند. همه پیکسل‌ها به نزدیک‌ترین کلاس طبقه‌بندی می‌شوند مگر اینکه انحراف استاندارد یا آستانه فاصله مشخص شده باشد، در این صورت ممکن است برخی از پیکسل‌ها در صورتی که معیارهای انتخاب شده را نداشته باشند، طبقه‌بندی نشوند (Richards, 1999). رابطه طبقه‌بندی حداقل فاصله به صورت زیر است (رابطه ۳):

$$D_i(x) = \sqrt{(x - m_i)^T (x - m_i)} \quad \text{رابطه (۳)}$$

که در این رابطه، D ، فاصله اقلیدسی، i هر طبقه، x داده n بعدی که n نشان‌دهنده تعداد باندهاست و m_i بردار ROI متوسط یک کلاس است. در این مطالعه، برای بررسی این روش، از نام اختصاری MinD استفاده شده است.

۲.۶. طبقه‌بندی شبکه عصبی (NN)

از شبکه عصبی برای اعمال تکنیک طبقه‌بندی شبکه عصبی لایه‌ای پیش‌خور می‌توان استفاده کرد. تکنیک شبکه عصبی از پس انتشار استاندارد برای یادگیری نظارت‌شده استفاده می‌کند. می‌توان تعداد لایه‌های مخفی و یکی از توابع فعال‌سازی لجستیک یا هایپربولیک را برای استفاده انتخاب کرد. یادگیری با تنظیم اوزان در گره برای به حداقل رساندن اختلاف بین فعال‌سازی گره خروجی و خروجی اتفاق می‌افتد. خطا از طریق شبکه منتشر می‌شود و تنظیم وزن با استفاده از یک روش بازگشتی صورت می‌گیرد. برای انجام طبقه‌بندی غیرخطی می‌توان از طبقه‌بندی شبکه عصبی استفاده کرد (Richards, 1999; Rumelhart and McClelland, 1987). در این مطالعه، برای بررسی این روش از نام اختصاری NN استفاده شده است.

۲.۷. طبقه‌بندی ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان (SVM) یک روش طبقه‌بندی نظارت‌شده است که از تئوری یادگیری آماری مشتق شده است و اغلب نتایج طبقه‌بندی خوبی را از داده‌های پیچیده و پر از نویز به دست می‌دهد. این روش طبقه‌بندی طبقه‌ها را با سطح تصمیم‌گیری جدا می‌کند که حاشیه بین طبقه‌ها را به حداکثر می‌رساند. این سطح اغلب ابرصفحه بهینه نامیده می‌شود و نقاط داده نزدیک به ابرصفحه را بردارهای پشتیبان می‌نامند. بردارهای پشتیبان عناصر مهم مجموعه آموزشی هستند. طبقه‌بندی SVM می‌تواند چندین ساعت طول بکشد تا با داده‌های آموزشی که از نواحی موردنظر (ROIs) بزرگ استفاده

می‌کند، کامل شود (Wu *et al.*, 2004; Chang and Lin, 2011; Hsu *et al.*, 2016). در این مطالعه، برای بررسی این روش از نام اختصاری SVM استفاده شده است.

مراحل انجام پژوهش به صورت گام به گام و مطابق با نمودار گردشی شکل (۲) می‌باشد. در ابتدا تصاویر وارد نرم‌افزار ادغام تصاویر (Mosaic) شد. سپس تصویر بزرگ‌تر به گونه‌ای تولید شد که در هر چهار مرحله زمانی یکسان باشد. پس از آن، نمونه‌های آموزشی برای سه دسته پوشش گیاهی، سایه زیر گیاه و خاک لخت تعیین شد. نمونه‌های آموزشی برای روش‌های مختلف طبقه‌بندی معرفی و روش‌ها بر اساس مبنای عملکرد خود، تصاویر خروجی را تولید کردند. از محاسبه پیکسل‌های پوشش گیاهی و تقسیم بر تعداد کل پیکسل‌های تصویر، درصد پوشش گیاهی به دست آمد و در نهایت ارزیابی آماری انجام شد.

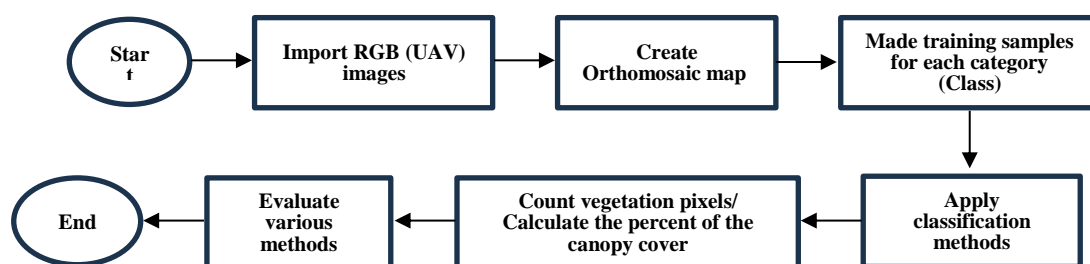


Figure 2. Flowchart of the work steps in this research

۸.۲. بررسی و تجزیه و تحلیل آماری

در این مطالعه علاوه بر بررسی تغییرات سه دسته پوشش گیاهی، خاک و سایه با استفاده از روش‌های مختلف طبقه‌بندی، آزمون تفکیک‌پذیری (Separability test) و پارامترهای ارزیابی صحت کل (Overall Accuracy)، ضریب کاپا (Kappa Coefficient)، صحت کاربر یا دقت (User's Accuracy)، صحت تولیدکننده یا یادآوری (Producer's Accuracy)، خطاهای حذف و اضافه (Omission and Commission error) و ماتریس آشفتگی (Confusion Matrix) برای بررسی کیفیت طبقه‌بندی بررسی شدند. نتایج مربوط به آزمون تفکیک‌پذیری بر اساس معیار Jefferies برای دسته‌های تعریف شده در محیط نرم‌افزار Envi 5.6 برای بررسی میزان شباهت یا عدم شباهت پیکسل‌های استفاده شده برای داده‌های آموزشی است. برای محاسبه سایر پارامترهای آماری اشاره شده، بایستی بین تصویر طبقه‌بندی و تصویر واقعیت زمینی مقایسه صورت بگیرد. تصویر واقعیت زمینی، تصویر مبنایی است که عملکرد روش‌های مختلف طبقه‌بندی از مقایسه با آن سنجیده می‌شود. روش‌های مختلفی نظیر سنجش زمینی برای تهیه این تصویر وجود دارد. در این مطالعه، تصویر واقعیت زمینی در بستر نرم‌افزار Envi و با استفاده از روش تولید تصویر واقعیت زمینی با استفاده از ناحیه موردنظر (ROI) با تعریف نمونه‌های آموزشی برای پیکسل‌های هر دسته انجام شد. روابط (۴) تا (۱۰)، فرمول پارامترهای KpC، OA، Producer's Accuracy، User's Accuracy، Omission Error، Commission Error و F1-score را نشان می‌دهد (Cardille *et al.*, 2024).

$$\text{Overall Accuracy (\%)} = \frac{\text{True Positive} + \text{True Negative}}{\text{Sample size}} \times 100 \quad (\text{رابطه ۴})$$

که در این رابطه، مقادیر True Positive (TP) و True Negative (TN) اعداد روی قطر اصلی ماتریس آشفتگی و مقادیری هستند که پیش‌بینی با مقادیر واقعی یکی شده است.

$$\text{Kappa Coefficient} = \frac{\text{observed accuracy} - \text{chance agreement}}{1 - \text{chance agreement}} \quad (\text{رابطه ۵})$$

در رابطه فوق، Observed Accuracy همان صحت کل و Chance Agreement حاصل ضرب کل ردیف و ستون هر دسته است.

$$\text{User's Accuracy (\%)} = \frac{TP}{(TP+FP)} \times 100 \quad \text{(رابطه ۶)}$$

صحت کاربر (User's Accuracy) که با نام Precision نیز شناخته می‌شود، برای یک دسته معین، نسبت پیکسل‌های شناسایی شده روی نقشه را برای آن دسته که واقعاً روی زمین هستند نشان می‌دهد.

$$\text{Producer's Accuracy (\%)} = \frac{TP}{(TP+FN)} \times 100 \quad \text{(رابطه ۷)}$$

صحت تولیدکننده (Producer's Accuracy) هم‌چنین با نام Recall نیز شناخته می‌شود و صحت نقشه از دیدگاه سازنده نقشه است و به‌صورت تعداد پیکسل‌هایی که به‌درستی شناسایی شده از یک دسته معین تقسیم بر تعداد کل پیکسل‌های واقعی در آن دسته محاسبه می‌شود.

$$\text{Omission Error (\%)} = 100 - \text{Producer's Accuracy (\%)} \quad \text{(رابطه ۸)}$$

خطای حذف (Omission Error)، مربوط به پیکسل‌هایی می‌شود که از دسته درست در نقشه طبقه‌بندی شده کنار گذاشته‌اند (حذف شده‌اند) و مکمل صحت تولیدکننده است.

$$\text{Commission Error (\%)} = 100 - \text{User's Accuracy (\%)} \quad \text{(رابطه ۹)}$$

خطای اضافه (Commission Error)، مربوط به پیکسل‌های دسته‌ای می‌شود که به اشتباه و به‌صورت اضافه در نقشه طبقه‌بندی شده‌اند و مکمل صحت کاربر است.

$$F1 - \text{score} = 2 \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad \text{(رابطه ۱۰)}$$

پارامتر F1-score، میانگین هارمونیک صحت کاربر و صحت تولیدکننده است. بنابراین به‌طور متقارن، هم صحت کاربر و هم صحت تولیدکننده را در یک آماره نشان می‌دهد.

۳. نتایج و بحث

طبقه‌بندی تصاویر در این مطالعه، با پنج روش MahD، MaxLh، MinD، NN و SVM و برای هر چهار تاریخ تصویربرداری تولید شد. سپس آزمون تفکیک‌پذیری برای بررسی کیفیت طبقه‌بندی هر طبقه و مقایسه با نمونه‌های واقعیت زمینی برای بررسی صحت طبقه‌بندی انجام شد. شکل (۳)، تصاویر طبقه‌بندی شده نمونه را برای تاریخ دوم نشان می‌دهد. در این تصاویر، به‌ترتیب رنگ سبز: پوشش گیاهی، رنگ قرمز: خاک لخت و رنگ آبی: سایه پوشش گیاهی را نشان می‌دهد. مقایسه نتایج بصری نشان می‌دهد هر یک از روش‌های مختلف قدرت طبقه‌بندی متفاوتی از یک تصویر یکسان داشته‌اند. دو روش MinD و MahD کلاس سایه‌ها را بیش از روش‌های دیگر به‌دست آورده است، درحالی‌که دو روش SVM و NN پیکسل‌های گیاه را با دقت بالاتری تشخیص داده‌اند. مقایسه دقیق‌تر روش‌های مختلف با تحلیل نتایج ضریب دقت کلی، ضریب کاپا، دقت کاربر (Omission error) و دقت تولید (Commission error)، موردبررسی و بحث قرار خواهد گرفت.

مقادیر درصد پوشش گیاهی، خاک و سایه زیر پوشش گیاهی در چهار مرحله زمانی مقایسه گردید (جدول ۱). مطابق جدول (۱)، تغییرات رشد پوشش گیاهی مشخص است، چون هم افزایش سطح پوشش گیاهی و هم افزایش سایه زیر هر گیاه و کاهش درصد سطح خاک مشاهده می‌شود. در تشخیص پوشش گیاهی، روش‌های MahD و MinD اعداد خارج از محدوده‌ای را نشان می‌دهند. در مرحله اول، به‌نظر می‌رسد طبقه‌بندی MinD عملکرد مطلوبی نداشته است. درستی این حدس، پس از مقایسه تصویر طبقه‌بندی شده با تصویر واقعیت زمینی و مقایسه مقادیر شاخص‌های ارزیابی قابل بررسی خواهد بود.

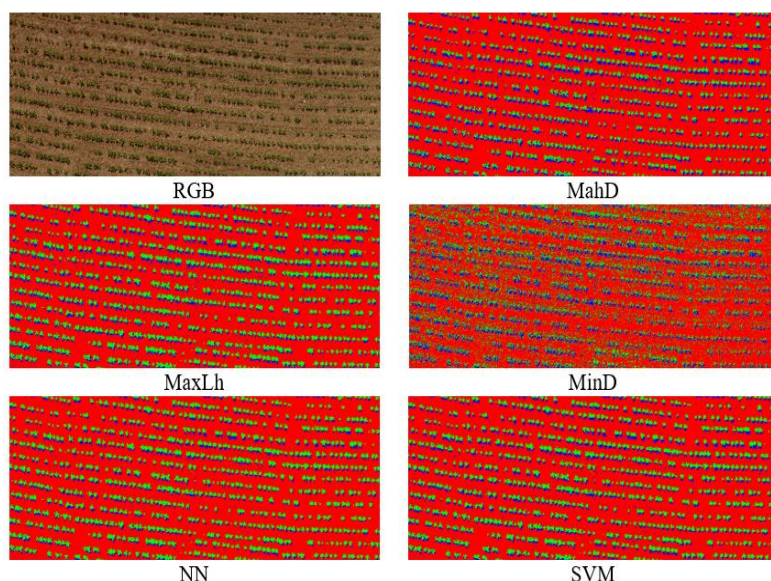


Figure 3. Classified images for second date of imaging via studied methods of classification

Table 1. Estimated canopy cover fraction, soil and shadow percent via various classification methods for four times

Stage (Imaging Date)	Classification Methods	Canopy Cover (%)	Soil (%)	Shadow (%)
1	MahD	3.47	93.92	2.61
	MaxLh	6.03	91.68	2.29
	MinD	23.21	70.38	6.41
	NN	5.42	93.27	1.31
	SVM	5.46	93.05	1.49
2	MahD	10.61	80.26	9.13
	MaxLh	15.21	76.81	7.98
	MinD	18.76	71.26	9.98
	NN	14.91	78.77	6.32
3	SVM	14.42	77.5	8.08
	MahD	20.44	69.86	9.7
	MaxLh	28.54	64.32	7.14
	MinD	19.56	67.29	13.15
	NN	28.38	64.64	6.98
4	SVM	26.64	65.92	7.44
	MahD	22.08	56.64	21.28
	MaxLh	34.91	50.74	14.35
	MinD	20.64	53.15	26.21
	NN	30.42	53.74	15.84
	SVM	31.48	52.13	16.39

نتایج مربوط به آزمون تفکیک‌پذیری براساس معیار Jefferies برای دسته‌های معرفی‌شده، براساس میزان شباهت یا عدم شباهت پیکسل‌های انتخاب‌شده آموزشی، در جدول (۲) نشان داده شده است. رنگ سبز، مربوط به دسته پوشش گیاهی، رنگ آبی، مربوط به دسته سایه و رنگ قرمز، مربوط به دسته خاک لخت می‌باشد. در این آزمون، هرچه مقدار به‌دست‌آمده به ۲ نزدیک‌تر باشد، به معنای تفکیک‌پذیری بیش‌تر بین دو دسته تعریف شده و دقت طبقه‌بندی در این شرایط بالاتر خواهد بود. بنابراین بیش‌ترین تفکیک‌پذیری در مرحله اول، مربوط به دسته گیاه و سایه با مقدار پایه پایین ۱/۹۹۶، در مرحله دوم، مربوط به گیاه و خاک لخت با مقدار ۱/۹۹۱، در مرحله سوم، مربوط به سایه و خاک لخت با مقدار ۱/۹۹۹ و در مرحله چهارم، مربوط به سایه و خاک لخت با مقدار ۱/۹۹۹ است.

Table 2. The results of the separability test (Jeffries-Matusita) of the selected training samples for three categories of vegetation, shade and bare soil

Stage (Imaging Date)	Crop	Shadow	Bare Soil	Schematic figure
1	Crop	0	1.996-1.999	1.99-2
	Shadow	1.996-1.999	0	1.975-1.999
	Bare Soil	1.999-2	1.975-1.999	0
2	Crop	0	1.977-1.998	1.991-1.999
	Shadow	1.977-1.998	0	1.975-1.999
	Bare Soil	1.991-1.999	1.975-1.999	0
3	Crop	0	1.998-2	1.999-2
	Shadow	1.998-2	0	1.999-2
	Bare Soil	1.999-2	1.999-2	0
4	Crop	0	1.992-2	1.974-1.999
	Shadow	1.992-2	0	1.999-2
	Bare Soil	1.974-1.999	1.999-2	0

به‌طور مشابه، در مرحله اول، بیش‌ترین خطا و کم‌ترین تفکیک‌پذیری مربوط به سایه و خاک لخت با مقدار ۱/۹۷۵، در مرحله دوم مربوط به سایه و خاک با مقدار ۱/۹۵۷، در مرحله سوم مربوط به گیاه و سایه با مقدار ۱/۹۹۸ و در مرحله چهارم مربوط به گیاه و خاک لخت با مقدار ۱/۹۷۴ است. به‌دلیل‌ه‌دلیل بزرگ‌تر بودن همه مقادیر از عدد یک می‌توان مشاهده کرد بین هر سه کلاس تعیین شده قابلیت تفکیک وجود دارد. ماتریس آشفتگی برای مقایسه پیکسل‌های طبقه‌بندی شده با پیکسل‌های واقعی در چهار مرحله در شکل (۴) نشان داده شده است. قطر اصلی ماتریس آشفتگی بیانگر میزان تحقق پیش‌بینی دسته‌ها با واقعیت زمینی است. مقادیر TP، TN، FP و FN از این ماتریس مستخرج و پارامترهای صحت کلی، ضریب کاپا، دقت، یادآوری و F1-score به کمک آن محاسبه می‌شود. ماتریس آشفتگی به‌صورت مطلق (تعداد پیکسل) و نسبی (درصدی) می‌توان نشان داده شود. چون تعداد نواحی موردنظر (ROI) در مراحل مختلف متفاوت است، نمایش نسبی درایه‌ها برای مقایسه مناسب‌تر است. در اینجا، برای سهولت نمایش، مراحل مختلف نیز در ماتریس نمایش داده شده و طبقه‌بندی رنگی براساس هر تاریخ صورت گرفته است. همچنین، مقدار متوسط پیش‌بینی شده برای هر دسته نیز اعلام شده تا ارزیابی کلی از بهترین روش طبقه‌بندی انجام پذیرد.




Figure 4. Confusion matrix of classification methods mentioned in the study for four time steps

همان‌طور که در شکل (۴) مشاهده می‌شود، قطر اصلی ماتریس که تحقق پیش‌بینی دسته پیکسل‌های منتخب را نشان می‌دهد، بیش‌ترین درصد را دارد. در روش MinD همان‌طور که مشاهده می‌شود ضعیف‌ترین عملکرد وجود دارد و نتیجه مرتبط با جدول (۱) را تأیید می‌کند. در تاریخ اول و با استفاده از این روش، ۴۳/۷۹ درصد از نمونه‌های پوشش گیاهی، در دسته خاک طبقه‌بندی شده‌اند. ۱۶/۹۹ درصد از نمونه‌های خاک نیز، در دسته پوشش گیاهی قرار گرفته است. البته نمونه‌های سایه، در این روش کاملاً درست طبقه‌بندی شده‌اند. بهترین روش برای طبقه‌بندی نمونه‌های پوشش گیاهی، روش MaxLh، NN و SVM

با طبقه‌بندی ۱۰۰ درست و بهترین روش برای طبقه‌بندی خاک لخت، روش SVM با ۹۹/۴۵ درصد درستی و با اختلاف کم روش NN با ۹۹/۴۲ درصد درستی بوده است. همانطور که مشاهده می‌شود روش MinD عملکرد ضعیفی در طبقه‌بندی نمونه‌های آموزشی پوشش گیاهی و خاک تاریخ دوم داشته است، اگرچه درستی طبقه‌بندی برای این دو دسته از مرحله اول بهتر بوده است. در این شکل، روش NN و SVM بهترین طبقه‌بندی را برای نمونه‌های پوشش گیاهی با ۱۰۰ درصد درستی داشته‌اند. پس از آن با اختلاف ناچیز (۰/۰۴ درصد) روش MaxLh بهترین روش است. روش NN، به‌عنوان بهترین روش با ۹۹ درصد درستی، نمونه‌های خاک را طبقه‌بندی کرده است. روش‌های MahD و MaxLh نمونه‌های سایه را ۹۲/۹۶ درصد درست طبقه‌بندی کرده‌اند. همچنین روش MinD نشان می‌دهد که همچون مرحله اول، در طبقه‌بندی سایه‌ها عملکرد بهتری دارد. در تاریخ سوم، روش MinD همچنان عملکرد ضعیفی در طبقه‌بندی نمونه‌های پوشش گیاهی نشان می‌دهد اما نمونه‌های خاک را با ۹۱/۱۴ درصد به درستی طبقه‌بندی می‌کند. روش MaxLh، NN و SVM به‌طور کامل (۱۰۰ درصد) نمونه‌های پوشش گیاهی را درست طبقه‌بندی کرده‌اند. روش SVM با ۹۹/۹۳ درصد درستی نمونه‌های خاک و روش MahD با ۱۰۰ درصد درستی نمونه‌های سایه‌رو طبقه‌بندی کرده‌اند. در تاریخ چهارم، روش MinD عملکرد مناسبی برای طبقه‌بندی پوشش گیاهی نداشته است و کم‌تر از ۵۰ درصد از نمونه‌ها (۴۸/۱۴ درصد) را در طبقه پوشش گیاهی قرار داده است. اگرچه این روش، دقت قابل‌قبولی (۹۰/۲۹ درصد) در تشخیص و طبقه‌بندی خاک و دقت فوق‌العاده ۹۹/۹۹ درصد را در طبقه‌بندی نمونه‌های سایه نشان داده است که از این حیث، تنها روش MahD با ۱۰۰ درصد دقت نمونه‌های سایه را طبقه‌بندی کرده است. دقت طبقه‌بندی پوشش گیاهی به‌طور کلی در این مرحله کم‌تر بوده است، اما روش MaxLh با ۹۷/۳۹ درصد و روش SVM با ۹۷/۱۶ درصد بهترین عملکرد را نشان داده‌اند. روش NN با ۹۹/۹۳ درصد دقت در تشخیص و طبقه‌بندی نمونه‌های خاک، بهترین روش بوده است.

جدول (۳)، پارامترهای صحت کلی، صحت کاربر، صحت تولیدکننده، خطای اضافه و خطای حذف را برای هر دسته در چهار تاریخ تصویربرداری نشان می‌دهد. براساس پارامترهای صحت کلی و ضریب کاپا، نتایجی که درباره روش MinD در قسمت‌های قبلی گزارش شد مورد تأیید قرار می‌گیرد. نکته قابل‌توجه از نتایج این مطالعه این است که روش MaxLh که سازوکار نسبتاً ساده‌ای دارد با دقت قابل‌قبول و در حد روش‌های یادگیری ماشینی NN و SVM که زمان اجرای زیادی از کاربر می‌گیرند، عمل می‌کند و می‌تواند به‌عنوان یک جایگزین مناسب و سریع و با دقت بالا برای هر دو روش انتخاب گردد. مسئله زمان اجرا، در مطالعات بسیاری موردتوجه قرار گرفته است و باعث تغییر اولویت انتخاب روش بهینه که بر مبنای صحت بالاتر بوده، شده است. با توجه به جدول (۳) و پارامترهای صحت هر دسته، عملکرد ضعیف روش MinD در طبقه‌بندی پوشش گیاهی و خاک به‌طور واضح مشخص است. روش SVM در طبقه‌بندی پوشش گیاهی بهترین عملکرد، روش MaxLh در تشخیص و طبقه‌بندی خاک بهترین عملکرد و روش MaxLh بهترین عملکرد در طبقه‌بندی سایه‌ها را نشان داد.

در نهایت، در شکل (۵) نتایج F1-score برای سه دسته، پنج روش طبقه‌بندی و چهار تاریخ موردبررسی قرار گرفته است. همانطور که گفته شد این پارامتر مستخرج از دو پارامتر Producer's Accuracy و User's Accuracy می‌باشد. در برخی از موارد، مقدار User's Accuracy بیش‌تر از Producer's Accuracy و در برخی موارد دیگر برعکس است. بنابراین، پارامتر F1-score این غیریکنواختی را از بین می‌برد. بنابراین، می‌توان فقط با استفاده از یک پارامتر F1-score صحت نتایج طبقه‌بندی را موردبررسی قرار داد. همانطور که قابل مشاهده است، صحت نتایج طبقه‌بندی پوشش گیاهی، در چهار روش، در تاریخ اول بیش‌تر است. تنها با استفاده از روش MinD، مشاهده می‌شود که صحت طبقه‌بندی پوشش گیاهی در تاریخ سوم بیش‌تر بوده است. به‌طور مشابه، در طبقه‌بندی خاک و

سایه نیز نظمی قابل مشاهده است و تنها روش MinD از این نظم پیروی نمی‌کند. فقط در خصوص طبقه‌بندی سایه، این بی‌نظمی کم‌تر است و صحت طبقه‌بندی نیز نسبت به سایر پدیده‌ها، بیش‌تر است. بنابراین، به‌نظر می‌رسد نتایج روش MinD کم‌تر قابل اعتماد است.

Table 3. Evaluation parameters for various classification Methods at four imaging dates

Stage (Imaging Date)	Classification Methods	Evaluation parameters							
		Overall performance		Vegetation		Soil		Shadow	
		OA*	K*	UA*	PA*	UA	PA	UA	PA
1	MahD	99	98.26	100	99.69	99.71	98.65	94.26	98.95
	MaxLh	99.18	98.58	99.69	100	98.58	99.97	95.13	99.87
	MinD	73.97	54.86	61.93	53.06	77.47	78.47	79.9	100
	NN	98.38	97.15	100	100	97.75	99.42	97.46	90.69
	SVM	98.76	97.83	100	100	98.38	99.45	97.67	93.32
2	MahD	97.7	96.5	100	94.92	99.73	98.04	93.03	99.96
	MaxLh	99.03	98.53	99.45	99.96	100	97.75	97.31	99.96
	MinD	84.46	76.48	77.6	70.56	91.59	83.26	81.93	99.92
	NN	98.81	98.19	99.24	100	98.66	99	98.6	97.37
	SVM	99.12	98.66	99.7	100	99.94	98.16	97.42	99.62
3	MahD	99.69	99.52	100	99.52	99.36	99.66	99.47	100
	MaxLh	99.88	99.81	99.85	100	100	99.73	99.81	99.81
	MinD	82.29	73.48	93.99	66.88	63.21	91.14	93.03	99.94
	NN	99.85	99.77	100	100	100	97.7	99.72	99.75
	SVM	99.95	99.92	100	100	100	99.93	99.94	99.88
4	MahD	97.01	95.45	100	91.01	92.14	99.51	98.38	100
	MaxLh	98.88	98.29	99.15	97.39	96.92	99.24	100	99.78
	MinD	80.89	70.89	86.72	48.14	67.34	90.29	89.43	99.99
	NN	98.65	97.95	99.94	95.98	95.34	99.93	100	99.87
	SVM	98.97	98.44	99.65	97.16	96.72	99.6	100	99.96

OA: Overall Accuracy
K: Kappa Coefficient
UA: User's Accuracy
PA: Producer's Accuracy

Continued table 3. Evaluation parameters for various classification Methods at four imaging dates

Stage (Imaging Date)	Classification Methods	Evaluation parameters					
		Vegetation		Soil		Shadow	
		CE*	OE*	CE	OE	CE	OE
1	MahD	0	0.31	0.29	1.35	5.74	1.05
	MaxLh	0.31	0	0.03	1.42	4.87	0.13
	MinD	38.07	46.94	22.53	21.53	20.10	0
	NN	0	0	2.25	0.58	2.54	9.31
	SVM	0	0	1.62	0.55	2.33	6.68
2	MahD	0	5.08	0.27	1.96	6.97	0.04
	MaxLh	0.55	0.04	0	2.25	2.69	0.04
	MinD	22.40	29.44	8.41	16.74	18.07	0.08
	NN	0.76	0	1.34	1	1.40	2.63
	SVM	0.30	0	0.06	1.84	2.58	0.38
3	MahD	0	0.48	0.64	0.34	0.53	0
	MaxLh	0.15	0	0	0.27	0.19	0.19
	MinD	6.06	33.12	36.79	8.86	6.97	0.06
	NN	0.15	0	0	0.30	0.28	0.25
	SVM	0.07	0	0	0.07	0.06	0.12
4	MahD	0	8.99	7.86	0.49	1.62	0
	MaxLh	0.85	2.61	3.08	0.76	0	0.22
	MinD	13.31	51.86	32.66	9.71	10.57	0.01
	NN	0.06	4.02	4.66	0.07	0	0.13
	SVM	0.35	2.84	3.28	0.40	0	0.04

CE: Commission Error
OE: Omission Error

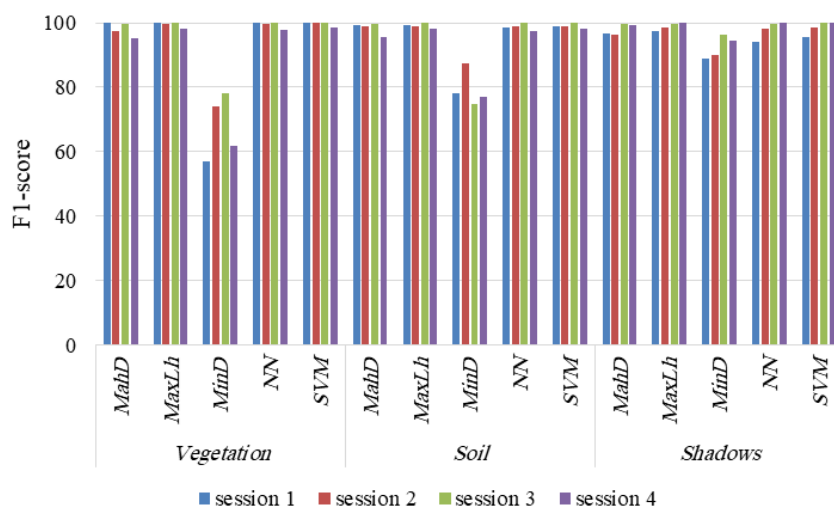


Figure 5. F1-score values for four time steps and five classification methods

۴. نتیجه گیری

امروزه با پیشرفت علوم رایانه و تجهیزات به روز می توان علاوه بر روش های مستقیم تعیین وضعیت سلامت گیاه که مبتنی بر نمونه برداری میدانی هستند، از تکنیک های پردازش تصویر در این زمینه استفاده نمود. روش های مستقیم، زمان بر و هزینه بر و بیش تر مستعد مواجهه با خطاهای انسانی و سیستماتیک هستند، در حالی که در روش پردازش تصاویر آسبایی به گیاه نمی زند، در حداقل زمان ممکن بیش ترین اطلاعات را به کشاورز خواهد داد و رویه و فرایند کم خطرتری را طی می کند. برآورد پوشش سایه انداز، زمانی بهینه می شود که پیکسل های ناخواسته تصویر توسط روش هایی نظیر دسته بندی نظارت شده (Supervised classification) و جداسازی (Segmentation) حذف شود. امروزه روش های دسته بندی نظارت شده به سادگی و از طریق تعیین نمونه های آموزشی قادرند تا پوشش سبز گیاهی را برآورد کنند. هر چند که روش های دسته بندی مختلفی براساس ساز و کارهای متفاوت ارائه شده است، بنابراین عملکرد هر کدام از این روش ها در برآورد پوشش سایه انداز می تواند متفاوت باشد. در این مطالعه، برآورد پوشش سایه انداز با استفاده از پنج روش دسته بندی نظارت شده MahD، MaxLh، MinD، NN و SVM و در چهار تاریخ در دوره رشد محصول چغندر قند انجام شد. روش MaxLh که سازوکار نسبتاً ساده ای دارد، در برآورد پوشش سایه انداز با دقت قابل قبول و در حد روش های یادگیری ماشینی NN و SVM که زمان اجرای زیادی از کاربر می گیرند، عمل کرد و می تواند به عنوان یک جایگزین مناسب و سریع و با دقت بالا برای هر دو روش انتخاب گردد.

۵. پی نوشت ها

1. Canopy Cover Fraction
2. Orthomosaic

۶. تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Behrens, T., & Diepenbrock, W. (2006). Using Digital Image Analysis to Describe Canopies of Winter Oilseed Rape (*Brassica napus* L.) during Vegetative Developmental Stages. *Journal of Agronomy and Crop Science*, 192(4), 295–302. <https://doi.org/10.1111/J.1439-037X.2006.00211.X>
- Bonan, G. B. (1993). Importance of leaf area index and forest type when estimating photosynthesis in boreal forests. *Remote Sensing of Environment*, 43(3), 303-314. [https://doi.org/10.1016/0034-4257\(93\)90072-6](https://doi.org/10.1016/0034-4257(93)90072-6)
- Bryson, R. J., Paveley, N. D., Clark, W. S., Sylvester-Bradley, R., & Scott, R. K. (1997). Use of in-field measurements of green leaf area and incident radiation to estimate the effects of yellow rust epidemics on the yield of winter wheat. *European Journal of Agronomy*, 7(1-3), 53-62. [https://doi.org/10.1016/S1161-0301\(97\)00025-7](https://doi.org/10.1016/S1161-0301(97)00025-7)
- Cardille, J. A., Saah, D., Crowley, M. A., & Clinton, N. E. (2024). Cloud-Based Remote Sensing with Google Earth Engine. In *Cloud-Based Remote Sensing with Google Earth Engine*. <https://doi.org/10.1007/978-3-031-26588-4>
- Chang, C. C., & Lin, C. J. (2011). LIBSVM. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2(3). <https://doi.org/10.1145/1961189.1961199>
- Chebroly, N., Labe, T., & Stachniss, C. (2018). Robust long-term registration of UAV images of crop fields for precision agriculture. *IEEE Robotics and Automation Letters*, 3(4), 3097-3104. <https://doi.org/10.1109/LRA.2018.2849603>
- CHEN, J. M., & BLACK, T. A. (1992). Defining leaf area index for non-flat leaves. *Plant, Cell & Environment*, 15(4), 421-429. <https://doi.org/10.1111/J.1365-3040.1992.TB00992.X>
- Coy, A., Rankine, D., Taylor, M., Nielsen, D. C., & Cohen, J. (2016). Increasing the accuracy and automation of fractional vegetation cover estimation from digital photographs. *Remote Sensing*, 8(7), 21-25. <https://doi.org/10.3390/rs8070474>
- De la Casa, A., Ovando, G., Bressanini, L., Martínez, J., Díaz, G., & Miranda, C. (2018). Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. *ISPRS Journal of Photogrammetry and Remote Sensing*, 146, 531-547. <https://doi.org/10.1016/J.ISPRSJPRS.2018.10.018>
- Drewry, D.T., Kumar, P., Long, S., Bernacchi, C., Liang, X.Z., & Sivapalan, M. (2010). Ecohydrological responses of dense canopies to environmental variability: 1. Interplay between vertical structure and photosynthetic pathway. *Journal of Geophysical Research: Biogeosciences*, 115(G4). <https://doi.org/10.1029/2010JG001340>
- Eslami, A., Anvari, S., Karimi, N., & Mohammadi, S. (2022). Application of pixel-based and object-based approaches for LULC mapping in Jiroft region, S.E. Iran. *Ecopersia*, 10(1), 71-83.
- Friha, O., Ferrag, M. A., Shu, L., Maglaras, L., & Wang, X. (2021). Internet of Things for the Future of Smart Agriculture: A Comprehensive Survey of Emerging Technologies. *IEEE/CAA Journal of Automatica Sinica*, 8(4), 718-752. <https://doi.org/10.1109/JAS.2021.1003925>
- Gooyandeh, M., Mirlatifi, S. M., & Akbari, M. (2019). Estimating Leaf Area Index of a corn silage field Using a Modified Commercial Digital Camera. *Iranian Journal of Irrigation & Drainage*, 12(6), 1396-1406. https://idj.iaid.ir/article_85906_en.html
- Haddadi, S. R., Soltani, M. Assessment of canopy cover fraction in sugar beet field using unmanned aerial vehicle imagery and different image segmentation methods. *Iranian Journal of Soil and Water Research*, 2024; 55(7), 1199-1215. doi: 10.22059/ijswr.2024.371136.669647
- Hsu, C.-W., Chang, C.-C., & Lin, C.-J. (2016). *A Practical Guide to Support Vector Classification*. <https://doi.org/10.1177/02632760022050997>
- Inoue, Y. (2020). Satellite- and drone-based remote sensing of crops and soils for smart farming – a review. *Soil Science and Plant Nutrition*, 66(6), 798-810. <https://doi.org/10.1080/00380768.2020.1738899>
- Lee, K.-J., & Lee, B.-W. (2011). Estimating canopy cover from color digital camera image of rice field. *Journal of Crop Science and Biotechnology*, 14(2), 151-155. <https://doi.org/10.1007/s12892-011-0029-z>
- Li, Y., Chen, D., Walker, C. N., & Angus, J. F. (2010). Estimating the nitrogen status of crops using a digital camera. *Field Crops Research*, 118(3), 221-227. <https://doi.org/10.1016/J.FCR.2010.05.011>
- Lottes, P., Khanna, R., Pfeifer, J., Siegwart, R., & Stachniss, C. (2017). UAV-based crop and weed classification for smart farming. *Proceedings-IEEE International Conference on Robotics and Automation*, 3024-3031. <https://doi.org/10.1109/ICRA.2017.7989347>

- Manfreda, S., McCabe, M. F., Miller, P. E., Lucas, R., Madrigal, V. P., Mallinis, G., Dor, E. Ben, Helman, D., Estes, L., Ciraolo, G., Müllerová, J., Tauro, F., de Lima, M. I., de Lima, J. L. M. P., Maltese, A., Frances, F., Caylor, K., Kohv, M., Perks, M., ... & Toth, B. (2018). On the use of unmanned aerial systems for environmental monitoring. *Remote Sensing*, 10(4). <https://doi.org/10.3390/rs10040641>
- Miraki, M., Sohrabi, H., & Fatehi, P. (2022). Citrus trees identification and trees stress detection based on spectral data derived from UAVs. *Research in Horticultural Sciences*, 1(1), 27-40. doi: 10.22092/rhsj.2022.127815
- Pan, G., Li, F. M., & Sun, G. J. (2007). Digital camera based measurement of crop cover for wheat yield prediction. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 797-800. <https://doi.org/10.1109/IGARSS.2007.4422917>
- Panday, U. S., Pratihast, A. K., Aryal, J., & Kayastha, R. B. (2020). A review on drone-based data solutions for cereal crops. *Drones*, 4(3), 1-29. <https://doi.org/10.3390/drones4030041>
- Patanè, C. (2011). Leaf Area Index, Leaf Transpiration and Stomatal Conductance as Affected by Soil Water Deficit and VPD in Processing Tomato in Semi Arid Mediterranean Climate. *Journal of Agronomy and Crop Science*, 197(3), 165-176. <https://doi.org/10.1111/J.1439-037X.2010.00454.X>
- Purevdorj, T. S., Tateishi, R., Ishiyama, T., & Honda, Y. (1998). Relationships between percent vegetation cover and vegetation indices. *IJRS*, 19(18), 3519-3535. <https://doi.org/10.1080/014311698213795>
- Qu, Y., Meng, J., Wan, H., & Li, Y. (2016). Preliminary study on integrated wireless smart terminals for leaf area index measurement. *Computers and Electronics in Agriculture*, 129, 56-65. <https://doi.org/10.1016/J.COMPAG.2016.09.011>
- Radoglou-Grammatikis, P., Sarigiannidis, P., Lagkas, T., & Moscholios, I. (2020). A compilation of UAV applications for precision agriculture. *Computer Networks*, 172, 107148. <https://doi.org/10.1016/J.COMNET.2020.107148>
- Rejeb, A., Abdollahi, A., Rejeb, K., & Treiblmaier, H. (2022). Drones in agriculture: A review and bibliometric analysis. In *Computers and Electronics in Agriculture* (Vol. 198). <https://doi.org/10.1016/j.compag.2022.107017>
- Richards, J. A., & Jia, X. (1999). Remote Sensing Digital Image Analysis. In *Remote Sensing Digital Image Analysis*. Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-662-03978-6>
- Richardson, M. D., Karcher, D. E., & Purcell, L. C. (2001). Quantifying Turfgrass Cover Using Digital Image Analysis. *Crop Science*, 41(6), 1884-1888. <https://doi.org/10.2135/CROPSCI2001.1884>
- Rumelhart, D. E., & McClelland, J. L. (1987). Learning Internal Representations by Error Propagation. In *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations* (pp. 318-362). MIT Press. <http://ieeexplore.ieee.org/document/6302929>
- Running, S. W., & Coughlan, J. C. (1988). A general model of forest ecosystem processes for regional applications I. Hydrologic balance, canopy gas exchange and primary production processes. *Ecological Modelling*, 42(2), 125-154. [https://doi.org/10.1016/0304-3800\(88\)90112-3](https://doi.org/10.1016/0304-3800(88)90112-3)
- Shi, J., Wang, J., & Xu, Y. (2012). Object-Based Change Detection Using Georeferenced Uav Images. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVIII-1/(September), 177-182. <https://doi.org/10.5194/isprsarchives-xxxviii-1-c22-177-2011>
- Soltani, M. (2024). Estimating maize canopy cover percent by means of image processing algorithms. *Water and Irrigation Management*, 14(1), 111-122. doi: 10.22059/jwim.2023.364331.1098
- Steduto, P., Hsiao, T. C., Fereres, E., & Raes, D. (2012). Crop yield response to water. *FAO Irrigation and Drainage Paper No.66*, (October 2012), 505.
- Su, J., Coombes, M., Liu, C., Guo, L., & Chen, W. H. (2018). Wheat Drought Assessment by Remote Sensing Imagery Using Unmanned Aerial Vehicle. *Chinese Control Conference, CCC, 2018-July*, 10340-10344. <https://doi.org/10.23919/ChiCC.2018.8484005>
- Vose, J. M., Vose, J. M., Dougherty, P. M., Dougherty, P. M., Long, J. N., Long, J. N., Smith, F. W., Smith, F. W., Gholz, H. L., Gholz, H. L., Curran, P. J., & Curran, P. J. (1994). Factors influencing the amount and distribution of leaf area of pine stands. *Ecological Bulletins*, 43(43), 102-114.
- Wu, F., Lin, C., & Weng, R. (2004). Probability Estimates for Multi-Class Support Vector Machines by Pairwise Coupling. *Journal of Machine Learning Research*, 5, 975-1005.
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: a review. *Precision Agriculture 2012 13:6*, 13(6), 693-712. <https://doi.org/10.1007/S11119-012-9274-5>