

Linking Grape Yield Performance to Remote Sensing Vegetation Indices: A Fusion of Sentinel Radar and Optical Imagery with Machine Learning Models

H. R. Maleki¹, M. Khodamorad Pour^{2*}, H. Mohamadi Monavar¹

1- Department of Bio-System Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

2- Department of Water Science and Engineering, Faculty of Agriculture, Bu-Ali Sina University, Hamedan, Iran

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

<https://doi.org/10.22067/jam.2025.91357.1325>

Introduction

Remote sensing is considered a key management tool in precision agriculture, particularly for monitoring and identifying plant coverage. Grapes are among the most valuable horticultural crops, with Hamedan province accounting for approximately 7.3 % of Iran's total vineyard area. This study evaluates the accuracy of vineyard identification in Hamedan province using machine learning algorithms including support vector machine (SVM), minimum distance (MD), and random forest (RF) models along with normalized difference vegetation index (NDVI) and normalized difference water index (NDWI) estimated from combined optical and radar images of Sentinel (Sentinel-1 and Sentinel-2). Based on the most accurate vineyard identification map, the maximum time series of NDVI and NDWI of the MODIS satellite in vineyards was estimated between 2007 and 2020, and their correlation with the actual yield of the grape crop was examined.

Materials and Methods

In this research, we first extracted images of pivotal remote sensing vegetation indicators, including NDVI and NDWI, from Sentinel-2 images in Hamedan province in 2020. The approach of addressing speckle noise through median pixels allowed for the acquisition of median radar images from Sentinel-1 over the designated study area. To create high-accurate images, spectral composition was used to combine these images with the NDVI and NDWI from Sentinel-2 images. Using these images, vineyard identification maps were generated through classification algorithms, including support vector machine, random forest, and minimum distance models. Training samples were used to train these algorithms. Samples from six land coverage classes involving vineyards, were collected using a combination of field observations and Google Earth imagery. Of these, 70% were used for training and 30% for testing the classification models. In order to assess the accuracy of the vineyard identification maps, indicators including overall accuracy and kappa coefficient were examined. Subsequently, the vineyard map with the highest assessment indicator was selected. Finally, using this accurate vineyard identification map, the maximum monthly NDVI and NDWI indices estimated from MODIS sensor images in the vineyards were calculated from 2007 to 2020, and their correlation with yields of the grape crop was computed using Pearson correlation.

Results and Discussion

Based on the comparison of different classification algorithms for distinguishing vineyards, random forest model along with NDVI and NDWI indices outperformed support vector machine and minimum distance models. With regard to accuracy, however, the random forest along with the NDWI has the best overall accuracy (95%) and kappa coefficient (0.95). The superior performance of NDWI is attributed to the high moisture levels in vineyards resulting from irrigation, as NDWI is particularly sensitive to variations in vegetation water content. The lower accuracy of vineyard identification using SVM and MD models can be linked to shadow effects caused by the canopy structure of grapevines, as well as imbalanced training data used for the support vector machine model. Correlation analysis of real grape yields with NDVI and NDWI of MODIS extracted from the highest accuracy vineyards map indicates NDVI (correlation coefficient 0.81) has a stronger linear relationship with yield than NDWI (correlation coefficient 0.75). This can be explained by NDVI's sensitivity to leaf chlorophyll changes, which results in a strong correlation with yield.

Conclusion

Vineyards can be accurately identified using machine learning algorithms and remote sensing vegetation indices derived from combined radar and optical satellite images. Furthermore, the strong correlation between NDVI and grape yield enable reliable yield prediction based on NDVI time series analysis. The outcomes of this

study facilitate the identification of grape cultivation areas, improved water resource management, the development of optimized irrigation strategies, pre-harvest yield estimation, and the exploration of export options.

Keywords: Minimum Distance model, NDVI index, NDWI index, Random Forest model, Support Vector Machine model

ارتباط عملکرد محصول انگور با شاخص‌های گیاهی سنجش از دور: ترکیبی تصاویر سنتینل راداری و اپتیکی و مدل‌های یادگیری ماشین

حمیدرضا ملکی^۱، مهرانه خدامرادپور^{۲*}، حسنی محمدی منور^۱

تاریخ دریافت: ۱۴۰۳/۱۰/۱۱

تاریخ پذیرش: ۱۴۰۳/۱۲/۲۵

چکیده

امروزه سنجش از دور به عنوان یک ابزار مدیریتی در کشاورزی دقیق محسوب می‌شود، که نقش مهمی در شناسایی پوشش‌های گیاهی متفاوت دارد. انگور از ارزشمندترین محصولات باغبانی است که استان همدان حدود ۷/۳ درصد از وسعت تاکستان‌های کشور را در اختیار دارد. با این حال توزیع جغرافیایی از تاکستان‌ها در این استان وجود ندارد. هدف اصلی این پژوهش، بررسی رابطه عملکرد محصول انگور با شاخص‌های سنجش از دور پوشش گیاهی در تاکستان‌های استان همدان است. به همین منظور، دقت شناسایی تاکستان‌های استان همدان توسط الگوریتم‌های یادگیری ماشین شامل: ماشین بردار پشتیبان (SVM) و حداقل فاصله (MD) و جنگل تصادفی (RF) با شاخص‌های سنجش از دور پوشش گیاهی شامل: شاخص تفاضلی نرمال‌شده گیاهی (NDVI) و شاخص تفاضلی نرمال‌شده آب (NDWI) برآورد شده از تصاویر ترکیبی اپتیکی و راداری سنتینل (Sentinel-1 و Sentinel-2) انجام شد. سپس براساس دقیق‌ترین نقشه شناسایی تاکستان‌ها، سری زمانی ماکزیمم شاخص‌های NDVI و NDWI سنجنده‌ی مودیس در تاکستان‌ها در سال‌های ۲۰۰۷ تا ۲۰۲۰ برآورد شد و همبستگی آن‌ها با عملکرد واقعی محصول انگور بررسی شد. مقایسه دقت طبقه‌بندی الگوریتم‌های متفاوت بیانگر برتری الگوریتم RF با شاخص NDWI با بالاترین دقت کلی (۹۵٪) و ضریب کاپا (۰/۹۵) بود. همچنین تحلیل همبستگی بین شاخص‌های NDVI و NDWI سنجنده مودیس مستخرج از نقشه تاکستان‌ها با عملکرد واقعی انگور نشان از رابطه خطی قوی تری بین شاخص NDVI نسبت به NDWI دارد. یافته‌های این پژوهش که بیانگر دقت بالای شاخص‌های سنجش از دور و الگوریتم‌های یادگیری ماشین در تاکستان‌ها است می‌تواند در پیش‌بینی عملکرد محصول انگور قبل از برداشت، بهبود کیفیت انگور و مدیریت بهینه‌ی آبیاری نقش مهمی داشته باشد.

واژه‌های کلیدی: شاخص NDVI، شاخص NDWI، مدل حداقل فاصله، مدل جنگل تصادفی، مدل ماشین بردار پشتیبان

مقدمه

انگور در ایران، این میوه از لحاظ خواص و فواید نیز جایگاه ویژه‌ای در بین میوه‌ها دارد که باعث افزایش اهمیت آن شده است. محاسبه سطح زیرکشت و مساحت زمین‌های باغی و زراعی نقش مهمی در برنامه‌ریزی و مدیریت کشاورزی، بازاریابی، پخش نهاده‌ها، تعیین قیمت، تنظیم توازن میان واردات و صادرات محصولات، بیمه و برآورد خسارات در حوزه مدیریت کشاورزی دارد (Mirzaei, Abbasi, Marofi, Solgi, & Karimi, 2018). سنجش از دور به روشی پرکاربرد و مؤثر برای برآورد سطح زیرکشت تبدیل شده است (Vintrou et al., 2012)، که در زمینه‌ی مطالعات پوشش‌های گیاهی به‌ویژه محصولات زراعی و باغی می‌تواند با در دسترس قرار دادن تصاویر ماهواره‌ای با توان تفکیک‌های زمانی و مکانی مناسب و منظم

انگور (*Vitis Vinifera*) گیاهی چند ساله است که در سراسر جهان کشت می‌شود. طبق گزارش سازمان بین‌المللی دلا ویگن و دو وین^۳ سطح زیر کشت تاکستان‌ها در سال ۲۰۱۸ حدود ۷/۴ میلیون هکتار بوده است. عوامل زیادی در رشد و نمو و عملکرد انگور تاثیر دارد که مهم‌ترین آن‌ها آب و هوا، خاک و شیوه‌های کشت است (Avalos & Araujo, 2021). انگور از نظر اقتصادی از اهمیت بالایی برخوردار است و مصرف جهانی بالا و سطح زیرکشت زیاد باعث افزایش اهمیت این گیاه شده است. درخت این گیاه در ایران با نام مو و اغلب به نام تاک نام‌گذاری شده است. علاوه بر پراکندگی و فراوانی سطح زیر کشت

(*)- نویسنده مسئول: (Email: mkhodamorad@basu.ac.ir
https://doi.org/10.22067/jam.2025.91357.1325
3- De La Vigne Et Du Vin

۱- گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران
۲- گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان، ایران

تاکستان‌ها استفاده می‌شوند (Basheer et al., 2022). به‌عنوان مثال، ژاو و همکاران (Zhao, Li, Zhang, Wang, & Du, 2019) در تفکیک تاکستان‌ها از مزارع زراعی در کشور چین از سری زمانی شاخص‌های سنجش از دور پوشش گیاهی شامل: EVI^۷ و GCVI^۸ استخراج شده از تصاویر سنتینل-۲ و روش‌های طبقه‌بندی شبکه عصبی CNN^۹ و RF استفاده کردند. آن‌ها با اعمال تبدیل موجک پیوسته CWT^{۱۰} برای هر سری زمانی بازسازی شده قبلی برای تولید اسکالوگرام^{۱۱} دریافتند که ترکیب CWT و CNN عملکرد دقیق‌تری نسبت به RF در شناسایی تاکستان داشت. بریتخوف و همکاران (Brinkhoff, Vardanega, & Robson, 2019) به شناسایی ۱۲ محصول از جمله تاکستان‌ها، با تلفیق تصاویر سنتینل-۱ و سنتینل-۲ با الگوریتم‌های RF، SVM، CART و بیشترین مقدار شاخص NDVI ماهانه در استرالیا پرداختند. نتیجه این پژوهش نشان داد که نقشه‌های تولید شده با استفاده از الگوریتم‌های CART و RF با باندهای یکسان، دقت کمتری نسبت به SVM داشتند. در پژوهشی هارتلینگ و همکاران (Hartling, Sagan, Sidike, Maimaitijiang, & Carron, 2019) با مقایسه الگوریتم‌های SVM و RF در شناسایی گونه‌های درخت شهری دریافتند که دقت کلی الگوریتم RF (۴۳/۴۱ درصد) بالاتر از الگوریتم SVM (۳۲/۵۲ درصد) بود.

پال و همکاران (Pal, Pandey, Sharma, & Nair, 2022) در هند با استفاده از تصاویر ماهواره‌ای سنتینل-۲، به طبقه‌بندی پوشش اراضی پرداختند که با استفاده از الگوریتم MD اراضی را به پنج کلاس طبقه‌بندی کردند. یافته‌های این پژوهش بیانگر دقت بالای طبقه‌بندی MD با ضریب کاپا در حدود ۰/۸۲ و دقت کلی حدود ۸۷٪ بود. کریمی و همکاران (Karimi, Sheshangosht, & Eftekhari, 2022) به تفکیک مزارع با استفاده از الگوریتم SVM با شاخص‌های سنجش از دور شامل: NDVI، NDWI و GNDVI پرداختند. نتایج این پژوهش نشان از دارا بودن دقت بالای الگوریتم SVM در تفکیک مزارع به ترتیب توسط شاخص‌های NDVI، NDWI و GNDVI بود، درحالی‌که اختلاف بسیار کوچکی بین دقت مدل با شاخص‌های NDVI و NDWI بود. تفکیک تاکستان‌های شهرستان ملکان در استان آذربایجان شرقی با الگوریتم درخت تصمیم CART و شاخص NDVI مستخرج از تصاویر ماهواره‌ای SPOT5 نشان از دقت بالای این الگوریتم (دقت کلی ۹۵٪) داشت (Faizizadeh, Valizadeh, Kamran, & Haydari, 2008).

نتایج پیشنهادی تحقیق نشان داد که با استفاده از شاخص‌های

نقش مهمی در بهبود شرایط ویژه کشاورزی ایفا کند. در حال حاضر، بررسی شاخص‌های سنجش از دور پوشش گیاهی از مهم‌ترین و پرکاربردترین روش‌های رایج بررسی وضعیت کمی و کیفی پوشش گیاهی زراعی، باغی و مراتع است (Nematollahi, Ashourloo, Alimohammadi, Khodabandehloo, & Radiom, 2018). این شاخص‌ها با روابط ریاضی یکسان در تمام پیکسل‌ها با توان تفکیک زمانی و مکانی بالا، بدون فرضیات قبلی محاسبه می‌شوند و بیانگر وضعیت پوشش زمین و نوع خاک هستند (Ahmad, 2012). شاخص تفاضلی نرمال شده گیاه NDVI^۱، از پرکاربردترین شاخص‌های گیاهی در اکولوژی، جنگل‌داری، کشاورزی، حیات وحش، تنوع زیستی و سایر رشته‌ها است (Robinson et al., 2017). شاخص NDVI براساس بازتاب در باند قرمز و مادون قرمز نزدیک برآورد می‌شود (Junges, Fontana, Anzanello, & Bremm, 2017). شاخص NDVI در واقع مقدار کلروفیل برگ را اندازه‌گیری می‌کند، درحالی‌که شاخص تفاضلی نرمال شده آب NDWI^۲ با استفاده از باندهای مادون قرمز نزدیک و مادون قرمز کوتاه، آب موجود در پوشش گیاهی را اندازه‌گیری می‌کند (Andalibi & Esmaeily, 2015). همچنین پژوهش‌ها نشان دادند که شاخص‌های سنجش از دور گیاهی براساس رابطه خطی با عملکرد می‌توانند نقش مهمی در بهبود کیفیت محصول انگور در مراحل مختلف رشد و افزایش عملکرد تاکستان‌ها داشته باشند، به طوری‌که شاخص NDVI بالاتر بیانگر انگور سالم‌تر و عملکرد بالاتر است (Borgogno-Mondino & Lessio, 2018; Vélez, Barajas, Blanco, Rubio, & Castrillo, 2021). شاخص سنجش از دور گیاهی NDWI براساس رابطه خطی قوی با رطوبت خاک (شاخص مهم در رشد انگور) می‌تواند به منجر به بهبود کیفیت انگور تاکستان‌ها با برآورد بهینه‌ی آب در دسترس گیاه شوند (Borgogno-Mondino & Lessio, 2018). با این حال این شاخص‌ها باید از نقشه‌های تفکیک شده دقیق تاکستان‌ها استخراج شوند و با توجه به عدم دسترسی به این نقشه‌ها در مقیاس‌های مکانی بزرگ، می‌توان از روش‌های طبقه‌بندی تصاویر ماهواره شامل: طبقه‌بندی نظارت شده و غیرنظارت شده استفاده کرد. به‌طور کلی طبقه‌بندی نظارت شده به روش‌های پارامتریک و ناپارامتریک تقسیم می‌شوند. در سال‌های اخیر، الگوریتم‌های نظارت شده پیشرفته مانند: جنگل تصادفی RF^۳، الگوریتم درخت رگرسیون CART^۴، ماشین بردار پشتیبان SVM^۵ از روش‌های ناپارامتری و روش حداقل فاصله MD^۶ از روش‌های پارامتری در پژوهش‌های مرتبط با طبقه‌بندی پوشش کاربری اراضی و تفکیک

7- Enhanced Vegetation Index
8- Green Chlorophyll Vegetation Index
9- Convolutional Neural Network
10- Continuous Wavelet Transform
11- Scalogram

1- Normalized Difference Vegetation Index
2- Normalized Difference Water Index
3- Random Forest
4- Classification and Regression Tree
5- Support Vector Machine
6- Minimum Distance

الگوریتم‌های یادگیری ماشین متفاوت شامل: MD، SVM و RF می‌پردازد. هم‌چنین بعد از انتخاب دقیق‌ترین نقشه تفکیک تاکستان‌ها، شاخص‌های سنجش از دور سنجنده مودیس در تاکستان‌های شناسایی شده، با توجه به دسترسی به سری زمانی طولانی تصاویر سنجنده مودیس (از سال ۲۰۰۰ تاکنون) استخراج شده و ارتباط خطی بین آن‌ها و عملکرد واقعی سالانه بررسی شد. نتایج این مطالعه می‌تواند در مطالعات مختلفی شامل: پیش‌بینی عملکرد محصول ماه‌ها قبل از برداشت انگور، برآورد بهینه آب مصرف‌شده و افزایش کیفیت انگور با هدف افزایش عملکرد، که اکثراً بر اساس رابطه خطی قوی بین متغیرهای مستقل و وابسته است، کاربرد داشته باشد. هم‌چنین این اهداف ذکرشده از نوآوری‌های این پژوهش می‌باشند که تاکنون به این شکل در پژوهش‌های پیشین در تاکستان‌های استان همدان انجام نشده است.


مواد و روش‌ها

منطقه مورد مطالعه

محدوده مورد مطالعه این تحقیق استان همدان است که در شکل ۱ تصویری از منطقه مورد مطالعه نشان داده شده است. استان همدان در بخش شمال غرب کشور بین عرض جغرافیایی ۳۳ درجه و ۵۹ دقیقه تا ۳۵ درجه و ۴۵ دقیقه شمالی و طول جغرافیایی ۴۷ درجه و ۴۵ دقیقه تا ۴۹ درجه و ۳۰ دقیقه شرقی قرار گرفته است (شکل ۱).

سنجش از دور پوشش گیاهی و الگوریتم‌های یادگیری ماشین می‌تواند مزارع و تاکستان‌ها را تفکیک نمود، اما تفاوت‌های قابل توجه در ویژگی طیفی محصولات و مراحل چرخه فنولوژی محصولات مختلف می‌تواند منجر به نتایج متفاوت الگوریتم‌های طبقه‌بندی در تفکیک محصولات گردد. بر همین اساس مطالعات منطقه‌ای برای تفکیک محصولات مختلف با الگوریتم‌های متفاوت طبقه‌بندی ضروری است. لذا، در این پژوهش بر اساس مطالعات انجام‌شده، سه مدل یادگیری ماشین از ساده تا پیشرفته شامل: MD، SVM و RF، که بر اساس پژوهش‌های ذکرشده نتایج مناسبی در تفکیک مزارع داشتند استفاده شد. استان همدان با توجه به اقلیم سرد و نیمه‌خشک از نواحی مناسب کشور در تولید انگور است و با دارا بودن حدود ۷/۳٪ از تاکستان‌های ایران، بیش از ۱۲٪ انگور کل کشور را تامین می‌کند (Agricultural statistics, 2023). اما با توجه به در دسترس نبودن مناطق کشت آن، تاکنون پژوهشی در راستای تهیه نقشه تاکستان‌ها در این استان انجام نشده است. نتایج این پژوهش می‌تواند نقش مهمی در مدیریت بهینه منابع آب و انرژی، برنامه‌ریزی صادرات با توجه به تخمین دقیق عملکرد قبل از برداشت، شناسایی نواحی مستعد کشت و تغییرات پوشش گیاهی و تاثیر آن بر عملکرد محصول داشته باشد.

این پژوهش ابتدا به مقایسه دقت تفکیک تاکستان‌های استان همدان با استفاده از شاخص‌های سنجش از دور شامل: NDVI و NDWI، برآورده‌شده از تصاویر ترکیبی تصاویر راداری و اپتیکی سنجنده‌های سنتینل-۱ و سنتینل-۲ با توان تفکیک مکانی بالا و




شکل ۱- منطقه محدوده مورد مطالعه در ایران

Fig.1. Study area in Iran

فرآیند انجام پژوهش

فرآیند انجام این پژوهش در شکل ۲ نشان داده شده است. براساس شکل ۲، ابتدا تصحیح اتمسفری بر روی تصاویر سنتینل-۲ در سال ۱۳۹۹ در محدوده استان همدان اعمال می‌شود و سپس بیشترین مقدار ماهانه شاخص‌های NDVI و NDWI در هر پیکسل برای کاهش تاثیر ابر اعمال می‌شود. حضور ابرها بر باندهای نوری تاثیر منفی دارد و سبب نویزی شدن شاخص‌های سنجش از دور پوشش گیاهی می‌شود. رویکرد مقدار بیشینه‌ی این شاخص‌ها در بازه‌های مختلف زمانی (مانند ماهانه) منجر به مقدار دقیق‌تری از وضعیت پوشش گیاهی می‌شود و تاثیر داده‌های نویزی را به شدت کاهش می‌دهد (Holben, 1986; Zhu & Woodcock, 2012). سپس تصویر میانه راداری منطقه مورد مطالعه برای فصل تابستان

سال ۱۳۹۹ از داده‌های ماهواره سنتینل-۱ استخراج و با مجموعه داده‌های بیشینه‌ی ماهانه شاخص‌های NDVI و NDWI سنتینل-۲ با روش چندطیفی ترکیب شد، به‌طوری‌که به شکل یک باند جدید به تصویر میانه راداری اضافه شد تا تصاویری با دقت بالا ایجاد شود. تصویر میانه از میانه هر پیکسل در سری زمانی تصاویر ایجاد می‌شود که برای کاهش تاثیر نویز اسپکل در تصاویر راداری، با توجه به مقاوم بودن میانه به داده‌های پرت، بسیار مفید است و در بسیاری از پژوهش‌ها استفاده می‌شود (Bovolo, & Bruzzone, 2007; Lopez-Martinez & Fabregas, 2002). سپس بر اساس این تصاویر ترکیبی شاخص‌ها و الگوریتم‌های طبقه‌بندی شامل: MD، SVM و RF تاکستان‌ها تفکیک می‌شوند و دقت تفکیک تاکستان‌ها در هر روش بررسی می‌شود.



شکل ۲- فرآیند انجام پژوهش

Fig.2. Research process

تأثیر شرایط ابری بر تصاویر آن، امکان شناسایی هرچه بهتر نوع کشت را فراهم آورده است. استفاده ترکیبی از داده‌های راداری و اپتیک موجب تولید نقشه‌های نوع کشت دقیق‌تری می‌شود. در این پژوهش از تصاویر سنتینل-۱ باند C و قطبش VH استفاده شد.

شاخص‌های سنجش از دور گیاهی

NDVI شاخصی است که با استفاده از روابط ریاضی بین باندهای طیفی مادون قرمز نزدیک (NIR^2) و قرمز (RED) مختلف اجرا می‌شود و در زمینه کشاورزی کاربرد فراوانی دارد (Sekeretkin & Zadbagher, 2021). این شاخص از رابطه (۱) محاسبه می‌شود.

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

شاخص پوشش گیاهی NDVI وضعیت پوشش گیاهی از قبیل کلروفیل را اندازه‌گیری می‌کند و ارتباط مستقیم با ظرفیت فتوسنتزی و جذب انرژی تاج پوشش گیاهی دارد (Arab, Noguchi, Matsushita, & Ahamed, 2021). شاخص NDVI در محدوده ۱ تا -۱ متغیر است، که مقادیر منفی نشان‌دهنده آب، مقادیر صفر تا ۰/۲ محدوده خاک و ۰/۲ تا یک بیانگر پوشش گیاهی است (Alex, Ramesh, & Sridevi, 2017). هرچه مقادیر NDVI به یک نزدیک‌تر باشد نشان‌دهنده تراکم بیشتر پوشش گیاهی است (Filgueiras, Mantovani, Althoff, FernandesFilho, & Cunha, 2019).

شاخص نرمال‌شده تفاضلی آب گیاه NDWI به‌عنوان شاخص دیگری برای طبقه‌بندی تصاویر مورد استفاده قرار گرفت. این شاخص از باندهای مادون قرمز نزدیک (NIR) و مادون قرمز کوتاه ($SWIR^3$) براساس رابطه (۲) محاسبه می‌گردد و میزان رطوبت گیاه را اندازه‌گیری می‌کند (Goa, 1996).

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR} \quad (2)$$

لازم به ذکر است که شاخص‌های NDVI و NDWI از باندهای B4 (Red)، B8 (NIR) و B11 (SWIR) تصاویر سنتینل-۲ و باندهای B1 (Red)، B2 (NIR) و B5 (SWIR) تصاویر سنجنده مودیس بعد از اعمال تصحیح اتمسفری (به‌منظور کاهش اثرات جو) و رادیومتری (در راستای تصحیح اختلافات ناشی از زاویه سنجش و تابش) محاسبه شد.

الگوریتم‌های طبقه‌بندی تصاویر

الگوریتم SVM از مهم‌ترین الگوریتم‌های طبقه‌بندی یادگیری


لازم به ذکر است که برای آموزش و ارزیابی الگوریتم‌های طبقه‌بندی از حدود ۱۲۰۰ نمونه از برداشت‌های میدانی و تصاویر رزولوشن بالای شرکت دیجیتال گلوب در گوگل ارث یا پراکندگی مناسب در کلاس‌های مختلف شامل: تاکستان‌ها (۲۰۳ نمونه)، کوه‌ها و زمین‌های غیر کشاورزی (۲۱۳ نمونه)، آب (۵۰ نمونه)، زمین‌های زراعی کشت‌نشده (۳۴۸ نمونه)، زمین‌های زراعی کشت‌شده (۳۴۳ نمونه) و جنگل (۴۳ نمونه) استفاده شد، به طوری که به شکل تصادفی، ۷۰٪ پیکسل‌ها برای آموزش (۳۰٪ از این ۷۰٪ هم برای صحت‌سنجی) و ۳۰٪ برای آزمایش استفاده شد. لازم به ذکر است که تمام این مراحل در سامانه ابری گوگل ارث انجین^۱ تحت وب انجام می‌شود که با دسترسی و امکان پردازش سریع سری‌های زمانی تصاویر ماهواره‌ای هزینه زمان و محاسبات را بسیار کاهش داده است (Kumar & Mutanga, 2018). سپس با انتخاب دقیق‌ترین نقشه تفکیک تاکستان‌ها، بیشینه‌ی شاخص‌های ماهانه NDVI و NDWI از تصاویر سنجنده مودیس، با توجه به سری زمانی طولانی در دسترس، در مکان تاکستان‌ها در دوره زمانی ۲۰۰۷ تا ۲۰۲۰ استخراج گردید و همبستگی آن‌ها با عملکرد واقعی محصول انگور استان همدان، دریافت‌شده از سازمان جهادکشاورزی همدان، در نرم‌افزار R نسخه 4.4.3 بررسی شد.

تصاویر ماهواره‌ای و تحلیل داده‌ها

تصاویر سنتینل-۲ و سنتینل-۱ توسط آژانس فضایی اروپا برای جمع‌آوری اطلاعات از زمین طراحی شده‌اند که در این پژوهش مورد استفاده قرار گرفتند. ماهواره سنتینل-۲، شامل دو سنجنده‌ی تصویربرداری به نام‌های سنتینل-۲a و سنتینل-۲b است. این تصاویر دارای توان تفکیک مکانی متغیر ۱۰ تا ۶۰ متر و شامل ۱۳ باند در محدوده طیفی مرئی، مادون قرمز نزدیک و مادون قرمز موج کوتاه است. علاوه بر این، سنتینل-۲ دارای عرض برداشت تصاویر ۲۹۰ کیلومتر و توان تفکیک زمانی ۵ روز در استوا است (Ezzatabadipour, 2015). ماهواره سنتینل-۱ نیز در سال ۲۰۱۴ به فضا پرتاب شد. این ماهواره دارای میدان دید وسیع و طولانی تصویربرداری در تمامی شرایط آب و هوایی و طی شب و روز و توان تفکیک زمانی بالا (سه تا پنج روز) است. این ماهواره دارای یک سنجنده SAR در باند C در طول موج مایکروویو در قطبش‌های مختلف VH، VV، HH و HV تصویربرداری می‌کند (Torres et al., 2012). امواج راداری (ماهواره‌های فعال) با توجه به حساس بودن به ویژگی‌های فیزیکی پدیده‌های مختلف از جمله ارتفاع گیاه و عدم

کلاس برای داده‌ها است. این الگوریتم با یافتن ابرصفحه دو کلاس را طوری از هم جدا می‌کند که فاصله نزدیک‌ترین نمونه‌های آموزشی از دو کلاس با این ابرصفحه از یکدیگر بیش‌تر شود (Mohamadi Monavar & Zibazaseh, 2022).

ماشین است که هدف آن تعیین مکان مرزهای تصمیم‌گیری است که جداسازی بهینه کلاس‌ها را ایجاد می‌کند (Pal & Mather, 2005). الگوریتم SVM برای تفکیک دو کلاس به‌صورت زوج‌های مرتب داده‌های آموزشی $\{x_i, y_i\}$, $i=1, \dots, n$, $y_i \in \{1, -1\}$, $x_i \in \mathbb{R}^d$ قابل‌ارائه هستند. در این رابطه x_i ویژگی‌های نقطه‌ی نام و y_i برچسب



شکل ۳- تابع طبقه‌بندی SVM: ابرصفحه که حاشیه را به‌صورت دوبعدی به حداکثر می‌رساند

Fig. 3. SVM classification function: Hyperplane that maximizes the margin in two dimensions (Yu & Kim, 2012)

الگوریتم تجمعی RF به‌عنوان روش سوم برای طبقه‌بندی تصاویر در این پژوهش استفاده شد، که براساس توسعه درخت‌های تصمیم ضعیف ایجاد می‌شود (Breiman, 2001). این الگوریتم به‌دلیل دقت و توانایی آن در فضاهای ویژگی با ابعاد بالا، به‌راحتی پتانسیل استفاده در سیستم‌های بزرگ واقعی را دارد (Biau & Scorene, 2016). جنگل تصادفی یک الگوریتم یادگیری ماشین نظارت‌شده می‌باشد که از مجموعه‌ای از درختان تصمیم تشکیل شده است. در مرحله اول این الگوریتم، جنگلی شامل k درخت تصمیم به‌صورت تصادفی ایجاد می‌شود، که از روش کیسه‌گذاری (Bagging) برای ساخت جنگل استفاده می‌شود. برای پیش‌بینی داده‌ها، ابتدا هر درخت پیش‌بینی را انجام می‌دهد و در مرحله آخر پیش‌بینی‌های ایجادشده درختان ترکیب می‌شوند. مدل RF براساس میانگین‌گیری از نتایج حاصل از تمام درخت‌های تصمیم است. دقت این روش از الگوریتم درخت تصمیم بالاتر است، زیرا با میانگین‌گیری منجر به کاهش بیش‌برازش می‌شود (Immitzer, Vuolo, & Atzberger, 2016).

شاخص‌های ارزیابی روش‌های طبقه‌بندی

$$F(x) = WX - b \quad (3)$$

الگوریتم SVM ابرصفحه‌هایی را با حداکثر حاشیه به‌دست می‌آورد که دسته‌ها را جدا می‌کنند (شکل ۳). در این الگوریتم داده‌هایی که به‌صورت خطی جداپذیر نباشند به فضایی با ابعاد بیشتر نگاشت پیدا می‌کنند. رابطه (۳) جداساز در الگوریتم SVM را نشان می‌دهد که در آن X و W نشان‌دهنده بردارهای واقعی و وزن است که بر ابرصفحه عمود هستند (Yu & Kim, 2012). هم‌چنین b بیانگر بایاس اربیی است که موقعیت ابرصفحه را نسبت به فضای ویژگی اولیه تنظیم می‌کند.

روش MD در این پژوهش به‌عنوان روش دوم برای طبقه‌بندی تصاویر استفاده شد. روش طبقه‌بندی MD، در سنجش از دور برای شناسایی نوع محصولات در نظر گرفته شده است که در این روش طبقه‌بندی، یک نمونه (گروهی از بردارها) در گروهی طبقه‌بندی می‌شوند که توزیع شناخته‌شده شباهت زیادی به نمونه تخمینی نمونه دارد (Wacker & Landgrebe, 1972). در این روش طبقه‌بندی پس از این‌که میانگین ارزش طیفی نمونه‌های انتخابی هر طبقه برای هر پیکسل اختصاص یافت، فاصله پیکسل‌های طبقه‌بندی‌نشده با پیکسل‌های میانگین مقایسه می‌شوند و به کلاسی که نزدیک‌ترین فاصله با میانگین دارد تعلق می‌گیرد.

بیانگر عدم وجود رابطه خطی بین دو متغیر است (Gogtay & Thatte, 2017).

نتایج و بحث

دقت طبقه‌بندی تفکیک تاکستان‌ها براساس الگوریتم‌های RF، MD و SVM با شاخص‌های NDVI و NDWI و داده‌های آزمون نمونه‌برداری (۳۰٪ کل داده‌های نمونه‌برداری ترکیبی از برداشت‌های میدانی و تصاویر گوگل‌ارث) براساس شاخص‌های ارزیابی خطا ارزیابی شد (جدول ۱). این نتایج نشان از برتری الگوریتم RF با شاخص NDVI (با دقت کلی ۹۵ درصد و ضریب کاپا ۰/۹۴) نسبت به الگوریتم SVM با شاخص NDVI (با دقت کلی ۷۰ درصد و ضریب کاپا ۰/۶۱) و الگوریتم MD با شاخص NDVI (با دقت کلی ۵۲ درصد و ضریب کاپا ۰/۳۹)، به دلیل دقت و ضریب کاپای بالاتر، در تفکیک تاکستان‌ها دارد. همچنین طبقه‌بندی با شاخص NDWI با الگوریتم RF (با دقت کلی ۹۵ درصد و ضریب کاپا ۰/۹۵) نسبت به الگوریتم SVM (دقت کلی ۷۷ درصد و ضریب کاپا ۰/۷۱) و الگوریتم MD (دقت کلی ۴۷ درصد و ضریب کاپا ۰/۳۴) عملکرد بالاتری دارد (جدول ۱). به طور کلی نتایج نشان از عملکرد مناسب طبقه‌بندی تصاویر با استفاده از الگوریتم RF توسط هر دو شاخص NDWI و NDVI نسبت به سایر الگوریتم‌ها دارد، در حالی که طبقه‌بندی تصاویر با الگوریتم MD توسط شاخص NDVI و الگوریتم‌های RF و SVM با شاخص NDWI عملکرد بهتری نسبت به طبقه‌بندی تصاویر با الگوریتم MD با شاخص NDWI و دو الگوریتم دیگر با شاخص NDVI داشت (جدول ۱).

ماتریس خطا که ماتریس درهم‌ریختگی^۱ نیز نامیده می‌شود، که با مقایسه پیکسل به پیکسل، پیکسل‌های معلوم (داده‌های اعتبارسنجی) با پیکسل‌های متناظر در نتایج طبقه‌بندی محاسبه می‌شود. از این ماتریس می‌توان دقت کلی (P_j) از رابطه (۴) و ضریب کاپا ($Kappa$) از رابطه (۵) را به عنوان شاخص‌های ارزیابی برآورد کرد.

$$P_j = \frac{\sum_{i=1}^C E_{ij}}{\sum_{k=1}^m t_{kj}} \quad (4)$$

$$Kappa = \frac{p_o - p_c}{1 - p_c} \quad (5)$$

که در رابطه (۴)، C شماره کلاس‌ها، t_{kj} تعداد کل پیکسل‌های معلوم و E_{ij} اعضای قطری ماتریس خطا یا پیکسل‌های دارای کلاس صحیح هستند (Lewis, & Brown, 2001). در رابطه (۵) نیز، p_c توافق مورد انتظار و p_o توافق درستی مشاهده است (ZareKhoramizi, GhafarianMalamiri, & Mortaz, 2020).

ضریب همبستگی

ضریب همبستگی پیرسون بین شاخص‌های سنجش از دور پوشش گیاهی مانند NDVI یا NDWI (x) با عملکرد سالانه تاکستان‌ها (y) (دریافتی از سازمان جهاد کشاورزی) از رابطه (۶) محاسبه می‌گردد (Pearson, 1896)، به طوری که $\bar{x}$ و $\bar{y}$ به ترتیب مقادیر میانگین‌های x و y هستند.

$$S_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (6)$$

ضریب همبستگی در محدوده ۱ و -۱ متغیر است، به طوری که ضریب همبستگی +۱ (-۱) نشان‌دهنده رابطه قوی خطی مستقیم (معکوس) بین دو متغیر است. همچنین، ضریب همبستگی برابر صفر

جدول ۱- ارزیابی دقت طبقه‌بندی با استفاده از شاخص‌های ارزیابی خطا

Table 1- Evaluating classification accuracy using metric errors


ضریب کاپا Kappa Coefficient	دقت کل (درصد) Total Accuracy (%)	الگوریتم Algorithm	شاخص سنجش از دور Remote sensing index
0.94	95	RF	NDVI
0.61	70	SVM	
0.39	52	MD	
0.95	95	RF	NDWI
0.71	77	SVM	
0.34	47	MD	

شاخص‌های NDVI و NDWI و الگوریتم‌های یادگیری ماشین شامل RF، SVM و MD در شکل ۴ ارائه شده است. بررسی تصاویر طبقه‌بندی‌شده با استفاده از شاخص‌های NDVI و NDWI توسط

نقشه‌های طبقه‌بندی‌شده در کلاس‌های مختلف شامل: تاکستان‌ها، کوه‌ها و زمین‌های غیر کشاورزی، آب، زمین‌های زراعی کشت‌نشده، زمین‌های زراعی کشت‌شده و جنگل با استفاده از

و SVM مشابهت بالایی در مکان کلاس تاکستان‌ها در نیمه جنوب شرقی و بخش کوچکی در نیمه جنوب غربی دارند، هرچند که تفکیک کلاس تاکستان‌ها توسط شاخص NDWI نسبت به شاخص NDVI در هر دو الگوریتم عملکرد بهتری داشت. این نتایج با نتایج جدول ۱ درخصوص دقت بالاتر توسط این دو الگوریتم، به‌ویژه با شاخص NDWI توافق دارد.


الگوریتم MD بیانگر کلاس‌های اشتباه بیشتری در کلاس زمین‌های کشاورزی کشت‌نشده یا زمین بایر بود و تاکستان‌ها نیز به اشتباه در کل نقشه طبقه‌بندی پراکنده شده‌اند، که با واقعیت مطابقت ندارند. همچنین زمین‌های کشاورزی کشت‌نشده نیز به‌خوبی شناسایی نشده است، که با نتایج اعتبارسنجی در جدول ۱ مبنی بر کمترین دقت و شاخص کاپا مطابقت دارد. با این حال نقشه‌های طبقه‌بندی‌شده با استفاده از شاخص‌های NDVI و NDWI توسط الگوریتم‌های RF



شکل ۴- تصاویر طبقه‌بندی شده تاکستان‌ها با شاخص‌های NDVI و NDWI توسط الگوریتم‌های متفاوت یادگیری ماشین در استان همدان
Fig.4. Classified images of vineyards with NDVI and NDWI indices using various machine learning algorithms in Hamedan province

جنوب شرقی استان) نسبت به دیگر مناطق استان، به‌ویژه با شاخص NDWI، است که با واقعیت تطابق دارد. بنابراین نتایج نقشه تفکیک تاکستان‌ها با شاخص NDWI و الگوریتم RF، با توجه به بالاترین دقت انتخاب شد.

بنابراین با توجه به پراکندگی صحیح و دقت بالاتر الگوریتم RF، نقشه شناسایی تاکستان‌ها تحت این الگوریتم با شاخص‌های NDVI و NDWI در دو کلاس تاکستان و غیرتاکستان جهت بررسی بیشتر، با توجه به اختلاف خیلی کم، در شکل ۵ ارائه شده است. شکل ۵ بیانگر تجمع اکثر تاکستان‌ها در منطقه شهرستان ملایر (واقع در



شکل ۵- نقشه تاکستان‌های استخراج‌شده استان همدان با شاخص‌های NDVI و NDWI توسط الگوریتم RF
Fig. 5. Extracted vineyard maps of Hamadan province with NDVI and NDWI indices using the RF algorithm

توزیع‌های گاوسی منجر به دقت پایین در تفکیک کلاس‌های پیچیده می‌شود (Negri, Dutra, Sant'Anna, & Lu, 2016). به‌طور مشابه، SVM اگرچه در ایجاد مرزهای تصمیم غیرخطی از طریق بخش هسته (Kernel) قدرتمند است، اما نیاز به تنظیم دقیق پارامترهای خود دارد و به شدت به کیفیت داده‌های ورودی حساس است. علاوه بر این، SVM می‌تواند تحت‌تاثیر نویز قرار گیرد و ممکن است در مواردی با کلاس‌های دارای همپوشانی یا مجموعه داده‌های نامتعادل با مشکل مواجه شود (Cortes & Vapnik, 1995). با این حال، حساسیت MD به نقاط پرت نیز می‌تواند منجر به عدم دقت پایین آن در طبقه‌بندی شود. در حالی که مدل RF براساس ماهیت تجمعی، با محاسبه میانگین، منجر به شناسایی قابل‌قبول‌تری از ویژگی‌های تاکستان‌ها می‌شود. این امر اهمیت انتخاب الگوریتم مناسب براساس پیچیدگی داده‌ها را برجسته می‌کند، در شرایطی که انعطاف‌پذیری و مقاوم بودن مدل RF می‌تواند منجر به مزیت قابل‌توجهی نسبت به فرضیات ساده مدل MD و حساسیت‌های به پارامتر مدل SVM باشد. نتایج این پژوهش با نتایج پژوهش‌های پیشین درخصوص برتری عملکرد مدل RF نسبت به SVM در طبقه‌بندی اراضی کاربری توسط آدم و همکاران (Adam, Mutanga, & Odindi, & Abdel-Rahman, 2014) در نواحی ساحلی و آدوگنا و همکاران (Adugna, Xu, & Fan, 2022) در آفریقا مطابقت دارد. هم‌چنین نتایج این پژوهش توسط غیور و همکاران (Ghayour et al., 2021) تایید می‌شود که الگوریتم SVM نسبت به الگوریتم MD، با استفاده از تصاویر ماهواره‌های سنتینل-۲ و لندست-۸ عملکرد بهتری در طبقه‌بندی کاربری اراضی در شهرستان سقز داشت. در تضاد با این نتایج، بشیر و همکاران (Basheer et al., 2022) با مقایسه دقت الگوریتم‌های طبقه‌بندی‌کننده پوشش اراضی با استفاده از تصاویر ماهواره سنتینل-۲ در کانادا دریافتند که الگوریتم SVM عملکرد بهتری از الگوریتم‌های RF، MD، و CART دارد. از دلایل این عدم تطابق می‌توان به ویژگی‌های اقلیمی متفاوت منطقه مورد مطالعه و نوع گیاهان متفاوت کشت‌شده (گیاهان سردسیری) اشاره کرد. هم‌چنین از دلایل عدم دقت مناسب الگوریتم SVM در این پژوهش،

جدول ۲، بیانگر ماتریس ضریب همبستگی پیرسون بین ماکزیمم ماهانه شاخص‌های NDVI و NDWI برآوردشده از تصاویر سنجنده مودیس در تاکستان‌ها (با استفاده از نقشه تفکیک‌شده تاکستان‌ها براساس شاخص NDWI و الگوریتم RF در شکل ۵) و عملکرد واقعی محصول انگور در سطح معناداری ۵٪ در بازه زمانی ۲۰۰۷ تا ۲۰۲۰ در استان همدان است. نتایج همبستگی بیانگر همبستگی بالاتر شاخص NDVI با عملکرد محصول (ضریب همبستگی ۰/۸۱) نسبت به همبستگی شاخص NDWI با عملکرد محصول (ضریب همبستگی ۰/۷۵) است. هم‌چنین همبستگی بسیار بالایی بین شاخص‌های سنجنش از دور NDVI و NDWI (۰/۹) وجود دارد.

جدول ۲- ماتریس ضریب همبستگی پیرسون شاخص‌های سنجنش از دور گیاهی با عملکرد محصول (سطح معناداری ۵٪)

Table 2- Pearson correlation coefficient matrix of remote sensing vegetation indices with crop yield (Significance at the 5% level)

	NDVI	NDWI
NDWI	0.9	1
NDVI	1	0.9
Yield	0.81	0.75

به‌طور کلی، نتایج این پژوهش نشان داد که طبقه‌بندی تاکستان‌ها تحت الگوریتم‌های RF و SVM، به‌ویژه RF، نسبت به الگوریتم MD با استفاده از هر دو شاخص پوشش گیاهی NDVI و NDWI دقت بالاتری دارد، هرچند که بالاترین دقت در طبقه‌بندی تاکستان‌ها در الگوریتم‌های RF و SVM با شاخص NDWI (دقت کل ۹۵٪ با الگوریتم RF) مشاهده شد. از دلایل دقت بالای مدل RF می‌توان به توانایی آن در مدل کردن بهینه‌ی روابط پیچیده و غیرخطی و مقاوم به داده‌های پرت و نویز اشاره کرد (Liaw & Wiener, 2002). در حالی که RF چندین درخت تصمیم را برای بهبود دقت طبقه‌بندی ترکیب کرده و مهم‌ترین ویژگی‌ها را در طبقه‌بندی استفاده می‌کند، الگوریتم MD مبتنی بر مرزهای تصمیم‌گیری خطی و با فرض

کلروفیل در برگ باشد که منجر به وابستگی بالا و رابطه خطی قوی و مستقیم با عملکرد محصول گردد. این نتایج توسط نتایج عرب و همکاران (Arab et al., 2021) تایید می‌شود، به‌طوری‌که بالاترین همبستگی بین عملکرد محصول انگور با شاخص NDVI (۰/۹۵) برآورد شده از تصاویر سنجنده لندست ۸ در تاجستان‌ها بود. اختلاف در نتایج همبستگی با این پژوهش می‌تواند به دلیل استفاده از سنجنده لندست باشد که توان تفکیک مکانی بسیار بالاتری نسبت به سنجنده مودیس دارد.

نتیجه‌گیری

طبقه‌بندی دقیق اراضی کشاورزی می‌تواند منجر به مدیریت بهینه منابع طبیعی، منابع آب و خاک، برنامه‌ریزی‌های کشاورزی و اقتصادی، اطلاعات دقیقی از نوع و وسعت اراضی در زمینه انتخاب کشت‌های مناسب و بهینه‌سازی تولید و انتخاب کشت‌های پایدار و مقاوم به خشکی شود. نتایج این پژوهش دقت قابل قبول شاخص‌های سنجش از دور پوشش گیاهی ترکیب تصاویر ماهواره‌ای اپتیک و راداری شامل: سنتینل-۲ و سنتینل-۱ و الگوریتم‌های یادگیری ماشین در شناسایی تاجستان‌ها را با نسبت به سایر محصولات زراعی بود، به‌طوری‌که طبقه‌بندی تصاویر با ترکیب الگوریتم RF و شاخص NDVI بالاترین دقت را دارد. هم‌چنین رابطه خطی قوی بین عملکرد با شاخص NDVI نسبت به NDWI در تاجستان‌های استان همدان وجود دارد، که می‌تواند در پیش‌بینی برآورد عملکرد انگور در ماه‌های قبل از برداشت استفاده شود. یافته‌های این پژوهش می‌تواند در راستای برنامه‌ریزی‌های کشاورزی و مدیریت بهینه منابع انرژی در تاجستان‌ها نیز نقش قابل توجهی داشته باشد.

سپاسگزاری

از همکاری جهاد کشاورزی استان همدان به دلیل ارائه داده‌های عملکرد انگور استان همدان سپاس‌گزاریم.

مشارکت نویسندگان

حمیدرضا ملکی: روش‌شناسی، تصویرسازی نتایج، استخراج و تهیه متن
مهرانه خدامرادپور: مفهوم‌سازی، تحلیل آماری، نظارت و مدیریت، تصویرسازی داده‌ها، مشاوره فنی و ویرایش متن
حسنا محمدی منور: مشاوره فنی، اعتبارسنجی، تصویرسازی نتایج و ویرایش متن

References

1. Alex, E. C., Ramesh, K. V., & Sridevi, H. (2017). Quantification and understanding the observed changes in land

می‌توان به عدم توازن در کلاس‌های نمونه‌برداری اشاره کرد، که نقش مهمی در برآورد کلاس‌های طبقه‌بندی دارد و کلاس‌هایی با نمونه‌های بیشتر را بهتر برآورد می‌کند. هم‌چنین دقت بالاتر مدل‌های RF و SVM در طبقه‌بندی با شاخص NDWI نسبت به شاخص NDVI در تفکیک تاجستان‌ها می‌تواند به دلیل محتوای آب بالاتر تاجستان‌ها نسبت به سایر پوشش‌های گیاهی، با توجه به آبیاری و رطوبت بالای خاک باشد، زیرا این شاخص به تغییرات آب موجود در پیکره گیاهی حساس است. این نتایج با نتایج پژوهش ژو و هوانگ (Zhou & Huang, 2019) درخصوص عملکرد بالای NDWI در شرایطی که رطوبت خاک و ویژگی‌های آبی اهمیت بیشتری دارند مطابقت دارد. این ویژگی به‌ویژه در مناطقی که با تنش‌های آبی مواجه هستند، از اهمیت بیشتری برخوردار است، زیرا NDWI می‌تواند به‌خوبی تغییرات رطوبت را در نظر بگیرد و سبب افزایش دقت طبقه‌بندی گردد (Zhang, Chen, & Zhang, 2018). هم‌چنین شواهد موجود از تحقیقاتی که در زمینه طبقه‌بندی پوشش گیاهی انجام شده، نشان می‌دهد که NDVI معمولاً برای شناسایی پوشش گیاهی سالم و زنده مناسب است، اما در شرایطی که رطوبت و آب در گیاهان نقش مهمی دارد، شاخص NDWI می‌تواند اطلاعات دقیق‌تری ارائه دهد (Tucker, 1979). از طرفی، از دلایل پایین بودن دقت طبقه‌بندی تاجستان‌ها با الگوریتم‌های SVM و MD می‌توان به اثر سایه (Shadow effect) در تاجستان‌ها اشاره کرد، که با توجه به شکل قرارگیری برگ و سایه‌اندازی روی زمین باعث اختلاف دمای ۲°C بین برگ‌های واقع در سایه و برگ‌های در معرض نور مستقیم می‌شود (Lu et al., 2022). توماس و همکاران (Tomas, Samuel, Dongryeol, 2018) نیز نشان دادند که اثر سایه در تاجستان‌ها بالا و حدود ۴۳٪ است. با این حال نتایج کریمی و همکاران (Karimi et al., 2022) درخصوص برتری عملکرد تفکیک مزارع با شاخص NDVI نسبت به NDWI برآورد شده از تصاویر لندست ۸ و الگوریتم طبقه‌بندی SVM با نتایج این پژوهش مغایرت دارد، که از دلایل آن می‌توان به اختلاف در نوع تصاویر ماهواره مطالعه شده، اختلاف در دوره‌های زمانی مورد مطالعه و نوع پوشش‌های گیاهی با چرخه فنولوژی متفاوت اشاره کرد.

مقایسه همبستگی بین شاخص‌های ماکزیمم NDVI و NDWI مستخرج از سنجنده مودیس در تاجستان‌ها (با استفاده از نقشه تفکیک تاجستان‌ها با شاخص NDWI و الگوریتم RF) با عملکرد واقعی محصول انگور نشان از رابطه خطی قوی بین شاخص NDVI (۰/۸۱) نسبت به NDWI با عملکرد انگور دارد. بنابراین، شاخص NDVI نسبت به NDWI رابطه نزدیک‌تری با عملکرد واقعی دارد. دلیل این نتیجه می‌تواند وابستگی بالای شاخص NDVI به تغییرات

- cover patterns in Bangalore. *International Journal of Civil Engineering and Technology*, 8(4), 597-603.
2. Adam, E., Mutanga, O., & Odindi, J., & Abdel-Rahman, E. M. (2014). Land-use/cover classification in a heterogeneous coastal landscape using Rapid Eye imagery: Evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing*, 35, 3440-3458. <https://doi.org/10.1080/01431161.2014.903435>
3. Adugna, T., Xu, W., & Fan, J. (2022). Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. *Remote Sensing*, 14(3), 574. <https://doi.org/10.3390/rs14030574>
4. Avalos, J. M. M., & Araujo, E. S. (2021). Optimization of Vineyard Water Management: Challenges Strategies, and Perspectives. *Water*, 13(6), 1-32. <https://doi.org/10.3390/w13060746>
5. Ahmad, F. (2012). Detection of change in vegetation cover using multi-spectral and multi-temporal information for district Sargodha, Pakistan. *Sociedade & Natureza*, 24(3), 557-571. <https://doi.org/10.1590/S1982-45132012000300014>
6. Andalibi, F., & Esmaeily, A. (2015). Vegetation Water Content Estimation Using Vegetation Indices of Low Resolution Satellite Data. *Geospatial Engineering Journal*, 6(2), 11-16. (in Persian).
7. Arab, S. T., Noguchi, R., Matsushita, S., & Ahamed, T. (2021). Prediction of grape yields from time-series vegetation indices using satellite remote sensing and a machine-learning approach. *Remote Sensing Applications: Society and Environment*, 22, 1-14. <https://doi.org/10.1016/j.rsase.2021.100485>
8. Biau, G., & Scornet. E. (2016). A random forest guided tour. *Test*, 25(2), 197-227. <https://doi.org/10.1007/s11749-016-0481-7>
9. Borgogno-Mondino, E., & Lessio, A. (2018). A FFT-Based approach to explore periodicity of vines/soil properties in vineyard from time series of satellite-derived spectral indices. *IEEE International Geoscience and Remote Sensing Symposium* (pp. 9078-9081). <https://doi.org/10.1109/igarss.2018.8519437>
10. Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
11. Brinkhoff, J., Vardanega, J., & Robson, A. J. (2019). Land Cover Classification of Nine Perennial Crops Using Sentinel-1 and -2 Data. *Remote Sensing*, 12(1), 1-26. <https://doi.org/10.3390/rs12010096>
12. Bovolo, F., & Bruzzone, L. (2007). A split-based approach to unsupervised change detection in large-size multitemporal images: Application to tsunami-damage assessment. *IEEE Transactions on Geoscience and Remote Sensing*, 45(6), 1658-1670. <https://doi.org/10.1109/tgrs.2007.895835>
13. Basheer, S., Wang, X., Farooque, A. A., Nawaz, R. A., Liu, K., Adekanmbi, T., & Liu, S. (2022). Comparison of Land Use Land Cover Classifiers Using Different Satellite Imagery and Machine Learning Techniques. *Remote Sensing*, 14(19), 1-18. <https://doi.org/10.3390/rs14194978>
14. Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
15. Egbert, S. L., Park, S., & Price, K. P. (2002). Using conservation reserve program maps derived from satellite imagery to characterize landscape structure. *Computers and Electronics in Agriculture*, 37(1-3), 141-156. [https://doi.org/10.1016/S0168-1699\(02\)00114-X](https://doi.org/10.1016/S0168-1699(02)00114-X)
16. Ezzatabadipour, H. (2015). Introducing Sentinel2 satellite images. *The third national conference on recent innovations in civil engineering, architecture and urban planning* in Tehran. (in Persian).
17. Filgueiras, R., Mantovani, E. C., Althoff, D., FernandesFilho, E. I., & Cunha, F. F. D. (2019). Crop NDVI monitoring based on sentinel 1. *Remote Sensing*, 11(12), 1-21. <https://doi.org/10.3390/rs11121441>
18. Faizizadeh, B., Valizadeh Kamran, K., & Haydari, H. (2008). Estimation of the cultivated area of vineyards in Malekan city using satellite images SPOT5. *Geography and Planning*, 14(27), 47-60. (in Persian).
19. Ghayour, L., Neshat, A., Paryani, S., Shahabi, H., Shirzadi, A., Chen, W., Ansari, N. A., Geertsema, M., Amiri, M. P., Gholamnia, M., Dou, J., & Ahmad, A. (2021). Performance evaluation of sentinel-2 and landsat8 OLI data for land cover/use classification using a comparison between machine learning algorithms. *Remote Sensing*, 13(7), 1-21. <https://doi.org/10.3390/rs13071349>
20. Geudtner, D., Torres, R., Snoeij, P., & Davidson, M. (2012). Sentinel-1 System Overview. In *Proceedings of the 9th European Conference on Synthetic Aperture Radar*, Nurnberg, Germany. 23-26.
21. Goa, B. (1996). NDWI-A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing Environment*, 58(3), 257-266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
22. Gogtay, N. J., & Thatte, U. M. (2017). Principles of correlation analysis. *Journal of the Association of Physicians of India*, 65(3), 78-81.
23. Hartling, S., Sagan, V., Sidike, P., Maimaitjiang, M., & Carron, J. (2019). Urban tree species classification using a WorldView-2/3 and LiDAR data fusion approach and deep learning. *Sensors*, 19(6), 1284. <https://doi.org/10.3390/s19061284>
24. Holben, B. N. (1986). Characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing*, 7(11), 1417-1434. <https://doi.org/10.1080/01431168608948945>
25. Immitzer, M., Vuolo, F., & Atzberger, C. (2016). First Experience with Sentinel-2 Data for Crop and Tree Species

- Classifications in Central Europe. *Remote Sensing*, 8(3), 166. <https://doi.org/10.3390/rs8030166>
26. Junges, A. H., Fontana, D. C., Anzanello, R., & Bremm, C. (2017). Normalized difference vegetation index obtained by ground-based remote sensing to characterize vine cycle in Rio Grande do Sul, Brazil. *Ciencia E Agrotecnologia*, 41(5), 543-553. <https://doi.org/10.1590/1413-70542017415049016>
 27. Karimi, N., Sheshangosht, S., & Eftekhari, M. (2022). Crop type detection using an object-based classification method and multi-temporal Landsat satellite images. *Paddy Water Environment*, 20(3), 395-412. <https://doi.org/10.1007/s10333-022-00901-x>
 28. Kumar, L., & Mutanga, O. (2018). Google Earth Engine Applications Since Inception: Usage, Trends, and Potential. *Remote Sensing*, 10(10), 1509. <https://doi.org/10.3390/rs10101509>
 29. Lewis, H. G., & Brown, M. (2001). A generalized confusion matrix for assessing area estimates from remotely sensed data. *International Journal of Remote Sensing*, 22(16), 3223-3235. <https://doi.org/10.1080/01431160152558332>
 30. Liaw, A., & Wiener, M. (2002). Classification and Regression by RandomForest. *R News*, 2, 18-22.
 31. Lopez-Martinez, C., & Fabregas, X. (2002). Modeling and reduction of SAR interferometric phase noise in the wavelet domain. *IEEE Transactions on Geoscience and Remote Sensing*, 40(12), 2553-2566. <https://doi.org/10.1109/tgrs.2002.806997>
 32. Lu, S., Xuan, J., Zhang, T., Bai, X., Tian, F., & Ortega-Farias, S. (2022). Effect of the shadow pixels on evapotranspiration inversion of vineyard: A high-resolution UAV-based and ground-based remote sensing measurements. *Remote Sensing*, 14(9), 2259. <https://doi.org/10.3390/rs14092259>
 33. Mirzaei, M., Abbasi, M., Marofi, S., Solgi, E., & Karimi, R. (2018). Spectral discrimination of important orchard species using hyperspectral indices and artificial intelligence approaches, *Journal of RS and GIS for Natural Resources*, 9(2), 76-92. (in Persian).
 34. MohamadiManavar, H., & Zibazadeh, S. (2022). Distinguishing rain-fed and irrigated crops in Hamadan province using spectral indices of satellite images. *Journal of Agricultural Machinery*, 12(4), 529-542. (in Persian with English abstract). <https://doi.org/10.22067/jam.2021.69074.1022>
 35. Nematollahi, H., Ashourloo, D., Alimohammadi, A., Khodabandehloo, & Radiom, S. (2018). Development and application of crop and field condition indices using time-series satellite images of Sentinel-2. *Iranian Journal of Remote Sensing & GIS*, 10(3), 105-122. (in Persian with English abstract). <https://doi.org/10.52547/gisj.13.4.1>
 36. Negri, R. G., Dutra, L. V., Sant'Anna, S. J. S., & Lu, D. (2016). Examining region-based methods for land cover classification using stochastic distances. *International Journal of Remote Sensing*, 37(8), 1902-1921. <https://doi.org/10.1080/01431161.2016.1165883>
 37. Pal, S., Pandey, S. K., Sharma, S. K., & Nair, R. (2022). Land use and land cover classification of Jabalpur district using minimum distance classifier. *The Pharma Innovation*, 11(11), 1161-1163.
 38. Pal, M., & Mather, P. M. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26(5), 1007-1011. <https://doi.org/10.1080/01431160512331314083>
 39. Pearson, K. (1896). Mathematical contributions to the theory of evolution III. Regression, heredity and panmixia. *Philosophical Transactions of the Royal Society of London. Series A*, 187, 253-318. <https://doi.org/10.1098/rsta.1896.0007>
 40. Robinson, N. P., Allred, B. W., Jones, M. O., Moreno, A., Kimball, J. S., Naugle, D. E., Erickson, T. A., & Richardson, A. D. (2017). A Dynamic Landsat Derived Normalized Difference Vegetation Index (NDVI) Product for the Conterminous United States. *Remote Sensing*, 9(8), 64-77. <https://doi.org/10.3390/rs9080863>
 41. Sekertekin, A., & Zadbagher, E. (2021). Simulation of future land surface temperature distribution and evaluating surface urban heat island based on impervious surface area. *Ecological Indicators*, 122, 1-11. <https://doi.org/10.1016/j.ecolind.2020.107230>
 42. Tomas, P., Samuel, O. F., Dongryeol, R. (2018). Automatic Coregistration Algorithm to Remove Canopy Shaded Pixels in UAV-Borne Thermal Images to Improve the Estimation of Crop Water Stress Index of a Drip-Irrigated Cabernet Sauvignon Vineyard. *Sensors*, 18, 397. <https://doi.org/10.3390/s18020397>
 43. Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127-150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
 44. Torres, R., Snoeijs, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E. & Rostan, F. (2012). GMES Sentinel-1 mission. *Remote sensing of Environment*, 120, 9-24. <https://doi.org/10.1016/j.rse.2011.05.028>
 45. Vélez, S., Barajas, E., Blanco, P., Rubio, J. A., & Castrillo, D. (2021). Spatio-temporal analysis of satellite imagery (NDVI) to identify terroir and vineyard yeast differences according to appellation of origin (AOP) and biogeographic origin. *Multidisciplinary Scientific Journal*, 4(3), 244-256. <https://doi.org/10.3390/j4030020>
 46. Vintrou, E., Desbrosse, A., Begue, A., Traore, S., Baron, C., & Lo seen, D. (2012). Crop area mapping in West Africa using landscape stratification of MODIS time series and comparison with existing global land products. *International Journal of Applied Earth Observation and Geoinformation*, 14(1), 83-93. <https://doi.org/10.1016/j.jag.2011.06.010>
 47. Wacker, A. G., & Landgrebe, D. A. (1972). Minimum Distance Classification in Remote Sensing. *LARS Technical*

-
- Reports*. Paper 25, 1-20.
48. Yu, H., & Kim, S. (2012). SVM Tutorial: Classification, Regression and Ranking. *Handbook of Natural Computing*, 1, 479-506. https://doi.org/10.1007/978-3-540-92910-9_15
 49. ZareKhoramizi, H., GhafarianMalamiri, H., & Mortaz, M. (2020). Evaluation of supervised classification capability of Landsat-8 and Sentinel-2A Satellite images in determining type and area of Pistachio Cultivars. *Journal of Rs and Gis for natural Resources*, 11(1), 84-103. (in Persian with English abstract).
 50. Zhang, Q., Chen, J., & Zhang, Y. (2018). Evaluating the performance of NDVI and NDWI for urban vegetation coverage assessment. *Remote Sensing*, 10(7), 1156.
 51. Zhao, L., Li, Q., Zhang, Y., Wang, H., & Du, X. (2019). Integrating the Continuous Wavelet Transform and a Convolutional Neural Network to Identify Vineyard Using Time Series Satellite Images. *Remote Sensing*, 11(22), 2641. <https://doi.org/10.3390/rs11222641>
 52. Zhou, Y., & Huang, J. (2019). Comparison of NDWI and NDVI for assessment of vegetation water content in a semiarid area. *Environmental Monitoring and Assessment*, 191(4), 228.
 53. Zhu, Z., & Woodcock, C. E. (2012). Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment*, 118, 83-94. <https://doi.org/10.1016/j.rse.2011.10.028>