Vol 16, No. 3, Autumn 2026

University of Tehran Press

Journal of Water and Irrigation Management Online ISSN: 2382-9931

Homepage: https://jwim.ut.ac.ir/

Estimation of Water Deficit Index Using Landsat-8 and Sentinel-2 Satellite Imagery and Machine Learning Models

Soroush Sharghi[1]✉ | **Amin Zeynolabedin**[2]

1. Corresponding Author, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran. E-mail: s_sharghi@sbu.ac.ir
2. Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran. E-mail: a_zeynolabedin@sbu.ac.ir

Article Info

Article type:
Research Article

Article history:
Received 9 April 2026
Received in revised form
16 August 2026
Accepted 22 August 2026
Published online 26 October 2026

Keywords:
Landsat-8
Machine Learning Models
METRIC Algorithm
Sentinel-2
Water Deficit Index

ABSTRACT

Low agricultural water productivity, together with the growing impacts of climate change, has increased pressure on water resources. Continuous monitoring of plant water stress at field and orchard scales can help alleviate this pressure. In this study, Machine Learning (ML) models were combined with remote sensing data to directly estimate the Water Deficit Index (WDI). Two scenarios were developed for WDI estimation in pistachio orchards of the Rafsanjan Plain. In the first scenario, Sentinel-2 spectral bands were used as input data, while WDI images derived from the METRIC algorithm were used as the target output. In the second scenario, the input data consisted of a combination of Sentinel-2 spectral bands and the thermal band of Landsat-8, while the output remained the same as in the first scenario. The novelty of this study lies in the development of a methodological framework for high-spatial-resolution mapping of WDI through the integration of ML models with Sentinel-2 and Landsat-8 satellite imagery. The results showed that, in the second scenario, incorporating thermal information improved the accuracy of WDI estimation across different plant growth stages. Among the evaluated models, the Artificial Neural Network (ANN) achieved the best performance, with DC and KGE values of 0.718 and 0.818, respectively, outperforming the SVR and RF models.

Cite this article: Sharghi, S., & Zeynolabedin, A. (2026). Estimation of Water Deficit Index Using Landsat-8 and Sentinel-2 Satellite Imagery and Machine Learning Models. *Journal of Water and Irrigation Management*, 16 (3), 581-606. DOI: https://doi.org/10.22059/jwim.2026.412422.1295

© The Author(s).
Publisher: University of Tehran Press.
DOI: https://doi.org/10.22059/jwim.2026.412422.1295

دوره شانزدهم، شماره سوم، پاییز ۱۴۰۵

انتشارات دانشگاه تهران

مدیریت آب و آبیاری

شاپا الکترونیکی: ۹۹۳۱-۲۳۸۲

Homepage: https://jwim.ut.ac.ir/

تخمین شاخص کسری آب با استفاده از تصاویر ماهواره لندست–۸ و سنتینل–۲ و مدل‌های یادگیری ماشین

سروش شرقی[۱]✉ | امین زین‌العابدین[۲]

۱. نویسنده مسئول، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: s_sharghi@sbu.ac.ir

۲. دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران. رایانامه: a_zeynolabedin@sbu.ac.ir

اطلاعات مقاله

نوع مقاله: مقالهٔ پژوهشی

تاریخ دریافت: ۱۴۰۵/۰۱/۲۰

تاریخ بازنگری: ۱۴۰۵/۰۵/۲۵

تاریخ پذیرش: ۱۴۰۵/۰۵/۳۱

تاریخ انتشار: ۱۴۰۵/۰۸/۰۴

کلیدواژه‌ها:

الگوریتم METRIC

شاخص کسری آب

سنتینل–۲

لندست–۸

مدل‌های یادگیری ماشین

چکیده

بهره‌وری پایین آب در بخش کشاورزی در کنار تشدید اثرات تغییر اقلیم، از عوامل مهم افزایش فشار بر منابع آب است. پایش مستمر تنش آبی در سطح مزارع و باغات می‌تواند به‌عنوان عاملی کمک‌کننده در جهت کاهش این فشار مطرح شود. در این پژوهش از ترکیب مدل‌های یادگیری ماشین و سنجش از دور برای برآورد مستقیم شاخص کسری آب استفاده شد. در این راستا دو سناریو برای تخمین شاخص کسری آب در باغات پسته دشت رفسنجان توسط مدل‌های یادگیری ماشین تهیه شد. در سناریوی ۱ ورودی و خروجی مدل‌های یادگیری ماشین به‌ترتیب باندهای طیفی ماهواره سنتینل–۲ و تصاویر شاخص کسری آب تخمین‌زده‌شده توسط الگوریتم METRIC در نظر گرفته شد. در سناریوی ۲ این ورودی شامل ترکیب باندهای طیفی سنتینل–۲ و باند حرارتی ماهواره لندست–۸ و خروجی مشابه سناریوی ۱ در نظر گرفته شد. نوآوری این پژوهش در ارائه یک روش‌شناسی برای تخمین مکانی شاخص کسری آب با تفکیک مکانی بالا با استفاده از مدل‌های یادگیری ماشین و تصاویر ماهواره‌های سنتینل–۲ و لندست–۸ است. نتایج نشان داد که در سناریوی ۲ با درنظرگرفتن اطلاعات حرارتی، شاخص کسری آب با دقت مطلوبی در مراحل مختلف رشد گیاه تخمین زده شد. در این راستا مدل ANN با شاخص DC و KGE به‌ترتیب برابر ۰/۷۱۸ و ۰/۸۱۸ بهترین عملکرد را نسبت به مدل‌های SVR و RF نشان داد.

استناد: شرقی، سروش و زین‌العابدین، امین (۱۴۰۵). تخمین شاخص کسری آب با استفاده از تصاویر ماهواره لندست–۸ و سنتینل–۲ و مدل‌های یادگیری ماشین. *نشریه مدیریت آب و آبیاری*، ۱۶ (۳)، ۵۸۱–۶۰۶. DOI: https://doi.org/10.22059/jwim.2026.412422.1295

ناشر: مؤسسه انتشارات دانشگاه تهران.

© نویسندگان.

۱. مقدمه و پیشینه پژوهش

شاخص‌های تنش آبی امکان ارزیابی دقیق‌تر و لحظه‌ای‌تری از وضعیت آبی گیاهان را فراهم کرده و زمینه تصمیم‌گیری آبیاری را بهینه‌تر می‌سازند. به‌کارگیری این شاخص‌ها در فرایند آبیاری، نه‌تنها موجب افزایش راندمان تولید محصولات کشاورزی می‌شود، بلکه برداشت‌های غیرضروری آب را نیز کاهش داده و در راستای مدیریت عرضه محور آب و حفظ بلندمدت منابع آب، نقشی مؤثر دارد (Parkash & Singh, 2020). در این راستا، شاخص تنش آبی گیاه (CWSI)[۱] نخستین‌بار براساس نرمال‌سازی اختلاف دمای کانوپی و هوا و با تعریف شرایط مرزی مرطوب و خشک توسط Idso *et al.* (1981) معرفی شد.

اگرچه شاخص CWSI به‌دلیل دقت و کارایی مناسب، به‌طور گسترده در زمان‌بندی آبیاری مورداستفاده قرار گرفته است، اما عدم تراکم کامل پوشش گیاهی، به‌ویژه در مراحل ابتدایی رشد، یکی از مهم‌ترین محدودیت‌های کاربرد این شاخص محسوب می‌شود (Qin *et al.*, 2021). به‌منظور رفع این محدودیت، Moran *et al.* (1994) شاخص کسری آب (WDI)[۲] را توسعه دادند که امکان برآورد تنش آبی را در شرایط پوشش گیاهی کامل و ناقص فراهم می‌سازد.

محاسبه دقیق WDI وابسته به تخمین تبخیرتعرق گیاه (ET) است (Antoniuk *et al.*, 2021). روش‌های سنجش از دور کارایی بهتری در اندازه‌گیری ET در شرایط عدم دسترسی به اطلاعات دقیق هواشناسی و یا ابزارهای میدانی مانند لایسیمتر را نشان داده‌اند. در این راستا مطالعات متعددی اهمیت استفاده از سنجش از دور برای تخمین ET و پایش مصرف آب به‌طور مؤثر را نشان داده است (Rahmani *et al.*, 2020; Sharghi *et al.*, 2023). روش‌های مبتنی بر بیلان انرژی مهم‌ترین رویکرد در دورسنجی ET به‌شمار می‌رود (Sishodia *et al.*, 2020).

الگوریتم سبال (SEBAL)[۳] از جمله نام آشناترین الگوریتم‌های مبتنی بر بیلان انرژی برای دورسنجی تبخیر–تعرق با استفاده از ماهواره‌های سری لندست[۴] هستند که اولین بار توسط Bastiaanssen (1998) در هلند توسعه داده شد. سپس الگوریتم METRIC توسط Allen *et al.* (2007) در دانشگاه آیداهو به‌عنوان مدل بهبود یافته SEBAL توسعه یافت. METRIC مزایای متعددی نسبت به SEBAL در مناطق خشک و نیمه‌خشک دارد از جمله رویکرد این روش در برآورد ET مرجع براساس داده‌های هواشناسی است، به‌طوری‌که امکان برآورد دقیق‌تر ET لحظه‌ای در بازه‌های زمانی طولانی‌تر را فراهم می‌آورد (Allen *et al.*, 2011; Reyes-Gonzalez *et al.*, 2017).

از سوی دیگر، مدل‌های یادگیری ماشین (ML)[۵] به‌عنوان ابزاری نوین برای تخمین مستقیم مؤلفه‌های مرتبط با آبیاری کشاورزی مانند رطوبت خاک و ET با استفاده از تصاویر ماهواره‌ای معرفی شده است (Sedighi *et al.*, 2024). این مدل‌ها می‌توانند براساس داده‌های سنجش از دور موجود آموزش ببینند و الگوهای پیچیده میان بازتابندگی سطح در طول موج‌های مختلف و ET را تشخیص دهند. با این رویکرد، ET به‌طور مستقیم با دقت قابل‌قبولی بدون نیاز به به‌کارگیری الگوریتم‌های پیچیده با پارامترهای دارای عدم قطعیت فراوان و یا روش‌های مبتنی بر معادلات تجربی، به‌طور گسترده در سطح یک مزرعه تخمین زده می‌شود. در این راستا، Neissi *et al.* (2021) از مدل‌های ML مبتنی بر درخت تصمیم برای برقراری روابط خطی بین ET و پارامترهای سنجش از دور مانند آلبدو[۶]، امیسیویتی[۷] و شاخص گیاهی NDVI[۸] استفاده کردند. هم‌چنین، Sharghi & Zeynolabedin (2025) با استفاده از تحلیل تصاویر ماهواره‌ی لندست–۸ به تخمین تصاویر WDI پرداختند و از این داده‌ها برای واسنجی و صحت‌سنجی مدل‌های ML استفاده نمودند. نتایج پژوهش مذکور بر کارایی مطلوب مدل‌های ML آموزش دیده با داده‌های سنجش از دور برای تخمین WDI دلالت دارد. با وجود پژوهش‌های مذکور همچنان کاربرد مدل‌های مختلف ML در تعیین تنش آبی گیاهان با استفاده توأمان از مزیت‌های تصاویر ماهواره‌های مختلف در سطح مزرعه با تفکیک مکانی بالا به‌ویژه در محصولات باغی با محدودیت مواجه است. این مهم ضرورت مطالعات جامع‌تر برای ارزیابی و بهبود اثربخشی این مدل‌ها را در پایش تنش آبی محصولات باغی تبیین می‌کند.

یکی از نوآوری‌های کلیدی این پژوهش، استفاده هم‌زمان و هدفمند از تصاویر ماهواره‌ای سنتینل-۲ [۹] و لندست-۸ است، به‌گونه‌ای که نقاط قوت هر یک از این ماهواره‌ها به‌صورت مکمل موردبهره‌برداری قرار گرفته‌اند. درحالی‌که ماهواره لندست-۸ با دارابودن باند حرارتی، اطلاعات ضروری مربوط به دمای سطح زمین و فرایندهای تبخیر-تعرق را فراهم می‌کند، ماهواره سنتینل-۲ با تفکیک مکانی بالاتر (۱۰ متر) در باندهای طیفی مرئی و فروسرخ نزدیک، امکان پایش دقیق‌تر ناهمگنی مکانی پوشش گیاهی را مهیا می‌سازد. ترکیب این دو منبع داده، تولید نقشه‌های شاخص WDI با تفکیک مکانی بالا را امکان‌پذیر کرده و محدودیت رایج رزولوشن مکانی پایین در مطالعات پیشین مبتنی بر تصاویر حرارتی را تا حد زیادی برطرف می‌کند.

علاوه بر این، چارچوب پیشنهادی با استفاده از مدل‌های ML، بخشی از محدودیت ذاتی شاخص WDI در مناطق با پوشش گیاهی پراکنده یا ناهمگن را کاهش می‌دهد، چراکه مدل‌ها قادرند اثرات متقابل بین باندهای طیفی، وضعیت پوشش گیاهی و شرایط حرارتی سطح را به‌صورت ضمنی در فرایند یادگیری لحاظ کنند. این ویژگی، به‌ویژه در باغات پسته که دارای ساختار مکانی ناهمگن، فواصل کاشت نامنظم و تغییرات قابل‌توجه در سن و رقم درختان هستند، اهمیت ویژه‌ای دارد. هم‌چنین، استفاده از مجموعه‌ای گسترده از تصاویر ماهواره‌ای در بازه‌های زمانی مختلف، این امکان را فراهم می‌کند تا تأثیر مراحل فنولوژیکی رشد گیاه، تفاوت ارقام، سن درختان و شیوه‌های مختلف مدیریت آبیاری در فرایند واسنجی و تعمیم‌پذیری مدل‌های ML لحاظ شود. این امر موجب افزایش پایداری مدل‌ها و قابلیت تعمیم آن‌ها در شرایط واقعی بهره‌برداری می‌شود.

در نهایت، با مقایسه عملکرد چندین مدل ML پرکاربرد شامل شبکه عصبی مصنوعی (ANN)[۱۰]، رگرسیون بردار پشتیبان (SVR)[۱۱] و جنگل تصادفی (RF)[۱۲]، این پژوهش مؤثرترین ساختار مدل‌سازی برای تخمین WDI در مقیاس مکانی بالا را شناسایی می‌کند. نتایج حاصل می‌تواند زمینه‌ساز توسعه ابزارهای عملیاتی، ساده و قابل‌دسترس برای پایش تنش آبی و پشتیبانی از تصمیم‌گیری در مدیریت به‌هنگام آبیاری در کشاورزی دقیق باشد، بدون آنکه کاربران نهایی نیازمند دانش تخصصی در حوزه سنجش از دور یا مدل‌های پیچیده فیزیکی باشند.

با وجود توسعه روزافزون استفاده از سنجش از دور در پایش ET و WDI، پژوهش حاضر از چهار جنبه کلیدی نسبت به مطالعات پیشین دارای نوآوری است. نخست، این مطالعه با ترکیب باندهای طیفی سنتینل-۲ و باند حرارتی لندست-۸، به‌ترتیب از مزایای تفکیک مکانی بالا (۱۰ متر) و داده‌های حرارتی به‌طور هم‌زمان برای تخمین تصاویر WDI بهره برده است؛ رویکردی که وجه تمایز این پژوهش با مطالعاتی نظیر Sharghi & Zeynolabedin (2025) و Neissi *et al.* (2021) است که از تصاویر یک ماهواره استفاده کرده‌اند. دوم، در این پژوهش از مدل‌های ML جهت تشخیص روابط غیرخطی و پیچیده میان باندهای ماهواره‌ای و شاخص WDI و محاسبه مستقیم آن استفاده شده است که نسبت به روش‌های تجربی-فیزیکی مورداستفاده در پژوهش‌هایی مانند Mokhtari *et al.* (2019) برتری دارد. سوم، یک مقایسه نظام‌مند میان مدل‌های مختلف ML انجام شده است تا نقاط قوت و ضعف هر مدل در شرایط و سناریوهای مختلف ورودی تعیین گردد. در نهایت، برخلاف پژوهش‌های پیشین (مانند Sedighi *et al.*, 2024 وRahmani *et al.*, 2020) که به‌طورعمده بر پایش تنش آبی در محصولات زراعی تمرکز داشته‌اند، این پژوهش به واسنجی و صحت‌سنجی مدل‌های ML برای تخمین WDI در محصولات باغی (باغات پسته) می‌پردازد که دارای پیچیدگی‌های ساختاری و فیزیولوژیک متفاوتی هستند.

۲. روش‌شناسی پژوهش

شکل (۱) نمودار روندنمای مراحل مختلف این پژوهش را نشان می‌دهد.

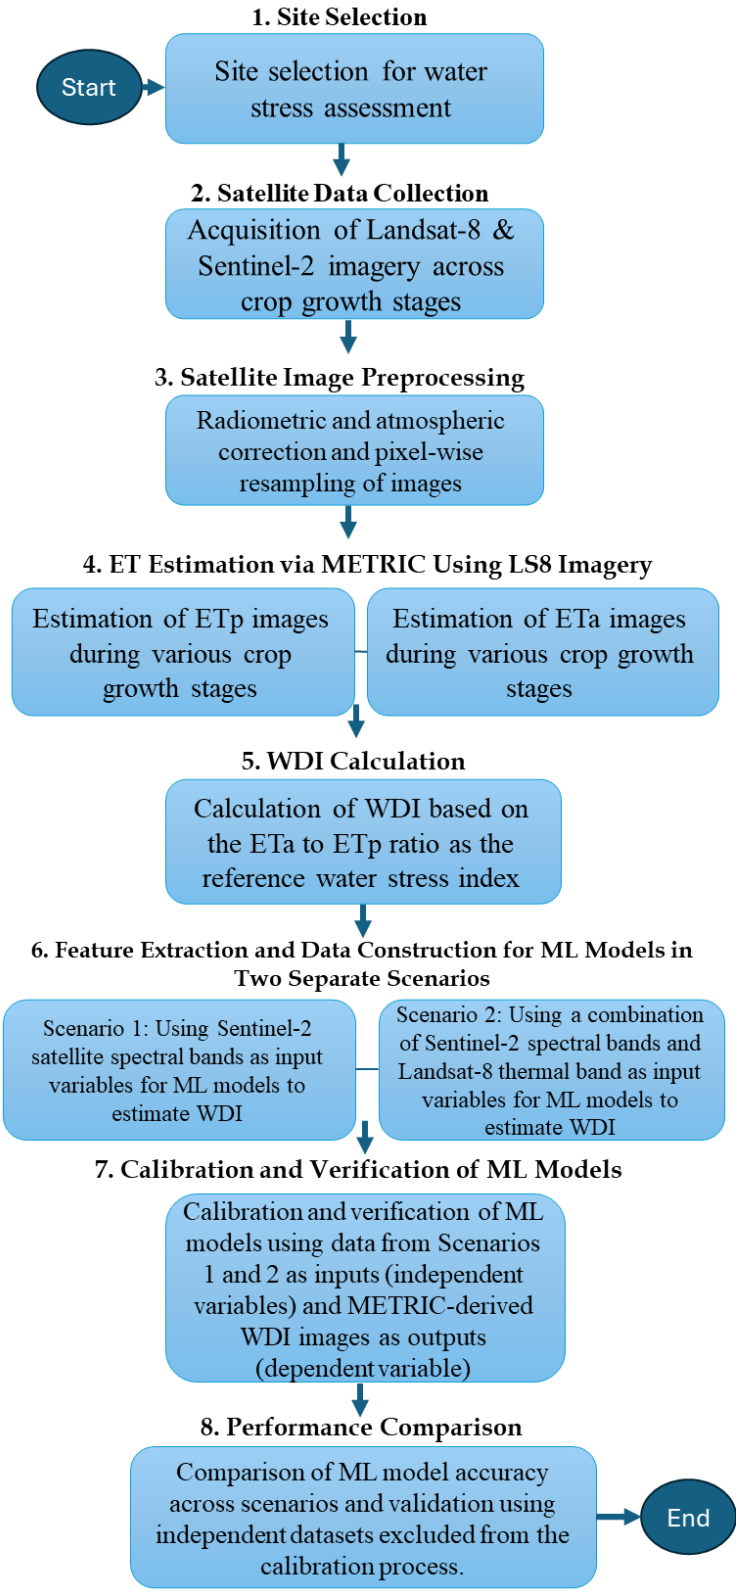


Figure 1. Flowchart of the current research methodology

هدف از این پژوهش، برآورد مکانی–زمانی WDI با بهره‌گیری از داده‌های سنجش از دور و مدل‌های ML، به‌منظور پشتیبانی از فرایند مدیریت به‌هنگام آبیاری در باغ‌های پسته است. در این راستا، در گام نخست ETa و ETp با استفاده از الگوریتم مبتنی بر توازن انرژی METRIC و تصاویر ماهواره‌ای لندست–۸ استخراج شد. محاسبات ET در دوره‌های مختلف رشد باغ‌های پسته انجام گرفت تا تغییرات زمانی وضعیت تنش آبی به‌صورت پیکسل‌محور ثبت شود. در ادامه، شاخص WDI براساس مقادیر ETa و ETp محاسبه و به‌عنوان متغیری کمی برای بیان شدت نسبی کمبود آب در سطح مزرعه مورداستفاده قرار گرفت. سپس، به‌منظور توسعه روشی کارآمد و قابل تعمیم برای برآورد سریع WDI، از داده‌های حاصل برای واسنجی و صحت‌سنجی مدل‌های ML استفاده شد. نتایج این مراحل امکان پایش مکانی و زمانی تنش آبی در باغ‌های پسته را فراهم کرده و می‌تواند مبنای تحلیل‌های مدیریتی و تصمیم‌سازی در سطوح بالاتر مدیریت آبیاری قرار گیرد.

۲. ۱. الگوریتم METRIC

الگوریتم METRIC به‌عنوان یک مدل تحلیل تصویری مبتنی بر داده‌های ماهواره‌ای، ETa را از طریق معادله بیلان انرژی و باندهای مختلف طیفی و حرارتی ماهواره لندست–۷ و ۸ محاسبه می‌کند. این الگوریتم به‌طور خاص برای برآورد ETa در مناطق گسترده‌ای با تنوع پوشش گیاهی و شرایط مختلف رطوبت خاک، مناسب و کارآمد است. پایه نظریMETRIC، معادله بیلان انرژی سطح زمین است (معادله ۱) که انرژی دریافتی را در قالب جریان‌های مختلف، از جمله شار گرمای محسوس، گرمای نهان و گرمای ذخیره‌شده، تقسیم‌بندی می‌کند (Allen *et al*., 2007).

$$\lambda E_{ins} = R_n - G - H$$ رابطه ۱)

در این معادله، λE شار گرمای نهان لحظه‌ای در زمان عبور ماهواره (W/m^2) است که انرژی مصرفی توسط ET را نشان می‌دهد. R_n نشان‌دهنده جریان تابش خالص ورودی از سمت خورشید به سمت زمین است که انرژی خالص ورودی به سطح زمین را نشان می‌دهد. G و H به‌ترتیب نشان‌دهنده شار گرمای خاک و شار گرمای محسوس هستند که به‌ترتیب انرژی مصرف شده توسط سطح زمین و انرژی مبادله‌شده بین سطح و جو را نشان می‌دهند. جزئیات محاسباتی متغیرهای مذکور به Allen *et al*. (2007) مراجعه شود.

تبخیر–تعرق لحظه‌ای (ET_{inst}) برحسب میلی‌متر بر ساعت به‌صورت زیر محاسبه می‌شود:

$$ET_{inst} = \lambda E_{ins} \frac{3600}{\lambda \rho_w}$$ رابطه ۲)

در این رابطه، λ گرمای نهان تبخیر آب (معادل ۲/۴۵ Mj/kg) و ρ_w چگالی آب (معادل ۱۰۰۰ kg/m^3) است. برای تبدیل ET_{inst} به تبخیر–تعرق واقعی روزانه (ET_{24})، الگوریتم METRIC فرض می‌کند که نسبت ET_{inst} به $ET_{r,inst}$ در طول روز ثابت است:

$$ET_rF = \frac{ET_{inst}}{ET_{r,inst}}$$ رابطه ۳)

در این معادله، ET_rF نشان‌دهنده کسر تبخیر–تعرق مرجع است. $ET_{r,inst}$ تبخیر–تعرق مرجع لحظه‌ای (mm/hr) در زمان عبور ماهواره است که معمولاً برای یک محصول مرجع فرضی (مانند یونجه) با استفاده از معادله استانداردی مانند معادله پنمن–مانتیث ASCE محاسبه می‌شود.

در نهایت، ET_{24} (mm/day) براساس معادله (۴) محاسبه می‌شود:

$$ET_{24} = ET_rF \times ET_{r,24}$$ رابطه ۴)

که در آن، $ET_{r,24}$ نشان‌دهنده تبخیر–تعرق مرجع تجمعی ۲۴ ساعته (mm/day) برای همان روز است که از داده‌های هواشناسی ساعتی یا روزانه و معادله پنمن–مانتیث محاسبه می‌شود.

۲. ۲. مدل شبکه عصبی مصنوعی (ANN)

مدل ANN به‌عنوان یک مدل ML می‌تواند برای مسائل رگرسیونی جهت تعیین و تخمین رابطه میان متغیرهای مستقل و وابسته یک مسئله به‌کار گرفته شود. در این پژوهش از این مدل برای تخمین WDI از روی تصاویر مربوط به باندهای طیفی مختلف ماهواره سنتینل-۲ و لندست ۸ استفاده می‌شود. ANN استفاده‌شده در این مطالعه از نوع پرسپترون چند لایه (MLP)[۱۳] با معماری پیش‌خور[۱۴] است که با استفاده از الگوریتم بازگشتی[۱۵] آموزش داده شده است. این ساختار برای حل مسائل رگرسیون به‌دلیل توانایی آن در شبیه‌سازی روابط پیچیده و غیرخطی بین متغیرهای ورودی و خروجی مناسب است (شکل ۲).

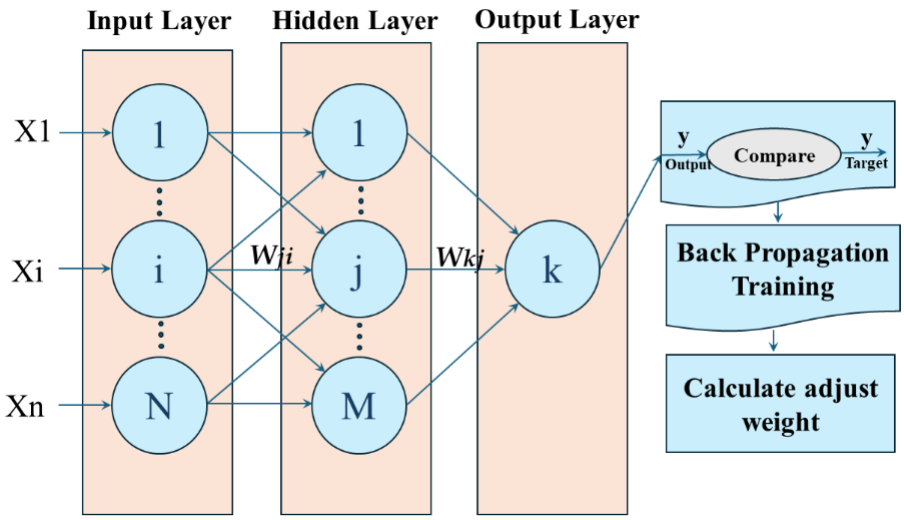


Figure 2. Architecture of the Artificial Neural Network used in this study

۲. ۳. مدل رگرسیون بردار پشتیبان (SVR)

در این پژوهش به‌عنوان یک مدل ML دیگر از مدل SVR برای تخمین WDI استفاده شده است. برای آموزش این مدل از تصاویر باندهای طیفی و حرارتی استخراج‌شده از ماهواره سنتینل-۲ و لندست-۸ به‌عنوان داده‌های ورودی و تصاویر WDI محاسبه‌شده توسط الگوریتم METRIC به‌عنوان داده‌های خروجی یا Labelها استفاده شده است. SVR یک مدل یادگیری نظارت‌شده کارآمد است که توانایی بالایی در حل مسائل رگرسیون غیرخطی دارد. مدل SVR این هدف را با نگاشت داده‌های ورودی به یک فضای با ابعاد بالاتر از طریق توابع هسته[۱۶] انجام می‌دهد.

هدف مدل SVR یافتن یک تابع $f(x)$ است (معادله ۵) که بتواند مقادیر هدف y_i را با دقتی قابل‌قبول پیش‌بینی کند، به‌طوری که انحراف پیش‌بینی‌ها از مقادیر واقعی بیش‌تر از یک مقدار مشخص ε نباشد.

رابطه ۵) $$f(x) = \langle w, \phi(x) \rangle + b$$

در این معادله، x بردار ویژگی ورودی است (مانند باندهای طیفی تصاویر ماهواره‌ای). w نیز بردار وزن است که مدل در طول فرایند آموزش آن را واسنجی می‌کند. $\Phi(x)$ یک نگاشت (تبدیل غیرخطی) است که بردار ورودی x را از فضای اصلی خود به یک فضای ویژگی جدید با ابعاد بالاتر منتقل می‌کند. هدف از این نگاشت، تبدیل روابط پیچیده و غیرخطی میان متغیرهای ورودی و خروجی به روابطی ساده‌تر و نزدیک به خطی در فضای جدید است. در این فضای ویژگی، مدل می‌تواند الگوهای موجود در داده‌ها را دقیق‌تر و آسان‌تر یاد بگیرد.

۲. ۴. مدل جنگل تصادفی (RF)

مدل RF یکی از روش‌های قدرتمند یادگیری گروهی[۱۷] است که توانایی بالایی در مدل‌سازی روابط پیچیده و غیرخطی دارد. این مدل با ساخت مجموعه‌ای از درخت‌های تصمیم به‌طور تصادفی و مستقل در فرایند آموزش و سپس با تلفیق و میانگین‌گیری پیش‌بینی‌های هر یک از آن‌ها پیش‌بینی نهایی خود را تولید می‌کند (Liaw & Wiener, 2002). با این رویکرد، RF نوسانات تصادفی داده‌ها را کاهش می‌دهد و از بیش‌برازش جلوگیری می‌کند. به‌دلیل پایداری بالا و توانایی در استخراج الگوهای پنهان در داده‌های پیچیده، مدل RF می‌تواند انتخاب ایده‌آلی برای پیش‌بینی WDI بر پایه داده‌های بازتاب طیفی–حرارتی محسوب شود.

ساختار اصلی مدل RF مبتنی بر درخت‌های تصمیم است که در مسائل رگرسیونی به آن‌ها درخت‌های رگرسیون[۱۸] گفته می‌شود. هر درخت از طریق تقسیم‌های بازگشتی در فضای داده‌های ورودی گسترش می‌یابد. این فضا در مطالعه حاضر شامل مقادیر باندهای طیفی استخراج‌شده از تصاویر ماهواره‌ای است. در هر گره m، با انتخاب یک ویژگی j و تعیین یک نقطه تقسیم s_j، داده‌ها به دو زیرمجموعه تفکیک می‌شود. هدف از این تقسیم، کاهش هرچه بیش‌تر واریانس متغیر هدف (WDI) در گره‌های حاصل از تقسیم است.

در درخت‌های رگرسیون، معیار رایجی برای انتخاب بهترین تقسیم، کمینه‌سازی مجموع مربعات خطا (SSE)[۱۹] درون هر گره است. اگر گره m شامل N_m نمونه آموزشی باشد، مقدار SSE آن با استفاده از معادله (۶) محاسبه می‌شود:

رابطه ۶) $$SSE_m = \sum_{i \in samples\ at\ node\ l\ m} (y_i - \bar{y}_m)^2$$

در معادله، y_i مقدار واقعی WDI برای iامین نمونه آموزشی در گره m است. $\bar{y}_m$ نیز میانگین مقدار WDI همه N_m نمونه آموزشی در گره m را نشان می‌دهد.

۲. ۵. محاسبه WDI

پس از برآورد ETa و ETp با استفاده از الگوریتم METRIC، شاخص WDI به‌منظور کمی‌سازی شدت تنش آبی محاسبه شد. مفهوم WDI نخستین بار توسط Moran *et al.* (1994) به‌عنوان توسعه‌ای از شاخص CWSI و بر پایه چارچوب فیزیکی تبادل انرژی–دما معرفی شد. در مطالعات بعدی، به‌ویژه در چارچوب الگوریتم‌های انرژی‌مبنا، این شاخص به‌صورت رابطه‌ای صریح برحسب نسبت ETa به ETp بازتعریف شد. بر این اساس، در پژوهش حاضر WDI مطابق معادله (۷) محاسبه شد (Antoniuk *et al.*, 2021):

رابطه ۷) $$WDI = 1 - \frac{ET_a}{ET_p}$$

۲. ۶. محدوده مطالعاتی

دشت رفسنجان در بخش جنوب‌شرقی ایران، استان کرمان، بین طول‌های جغرافیایی ۵۴ درجه و ۵۲ دقیقه تا ۵۶ درجه و ۳۴ دقیقه شرقی و عرض‌های جغرافیایی ۲۹ درجه و ۵۱ دقیقه تا ۳۰ درجه و ۳۱ دقیقه شمالی واقع شده است (شکل a-c–۳). این منطقه با وسعتی حدود ۱،۲۴۲،۱۰۰ هکتار، به‌طورعمده به کشت پسته اختصاص دارد که فعالیت اقتصادی–کشاورزی اصلی آن محسوب می‌شود. دشت رفسنجان نقش حیاتی در تولید و صادرات پسته ایران ایفا می‌کند. میانگین بارندگی سالانه در نواحی پست ۶۰ میلی‌متر و در نواحی مرتفع تا ۱۲۰ میلی‌متر در محدوده مطالعاتی گزارش شده است. هم‌چنین نرخ ET حدود ۳۰۰۰ میلی‌متر در سال است. متوسط سالانه درجه حرارت در ارتفاعات محدوده ۱۴/۷ و در دشت ۱۷/۷ درجه سانتی‌گراد است. هم‌چنین، بیش‌ترین درجه حرارت متوسط ماهانه در تیرماه ۲۹/۴ و کم‌ترین آن در دی ماه ۳/۸ درجه

سانتی‌گراد است (IRWRMC, 2011). همان‌طورکه توسط شرکت مدیریت منابع آب ایران (IRWRMC, 2011) گزارش شده است، بیلان آب زیرزمینی نشان‌دهنده برداشت ناپایدار از منابع آب‌زیرزمینی بیش از ظرفیت تجدیدپذیری در این منطقه است. اجرای روش‌های مدیریت آبیاری کارآمد در باغات رفسنجان می‌تواند به‌عنوان یک استراتژی مؤثر برای مدیریت منابع آب زیرزمینی محسوب شود.

در این مطالعه، برای برداشت تصاویر ماهواره‌ای یک محدوده مناسب از باغات پسته دشت رفسنجان انتخاب شده است که شامل باغات پسته با تنوع در عوامل مختلف زراعی و مدیریتی است (شکل d–۳). این عوامل شامل اندازه باغ، جنس خاک، سن درخت، نوع رقم پسته، شیوه‌های مختلف آبیاری و دسترسی به منابع آب زیرزمینی با کمیت و کیفیت متفاوت است. این تنوع طیف گسترده‌ای از شرایط بیوفیزیکی را شامل می‌شود به‌طوری‌که آموزش مدل‌های ML به‌نحوه مطلوبی صورت می‌گیرد. ناهمگونی محدوده مطالعاتی، تغییرپذیری دنیای واقعی را منعکس می‌کند و در نتیجه تعمیم‌پذیری و قدرت عملکرد مدل‌های آموزش‌دیده را افزایش می‌دهد.

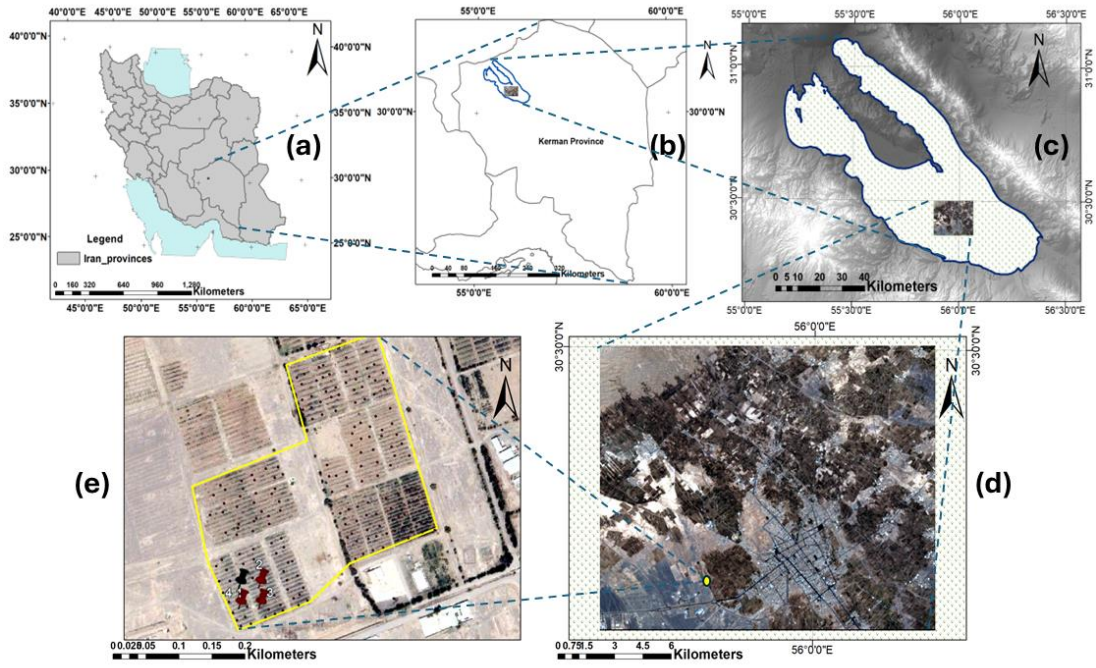


Figure 3. Geographic location of the study area ((a) Iran, (b) Kerman Province, (c) Rafsanjan Plain, (d) Imaging extent, (e) Area of optimally irrigated orchards)

در این پژوهش از داده‌های مربوط به محدوده‌ای خاص استفاده‌شده که در مجاورت مرکز تحقیقات پسته قرار دارد (شکل e–۳). نهال‌های کاشته‌شده در این محدوده شامل ترکیبی از ارقام و سنین مختلف هستند که تحت شرایط آبیاری کامل و بهینه کشت شده‌اند، به‌طوری‌که میزان تنش آبی آن‌ها در طول فصل رشد تقریباً صفر است. برای آموزش مدل‌های ML، مقدار شاخص WDI برای نمونه‌های این محدوده به‌طور مصنوعی برابر با صفر در نظر گرفته شد (به‌عنوان شرایط مرزی مدل). این عدد نشان‌دهنده شرایط کاملاً ایده‌آل و فاقد هرگونه تنش آبی است. به‌کارگیری این داده‌ها با مقدار WDI ثابت‌شده، به مدل کمک می‌کند تا بهتر بین شرایط پرتنش و بدون تنش تمایز قائل شود و دقت پیش‌بینی در مناطق کم‌پوشش را بهبود دهد.

دقت الگوریتم METRIC در برآورد ETa برای باغ‌های پسته دشت رفسنجان توسط Safari *et al*. (2023) ارزیابی شده است. در آن مطالعه، عملکرد الگوریتم با استفاده از داده‌های لایسیمتری موجود در منطقه موردبررسی قرار گرفت. داده‌های لایسیمتری مورداستفاده مربوط به چهار ایستگاه لایسیمتر زه‌کشی (نقاط مرجع ۱ تا ۴) در باغ‌های پسته بوده که توسط مرکز تحقیقات پسته طی سال‌های ۲۰۰۲ تا ۲۰۰۳ اندازه‌گیری و ثبت شده‌اند. این داده‌ها به‌صورت تبخیر- تعرق میانگین در بازه‌های زمانی ۲۰ روزه ارائه شده‌اند. به‌منظور مقایسه داده‌های زمینی با نتایج الگوریتم METRIC، ابتدا مقادیر ETa با استفاده از الگوریتم METRIC برای تاریخ‌های موجود تصاویر ماهواره‌ای محاسبه شد. سپس مقادیر روزانه حاصل، در بازه‌های زمانی ۲۰ روزه میانگین‌گیری گردید تا با مقادیر لایسیمتری مشاهده‌شده قابل مقایسه باشند. شکل (۴) مقایسه‌ای بین ETa روزانه برآوردشده توسط الگوریتم METRIC و مقادیر مشاهده‌شده لایسیمتری را در به‌صورت میانگین دوره‌های ۲۰ روزه نشان می‌دهد. نتایج نشان می‌دهد که شاخص DC، RMSE و KGE به‌ترتیب برابر با ۰/۷۷، ۰/۳۷ میلی‌متر در روز و ۰/۷۵ به‌دست آمد که بیانگر عملکرد قابل‌قبول الگوریتم METRIC در برآورد ETa برای شرایط منطقه موردمطالعه است (Safari *et al*., 2023).

در این پژوهش، شاخص WDI براساس خروجی‌های الگوریتم METRIC محاسبه شده و به‌عنوان داده مرجع برای آموزش مدل‌هایML مورداستفاده قرار گرفته است. بنابراین، هرگونه خطای احتمالی در الگوریتم METRIC به‌طورمستقیم بر خطای نهایی مدل‌های ML تأثیر می‌گذارد. با این‌حال، به‌دلیل نبود داده‌های میدانی گسترده از تنش آبی واقعی گیاه در منطقه، استفاده از خروجی یک مدل فیزیکی معتبر مانند METRIC به‌عنوان داده مرجع رویکردی متداول در مطالعات سنجش از دور محسوب می‌شود. با وجود این، اتکا به خروجی یک مدل به‌عنوان داده مرجع می‌تواند به‌عنوان یکی از محدودیت‌های پژوهش در نظر گرفته شود. بنابراین پیشنهاد می‌شود در مطالعات آینده، در صورت امکان از داده‌های میدانی مرتبط با تنش آبی گیاه (مانند اندازه‌گیری‌های فیزیولوژیک یا رطوبت خاک) برای آموزش یا ارزیابی مدل‌ها استفاده شود.

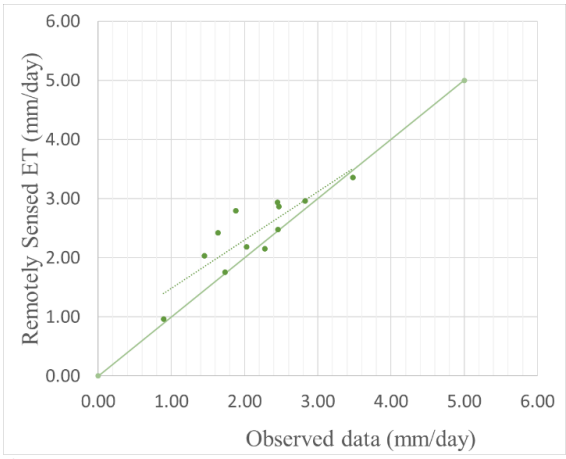


Figure 4. Comparison of lysimeter-measured ETa versus remotely sensed ETa (Adapted from Safari *et al*., 2023)

۲. ۷. داده‌های پژوهش

تصاویر ماهواره‌ای مورداستفاده در این مطالعه از مجموعه داده Landsat 8 OLI-TIRS Collection 2, Level 2 از طریق سامانه Earth Explorer و Sentinel-2, L2A از طریق سامانه Copernicus تهیه شدند. برای هرکدام از این ماهواره‌ها این مجموعه شامل ۱۲ تصویر متعلق به بازه زمانی سال‌های ۲۰۲۲ تا ۲۰۲۳ است. تمامی تصاویر ماهواره لندست-۸ و

سنتینل-۲ دارای تفکیک مکانی به‌ترتیب ۳۰ و ۱۰ متر بوده و پیش‌پردازش شامل تصحیح اتمسفری و رادیومتری بر روی آن‌ها اعمال شده است. برای جلوگیری از در نظرگرفته‌شدن داده‌های مربوط به شوره‌زارها و زمین‌های بایر در مدل‌های ML، پیکسل‌های مربوطه به این نواحی با استفاده از ابزار ماسک و شاخص گیاهی NDVI از تصاویر حذف شده‌اند. هم‌چنین به‌منظور اطمینان از کیفیت داده‌ها، تنها تصاویری با پوشش ابر کم‌تر از ۲ درصد انتخاب شدند. تاریخ اخذ تصاویر هر دو ماهواره به شرح زیر است: ۵ می ۲۰۲۲، ۱۵ ژوئن ۲۰۲۲، ۱۰ ژوئیه ۲۰۲۲، ۱۱ اوت ۲۰۲۲، ۱۸ سپتامبر ۲۰۲۲، ۳ اکتبر ۲۰۲۲، ۱۲ آوریل ۲۰۲۳، ۱۲ می ۲۰۲۳، ۱۵ ژوئن ۲۰۲۳، ۸ ژوئیه ۲۰۲۳، ۲ اوت ۲۰۲۳ و ۱۲ سپتامبر ۲۰۲۳. هر تصویر ماهواره لندست-۸ استفاده‌شده در این پژوهش شامل هفت باند طیفی است که باندهای ۲ الی ۷ و ۱۰ که به‌ترتیب شامل باند Blue، Green، Red، Near Infrared، SWIR1 و SWIR2 و باند حرارتی Thermal Infrared جهت برآورد دمای سطح را در بر می‌گیرد. هم‌چنین تصاویر ماهواره سنتینل-۲ شامل باندهای ۲ الی ۴، ۸، ۱۱ و ۱۲ که به‌ترتیب شامل باند Blue، Green، Red، Near Infrared، SWIR1 و SWIR2 است. تصاویر ماهواره‌ای لندست-۸ و سنتینل-۲ مورداستفاده در این پژوهش از روزهای مشترک برداشت شده‌اند.

شایان ذکر است که تصاویر هر دو ماهواره لندست-۸ و سنتینل-۲ در تاریخ‌های یکسان (بیان‌شده در بالا) تهیه شده‌اند. این دو ماهواره در مدارهای خورشیدآهنگ قرار دارند و حدوداً در ساعت ۱۰:۳۰ صبح به وقت محلی از استوا عبور می‌کنند. اختلاف زمانی چند دقیقه‌ای در میانه روز، تغییرات شدیدی در زاویه تابش خورشید، شرایط اتمسفری و ... ایجاد نمی‌کند (Claverie *et al*., 2018). بنابراین این اختلاف زمانی بین تصاویر دو ماهواره تأثیر قابل‌توجهی بر نتایج نهایی WDI ندارد. به علاوه، متغیرهای ETrF و ET24 که مبنای محاسبه WDI هستند، براساس روش Allen *et al*. (2007) در طول ساعات روز ثابت فرض شده‌اند. در نتیجه تصاویر ماهواره لندست-۸ و سنتینل-۲ که مربوط به یک روز با فاصله زمانی کم‌تر از ۱۵ دقیقه‌ای هستند (جدول ۱) بیان‌کننده شرایط یکسان برای محاسبه WDI روزانه است. بنابراین، تلفیق داده‌های این دو سنجنده برای محاسبه WDI از نظر علمی معتبر است.

Table 1. Satellite Imaging Times in Iran Local Time (AM)

	May 5, 2022	June 15, 2022	July 10, 2022	August 11, 2022	September 18, 2022	October 3, 2022	April 12, 2023	May 12, 2023	June 15, 2023	July 8, 2023	August 2, 2023	September 12, 2023
Landsat-8	10:39:21	10:39:45	10:39:21	10:39:57	10:39:44	10:39:21	10:39:45	10:39:21	10:39:21	10:39:57	10:39:44	10:39:21
Sentinel-2	10:26:19	10:26:19	10:26:41	10:26:31	10:26:31	10:28:01	10:26:21	10:26:29	10:26:29	10:26:29	10:26:31	10:26:31

ازآنجاکه الگوریتم METRIC با باندهای طیفی ماهواره لندست سازگاری دارد، برای برآورد ETa و ETp و در نهایت محاسبه شاخص WDI=1-ETa/ETp (به‌عنوان داده آموزشی مدل‌های ML)، تنها از تصاویر ماهواره لندست-۸ استفاده شد. برای استفاده هم‌زمان از داده‌های لندست-۸ و سنتینل-۲ در سناریوی ۲، تصاویر لندست-۸ (با تفکیک مکانی ۳۰ متر) و نقشه‌های WDI حاصل از METRIC به تفکیک مکانی ۱۰ متر بازنمونه‌گیری شدند تا با تفکیک مکانی سنتینل-۲ هم‌سطح شوند. هم‌چنین، باندهای ۱۱ و ۱۲ سنتینل-۲ که دارای تفکیک ۲۰ متر بودند، با استفاده از درون‌یابی دوخطی[۲۰] به تفکیک ۱۰ متر بازنمونه‌گیری[۲۱] شدند. این روش بازنمونه‌گیری که در فضای نرم‌افزار Arc GIS استفاده شده است، با بهره‌گیری از میانگین‌گیری وزنی از چهار پیکسل مجاور، از بروز خطاهای ناشی از تغییر ناگهانی مقادیر پیکسلی جلوگیری کرده و پیوستگی طیفی و فضایی لایه‌ها را در رزولوشن ۱۰ متر حفظ می‌کند. استفاده از این روش، عدم قطعیت‌های ناشی از انطباق داده‌های با رزولوشن‌های متفاوت را به حداقل رسانده و بستری پایدار برای آموزش دقیق الگوریتم‌های ML فراهم می‌آورد (Parker *et al*., 1983). شایان ذکر است درصورت استفاده از تصاویر ماهواره لندست-۸ سطح ۱

(Level 1) می‌بایست بازنمونه‌گیری برای باند حرارتی جهت تبدیل رزولوشن مکانی ۱۰۰ متر به ۱۰ متر در شرایط استفاده هم‌زمان از باندهای هر دو ماهواره صورت گیرد.

تاریخ‌های اخذ تصاویر به‌گونه‌ای هدفمند انتخاب شدند تا تغییرات نیاز آبی درختان پسته در طول مراحل مختلف فنولوژیکی رشد، مطابق با تقویم ارائه‌شده توسط Goldhamer (2005)، به‌درستی بازتاب شوند. این تصاویر به‌عنوان ورودی اصلی الگوریتم METRIC برای برآورد ETa روزانه مورداستفاده قرار گرفتند. شکل (۴) تصاویر ETa روزانه تخمین‌زده‌شده را در محدوده مطالعاتی در تاریخ‌های مذکور نشان می‌دهد. زمان‌بندی دقیق در اخذ تصاویر برای ارزیابی دقیق تنش آبی گیاهان نقش حیاتی دارد، چرا که حساسیت مدل ML را که قرار است براساس این داده‌ها آموزش داده شود، به تغییرات زمانی در فیزیولوژی گیاه را به‌شکل قابل‌توجهی افزایش می‌دهد. با هماهنگ‌سازی برنامه زمانی اخذ تصاویر با مراحل کلیدی رشد، نظیر گسترش سایه‌انداز و بلوغ میوه، این روش‌شناسی امکان پایش دقیق نوسانات نیاز آبی در طول فصل رشد را فراهم می‌آورد.

همان‌طورکه بیان شد، تصاویر ماهواره‌ای استفاده‌شده در این پژوهش از نوع Level 2 بودند و بنابراین پیش‌پردازش اتمسفری آن‌ها از قبل انجام شده است. این مهم بخشی از نویز موجود در تصاویر ماهواره‌ای در باندهای مختلف ناشی از بخار آب موجود در اتمسفر را حذف می‌کند. هم‌چنین به‌منظور کاهش اثر نویز و افزایش کیفیت ورودی مدل‌ها، تصاویر دارای ابرناکی بیش از ۲ درصد حذف شده و ماسک ابر و سایه بر روی باندهای طیفی و حرارتی اعمال شده است. این رویکرد باعث افزایش پایداری و دقت نتایج در واسنجی و صحت‌سنجی مدل‌های ML شده است.

۳. یافته‌های پژوهش و بحث

در گام نخست، هدف دورسنجی ET_a و ET_p برای محدوده مطالعاتی است. برای این منظور از توسعه الگوریتم METRIC که توسط Safari *et al.* (2023) برای دورسنجی تصاویر ET_a روزانه در باغات پسته مناطق خشک و نیمه‌خشک پیشنهاد و آزمایش شده است استفاده شد. دلیل این انتخاب، دقت بالای این مدل در دورسنجی ET_a در باغات پسته است. در گام بعد، هدف محاسبه تصاویر WDI با استفاده از داده‌های تبخیر–تعرق روزانه حاصل از تصاویر ماهواره لندست–۸ و الگوریتم METRIC به‌عنوان تصاویر مرجع برای واسنجی و صحت‌سنجی مدل‌های ML در مراحل بعدی است. براساس نتایج پژوهش‌های Parodi & Gabriel (2002) و Mokhtari *et al.* (2019)، در شرایطی که تبخیر–تعرق پتانسیل رخ می‌دهد، سهم شار گرمای محسوس[۲۲] ناچیز بوده و می‌توان آن را نادیده گرفت. بنابراین در الگوریتم METRIC، با صفر درنظرگرفتن ترم مربوط به این شار (H=۰)، امکان تخمین تصاویر Etp فراهم می‌شود. به‌منظور ارزیابی صحت این فرض تئوریک در شرایط بومی منطقه موردمطالعه، H در محدوده باغ مرجع که تحت آبیاری تنظیم شده و بدون تنش آبی است، برآورد شد. براساس خروجی‌های به‌دست‌آمده برای دو تاریخِ تصویربرداریِ منتخب در دو سال ۲۰۲۲ و ۲۰۲۳ (شکل ۵)، مقادیر H در این ناحیه (محدوده باغات درون کادر سیاه رنگ) ناچیز یا نزدیک به صفر است. این شواهد نشان‌دهنده انطباق قابل‌قبول فرض H≈۰ با شرایط محلیِ باغاتِ سیراب است؛ امری که ضمن توجیه استفاده از این فرض در محاسبه ETp، احتمال بروز خطاهای سیستماتیک در تعیین شاخص WDI را به حداقل می‌رساند.

پس از محاسبه ET_a و ET_p تصاویر WDI در تاریخ‌های مختلف تولید شدند (شکل‌های ۶ و ۷). در این تصاویر پیکسل‌های با مقدار نزدیک به یک بیانگر شرایط بیشینه تنش آبی و پیکسل‌های با مقدار نزدیک به صفر معرف نواحی با شرایط کمینه تنش آبی هستند. هم‌چنین پیکسل‌های با رنگ آبی عمیق (مقادیر مطلقاً صفر) نشان‌دهنده نواحی بدون پوشش گیاهی (خاک برهنه) هستند که طی فرایند Masking از تصویر حذف شده و به‌صورت مقادیر NaN تعریف شده‌اند. در مجموع، نادیده‌گرفتن شار گرمای محسوس در برآورد ETp یک ساده‌سازی منطقی و

قابل‌قبول است که به‌ویژه در مناطقی با محدودیت داده برای محاسبات پیچیده‌تر، رویکردی ارزشمند و کاربردی محسوب می‌شود.

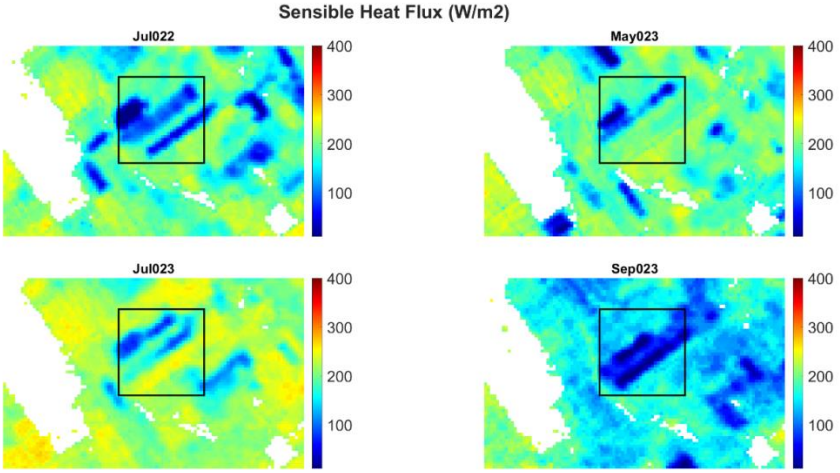


Figure 5. Estimated H over the reference lysimeter orchard

همان‌طورکه پیش‌تر بیان شد برای جلوگیری از بیش‌تخمین WDI و هم‌چنین جبران بایاس تولیدشده حاصل از فرض H=۰ در محاسبه ETp، مقادیر پیکسل‌های مربوط به محدوده باغات خوب آبیاری شده (شکل e–۳) به‌عنوان شرایط مرزی مدل‌های ML مقدار صفر اختصاص داده می‌شود.

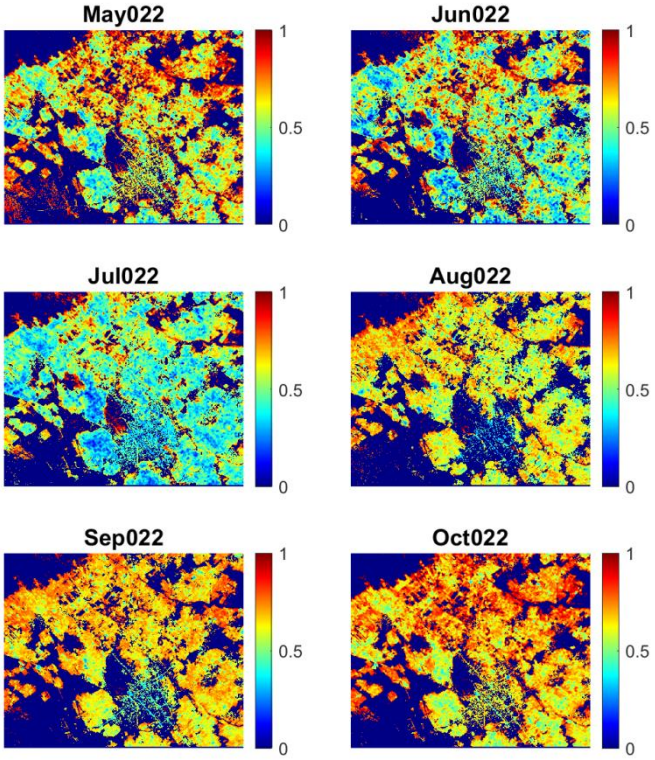


Figure 6. Calculated WDI maps for selected dates in 2022

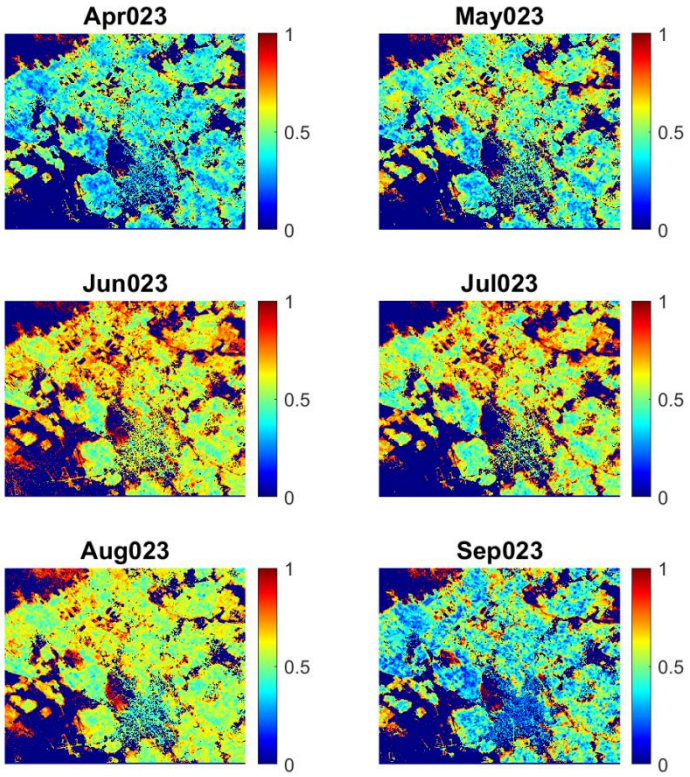


Figure 7. Calculated WDI maps for selected dates in 2023

در ادامه به واسنجی و صحت‌سنجی مدل‌های ML پرداخته شده است. برای این‌منظور دو سناریو برای تخمین WDI توسط این مدل‌ها در نظر گرفته شده است. در سناریوی ۱ ورودی و خروجی مدل‌های ML به‌ترتیب باندهای طیفی ماهواره سنتینل-۲ و تصاویر WDI تخمین‌زده‌شده توسط الگوریتم METRIC در نظر گرفته شد. در سناریوی ۲ این ورودی شامل ترکیب باندهای طیفی ماهواره سنتینل-۲ (۶ باند طیفی) و ۱ باند حرارتی ماهواره لندست-۸ و خروجی مشابه سناریوی ۱ در نظر گرفت شد. در سناریوی ۲ از مزیت تفکیک مکانی بالا تصاویر ماهواره سنتینل-۲ (۱۰ متر در ۱۰ متر در باندهای ۲ الی ۴ و ۸) و مزیت باند حرارتی ماهواره لندست-۸ به‌طور هم‌زمان بهره گرفته شده است.

با درنظرگرفتن ورودی‌ها و خروجی‌های مذکور به‌عنوان به‌ترتیب متغیرهای ورودی (ویژگی‌ها)[۲۳] و متغیر هدف (پیش‌بینی‌شونده)، مدل‌های ML که شامل سه مدل ANN، SVR و RF است، واسنجی و صحت‌سنجی شدند. ابرپارامترهای[۲۴] تمامی مدل‌های ML از طریق یک فرایند اعتبارسنجی[۲۵] مبتنی بر سعی و خطای دستی بهینه‌سازی شدند. برای مدل ANN، از یک شبکه پرسپترون پیش‌خور با شش لایه پنهان استفاده شد که هر لایه شامل ۲۰ نورون بود. برای مدل SVR، از هسته‌های مختلف از جمله هسته RBF[۲۶] و چندجمله‌ای (Polynomial) استفاده شد تا بهترین مدل پیش‌بینی شناسایی گردد. در نهایت، هسته RBF به‌عنوان گزینه با عملکرد بهینه انتخاب شد.

تمامی مدل‌های ML در نرم‌افزار MATLAB پیاده‌سازی شدند. برای ANN و SVR به‌ترتیب از توابع *fitrnet* و *fitrsvm* استفاده شد. مدل RF نیز با استفاده از *fitrtree* در یک چارچوب Ensemble تکراری ساخته شد. در هر تکرار، نمونه‌گیری بوت‌استرپ از داده‌های آموزش و انتخاب تصادفی ویژگی‌ها انجام گرفت تا یک درخت رگرسیونی ایجاد شود و پیش‌بینی‌های همه درخت‌ها با میانگین‌گیری ترکیب شد تا پیش‌بینی نهایی به‌دست آید. این مطالعه RF را با ۴۰ درخت و حداقل اندازه برگ[۲۷] ۱۰ ساخت که تعادل مناسبی بین دقت مدل و هزینه محاسباتی برقرار می‌کند.

برای ارزیابی و مقایسه دقت مدل‌های ML در تخمین تصاویر WDI از سه معیار آماری ریشه میانگین مربع خطا (RMSE)[۲۸]، ضریب تبیین (DC)[۲۹] و شاخص KGE[۳۰] بهره گرفته شده است. شاخص RMSE هرچه به عدد صفر نزدیک‌تر باشد و شاخص‌های DC و KGE هرچه به عدد یک نزدیک‌تر باشند، نشان‌دهنده عملکرد مطلوب‌تر مدل هستند. روابط ریاضی این شاخص‌ها به قرار روابط (۸) تا (۱۰) است:

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2} \quad \text{رابطه ۸)}$$

$$\mathrm{DC} = 1 - \frac{\sum_{i=1}^{N}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{N}(y_i - \bar{y})^2} \quad \text{رابطه ۹)}$$

$$\mathrm{KGE} = 1 - \sqrt{(1-\beta)^2 + (1-\gamma)^2 + (1-r)^2} \quad \text{رابطه ۱۰)}$$

در این معادلات، y_i ،$\hat{y}_i$ و $\bar{y}$ به‌ترتیب مقادیر محاسباتی (شبیه‌سازی‌شده)، مشاهداتی (نمونه‌ها یا برچسب‌های مشاهده‌شده) و میانگین مقادیر مشاهده‌شده را نشان می‌دهد. B معروف است به نسبت بایاس[۳۱] که به‌صورت نسبت میانگین مقادیر شبیه‌سازی‌شده به میانگین مقادیر مشاهده‌شده $(\frac{\bar{\hat{y}}}{\bar{y}})$ محاسبه می‌شود. γ نسبت تغییرپذیری[۳۲] را بیان می‌کند و از طریق نسبت انحراف معیار مقادیر شبیه‌سازی‌شده به انحراف معیار مقادیر مشاهده‌شده $(\frac{CV_{\hat{y}}}{CV_y})$ به‌دست می‌آید. r نیز نشان‌دهنده ضریب همبستگی پیرسون[۳۳] بین مقادیر پیش‌بینی‌شده و مشاهده شده است. شایان ذکر است که برای ساخت مجموعه‌های واسنجی و صحت‌سنجی، پیکسل‌ها به‌صورت تصادفی از نواحی مختلف تصاویر ماهواره‌ای موجود انتخاب شدند. به‌طوری‌که بلوک‌هایی از تصاویر برای فرایند واسنجی و بلوک‌های دیگر برای فرایند صحت‌سنجی مورداستفاده قرار گرفتند. هر تصویر WDI مورداستفاده شامل حدود ۹۰۷،۵۶۱ پیکسل معتبر در محدوده باغ‌های پسته منطقه مطالعاتی بوده است. در این پژوهش، تعداد ۱۲ تاریخ تصویربرداری (قیدشده در بخش ۲-۷) معادل ۱۲ تصویر WDI مورداستفاده قرار گرفت که برای هر تاریخ، تصاویر متناظر باندهای طیفی سنتینل-۲ و باند حرارتی شماره ۱۰ ماهواره لندست-۸ به‌عنوان ورودی مدل‌ها استخراج شدند. در نتیجه، مجموعه داده نهایی شامل حدود ۱۱ میلیون نمونه پیکسلی (برای تصویر WDI و تصویر مربوط به هر باند ماهواره) از ترکیب تصاویر چندزمانه و چندحس‌گری بود. داده‌ها به‌صورت تصادفی از کل این مجموعه انتخاب و به نسبت ۷۰ درصد برای واسنجی و ۳۰ درصد برای صحت‌سنجی مدل‌های ML تخصیص داده شدند. این رویکرد انتخاب تصادفی از میان کل تصاویر و تاریخ‌ها و تفکیک بلوک‌های تصاویر برای مراحل واسنجی و صحت‌سنجی باعث می‌شود که وابستگی مکانی بین داده‌های واسنجی و صحت‌سنجی دیده شود و تا حد امکان کاهش یابد.

در ادامه به ارائه نتایج مدل‌های ML پرداخته شده است. شکل‌های (۸) و (۹)، نمودارهای همگرایی مدل‌های ANN و RF را در فاز آموزش به‌ترتیب برای سناریوی ۱ و ۲ براساس معیار کاهش خطای MSE[۳۴] نشان می‌دهند. همگرایی بیانگر رسیدن مدل‌ها به نقطه بهینه پارامترها و تثبیت پیش‌بینی‌ها در اطراف یک مقدار ثابت می‌باشد. نمودارهای همگرایی هر دو مدل ANN و RF در سناریوهای ۱ و ۲ به وضوح این روند بهینه‌سازی را نشان می‌دهند. شایان توجه است که مدل RF سریع‌تر از مدل ANN به همگرایی رسیده است. این سرعت بیش‌تر در همگرایی، حاکی از توانایی بالاتر مدل RF در یادگیری کارآمد و تعمیم‌پذیری قوی‌تر از داده‌های آموزشی است که آن را به ابزاری مؤثر در مدل‌سازی روابط پیچیده و ساختارهای داده تبدیل می‌کند. هم‌چنین در سناریوی ۲ هر دو مدل به محدوده‌ی بهینه‌تری نسبت به سناریوی ۱ رسیده است.

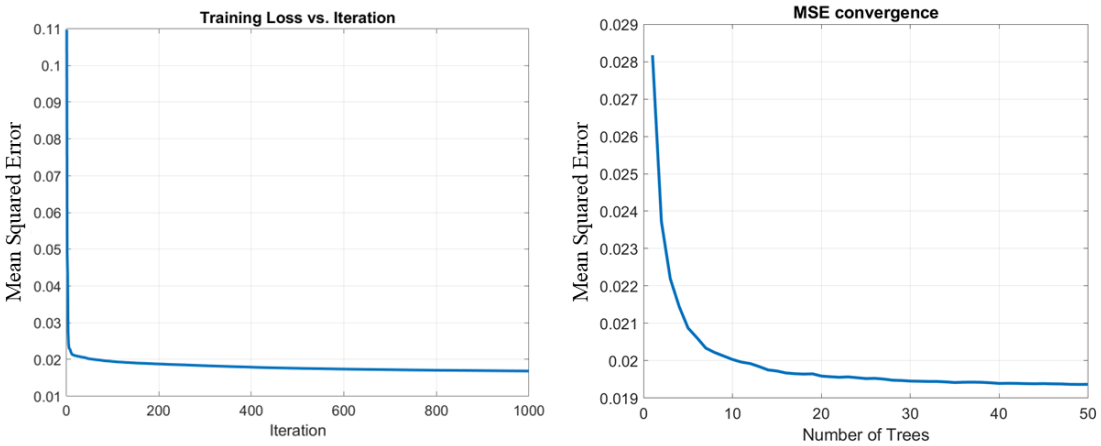


Figure 8. Convergence plot of ANN and SVR models based on the reduction of MSE in Scenario 1

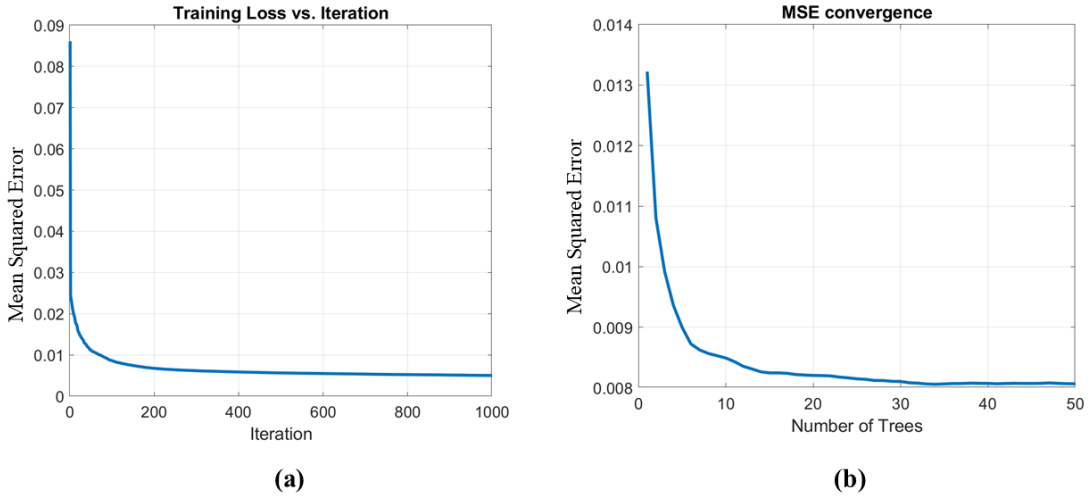


Figure 9. Convergence plot of ANN and SVR models based on the reduction of MSE in Scenario 2

جدول (۲) مقایسه‌ای از عملکرد مدل‌های مختلف در تخمین تصاویر WDI را در دو مرحله واسنجی و صحت‌سنجی در سناریوی ۱ نشان می‌دهد. طبق نتایج مرحله صحت‌سنجی، عملکرد مدل‌ها بسته به معیار ارزیابی متفاوت است. براساس شاخص‌های RMSE و DC، مدل SVR دقت بهتری را در تخمین WDI در مرحله صحت‌سنجی با RMSE=۰/۱۳۸۶ و DC=۰/۲۱۶۱ نسبت به سایر مدل‌ها نشان می‌دهد. این نتیجه بیانگر آن است که SVR توانسته ارتباط خطی و غیرخطی موجود میان باندهای طیفی و مقادیر WDI را با دقت مناسبی بازسازی نماید. در مقابل، مدل ANN اگرچه از نظر RMSE در مرحله صحت‌سنجی اندکی ضعیف‌تر عمل کرد، اما بالاترین مقدار KGE=۰/۳۰۳۶ را به‌دست آورد. ازآنجاکه شاخص KGE علاوه بر همبستگی، میزان انحراف سیستماتیک بین مقادیر پیش‌بینی‌شده و مشاهده‌شده (بایاس) و نیز الگوی تغییرپذیری داده‌ها را در نظر می‌گیرد، می‌توان نتیجه گرفت که ANN تعادل بهتری میان این سه مؤلفه برقرار کرده است. بنابراین، ANN گرچه در بعضی نقاط خطای بیش‌تری داشت، اما در کل توانست میانگین پیش‌بینی‌ها را به مقدار واقعی نزدیک‌تر نگه دارد و روند کلی تغییرات WDI را واقع‌بینانه‌تر بازتولید کند. به بیان دیگر، ANN توانسته است پویایی

کلی داده‌ها و رفتار هیدرولوژیکی WDI را بهتر بازتولید کند، هرچند دقت نقطه‌ای آن در مقایسه با SVR اندکی کم‌تر است. مدلRF در سناریوی ۱ برخلاف انتظار عملکرد متوسطی را نشان داد و در هیچ‌یک از شاخص‌ها برتری محسوسی نداشت. این مسئله می‌تواند به محدودیت حجم داده‌ها و یا همگنی نسبی نمونه‌ها مرتبط باشد، زیرا الگوریتم‌های RF معمولاً در شرایطی که داده‌های آموزشی متنوع و فراوان باشند، مزیت خود را نشان می‌دهند. شایان ذکر است، در سناریوی ۱، به‌دلیل عدم استفاده از باند حرارتی به‌عنوان یکی از متغیرهای فیزیکی مؤثر بر فرایند تبخیر–تعرق و شاخص WDI، برخی مدل‌ها به‌ویژه RF ممکن است الگوهای غیر فیزیکی و غیرمعنادار یا نویزهای موجود در داده‌های آموزشی (که فقط شامل باندهای اپتیکال هستند) را به‌عنوان روابط قطعی شناسایی کرده باشند. این مسئله منجر به عملکرد بهتر مدل در مرحله واسنجی و کاهش نسبی کارایی در مرحله صحت‌سنجی شده است. در مقابل، مدل ANN در این سناریو با وجود دقت کم‌تر در مرحله آموزش، ثبات بیش‌تری در مرحله صحت‌سنجی نشان داده که بیانگر توان تعمیم‌پذیری بالاتر آن در شرایط محدودیت متغیرهای فیزیکی است. با لحاظ‌کردن باند حرارتی در سناریوی ۲، این محدودیت تا حد زیادی برطرف شده و عملکرد مدل‌ها، به‌ویژه RF، بهبود یافته است که بر نقش کلیدی این متغیر در پایدارسازی تخمین WDI تأکید می‌کند. درنهایت می‌توان بیان داشت که انتخاب مدل به هدف کاربردی وابسته است. اگر هدف اصلی کاهش خطای پیش‌بینی و افزایش دقت عددی باشد، مدل SVR گزینه مناسب‌تری خواهد بود، اما اگر هدف داشتن برآوردی پایدارتر و نزدیک‌تر به میانگین واقعی مقادیر باشد یعنی بازنمایی واقع‌بینانه‌تر رفتار سامانه هیدرولوژیکی، استفاده از ANN در این سناریو توصیه می‌شود.

به‌طورکلی، در سناریوی ۱ دقت همه مدل‌های ML قابل‌قبول به‌نظر نمی‌رسد. با این‌که در باندهای طیفی تصاویر ماهواره سنتینل–۲ به‌ویژه در باند NIR، SWIR1 و SWIR2 می‌توان به‌طور ضمنی اثرات دمای سطح را تبیین کرد، اما در مجموع عدم وجود باند حرارتی در تصاویر باندهای این ماهواره به‌وضوح دلیل ضعف سناریوی ۱ معرفی می‌شود. چراکه دمای سطح به‌طور صریح بر تبخیر–تعرق و در نهایت شاخص WDI اثرگذار است. بنابراین در سناریوی ۲ در کنار شش باند طیفی تصاویر ماهواره سنتینل–۲ از یک باند حرارتی ماهواره لندست–۸ نیز استفاده شده است. به این ترتیب سناریوی ۲ از هر دو مزیت تفکیک مکانی بالا (تصاویر ماهواره سنتینل–۲) و وجود باند حرارتی (ماهواره لندست–۸) بهره‌مند شده است.

Table 2. Comparison of ML model performance in estimating WDI in Scenario 1

	Calibration			Verification		
	RMSE	**DC**	**KGE**	**RMSE**	**DC**	**KGE**
ANN	0.129	0.320	0.386	0.141	0.184	0.303
SVR	0.133	0.284	0.302	0.138	0.216	0.251
RF	0.102	0.577	0.495	0.139	0.209	0.246

در جدول (۳) نتایج حاصل از واسنجی و صحت سنجی مدل‌های ML در سناریوی ۲ نشان داده شده است. در این سناریو که در آن علاوه بر باندهای طیفی سنتینل–۲ از باند حرارتی لندست–۸ نیز استفاده شد، دقت مدل‌های ML به‌طور قابل‌توجهی افزایش یافت. بر این اساس، مدل ANN بهترین عملکرد را در میان مدل‌ها با RMSE=۰/۰۸۳۱، DC=۰/۷۱۸۴ و KGE=۰/۸۱۸ نشان داد و از نظر هر سه شاخص به‌طور محسوس از SVR و RF برتر بود. این موضوع نشان می‌دهد که مدل ANN توانسته است روابط غیرخطی میان ترکیب باندهای طیفی و حرارتی با WDI و هم‌چنین رفتار کلی این شاخص را به‌خوبی فرا بگیرد و بازتولید نماید. مقایسه نتایج سناریوی ۱ و ۲ نشان می‌دهد که افزودن باند حرارتی منجر به بهبود قابل‌توجه و پایدار عملکرد مدل‌ها، به‌ویژه در مرحله صحت‌سنجی، شده است. این رفتار به‌طور ضمنی بیانگر نقش غالب باند حرارتی به‌عنوان متغیر فیزیکی مؤثر بر فرایند تبخیر–تعرق و WDI است. بر این اساس،

می‌توان نتیجه گرفت که اطلاعات حرارتی بیش‌ترین تأثیر را در دقت و تعمیم‌پذیری مدل‌ها داشته‌اند. در پژوهش‌های آتی، می‌توان با به‌کارگیری روش‌های متداول تحلیل حساسیت سهم نسبی باندهای طیفی و حرارتی در تخمین WDI را به‌صورت کمی ارزیابی کرد. این تحلیل‌ها می‌تواند به درک بهتر نقش هر یک از ورودی‌ها و بهینه‌سازی انتخاب ویژگی‌ها در مدل‌های ML کمک کند.

Table 3. Comparison of ML model performance in estimating WDI in Scenario 2

	Calibration			Verification		
	RMSE	**DC**	**KGE**	**RMSE**	**DC**	**KGE**
ANN	0.070	0.797	0.847	0.083	0.718	0.818
SVR	0.086	0.700	0.701	0.092	0.649	0.680
RF	0.066	0.821	0.776	0.089	0.670	0.707

شایان ذکر است، با وجود آن‌که عملکرد مدل‌ها براساس معیارهای آماری ارزیابی شد، تفاوت‌های مشاهده‌شده میان ANN، SVR و RF را می‌توان از منظر ساختار مدل‌ها نیز تبیین کرد. مدل ANN به‌دلیل ساختار لایه‌ای و استفاده از توابع فعال‌سازی غیرخطی، توانایی بالاتری در مدل‌سازی روابط غیرخطی (nonlinearity capture) میان متغیرهای ورودی سنجش از دور و شاخص WDI دارد. این ویژگی موجب شده است ANN در بازنمایی تعاملات غیرخطی میان باندهای طیفی، شاخص‌های پوشش گیاهی و داده‌های حرارتی عملکرد بهتری نسبت به SVR و RF نشان دهد (Pal & Mather, 2003). با این‌حال، یکی از ضعف‌های ذاتی ANN، حساسیت آن به بیش‌برازش (overfitting) در شرایط داده‌های محدود یا نویزدار است که در این پژوهش، این مسئله با استفاده از تفکیک داده‌ها به مجموعه‌های واسنجی و صحت‌سنجی و تنظیم ساختار شبکه کنترل شده است. در مقابل، عملکرد مدل SVR به‌شدت به انتخاب پارامترهای کنترلی، به‌ویژه پارامتر C و نوع کرنل وابسته است، به‌گونه‌ای که تنظیم نامناسب این پارامترها در داده‌های دارای نویز می‌تواند توان تعمیم‌پذیری مدل را کاهش دهد (Smola & Schölkopf, 2004).

در گام بعدی برای ارزیابی خطای احتمالی ناشی از عملیات بازنمونه‌گیری از آزمون بازتجمیع مکانی[۳۵] استفاده شده است. در این روند، تصویر WDI مرجع در تاریخ ۵ می ۲۰۲۲ که در گام اول با استفاده از الگوریتم METRIC با تفکیک مکانی ۳۰ متر محاسبه شد، با روش درون‌یابی دوخطی به تفکیک مکانی ۱۰ متر بازنمونه‌گیری شد. سپس این تصویر با روش تجمیع میانگین[۳۶] به تفکیک مکانی ۳۰ متر بازگردانده شد (شکل ۱۰). مقایسه این خروجی با تصویر ۳۰ متری اولیه نشان داد خطای ایجادشده با RMSE=۰/۰۱۷۸ و DC=۰/۹۲ بسیار ناچیز است و تأثیر معناداری منفی بر کیفیت تخمین WDI در سناریوهای مطروحه نداشته و ارتقای رزولوشن مکانی با این روش توجیه‌پذیر و کارآمد است.

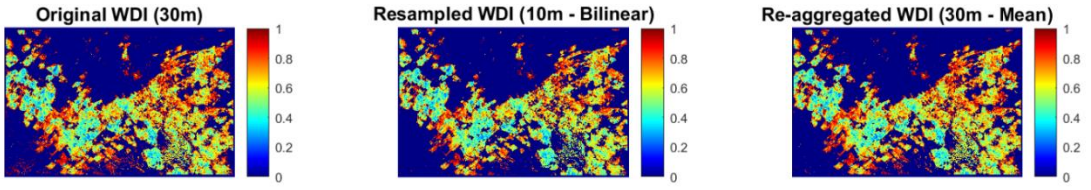


Figure 10. Comparison of the original and re-aggregated 30-m WDI maps

در ادامه برای اعتبارسنجی مدل‌های ML و اطمینان از عدم رخداد بیش‌برازش، تصاویر WDI برای محدوده و تاریخی خارج از محدوده مکانی و زمانی داده‌هایی که این مدل‌های با آن‌ها واسنجی و صحت‌سنجی شده‌اند

تخمین زده می‌شود. در این راستا، در شکل (۱۱) تصاویر WDI تخمین‌زده‌شده برای یک منطقه موردنظر (ROI)[۳۷] در تاریخ ۳ آوریل ۲۰۲۴ توسط مدل‌های ANN (شکل a–۱۱)، SVR (شکل b–۱۱) و RF (شکل c–۱۱) برای سناریوی ۱ نشان داده شده است. هم‌چنین در شکل (d-f–۱۱) نقشه خطای مکانی حاصل از تفاضل تصویر WDI تخمین زده شده با WDI معیار (WDI محاسبه‌شده توسط METRIC) به‌ترتیب برای مدل‌های ANN، SVR و RF برای سناریوی ۱ ارائه شده است. در شکل (۱۲) موارد مذکور برای سناریوی ۲ به تصویر کشیده شده است. شایان ذکر است که در تصاویر مربوط به خطای مکانی، پیکسل‌های با رنگ آبی عمیق مربوط به محدوده‌هایی است که از قبل به‌دلیل نبود پوشش گیاهی Mask شده‌اند. شکل (۱۳) نمودار پراکندگی[۳۸] مقایسه میان داده‌های WDI تخمین‌زده‌شده و WDI معیار را برای سناریوی ۱ (شکل a-c–۱۳) و سناریوی ۲ (شکل e, f–۱۳) به‌ترتیب برای مدل‌های ANN، SVR و RF نشان می‌دهد. نتایج مذکور اهمیت وجود باند حرارتی ماهواره لندست–۸ را در کنار باندهای طیفی سنتینل–۲ و تأثیر قابل‌توجه آن در بهبود دقت تخمین WDI در فرایند اعتبار سنجی مدل‌های ML را تأیید می‌کنند. براساس نتایج به‌دست‌آمده که با استفاده از تصاویر خارج از بازه زمانی و مکانی داده‌های واسنجی و صحت‌سنجی انجام شد (شکل ۱۱ تا ۱۳)، برخلاف نتایج اولیه، مدل RF با شاخص DC و KGE به‌ترتیب ۰/۲۳ و ۰/۲۸ برای سناریوی ۱ و ۰/۷۹ و ۰/۸۵ برای سناریوی ۲، دقت بالاتری نسبت به ANN نشان داد. مرحله اعتبارسنجی مستقل نشان داد که مدل RF در مواجهه با داده‌های مکانی–زمانی کاملاً جدید، قابلیت تعمیم نسبتاً بهتری در مقایسه با مدل ANN از خود نشان می‌دهد. این تفاوت رفتاری اساساً ریشه در ویژگی‌های ذاتی این الگوریتم‌ها دارد. مدل RF به‌عنوان یک روش یادگیری تجمعی، از تکنیک Bagging استفاده می‌کند. در این رویکرد، درخت‌های تصمیم متعددی بر روی زیرمجموعه‌های تصادفی متفاوتی از داده‌های آموزشی ایجاد می‌شوند و در نهایت از پیش‌بینی‌های آن‌ها میانگین‌گیری می‌شود (Liaw & Wiener, 2002). این مکانیسم ذاتاً واریانس کلی مدل را کاهش داده و مقاومت آن را در برابر بیش‌برازش به شکل چشم‌گیری افزایش می‌دهد. در مقابل، اگرچه معماری بسیار انعطاف‌پذیر ANN به آن اجازه می‌دهد الگوهای پیچیده غیرخطی را در مرحله آموزش به‌خوبی یاد بگیرد، اما این مدل را نسبت به نویزهای محلی کمی حساس‌تر می‌کند که منجر به افت جزئی عملکرد در هنگام تعمیم به شرایط کاملاً جدید می‌شود. بنابراین، چنانچه هدف، دست‌یابی به بیش‌ترین دقت در تخمین WDI باشد، مدل ANN برتری خود را نشان می‌دهد. اما در صورت هدف‌گذاری برای توسعه یک مدل عملیاتی پایدار با قابلیت تعمیم بالا به شرایط مکانی–زمانی جدید، نتایج اعتبارسنجی مستقل نشان داد که مدل RF به‌دلیل پایداری عملکرد، گزینه قابل‌اتکاتر و مطمئن‌تری است.

همان‌طورکه در نمودارهای پراکندگی شکل ۱۳ مشاهده می‌شود، عملکرد مدل‌های ML در پیش‌بینی مقادیر حدی WDI (نزدیک به صفر و ۱) به‌ویژه در سناریوی ۱، با کاهش دقت و افزایش پراکندگی همراه است. این رفتار در مدل‌های داده‌محور پدیده‌ای رایج است و دلیل اصلی آن، توزیع نامتوازن داده‌های آموزشی است، به‌گونه‌ای‌که شرایط حدی (رطوبت کامل یا تنش شدید) در مقایسه با شرایط متوسط، سهم بسیار کم‌تری در مجموعه داده‌ها دارند. الگوریتم‌های مبتنی بر درخت مانند RF ذاتاً تمایل دارند نتایج پیش‌بینی را به سمت میانگین داده‌ها سوق دهند که این ویژگی موجب افت عملکرد مدل در لبه‌های کرانه‌ای داده‌ها می‌شود. با این وجود، استفاده از سناریو ۲ (با بهره‌گیری از ویژگی‌های ورودی جامع‌تر) توانست این محدودیت را تا حد زیادی تعدیل کرده و تراکم نقاط را در اطراف خط ۱:۱ بهبود بخشد. برای غلبه بر این محدودیت در پژوهش‌های آتی، پیشنهاد می‌شود از تکنیک‌هایی نظیر تولید داده‌های مصنوعی[۳۹] برای مقادیر حدی و نمونه‌برداری طبقه‌بندی‌شده[۴۰] استفاده شود تا دقت پیش‌بینی در شرایط حدی ارتقا یابد.

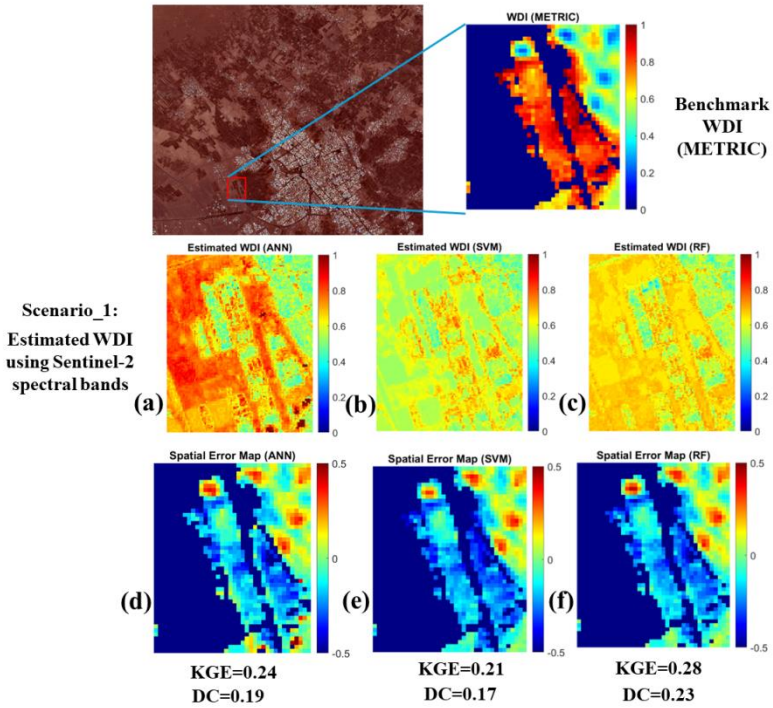


Figure 11. Estimated WDI for the selected ROI (a–c) and spatial error maps (d–f) for the ANN, SVR, and RF models, respectively, in Scenario 1

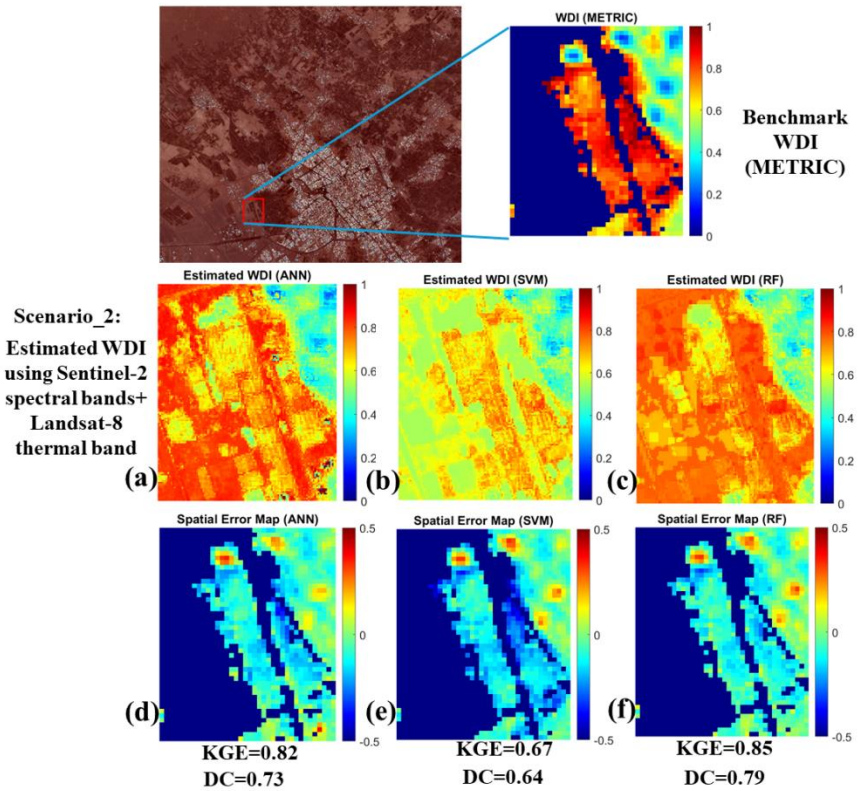


Figure 12. Estimated WDI for the selected ROI (a–c) and spatial error maps (d–f) for the ANN, SVR, and RF models, respectively, in Scenario 2

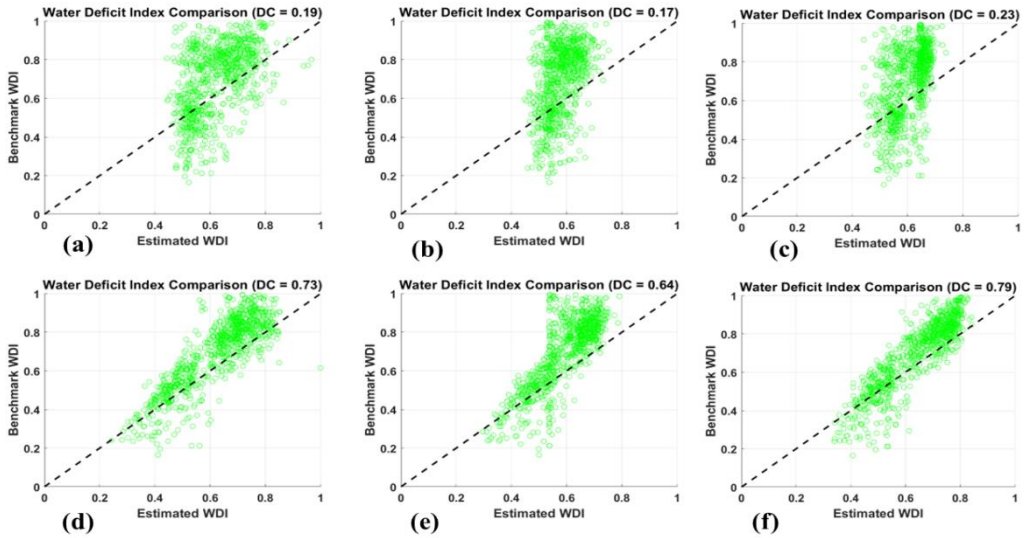


Figure 13. Scatter plots in Scenario 1 (a–c) and Scenario 2 (d–f) for the ANN, SVR, and RF models, respectively

به‌منظور ارزیابی میزان تأثیرگذاری هر یک از متغیرهای ورودی در تخمین WDI و درک بهتر رفتار مدل، از قابلیت تحلیل اهمیت متغیرها (FH)[۴۱] در مدل RF استفاده شد. همان‌طور که در شکل (۱۴) مشاهده می‌شود، نتایج این تحلیل نشان می‌دهد که باند حرارتی (Thermal) با کسب بیش‌ترین میزان اهمیت (حدود ۴۰ درصد)، نقش کلیدی و غالب را در مدل‌سازی ایفا می‌کند. این موضوع با ماهیت فیزیکی WDI، کاملاً تطابق دارد. پس از آن، باند مادون قرمز نزدیک (NIR) با اهمیت نسبی حدود ۲۲ درصد در جایگاه دوم قرار دارد که در کنار باند قرمز (Red)، نشان‌دهنده اتکای منطقی و فیزیکی مدل به شاخص‌های پوشش گیاهی مانند NDVI به‌عنوان محور دیگر در مفهوم ذوزنقه دمایی است. علاوه بر این، اهمیت باندهای مادون قرمز کوتاه به‌ویژه SWIR2 حساسیت درست مدل به تغییرات محتوای آب تاج‌پوشش گیاهی در شرایط تنش را نشان می‌دهد. به‌طورکلی، این تحلیل ثابت می‌کند که مدل ML توانسته است فیزیک مسئله را به‌درستی استخراج کند و دلیل برتری قاطع سناریوی ۲ (شامل داده‌های حرارتی) بر سناریوی اول را به‌روشنی توجیه میکند. شایان ذکر است که تحلیل حساسیت مدل و تعیین میزان اهمیت نسبی متغیرهای ورودی آن از قابلیت‌های ذاتی و برجسته مدل RF است. این موضوع را می‌توان یکی از جنبه‌های برتری مدل RF نسبت به سایر مدل‌ها در نظر گرفت.

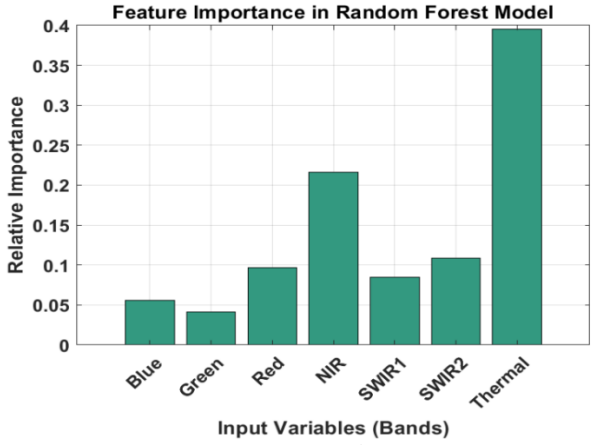


Figure 14. Feature importance of the input variables

یافته‌های این پژوهش مبنی بر بهبود دقت تخمین WDI در سناریوی ۲ که در آن از ترکیب داده‌های طیفی سنتینل-۲ همراه با باند حرارتی TIRS لندست-۸ به‌عنوان ورودی مدل‌ها استفاده شده، با نتایج مطالعات علمی اخیر همسو است. مطالعات متعددی از جمله Gerhards *et al.* (2019)، Stutsel *et al.* (2021) و Psomiadis *et al.* (2025) نشان داده‌اند که اطلاعات حرارتی می‌تواند به‌عنوان یک شاخص مستقیم از وضعیت تبخیر-تعرق گیاه مورداستفاده قرار گیرد، زیرا کاهش تبخیر با افزایش دمای تاج گیاه همراه است و این تغییر حرارتی به‌طور مستقیم توسط سنجش از دور حرارتی قابل‌پایش است. این توانایی باعث شده است تا شاخص‌های مبتنی بر دمای سطح و اطلاعات حرارتی مانند LST در تشخیص تنش آبی مؤثرتر از استفاده صرف از داده‌های طیفی باشند، به‌ویژه زمانی که با مدل‌های انرژی‌مبنای تبخیر-تعرق ترکیب می‌شوند. این شواهد علمی حمایت می‌کند از این‌که افزودن اطلاعات حرارتی به ورودی مدل‌ها می‌تواند دقت تخمین WDI را افزایش دهد و منشأ فیزیکی بهتری برای ارتباط با فرایندهای تبخیر-تعرق فراهم نماید. هم‌چنین نتایج حاصل از مدل‌سازی WDI با استفاده از مدل‌های ML در این پژوهش را می‌توان در چارچوب مطالعاتی قرار داد که از روش‌های مشابه برای برآورد متغیرهای مبتنی بر سنجش‌ازدور استفاده کرده‌اند (جدول ۴). در این مقایسه، هدف اصلی، بررسی سطح دقت و عملکرد کلی مدل‌ها در کاربردهای سنجش‌ازدوری مبتنی بر ML است. برای نمونه، در پژوهش Sedighi *et al.* (2024) که با هدف بازیابی رطوبت خاک و با استفاده از مدل نیمه‌تجربی WCM و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN)[۴۲] انجام شد، مقدار RMSE برابر با ۰/۰۸۵ گزارش شد. در پژوهش حاضر نیز مقدار RMSE برابر با ۰/۰۸۳۱ برای مدل ANN در سناریوی ۲ به‌دست آمد که از نظر سطح خطا، همخوانی مناسبی با نتایج پژوهش مذکور نشان می‌دهد. هم‌چنین در پژوهش Neissi *et al.* (2021) که به مدل‌سازی تبخیرتعرق دورسنجی‌شده مبتنی بر الگوریتم SEBAL با استفاده از مدل تصمیم‌گیری M5 پرداخته است، مقدار ضریب کارایی مدل (DC) برابر با ۰/۹۲ گزارش شده است. در این پژوهش نیز مقدار DC برابر با ۰/۷۱۸۴ برای مدل ANN در سناریوی ۲ به‌دست آمد که بیانگر عملکرد مناسب مدل در بازتولید مقادیر مشاهده‌ای و قرارگرفتن دقت مدل در محدوده قابل‌قبول مطالعات مبتنی بر ML در حوزه سنجش‌ازدور است.

Table 4. Comparison of the performance metrics of the proposed model with previous studies

Metrics	Target variable	Method/Model	Study
RMSE= 0.085	Soil moisture	GRNN	Sedighi *et al.* (2024)
DC= 0.92	ET	M5	Neissi *et al.* (2021)
RMSE= 0.083/DC=0.7184	WDI	ANN	Present study

با وجود نتایج رضایت‌بخش به‌دست‌آمده، روش پیشنهادی و مدل‌های داده‌محور مورداستفاده در این پژوهش با محدودیت‌های عملیاتی همراه هستند که نیازمند تحلیل است. نخست، وابستگی مستقیم روش به‌دسترسی به تصاویر ماهواره‌ای با کیفیت مناسب، به‌ویژه باندهای حرارتی، باعث می‌شود پوشش ابری و شرایط جوی نامناسب منجر به حذف یا کاهش تعداد تصاویر قابل استفاده شود. پیامد اصلی این محدودیت، ایجاد شکاف‌های زمانی در پایش پیوسته وضعیت رطوبتی مزرعه است. به‌ویژه در مراحل حساس رشد گیاه که تصمیم‌گیری به‌هنگام برای آبیاری حیاتی است، عدم دسترسی به تصاویر ماهواره‌ایِ روزآمد می‌تواند کارایی سیستم پایش را کاهش دهد. دومین محدودیت اساسی، نیاز مدل‌های ML به داده‌های زمینی دقیق نظیر پارامترهای هواشناسی و اندازه‌گیری‌های میدانی برای آموزش و کالیبراسیون اولیه به‌ویژه الگوریتم METRIC است. ازآنجاکه ماهیت این مدل‌ها داده‌محور است، دقت پیش‌بینی و قابلیت تعمیم‌پذیری آن‌ها وابستگی شدیدی به کیفیت، گستردگی و پراکنش داده‌های آموزشی دارد. جمع‌آوری داده‌های زمینیِ هم‌زمان با عبور ماهواره فرایندی زمان‌بر و پرهزینه است. در نتیجه، توسعه و پیاده‌سازی این مدل‌ها در مناطق جدیدی که فاقد شبکه مناسب ایستگاه‌های هواشناسی یا داده‌های میدانی تاریخی هستند، با چالش مواجه خواهد شد.

۴. نتیجه‌گیری و پیشنهادها

این پژوهش با هدف ارزیابی کارایی مدل‌های ML در تخمین مکانی WDI در باغات پسته با استفاده از داده‌های سنجش از دور انجام شد. یافته‌های کلیدی نشان داد که سناریو ۲، به‌دلیل تلفیق داده‌های اپتیکال و حرارتی ماهواره‌های سنتینل-۲ و لندست-۸، موثرترین سناریو جهت تخمین WDI است. در خصوص انتخاب مدل بهینه، نتایج نشان‌دهنده یک انتخاب هدف محور است. چنانچه هدف، دست‌یابی به بیش‌ترین دقت پیش‌بینی در مجموعه داده‌ای با ویژگی‌های مشابه داده‌های آموزشی باشد، مدل ANN برتری خود را نشان می‌دهد. اما اگر هدف، توسعه یک مدل عملیاتی پایدار با قابلیت تعمیم بالا برای استفاده در شرایط متغیر و جدید باشد، مدل RF به‌دلیل پایداری عملکرد، گزینه‌ای قابل‌اتکاتر و مطمئن‌تر است.

خروجی کاربردی این پژوهش، ارائه نقشه مکانی WDI با وضوح بالا است که به‌عنوان یک ابزار تشخیصی قدرتمند برای پایش وضعیت تنش رطوبتی گیاه عمل می‌کند. نقشه‌های مکانی WDI این امکان را فراهم می‌کنند که نواحی دارای تنش آبی بیش‌تر در سطح باغ شناسایی شوند و بر این اساس، کشاورزان بتوانند اولویت‌بندی آبیاری، مدیریت توزیع آب و پایش تغییرات تنش آبی را با دقت بیش‌تری انجام دهند. به‌طور مشخص در سطح منطقه مطالعاتی حاضر، کشاورزان می‌توانند براساس این نقشه‌ها اقدامات مدیریتی هدفمندی (آبیاری متغیر و دقیق) را اجرا کنند؛ بدین صورت که شناسایی نقاط با WDI بالا (بیانگر تنش آبی شدید)، به منزله هشدار برای تخصیص فوری آب، بازبینی خطوط سیستم‌های آبیاری (جهت تشخیص نشتی یا انسداد قطره‌چکان‌ها) و مداخله سریع برای جلوگیری از افت عملکرد محصول است. در نقطه مقابل، در مناطقی با WDI پایین (نشان‌دهنده کفایت رطوبت یا حتی آبیاری مازاد)، می‌توان با کاهش، قطع یا به تعویق‌انداختن دور آبیاری در آن بخش‌ها، علاوه بر صرفه‌جویی چشم‌گیر در مصرف آب و هزینه‌های انرژی (پمپاژ)، از بروز مشکلاتی نظیر غرقابی‌شدن خاک، خفگی ریشه و آب‌شویی عناصر غذایی جلوگیری کرد. در مقیاس کلان و منطقه‌ای نیز، سازمان‌های متولی نظیر شرکت‌های آب منطقه‌ای و جهاد کشاورزی می‌توانند این نقشه‌ها را به‌عنوان ابزاری برای تصمیم‌گیری‌های استراتژیک به‌کار گیرند. به‌عنوان مثال، با هدف تخصیص هوشمند و اولویت‌بندی منابع آب، در شرایط خشک‌سالی و محدودیت منابع سدها، رهاسازی آب می‌تواند به‌صورت هدفمند و با اولویت‌بندی دشت‌ها یا شبکه‌های آبیاری که دارای میانگین WDI بحرانی (تنش شدید و فراگیر) هستند، انجام شود. هم‌چنین با هدف شناسایی برداشت‌های غیرمجاز، مشاهده مقادیر WDI پایین که نشان‌دهنده آبیاری کامل و شادابی گیاه در مناطقی که فاقد تخصیص آب قانونی هستند یا برداشت آب زیرزمینی در آن‌ها ممنوع است، می‌تواند به‌عنوان شاخصی برای شناسایی سریع تخلفات و چاه‌های غیرمجاز عمل کند. به‌علاوه، به‌عنوان سیاست‌گذاری الگوی کشت، پایش بلندمدت و چندساله نقشه‌های WDI امکان شناسایی مناطقی که به‌طور مستمر دچار تنش آبی هستند را فراهم می‌کند؛ امری که می‌تواند مبنایی علمی برای الزام به تغییر الگوی کشت از گیاهان پرآب‌طلب به گونه‌های مقاوم در آن دشت‌ها باشد. در نهایت ارزیابی دقیق وسعت و شدت تنش خشک‌سالی در سطح یک حوضه آبریز، جهت برآورد خسارت و پرداخت عادلانه و مبتنی بر داده‌ی غرامت‌های بیمه محصولات کشاورزی می‌تواند به‌عنوان کاربرد کلان دیگر این روش‌شناسی معرفی شود.

بر این اساس، پیشنهاد می‌شود در پژوهش‌های آتی، از مقادیر برآوردشده WDI در کنار سایر اطلاعات تکمیلی نظیر مرحله فنولوژیکی گیاه، نوع و بافت خاک، ظرفیت نگهداشت رطوبتی خاک، شرایط اقلیمی و محدودیت‌های بهره‌برداری منابع آب، به‌منظور تدوین تقویم‌های آبیاری پویا و متناسب با شرایط واقعی مزرعه استفاده شود. چنین رویکردی می‌تواند امکان تبدیل مقادیر عددی WDI به سطوح عملیاتی تصمیم‌گیری (نظیر آبیاری فوری، آبیاری با تأخیر کوتاه‌مدت یا عدم نیاز به آبیاری) را فراهم سازد. هم‌چنین پیشنهاد می‌شود به‌منظور ارزیابی دقیق‌تر قابلیت تعمیم مکانی مدل‌های ML، از روش‌های اعتبارسنجی با تفکیک مکانی مانند Spatial Block Cross-Validation نیز استفاده شود تا اثر همبستگی مکانی بین پیکسل‌ها در فرایند ارزیابی مدل‌ها بهتر موردبررسی قرار گیرد.

۵. پی‌نوشت‌ها

1. Crop Water Stress Index
2. Water Deficit Index
3. Surface Energy Balance Algorithm for Land
4. Landsat
5. Machine Learning
6. Albedo
7. Emissivity
8. Normalize Differences Vegetation Index
9. Sentinel-2
10. Artificial Neural Network
11. Support Vector Regression
12. Random Forests
13. Multi-Layer Perceptron
14. Feed-forward architecture
15. Backpropagation algorithm
16. Kernel functions
17. Ensemble learning
18. Regression trees
19. Sum of Squared Errors
20. Bilinear Interpolation
21. Resampling
22. Sensible heat flux
23. Features
24. Hyperparameters
25. Validation
26. Radial Basis Function
27. Minimum leaf size
28. Root Mean Squared Error
29. Determined Coefficient
30. Kling-Gupta Efficiency
31. Bias ratio
32. Variability ratio
33. Pearson correlation coefficient
34. Mean Squared Error
35. Spatial Re-aggregation Test
36. Mean Aggregation
37. Region of interest
38. Scatter plot
39. Data Augmentation
40. Stratified Sampling
41. Feature Importance
42. Generalized Regression Neural Network

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

Allen, R. G., Irmak, A., Trezza, R., Hendrickx, J. M. H., Bastiaanssen, W. G. M., & Kjaersgaard, J. (2011). Satellite-based ET estimation in agriculture using SEBAL and METRIC. *Hydrological Processes*, *25*, 4011–4027.

Allen, R. G., Tasumi, M., & Trezza, R. (2007). Satellite-based energy balance for mapping evapotranspiration with internalized calibration (METRIC)—Model. *Journal of Irrigation and Drainage Engineering*, *133*, 380–394.

Antoniuk, V., Manevski, K., Korup, K., Larsen, R., Sandholt, I., Zhang, X., & Andersen, M. N. (2021). Diurnal and seasonal mapping of water deficit index and evapotranspiration by an unmanned aerial system: A case study for winter wheat in Denmark. *Remote Sensing*, *13*, 2998.

Bastiaanssen, W. G. M., Menenti, M., Feddes, R. A., & Holtslag, A. A. M. (1998). A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, *212*, 1–4.

Claverie, M., Ju, J., Masek, J. G., Dungan, J. L., Vermote, E. F., Roger, J. C., & Skakun, S. V. (2018). The Harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sensing of Environment*, *219*, 145–161.

Goldhamer, D. A. (2005). Tree water requirements and regulated deficit irrigation. *Pistachio*, 1–12.

Gerhards, M., Schlerf, M., Mallick, K., & Udelhoven, T. (2019). Challenges and future perspectives of multi-/hyperspectral thermal infrared remote sensing for crop water-stress detection: A review. *Remote Sensing*, *11*(10), 1240.

Idso, S. B., Jackson, R. D., Reginato, R. J., Pinter Jr., P. J., & Hatfield, J. L. (1981). Normalizing the stress-degree-day parameter for environmental variability. *Agricultural Meteorology*, *24*, 45–55.

Iran Water Resources Management Company (IRWRMC). (2011). *Water resources balance sheet in catchment of Darangir desert*. Technical report, Tehran, Iran. (In Persian)

Liaw, A., & Wiener, M. (2002). Classification and regression by random forest. *R News*, *2*, 18–22.

Mokhtari, A., Noory, H., Pourshakouri, F., Haghighatmehr, P., Afrasiabian, Y., Razavi, M., & Naeni, A. S. (2019). Calculating potential evapotranspiration and single crop coefficient based on energy balance equation using Landsat 8 and Sentinel-2. *ISPRS Journal of Photogrammetry and Remote Sensing*, *154*, 231–245.

Moran, M. S., Clarke, T. R., Inoue, Y., & Vidal, A. (1994). Estimating crop water deficit using the relation between surface–air temperature and spectral vegetation index. *Remote Sensing of Environment*, *49*(3), 246–263.

Neissi, L., Golabi, M., Albaji, M., & Naseri, A. A. (2021). Evaluating evapotranspiration using data mining instead of physical-based model in remote sensing. *Theoretical and Applied Climatology*, *147*, 701–716.

Pal, M., & Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, *86*(4), 555–565.

Parkash, V., & Singh, S. (2020). A review on potential plant based water stress indicators for vegetable crops. *Sustainability*, *12*, 3945.

Parker, J. A., Kenyon, R. V., & Troxel, D. E. (1983). Comparison of interpolating methods for image resampling. *IEEE Transactions on Medical Imaging*, *2*(1), 31–39.

Parodi, N., & Gabriel, I. R. (2002). *AHVRR Hydrological AnalySI System algorithms and theory—Version 1.3*. John Wiley & Sons, New York.

Psomiadis, E., Philippopoulos, P. I., & Kakaletris, G. (2025). Non-invasive estimation of crop water stress index and irrigation management with upscaling from field to regional level using remote sensing and agrometeorological data. *Remote Sensing*, *17*(14), 2522.

Qin, Q., Wu, Z., Zhang, T., Sagan, V., Zhang, Z., Zhang, Y., Zhang, C. Y., Ren, H., Sun, Y., Xu, W., & Zhao, C. (2021). Optical and thermal remote sensing for monitoring agricultural drought. *Remote Sensing*, *13*, 5092.

Rahmani, J., Danesh Yazdi, M., & Tajrishy, M. (2020). Development of a toolbox for actual evapotranspiration estimation using the METRIC algorithm and Landsat 8 imagery (The case of Urmia Plain). *Iran-Water Resources Research*, *16*, 109–119. (In Persian).

Reyes-González, A., Kjaersgaard, J. H., Trooien, T., Hay, C., & Ahiablame, L. M. (2017). Comparative analysis of METRIC model and atmometer methods for estimating actual evapotranspiration. *International Journal of Agronomy*, *2017*, 1–16.

Safari, S., Sharghi, S., Kerachian, R., & Noory, H. (2023). A market-based mechanism for long-term groundwater management using remotely sensed data. *Journal of Environmental Management*, *332*, 117409.

Sedighi, A., Hamzeh, S., Alavipanah, S. K., Naseri, A. A., & Mohammadi Moalezade, J. (2024). Combination of semi-empirical radar remote sensing models for soil moisture retrieval during the plant growing season based on machine learning. *Iran-Water Resources Research*, *20*, 197–215. (In Persian).

Sharghi, S., Kerachian, R., & Safari, S. (2023). Market-based groundwater resources management considering the uncertainty of water consumption monitoring. *Modares Civil Engineering Journal*, *23*, 143–162. (In Persian).

Sharghi, S., & Zeynolabedin, A. (2025). Integration of machine learning models and remote sensing for estimating the Water Deficit Index. *Agricultural Water Management*, *319*, 109827.

Sishodia, R. P., Ray, R. L., & Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, *12*, 3136.

Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, *14*(3), 199–222.

Stutsel, B., Johansen, K., Malbéteau, Y. M., & McCabe, M. F. (2021). Detecting plant stress using thermal and optical imagery from an unoccupied aerial vehicle. *Frontiers in Plant Science*, *12*, 734944.