



<https://gep.ui.ac.ir/?lang=en>
Geography and Environmental Planning
E-ISSN: 2252- 0910
Document Type: Research Paper
Vol. 35, Issue 2, No.94, Summer 2024, pp. 1- 4
Received: 06/08/2023 Accepted: 20/01/2024

Crop Mapping from Landsat-8 Images Time Series Using Machine-Learning Methods (Case Study: Marvdasht in Fars Province)

Iman Khosravi¹  *

1- Department of Mapping Engineering, Faculty of Civil Engineering and Transportation, Isfahan University, Isfahan, Iran
i.khosravi@cet.ui.ac.ir

Abstract

One of the key priorities of the Ministry of Agriculture Jihad is the mapping of croplands to estimate crop acreage and annual yield. In recent decades, remote sensing technology has proven to be highly effective in estimating the extent of crop cultivation through the use of timely images and synchronized data with diverse spatial, temporal, and spectral resolutions, leveraging advanced machine-learning algorithms. This study presented a framework for crop mapping in Marvdasht, Fars Province, by utilizing time series of Landsat-8 satellite images and advanced machine-learning algorithms. The employed algorithms included Decision Tree (DT), Random Forest (RF), Rotation Forest (RoF), Support Vector Machine (SVM), and Dynamic Time Warping (DTW) analysis. The results indicated that the dynamic time warping and random forest methods outperformed others, achieving significantly higher accuracy (with an overall accuracy improvement of 10-12%) in generating the agricultural land-use map of the study area. Furthermore, this research demonstrated the effectiveness of Bands 2-5 of Landsat-8 satellite in confidently identifying all crops in this region using the mentioned methods.

Keywords: Crop Mapping, Crop Acreage Estimation, Landsat-8 Satellite, Machine Learning, Random Forest (RF), Support Vector Machine (SVM), Dynamic Time Warping (DTW), Remote Sensing.

*Corresponding Author

Khosravi, I. (2024). Crop Mapping from Landsat-8 Images Time Series Using Machine Learning Methods (Case Study: Marvdasht of the Fars Province). *Geography and Environmental Planning*, 35 (2), 1 -4.



2252-0910 © University of Isfahan

This is an open access article under the CC BY-NC 4.0 License (<https://creativecommons.org/licenses/by-nc/4.0>).



10.22108/GEP.2024.138615.1601

Introduction

One of the key priorities of the Ministry of Agricultural Jihad and the related organizations is to create a cropland map for estimating crop area and annual yield of strategic products. This study aimed to establish a framework based on classification algorithms using time series of Landsat-8 satellite images to estimate the crop acreage of agricultural products. The study area was the city of Marvdasht in Fars Province, which boasted a relatively diverse range of agricultural crop types. In addition to the main satellite bands, the NDVI time series was also utilized for collecting the data in this research. Various classification methods, such as Support Vector Machine (SVM), Decision Tree (DT), Random Forest (RF), and Rotation Forest (RoF), were compared with the Dynamic Time Warping (DTW) method as well. Furthermore, a reliable cropland map of the study area was prepared by using each method.

Methodology

In this study, a rule-based framework utilizing well-known classifiers, such as DT, RF, RoF, SVM, and DTW methods, was proposed by using an 8-day time series of Landsat-8 satellite images and the Digital Elevation Model (DEM) of the region. The proposed framework consisted of two fundamental steps: Firstly, non-agricultural areas, including urban areas, water bodies, and mountainous regions, were masked in the region by using several rules. Subsequently, the agricultural fields were classified. To mask urban areas, the Standard Deviation (SD) of the time series of the NDVI index was employed. For identifying water bodies, a simple thresholding method was used based on the negative NDVI values. Additionally, the DEM of the region was utilized to mask highland areas. Finally, the pixels belonging to agricultural areas were classified by using the five algorithms, i.e., DT, RF, RoF, SVM, and DTW.

Research Findings

Using only the NDVI index, the methods achieved an overall accuracy between 81% and 86% (Kappa coefficient of 0.78-0.83). Notably, the RF and DTW methods exhibited the highest overall accuracy. The resulting SD also indicated the high stability of these two methods compared to the others. Conversely, the RoF method demonstrated the lowest accuracy, while the DT method proved to be less stable than all the other methods. The SVM method, exhibited similar inefficiency and low reliability in identifying summer crops and tomato products as the RoF method although it achieved relatively a good overall accuracy and kappa coefficient. In contrast, the RF and DTW methods were able to distinguish tomato products with relatively good accuracy, but they did not perform well in detecting summer crops. It appeared that regardless of the classification method, relying solely on the NDVI index was insufficient for vegetation identification.

Another important observation was that none of these methods achieved the standard accuracy of 85% for identifying products in the study area. Even the RF and DTW methods, which exhibited higher F-score values in most classes compared to the other methods, could not meet this standard accuracy for most classes, including sugar beet, wheat, corn, summer crops, and tomatoes. Therefore, it could be concluded that relying solely on the NDVI index might not be effective for classifying the agricultural croplands of this region.

When the time series of the spectral bands were used in conjunction with the NDVI index time series, the overall accuracy of all the methods improved from 88% to 96% (a 6-12% increase in accuracy). The highest increase in accuracy was 12% and 10% for the DTW and RF methods, respectively. Additionally, these two methods exhibited greater stability compared to the other


methods. The inclusion of spectral bands even provided additional assistance to the DT, RoF, and SVM methods in identifying certain crops, such as summer crops and tomatoes, which had been challenging to identify in the previous stage. Another noteworthy point was that, with the addition of spectral bands, the standard accuracy of 85% was ultimately achieved for all crop types in the city of Marvdasht by the two methods of DTW and RF.

Discussion of Results & Conclusion

This article explored the creation of a cropland map for the agricultural fields of Marvdasht City in Fars Province during the 2014-15 crop year using remote sensing images. An 8-day time series of the spectral bands of 2 to 5 and the NDVI index of Landsat-8 satellite images were employed. This case study encompassed a wide variety of crops, including alfalfa, barley, wheat, corn, sugar beet, tomato, rice, and summer crops. The classification methods utilized in this study comprised Decision Tree (DT), Random Forest (RF), Rotation Forest (RoF), Support Vector Machine (SVM), and Dynamic Time Warping (DTW) algorithms. The implementation of these methods in the mentioned area led to the following conclusions: The DTW and RF methods proved to be more effective than the other methods in identifying agricultural crop types in the study area. Conversely, the DT and RoF methods exhibited subpar performance. The overall low accuracy and inability to identify certain products, such as tomatoes and summer crops, by relying solely on the NDVI index, raised doubts about the efficacy of this method in this region. On the other hand, the DTW method as a novel approach demonstrated excellent efficiency in identifying the agricultural crop types in this region. In summary, this article underscored that, relying solely on the NDVI index for creating a reliable and effective cropland map in Marvdasht was insufficient and it was imperative to incorporate additional features, such as spectral bands, to achieve high accuracy in crop mapping.

مقاله پژوهشی

تهیه نقشه نوع محصول کشاورزی از سری زمانی تصاویر لندست-۸ با استفاده از روش‌های یادگیری ماشین (مطالعه موردی: مرودشت استان فارس)

ایمان خسروی* ، استادیار گروه مهندسی نقشه‌برداری، دانشکده مهندسی عمران و حمل‌ونقل، دانشگاه اصفهان، اصفهان، ایران

i.khosravi@cet.ui.ac.ir

چکیده

یکی از اولویت‌های مهم وزارت جهاد کشاورزی، تهیه نقشه نوع محصول کشاورزی برای تخمین میزان سطح زیرکشت محصولات استراتژیک و برآورد سالیانه میزان تولید آنهاست. در دهه‌های اخیر، فناوری سنجنش از دور به دلیل تهیه تصاویر و داده‌های به‌هنگام با تفکیک‌پذیری‌های متنوع مکانی، زمانی و طیفی و با بهره‌گیری از الگوریتم‌های یادگیری ماشین بهبود یافته در تخمین میزان سطح زیرکشت محصولات کارایی زیادی را نشان داده است. در پژوهش حاضر با استفاده از سری زمانی تصاویر ماهواره لندست-۸ و الگوریتم‌های یادگیری ماشین پیشرفته یک چهارچوب تهیه نقشه نوع محصول کشاورزی مرودشت استان فارس ارائه شد. الگوریتم‌های به کار گرفته شده شامل الگوریتم درخت تصمیم، جنگل تصادفی، جنگل دورانی، ماشین بردار پشتیبان و آنالیز انحراف زمانی پویا بود. نتایج نشان داد که روش‌های آنالیز انحراف زمانی پویا و جنگل تصادفی نسبت به روش‌های دیگر کارایی بسیار بیشتری (با افزایش دقت کلی به میزان ۱۰٪ تا ۱۲٪ بیشتر) در تهیه نقشه نوع محصول کشاورزی منطقه مطالعه شده داشتند. همچنین، در این پژوهش قابلیت باندهای ۲ تا ۵ ماهواره لندست-۸ در شناسایی کارا و مطمئن همه محصولات این منطقه با استفاده از روش‌های مذکور اثبات شد.

واژه‌های کلیدی: تهیه نقشه نوع محصول کشاورزی، تخمین سطح زیرکشت، ماهواره لندست-۸، یادگیری ماشین، جنگل تصادفی، ماشین بردار پشتیبان، آنالیز انحراف زمانی پویا، سنجنش از دور.

*نویسنده مسئول

خسروی، ایمان. (۱۴۰۲). تهیه نقشه نوع محصول کشاورزی از سری زمانی تصاویر لندست-۸ با استفاده از روش‌های یادگیری ماشین (مطالعه موردی: مرودشت استان فارس). *جغرافیا و برنامه‌ریزی محیطی*. ۳۵ (۲)، ۶۶-۴۵.



مقدمه

بخش کشاورزی به‌عنوان یکی از ارکان بنیادی و کلان اقتصاد ملی نه‌تنها نقش بسزایی در تأمین مواد غذایی مردم دارد، به‌عنوان یک مؤلفه اساسی از اقتدار و امنیت ملی کشورها به‌ویژه ایران شناخته می‌شود. مدیریت کارآمد، هدفمند و پایش دقیق این بخش تأثیر فوری و مستقیمی بر اقتصاد داخلی و نیز روابط بین‌المللی کشور دارد. یکی از اولویت‌های حیاتی وزارت جهاد کشاورزی، تهیه نقشه نوع محصول کشاورزی (Crop Mapping) یا تخمین سطح زیرکشت محصولات (Crop Acreage Estimation) با هدف برآورد سالیانه میزان تولید محصولات استراتژیک است. داشتن اطلاعات دقیق از سطح زیرکشت محصولات، اقدام‌های منطقی و مؤثرتری را در سیاست‌های مدیریتی و اجرایی کوتاه‌مدت و بلندمدت بخش کشاورزی فراهم می‌کند (Zhu et al., 2017).

باوجود ضرورت این مسئله و تأثیر ویژه آن در مدیریت کشاورزی و اقتصاد ملی، بیشتر شیوه سنتی همچون جمع‌آوری اطلاعات میدانی از کشاورزان و صاحبان املاک استفاده شده است. این شیوه امکان تخمین سطح زیرکشت را فراهم می‌کند؛ اما به‌دلیل تنوع زیاد اظهارنظرها، اعتماد کاملی به آن وجود ندارد؛ بنابراین نیازمند هزینه‌های انسانی و زمانی چشمگیری به‌ویژه در منطقه‌های وسیع است (Li et al., 2022). در دهه‌های اخیر، فناوری سنجش از دور (Remote Sensing) با رشد و توسعه سیستم‌های تصویربرداری از سطح زمین به‌عنوان یک ابزار حیاتی در زمینه مطالعه، تولید اطلاعات جامع و مدیریت یکپارچه کشاورزی شناخته شده است (Wu et al., 2023). این فناوری به‌دلیل فراهم کردن تصاویر و داده‌های به‌هنگام با تفکیک‌پذیری‌های متنوع مکانی، زمانی و طیفی نقش مهمی در بخش کشاورزی به‌ویژه در تخمین میزان سطح زیرکشت محصولات دارد (Mao et al., 2023).

تاکنون ماهواره‌های سنجش از دور متنوعی در مطالعات کشاورزی به کار گرفته شده است. در چند سال گذشته، ماهواره لندست-۸ به‌طور ویژه توجه پژوهشگران را به خود جلب کرده است (Du et al., 2022; Lv et al., 2020). این ماهواره قابلیت تهیه نقشه‌های پهنه‌بندی را در مقیاس ملی-محلی دارد. تصاویر ماهواره لندست-۸ خطای نوارشدگی موجود در برخی تصاویر لندست-۷ را ندارد و با داشتن باندهای اضافه‌تر در کاربردهای کشاورزی مفید است. زمان تکرار تصویربرداری این ماهواره ۱۶ روز است که به دلیل هم‌پوشانی عرضی باندهای تصویربرداری این زمان در بیشتر مواقع تا ۸ روز هم کاهش می‌یابد؛ بنابراین برای پایش روند رشد گیاه مناسب به نظر می‌رسد (Zhang et al., 2022). عمده ویژگی‌های استفاده‌شده از این ماهواره در مقاله‌ها شامل اطلاعات باندهای طیفی ۲ تا ۵ (مرئی و مادون قرمز نزدیک) است که بیانگر رفتار انعکاسی انواع محصولات است (Wei et al., 2022). علاوه بر این، شاخص گیاهی تفاضلی نرمال‌شده (Normalized Difference Vegetation Index) (NDVI) و شاخص گیاهی بهبودیافته (Enhanced Vegetation Index) (EVI) در برخی مقاله‌ها به کار گرفته شده است (Chellasamy et al., Peña-Barragán et al., 2011). سری زمانی این شاخص‌ها به‌ویژه NDVI می‌تواند برای بررسی و تشخیص وقایع رشدشناسی محصول (فنولوژی) همچون شروع، پایان و طول فصل رشد گیاه مفید باشد.

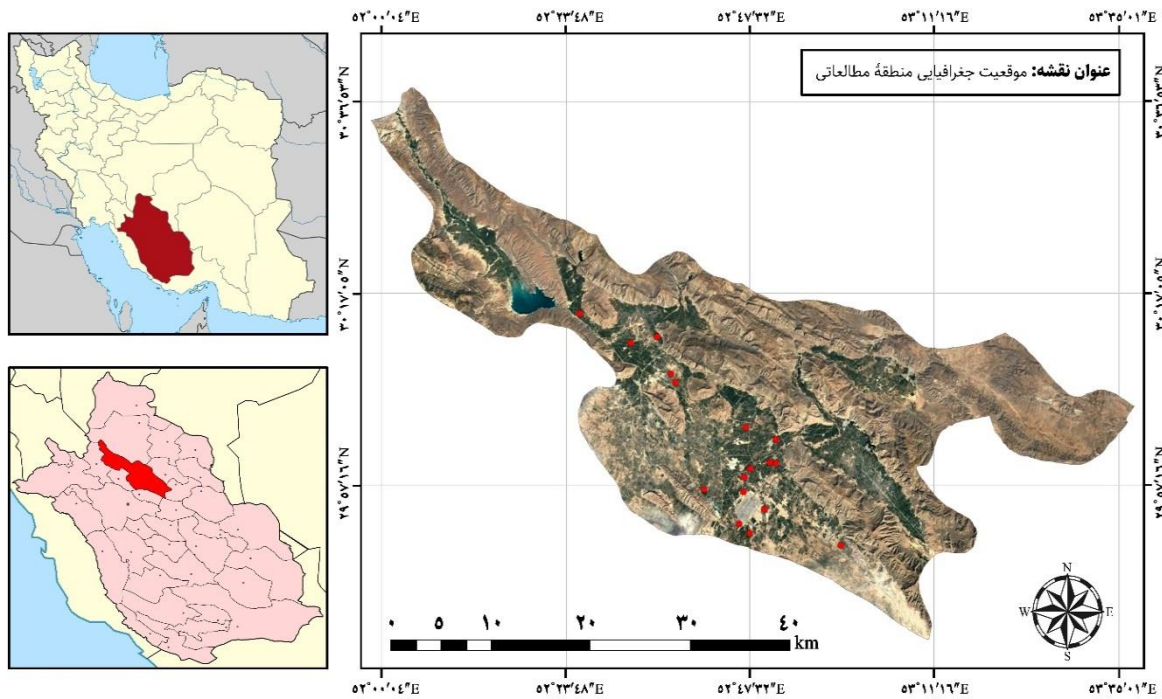
در دهه‌های اخیر، روش‌های یادگیری ماشین مختلفی با ساختارها و معماری‌های متنوعی برای تهیه نقشه نوع محصول کشاورزی از تصاویر ماهواره‌ای استفاده شده است. در این میان، روش‌های طبقه‌بندی نظارت‌شده چندزمانه با کمک شاخص‌های پوشش گیاهی نتایج مؤثری را برای تفکیک محصولات کشاورزی ارائه کرده است. در برخی مطالعات از روش شبکه بیزین و الگوریتم بیشترین شباهت (Maximum Likelihood) استفاده شده است (Chen et al., 2020; López-Andreu et al., 2021; Lu et al., 2022a, 2020). این دو روش به شدت وابسته به توزیع داده‌ها هستند که بیشتر در طبقه‌بندی مجموعه داده‌های بزرگ با محدودیت مواجه می‌شوند. در برخی از مطالعات دیگر از شبکه عصبی مصنوعی (ANN) (Artificial Neural Network) و ماشین بردار پشتیبان (SVM) (Support Vector Machine) بهره برده شده است (Ioannidou et al., 2022; Shen et al., 2022; Gao et al., 2023; Mao et al., Denize et al., 2019; Du et al., 2023; Vilela et al., 2023). الگوریتم ANN بیشتر به‌عنوان یک طبقه‌بندی‌کننده ناپایدار شناخته می‌شود (Du et al., 2012). SVM نیز اگرچه یک روش تعمیم‌پذیر و پایدار برای طبقه‌بندی داده‌ها در فضایی با ویژگی ابعاد بالاست، با چندین چالش بزرگ همچون انتخاب کرنل و پارامترهای بهینه آن و اثر داده‌های نویزی روی کارایی اش مواجه است (Khosravi et al., 2021). از روش‌های یادگیری ماشین مبتنی بر درخت از جمله درخت تصمیم (DT) (Decision Tree)، روش جنگل تصادفی (RF) (Random Forest) و روش جنگل دورانی (RoF) (Rotation Forest) در مطالعات طبقه‌بندی محصولات کشاورزی استفاده شده است (Denize et al., 2018; Forest et al., 2019; Seydi et al., 2022; Tuvdendorj et al., 2022; Yi et al., 2022; Bolaños et al., 2023; Gao et al., 2023; Vilela et al., 2023; Mirzaei et al., 2023; Mao et al., 2023; al., 2023). الگوریتم DT ساختار ساده و قابل فهمی دارد؛ اما ممکن است با مشکلاتی در طبقه‌بندی داده‌های بزرگ روبه‌رو شود (Du et al., 2012). در مقابل، الگوریتم RF همانند SVM کارایی زیادی در چنین شرایطی دارد. الگوریتم RF به لطف امتیازاتش نسبت به الگوریتم SVM مطلوب‌تر است. روش RF سرعت عملکردی بیشتر، انعطاف بیشتر و ساختار ساده‌تر دارد و نسبت به داده‌های نویزی مقاوم‌تر است. همچنین، برخلاف SVM دغدغه کمتری برای انتخاب پارامترهای بهینه دارد (Khosravi & Alavipanah, 2019).

حصول دقت بالا روش‌های یادگیری ماشین ذکرشده بیشتر در صورت وجود داده‌های زمینی کافی امکان‌پذیر است؛ با این حال جمع‌آوری داده‌های زمینی به‌هنگام یک فرآیند زمانبر و هزینه‌بر است؛ بنابراین این روش‌ها در شرایط محیطی پیچیده و سیستم‌های کشاورزی مختلف ممکن است کارایی مناسبی نداشته باشد. به‌تازگی، آنالیز انحراف زمانی پویا (DTW) (Dynamic Time Warping) در چندین مطالعه طبقه‌بندی محصولات کشاورزی استفاده شده است (Belgiu et al., 2020; Rafif et al., 2021; Singh et al., 2021; Xiao et al., Belgiu & Csillik, 2018; Xiao et al., 2023). این روش کارایی زیاد در هنگام محدودیت دسترسی به داده‌های زمینی و تنها یک نیاز حداقلی به دانش تقویم زراعی و عملیات کشاورزی دارد. همچنین، این روش قابلیت تعمیم به سال‌های مختلف و منطقه‌های وسیع‌تر را با تنظیمات جزئی مربوط به شرایط کشاورزی و آب‌وهوایی سالیانه دارد (Xiao et al., 2023).

تاکنون در ایران اقدام‌های بسیار محدود و غیرمنسجمی برای ارائه یک چارچوب جامع تهیه نقشه نوع محصول یا تخمین سطح زیرکشت محصولات کشاورزی با استفاده از روش‌های یادگیری ماشین به‌ویژه روش‌های جنگل تصادفی و آنالیز انحراف زمانی پویا از تصاویر ماهواره‌ای لندست-۸ انجام شده است. این نقطه ضعف اقدام‌های محدود اغلب به دلیل در دسترس نبودن به داده‌های زمینی کافی مشکلاتی را در جمع‌آوری آنها به وجود آورده است؛ بنابراین محققان در پژوهش حاضر قصد دارند تا برای پرکردن این خلأ براساس روش‌های یادگیری ماشین نظارت‌شده گامی در راستای ارائه یک چارچوب تخمین سطح زیرکشت محصولات کشاورزی یک منطقه در ایران با استفاده از سری زمانی تصاویر ماهواره‌ای لندست-۸ بردارند. شهر مرودشت استان فارس به دلیل تنوع فراوان محصولات کشاورزی به‌عنوان منطقه مطالعاتی این پژوهش انتخاب شده است. ویژگی‌های استفاده‌شده در این پژوهش سری زمانی باندهای ۲ تا ۵ و سری زمانی NDVI استخراج‌شده از تصاویر این ماهواره است. همچنین، روش‌های طبقه‌بندی مختلف از جمله SVM، DT، RF، RoF با روش DTW از لحاظ وابستگی به نمونه آموزشی مقایسه شده است. ضمن اینکه، با هر روش یک نقشه تهیه نوع محصول کشاورزی تهیه می‌شود. نتایج حاصل از این مطالعه نه تنها به دقت و کارایی هر مدل اشاره خواهد کرد، می‌تواند به مسئولان و پژوهشگران در برنامه‌ریزی مناسب برای افزایش بهره‌وری و توسعه کشاورزی در ایران کمک کند.

معرفی منطقه مطالعاتی

دشت مرودشت استان فارس به‌عنوان مطالعه موردی این پژوهش انتخاب شده است. علت انتخاب این منطقه تنوع فراوان محصولات کشاورزی آن است که می‌تواند الگوی خوبی برای سیستم کشاورزی کل ایران باشد. [شکل ۱](#) محدوده سیاسی این منطقه و موقعیتش را نسبت به کشور و استان فارس نشان می‌دهد. مرودشت در ۴۰ کیلومتری شمال شیراز و در حد فاصل طول‌های جغرافیایی ۵۲ درجه و ۴ ثانیه تا ۵۳ درجه، ۳۵ دقیقه و ۱ ثانیه شرقی و عرض‌های جغرافیایی ۲۹ درجه، ۳۷ دقیقه و ۲۸ ثانیه تا ۳۰ درجه، ۳۶ دقیقه و ۵۲ ثانیه شمالی واقع شده است. مساحت این منطقه حدود ۴/۷ هزار کیلومتر مربع و ارتفاع متوسط آن از سطح دریا ۱۶۲۰ متر است. آب‌وهوای این منطقه کوهستانی و معتدل است و تنوع فراوانی از مزارع کشاورزی را دارد. ضمن اینکه، نواحی کوهستانی در این منطقه به شدت به چشم می‌خورد. همچنین، در قسمت شمال شرقی این منطقه دریاچه‌ای قرار دارد که به نام دریاچه دودزن مشهور و سدی بر این دریاچه احداث شده است. شهر مرودشت به‌عنوان مرکز شهرستان مرودشت در قسمت جنوبی این منطقه قرار دارد. طبق سرشماری عمومی نفوس و مسکن سال ۱۳۹۵ برآورد جمعیت این شهرستان برابر با حدود ۳۲۴ هزار نفر به‌عنوان دومین شهر پرجمعیت استان فارس بوده است. شغل بیشتر مردم این شهرستان کشاورزی و دامداری است.



شکل ۱: موقعیت جغرافیایی منطقه مطالعاتی: دشت مروودشت، استان فارس، ایران: نمونه های جمع آوری شده از این منطقه با

دوایر قرمز رنگ در این شکل مشخص شده است (منبع: نگارنده ۱۴۰۲)

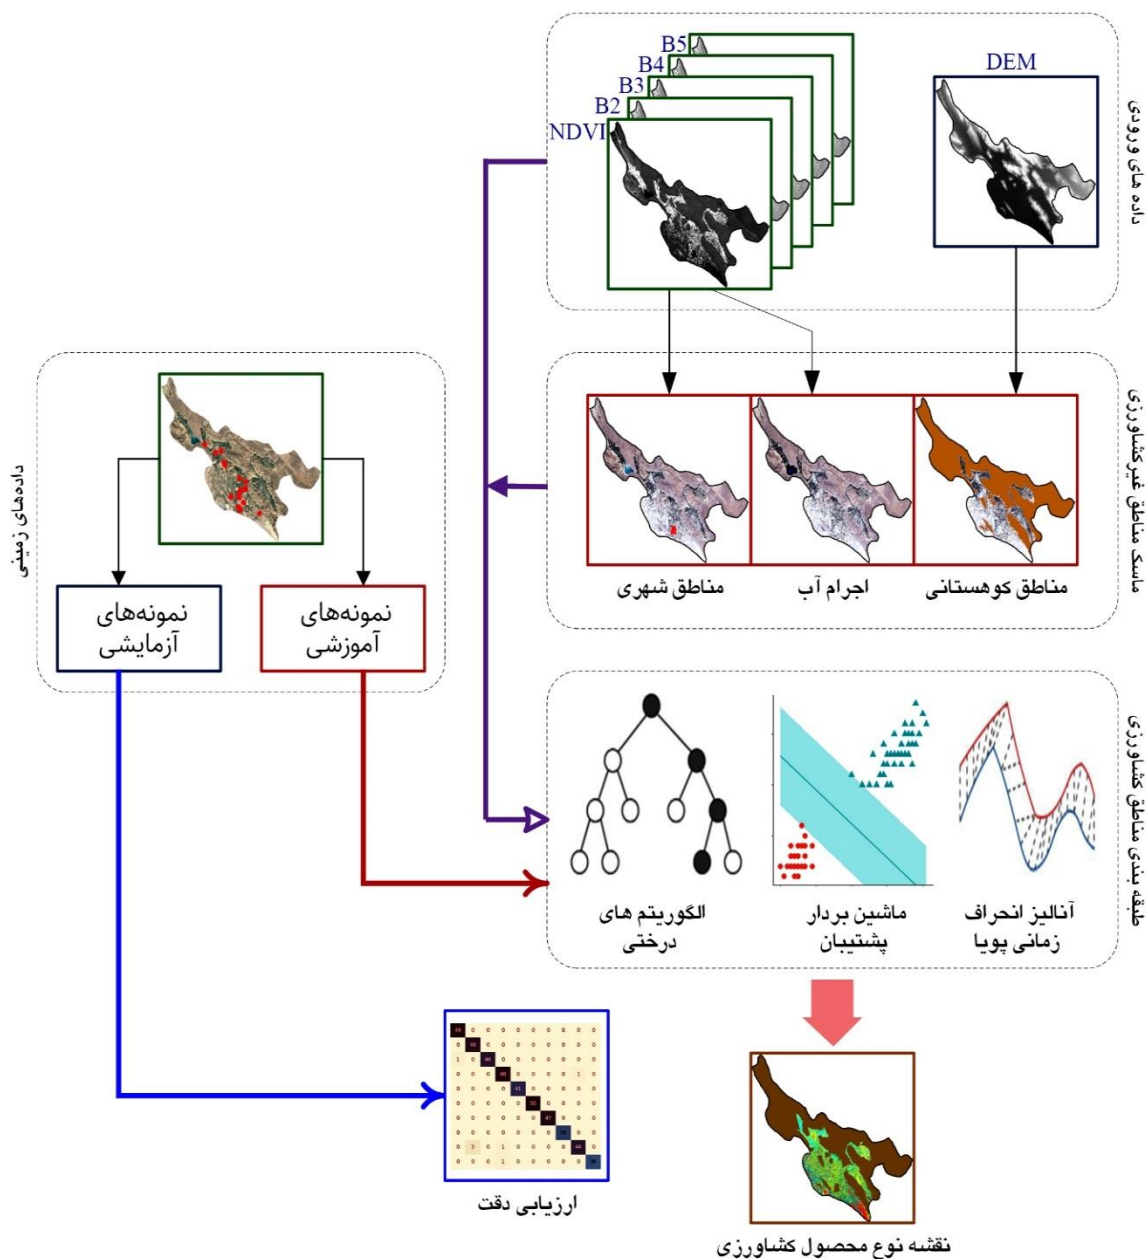
Figure 1: Geographical location of the study area: Marvdasht city, Fars province, Iran. The samples collected from this area were marked with red circles.

روش شناسی پژوهش

در پژوهش حاضر یک چارچوب قاعده مبنای کمک روش های یادگیری ماشین پیشرفته شامل الگوریتم های درختی (از جمله درخت تصمیم (DT)، جنگل تصادفی (RF)، جنگل دورانی (RoF)، ماشین بردار پشتیبان (SVM)، آنالیز انحراف زمانی پویا (DTW)) از سری زمانی ۸ روزه تصاویر ماهواره لندست-۸ و مدل ارتفاعی رقومی مروودشت استان فارس برای تهیه نقشه نوع محصول کشاورزی این منطقه پیشنهاد می شود.

مطابق با شکل ۲ چارچوب پیشنهادی گام های اساسی زیر را دارد.

ابتدا داده های ورودی شامل باندهای تصویری و شاخص گیاهی NDVI استخراج شده از ماهواره لندست-۸ به همراه داده کمکی مدل ارتفاعی (DEM) آماده و پیش پردازش می شود. پس از آن با استفاده از قواعدی منطقه های غیرکشاورزی شامل منطقه های شهری، اجرام آبی و منطقه های کوهستانی در تصویر ماسک می شود. سپس با استفاده از الگوریتم های طبقه بندی اشاره شده، مزارع کشاورزی منطقه مطالعاتی تفکیک و در نهایت، نقشه نوع محصول کشاورزی از هر روش تهیه می شود.



شکل ۲: نمای شماتیک چارچوب قاعده‌مبنای پیشنهادی برای تهیه نقشه نوع محصول کشاورزی (منبع: نگارنده ۱۴۰۲)

Figure 2: Schematic diagram of the proposed rule-based framework for crop mapping.

معرفی داده‌های ورودی

داده‌های ماهواره‌ای استفاده‌شده در پژوهش حاضر تصاویر سری زمانی ۸ روزه از سپتامبر سال ۲۰۱۴ میلادی تا سپتامبر سال ۲۰۱۵ میلادی (مهر ۱۳۹۳ تا مهر ۱۳۹۴) مربوط به سنجنده OLI ماهواره لندست-۸ اخذشده از منطقه مطالعاتی است (جدول ۱). ماهواره لندست-۸ در ۱۱ فوریه سال ۲۰۱۳ میلادی به فضا پرتاب شد که ۲ سنجنده OLI و TIRS با مجموع ۱۱ باند طیفی دارد. در این پژوهش تنها از سری زمانی باندهای ۲ تا ۵ (باند ۲: آبی، باند ۳: سبز،

باند ۴: قرمز، باند ۵: مادون قرمز نزدیک) با حد تفکیک مکانی ۳۰ متر استفاده شد. تمام این تصاویر در دیتوم سیستم ژئودتیک جهانی ۱۹۸۴ (WGS-84) زمین مرجع شده است. پیش پردازش‌هایی روی باندهای تصویری (تصحیحات جوئی، تبدیل درجه خاکستری به مقدار بالای جو برای باندهای طیفی و ماسک و تصحیح منطقه‌های ابری) انجام شد. برای ماسک ابر از روش خودکار Fmask بهره گرفته (Qiu et al., 2019) و سپس با درون‌یابی تصاویر قبل و بعد تاریخ‌های ابری، درجه خاکستری این منطقه‌ها تصحیح شد. همچنین، در پژوهش حاضر سری زمانی شاخص NDVI استخراج شده از سری زمانی باندهای قرمز و مادون قرمز نزدیک به کار گرفته شد؛ البته گفتنی است که برای تمام روش‌های طبقه‌بندی، ویژگی‌ها به دو صورت به کار گرفته شد. یکبار از سری زمانی شاخص NDVI به‌تنهایی (۴۶ ویژگی) و بار دیگر از سری زمانی باندها و سری زمانی NDVI (۲۳۰ ویژگی) استفاده شد.

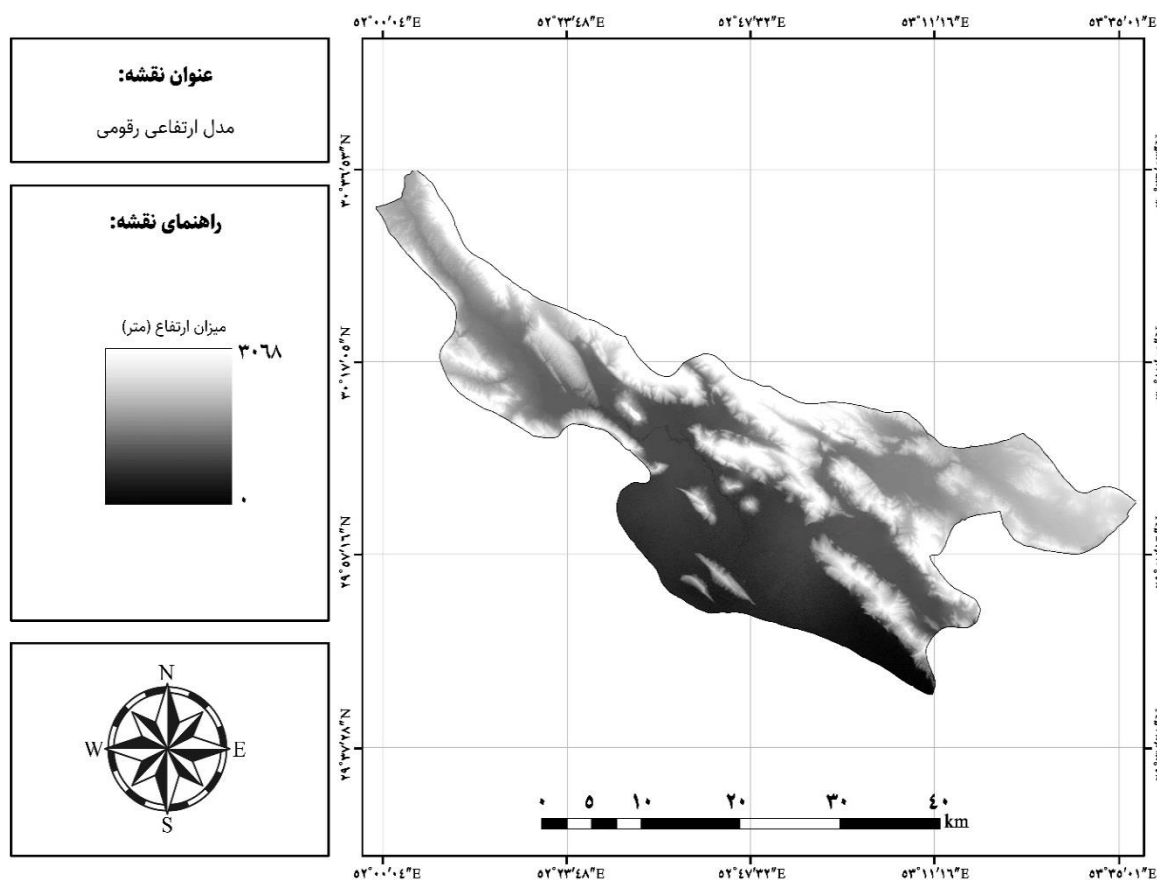
جدول ۱: تاریخ اخذ تصاویر لندست-۸ مربوط به منطقه مطالعاتی مرودشت در سال زراعی ۹۳-۹۴

Table 1: The date of taking Landsat-8 images related to Marvdasht study area in the crop year 93-94.

سال شمسی		ماه شمسی اخذ تصویر	سال میلادی		ماه میلادی اخذ تصویر
۱۳۹۴	۱۳۹۳		2015	2014	
	۲۳، ۱۵، ۰۷	مهر		۲۹	سپتامبر
	۲۵، ۱۷، ۰۹، ۰۱	آبان		۳۱، ۲۳، ۱۵، ۰۷	اکتبر
	۲۷، ۱۹، ۱۱، ۰۳	آذر		۲۴، ۱۶، ۰۸	نوامبر
	۲۹، ۲۱، ۱۳، ۰۵	دی		۲۶، ۱۸، ۱۰، ۰۲	دسامبر
	۲۳، ۱۵، ۰۷	بهمن	۲۷، ۱۹، ۱۱، ۰۳		ژانویه
	۲۵، ۱۷، ۰۹، ۰۱	اسفند	۲۸، ۲۰، ۱۲، ۰۴		فوریه
۲۸، ۲۰، ۱۲، ۰۴		فروردین	۲۴، ۱۶، ۰۸		مارس
۲۹، ۲۱، ۱۳، ۰۵		اردیبهشت	۲۵، ۱۷، ۰۹، ۰۱		آوریل
۳۰، ۲۲، ۱۴، ۰۶		خرداد	۲۷، ۱۹، ۱۱، ۰۳		مه
۳۱، ۲۳، ۱۵، ۰۷		تیر	۲۸، ۲۰، ۱۲، ۰۴		ژوئن
۲۴، ۱۶، ۰۸		مرداد	۳۰، ۲۲، ۱۴، ۰۶		ژوئیه
۲۵، ۱۷، ۰۹، ۰۱		شهریور	۳۱، ۲۳، ۱۵، ۰۷		اوت
۰۲		مهر	۲۴، ۱۶، ۰۸		سپتامبر

منبع: نگارنده ۱۴۰۲

داده کمی استفاده شده در این پژوهش مدل ارتفاعی رقومی (DEM) اخذ شده از SRTM با حد تفکیک مکانی نزدیک به ۳۰ متر مربوط به سال ۲۰۱۴ از منطقه مطالعاتی است. برای این منطقه ۸ الگوریتم DEM موجود بود که ابتدا این ۸ الگوریتم DEM با یکدیگر موزاییک و سپس با تصاویر ماهواره‌ای لندست-۸ هم‌سیستم مختصات شدند. شکل ۳ مدل ارتفاعی رقومی مرودشت را نشان می‌دهد. منطقه‌های مرتفع و کوهستانی درجه خاکستری روشن (سفید) و منطقه‌های کم‌ارتفاع که بیشتر شامل زمین‌های کشاورزی، اجرام آبی و منطقه‌های ساخته شده است با درجه خاکستری تیره (مشکی) در این شکل مشخص است.



شکل ۳: مدل ارتفاعی رقومی (DEM) اخذ شده از SRTM از دشت مرو دشت (منبع: نگارنده ۱۴۰۲)

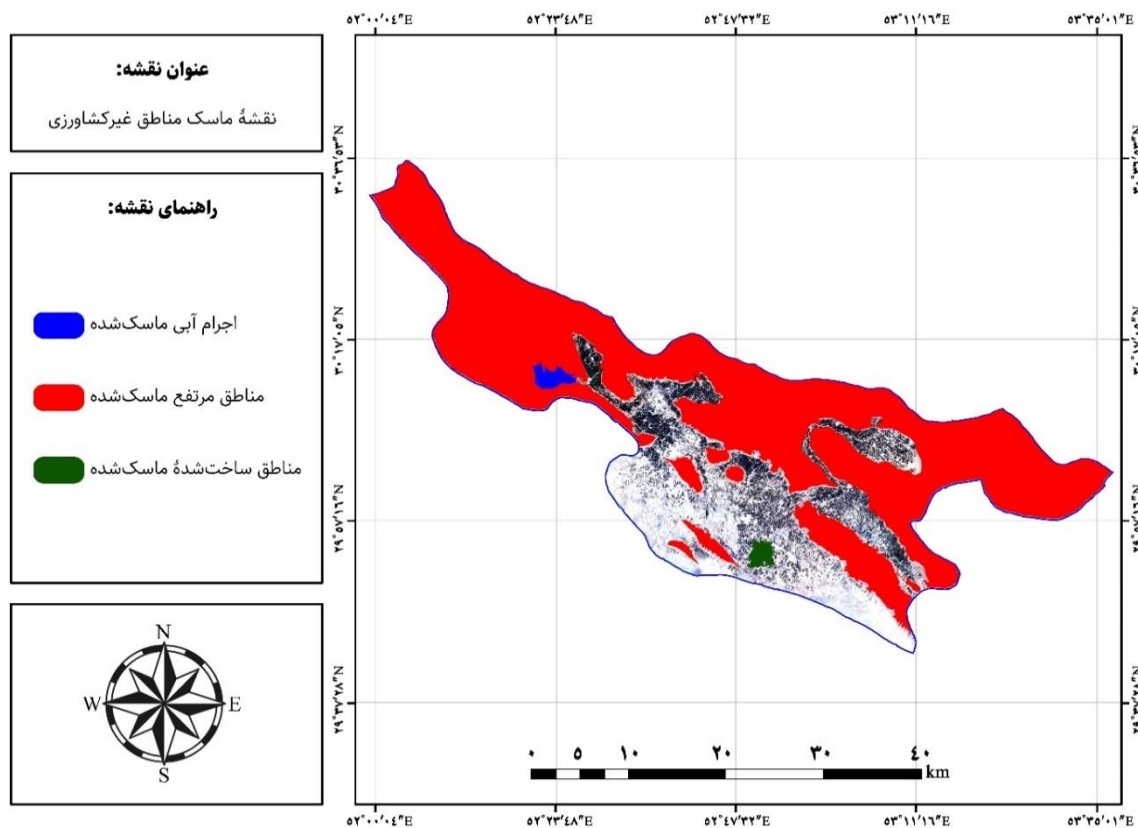
Figure 3: Digital Elevation Model (DEM) obtained by SRTM from Marvdasht City.

ماسک منطقه‌های غیرکشاورزی

ماسک منطقه‌های غیرکشاورزی شامل ماسک اجرام آبی، منطقه‌های مرتفع و منطقه‌های شهری در تصاویر می‌شود. برای شناسایی و ماسک اجرام آبی در این منطقه بدین صورت عمل شد: مقدار شاخص NDVI اجرام آبی منفی است؛ بنابراین با یک آستانه‌گذاری ساده از شاخص NDVI میانگین (کوچکتر از صفر) این منطقه‌ها در تصویر ماسک شد. [شکل ۴](#) اجرام آبی ماسک شده را در تصویر منطقه مطالعاتی به رنگ آبی نشان می‌دهد.

برای شناسایی و ماسک منطقه‌های مرتفع کوهستانی بدین صورت عمل شد: با توجه به DEM منطقه، ارتفاع منطقه‌های کوهستانی اختلاف شدیدی با منطقه‌های غیرمرتفع (به‌ویژه مزارع کشاورزی) دارد؛ بنابراین می‌توان تصویر DEM را به صورت یک تصویر باینری که هیستوگرام دو قله‌ای (Bi-Modal) دارد، تصور کرد که یک قله آن، نمایانگر منطقه‌های مرتفع و کوهستانی و قله دیگر، نمایانگر منطقه‌های غیرمرتفع و پست است؛ بنابراین با یک روش قطعه‌بندی کارا همچون روش مدل مخلوط گوسی (Gaussian Mixture Model) (GMM) و با در نظر گرفتن تعداد خوشه‌ها برابر ۲ منطقه‌های مرتفع کوهستانی از سایر منطقه‌ها ماسک شد. [شکل ۴](#) منطقه‌های مرتفع ماسک شده را در تصویر منطقه مطالعاتی به رنگ قرمز نشان می‌دهد.

برای شناسایی و ماسک منطقه‌های ساخته‌شده بشری بدین صورت عمل شد: منطقه‌های ساخته‌شده بشری همچون منطقه‌های شهری برخلاف منطقه‌های طبیعی (گیاهان و مزارع کشاورزی) رفتار طیفی ایستا و به نسبت ثابتی در طول زمان (یک سال زراعی) دارند. پس می‌توان نتیجه گرفت که انحراف معیار این منطقه‌ها در طول زمان نسبت به مزارع کشاورزی بسیار متفاوت است؛ با این حال باید در نظر داشت که منطقه‌های طبیعی همچون کوهستان و تپه‌ها نیز همانند منطقه‌های ساخته‌شده بشری رفتار طیفی به نسبت ایستایی در طول زمان دارند؛ بنابراین همانند ایده قبلی مجدد با روش قطعه‌بندی GMM این منطقه‌ها در تصویر ماسک شد. در اینجا تعداد خوشه‌ها به تنوع منطقه‌های ساخته‌شده بشری در مقابل منطقه‌های طبیعی بستگی دارد. شکل ۴ منطقه‌های ساخته‌شده بشری ماسک‌شده را در تصویر منطقه مطالعاتی به رنگ سبز نشان می‌دهد. منطقه‌های کوهستانی از این منطقه‌ها مجزا شدند.



شکل ۴: ماسک منطقه‌های غیرکشاورزی در مرودشت شامل: الف) اجرام آبی (ماسک‌شده به رنگ آبی)؛ ب) منطقه‌های مرتفع (ماسک‌شده به رنگ قرمز)؛ پ) منطقه‌های ساخته‌شده بشری (ماسک‌شده به رنگ سبز) (منبع: نگارنده ۱۴۰۲)

Figure 4: Mask of non-agricultural areas in the Marvdasht including: a) water bodies (masked in blue color); b) highland areas (masked in red) and c) man-made areas (masked in green).

روش‌های یادگیری ماشین

پس از ماسک منطقه‌های غیرکشاورزی، پیکسل‌های متعلق به مزارع کشاورزی با پنج الگوریتم DT, RF, RoF, SVM و DTW طبقه‌بندی می‌شود. در الگوریتم DT نمونه‌ها به نحوی دسته‌بندی می‌شود که از گره ریشه به سمت پایین رشد می‌کنند و در انتها به گره‌های پایانی یا برگ‌ها که همان تصمیم‌ها یا برچسب نمونه‌هاست، می‌رسند. گره


ریشه و هر گره داخلی (انشعاب) یک ویژگی را نشان می‌دهد که به تعداد ارزش یا مقدار آن ویژگی، شاخه از آن به گره‌های پایین‌تر وجود دارد. برای یادگیری DT یک الگوریتم از معیار بهره‌ اطلاعاتی که مبتنی بر مفهوم بی‌نظمی است، برای رشد درختان از بالا به پایین استفاده می‌کند. پس از تشکیل کامل درخت برای جلوگیری از پیچیده‌تر شدن ساختار درخت از عمل هرس کردن درخت و کنار گذاشتن شاخه‌های اضافی و غیرضروری استفاده می‌شود (خسروی و همکاران، ۱۳۹۴). در واقع، الگوریتم DT در کنار رتبه‌بندی ویژگی‌ها، کار طبقه‌بندی (رسیدن به تصمیمات) را نیز انجام می‌دهد.

الگوریتم RF از تعداد زیادی DT ساخته شده است و علت نام‌گذاری آن نیز به همین مسئله برمی‌گردد. در این روش ابتدا چندین زیرمجموعه آموزشی از کل مجموعه آموزشی با استفاده از نمونه‌برداری تصادفی و با جای‌گذاری انتخاب و پس از آن در هر زیرمجموعه آموزشی زیرمجموعه‌ای از ویژگی‌ها با استفاده از یک نمونه‌برداری تصادفی و بدون جای‌گذاری ایجاد و سپس با هریک از زیرمجموعه‌ها یک الگوریتم DT آموزش داده می‌شود. سرانجام، خروجی حاصل از DTها با یک قانون رأی‌گیری حداکثریت (Majority Voting) (MV) با یکدیگر ترکیب می‌شود. این روش کلاسی را انتخاب می‌کند که تمام یا بیشتر طبقه‌بندی‌کننده‌ها روی آن هم‌نظر باشند یا آن کلاس، بیشترین تعداد آرای به‌دست‌آمده از همه طبقه‌بندی‌کننده‌ها را کسب کرده باشد (Mangai et al., 2010). مهم‌ترین پارامترهای الگوریتم RF تعداد درخت‌های به کار رفته ($nTrees$) و تعداد ویژگی‌های انتخاب‌شده در هر زیرمجموعه ($mTry$) است. در پژوهش حاضر پس از سعی و خطا دو پارامتر $nTree$ و $mTry$ به ترتیب برابر با ۱۰۰ و مجذور تعداد ویژگی‌ها ۷ و ۱۶ در نظر گرفته شد.

الگوریتم RoF همانند الگوریتم RF از طبقه‌بندی‌کننده DT به‌عنوان الگوریتم پایه در ساختار خود استفاده می‌کند. ابتدا مجموعه ویژگی‌ها به چند زیرمجموعه ویژگی (K) که اشتراک یا غیراشتراک دارد، تقسیم می‌شود. سپس برای هر زیرمجموعه ویژگی یک نمونه خودرانداز که شامل ۶۰٪ تا ۷۵٪ از تعداد نمونه‌های هر زیرمجموعه است، انتخاب می‌شود. در ادامه، یک روش استخراج ویژگی به نام تجزیه و تحلیل مؤلفه‌های اصلی (PCA) (Principal Component Analysis) روی هر نمونه خودرانداز به کار برده و سپس با استفاده از ضرایب یا مؤلفه‌های PCA یک ماتریس دوران مربعی با ابعاد تعداد ویژگی‌ها ساخته می‌شود. پس از این کار هریک از نمونه‌های آموزشی با ضرب در ماتریس دوران به‌روز و سپس یک مدل از الگوریتم DT با استفاده از هر نمونه آموزشی به‌روز شده، آموزش داده می‌شود. در نهایت، با یک روش رأی‌گیری همچون MV نتایج این m طبقه‌بندی‌کننده با یکدیگر ترکیب می‌شود (Rodriguez et al., 2006). در این پژوهش دو پارامتر K و m به ترتیب برابر با {۷ و ۱۶} و ۱۰۰ در نظر گرفته شد.

روش SVM شامل یافتن ابرصفحه‌ای در فضای ویژگی است که حاشیه بین کلاس‌ها، یعنی فاصله نزدیک‌ترین نقاط داده آموزشی کلاس‌ها را بیشینه می‌کند؛ البته به کمک حقه کرنل SVM به توابع تصمیم غیرخطی نیز قابل تعمیم است. در این حالت الگوریتم به‌جای فضای ویژگی در فضای نگاشت‌یافته کرنل به‌دنبال ابرصفحه جداکننده است. رایج‌ترین کرنل‌های استفاده‌شده در سنجش از دور کرنل تابع چندجمله‌ای و کرنل تابع پایه‌ای شعاعی (RBF) (Radial Basis Function) است. برای کرنل چندجمله‌ای لازم است تا پارامتر درجه (d) و پارامتر گاما و برای کرنل

RBF باید پارامتر گاما (γ) تنظیم شود؛ البته یک پارامتر دیگر به نام پارامتر جریمه (C) باید برای هر دو کرنل از پیش تعیین شود (مؤمنی و همکاران، ۱۳۹۲، ص. ۱۷۶). در پژوهش حاضر از یک کرنل RBF استفاده و سپس به کمک اعتبارسنجی جانبی و در یک جست‌وجوی شبکه‌ای، پارامترهای C و γ بهینه شد. دو مقدار ۱۰,۰۰۰ و ۱,۰۰۰ برای پارامتر C و مقدارهای ۰/۰۰۴ و ۰/۰۰۲ برای پارامتر γ به‌عنوان مقدارهای بهینه انتخاب شد.



شکل ۵: نمای شماتیک الگوریتم انحراف زمانی پویا (منبع: نگارنده ۱۴۰۲)

Figure 5: Schematic diagram of dynamic time warping algorithm.

الگوریتم DTW ابتدا برای تشخیص گفتار توسعه یافت؛ اما بعدها در آنالیز تصاویر سری زمانی نیز معرفی شد. در آنالیز سری زمانی روش DTW مشابهت بین دو دنباله زمانی را که ممکن است سرعت / فرکانس متفاوت داشته باشد، اندازه می‌گیرد (شکل ۲). در واقع، این روش با مقایسه مشابهت بین دو دنباله زمانی و یافتن مسیر بهینه آنها یک معیار عدم تشابه را به دست می‌آورد (Belgiu & Csillik, 2018). در سنجش از دور الگوریتم DTW می‌تواند با اعوجاجات زمانی سروکار داشته باشد و به لطف توانایی ترازکردن پروفیل‌های رادیومتریکی در یک حالت بهینه، پروفیل‌های تغییر شکل یافته و نمونه‌برداری نامنظم را نیز مقایسه کند.

جمع‌آوری داده‌های زمینی

کارشناسان سازمان فضایی ایران طی یک مأموریت نقشه‌برداری زمینی در سال‌های زراعی ۱۳۹۳ تا ۱۳۹۴ با اتکا به اطلاعات مالکان و کشاورزان منطقه مرودشت داده‌های زمینی لازم را از مزارع کشاورزی این منطقه جمع‌آوری کردند. دوایر قرمز رنگ در شکل ۱ مکان این داده‌ها را نشان می‌دهد. مطابق با این اطلاعات در سال زراعی ۹۴-۹۳ محصولات عمده این منطقه شامل یونجه، چغندر قند، جو، گندم، ذرت، برنج، گوجه‌فرنگی و صیفی‌جات است (جدول ۲).

برای طبقه‌بندی محصولات کشاورزی با روش‌های نظارت‌شده، نمونه‌های آموزشی و آزمایشی لازم از داده‌های زمینی انتخاب می‌شود. نمونه‌های آموزشی فقط برای آموزش الگوریتم‌ها و یا به‌نوعی ساختن مدل اولیه طبقه‌بندی‌کننده به کار می‌رود. در مقابل، نمونه‌های آزمایشی برای ارزیابی دقت، صحت، اعتمادپذیری روش‌ها و نتایج حاصل استفاده می‌شود. در پژوهش حاضر ۵۰٪ کل داده‌ها به‌صورت تصادفی چینه‌چینه شده در ده مرتبه به‌عنوان نمونه آموزشی و مابقی به‌عنوان نمونه آزمایشی انتخاب می‌شود. تعداد نمونه‌های آموزشی برای هر کلاس در جدول ۳ آورده شده است.

جدول ۲: مشخصات کلاس‌های محصولات کشاورزی منطقه مطالعاتی: مرودشت

Table 2: Characteristics of crop types in the study area: Marvdasht.

محصول سال ۹۴-۹۳	مختصه N (متر)	مختصه E (متر)	کلاس
یونجه	۳۲۹۹۸۹۵	۶۹۳۵۵۵	۱
جو	۳۳۰۲۰۵۵	۶۷۵۱۶۵	۲
چغندر قند	۳۳۰۳۸۵۵	۶۷۲۹۴۵	۳
چغندر قند	۳۳۰۹۶۱۵	۶۷۳۸۱۵	۴
گندم	۳۳۱۰۰۳۵	۶۶۵۸۰۵	۵
ذرت	۳۳۱۳۹۰۵	۶۷۵۳۱۵	۶
صیفی جات	۳۳۱۴۷۴۵	۶۸۰۴۴۵	۷
گندم	۳۳۱۴۹۵۵	۶۷۹۱۸۵	۸
گندم	۳۳۱۹۱۸۵	۶۸۰۴۷۵	۹
چغندر قند	۳۳۲۱۳۱۵	۶۷۴۳۵۵	۱۰
گوجه‌فرنگی	۳۳۲۹۴۷۵	۶۶۰۰۱۵	۱۱
برنج	۳۳۳۷۸۴۵	۶۵۶۳۸۵	۱۲
برنج	۳۳۴۲۰۴۵	۶۴۰۷۲۵	۱۳

منبع: نگارنده ۱۴۰۲

جدول ۳: تعداد نمونه‌های آموزشی کلاس‌های محصولات کشاورزی منطقه مطالعاتی: مرودشت

Table 3: The number of training samples of crop types in the study area: Marvdasht.

کلاس	یونجه	جو	چغندر قند	گندم	ذرت	صیفی جات	گوجه‌فرنگی	برنج
تعداد کل نمونه‌ها	۲۰۳	۳۰۳	۱۹۰	۱۴۶	۱۰۰	۵۹	۳۹	۵۰۰
تعداد نمونه‌های آموزشی	۱۰۱	۱۵۱	۹۵	۷۳	۵۰	۲۹	۱۹	۲۵۰

منبع: نگارنده ۱۴۰۲

ارزیابی دقت نتایج

برای ارزیابی دقت هر روش برچسب حاصل از آن روش برای نمونه‌های آزمایشی با برچسب واقعی‌شان مقایسه و برای گزارش مقادیر کمی و توصیفی دقت از کمیت‌های استخراج‌شده از ماتریس خطا، یعنی دقت کلی (OA)، ضریب کاپا (kappa) و امتیاز F (F-score) استفاده شد. این کمیت‌ها از روابط

$$OA = \frac{\sum_{i=1}^k n_{ii}}{N} \quad (1)$$

$$Kappa = \frac{n \sum_{i=1}^k n_{ii} - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}}, \quad n_{i+} = \sum_{j=1}^k n_{ij}, \quad n_{+j} = \sum_{i=1}^k n_{ij} \quad (2)$$

$$F\text{-score}_j = 2 \times \frac{PA_j \times UA_j}{PA_j + UA_j}, \quad PA_j = \frac{n_{jj}}{n_{+j}}, \quad UA_i = \frac{n_{ii}}{n_{i+}} \quad (3)$$

قابل محاسبه است که در آن، $n_{ii} \in \{1, 2, 3, \dots, k\}$ تعداد نمونه‌های کلاس i -ام است که به درستی با الگوریتم شناسایی شده، n_{i+} تعداد نمونه‌هایی است که با الگوریتم طبقه‌بندی‌کننده به عنوان کلاس i شناسایی شده، n_{+j} تعداد نمونه‌هایی است که در حقیقت به عنوان کلاس j در داده مرجع وجود دارد و N تعداد کل نمونه‌هاست. در واقع، پارامتر OA نسبت مجموع نمونه‌های درست شناسایی شده به کل نمونه‌هاست. OA یک برآورد کلی از طبقه‌بندی فراهم کرده است؛ زیرا به تنهایی نمی‌تواند ارزیابی منطقی و جامعی از عملکرد، کارایی، اعتماد الگوریتم و نتایج آن را ارائه دهد. معیار Kappa برای تعیین اینکه آیا مقادارها درون یک ماتریس خطا به طور عمده بهتر از مقادارهای درون یک آزمایش تصادفی است یا نه، محاسبه می‌شود. معیار F-score برخلاف OA و Kappa برای هر کلاس محاسبه می‌شود که در واقع، میانگین هارمونیک دقت‌های تولیدکننده (PA) (Producer's Accuracy) و کاربر (UA) (User's Accuracy) آن کلاس است. این کمیت در واقع، یک معیاری از درصد شناسایی مطمئن نمونه‌های یک کلاس ارائه داده است؛ بنابراین ما را از تفسیر کمیت‌های PA و UA برای هر کلاس بی‌نیاز می‌کند. محققان در مطالعات پیشین طبقه‌بندی محصولات کشاورزی اظهار کردند که دقت استاندارد برای استخراج هر محصول کشاورزی برابر با $F\text{-score} > 85\%$ است (خسروی و همکاران، ۱۳۹۷).

یافته‌های پژوهش و تجزیه و تحلیل

شکل‌های ۶ و ۷ نقشه‌های نوع محصول کشاورزی مرودشت را در دو حالت استفاده تنها از سری زمانی شاخص NDVI و استفاده از ترکیب سری زمانی شاخص NDVI و سایر باندهای طیفی نشان می‌دهد. جدول‌های ۴ و ۵ نیز مقادارهای دقت حاصل از این روش‌ها را ارائه می‌دهد. در این جدول‌ها اعداد زیر دقت‌های OA و Kappa بیانگر انحراف معیار آنها در ده مرتبه پیاده‌سازی و اعداد زیر دقت $F\text{-score}$ نمایانگر تعداد پیکسل‌های شناسایی‌شده هر محصول در این منطقه است.

جدول ۴: مقادارهای OA (%) و kappa حاصل از روش‌های طبقه‌بندی مزارع کشاورزی منطقه مطالعاتی: مرودشت اعداد زیر

دقت‌ها بیانگر انحراف معیار این دقت‌ها در ده مرتبه پیاده‌سازی است

Table 4: OA (%) and kappa resulting from the classification methods in the study area: Marvdasht. The numbers below the accuracy values represent the standard deviation of these accuracies over ten implementation instances.

DTW		RF		SVM		RoF		DT		روش‌ها
NDVI	NDVI	NDVI	NDVI	NDVI	NDVI	NDVI	NDVI	NDVI	NDVI	ویژگی‌ها
و باندها	تنها	و باندها	تنها	و باندها	تنها	و باندها	تنها	و باندها	تنها	
۹۶/۳۰	۸۴/۷۲	۹۵/۲۴	۸۵/۹۲	۹۰/۲۰	۸۴/۳۹	۸۸/۴۰	۷۹/۹۶	۸۸/۲۳	۸۱/۲۵	OA
۱/۷۳	۲/۰۱	۱/۲۹	۱/۹۰	۱/۶۱	۲/۰۳	۱/۶۱	۲/۲۲	۲/۳۴	۳/۲۸	(%)
۰/۹۵	۰/۸۲	۰/۹۴	۰/۸۳	۰/۸۸	۰/۸۱	۰/۸۶	۰/۷۷	۰/۸۶	۰/۷۸	Kappa
۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۳	۰/۰۴	

منبع: نگارنده، ۱۴۰۲

جدول ۵: مقدارهای F -score (%) کلاسی حاصل از روش‌های طبقه‌بندی مزارع کشاورزی منطقه مطالعاتی: مرودشت. اعداد زیر

مقدارهای F -score بیانگر تعداد پیکسل‌های شناسایی شده هر محصول است

Table 5: F -score (%) resulting from the classification methods in the study area: Marvdasht. The numbers below the F -score values represent the number of pixels identified for each crop types.

DTW		RF		SVM		RoF		DT		روش‌ها
NDVI و باندها	NDVI تنها	NDVI و باندها	NDVI تنها	NDVI و باندها	NDVI تنها	NDVI و باندها	NDVI تنها	NDVI و باندها	NDVI تنها	ویژگی‌ها
۹۷/۹۷	۹۴/۰۵	۹۶/۷۲	۹۱/۴۹	۹۳/۳۶	۹۲/۰۶	۹۲/۵۰	۹۲/۷۹	۹۶/۵۹	۹۱/۴۶	یونجه
۴۲۰۸۵	۷۴۴۲۵	۱۲۱۷۹۷	۷۴۷۳۳	۷۶۵۰۴	۶۹۷۵۱	۱۳۱۷۰۸	۱۳۸۴۸۹	۸۲۰۰۸	۷۴۴۰۴	
۹۸/۶۸	۹۷/۳۹	۹۷/۸۹	۹۷/۵۶	۹۶/۷۰	۹۴/۲۴	۹۷/۵۹	۹۵/۱۰	۹۷/۲۰	۹۴/۶۴	جو
۱۸۱۹۰۲	۵۵۶۴۹	۱۴۷۸۹۱	۴۷۵۱۲	۳۲۱۶۱	۸۶۹۲۴	۴۹۰۲۸	۸۷۶۲۱	۶۶۰۳۸	۶۸۶۵۱	
۹۴/۰۱	۶۹/۸۵	۹۰/۴۸	۷۲/۱۶	۷۹/۲۴	۶۶/۴۱	۷۹/۱۵	۶۰/۸۰	۷۹/۶۶	۶۴/۶۰	چغندر قند
۵۱۱۴۰۶	۱۲۳۹۵۵۰	۵۴۷۷۰۳	۷۹۲۱۰۲	۸۴۴۲۵۷	۶۰۴۷۹۸	۵۳۷۲۴۳	۶۱۹۵۴۲	۵۹۱۴۸۸	۱۲۴۳۴۸۱	
۹۲/۵۲	۷۵/۰۷	۹۵/۲۵	۷۸/۵۲	۸۲/۶۱	۷۶/۵۹	۸۶/۳۲	۶۶/۲۸	۸۱/۳۰	۶۶/۷۱	گندم
۶۶۷۹۸	۸۶۸۷۶	۷۶۳۲۹	۸۳۷۲۸	۶۴۸۶۵	۹۹۵۸۲	۶۹۰۷۱	۱۰۲۳۳۳	۱۰۳۵۳۴	۹۷۱۴۳	
۹۰/۸۵	۶۵/۶۶	۸۸/۷۲	۷۰/۱۹	۸۳/۰۹	۶۹/۵۵	۷۴/۷۷	۶۷/۲۷	۷۵/۷۶	۶۶/۵۶	ذرت
۱۱۳۸۴۵	۶۰۵۲۴	۱۱۲۰۹۷	۵۵۰۸۱۵	۲۳۵۶۶۶	۱۰۵۸۹۳	۴۲۶۶۸۶	۶۴۳۴۸۶	۷۱۵۸۳۵	۵۶۹۹۴	
۸۸/۱۷	۴۴/۱۶	۸۵/۲۶	۵۱/۳۷	۷۰/۱۸	-	۵۸/۸۷	-	۴۹/۷۲	۴۳/۷۷	صیفی جات
۱۷۴۳۴۰	۳۵۸۶۰	۱۷۶۲۰۳	۵۳۹۵۹	۶۶۰۸۱	۱۲۳۶۰۷	۳۹۱۸۳۱	۳۰۶۵۵	۴۶۳۰۶	۴۴۰۹۹	
۹۰/۶۴	۷۳/۸۱	۸۵/۶۲	۷۹/۴۸	۶۵/۲۸	-	۷۳/۱۵	-	۷۹/۴۸	-	گوجه‌فرنگی
۴۷۴۹۱۷	۸۵۳۹۴	۴۰۱۹۱۳	۳۸۳۱۵	۲۵۴۷۰۶	۴۸۶۸۵۷	۳۰۰۴۳	۱۰۳۰۳	۴۹۰۱۸	۱۵۳۶۵	
۹۸/۳۸	۹۱/۱۵	۹۷/۹۴	۹۱/۵۰	۹۷/۲۲	۹۵/۱۸	۹۲/۷۸	۸۸/۰۶	۹۲/۰۶	۸۹/۸۸	برنج
۱۹۵۵۰۱	۱۲۲۵۱۶	۱۷۶۸۶۱	۱۱۹۶۳۰	۱۸۶۵۵۴	۱۸۳۳۸۲	۱۲۵۱۸۴	۱۲۸۳۶۵	۱۰۶۵۶۷	۱۶۰۶۵۷	

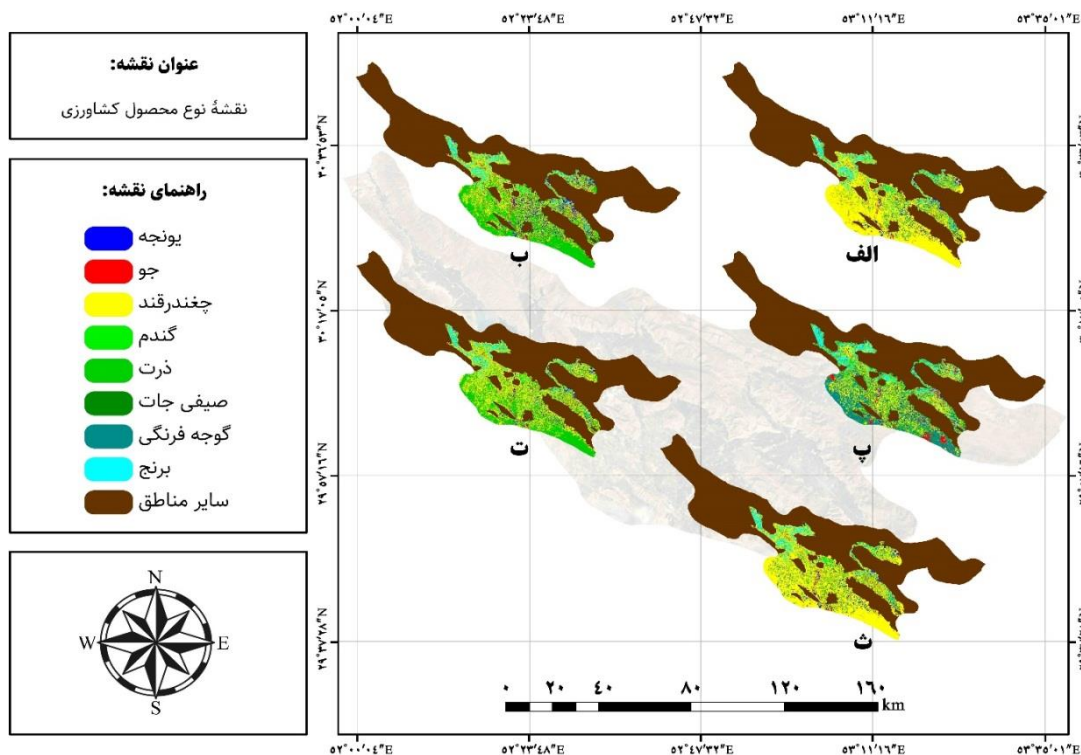
منبع: نگارنده، ۱۴۰۲

در جدول ۴ تنها نتایج حاصل از استفاده از شاخص NDVI برای طبقه‌بندی محصولات کشاورزی آمده است. روش‌های مختلف در این سنجش توانسته‌اند دقت کلی در بازه ۸۰٪ تا ۸۶٪ (معادل کاپا از ۰/۷۷ تا ۰/۸۳) را به دست آورند. بررسی نتایج نشان می‌دهد که روش‌های RF و DTW به ترتیب، بیشترین دقت کلی را کسب کردند. همچنین، این دو روش به لطف کمترین انحراف معیار در مقایسه با سایر روش‌ها ثبات عملکردی بیشتری داشتند. در مقابل، روش RoF کمترین دقت را نسبت به سایر روش‌ها کسب کرده است؛ به گونه‌ای که این روش حتی در شناسایی محصولات صیفی جات و گوجه‌فرنگی نتوانست به عملکرد مطلوب و اطمینان‌بخشی دست یابد (مقدارهای F -score آنها نامعلوم است). علاوه بر این، روش DT با ثبات کمتری نسبت به سایر روش‌ها ظاهر شده است. نکته جالب دیگر درباره روش SVM است که با وجود دقت کلی و ضریب کاپای به نسبت خوب، مشابه روش RoF در شناسایی محصولات صیفی جات و گوجه‌فرنگی عملکرد مناسبی ندارد. به عبارتی دیگر، این دو روش در شناسایی این دسته از محصولات با چالش کارایی و اطمینان‌پذیری مواجه شدند.

در مقابل، دو روش RF و DTW توانسته‌اند محصولات گوجه‌فرنگی را با دقت به نسبت خوبی تشخیص دهند؛ با این حال این دو روش در تشخیص صیفی جات نیز دقت مطلوبی کسب نکرده‌اند. این نتایج نشان می‌دهد که استفاده از شاخص NDVI برای شناسایی محصولات کشاورزی به‌تنهایی ممکن است کافی نباشد؛ بنابراین استفاده از شاخص‌های دیگر طیفی نیز لازم است.

یک نکته مهم دیگر که از [جدول ۵](#) به‌وضوح پدیدار می‌شود، عدم دستیابی هیچ یک از روش‌ها به دقت استاندارد ۸۵٪ در شناسایی محصولات در منطقه مطالعه شده است (جدول ۵). حتی دو روش RF و DTW که مقادیرهای F -score بالاتری در بیشتر محصولات نسبت به سایر روش‌ها داشتند، نتوانستند به این دقت استاندارد برای محصولاتی همچون چغندر قند، گندم، ذرت، صیفی جات و گوجه‌فرنگی دست یابند. این نتایج نشان می‌دهد که برای ایجاد عملکرد مطلوب در طبقه‌بندی محصولات کشاورزی در این منطقه تنها تکیه به شاخص NDVI کافی نیست. با الحاق سری زمانی باندهای طیفی به سری زمانی شاخص NDVI دقت کلی تمامی روش‌ها بهبود یافت و در بازه ۸۸٪ تا ۹۶٪ قرار گرفت (افزایش ۶٪ تا ۱۲٪). بیشترین افزایش دقت به ترتیب متعلق به روش‌های RF و DTW بوده است که هریک با ۱۲٪ و ۱۰٪ افزایش مواجه شدند. همچنین، این دو روش ثبات بیشتری نسبت به دیگر روش‌ها داشتند.

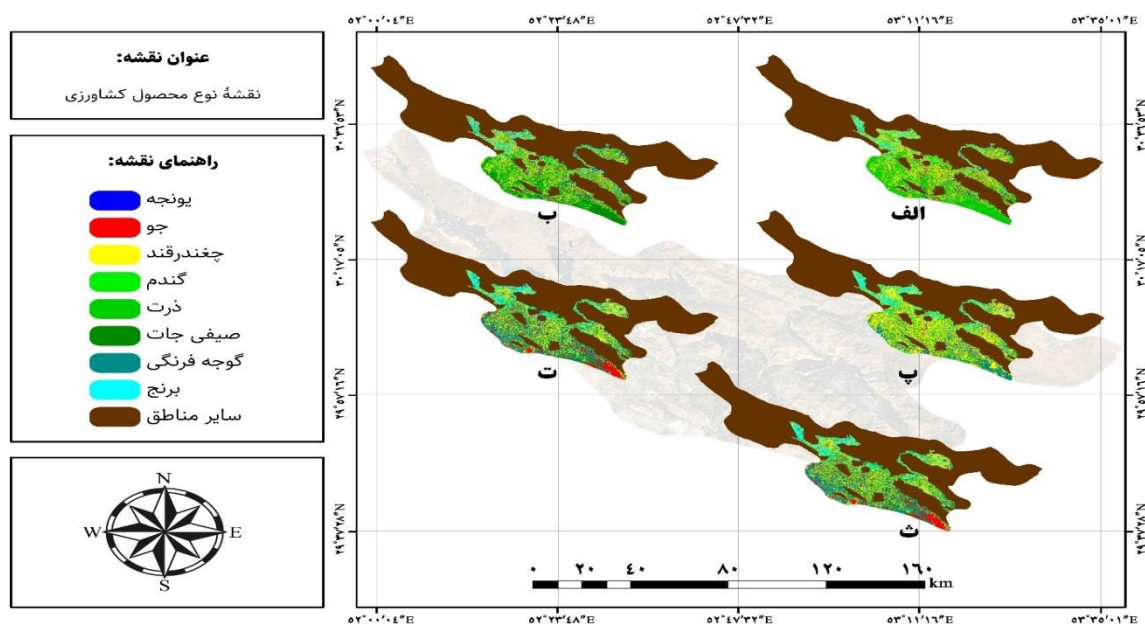
استفاده از باندهای طیفی به‌ویژه به روش‌های DTW، RoF و SVM کمک مضاعفی در شناسایی برخی از محصولات مانند صیفی جات و گوجه‌فرنگی کرد که در مرحله قبل به مشکل برخوردده بودند؛ با این حال روش‌هایی مانند DT و RoF در شناسایی صیفی جات که با داده‌های نامتوازن سروکار دارند، به کارایی مطلوبی دست نیافتند. نکته مهم دیگر این است که با افزودن باندهای طیفی دقت استاندارد ۸۵٪ برای تمام محصولات منطقه مرودشت با دو روش DTW و RF به دست آمد. این دقت بالا می‌تواند به‌عنوان یک نشانه مطمئن‌کننده از کارایی بالا و پذیرفتنی نقشه‌های نوع محصول کشاورزی حاصل از این دو الگوریتم (شکل‌های ۷ ت و ۷ ث) در تشخیص و دسته‌بندی محصولات کشاورزی در این منطقه در سال زراعی ۹۳-۹۴ تلقی شود. این نتایج نه تنها بر اهمیت این الگوریتم‌ها در شناسایی محصولات، به سازمان‌های کشاورزی در برنامه‌ریزی و مدیریت منابع نیز کمک می‌کند.



شکل ۶: نقشه‌های نوع محصول کشاورزی منطقه مطالعاتی حاصل از تنها سری زمانی شاخص NDVI با استفاده از

الگوریتم‌های: الف) DT؛ ب) RoF؛ پ) SVM؛ ت) RF و ث) DTW (منبع: نگارنده، ۱۴۰۲)

Figure 6: Cropland maps of the study area obtained from the only time series of NDVI index using algorithms: a) DT; b) RoF; c) SVM; T) RF and C) DTW.



شکل ۷: نقشه‌های نوع محصول کشاورزی منطقه مطالعاتی حاصل از سری زمانی باندهای ۲ تا ۵ لندست-۸ به همراه شاخص

NDVI با استفاده از الگوریتم‌های: الف) DT؛ ب) RoF؛ پ) SVM؛ ت) RF و ث) DTW (منبع: نگارنده، ۱۴۰۲)

Figure 7: Cropland maps of the study area obtained from the time series of bands 2 to 5 of Landsat-8 along with the NDVI index using algorithms: a) DT; b) RoF; c) SVM; T) RF and C) DTW.

در مقایسه نتایج حاصل از روش‌های این پژوهش با نتایج به‌دست‌آمده در پژوهش‌های گذشته (Belgiu & Csillik, 2018; Khosravi et al., 2018; Denize et al., 2019; Belgiu et al., 2020; Rafif et al., 2021; Singh et al., 2021; Seydi et al., 2022; Tuvdendorj et al., 2022; Yi et al., 2022; Bolaños et al., 2023; Gao et al., 2023; Mao et al., 2023; Mirzaei et al., 2023; Vilela et al., 2023; Xiao et al., 2023) این موضوع به وضوح مشخص بود که روش‌های DTW و RF نه تنها در منطقه مرودشت در منطقه‌های دیگر با مشخصات جغرافیایی متفاوت نیز به دقت بالایی دست یافتند. این نتایج نشان‌دهنده قدرت تعمیم‌پذیری این الگوریتم‌ها به منطقه‌های مختلف و قابلیت ارائه نتایج دقیق در شرایط مختلف جغرافیایی است. تفسیر این مقایسه نشان می‌دهد که الگوریتم‌های استفاده‌شده در این پژوهش از نظر دقت و کارایی سازگاری کاملی با نتایج پژوهش‌های گذشته دارند. این امر نه تنها نتیجه‌گیری‌های این پژوهش را تقویت می‌کند، به اعتبار و قابلیت اعتماد بیشتر به این الگوریتم‌ها در سیاق گسترده‌تری اشاره دارد. همچنین، به ما امکان می‌دهد که با اطمینان بیشتری به نتایج به‌دست‌آمده از این پژوهش‌ها در کاربردهای عملی و برنامه‌ریزی کشاورزی در منطقه‌های مختلف اعتماد کنیم.

نتایج برآورد می‌کند که در این سال زراعی، محصولات چغندر قند و گوجه‌فرنگی هر یک بیش از ۴۰ هزار هکتار سطح زیرکشت و پس از آن، جو، ذرت، صیفی‌جات و برنج نیز بیش از ۱۵ هزار هکتار سطح زیرکشت در مرودشت داشته است. این آمار با آمارنامه‌های حاصل از جهاد کشاورزی در تطابق نسبی بود.

نتیجه‌گیری

در پژوهش حاضر نقشه نوع محصول کشاورزی دشت مرودشت در استان فارس در سال زراعی ۹۳-۹۴ با استفاده از تصاویر ماهواره‌ای لندست-۸ تهیه و از سری زمانی ۸ روزه باندهای طیفی ۲ تا ۵ و شاخص NDVI در تحلیل داده‌ها استفاده شد. در این منطقه محصولات زراعی متنوعی از جمله یونجه، جو، گندم، ذرت، چغندر قند، گوجه‌فرنگی، برنج، و صیفی‌جات تولید می‌شد. برای طبقه‌بندی این مزارع از روش‌های یادگیری ماشین کارا همچون الگوریتم‌های درخت تصمیم (DT)، جنگل تصادفی (RF)، جنگل دورانی (RoF)، ماشین بردار پشتیبان (SVM) و آنالیز انحراف زمانی پویا (DTW) به‌کار گرفته شد.

نتایج حاصل از پیاده‌سازی این الگوریتم‌ها به شرح زیر است.

- الگوریتم‌های DTW و RF نسبت به سایر روش‌ها به‌خوبی محصولات کشاورزی این منطقه را شناسایی کردند؛
- تنها دو الگوریتم DTW و RF توانستند با دقت استاندارد ۸۵٪ تمام محصولات از جمله صیفی‌جات و گوجه‌فرنگی را که داده‌های نامتوازی داشتند با کارایی بالا طبقه‌بندی کنند؛
- این موضوع که با نتایج پژوهش‌های گذشته در سازگاری بود، نشان داد که تنها نقشه‌های حاصل از این دو الگوریتم برای سازمان‌های کشاورزی مطمئن است؛
- الگوریتم‌های DT و RoF چندان عملکرد خوبی از خود نشان ندادند و دقت کلی آنها پایین بود. ضمن آنکه در شناسایی برخی محصولات به‌طور کلی ناتوان بودند؛
- استفاده تنها از شاخص NDVI قابلیت و کارایی لازم را برای شناسایی محصولات این منطقه نداشت؛
- حصول نقشه دقیق‌تر از نوع محصول کشاورزی منطقه مطالعاتی منوط به استفاده از ویژگی‌های اضافه‌تری همچون باندهای طیفی بود؛

محدودیت و مشکلاتی که در پیاده‌سازی روش پژوهش‌های مقاله وجود داشت عبارت بود از:

- اولین مشکل به عدم اطمینان‌پذیری کامل داده‌های زمینی تهیه‌شده از این منطقه مرتبط بود. این اطلاعات بیشتر براساس اظهارنظرهای مالکان و کشاورزان منطقه جمع‌آوری شده بود که اطمینان بیشتری از دقت و صحت این اطلاعات را فراهم نمی‌کرد. انحراف معیار و میانگین بین کلاس‌ها نیز نشان از آمیختگی کلاس‌های محصولات داشت.
- دومین مشکل و محدودیت به حجم فراوان اطلاعاتی از منطقه مطالعاتی برمی‌گشت که با وجود کارایی زیاد آن منجر به زمان‌بر شدن اجرای روش انحراف زمانی پویای آن شد؛

نتایج پژوهش حاضر نه تنها برای پژوهش‌های آینده در زمینه تهیه نقشه نوع محصول کشاورزی، برای متخصصان، سیاست‌گذاران و تصمیم‌گیران در حوزه کشاورزی نیز اهمیت دارد. توصیه می‌شود تا از نتایج این مطالعه در فرآیندهای تصمیم‌گیری مرتبط با کشاورزی، همچون برنامه‌ریزی منطقه‌ای، مدیریت آب و پیش‌بینی تولید محصولات کشاورزی استفاده شود. علاوه بر این، برای پژوهش‌های آینده بهبود دقت و قابلیت پیش‌بینی در تهیه نقشه نوع محصولات، توسعه رویکردهای تحلیل داده، استفاده از داده‌های ماهواره‌های نوری جدید لندست-۹ و سنتینل-۲، استفاده از داده‌های ماهواره‌های راداری رایگان مثل سنتینل-۱ و ادغام این داده‌ها با یکدیگر پیشنهاد می‌شود. در نهایت، پژوهش‌های بیشتر در زمینه بهینه‌سازی الگوریتم‌های یادگیری ماشین همچون الگوریتم DTW براساس ویژگی‌های خاص منطقه‌های جغرافیایی می‌تواند در توسعه روش‌های کارآمدتر تأثیرگذار باشد.

منابع

- خسروی، ایمان، موسوی، میرمجید، و امینی، جلال (۱۳۹۴). ارائه یک روش انتخاب ویژگی بر مبنای الگوریتم ژنتیک و درخت تصمیم برای طبقه‌بندی تصاویر تمام پلاریمتریک راداری. *نشریه علمی پژوهشی مهندسی فناوری اطلاعات مکانی*، ۳(۲)، ۷۵-۸۸. [10.29252/jgit.3.2.75](https://doi.org/10.29252/jgit.3.2.75)
- مؤمنی، مهدی، خسروی، ایمان، و مستأجران، بهنوش (۱۳۹۲). شیء‌گرایی در پردازش تصاویر سنجش از دور. انتشارات دانشگاه اصفهان.
- خسروی، ایمان، صفری، عبدالرضا، و همایونی، سعید (۱۳۹۷). سیستم‌های طبقه‌بندی‌کننده چندگانه نوین درختی به منظور طبقه‌بندی زمین‌های کشاورزی از تصاویر نوری و راداری تمام‌قطبیده. *نشریه علمی پژوهشی علوم و فنون نقشه‌برداری*، ۸(۲)، ۱۳-۳۴. <http://jgst.issgeac.ir/article-1-716-fa.html>

References

- Belgiu, M., & Csillik, O. (2018). Sentinel-2 cropland mapping using pixel-based and object-based time-weighted dynamic time warping analysis. *Remote Sensing of Environment*, 204, 509-523. <https://doi.org/10.1016/j.rse.2017.10.005>
- Belgiu, M., Zhou, Y., Marshall, M., & Stein, A. (2020). Dynamic time warping for crops mapping. *The International Archives of The Photogrammetry, Remote Sensing And Spatial Information Sciences*, 43, 947-951. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2020-947-2020>
- Bolaños, J., Corrales, J.C., & Campo, L.V. (2023). Feasibility of early yield prediction per coffee tree based on multispectral aerial imagery: Case of arabica coffee crops in Cauca-Colombia. *Remote Sensing*, 15(1), 282. <https://doi.org/10.3390/rs15010282>

- Chellasamy, M., Zielinski, R. T., & Greve, M. H. (2014). A multievidence approach for crop discrimination using multitemporal worldview-2 imagery. *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*, 7(8), 3491-3501. <https://doi.org/10.1109/JSTARS.2014.2349945>
- Chen, P. C., Chiang, Y. C., & Weng, P. Y. (2020). Imaging using unmanned aerial vehicles for agriculture land use classification. *Agriculture*, 10(9), 416. <https://doi.org/10.3390/agriculture10090416>
- Denize, J., Hubert-Moy, L., Betbeder, J., Corgne, S., Baudry, J., & Pottier, E. (2019). Evaluation of using sentinel-1 and-2 time-series to identify winter land use in agricultural landscapes. *Remote Sensing*, 11(1), 37. <https://doi.org/10.3390/rs11010037>
- Du, M., Huang, J., Wei, P., Yang, L., Chai, D., Peng, D., Sha, J., Sun, W., & Huang, R. (2022). Dynamic mapping of paddy rice using multi-temporal landsat data based on a deep semantic segmentation model. *Agronomy*, 12(7), 1583. <https://doi.org/10.3390/agronomy12071583>
- Du, P., Xia, J., Zhang, W., Tan, K., Liu, Y., & Liu, S. (2012). Multiple classifier system for remote sensing image classification: A review. *Sensors*, 12(4), 4764-4792. <https://doi.org/10.3390/s120404764>
- Fieuzal, R., Bustillo, V., Collado, D., & Dedieu, G. (2020). Combined use of multi-temporal Landsat-8 and sentinel-2 images for wheat yield estimates at the intra-plot spatial scale. *Agronomy*, 10(3), 327. <https://doi.org/10.3390/agronomy10030327>
- Gao, C., Ji, X., He, Q., Gong, Z., Sun, H., Wen, T., & Guo, W. (2023). Monitoring of wheat fusarium head blight on spectral and textural analysis of UAV multispectral imagery. *Agriculture*, 13(2), 293. <https://doi.org/10.3390/agriculture13020293>
- Ghorbanpour, A.K., Kisekka, I., Afshar, A., Hessels, T., Taraghi, M., Hessari, B., Tourian, M.J., & Duan, Z. (2022). Crop water productivity mapping and benchmarking using remote sensing and google earth engine cloud computing. *Remote Sensing*, 14(19), 4934. <https://doi.org/10.3390/rs14194934>
- Guo, Y., Xia, H., Zhao, X., Qiao, L., & Qin, Y. (2022). Estimate the earliest phenophase for garlic mapping using time series Landsat 8/9 images. *Remote Sensing*, 14(18), 4476. <https://doi.org/10.3390/rs14184476>
- Ioannidou, M., Koukos, A., Sitokonstantinou, V., Papoutsis, I., & Kontoes, C. (2022). Assessing the added value of sentinel-1 PolSAR data for crop classification. *Remote Sensing*, 14(22), 5739. <https://doi.org/10.3390/rs14225739>
- Khosravi, I., & Alavipanah, S. K. (2019). A random forest-based framework for crop mapping using temporal, spectral textural and polarimetric observations. *International Journal of Remote Sensing*, 40(18), 7221-7251. <https://doi.org/10.1080/01431161.2019.1601285>
- Khosravi, I., Mousavi, M. M., & Amini, J. (2015). Presenting a feature selection method based on genetic algorithm and decision tree for classifying fully polarimetric SAR images. *Engineering Journal of Geospatial Information Technology*, 3(2), 75-88 [10.29252/jgit.3.2.75](https://doi.org/10.29252/jgit.3.2.75) [In Persian].
- Khosravi, I., Razoumny, Y., Hatami Afkoeieh, J., & Alavipanah, S. K. (2021). Fully polarimetric synthetic aperture radar data classification using probabilistic and non-probabilistic kernel methods. *European Journal of Remote Sensing*, 54(1), 310-317. <https://doi.org/10.1080/22797254.2021.1924081>
- Khosravi, I., Safari, A., & Homayouni, S. (2018). Enhanced tree-based multiple classifier systems for cropland classification from optical and full-polarimetric radar images. *Journal Of Geomatics Science and Technology*, 8(2), 13-34 <http://jgst.issgeac.ir/article-1-716-fa.html> [In Persian].
- Khosravi, I., Safari, A., & Homayouni, S. (2018). MSMD: Maximum separability and minimum dependency feature selection for cropland classification from optical and radar data. *International Journal Of Remote Sensing*, 39(8), 2159-2176. <https://doi.org/10.1080/01431161.2018.1425564>

- Li, F., Miao, Y., Chen, X., Sun, Z., Stueve, K., & Yuan, F. (2022). In-season prediction of corn grain yield through PlanetScope and Sentinel-2 images. *Agronomy*, *12*(12), 3176. <https://doi.org/10.3390/agronomy12123176>
- López-Andreu, F.J., Erena, M., Dominguez-Gómez, J.A., & López-Morales, J.A. (2021). Sentinel-2 images and machine learning, as tool for monitoring of the common agricultural policy: Calasparra rice as a case study. *Agronomy*, *11*(4), 621. <https://doi.org/10.3390/agronomy11040621>
- Lu, M., Bi, Y., Xue, B., Hu, Q., Zhang, M., Wei, Y., Yang, P., & Wu, W. (2022). Genetic programming for high-level feature learning in crop classification. *Remote Sensing*, *14*(16), 3982. <https://doi.org/10.3390/rs14163982>
- Lv, Y., Zhang, C., Yun, W., Gao, L., Wang, H., Ma, J., Li, H., & Zhu, D. (2020) The delineation and grading of actual crop production units in modern smallholder areas using RS Data and Mask R-CNN. *Remote Sensing*, *12*(7), 1074. <https://doi.org/10.3390/rs12071074>
- Mangai, U. G., Samanta, S., Das, S., & Chowdhury, P. R. (2010). A survey of decision fusion and feature fusion strategies for pattern classification. *IETE Technical Review*, *27*(4), 293-307. <https://doi.org/10.4103/0256-4602.64604>
- Mao, M., Zhao, H., Tang, G., & Ren, J. (2023). In-season crop type detection by combing sentinel-1a and sentinel-2 imagery based on the CNN model. *Agronomy*, *13*(7), 1723. <https://doi.org/10.3390/agronomy13071723>
- Mirzaei, A., Bagheri, H., & Khosravi, I. (2023). Enhancing crop classification accuracy through synthetic SAR-optical data generation using deep learning. *ISPRS International Journal Of Geo-Information*, *12*(11), 450. <https://doi.org/10.3390/ijgi12110450>
- Momeni, M., Khosravi, A., & Mostajran, B. (2012). *Object orientation in remote sensing image processing*. University of Isfahan Press. [In Persian].
- Nguyen, M. D., Baez-Villanueva, O. M., Bui, D. D., Nguyen, P. T., & Ribbe, L. (2020). Harmonization of Landsat and sentinel 2 for crop monitoring in drought prone areas: Case studies of Ninh Thuan (Vietnam) and Bekaa (Lebanon). *Remote Sensing*, *12*(2), 281. <https://doi.org/10.3390/rs12020281>
- Peña-Barragán, J. M., Ngugi, M. K., Plant, R. E., & Six, J. (2011). Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sensing of Environment*, *115*(6), 1301-1316. <https://doi.org/10.1016/j.rse.2011.01.009>
- Qiu, S., Zhu, Z., & He, B. (2019). Fmask 4.0: Improved cloud and cloud shadow detection in Landsats 4–8 and sentinel-2 imagery. *Remote Sensing Of Environment*, *231*, 111205. <https://doi.org/10.1016/j.rse.2019.05.024>
- Rafif, R., Kusuma, S. S., Saringatin, S., Nanda, G. I., Wicaksono, P., & Arjasakusuma, S. (2021). Crop intensity mapping using dynamic time warping and machine learning from multi-temporal PlanetScope data. *Land*, *10*(12), 1384. <https://doi.org/10.3390/land10121384>
- Rodriguez, J. J., Kuncheva, L. I., & Alonso, C. J. (2006). Rotation forest: A new classifier ensemble method. *IEEE Transactions on Pattern Analysis And Machine Intelligence*, *28*(10), 1619-1630. <https://doi.org/10.1109/TPAMI.2006.211>
- Seydi, S.T., Amani, M., & Ghorbanian, A. (2022). A dual attention convolutional neural network for crop classification using time-series Sentinel-2 imagery. *Remote Sensing* 2022, *14*(3), 498. <https://doi.org/10.3390/rs14030498>
- Shen, Y., Zhang, J., Yang, L., Zhou, X., Li, H., & Zhou, X. (2022). A novel operational rice mapping method based on multi-source satellite images and object-oriented classification. *Agronomy*, *12*(12), 3010. <https://doi.org/10.3390/agronomy12123010>
- Singh, R. K., Rizvi, J., Behera, M. D., & Biradar, C. (2021). Automated crop type mapping using time-weighted dynamic time warping-A basis to derive inputs for enhanced food and nutritional security. *Current Research In Environmental Sustainability*, *3*, 100032. <https://doi.org/10.1016/j.crsust.2021.100032>

- Tuvdendorj, B., Zeng, H., Wu, B., Elnashar, A., Zhang, M., Tian, F., Nabil, M., Nanzad, L., Bulkhbai, A., & Natsagdorj, N. (2022). Performance and the optimal integration of sentinel-1/2 time-series features for crop classification in northern mongolia. *Remote Sensing*, 14(8), 1830. <https://doi.org/10.3390/rs14081830>
- Vilela, E.F., Ferreira, W.P.M., Castro, G.D.M. D., Faria, A.L.R. D., Leite, D.H., Lima, I.A., Matos, C. D. S.M. D., Silva, R.A., & Venzon, M. (2023). New spectral index and machine learning models for detecting coffee leaf miner infestation using sentinel-2 multispectral imagery. *Agriculture*, 13(2), 388. <https://doi.org/10.3390/agriculture13020388>
- Wei, J., Cui, Y., Luo, W., & Luo, Y. (2022). Mapping paddy rice distribution and cropping intensity in China from 2014 to 2019 with Landsat images effective flood signals and Google Earth engine. *Remote Sensing*, 14(3), 759. <https://doi.org/10.3390/rs14030759>
- Wu, Y., Wu, Y., Wang, B., & Yang, H. (2023). A remote sensing method for crop mapping based on multiscale neighborhood feature extraction. *Remote Sensing*, 15(1), 47. <https://doi.org/10.3390/rs15010047>
- Xiao, X., Jiang, L., Liu, Y., & Ren, G. (2023). Limited-samples-based crop classification using a time-weighted dynamic time warping method sentinel-1 imagery and Google Earth engine. *Remote Sensing*, 15(4), 1112. <https://doi.org/10.3390/rs15041112>
- Yi, Z., Jia, L., Chen, Q., Jiang, M., Zhou, D., & Zeng, Y. (2022). Early-season crop identification in the Shiyang river basin using a deep learning algorithm and time-series sentinel-2 data. *Remote Sensing*, 14(21), 5625. <https://doi.org/10.3390/rs14215625>
- Zhang, H., He, B., & Xing, J. (2022). Mapping paddy rice in complex landscapes with Landsat time series data and superpixel-based deep learning method. *Remote Sensing*, 14(15), 3721. <https://doi.org/10.3390/rs14153721>
- Zhu, L., Radeloff, V. C., & Ives, A. R. (2017). Improving the mapping of crop types in the midwestern US by fusing Landsat and MODIS satellite data. *International Journal Of Applied Earth Observation And Geoinformation*, 58, 1-11. <https://doi.org/10.1016/j.jag.2017.01.012>

