

Combination of Semi-Empirical Radar Remote Sensing Models for Soil Moisture Retrieval During the Plant Growing Season Based on Machine Learning

A. Sedighi¹, S. Hamzeh^{2*}, S.K. Alavipanah³, A.A. Naseri⁴, and J. Mohammadi Moalezade⁵

Abstract

Soil moisture is one of the most important environmental parameters for water resources management and irrigation planning in agricultural areas. In agricultural areas, most soil moisture retrieval models are unstable in terms of their accuracy and performance during crop growth season. As a result, there is no consensus on which model performs optimally during the agricultural season. This is because of the uncertainties associated with model physics, initial assumptions, input data, vegetation attenuation and soil characteristics. To better deal with these practical concerns, in this research, a simple but effective soil moisture retrieval method has been introduced using a combination of multiple models based on machine learning. Firstly, the semi-empirical water cloud model (WCM) with different vegetation descriptors was calibrated and validated in sugarcane fields for Sentinel-1 backscattering coefficients (VV and VH). For this purpose, soil moisture measurements of sugarcane fields (400 samples in total) during the plant growing season in 2020 were used. The optimization of calculations was done using the generalized regression neural network (GRNN). The results showed that WCM_{NDWI} retrieves soil moisture more accurately than other models in the early stages of sugarcane growth, while WCM_{VWC} and WCM_{LAI} were more accurate in late sugarcane growth stages. The machine learning method by combining models can make full use of the different advantages they offer. Time-series soil moisture retrieval accuracy using the combined method based on GRNN was higher than that of single WCM models. According to the results of the in situ validation for sugarcane fields, with the optimal combination of models, the minimum mean absolute error (MAE) was less than 0.02 m³m⁻³, the root mean square error (RMSE) was approximately 0.085 m³m⁻³, and the Pearson's correlation coefficient (R) was equal to 0.7 for the sugarcane growing season. The findings showed that the proposed method provides a way to select an optimal model for retrieving time-series soil moisture during the plant growth season.

Keywords: Soil Moisture, Irrigation Management, WCM Model, Machine Learning, Remote Sensing.

Received: February 13, 2024

Accepted: May 10, 2024

ت ترکیب مدل‌های نیمه تجربی سنجش از دور راداری برای بازیابی رطوبت خاک در فصل رشد گیاه مبتنی بر یادگیری ماشین

امیر صدیقی^۱، سعید حمزه^{۲*}، سید کاظم علوی پناه^۳، عبدعلی ناصری^۴ و جمال محمدی معله‌زاده^۵

چکیده

رطوبت خاک یکی از مهمترین پارامترهای محیطی جهت مدیریت منابع آب و برنامه‌ریزی آبیاری در اراضی کشاورزی است. در اراضی کشاورزی، اکثر مدل‌های بازیابی رطوبت خاک از نظر دقت و عملکرد طی فصل رشد گیاه ناپایدار هستند. در نتیجه، هیچ اتفاق نظری در مورد اینکه کدام مدل طی فصل کشاورزی عملکرد بهینه دارد، وجود ندارد. این به دلیل عدم قطعیت‌های مرتبط با فیزیک مدل، مفروضات اولیه، داده‌های ورودی، اثرات تضعیف پوشش گیاهی و ویژگی‌های گوناگون خاک است. برای رفع این نگرانی‌های عملی، در این تحقیق یک روش ساده، اما مؤثر برای بازیابی رطوبت خاک با استفاده از ترکیب مدل‌های متعدد مبتنی بر یادگیری ماشین معرفی شده است. در گام اول، مدل نیمه تجربی ابر آب (WCM) با توصیف‌گرهای پوشش گیاهی مختلف در مزارع نیشکر برای ضرایب بازپراکنش Sentinel-1 (VH و VV) کالیبره و اعتبارسنجی شد. بدین منظور از داده‌های اندازه‌گیری شده رطوبت خاک مزارع نیشکر (در مجموع ۴۰۰ نمونه) طی فصل رشد گیاه در سال ۲۰۲۰ استفاده شد. سپس بهینه‌سازی محاسبات با استفاده از شبکه عصبی رگرسیون تعمیم یافته (GRNN) انجام گردید. نتایج نشان داد که WCM_{NDWI} دقیق‌تر از سایر مدل‌ها در مراحل اولیه رشد نیشکر رطوبت خاک را بازیابی می‌کند، در حالی که WCM_{LAI} و WCM_{VWC} در اواخر فصل رشد نیشکر از دقت بیشتری برخوردار بودند. روش یادگیری ماشین با ترکیب مدل‌ها می‌تواند از مزایای متفاوتی که ارائه می‌کنند، استفاده می‌کند. دقت بازیابی سری زمانی رطوبت خاک با استفاده از روش ترکیبی مبتنی بر GRNN بیشتر از مدل‌های تکی WCM است. با توجه به نتایج اعتبارسنجی میدانی برای مزارع نیشکر، با ترکیب بهینه مدل‌ها حداقل میانگین خطای مطلق (MAE) کمتر از ۰/۰۲ m³m⁻³، میانگین خطا جذر میانگین مربعات RMSE تقریباً ۰/۰۸۵ m³m⁻³ و ضریب همبستگی پیرسون (R) برابر با ۰/۷ برای فصل رشد نیشکر حاصل گشت. یافته‌ها نشان می‌دهد روش پیشنهادی راهی برای انتخاب یک مدل بهینه برای بازیابی سری زمانی رطوبت خاک طی فصل رشد گیاه فراهم می‌کند.

کلمات کلیدی: رطوبت خاک، برنامه‌ریزی آبیاری، مدل WCM، یادگیری ماشین، سنجش از دور.

تاریخ دریافت مقاله: ۱۴۰۲/۱۱/۲۴

تاریخ پذیرش مقاله: ۱۴۰۳/۲/۲۱

1- Ph.D. Student of Remote Sensing & GIS, Department of Remote Sensing & GIS, Faculty of Geography, University of Tehran, Tehran, Iran. Email: amir.sedighi@ut.ac.ir

2- Associate Professor, Department of Remote sensing & GIS, Faculty of Geography, University of Tehran, Tehran, Iran. Email: saeid.hamzeh@ut.ac.ir

3- Professor, Department of Remote Sensing & GIS, Faculty of Geography, University of Tehran, Tehran, Iran. Email: salavipa@ut.ac.ir

4- Professor, Department of Irrigation and Drainage, Faculty of Water Sciences Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran. Email: abdalinaseri@scu.ac.ir

5- Head of Department of Remote Sensing and GIS, Research and Training Institute of Sugarcane & By-Products Development Company of Khuzestan Province, Khuzestan, Iran. Email: jamalmohammadi611@gmail.com

*. Corresponding Author

Doi: [10.22034/IWRR.2024.443011.2742](https://doi.org/10.22034/IWRR.2024.443011.2742)

۱- دانشجوی دکتری سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران.

۲- دانشیار گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران.

۳- استاد گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده جغرافیا، دانشگاه تهران، تهران، ایران.

۴- استادیار گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.

۵- رئیس اداره سنجش از دور و سیستم اطلاعات جغرافیایی، مؤسسه تحقیقات و آموزش توسعه نیشکر و صنایع جانبی استان خوزستان، خوزستان، ایران.

*- نویسنده مسئول
بحث و مناظره (Discussion) در مورد این مقاله تا پایان تابستان ۱۴۰۳ امکانپذیر است.



۱- مقدمه

قدرت تفکیک مکانی خوب (کمتر از ۱۰۰ متر مربع)، سری زمانی داده‌ها (دوره بازدید مجدد هفتگی و یا کمتر) و دقت مطلوب (ubRMSE کمتر از $0.4 \text{ m}^3 \text{ m}^{-3}$) است (Li et al., 2021; Peng et al., 2021).

با بکارگیری داده‌های مایکروویو فعال (مانند سنجنده‌های رادار دیافراگم مصنوعی (SAR)، سری زمانی رطوبت خاک را می‌توان تحت همه شرایط آب و هوایی با تفکیک مکانی خوب، که برای کاربردهای میدانی ایده‌آل است، بازیابی نمود (Zeyliger et al., 2022). با این حال، زبری سطح خاک و پوشش گیاهی بر سیگنال‌های فعال تأثیر می‌گذارد (Moran et al., 2004). در نتیجه پرتاب مجموعه ماهواره‌های سنتینل (S-1 A&B and S-2 A&B) بازیابی رطوبت خاک با قدرت تفکیک مناسب در مناطق کشاورزی امکان‌پذیر شده است. با استفاده از مدل‌های فیزیکی، تجربی و نیمه تجربی، ضرایب بازپراکنش برگشتی SAR با محتوای رطوبت خاک در سطوحی که بایر یا با پوشش گیاهی کم هستند، مرتبط می‌شوند (Li et al., 2021). کارکرد اکثر مدل‌های فوق در خاک‌های بایر است. تا آنجا که به کاربردهای کشاورزی مربوط می‌شود، اکثر سطوح توسط مقادیری از پوشش گیاهی پوشیده شده است. ویژگی‌های دی الکتریک و همچنین ساختار پوشش گیاهی، نقش مهمی در کاهش یا تأثیر بر ضرایب بازپراکنش SAR ایفا می‌کنند (Ulaby et al., 1982). با این حال، رطوبت خاک زیر یک تاج پوشش گیاهی را می‌توان با تلفیق یک مدل بازپراکنش پوشش گیاهی با یک مدل بازپراکنش خاک بازیابی کرد. این روش برای چندین محصول کشاورزی اجرا شده است (Balenzano et al., 2011; Wu et al., 2020). مدل‌های بازپراکنش پوشش گیاهی مانند مدل ابر آب^۲ (WCM) و مدل بازپراکنش سایه‌بان مایکروویو میشیگان^۳ (MIMICS) استفاده می‌شوند. در مطالعات متعددی گزارش شده است که هم‌افزایی بین داده‌های مرئی و SAR به ویژه برای جداسازی زبری سطح و اثرات زیست توده گیاهی بر روی ضرایب بازپراکنش SAR مفید و سبب بهبود بازیابی رطوبت خاک می‌شود (Das et al., 2023; Madelon et al., 2023; Wang et al., 2020).

بازیابی پارامترهای خاک به طور قابل توجهی نسبت به مدل‌های سنتی در چند سال اخیر بهبود یافته است؛ زیرا روش‌های یادگیری ماشین به‌ویژه زمانی مفید هستند که حل مسئله با مدل‌های فیزیکی بسیار پیچیده است (مانند فرایند معکوس‌سازی، روابط غیرخطی و غیرقابل تعمیم‌پذیر) (Ge et al., 2018; Leng et al., 2023; Zhang et al., 2022). به عنوان مثال، Ezzahar et al. (2023) به ارزیابی اثربخشی

رطوبت خاک یکی از مهم‌ترین پارامترهای زیست محیطی جهت مدیریت منابع آب و برنامه‌ریزی آبیاری در اراضی کشاورزی است (Khazaei et al., 2023; Moalezade et al., 2022). پایش رطوبت سطحی خاک در مناطق مختلف یک مسئله چالش‌برانگیز است، هر چند پیشرفت‌های قابل توجهی در روش‌شناسی طی چندین دهه اخیر صورت گرفته است که منجر به تعداد زیادی کاربردهای عملیاتی شده‌اند. ایستگاه‌های اندازه‌گیری یا مشاهدات میدانی به طور سنتی برای نظارت بر رطوبت خاک استفاده می‌شوند. با این وجود، تعداد داده‌های نقطه‌ای ارائه شده به طور کلی محدود است. داده‌های سنجش از دور ماهواره‌ای مزایایی مانند پوشش وسیع، هزینه کم و راندمان مطلوب را ارائه می‌دهند که آنها را به ویژه برای دستیابی به سری زمانی رطوبت خاک بسیار مفید می‌کند (Fatholouloumi et al., 2020; Liu et al., 2019). اطلاعات دقیق رطوبت خاک نقش مهمی در کاربردهای کشاورزی مانند برنامه‌ریزی آبیاری (Leghayat et al., 2023)، شناسایی میزان تقاضای آب محصول (Singh and Champagne et al., 2022)، پیش‌بینی عملکرد محصول (Martínez-Fernández et al., 2019) و نظارت بر خشکسالی (2016) ایفا می‌کند.

در طی چند دهه گذشته، پیشرفت‌های تکنولوژیکی در سنجش از دور، برآورد و پایش مکانی سری زمانی رطوبت خاک را از داده‌های مرئی، مادون قرمز حرارتی، و مایکروویو (غیرفعال و فعال) را امکان‌پذیر نموده است (Petropoulos et al., 2015; Zhang and Zhou, 2016). اخیراً، رویکردها و مدل‌های جدیدی برای بازیابی رطوبت خاک با استفاده از هم‌افزایی بین داده‌های مختلف (به عنوان مثال داده‌های مرئی/حرارتی، داده‌های مایکروویو فعال/غیرفعال (رادومتر)، و داده‌های مایکروویو با داده‌های مرئی) توسعه داده شده‌اند. این رویکردها برای استفاده از قابلیت مکمل و جایگزینی بین انواع مختلف داده‌های سنجش از دور ایجاد شده‌اند. اگرچه داده‌های مایکروویو غیرفعال و حرارتی برای ارائه اطلاعات رطوبت خاک در مقیاس منطقه‌ای و جهانی مفید هستند، به ترتیب قدرت تفکیک مکانی و زمانی پایین آنها از ارائه داده برای بازیابی سری زمانی رطوبت خاک در مناطق کشاورزی جلوگیری می‌کند. در مقابل، داده‌های مرئی و مایکروویو فعال به طور گسترده در مناطق کشاورزی با زمان‌های بازدید مجدد بالا برای دستیابی به اطلاعات رطوبت خاک در قدرت تفکیک مکانی مناسب استفاده می‌شوند (Ebrahimi-Khusfi et al., 2018; Khazaei et al., 2023; Li et al., 2021). در حال حاضر، نیازهای خاص برنامه‌های کشاورزی شامل پوشش کامل منطقه جغرافیایی،

الگوریتم‌های یادگیری ماشین شامل شبکه عصبی مصنوعی^۴ (ANN)، شبکه عصبی عمیق، سه مدل از رگرسیون بردار پشتیبان^۵ (SVR)، الگوریتم جنگل تصادفی^۶ (RF) و الگوریتم تقویت گرادیان^۷ (XGBoost) و مدل‌های نیمه‌تجربی برای بازیابی رطوبت خاک با استفاده از داده‌های Sentinel-1 در مزارع گندم دیم و آبی واقع در مراکش و تونس پرداختند. بهترین نتایج بازیابی با بکارگیری الگوریتم SVR و ANN، با R و خطای جذر میانگین مربعات^۸ (RMSE) به ترتیب ۰/۸۱ و $0.34 \text{ m}^3 \text{ m}^{-3}$ بدست آمده است.

هیچ توافق کلی در مورد اینکه کدام مدل در طول فصل رشد گیاه برای تخمین رطوبت خاک بصورت بهینه عمل می‌کند، وجود ندارد. این عمدتاً به دلیل عدم قطعیت‌های مرتبط با فیزیک مدل، مفروضات اولیه، فرآیندهای معکوس‌سازی مدل، داده‌های ورودی، اثرات تضعیف پوشش گیاهی، شرایط آبرودینامیکی مختلف تاج پوشش گیاهی و ویژگی‌های متنوع خاک است. به طور مثال، بررسی منابع تحقیقاتی نشان می‌دهد که مدل WCM، که در این تحقیق به عنوان نمونه‌ای از مدل‌های بازیابی رطوبت خاک مبتنی بر داده‌های SAR در نظر گرفته شده است، توانایی پیاده‌سازی با شاخص‌های مختلف پوشش گیاهی و ویژگی‌های SAR به عنوان توصیف‌گر پوشش گیاهی را دارا است؛ اما دقت و کارایی این مدل تحت تأثیر توصیف‌گرهای پوشش گیاهی مورد استفاده در فرآیند کالیبراسیون بسیار متفاوت است. نتایج برخی از تحقیقات نشان دادند که WCM مبتنی بر شاخص تفاضلی نرمال شده آب^۹ (NDWI) منجر به بازیابی دقیق‌تر رطوبت خاک نسبت به WCM مبتنی بر شاخص تفاضلی نرمال شده پوشش گیاهی^{۱۰} (NDVI) می‌شود (Bao et al., 2018; Wang et al., 2020). در مقابل، Zhang et al. (2021) نتایج حاصل از WCM مبتنی بر NDVI را بهتر گزارش کرد. برخی هم نتایج قابل اعتمادی را هنگام استفاده از WCM مبتنی بر شاخص سطح برگ^{۱۱} (LAI) یافتند (El Hajj et al., 2016; Weiß et al., 2020).

زمانی که مدل‌های بازیابی رطوبت خاک در عمل به کار می‌روند، محققان معمولاً با سه مشکل اساسی مواجه می‌شوند: (۱) کدام مدل باید از بین مدل‌های موجود انتخاب شود، و (۲) کالیبراسیون مناسب آن چیست، و (۳) زمان مناسب استفاده از هر مدل در طول فصل رشد گیاه کدام است. بررسی جامع مدل‌های موجود برای پاسخ به سؤال اول مورد نیاز است؛ زیرا هیچ راهنمای روشنی برای انتخاب مدل‌های بازیابی رطوبت خاک برای محصولات مختلف کشاورزی وجود ندارد. مشکل دوم زمانی ایجاد می‌شود که چندین کاربر از یک مدل پایه، اما با کالیبراسیون‌های متفاوت استفاده می‌کنند، که منجر به نتایج متناقض

می‌شود. در بسیاری از موارد، کالیبراسیون از پیش تعریف شده توسط توسعه‌دهندگان مدل اصلی نیاز به کالیبراسیون مجدد برای هر منطقه دارد. برای سوال سوم، در نظرگیری در دسترس بودن داده‌های ماهواره‌ای و همچنین شرایط محصول در تاریخ‌های مختلف در طول فصل رشد مهم است. در سال‌های اخیر و با توسعه رویکردهای جدید، استفاده از ترکیب چندین مدل مورد بررسی قرار گرفته است. ترکیب چندین مدل می‌تواند بر اساس شایستگی‌های هر یک به هم افزایی دست یابد و در مقایسه با رویکرد مدل واحد، کمتر به یک نوع داده در مناطق مختلف کشاورزی وابسته است. پایه و اساس این رویکردها مبتنی بر مفاهیم «هوش تجمعی» (Malone et al., 2009) و «خرد جمعیت» (Surowiecki, 2005) هستند، که در آن مدل‌های متعدد می‌توانند اطلاعات تکمیلی را برای پشتیبانی از برآورد دقیق‌تر و قابل اطمینان‌تر از هر مدل به صورت جداگانه ارائه دهند.

با الهام از این مفاهیم، در این تحقیق روشی جدید برای پرداختن به سه چالش ذکر شده در بالا برای بازیابی مؤثر سری زمانی رطوبت خاک پیشنهاد می‌شود. روش پیشنهادی مبتنی بر ترکیب مدل‌های بازیابی رطوبت خاک در فصل رشد گیاه برای بهره‌برداری از مزایای هر یک از مدل‌ها با استفاده از یادگیری ماشین است. مزایای روش پیشنهادی عبارتند از: (۱) نگرانی کمتر در مورد انتخاب مدل‌ها، و (۲) حساسیت کمتر نسبت به کالیبراسیون مدل‌ها نسبت به روش تک مدلی در طول فصل رشد. چارچوب پیشنهادی اساساً یک رویکرد گروهی ساده، اما مؤثر است که در آن ترکیب چند مدل مبتنی بر یادگیری ماشین انجام می‌شود. نکته مهم این است که روش پیشنهادی چندین مدل را برای بازیابی سری زمانی رطوبت خاک ترکیب می‌کند، که با مطالعات قبلی که بر ترکیب و استفاده هم افزایی از داده‌های طیفی مختلف تمرکز داشتند، متفاوت است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

مزارع نیشکر شرکت کشت و صنعت امیرکبیر در استان خوزستان واقع در عرض‌های جغرافیایی ۴۸ درجه و ۱۲ دقیقه تا ۴۸ درجه و ۲۱ دقیقه شرقی و طول‌های جغرافیایی ۳۰ درجه و ۵۸ دقیقه تا ۳۱ درجه و ۵ دقیقه شمالی، در حدود ۵۰ کیلومتری جنوب غربی شهر اهواز، به عنوان منطقه مورد مطالعه در این تحقیق انتخاب شدند (شکل ۱). منطقه‌ای به مساحت تقریبی ۹۲۰۰ هکتار از مجموع ۱۲۰۰۰ هکتار این کشت و صنعت در سال ۲۰۲۰ در این تحقیق مورد مطالعه قرار گرفت. مزارع نیشکر منطقه عموماً همگن بوده و دارای ۲۵ هکتار (با طول تقریبی ۱۰۰۰ متر و عرض ۲۵۰ متر) مساحت هستند. بافت خاک در بیشتر

۲-۲- داده‌ها

داده‌های مورد استفاده در این تحقیق به دو بخش داده‌های میدانی و ماهواره‌ای تقسیم می‌شوند. داده‌های میدانی شامل اندازه‌گیری رطوبت سطح خاک، و اندازه‌گیری ویژگی‌های محصول مانند ارتفاع محصول، داده‌های آبیاری (مقدار و تاریخ) و داده‌های مرتبط با هواشناسی (بارش، رطوبت نسبی و دمای هوا) هستند. برای نمونه برداری تصادفی رطوبت خاک (عمق تقریبی ۵ سانتیمتر) از مزارع نیشکر (در مجموع ۴۰۰ نمونه) همزمان با عبور ماهواره در طول فصل رشد از رطوبت سنج خاک Fieldscout TDR 350 استفاده شد. همچنین، اندازه‌گیری ویژگی‌های گیاه نیشکر به صورت هفتگی در طول فصل رشد انجام شد.

مزارع معمولاً لومی رسی و لومی رسی سیلتی است (Leghayat et al., 2023; Mohammadi Moalezade et al., 2023). این منطقه دارای آب و هوای نیمه خشک با میانگین بارندگی سالانه ۲۶۶ میلی متر است. در ماه جولای میانگین حداکثر دمای ماهانه ۳۸ درجه سانتیگراد و در ژانویه میانگین حداقل دمای ماهانه ۱۲/۴ درجه سانتیگراد است. بر اساس برآوردها، میزان تبخیر و تعرق مرجع تقریباً ۳۳۳۰ میلی‌متر در سال است (Soltanikazemi et al., 2022; Hajeb et al., 2023). پایش مزارع نیشکر در طول فصل رشد سال ۲۰۲۰ انجام شد. مدیریت آبیاری، سیستم‌های زهکشی و عملیات‌های کشاورزی مشابه برای مزارع نیشکر در منطقه مورد مطالعه به کار گرفته شده است. یک معیار کلیدی در انتخاب این مزارع برای این تحقیق، دسترسی به داده‌های میدانی است که به طور دوره‌ای در طول فصل رشد محصول جمع‌آوری شده‌اند.

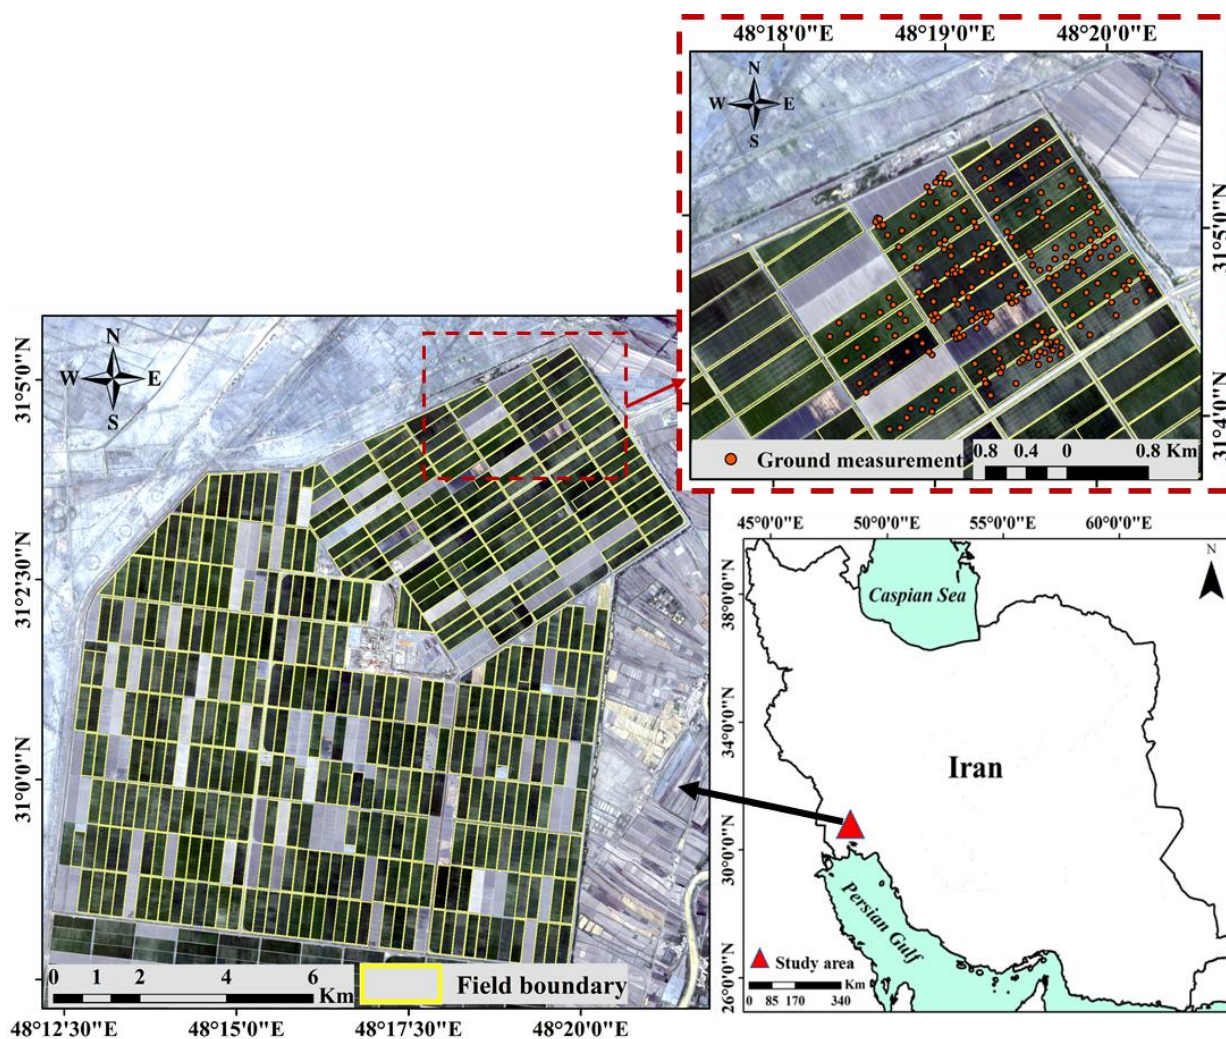


Fig. 1- Location of the study area

شکل ۱- موقعیت منطقه مورد مطالعه

شده و به سادگی افزودن مدل‌های مختلف کافی نیست (Stumpf, 2020). برای برخی مشکلات، انتخاب مدل ممکن است نتواند مناسب‌ترین مدل را تعیین کند. ممکن است مدل‌های زیادی با پشتیبانی قابل مقایسه وجود داشته باشد، در این صورت ممکن است تخمین‌ها با استفاده از مجموعه‌ای از مدل‌های پشتیبانی شده توسط داده‌های موجود انجام شود. مجموعه‌ای از مدل‌هایی که با دقت انتخاب شده‌اند عموماً دقیق‌تر از روش‌هایی هستند که بر یک مدل تکیه می‌کنند. روش پیشنهادی می‌تواند با انتخاب مدل‌ها و دستیابی به دقت پایدار در شرایط مختلف، راه‌حلی جامع برای بازیابی سری‌های زمانی رطوبت خاک ارائه دهد. نمای کلی از روند گام به گام این تحقیق را می‌توان در شکل ۲ مشاهده کرد.

در ابتدا، از تصاویر ماهواره‌ای پیش پردازش شده برای استخراج ویژگی‌های مختلف استفاده شد. از باندهای Sentinel-2 L2A برای محاسبه شاخص‌های طیفی و توصیف‌گرهای پوشش گیاهی مانند LAI، NDVI و غیره استفاده شد. علاوه بر این، ضرایب بازپراکنش SAR برای استخراج ویژگی‌های SAR مانند شاخص پوشش گیاهی رادار^{۱۷} (RVI)، زاویه برخورد (θ)، نسبت قطبش^{۱۸} (PR) و اختلاف قطبش^{۱۹} (PD) استفاده شد. سپس تفسیر سری‌های زمانی ضرایب بازپراکنش و توصیف‌گرهای پوشش گیاهی، و همچنین رابطه آن‌ها با رطوبت خاک، برای تعیین تأثیر هر پارامتر بر روی مدل‌ها در مراحل مختلف فصل رشد گیاه انجام شد. گام سوم شامل کالیبراسیون و اعتبارسنجی مدل WCM برای ضرایب بازپراکنش VV و VH در طول فصل رشد در مزارع بر اساس توصیف‌گرهای مختلف پوشش گیاهی است. در ادامه از یک عملگر به عنوان تنظیم‌گر استفاده شد. نقش تنظیم‌گر این است که مدل‌ها را بر اساس قوانین از پیش تعیین شده انتخاب کند. به عنوان بخشی از گام چهارم، از خروجی‌های مدل‌های WCM کالیبره‌شده و اندازه‌گیری‌های رطوبت خاک میدانی برای ایجاد مجموعه داده‌های آموزشی و آزمایشی استفاده شد، و سپس از شبکه عصبی رگرسیون تعمیم‌یافته^{۲۰} (GRNN) یکی از روش‌های یادگیری ماشین برای ترکیب مدل‌های متعدد و محاسبه بهینه مقادیر رطوبت خاک استفاده شد. همچنین، در این مرحله مقایسه و شناسایی اهمیت نسبی هر یک از مدل‌ها در ترکیب بهینه برای محاسبه رطوبت خاک طی فصل رشد گیاه انجام شد. به عنوان آخرین گام، برای سنجش دقت روش پیشنهادی نتایج آن با اندازه‌گیری‌های رطوبت خاک میدانی ارزیابی شد. علاوه بر این، نتایج بازیابی روش پیشنهادی با عملکرد انفرادی مدل‌های مختلف WCM طی فصل رشد مقایسه شد.

داده‌های ماهواره‌ای شامل تصاویر Sentinel-1 و Sentinel-2 هستند. تصاویر ماهواره‌ای Sentinel-1 (S-1A and S-1B) شامل قطبش‌های VH و VV هستند. در این تحقیق از ۷۲ محصول GRD طی فصل کشاورزی ۲۰۲۰ (فوریه تا نوامبر)، برای مزارع نیشکر استفاده شد. از این محصولات برای استخراج ضرایب بازپراکنش (σ^0)، ویژگی‌های SAR، پیاده‌سازی مدل‌های بازپراکنش سطحی و در نهایت بازیابی رطوبت خاک استفاده شد. همچنین، سنجنده‌های ماهواره‌های Sentinel-2 (S-2A and S-2B) تصاویر را در ۱۳ باند طیفی حداقل یک بار در هفته برای منطقه مورد مطالعه ارائه می‌دهند. محصولات S-2 Level-1C (L1C) از طریق ESA و پردازش شده این تصاویر در قالب محصول Level-2A از طریق سامانه Google earth engine در دسترس هستند. در مزارع نیشکر، ۹۰ تصویر از ۱۴۴ تصویر S-2 موجود برای فصل کشاورزی ۲۰۲۰ بدون ابر بودند. از این تصاویر برای محاسبه شاخص‌های طیفی و متغیرهای بیوفیزیکی استفاده شد. متغیرهای بیوفیزیکی مستخرج از داده‌های مرئی مورد استفاده در این تحقیق شامل کسر پوشش گیاهی^{۱۲} (FVC)، LAI، کسر تابش فعال فتوسنتزی جذب شده^{۱۳} (FAPAR)، محتوای کلروفیل تاج پوشش^{۱۴} (CCC) و محتوای آب پوشش گیاهی^{۱۵} (VWC) هستند که با استفاده از ماژول کمیته بیولوژیکی در نرم‌افزار SNAP محاسبه شدند. این ماژول این پارامترها را بر اساس مدل انتقال تابشی PROSAIL که مدل ترکیبی از PROSPECT (مدل بازتاب و عبور برگ) و SAIL (مدل بازتاب تاج پوشش گیاه) است، و یک شبکه عصبی مصنوعی (ANN) محاسبه می‌کند (Hu et al., 2020; Weiss et al., 2020). همچنین، شاخص‌های طیفی مستخرج از داده‌های مرئی مورد استفاده در این تحقیق شامل NDVI، NDWI و شاخص پوشش گیاهی تعدیل شده اثر خاک^{۱۶} (SAVI) هستند. جزئیات و روابط این شاخص‌ها در (Adamu et al., 2021) قابل مشاهده است.

۳- روش تحقیق

روش پیشنهادی در این تحقیق گروهی از مدل‌های WCM را برای ارائه بازیابی دقیق‌تر و پایدارتر رطوبت خاک در مراحل مختلف رشد محصول ترکیب می‌کند. منطق استفاده از این روش آن است که گروهی از مدل‌ها می‌توانند یکدیگر را تکمیل کنند و باعث افزایش دقت خروجی‌ها در مقایسه با یک مدل واحد شوند (Hoch, 2001). با این حال همواره تضمین نمی‌شود که برآوردهای مبتنی بر مجموعه‌ای از چند مدل بهتر از برآوردهای تک مدلی باشد. بسیار مهم است هنگام انتخاب مدل‌ها و ساخت مجموعه ترکیبی از آنها، دقت لازم ساخته

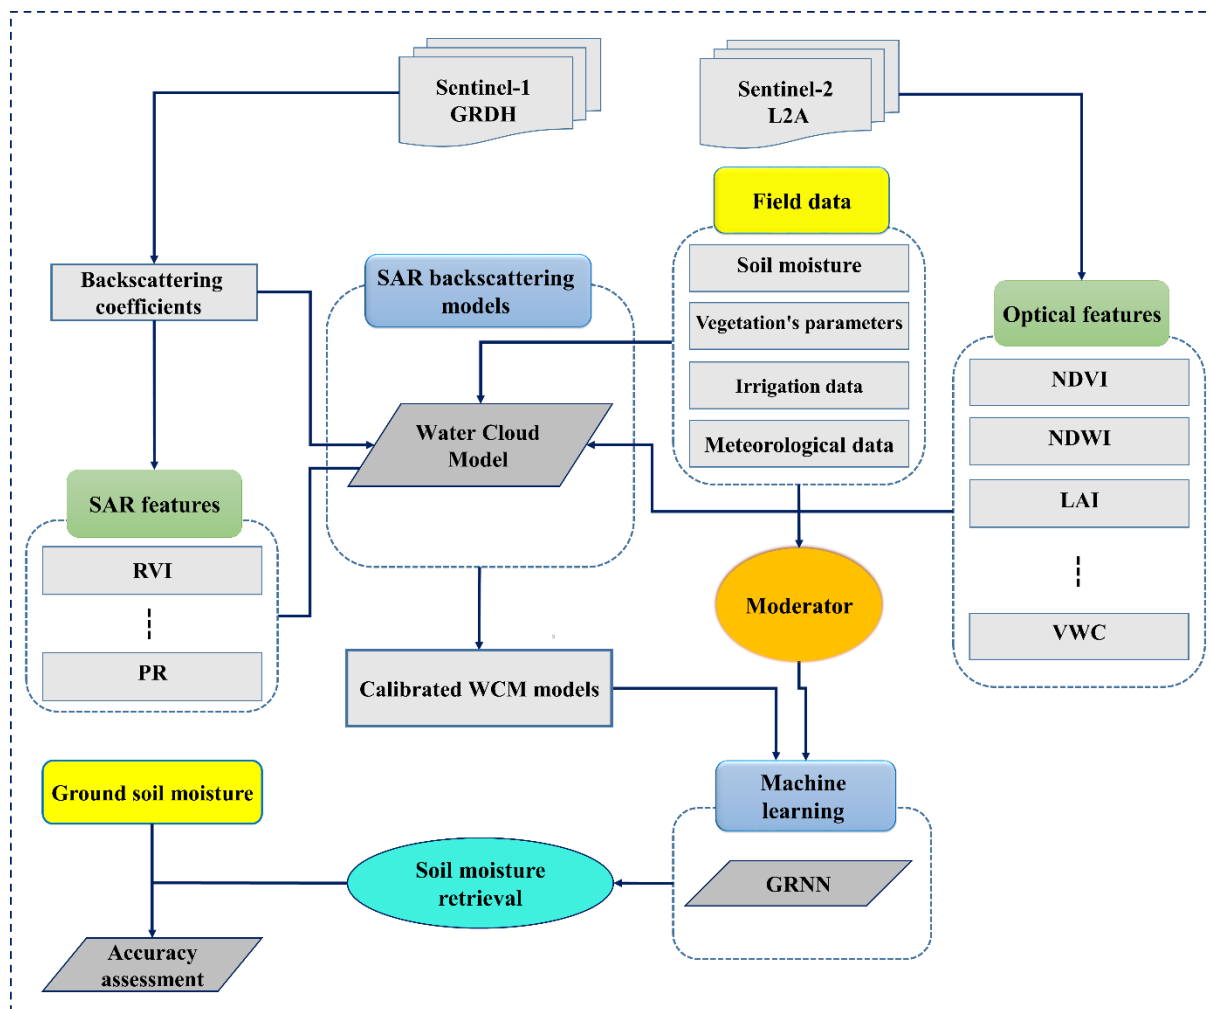


Fig. 2- The research flowchart
 شکل ۲- نمودار جریان‌ی مراحل تحقیق

۳-۱- مدل WCM

فرکانس‌های بین ۸ تا ۱۸ گیگاهرتز و زوایای برخورد از ۰ تا ۷۰ درجه معتبر است. این مدل یک روش ساده برای محاسبه σ° کل بدون در نظرگیری پراکنش چندگانه در تاج پوشش گیاهی و خاک است (Pierdicca et al., 2010). بنابراین معادل حل مرتبه اول معادله انتقال تابشی در یک محیط ضعیف است. در نتیجه، ضرایب بازپراکنش تاج پوشش به طور نامنسجم از سه سهم محاسبه می‌شوند (رابطه ۱): پراکنش حجمی از پوشش گیاهی (σ_{veg}°) (رابطه ۲)، پراکنش سطحی تضعیف شده از خاک زیرین (σ_{soil}°) (رابطه ۳)، و برهمکنش‌های پراکنش چندگانه بین خاک و پوشش گیاهی ($\sigma_{soil*veg}^{\circ}$).

$$\sigma_{canopy}^{\circ} = \sigma_{veg}^{\circ} + \tau^2 \sigma_{soil}^{\circ} + \sigma_{soil*veg}^{\circ} \quad (1)$$

$$\sigma_{veg}^{\circ} = A * V_1 + \cos \theta (1 - \tau^2) \quad (2)$$

$$\tau^2 = e^{-2B V_2 / \cos \theta} \quad (3)$$

$$\sigma_{soil}^{\circ} = CMv + D \quad (4)$$

ضرایب بازپراکنش SAR به طور کلی تحت تأثیر محتوای رطوبت خاک و زبری سطح در پوشش‌های بایر قرار دارند. وجود و رشد گیاهان بازیابی رطوبت خاک را در مناطق دارای پوشش گیاهی پیچیده می‌کند (Brognioni et al., 2010). WCM یک مدل نیمه تجربی است که برای شبیه‌سازی بازپراکنش سیگنال رادار بر روی تاج پوشش گیاهی طراحی شده است. در واقع، ثابت دی الکتریک ماده رویشی (گیاه) به طور قابل توجهی کوچکتر از آب است و تاج پوشش گیاهی از نظر حجمی معمولاً از درصدی هوا تشکیل شده است. بنابراین تاج پوشش گیاهی در WCM ابری از قطرات آب در نظر گرفته می‌شود که توسط ماده رویشی احاطه می‌شود (Attema and Ulaby, 1978). اساساً، WCM فرض می‌کند: (۱) می‌توان از پراکنش چندگانه در داخل حجم تاج پوشش گیاهی چشم‌پوشی کرد. (۲) تراکم و ارتفاع ابر ارتباط نزدیکی با پارامتر محتوای آب گیاه (VWC) دارد. مدل WCM برای

مکانیسم های پراکنش و مرحله رشد محصول عمل می‌کند. در هر تاریخ از فصل رشد، تنظیم‌گر حداقل سطح قابل قبول دقت مدل‌ها را تعیین می‌کند. اگر دقت یک مدل قابل قبول نباشد، تنظیم‌گر از مشارکت آن مدل در الگوریتم یادگیری ماشین جلوگیری می‌کند. اگر سطح دقت مدل قابل قبول باشد، تنظیم‌گر یک فرآیند انتخاب را برای مشارکت مدل در الگوریتم یادگیری ماشین اتخاذ می‌کند.

۳-۲- الگوریتم GRNN برای محاسبات بهینه

برای بهینه‌سازی محاسبات در روش پیشنهادی و انتخاب ترکیب بهینه مدل‌ها در طول فصل رشد گیاه نیشکر، از شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) استفاده شد. GRNN مانند سایر شبکه های عصبی دارای مزایای زیر است: استخراج اطلاعات از نمونه‌های آموزشی، کاوش و کشف ویژگی مبتنی بر نمونه، و ساده‌سازی پیچیدگی مدل فیزیکی. با این حال، مزایای اصلی GRNN عبارتند از (۱) یادگیری تک مرحله‌ای، که نیاز به پس انتشار را از بین می‌برد. (۲) استفاده از توابع گاوسی، (۳) توانایی کنترل نویز داده های ورودی، و (۴) دارای حافظه است. از طرف دیگر، معایب اصلی GRNN عبارتند از: (۱) ابعاد آن می‌تواند بزرگ باشد که از نظر محاسباتی گران می‌شود، و (۲) هیچ روش بهینه‌ای برای بهبود آن وجود ندارد. GRNN بر اساس توابع پایه شعاعی و تحلیل رگرسیون ناپارامتریک است. GRNN با کمک تابع چگالی احتمال داده‌های آموزشی، رابطه عملکردی بین متغیرهای وابسته و مستقل برقرار می‌کند (Mohammadpouri et al., 2023; Specht, 1991). علاوه بر توانایی نگاشت غیرخطی و توانایی یادگیری، می‌تواند در تحلیل رگرسیون با حجم نمونه بسیار بزرگتر به همگرایی دست یابد. زمانی که حجم نمونه کوچک باشد، خروجی پیش‌بینی عموماً بسیار دقیق است (Li et al., 2013). در این تحقیق از اعتبارسنجی متقاطع K-fold برای تعیین مقادیر پارامترهای GRNN بین داده‌های آموزشی و آزمایشی استفاده شد تا حداقل خطای میانگین مربعات و بهبود بازیابی رطوبت خاک حاصل شود. روش GRNN را می‌توان از طریق رابطه (۵) نشان داد.

$$E(Y|X) = \frac{\int_{-\infty}^{\infty} Yf(Y.X)dX}{\int_{-\infty}^{\infty} f(Y.X)dX} \quad (5)$$

که در آن X بردار ورودی n بعدی است، Y مقدار پیش‌بینی شده توسط GRNN، $E(Y|X)$ مقدار مورد انتظار خروجی Y مطابق بردار ورودی X ، و $f(Y.X)$ تابع چگالی احتمال توأم Y و X است.

معماری GRNN دارای چهار لایه است: لایه ورودی، لایه گنو، لایه تجمیع و لایه خروجی. پس از دریافت اطلاعات، لایه ورودی بردار

که در روابط ۲ و ۳، τ^2 پارامتر انتقال دو طرفه تاج پوشش گیاهی و θ زاویه برخورد سیگنال رادار است. ضریب A نشان‌دهنده پراکنش مستقیم پوشش گیاهی است، در حالی که ضریب B مربوط به تضعیف بازپراکنش زیرین خاک توسط تاج پوشش گیاهی است. این ضرایب به نوع و تاج پوشش گیاهی، قطبش و فرکانس سنجنده و همچنین زاویه برخورد بستگی دارند که هنگام کالیبراسیون مدل باید محاسبه شوند. V_1 و V_2 توصیف‌گرهای پوشش گیاهی هستند که پویایی و دینامیک تاج پوشش گیاهی را توصیف می‌کنند. در صورت دسترسی به پارامترهای زبری سطح، می‌توان برای محاسبه سهم مؤلفه خاک (σ_{soil}) در WCM را از طریق یکی از مدل‌های بازپراکنش سطحی مانند Oh و یا IEM استفاده نمود ولی از آنجا که در این تحقیق این پارامترها در دسترس نبودند، این مؤلفه از طریق رابطه ۴ محاسبه شد، که در این رابطه M_v رطوبت خاک اندازه‌گیری شده، ضریب C بیانگر حساسیت سیگنال رادار به رطوبت خاک و ضریب D عقب ماندگی ناشی از زبری سطح خاک هستند (El Hajj et al., 2016; Ouaadi et al., 2020). پارامتر محتوای آب گیاه (VWC) برای کمی‌سازی اثرات پوشش گیاهی بر ضرایب بازپراکنش در مدل‌های بازپراکنش پوشش گیاهی رادار استفاده شده است. با توجه به رابطه مستقیم بین VWC و عمق نفوذ رادار، VWC بر کیفیت بازیابی رطوبت خاک تأثیر می‌گذارد. برای تخمین VWC، شاخص‌ها و متغیرهای بیوفیزیکی مستخرج از داده‌های مرئی مانند NDVI، NDWI و LAI اغلب مورد استفاده قرار گرفته‌اند (Baghdadi et al., 2020; Wang et al., 2018; Bao et al., 2017). در این تحقیق، مدل‌های WCM با توصیف‌گرهای پوشش گیاهی مستخرج از داده‌های مرئی شامل WCM_{NDWI} ، WCM_{NDVI} ، WCM_{VWC} ، WCM_{LAI} و WCM_{SAVI} ، WCM_{FVC} ، WCM_{CCC} علاوه بر این مدل‌های WCM با توصیف‌گرهای مستخرج از داده‌های SAR، مانند WCM_{VV-VH} ، WCM_{PR} و WCM_{RVI} نیز استفاده شدند.

برای کاهش هزینه محاسباتی و بهبود عملکرد الگوریتم یادگیری ماشین، از یک عملگر به عنوان تنظیم‌گر^{۲۱} برای پیش‌انتخاب مدل‌های VWC در هر مرحله از فصل رشد محصول استفاده شد. در روش پیشنهاد شده در این تحقیق ممکن است از تمام مدل‌های موجود در طول فصل رشد به دلایل مختلف از جمله عدم دسترسی به تصویر سنجنده مرئی در تاریخ مورد نظر، شرایط آب و هوایی و دقت بسیار پایین بازیابی برخی از مدل‌ها (بر اساس میانگین و انحراف معیار دقت آنها) استفاده نشود. تنظیم‌گر در واقع یک درخت تصمیم است که بر اساس قوانین از پیش تعیین شده مانند شرایط آب و هوایی (درصد پوشش ابر، رطوبت نسبی و روزهای بارانی)، میزان پوشش گیاهی،

ورودی X را ذخیره می‌کند که تعداد نورون‌های آن برابر با بردار ورودی است. پس از آن، نورون‌های لایه ورودی داده‌ها را به لایه الگو تغذیه می‌کنند. فضای ورودی به فضای الگو به طور غیر خطی توسط لایه الگو تبدیل می‌شود. نورون‌های لایه الگو می‌توانند رابطه بین نورون‌های ورودی و پاسخ مناسب لایه الگو را به یاد بسپارند. الگوی تابع گاوسی (p_i) با استفاده از رابطه (۶) محاسبه می‌شود:

$$p_i = \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad (i = 1, 2, \dots, n) \quad (6)$$

که در آن σ پارامتر هموارسازی، X متغیر ورودی شبکه، و X_i بردار آموزشی خاص نورون i در لایه الگو است. لایه تجمیع دو عملیات جمع دارد: S_s و S_w که S_s تجمیع ساده عبارت از جمع ریاضی حاصل از خروجی‌های لایه الگو است و وزن اتصال آن برابر با یک است. S_w تجمیع وزنی عبارت از مجموع وزنی خروجی‌های لایه الگو است و وزن اتصال آن برابر با w_i است. S_w و S_s را می‌توان از روابط (۷) و (۸) تعیین کرد.

$$S_s = \sum_{i=1}^n p_i \quad (7)$$

$$S_w = \sum_{i=1}^n w_i p_i \quad (8)$$

که در آن w_i وزن نورون الگوی i است که به لایه تجمیع متصل است. تعداد نورون‌های لایه خروجی برابر با بعد k بردار خروجی Y است. پس از تجمیع نورون‌ها در لایه تجمیع، خروجی Y مدل GRNN با استفاده از رابطه (۹) قابل محاسبه است:

$$Y = \frac{S_s}{S_w} \quad (9)$$

در این تحقیق، از گروه دوم داده‌های اندازه‌گیری شده (زیر مجموعه اعتبارسنجی) برای تنظیم پارامترهای روش GRNN استفاده شد که رطوبت خاک (متغیر وابسته) را از متغیرهای مستقل (مدل‌های کالیبره شده) بازیابی می‌کند.

۳-۳- ارزیابی دقت

داده‌های میدانی رطوبت خاک برای ارزیابی دقت روش پیشنهادی استفاده شد. سه زیر مجموعه داده به طور تصادفی از داده‌های موجود انتخاب شدند: زیر مجموعه آموزشی (۵۰ درصد)، زیر مجموعه اعتبارسنجی (۲۰ درصد) و زیر مجموعه آزمایشی (۳۰ درصد). به منظور اجتناب از وابستگی به نتایج بازیابی، فرآیند نمونه‌گیری زیرمجموعه‌ها به صورت تصادفی بر اساس روش اعتبارسنجی متقاطع $k=2$ انجام شد (Soper, 2021). GRNN بر اساس زیرمجموعه آموزشی، آموزش

داده شد و زیر مجموعه اعتبارسنجی برای ارزیابی شبکه در مرحله آموزش استفاده شد. برای ارزیابی مستقل عملکرد شبکه GRNN تنظیم شده، زیرمجموعه آزمایشی کاملاً استفاده نشده تنها یک بار در مرحله نهایی ارزیابی دقت مورد استفاده قرار گرفت (Santi et al., 2018; Yamashita et al., 2016). دقت تمام مدل‌های بازیابی رطوبت خاک با استفاده از ضریب همبستگی پیرسون (R)، میانگین خطای مطلق MAE و $RMSE$ ارزیابی شد (Entekhabi et al., 2019; Rawat et al., 2010).

۴- نتایج و بحث

در بخش اول نتایج، تفسیر سری زمانی ضرایب بازپراکنش و توصیف‌گرهای پوشش گیاهی بر اساس مراحل اصلی رشد گیاه نیشکر (به ترتیب شامل مرحله استقرار و تثبیت، مرحله پنجه‌زنی، مرحله رشد بزرگ و اصلی، مرحله بلوغ و رسیدگی، برداشت) طی فصل کشاورزی ارائه شده است. بخش دوم بر کالیبراسیون و نتایج مدل WCM تمرکز دارد، در حالی که بخش سوم بازیابی رطوبت خاک بر اساس ترکیب مدل‌های مختلف را مورد بحث قرار می‌دهد.

۴-۱- تفسیر سری‌های زمانی

سری زمانی ضرایب بازپراکنش برگشتی $S-1$ (VH و VV) در زوایای برخورد $43/5$ درجه (مدار صعودی) و $37/8$ درجه (مدار نزولی)، $NDVI$ ، $NDWI$ و LAI از $S-2$ و اندازه‌گیری‌های میدانی در مراحل مختلف رشد گیاه نیشکر در مزارع نیشکر طی فصل کشاورزی ۲۰۲۰ در شکل ۳ ارائه شده است.

گیاهان نیشکر یک الگوی متمایز در ضرایب بازپراکنش برگشتی (σ°) خود نشان می‌دهند. به طور خاص، σ° به طور قابل توجهی از مرحله استقرار (فوریه) تا مرحله رشد بزرگ (ژوئن) افزایش یافت. در مرحله استقرار، گیاهان نیشکر میانگین پایین σ_{VV}° و σ_{VH}° را ارائه کردند. در مرحله پنجه‌زنی (زمانی که نیشکر چندین ساقه تولید می‌کند)، σ° به تدریج افزایش یافت و تا مرحله رشد بزرگ (زمانی که نیشکر شروع به رشد سریع می‌کند و برخی از ساقه‌ها شروع به رشد می‌کنند) ادامه یافت. σ° عمدتاً تحت تأثیر تغییرات رطوبت خاک و زبری سطح در مراحل اولیه رشد است، زمانی که مقادیر LAI و FVC هنوز کم هستند (Baghdadi et al., 2009). در طی مراحل رشد بزرگ و رسیدگی، σ° به تدریج و با توسعه ساختار عمودی تاج پوشش گیاهی نیشکر کاهش یافت.




Fig. 3- Time-series of σ_{VV}° and σ_{VH}° at 43.5° (a and b) and 37.8° (c and d), spectral indices (e) and vegetation parameters (f) over sugarcane fields

شکل ۳- سری زمانی σ_{VV}° و σ_{VH}° در زاویه 43.5° درجه (a و b) و در زاویه 37.8° درجه (c و d)، شاخص‌های طیفی (e) و پارامترهای محصول (f) در مزارع نیشکر

همانطور که Yuan et al. (2019) هم گزارش کرده‌اند این دوره با پراکنش حجمی مشخص می‌شود. نقطه شروع و پایان تضعیف سیگنال در مزارع را می‌توان نقاط کلیدی در سری زمانی σ° در نظر گرفت. در اواخر ژوئن این کاهش شروع شد و تا زمان برداشت ادامه داشت. در زاویه برخورد 43.5° درجه شدیدتر از 37.8° درجه، و در σ_{VH}° شدیدتر از σ_{VV}° دیده می‌شود. رفتار σ° مشاهده شده مشابه آنچه در مطالعات

den Besten et al., 2023; Molijn et al., 2019) گزارش شده است: افزایش قابل توجهی در نیمه اول فصل رشد و پس از گذشت از حداکثر مقدار، کاهش نسبتاً ملایم می‌یابد. حداکثر مقادیر در σ_{VV}° و σ_{VH}° زودتر از حداکثر مقادیر در شاخص‌های مرئی رخ داده است. به طور کلی مقادیر σ_{VV}° بزرگتر از مقادیر σ_{VH}° بوده و شدت کاهش پس از مقادیر حداکثر در این دو قطبش متفاوت است.

۴-۲- باز یابی رطوبت خاک با استفاده از مدل‌های WCM و روش ترکیبی

انواع توصیف‌گرهای پوشش گیاهی (مشتق شده از داده‌های مرئی و یا از داده‌های SAR) برای کالیبراسیون مدل WCM استفاده شد، که در نتیجه تفاوت‌هایی بین دقت مدل‌ها ایجاد شد. چندین توصیف‌گر پوشش گیاهی در فرآیند کالیبراسیون WCM مورد ارزیابی قرار گرفتند، از جمله NDVI، NDWI، LAI و VWC. در اینجا، نتایج کالیبراسیون مدل WCM بر اساس NDWI برای مزارع نیشکر مورد بحث قرار می‌گیرد. سری زمانی σ° مشاهده شده و باز یابی شده در مزارع نیشکر در، و همچنین سهم خاک (σ°_{soil}) و سهم پوشش گیاهی (σ°_{veg}) هنگام استفاده از NDWI، در شکل ۴ ارائه شده است.

برازش خوبی بین تغییرات نسبی در σ° (مقادیر بیشتر σ°_{VV} نسبت به σ°_{VH} و مقادیر کمتر σ° در زاویه $43/5$ درجه نسبت به زاویه $37/8$ درجه برای هر دو قطبش VV و VH) وجود دارد، که نشان می‌دهد مدل به خوبی کالیبره شده است. با توسعه تاج پوشش گیاهی نیشکر، سهم خاک در مکانیسم‌های پراکنش به تدریج کاهش می‌یابد. طی نیمه اول فصل کشاورزی (از فوریه تا ژوئن)، باز یابی رضایت‌بخش بود. با این حال، خطا به تدریج تا ۴ دسی بل در مرحله رسیدگی نیشکر افزایش یافت. RMSE برای σ°_{VV} در زاویه $37/8$ درجه در مرحله رسیدگی $2/5$ دسی بل بیشتر از کل فصل کشاورزی در مزارع نیشکر بود. در نتایج مشخص است که تفاوت‌های σ° مشاهده شده و باز یابی شده منجر به انحراف‌های کوچک در باز یابی رطوبت خاک با RMSE برابر با $0.02 \text{ m}^3 \text{ m}^{-3}$ برای مراحل اولیه رشد نیشکر، و همچنین تغییرات بزرگ در باز یابی رطوبت خاک با RMSE برابر با $0.1 \text{ m}^3 \text{ m}^{-3}$ طی توسعه تاج پوشش گیاهی نیشکر می‌شود. بنابراین، انحرافات باز یابی رطوبت خاک در نیمه دوم فصل کشاورزی (از اواسط مرحله رشد بزرگ) افزایش می‌یابد.

با توجه به ارزیابی کلی مدل‌های مختلف WCM، WCM مبتنی بر NDWI در مراحل اولیه فصل زراعی نیشکر قبل از شروع دوره تضعیف در مرحله رشد بزرگ، عملکرد مناسبی داشت. دوره حداکثر تضعیف در مرحله رسیدگی رخ داد. با آغاز مرحله رشد بزرگ گیاه نیشکر، مدل WCM مبتنی بر VWC، σ° را با دقت بیشتری نسبت به مدل مبتنی بر NDWI باز یابی می‌کند. هنگامی که زوایای برخورد کم و نیشکرها جوان هستند، خاک به طور قابل توجهی در σ° مشاهده شده سهم دارد. در این هنگام، σ° در درجه اول زبری سطح و رطوبت خاک را نشان می‌دهد.

NDWI و NDVI منحنی تغییرات مشابهی را طی فصل رشد نشان دادند (شکل ۳)، به طوری که بلافاصله پس از مرحله استقرار مقادیر آنها افزایش یافت که بیانگر رشد اولیه نیشکر است. در اواسط مرحله رشد بزرگ (ارتفاع ساقه بیش از ۱۵۰ سانتیمتر)، آنها به یک سطح اشباع رسیدند که مقادیرشان تا شروع مرحله رسیدگی در این سطح مانده و پس از آن همزمان با رسیدن گیاه نیشکر، مقادیرشان کاهش جزئی نشان دادند. همانطور که توسط Molijn et al. (2019) هم بیان شده، این کاهش همزمان با کاهش زیست توده برگ و شروع پیری است. روندهای فصلی LAI، NDVI و VWC ارتباط نزدیکی با هم دارند. با این وجود، VWC پس از مرحله رسیدگی گیاه در ماه سپتامبر، زمانی که میزان مصرف نیتروژن و آبیاری کاهش می‌یابد تا رشد نیشکر کاهش و منجر به تجمع بیشتر قند در ساقه شود، به طور قابل توجهی کاهش می‌یابد (شکل ۳). علاوه بر این، برخی منابع تحقیقاتی گزارش کرده‌اند توزیع عمودی VWC در طول فصل رشد نیشکر تغییر می‌کند که بر σ° مشاهده شده تأثیر می‌گذارد (den Besten et al., 2023). در کل فصل، VWC و LAI ارتباط خطی ندارند و رابطه آنها به ساختار تاج پوشش گیاهی بستگی دارد. با توجه به یافته‌های فوق، می‌توان نتیجه گرفت که NDWI، NDVI و VWC دارای پتانسیل بیشتری به عنوان توصیف‌گر پوشش گیاهی در مدل WCM برای باز یابی رطوبت خاک در مزارع نیشکر هستند.

روابط بین مقادیر رطوبت خاک اندازه‌گیری شده و σ° به طور آشکاری در کل فصل پراکنده است. برای تجزیه و تحلیل دقیق‌تر، روابط از نظر شاخص سطح برگ (LAI) بر حسب $\text{m}^2 \text{ m}^{-2}$ نیز مورد بررسی قرار گرفت. مقادیر R بین σ°_{VV} و رطوبت خاک اندازه‌گیری شده در مزارع نیشکر در کل فصل ($LAI < 1.1$ ، $LAI > 1.1$) در زوایای $43/5$ و $37/8$ درجه به ترتیب 0.29 ، 0.64 ، 0.08 و 0.36 ، 0.72 و 0.18 است. همبستگی‌های یافت شده در هنگامی که LAI کمتر از $1/1$ است، برای همه σ° معنی‌دار است. با توجه به تاج پوشش گیاه نیشکر، سهم خاک در σ° مشاهده شده هنگامی که نیشکر رشد می‌کند کاهش می‌یابد (ارتفاع ساقه بیش از ۹۰ سانتی‌متر) که منجر به کاهش همبستگی بین رطوبت خاک اندازه‌گیری شده و σ° می‌شود. به طور کلی، σ°_{VV} با رطوبت خاک بیشتر از σ°_{VH} همبستگی دارد. همبستگی بین σ° و رطوبت خاک در زاویه برخورد $37/8$ درجه بیشتر از زاویه برخورد $43/5$ درجه است؛ زیرا خاک در زاویه برخورد کمتر سهم بیشتری در ضریب بازپراکنش برگشتی دارد.

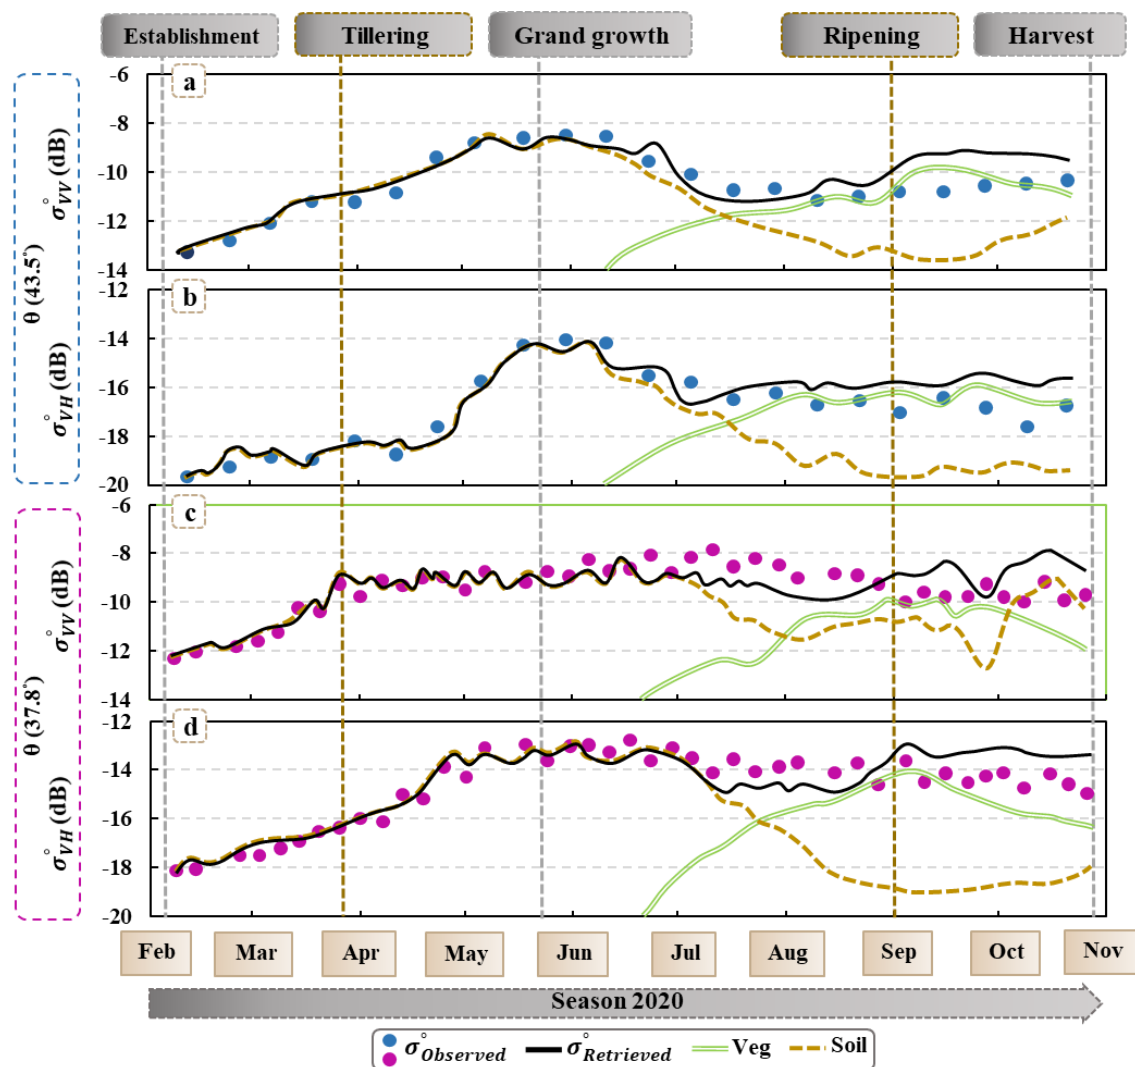


Fig. 4- Time-series of observed and retrieved σ^o based on WCM (vegetation descriptor: NDWI) over sugarcane fields at 43.5° (a and b) and 37.8° (c and d)

شکل ۴- سری زمانی σ^o مشاهده شده و بازیابی شده بر اساس WCM (توصیف‌گر پوشش گیاهی: NDWI) در مزارع نیشکر در زاویه ۴۳/۵ درجه (a و b) و در زاویه ۳۷/۸ درجه (c و d)

در نیمه دوم فصل توسط زیست توده پوشش گیاهی تعیین می‌شود. آشکار است که مقادیر σ^o بازیابی شده نسبت به σ^o مشاهده شده در پایان فصل افزایش یافته است. با توجه به این دلایل، هیچ یک از مدل‌های WCM نتوانستند رطوبت خاک را در سطح قابل قبولی در مرحله رسیدگی گیاه نیشکر بازیابی کنند.

در مقایسه با سایر توصیف‌گرهای مشتق شده از داده‌های مرئی، WCM مبتنی بر NDVI تفاوت‌های بیشتری را بین مقادیر σ^o مشاهده شده و بازیابی شده مزارع نیشکر نشان دادند، که به معنای دقت کمتر است. WCM مبتنی بر RVI (توصیف‌گر مشتق از SAR) دقت

ولی سهم خاک در σ^o مشاهده شده برای نیشکرها با تاج پوشش گیاهی توسعه یافته اندک است (گیاهانی با LAI بیش از m^2m^{-2} ۱/۰۵ و ارتفاع ساقه بیش از ۱۰۰ سانتیمتر). همانگونه که Baghdadi et al. (2009) هم ذکر کرده‌اند، با رشد گیاه، حساسیت σ^o در باند C نسبت به پارامترهای خاک کمتر و به پارامترهای تاج پوشش بیشتر می‌شود. چندین محدودیت در نیمه دوم فصل رشد گیاه در همه مدل‌ها وجود دارد: در گیاهان نیشکر با تاج پوشش گیاهی توسعه یافته (ارتفاع ساقه بیش از ۲۰۰ سانتیمتر)، سهم خاک در σ^o مشاهده شده به دلیل پراکنش حجمی نسبتاً کم است و مقادیر σ^o بیشتر با اندازه، تعداد و جهت برگ‌های نیشکر مرتبط است. بنابراین، σ^o مشاهده شده

ادامه دقت بازیابی برای محصول نیشکر در مدل‌های مختلف برای ارزیابی سهم هر مدل در مراحل مختلف رشد محصول مقایسه شد.

روش ترکیبی مبتنی بر GRNN، مقادیر RMSE کمتر (m^3m^{-3}) $0/085$ و R بیشتر ($0/7$) را نسبت به هر یک از مدل‌های تکی در کل فصل رشد نیشکر تولید کرد. رشد نیشکر طی مراحل مختلف فصل رشد عموماً بر عملکرد روش ترکیبی مبتنی بر GRNN تأثیر می‌گذارد، اما این تأثیر پس از مرحله رشد بزرگ گیاه نیشکر بیشتر و قابل توجه است (شکل ۷ را ببینید). برای گیاه نیشکر، در مرحله استقرار کمترین RMSE به میزان $0/037 m^3m^{-3}$ مشاهده شد، در حالی که پس از مرحله رسیدگی در سپتامبر بالاترین RMSE با مقدار $0/094 m^3m^{-3}$ مشاهده شد. در شکل ۷ می‌توان سهم اصلی هر یک از مدل‌ها را در افزایش دقت بازیابی سری زمانی رطوبت خاک بر اساس GRNN را مشاهده کرد. به عنوان مثال، می‌توان با مدل WCM_{NDWI} رطوبت خاک را در ابتدای فصل رشد گیاه نیشکر و با مدل WCM_{VWC} در مراحل میانی فصل رشد گیاه نیشکر با دقت مناسب بازیابی کرد. با این وجود، در بازیابی محتوای رطوبت خاک در نیمه دوم فصل رشد، به ویژه پس از مرحله رسیدگی، دقت کاهش می‌یابد. مقادیر RMSE شش مدل WCM با دقت بهتر و روش ترکیبی مبتنی بر یادگیری ماشین برای مزارع نیشکر در کل فصل کشاورزی در شکل ۶ ارائه شده است.

نسبتاً پایینی در بازه حداکثر تضعیف ایجاد کرد که ناشی از افزایش تفاوت‌های بین σ مشاهده‌شده و بازیابی‌شده در هنگام توسعه تاج پوشش گیاهی نیشکر است. از میان مدل‌های مختلف WCM، برخی از مدل‌ها (مانند WCM مبتنی بر NDWI) در مراحل اولیه رشد گیاه نیشکر بهتر عمل کردند در حالی که برخی دیگر (مانند WCM مبتنی بر LAI و VWC) در مراحل بعدی عملکرد بهتری داشتند. هنگام انتخاب فقط یک مدل، مدل WCM مبتنی بر NDWI دقیق‌ترین بازیابی سری زمانی σ را از نظر RMSE کل فصل در مقایسه با سایر مدل‌های WCM برای مزارع نیشکر ارائه کرد.

اهمیت نسبی انواع مدل‌های مؤثر در کل فصل کشاورزی برای افزایش دقت بازیابی رطوبت خاک ارزیابی شد (شکل ۵). برای محاسبه امتیاز اهمیت نسبی مدل‌ها از تمامی نمونه‌های آموزشی استفاده شد. در کل فصل زراعی نیشکر، WCM_{NDWI} ($0/72$)، WCM_{VWC} ($0/69$) و WCM_{LAI} ($0/63$) بالاترین امتیازات اهمیت نسبی را برای بازیابی رطوبت خاک بر اساس ترکیب بهینه مدل‌ها مبتنی بر یادگیری ماشین دریافت کردند. WCM_{PR} و WCM_{VV-VH} به ترتیب با $0/2$ و $0/15$ کمترین امتیازات اهمیت نسبی را کسب کردند. نتایج ارزیابی نشان می‌دهد که توصیف‌گرهای مبتنی بر ویژگی‌های زیست توده و شاخص‌های مرئی نسبت به ویژگی‌های SAR در هنگام بازیابی رطوبت خاک مزارع نیشکر با مدل WCM بیشتر کمک می‌کنند.

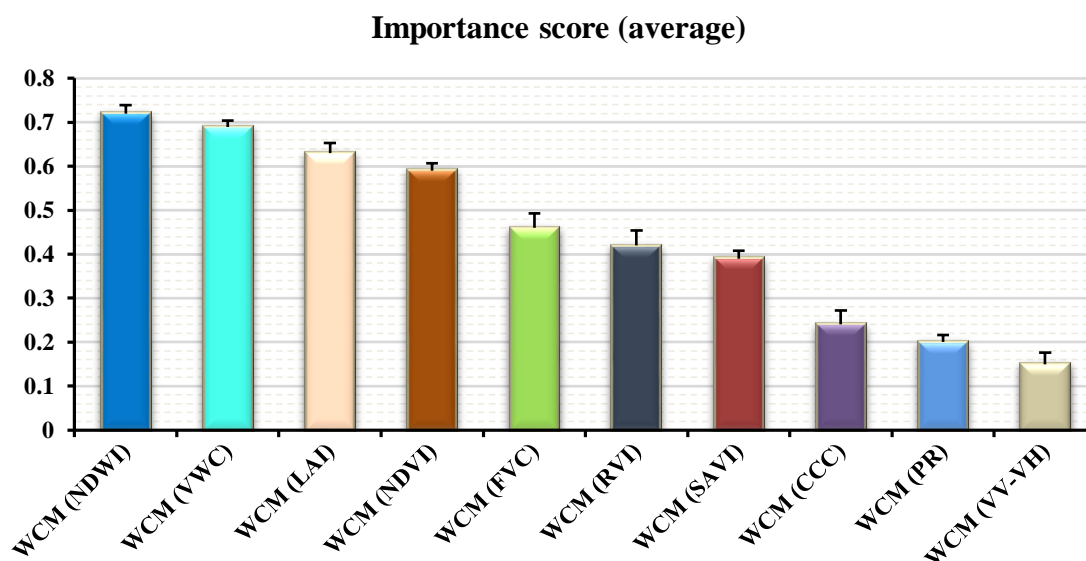


Fig. 5- Average of importance score of each model over the whole growth season of sugarcane
 شکل ۵- میانگین امتیاز اهمیت هر مدل در کل فصل رشد نیشکر

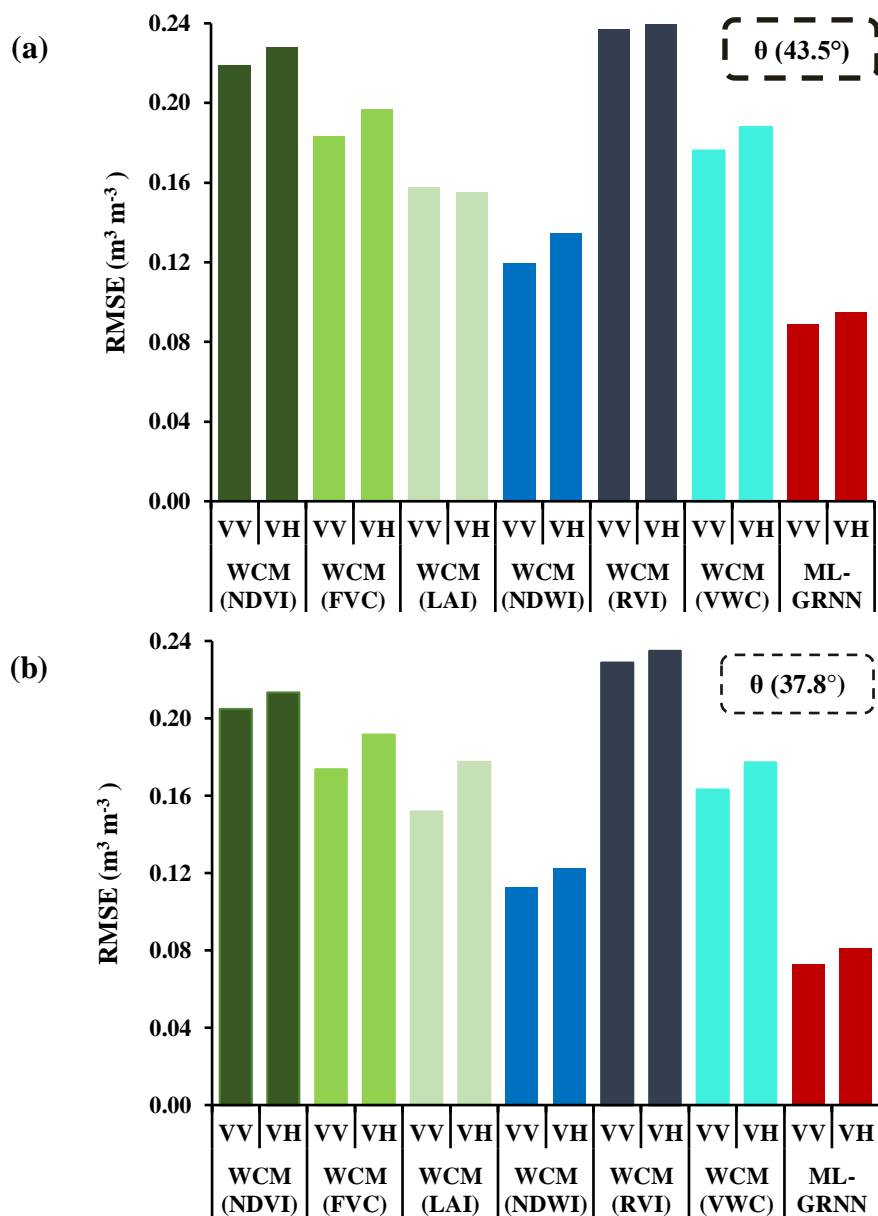


Fig. 6- The average RMSE of different models for sugarcane fields at 43.5° (a) and 37.8° (b)
 شکل ۶- میانگین مقادیر RMSE مدل‌های مختلف برای مزارع نیشکر در زاویه 43.5° درجه (a) و در زاویه 37.8° درجه (b)

همان‌طور که در شکل ۶ مشاهده می‌شود کمترین میانگین مقادیر RMSE در مزارع نیشکر در کل فصل توسط روش ترکیبی مبتنی بر GRNN برای σ_{VV} در زاویه 37.8° درجه حاصل گشت که برابر $0.07 m^3 m^{-3}$ بود. بر اساس نتایج، روش ترکیبی مبتنی بر GRNN رطوبت خاک را با دقت بیشتری نسبت به مدل‌های تکی بازیابی نمود. روش ترکیبی مبتنی بر GRNN در هر سه معیار (MAE و R، RSME) به نتایج بهینه دست یافت. همچنین، بررسی نتایج نشان داد که با ترکیب بهینه مدل‌ها حداقل میانگین خطای مطلق (MAE) کمتر از $0.07 m^3 m^{-3}$ است در حالی که مدل‌های تکی همگی دارای MAE بیش از $0.07 m^3 m^{-3}$ هستند. در روش ترکیبی مبتنی بر GRNN، ضریب همبستگی پیرسون (R) برابر با 0.7 برای طی فصل رشد نیشکر حاصل گشت که این معیار در مدل‌های WCM_{VWC} ، WCM_{NDWI} و WCM_{LAI} به ترتیب برابر با 0.63 ، 0.54 و 0.48 بود. علاوه بر این، ثبات بالایی را در زوایای برخورد مختلف برای کل فصل نشان داد. این موضوع پتانسیل روش پیشنهادی را به عنوان یک چارچوب کاربردی مبتنی بر یادگیری ماشین برای بازیابی رطوبت خاک از چندین مدل و داده‌های مختلف سنجش از دور برجسته می‌کند.

همان‌طور که در شکل ۶ مشاهده می‌شود کمترین میانگین مقادیر RMSE در مزارع نیشکر در کل فصل توسط روش ترکیبی مبتنی بر GRNN برای σ_{VV} در زاویه 37.8° درجه حاصل گشت که برابر $0.07 m^3 m^{-3}$ بود. بر اساس نتایج، روش ترکیبی مبتنی بر GRNN رطوبت خاک را با دقت بیشتری نسبت به مدل‌های تکی بازیابی نمود. روش ترکیبی مبتنی بر GRNN در هر سه معیار (MAE و R، RSME) به نتایج بهینه دست یافت. همچنین، بررسی نتایج نشان داد که با ترکیب بهینه مدل‌ها حداقل میانگین خطای مطلق (MAE) کمتر از $0.07 m^3 m^{-3}$ است در حالی که مدل‌های تکی همگی دارای MAE بیش از $0.07 m^3 m^{-3}$ هستند.

به عنوان بخشی از روش بازیابی تک مدلی، مقادیر رطوبت خاک بر اساس اطلاعات مربوط به ضرایب بازپراکنش پس از کالیبراسیون اختصاص داده می شوند. با این وجود، هنگام بازیابی سری زمانی رطوبت خاک، مدل‌های اعمال شده ممکن است از نظر چارچوب روش خود به انعطاف‌پذیری نیاز داشته باشند تا مکانیسم‌های پراکنش بالقوه را به عنوان تابعی از مرحله رشد گیاه در نظر بگیرند. در نتیجه، خطای بازیابی را می‌توان از طریق محاسبه بهینه گام به گام با استفاده از روش یادگیری ماشین کاهش داد، و دقت بازیابی رطوبت خاک را به بالاترین سطح خود رساند. در منطقه مورد مطالعه این تحقیق (مزارع نیشکر) نشان داده شد که چهار مدل به طور قابل توجهی به بازیابی سری زمانی رطوبت خاک در مزارع نیشکر طی فصل کشاورزی با دقت بالا کمک می‌کنند (شکل ۷). با توجه به یافته‌های این تحقیق، ممکن است اهمیت مدل‌هایی که از توصیف‌گرهای پوشش گیاهی مختلف استفاده می‌کنند متفاوت باشد، ولی همه مدل‌ها به بهبود عملکرد بازیابی رطوبت خاک کمک کردند.

بکارگیری GRNN در این تحقیق به عنوان یکی از الگوریتم‌های یادگیری ماشین کمک شایانی به بهینه سازی محاسبات و فرآیند معکوس سازی نمود. علاوه بر این، همان طور که Wang et al. (2023) و Zhang et al. (2022) هم نشان دادند روش‌های یادگیری ماشین می‌توانند به طور مؤثر اطلاعات استخراج شده از داده‌ها و مدل‌های مختلف را دریافت کنند و دقت بازیابی رطوبت خاک را افزایش دهند. بر اساس مطالعه El Hajj et al. (2017)، شبکه‌های عصبی برای حل مسئله بازیابی رطوبت خاک مناسب هستند؛ زیرا دارای قابلیت‌هایی مانند تقریب تابع و بهینه سازی محاسبات هستند. روش ترکیبی مبتنی بر GRNN مورد استفاده در این تحقیق قادر به بهبود محاسبات پیچیده مورد نیاز برای بازیابی رطوبت خاک طی فصل رشد محصول با استفاده از اطلاعات تفسیر سری‌های زمانی، مدل‌های متعدد و قابلیت‌های یادگیری ماشین بود. در این تحقیق، مشخص گردید که GRNN (یادگیری ماشین) یک روش معکوس سازی مؤثر است.

یکی از مزایای تحقیق حاضر این است که مدل‌ها می‌توانند توسط تنظیم‌گر از قبل انتخاب شوند. باید توجه داشت که اگر مدل‌های با عملکرد ضعیف غالب باشند، رویکرد گروهی و ترکیبی می‌تواند با مشکل مواجه شود. علاوه بر این، به نظر نمی‌رسد افزایش تعداد مدل‌ها سود چندانی ارائه دهد (Murphy, 2012). در حال حاضر، بکارگیری مجموعه‌های چند مدلی موجود از نظر محاسباتی گران هستند و گاهی در بازیابی پارامتر مورد نظر به نفع یک مدل خاص سوگیری دارند.

روش پیشنهادی نیازی به انتخاب مدل از قبل ندارد. علاوه بر این، مدل‌ها (پارامترهای ورودی) در روش پیشنهادی نیازی به کالیبراسیون دقیق در طول فصل رشد گیاه ندارند. بدیهی است که اگر مدل‌ها به طور کامل کالیبره شوند، دقت بازیابی به طور قابل توجهی افزایش می‌یابد. با توجه به مدل WCM به عنوان نمونه‌ای از مدل‌های SAR، یافته‌های ما در رابطه با تأثیر توصیف‌گرهای مختلف پوشش گیاهی بر فرآیند کالیبراسیون با آنچه در مطالعات قبلی نشان داده شده است، مطابقت داشت. به طور کلی مدل WCM یک مدل ساده با پیاده‌سازی نسبتاً آسان در نظر گرفته می‌شود، اگرچه قابلیت‌های کالیبراسیون و بازیابی آن ممکن است از مکانی به مکان دیگر متفاوت و در طول زمان نیز ناپایدار باشد (Bouchat et al., 2022). برخی از مطالعات نتایج مشابهی را برای WCM با توصیف‌گرهای پوشش گیاهی NDVI و NDWI گزارش کرده‌اند. در حالی که در برخی دیگر گزارش شده که WCM مبتنی بر NDWI بهتر از WCM مبتنی بر NDVI رطوبت خاک را بازیابی می‌کند (Bao et al., 2018; Wang et al., 2020)؛ زیرا باند SWIR حساسیت بالاتری به VWC دارد، در حالی که حساسیت NDVI به رشد پوشش گیاهی پس از مقدار ۰/۸ نسبتاً پایین است (Baghdadi et al., 2017). بر خلاف این گزارشات، Zhang et al. (2021) نتایج چندین مطلوبی از بکارگیری WCM مبتنی بر NDWI گزارش نکردند که به اشباع VWC نسبت داده شد. همچنین، برخی از مطالعات نتایج قابل اعتمادی را هنگام استفاده از WCM مبتنی بر LAI یافتند (Leghayat et al., 2023). WCM ممکن است از توصیف‌گرهای پوشش گیاهی مشتق از داده‌های SAR، مانند PR و RVI بهره‌مند شود؛ زیرا این توصیف‌گرها کالیبراسیون را بدون نیاز به تصاویر مرئی ارائه می‌دهند (Wang et al., 2021). همانطور که در برخی از تاریخ‌های فصل کشاورزی ۲۰۲۰ مشاهده شد، وجود ابرها دسترسی به داده‌های مرئی را محدود کردند. در این تحقیق تنها WCM مبتنی بر RVI اندکی نتایج رضایت‌بخش به همراه داشت. به طور کلی می‌توان نتیجه گرفت که برای دستیابی به دقت بالا، یک مدل واحد باید در طی فصل رشد گیاه تحت کالیبراسیون کامل قرار گیرد که این تقریباً غیرممکن است و استفاده از روش ترکیبی رویکردی بهینه است.

لازم به ذکر است که هر مقدار رطوبت خاک به طور بالقوه تعدادی از ضرایب بازپراکنش قابل مشاهده را نشان می‌دهد که دامنه مقادیر آنها گاهی به طور قابل توجهی متفاوت است و منجر به عدم قطعیت در بازیابی مقدار رطوبت خاک می‌شود. این بدان معناست که بازیابی رطوبت خاک را می‌توان به عنوان یک مسئله با ابعاد بالا در نظر گرفت.

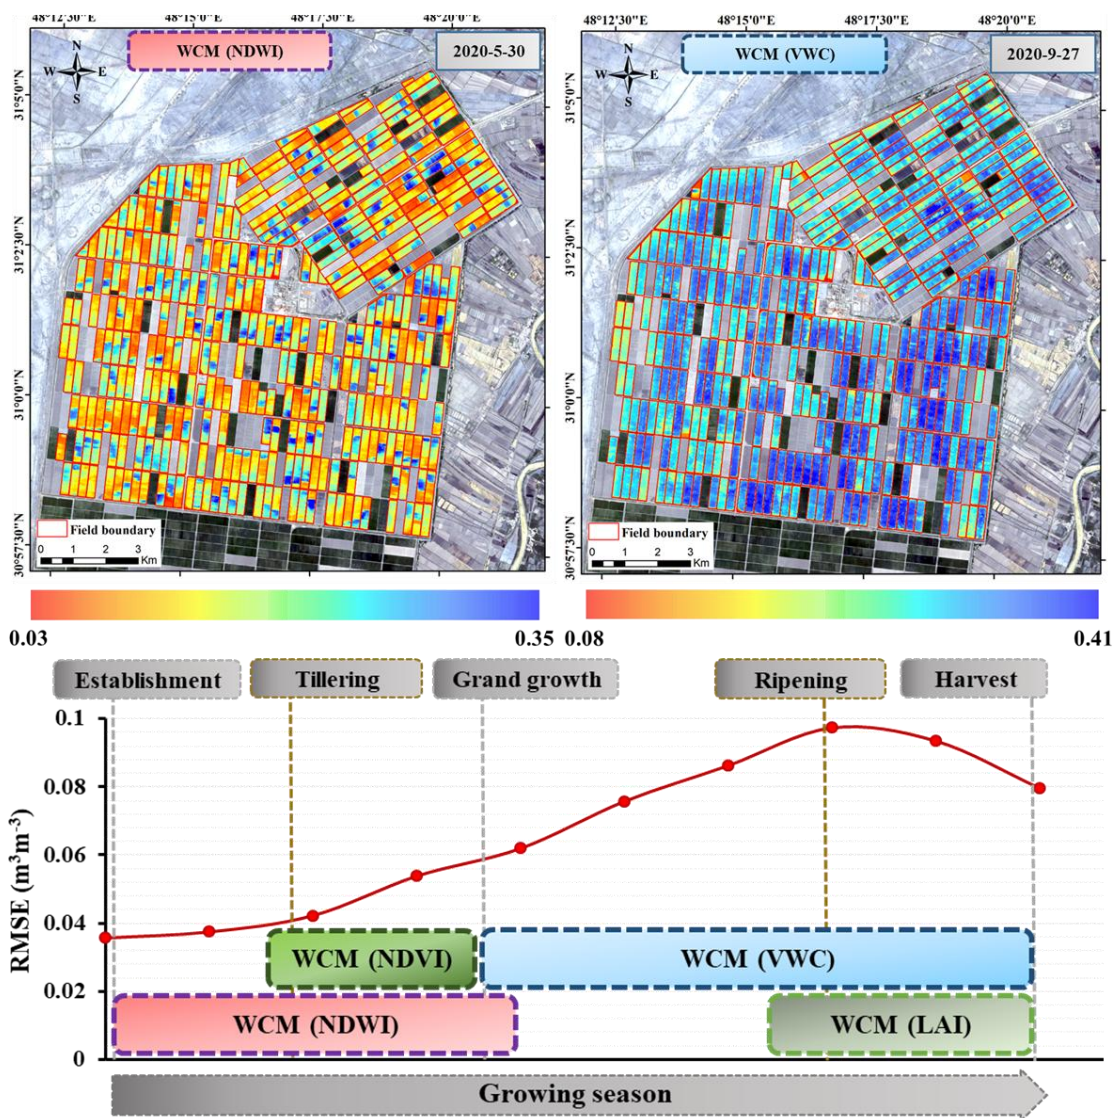


Fig. 7- The optimal combination of models to retrieve time-series soil moisture during the growth season and related soil moisture maps

شکل ۷- ترکیب بهینه مدل‌ها برای بازیابی سری زمانی رطوبت خاک طی فصل رشد و نقشه‌های رطوبت خاک مرتبط

دیگر محصولات (مانند گندم، ذرت، سویا و غیره) با الگوهای پیچیده‌تر و مکانیسم‌های پراکنش مختلف انجام شود. همچنین، در روش پیشنهادی برای انتخاب الگوریتم یادگیری ماشین مناسب، تحقیقات بیشتری نیاز است. هر چند GRNN در این تحقیق و بسیاری از کاربردهای سنسور از دوری عملکرد مناسبی نشان داده است؛ اما دارای معایبی است که بررسی عملکرد سایر الگوریتم‌های یادگیری ماشین و یا یادگیری عمیق را در روش پیشنهادی می‌طلبد. همچنین، در راستای بهبود دقت بازیابی رطوبت خاک در مزارع نیشکر در نیمه دوم فصل کشاورزی که عملکرد مدل‌های WCM مطلوب نیست، لازم است در تحقیقات آتی از مدل‌های مبتنی بر داده‌های مرئی و یا

در اصل، ترکیب قوی‌ترین مدل‌ها با بهره‌گیری از نقاط قوت منحصربه‌فرد آن‌ها امکان‌پذیر است، اما این فرآیند مستلزم شناسایی قابل اعتماد و مستقل هر مدل است (Stumpf, 2020). این تحقیق نشان داد که روش پیشنهادی زمانی قابل اعتماد است که ترکیب مجموعه مدل‌ها به درستی ساخته شوند. در مراحل اولیه پیاده‌سازی این تحقیق مشخص شد که عملکرد روش ترکیبی مبتنی بر GRNN به طور منفی تحت تأثیر عملکرد ضعیف برخی از مدل‌ها قرار می‌گیرد. بنابراین، مدل‌هایی که دقت کم و عملکرد ضعیف داشتند، توسط تنظیم‌گر از ترکیب مجموعه مدل‌ها حذف شدند. در آینده، باید تحقیقات بیشتری برای آزمایش عملکرد روش پیشنهادی برای انواع

مدل‌های مبتنی بر داده‌های حرارتی در روش پیشنهادی به صورت ترکیبی با مدل‌های مبتنی بر داده‌های SAR استفاده شود.

۵- خلاصه و جمع‌بندی

در این تحقیق یک روش پیشنهادی جدید برای بازیابی رطوبت خاک در مزارع کشاورزی بر اساس مجموعه چند مدلی و یادگیری ماشین پیشنهاد شد. به طور جامع تفسیر سری زمانی ضرایب بازپراکنش و توصیف‌گرهای پوشش گیاهی، بررسی روابط بین پارامترها، مزایا و معایب انواع مدل‌های WCM انجام و ترکیبی از مدل‌ها برای دستیابی به دقت بازیابی بالا بسته به مرحله رشد گیاه نیشکر طی فصل کشاورزی شناسایی شد. یک مجموعه چند مدلی با استفاده از قابلیت‌های یادگیری ماشین برای حل مشکل بازیابی رطوبت خاک توصیه شد که بر ارتباطات بین مدل‌ها متکی است. نتایج این تحقیق نشان داد که روش ترکیبی مبتنی بر GRNN دارای دقت بازیابی بهتری نسبت به مدل‌های نیمه تجربی WCM تکی است. در نتیجه اعتبارسنجی با استفاده از اندازه‌گیری‌های میدانی، حداقل MAE بدست‌آمده از ترکیب بهینه مدل‌ها کمتر از $0.02 \text{ m}^3 \text{ m}^{-3}$ طی فصل رشد گیاه نیشکر است. اعتبارسنجی نتایج نشان داد که میانگین RMSE بدست آمده از ترکیب بهینه مدل‌ها تقریباً $0.085 \text{ m}^3 \text{ m}^{-3}$ برای مزارع نیشکر است. با این حال، زمانی که داده‌های مرئی در دسترس نیستند و مدل‌های WCM با توصیف‌گرهای SAR اجرا می‌شوند، دقت بازیابی به طور قابل توجهی کاهش می‌یابد. به طور خلاصه، نتایج نشان داد که پتانسیل تولید سری زمانی رطوبت خاک دقیق‌تر با قدرت تفکیک مکانی مناسب (۲۰ متر) در مزارع کشاورزی وجود دارد که برای کاربردهای کشاورزی و مدیریت منابع آب کشاورزی بسیار مهم است. روش پیشنهادی مستقل از نوع مدل و سنجنده است و به راحتی قابل تعمیم به سایر مدل‌ها (مانند مدل‌های اپتیک و یا حرارتی) و تصاویر سنجنده‌های ماهواره‌ای (مانند Landsat 8/9، GF-1/3 و داده‌های باند L مانند ALOS-2) است. شاید مهم‌تر از آن، روش پیشنهادی ترکیب مدل‌ها مبتنی بر یادگیری ماشین می‌تواند به‌عنوان روشی مناسب و جایگزین برای بازیابی سری زمانی رطوبت خاک به طور پیوسته از مزارع کشاورزی در نبود مدل‌های فیزیکی مناسب استفاده شود. یافته‌های این تحقیق می‌تواند منجر به دستیابی به اطلاعات دقیق رطوبت خاک شود که نقش مهمی در مدیریت مصرف بهینه آب و برنامه‌ریزی آبیاری در مزارع کشاورزی دارد و امکان پاسخگویی به بسیاری از نیازهای کاربردی کشاورزی مانند شناسایی میزان تقاضای آب محصول، نظارت بر تنش کم آبی در محصول و پیش‌بینی عملکرد و بازده محصول را فراهم نماید. همچنین، دستیابی به سری زمانی رطوبت خاک دقیق‌تر با قدرت

تفکیک مکانی مناسب (۲۰ متر) به طور پیوسته (کمتر از یک هفته) در مزارع کشاورزی می‌تواند مقدمه‌ای برای پیاده‌سازی کشاورزی دقیق در جهت بهره‌وری بیشتر، و کمک به بهینه‌سازی مراحل مختلف کشاورزی و کاهش ضایعات در فرآیند تولید محصولات کشاورزی باشد.

۶- تشکر

نویسندگان مقاله از مؤسسه تحقیقات و آموزش شرکت توسعه نیشکر و صنایع جانبی و همچنین کشت و صنعت نیشکر امیرکبیر برای مساعدت فراوان در فعالیت‌های میدانی و ارائه داده‌های زمینی مورد استفاده در این تحقیق تشکر و قدردانی می‌کنند.

پی‌نوشت‌ها

- 1- Synthetic Aperture Radar
- 2- Water Cloud Model
- 3- Michigan Microwave Canopy Scattering
- 4- Artificial Neural Networks
- 5- Support Vector Regression
- 6- Random Forest
- 7- Extreme Gradient Boosting
- 9- Normalized Difference Water Index
- 10- Normalized Difference Vegetation Index
- 11- Leaf Area Index
- 12- Fractional Vegetation Cover
- 13- Fraction of Absorbed Photosynthetically Active Radiation
- 14- Canopy Chlorophyll Content
- 15- Vegetation Water Content
- 16- Soil Adjusted Vegetation Index
- 17- Radar Vegetation Index
- 18- Polarization Ratio
- 19- Polarization Difference
- 20- Generalized Regression Neural Network
- 21- Moderator
- 22- 5-Fold Cross Validation
- 23- Mean Absolute Error

۷- مراجع

- Adamu B, Rasul A, Whanda SJ, Headboy P, Muhammed I, & Maiha IA (2021) Evaluating the accuracy of spectral indices from Sentinel-2 data for estimating forest biomass in urban areas of the tropical savanna. *Remote Sensing Applications: Society and Environment* 22:100484
- Attema E, & Ulaby FT (1978) Vegetation modeled as a water cloud. *Radio Science* 13:357-364
- Baghdadi N, Boyer N, Todoroff P, El Hajj M, & Bégué A (2009) Potential of SAR sensors TerraSAR-X, ASAR/ENVISAT and PALSAR/ALOS for monitoring sugarcane crops on Reunion Island. *Remote Sensing of Environment* 113(8):1724-1738
- Baghdadi N, El Hajj M, Zribi M, & Bousbih S (2017) Calibration of the water cloud model at C-band for winter crop fields and grasslands. *Remote Sensing* 9(9):969
- Balenzano A, Satalino G, Pauwels V, & Mattia F (2011) Soil moisture retrieval from dense temporal series of C-band SAR data over agricultural sites. In, 2011 IEEE International Geoscience and Remote Sensing Symposium (pp. 3136-3139): Canada, Vancouver
- Bao Y, Lin L, Wu S, Deng K A K, & Petropoulos G P (2018) Surface soil moisture retrievals over partially vegetated areas from the synergy of Sentinel-1 and Landsat 8 data using a modified water-cloud model. *International Journal of Applied Earth Observation and Geoinformation* 72:76-85
- Bouchat J, Tronquo E, Orban A, Neyt, X, Verhoest N E, & Defourny P (2022) Green area index and soil moisture retrieval in maize fields using multi-polarized C-and L-Band SAR data and the water cloud model. *Remote Sensing* 14(10):2496
- Brogioni M, Pettinato S, Macelloni G, Paloscia S, Pampaloni P, Pierdicca N, & Ticconi F (2010) Sensitivity of bistatic scattering to soil moisture and surface roughness of bare soils. *International Journal of Remote Sensing* 31(15):4227-4255
- Champagne C, White J, Berg A, Belair S, & Carrera M (2019) Impact of soil moisture data characteristics on the sensitivity to crop yields under drought and excess moisture conditions. *Remote Sensing* 11(4):372
- Das B, Rathore P, Roy D, Chakraborty D, Bhattacharya B K, Mandal D, Jatav R, Sethi D, Mukherjee J, & Sehgal V K (2023) Ensemble surface soil moisture estimates at farm-scale combining satellite-based optical-thermal-microwave remote sensing observations. *Agricultural and Forest Meteorology* 339:109567
- Den Besten N, Dunne S S, Mahmud A, Jackson D, Aouizerats B, de Jeu R, Burger R, Houborg R, McGlinchey M, & van der Zaag P (2023) Understanding Sentinel-1 backscatter response to sugarcane yield variability and waterlogging. *Remote Sensing of Environment* 290:113555
- Ebrahimi-Khusfi M, Alavipanah S.K, Hamzeh S, Amiraslani F, Samany N N, & Wigneron J P (2018) Comparison of soil moisture retrieval algorithms based on the synergy between SMAP and SMOS-IC. *International Journal of Applied Earth Observation and Geoinformation* 67:148-160
- El Hajj M, Baghdadi N, Zribi M, & Bazzi H (2017) Synergic use of Sentinel-1 and Sentinel-2 images for operational soil moisture mapping at high spatial resolution over agricultural areas. *Remote Sensing* 9(12):1292
- El Hajj M, Baghdadi N, Zribi M, Belaud G, Cheviron B, Courault D, & Charron F (2016) Soil moisture retrieval over irrigated grassland using X-band SAR data. *Remote Sensing of Environment* 176:202-218
- Entekhabi D, Reichle R H, Koster R D, & Crow W T (2010) Performance metrics for soil moisture retrievals and application requirements. *Journal of Hydrometeorology* 11(3):832-840
- Fatholouloumi S, Vaezi A R, Alavipanah S K, Ghorbani A, & Biswas A (2020) Comparison of spectral and spatial-based approaches for mapping the local variation of soil moisture in a semi-arid mountainous area. *Science of the Total Environment* 724:138319
- Ge L, Hang R, Liu Y, & Liu Q (2018) Comparing the performance of neural network and deep Convolutional neural network in estimating soil moisture from satellite observations. *Remote Sensing* 10(9):1327
- Hajeb M, Hamzeh S, Alavipanah S K, Neissi L, & Verrelst J (2023) Simultaneous retrieval of sugarcane variables from Sentinel-2 data using Bayesian regularized neural network. *International Journal of Applied Earth Observation and Geoinformation* 116:103168
- Hoch S.J (2001) Combining models with intuition to improve decisions. *Wharton on Making Decisions*, New York: Wiley, 81-101
- Hu Q, Yang J, Xu B, Huang J, Memon M S, Yin G, Zeng Y, Zhao J, & Liu K (2020) Evaluation of global decametric-resolution LAI, FAPAR and FVC estimates derived from Sentinel-2 imagery. *Remote Sensing* 12(6):912
- Khazaei M, Hamzeh S, Samani N N, Muhuri A, Goïta K, & Weng Q (2023) A web-based system for satellite-

- based high-resolution global soil moisture maps. *Computers & Geosciences* 170:105250
- Leghayat R, Hamzeh S, Neysani Samani N, MOhammadi Moalehzadeh J, & Naseri A A (2023) Estimation of soil moisture using WCM model and Sentinel satellite imagery for irrigation scheduling of sugarcane fields. *Engineering Journal of Geospatial Information Technology* 10(4):109-123 (In Persian)
- Leng P, Yang Z, Yan Q Y, Shang G F, Zhang X, Han X J, & Li Z L (2023) A framework for estimating all-weather fine resolution soil moisture from the integration of physics-based and machine learning-based algorithms. *Computers and Electronics in Agriculture* 206:107673
- Li H z, Guo S, Li C j, & Sun, J q (2013) A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm. *Knowledge-Based Systems* 37:378-387
- Li Z L, Leng P, Zhou C, Chen K S, Zhou F C, & Shang G F (2021) Soil moisture retrieval from remote sensing measurements: Current knowledge and directions for the future. *Earth-Science Reviews* 218:103673
- Liu Y, Liu Y, & Wang W (2019) Inter-comparison of satellite-retrieved and Global Land Data Assimilation System-simulated soil moisture datasets for global drought analysis. *Remote Sensing of Environment* 220:1-18
- Madelon R, Rodríguez-Fernández N J, Bazzi H, Baghdadi N, Albergel C, Dorigo W, & Zribi M (2023) Soil moisture estimates at 1 km resolution making a synergistic use of Sentinel data. *Hydrology and Earth System Sciences* 27(6):1221-1242
- Malone T W, Laubacher R, & Dellarocas C (2009) *Harnessing crowds: Mapping the genome of collective intelligence*. MIT, Sloan School of Management
- Martínez-Fernández J, González-Zamora A, Sánchez N, Gumuzzio A, & Herrero-Jiménez C (2016) Satellite soil moisture for agricultural drought monitoring: Assessment of the SMOS derived Soil Water Deficit Index. *Remote Sensing of Environment* 177:277-286
- Moalezade J M, Hamze S, & Naseri A.A (2022) Estimating soil surface moisture content and investigating irrigation schedule of sugarcane fields using Thermal Trapezoidal Model. *Iranian Journal of Soil and Water Research* 53(10):2209-2223 (In Persian)
- Mohammadi Moalezade J, Hamzeh S, & Naseri A (2023) Evaluation of optical remote sensing efficiency in estimating soil surface moisture and comparing it with thermal data for irrigation management of sugarcane. *Journal of Water Research in Agriculture* 37(1):85-101 (In Persian)
- Mohammadpouri S, Sadeghnejad M, Rezaei H, Ghanbari R, Tayebi S, Mohammadzadeh N, Mijani N, Raeisi A, Fathololoumi S, & Biswas A (2023) A generalized regression neural network model for accuracy improvement of global precipitation products: A climate zone-based local optimization. *Sustainability* 15(11):8740
- Molijn R A, Iannini L, Vieira Rocha J, & Hanssen R F (2019) Sugarcane productivity mapping through C-band and L-band SAR and optical satellite imagery. *Remote Sensing* 11(9):1109
- Moran M S, Peters-Lidard C D, Watts J M, & McElroy S (2004) Estimating soil moisture at the watershed scale with satellite-based radar and land surface models. *Canadian Journal of Remote Sensing* 30(5):805-826
- Murphy .P (2012) *Machine learning: A probabilistic perspective*. MIT Press
- Ouaadi N, Jarlan L, Ezzahar J, Zribi M, Khabba S, Bouras E, Bousbih S, & Frison P-L (2020) Monitoring of wheat crops using the backscattering coefficient and the interferometric coherence derived from Sentinel-1 in semi-arid areas. *Remote Sensing of Environment* 251:112050
- Peng J, Albergel C, Balenzano A, Brocca L, Cartus O, Cosh M H, Crow W T, Dabrowska-Zielinska K, Dadson S, & Davidson M W (2021) A roadmap for high-resolution satellite soil moisture applications-confronting product characteristics with user requirements. *Remote Sensing of Environment* 252:112162
- Petropoulos G P, Ireland G, & Barrett B (2015) Surface soil moisture retrievals from remote sensing: Current status, products & future trends. *Physics and Chemistry of the Earth (Parts A/B/C)* 83:36-56
- Pierdicca N, Pulvirenti L, & Bignami C (2010) Soil moisture estimation over vegetated terrains using multitemporal remote sensing data. *Remote Sensing of Environment* 114:440-448
- Rawat K S, Singh S K, & Pal R K (2019) Synergetic methodology for estimation of soil moisture over agricultural area using Landsat-8 and Sentinel-1 satellite data. *Remote Sensing Applications: Society and Environment* 15:100250
- Santi E, Paloscia S, Pettinato S, & Fontanelli G (2016) Application of artificial neural networks for the soil moisture retrieval from active and passive microwave spaceborne sensors. *International Journal of Applied Earth Observation and Geoinformation* 48:61-73

- Singh G, & Das N N (2022) A data-driven approach using the remotely sensed soil moisture product to identify water-demand in agricultural regions. *Science of the Total Environment* 837:155893
- Soper D S (2021) Greed is good: Rapid hyperparameter optimization and model selection using greedy k-fold cross validation. *Electronics* 10(16):1973
- Specht D F (1991) A general regression neural network. *IEEE Transactions on Neural Networks* 2(6):568-576
- Stumpf M P (2020) Multi-model and network inference based on ensemble estimates: Avoiding the madness of crowds. *Journal of the Royal Society Interface* 17(171):20200419
- Surowiecki J (2005) The wisdom of crowds. Anchor
- Ulaby F T, Aslam A, & Dobson M C (1982) Effects of vegetation cover on the radar sensitivity to soil moisture. *IEEE Transactions on Geoscience and Remote Sensing* 4:476-481
- Wang Q, Li J, Jin T, Chang X, Zhu Y, Li Y, Sun J, & Li D (2020) Comparative analysis of Landsat-8, Sentinel-2, and GF-1 data for retrieving soil moisture over wheat farmlands. *Remote Sensing* 12(17):2708
- Wang S, Li R, Wu Y, & Wang W (2023) Estimation of surface soil moisture by combining a structural equation model and an artificial neural network (SEM-ANN). *Science of the Total Environment* 876:162558
- Wang Z, Zhao T, Qiu J, Zhao X, Li R, & Wang S (2021) Microwave-based vegetation descriptors in the parameterization of water cloud model at L-band for soil moisture retrieval over croplands. *GIScience & Remote Sensing* 58(1):48-67
- Weiss M, Baret F, & Jay S (2020) S2ToolBox Level 2 products LAI, FAPAR, FCOVER. In: EMMAH-CAPTE, INRAe Avignon
- Weiß T, Ramsauer T, Löw A, & Marzahn P (2020) Evaluation of different radiative transfer models for microwave backscatter estimation of wheat fields. *Remote Sensing* 12(18):3037
- Wu S, Ren J, Chen Z, Yang P, & Li H (2020) Soil moisture estimation based on the microwave scattering mechanism during different crop phenological periods in a winter wheat-producing region. *Journal of Hydrology* 590:125521
- Yamashita R, Nishio, M, Do R K G, & Togashi K (2018) Convolutional neural networks: An overview and application in radiology. *Insights into Imaging* 9:611-629
- Yuan X, Li H, Han Y, Chen J, & Chen X (2019) Monitoring of sugarcane crop based on time series of Sentinel-1 data: A case study of Fusui, Guangxi. In, 2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics) (pp. 1-5): Turkey, Istanbul
- Zeyliger A, Muzalevskiy K, Zinchenko E, & Ermolaeva O (2022) Field test of the surface soil moisture mapping using Sentinel-1 radar data. *Science of the Total Environment* 807:151121
- Zhang D, & Zhou G (2016) Estimation of soil moisture from optical and thermal remote sensing: A review. *Sensors* 16(8):1308
- Zhang M, Lang F, & Zheng N (2021) Soil moisture retrieval during the wheat growth cycle using SAR and optical satellite data. *Water* 13(2):135
- Zhang Y, Liang S, Zhu Z, Ma H, & He T (2022) Soil moisture content retrieval from Landsat 8 data using ensemble learning. *ISPRS Journal of Photogrammetry and Remote Sensing* 185:32-47