



Prediction of daily evapotranspiration images of rice using machine learning

Homa Noghankar¹  | Mahmoud Raeini-Sarjaz²  | MohammadAli Gholami Sefidkouhi³ 
 | Majid Mobini⁴ 

1. Department of Water Engineering, Faculty of Agricultural Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran. E-mail: h.noghankar@stu.sanru.ac.ir
2. Department of Water Engineering, Faculty of Agricultural Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran. E-mail: raeini@yahoo.com
3. Corresponding Author, Department of Water Engineering, Faculty of Agricultural Engineering, Sari Agricultural Sciences and Natural Resources University, Sari, Iran. E-mail: ma.gholami@sanru.ac.ir
4. Department of Electrical and Computer Engineering, Mazandaran Institute of Technology, Iran. E-mail: mobini2002@gmail.com

Article Info

Article type: Research Article

Article history:

Received: Nov. 11, 2022

Revised: Dec. 20, 2022

Accepted: Dec. 24, 2022

Published online: Feb. 20, 2023

Keywords:

LSTM METRIC algorithm,
Relevance Vector Machine,
Satellite image fusion.

ABSTRACT

Short-term prediction of daily plant evapotranspiration (ET) is of great importance in precision agriculture and irrigation management. In this paper, a method for short-term prediction of daily ET maps of rice is presented using satellite images and machine learning algorithms. After merging the bands of Landsat-8 and MODIS images using the STARFM method, daily ET images were produced using the METRIC algorithm and used to predict the ET maps of the following days as input to the relation vector machine (RVM) and long short-term memory (LSTM). Two scenarios were considered for prediction. In the first scenario, model is trained using image of nth day of the growth period as input, and the n+6th day's image as target. Using this configuration, the model can predict ET images at a six-day timestep. In the second scenario, the forecast was made for consecutive days up to six days. The correlation coefficient between the values obtained by RVM and the values calculated by METRIC for the first and second scenario were 0.89 and 0.84, respectively, which indicates the acceptable accuracy of these two scenarios in predicting ET. In the first scenario, R2 values for RVM and LSTM methods were 0.8 and 0.59, respectively, which shows that RVM is more accurate for evapotranspiration prediction compared to LSTM. The values of RMSE for RVM in the first and second scenarios were 0.56 and 0.82, respectively, and the values of MAE were 0.43 and 0.66, respectively, which indicates a lower error in the configuration of the first scenario.

Cite this article: Noghankar, H., Raeini-Sarjaz, M., Gholami-Sefidkouhi, M. A. & Mobini, M. (2023). Prediction of daily evapotranspiration images of rice using machine learning. *Iranian Journal of Soil and Water Research*, 53 (12), 2793-2807. <https://doi.org/10.22059/ijswr.2022.350978.669391>

© The Author(s).

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2022.350978.669391>



پیش‌بینی تبخیر-تعرق روزانه برنج در مقیاس مزرعه با استفاده از رویکرد یادگیری ماشین

هما نوغان‌کار^۱ | محمود رائینی سرجاز^۲ | محمدعلی غلامی سفیدکوهی^۳ | مجید مبینی^۴^۱. گروه مهندسی آب، دانشکده مهندسی زراعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران. رایانامه: h.noghankar@stu.sanru.ac.ir^۲. گروه مهندسی آب، دانشکده مهندسی زراعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران. رایانامه: m.raeini@sanru.ac.ir^۳. نویسنده مسئول، گروه مهندسی آب، دانشکده مهندسی زراعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران. رایانامه:ma.gholami@sanru.ac.ir^۴. دانشکده مهندسی برق، موسسه آموزش عالی صنعتی مازندران، بابل، ایران. رایانامه: mobini@aut.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۱/۸/۲۰

تاریخ بازنگری: ۱۴۰۱/۹/۲۹

تاریخ پذیرش: ۱۴۰۱/۱۰/۳

تاریخ انتشار: ۱۴۰۱/۱۲/۱

واژه‌های کلیدی:

الگوریتم METRIC،

تلفیق تصاویر ماهواره‌ای،

ماشین بردار ارتباط،

LSTM

پیش‌بینی کوتاه‌مدت تبخیر-تعرق روزانه گیاه در کشاورزی دقیق و مدیریت آبیاری اهمیت فراوانی دارد. در این مقاله، روشی برای پیش‌بینی کوتاه مدت نقشه‌های تبخیر-تعرق روزانه گیاه برنج با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های یادگیری ماشین ارائه شده است. پس از تلفیق باندهای تصاویر لندست ۸ و مودیس با استفاده از روش STARFM، تصاویر تبخیر-تعرق روزانه به کمک الگوریتم METRIC تولید و برای پیش‌بینی نقشه‌های تبخیر-تعرق روزهای بعدی به عنوان ورودی به ماشین بردار ارتباط (RVM) و حافظه کوتاه-مدت طولانی (LSTM) اعمال شدند. دو سناریو برای پیش‌بینی در نظر گرفته شد. در سناریوی اول، با استفاده از یک تصویر و یک گام زمانی شش روزه، تصویر شش روز بعد پیش‌بینی شد. در سناریوی دوم، پیش‌بینی برای روزهای متوالی تا شش روز انجام شد. ضریب همبستگی بین مقادیر پیش‌بینی شده توسط RVM و مقادیر واقعی برای سناریوی اول و دوم به ترتیب ۰/۸۹ و ۰/۸۴ بدست آمد که نشان دهنده دقت قابل قبول این دو سناریو در پیش‌بینی تبخیر-تعرق است. در سناریوی نخست، مقادیر R2 برای دو روش RVM و LSTM به ترتیب برابر با ۰/۸ و ۰/۵۹ بدست آمد که نشان می‌دهد RVM در مقایسه با LSTM از دقت بیشتری برای پیش‌بینی تبخیر-تعرق برخوردار است. مقدار RMSE برای RVM در سناریوی اول و دوم به ترتیب برابر با ۰/۵۶ و ۰/۸۲ و مقدار MAE نیز به ترتیب برابر با ۰/۴۳ و ۰/۶۶ بدست آمد که نشان از خطای کمتر ناشی از پیکره‌بندی انجام شده در سناریوی اول می‌باشد.

استناد: نوغان‌کار، هما؛ رائینی سرجاز، محمود؛ غلامی سفیدکوهی، محمدعلی؛ مبینی، مجید. (۱۴۰۱). پیش‌بینی تبخیر-تعرق روزانه گیاه برنج با استفاده از رویکرد یادگیری

ماشین. تحقیقات آب و خاک ایران، ۵۳ (۱۲)، ۲۸۰۷-۲۷۹۳. <https://doi.org/10.22059/ijswr.2022.350978.669391>

ناشر: مؤسسه انتشارات دانشگاه تهران.

© نویسندگان.

DOI: <https://doi.org/10.22059/ijswr.2022.350978.669391>

مقدمه

تبخیر-تعرق (ET) یکی از اجزای اصلی چرخه آب در طبیعت است که به صورت مجموع تبخیر از سطح خاک و تعرق از سطح گیاه در پوشش‌های گیاهی تعریف می‌شود. برای مدیریت سامانه‌های آبیاری، ارائه پیش‌بینی کوتاه مدت قابل اطمینان از تبخیر-تعرق ضروری است. برآورد دقیق مصرف آب در مناطق کشاورزی برای برنامه‌ریزی، مدیریت و تنظیم منابع آب کشاورزی مهم است. تخصیص ناکافی آب بر رشد محصولات زراعی، برداشت و در نهایت امنیت غذایی تأثیر می‌گذارد. در کشاورزی دقیق، پیش‌بینی ET می‌تواند برای کشاورزان و مدیران منابع آب بعنوان چالش محسوب می‌شود (Talib et al., 2021).

با توجه به ضرورت پیش‌بینی تبخیر-تعرق، روش‌های عددی و آماری گوناگونی برای شبیه‌سازی ماهیت تصادفی این متغیر هواشناسی معرفی شده است. روش‌های قدیمی‌تر، مانند تحلیل سری زمانی، اغلب بر اساس ایستایی و خطی بودن رفتار سری زمانی بنا شده‌اند، در حالی که تبخیر-تعرق اساساً متغیری پویا و غیرخطی است (Chen et al., 2020). در نتیجه، رهیافت‌های تحلیل مبتنی بر یادگیری ماشین در سال‌های اخیر به گستردگی در زمینه کشاورزی و تحلیل داده‌های تبخیر-تعرق مورد استفاده قرار گرفته است (Liakos et al., 2018, Althoff et al., 2018, Carter and Liang, 2019, Dou and Yang, 2018, Ferreira et al., 2019, Elbeltagi et al., 2021, Patil and Deka, 2016). همچنین امروزه سنجش از دور به عنوان یک ابزار کارآمد برای برآورد تبخیر-تعرق، در مقیاس‌های مختلف زمانی و مکانی، شناخته می‌شود. این ابزار توانایی خوبی در جبران اختلاف بین اندازه‌گیری‌های نقطه‌ای با اندازه‌گیری‌های بزرگ-مقیاس دارد. (Sheffield et al., 2018) استفاده همزمان از الگوریتم‌های یادگیری ماشین و سنجش از دور منجر به ابداع روش‌های دقیق‌تر پیش‌بینی تبخیر-تعرق شده است (Dong et al., 2022, Granata 2019, Filgueiras et al., 2019). با وجود این توانایی‌ها، در برخی موارد مانند تصاویر ماهواره‌ای لندست و مودیس، وجود ابر و قدرت تفکیک مکانی پایین سنجنده منجر به از دست دادن اطلاعات زمانی و مکانی می‌شود. به همین دلیل، استفاده از این تصاویر برای پیش‌بینی در مقیاس کوچک، مثل مزرعه، با مشکل مواجه می‌شود. در این پژوهش از تلفیق تصاویر ماهواره‌ای لندست و مودیس استفاده شد، تا از این طریق پیش‌بینی روزانه تبخیر-تعرق واقعی در مقیاس مزرعه امکان‌پذیر شود.

پیشینه پژوهش

ماشین بردار ارتباطی از روش‌های یادگیری نظارت شده است که در آن با استفاده از یک رهیافت بیزی ۲ توزیع احتمال شرطی خروجی محاسبه می‌شود تا عدم قطعیت در پیش‌بینی لحاظ شود (Tipping, 2001). این مدل برای برآورد تبخیر-تعرق با استفاده از تصاویر چندطیفی در مقیاس بسیار کوچک (با دقت سانتی‌متر) در آمریکا مورد استفاده قرار گرفت (Newcome et al., 2021) همچنین چندین الگوریتم پیش‌بینی تبخیر-تعرق مرجع و عملکرد گیاه در ده ایالت آمریکا با یکدیگر مقایسه شده‌اند. در این پژوهش از چهار ترکیب متغیرهای ورودی، شامل دمای حداکثر و حداقل، تابش خالص، سرعت باد دو متری و رطوبت نسبی به عنوان متغیرهای پیش‌بینی استفاده شده است (Bhandari, 2021) و نتایج حاکی از عملکرد مناسب یادگیری ماشین در پیش‌بینی این متغیر دارد. ماشین بردار ارتباطی همچنین در چین برای برآورد تبخیر-تعرق ماهانه با روش‌های تجربی مقایسه شد و نتایج نشان داد که مدل‌های یادگیری ماشین برآورد دقیق‌تری نسبت به روش‌های تجربی برآورد تبخیر-تعرق ارائه می‌دهند (Lou et al., 2022).

یادگیری عمیق ۳ زیرمجموعه‌ای از یادگیری ماشین است که مبتنی بر شبکه‌های عصبی مصنوعی است. بسیاری از محققان از یادگیری عمیق برای تحلیل سری‌های زمانی استفاده کرده‌اند (Ahmed et al., 2021). به عنوان مثال، رهیافت‌های مختلف یادگیری عمیق برای پیش‌بینی سری‌های زمانی بارش (Hu et al., 2018)، کیفیت هوا (Dou and Yang, 2018)، جریان رودخانه (Damavandi et al., 2019) و تبخیر-تعرق (Tikhmarine et al., 2019) استفاده شده است. کارایی الگوریتم‌های RF^۴ و LSTM برای تخمین و پیش‌بینی تبخیر-تعرق روزانه ذرت، سویا و سیب زمینی در ۱۹ مزرعه در آمریکا در طول سال‌های ۲۰۰۳ تا ۲۰۱۹ مورد ارزیابی قرار گرفته که نتایج نشان می‌دهند مدل RF عملکرد بهتری نسبت به LSTM ارائه می‌دهد. همچنین، برای پیش‌بینی کوتاه مدت سه روزه، LSTM

1. Relevance Vector Machine (RVM)
2. Bayesian Approach
3. Deep Learning
4. Random Forest



حساسیت بیشتری به عدم قطعیت در متغیرهای پیش‌بینی‌کننده نشان می‌دهد (Talib et al., 2021). پژوهشگران همچنین دقت روش‌های LSTM و Bi-LSTM را با سایر روش‌های یادگیری ماشین در پیش‌بینی تبخیر-تعرق مرجع مقایسه کردند (Roy et al., 2021). بر اساس نتایج این پژوهش‌ها، روش Bi-LSTM در پیش‌بینی تبخیر-تعرق دارای دقت بیشتری نسبت به سایر روش‌های مقایسه شده است. در پژوهشی دیگر، LSTM برای پیش‌بینی تغییرات بلندمدت و کوتاه‌مدت تبخیر-تعرق روزانه استفاده شده است (Babaeian et al., 2021). مدل پیشنهادی آن‌ها با استفاده از داده‌های زمینی و داده‌های سنجش از دور پیکربندی شد و نتایج نشان داد که مدل LSTM پیش‌بینی‌های دقیق روزانه، هفتگی و ماهانه از تبخیر-تعرق روزانه در اقلیم‌های مختلف، انواع مختلف خاک و پوشش‌های گیاهی متفاوت ارائه می‌دهد.

نقشه‌برداری تبخیر-تعرق با توان جداسازی بالا با کالیبراسیون داخلی ۲ که به اختصار با نام METRIC شناخته می‌شود یک ابزار پردازش تصویر ماهواره‌ای برای محاسبه تبخیر-تعرق به عنوان باقیمانده تراز انرژی در سطح زمین است (Allen et al., 2007a). در این روش، تبخیر-تعرق روزانه با استفاده از معادله تراز انرژی محاسبه می‌شود. این الگوریتم METRIC ابتدا در ایالت آیداهوی آمریکا استفاده و نتایج آن با اندازه‌گیری‌های لایسیمتر مقایسه شد (Allen et al., 2007b). مقایسه خروجی مدل METRIC با مقادیر اندازه‌گیری شده توسط آتمومتر ۳ در داکوتای جنوبی (Reyes-González et al., 2017)، مقادیر محاسبه شده از برج‌های محاسبه شار (Numata et al., 2017) و روش تجربی بلانی-کریدل (Bchir et al., 2021) نیز قابلیت روش METRIC را تأیید می‌کند. در ایران این روش برای محاسبه تبخیر-تعرق برنج در استان گیلان مورد استفاده قرار گرفت و نتایج نشان‌دهنده قابلیت آن برای برآورد تبخیر-تعرق این گیاه در مقایسه با اندازه‌گیری‌های لایسیمتری بود (اسمعیلی و همکاران، ۱۳۹۶).

مرور مقالات نشان می‌دهد که استفاده از تصاویر روزانه سنجنده مودیس، به ویژه در مناطق ساحلی، برای پیش‌بینی روزانه تبخیر-تعرق واقعی در مقیاس مزرعه امکان‌پذیر نیست. زیرا وجود ابر و توان جداسازی مکانی پایین سنجنده منجر به از دست دادن اطلاعات زمانی و مکانی می‌شود. به عنوان مثال، در (Babaeian et al., 2021) از محصول تبخیر-تعرق مودیس برای پیش‌بینی تبخیر-تعرق در مقیاس قاره‌ای استفاده شده و تا کنون روشی برای پیش‌بینی در مقیاس کوچک، مثل مزرعه، ارائه نشده است. بنابراین، در این پژوهش از تلفیق تصاویر ماهواره‌ای لندست و مودیس استفاده شد، تا از این طریق پیش‌بینی روزانه تبخیر-تعرق واقعی در مقیاس مزرعه امکان‌پذیر شود. به عبارت دیگر، داده‌های مورد نیاز برای پیش‌بینی تبخیر-تعرق روزانه در مقیاس مزرعه به صورت مصنوعی با استفاده از یک روش شناخته شده به نام STARFM^۴ تولید شد و به عنوان داده ورودی در مدل‌های پیش‌بینی مورد استفاده قرار گرفت. در این تحقیق، برای پیش‌بینی کوتاه‌مدت تصاویر تبخیر-تعرق، از یک مدل یادگیری ماشین به نام RVM استفاده شد و نتایج آن با مقادیر حاصل از LSTM، که یک پیش‌بینی‌کننده مبتنی بر یادگیری عمیق است، مقایسه شد.

روش‌شناسی پژوهش

در پژوهش حاضر، تصاویر ورودی به مدل‌های پیش‌بینی از تلفیق زمانی-مکانی تصاویر ماهواره‌ای لندست ۸ و مودیس به دست آمده است. رهیافت تراز انرژی (Dingre et al., 2020) برای محاسبه تبخیر-تعرق روزانه استفاده شد. مطابق شکل ۱، این پژوهش شامل چهار مرحله شامل تهیه داده، پیش‌پردازش، پردازش و پیش‌بینی است.

۱. منطقه مورد مطالعه و داده‌ها

دانشگاه علوم کشاورزی و منابع طبیعی ساری در شمال شهر ساری در استان مازندران واقع شده است. با توجه به داده‌های نزدیک‌ترین ایستگاه سینوپتیک (دشت‌ناز)، مجموع بارش سالانه در این منطقه ۶۵۶ میلی‌متر، میانگین دمای آن ۱۷/۶ درجه سانتی‌گراد، رطوبت نسبی ۷۵ درصد و مجموع تبخیر سالانه ۱۱۸۷ میلی‌متر است. این پژوهش در محدوده پنجاه هکتار از اراضی شالیزاری مزرعه تحقیقاتی دانشگاه انجام شده است. داده‌های مورد استفاده در این پژوهش ترکیبی از داده‌های ایستگاهی و تصاویر ماهواره‌ای به شرح زیر است:

۱-۱. داده‌های زمینی

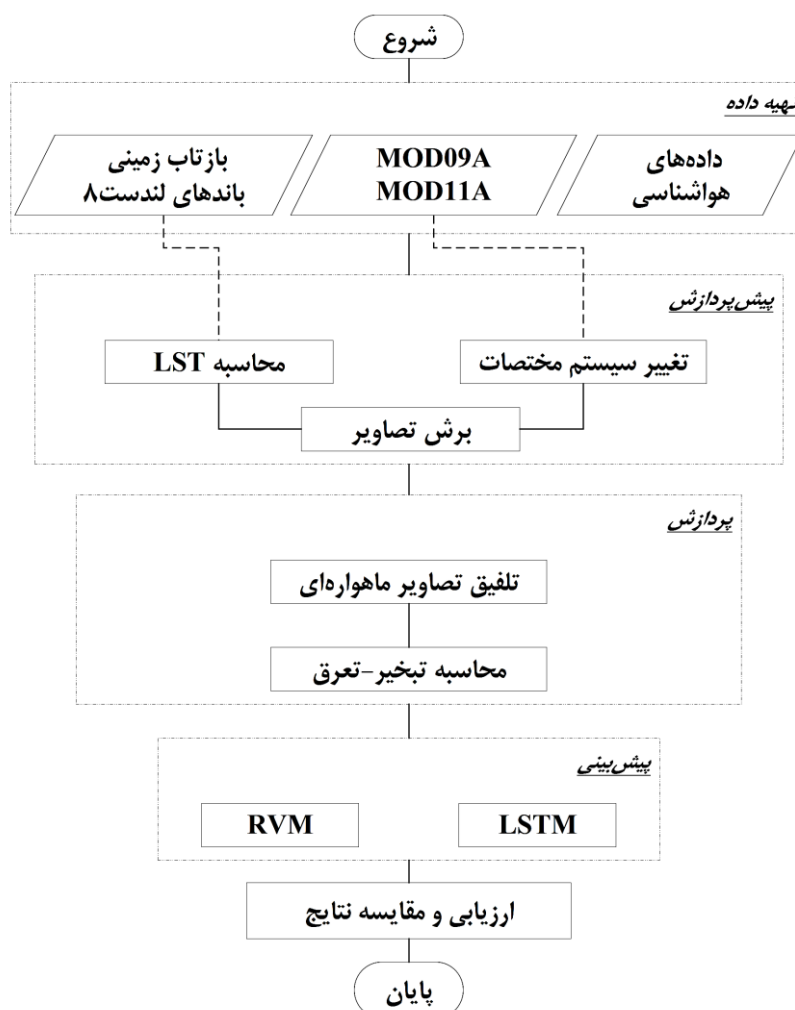
برای ارزیابی دقت مدل METRIC از اندازه‌گیری‌های میدانی تبخیر-تعرق روزانه توسط لایسیمتر استفاده شد. داده‌های ایستگاهی شامل

1. Bidirectional LSTM
2. Mapping Evapotranspiration at High Resolution with Internalized Calibration (METRIC)
3. Atmometer
4. Spatial and Temporal Adaptive Reflectance Fusion Model

دمای هوا، سرعت باد، تابش خورشیدی و رطوبت نسبی برای ماه‌های می تا آگوست سال ۲۰۱۸ بود که به صورت ساعتی از ایستگاه دشت‌ناز ساری، توسط اداره هواشناسی استان مازندران جمع‌آوری شد.

۲-۱. داده‌های سنجش از دور

" امروزه تصاویر سنتینل-۲ با توان جداسازی مکانی ۱۰ متر و فاصله زمانی ۳ تا ۵ روز در دسترس هستند، اما این داده‌ها فاقد باند حرارتی بوده و برای محاسبه تبخیر-تعرق با استفاده از روش‌های تراز انرژی مناسب نیستند. ماهواره سنتینل-۳ اقدام به تصویربرداری در محدوده باند گرمایی می‌کند که به علت قدرت تفکیک مکانی ناکافی (۳۰۰ متر) برای پیش‌بینی در مقیاس کوچک مناسب نیست. با توجه به توان جداسازی مکانی مناسب تصاویر لندست ۸ (۳۰ متر در باندهای مرئی، فرورسرخ نزدیک و SWIR)، این ماهواره برای انجام این پژوهش انتخاب شد. تصاویر مورد نظر از پایگاه داده GEE۱ استخراج شد که شامل بازتاب زمینی باندهای ۲ تا ۷ در سال ۲۰۱۸ برای ماه‌های می تا آگوست (دوره رشد - کشت اول) است. تعداد تصاویر استخراج شده در این بازه زمانی ۱۴ تصویر با تصحیحات رادیومتری و اتمسفری است. تصاویر دمای سطح زمین ۲ با استفاده از فضای برنامه‌نویسی GEE محاسبه و دریافت شد. بنابراین هر تصویر لندست نهایی شامل سه باند مرئی، یک باند فرورسرخ نزدیک، دو باند فرورسرخ موج کوتاه و یک باند LST است. هر یک از تصاویر لندست به اندازه محدوده مورد مطالعه برش خوردند که نتیجه آن تصاویری با ابعاد ۵۳×۴۹ پیکسل با ابعاد ۳۰ متر بود. همچنین محصولات MOD09 برای بازتاب زمینی و MOD11A1 برای دمای روزانه سطح زمین از سنجنده مودیس انتخاب شدند. پس از تغییر سیستم مختصات تصاویر مودیس از سیستم جغرافیایی به UTM، ابعاد پیکسل‌ها، با استفاده از نرم‌افزار ENVI 5.3 به ۳۰ متر تبدیل شد و این تصاویر نیز به ابعاد ۵۳×۴۹ پیکسل برش داده شدند. از مجموع ۱۲۳ تصویر دریافت شده مودیس، ۴۵ تصویر قابل استفاده بود و بقیه به دلیل ابری بودن حذف شدند.



شکل ۱. مراحل انجام روش پیشنهادی

۲. تلفیق تصاویر ماهواره‌ای

در این مرحله، بعد از پردازش ابتدائی تصاویر لندست ۸ و مودیس و یکسان‌سازی سیستم مختصات، اندازه پیکسل‌ها و ابعاد تصاویر، باندهای متناظر دو سنجنده با استفاده از الگوریتم STARFM (Gao et al., 2006) تلفیق شدند. هدف از این کار تولید تصاویر مصنوعی لندست ۸ برای روزهایی است که تصاویر اصلی در دسترس نیستند. با توجه به اینکه هدف پژوهش، پیش‌بینی کوتاه‌مدت تبخیر-تعرق در مقیاس مزرعه است استفاده از تصاویر مودیس یا لندست به تنهایی به دلیل تعداد زیاد تصاویر ابری در روزهای متوالی و ناکافی بودن داده‌های ورودی امکان‌پذیر نیست. بنابراین، در این پژوهش تلاش شد تا نقشه‌های تبخیر-تعرق به طور مصنوعی با استفاده از الگوریتم تلفیق زمانی-مکانی تولید شوند. هشت زوج تصویر لندست-مودیس در بازه زمانی مورد مطالعه موجود بود که به عنوان ورودی اولیه مدل STARFM برای تولید تصاویر مصنوعی لندست در نظر گرفته شدند. سپس هر تصویر مصنوعی لندست به عنوان ورودی جدید برای تولید تصاویر مصنوعی روز بعد استفاده شد. جدول ۱ مشخصات باندهای استفاده شده را نشان می‌دهد. مطابق جدول ۱، هر باند لندست با باند متناظر خود از تصاویر مودیس، توسط الگوریتم STARFM، تلفیق شد. به این ترتیب، در تاریخ‌هایی که تصویر اصلی لندست موجود نبود به کمک این الگوریتم یک تصویر مصنوعی لندست تولید شد.

جدول ۱. باندهای متناظر قابل تلفیق لندست ۸ و مودیس

لندست ۸				مودیس			
توان جداسازی مکانی (متر)	میانگین طول موج (میکرومتر)	شرح باند	شماره باند	توان جداسازی مکانی (متر)	میانگین طول موج (میکرومتر)	شرح باند	شماره باند
۳۰	۰/۶۵۵	RED	۴	۲۵۰	۰/۶۴۵	VIS	۱
۳۰	۰/۸۶۵	NIR	۵	۲۵۰	۰/۸۵۸۵	NIR	۲
۳۰	۰/۴۸۲۵	BLUE	۲	۵۰۰	۰/۴۶۹	VIS	۳
۳۰	۰/۵۶۲۵	GREEN	۳	۵۰۰	۰/۵۵۵	VIS	۴
۳۰	۱/۶۱	SWIR	۶	۵۰۰	۱/۶۴	SWIR	۶
۳۰	۲/۲	SWIR	۷	۱۰۰۰	۲/۱۳	SWIR	۷

۳. محاسبه تبخیر-تعرق روزانه با استفاده از روشی METRIC

در این مرحله با استفاده از الگوریتم METRIC، مقدار تبخیر-تعرق روزانه به کمک محیط برنامه نویسی IDL 8.5 و نرم‌افزار ENVI 5.3 محاسبه شد. METRIC یک ابزار پردازش تصویر ماهواره‌ای برای محاسبه تبخیر-تعرق با استفاده از معادله تراز تابش در سطح زمین است (Allen et al., 2007a).

$$LE = R_n - G - H \quad \text{رابطه (۱)}$$

که در آن، LE چگالی شار گرمای نهان، R_n چگالی شار تابش خالص (برآیند تابش موج کوتاه ورودی و بلند موج بلند خروجی در سطح زمین)، G چگالی شار گرمایی خاک و H چگالی شار گرمای محسوس است. پارامترهای این معادله بر حسب وات بر متر مربع بیان می‌شود. پس از محاسبه LE از رابطه ۱، مقدار تبخیر-تعرق در لحظه تصویربرداری ماهواره در هر پیکسل با استفاده از رابطه زیر به دست می‌آید.

$$ET_{inst} = 3600 \frac{LE}{\lambda p_w} \quad \text{رابطه (۲)}$$

که در آن، ET_{inst} تبخیر-تعرق لحظه‌ای (بر حسب میلی‌متر بر ساعت)، عدد ۳۶۰۰ ضریب تبدیل ساعت به ثانیه، λ گرمای نهان تبخیر (بر حسب ژول بر کیلوگرم) و تابعی از دمای سطح است (آلن و همکاران، ۲۰۰۷ الف) و p_w چگالی آب است که تقریباً برابر با ۱۰۰۰ کیلوگرم بر متر مکعب در نظر گرفته می‌شود. تبخیر-تعرق مرجع جزئی ($ET_r F$) به صورت نسبت تبخیر-تعرق لحظه‌ای محاسبه شده از هر پیکسل به تبخیر-تعرق مرجع محاسبه شده از داده‌های هواشناسی تعریف می‌شود.

$$ET_r F = \frac{ET_{inst}}{ET_r} \quad \text{رابطه (۳)}$$

که در آن، مفهوم ET_rF مشابه مفهوم ضریب گیاهی ۱ (Kc) است و برای تبدیل تبخیر-تعرق لحظه‌ای به تبخیر-تعرق ۲۴ ساعته استفاده می‌شود. در این پژوهش در فرآیند کالیبراسیون داخلی، برای تعیین پیکسل‌های گرم و سرد از الگوریتم جستجوی جامع ۲ (Bhattari et al., 2017) استفاده شده است.

به طور کلی، مقادیر روزانه تبخیر-تعرق (ET_{r24}) کاربردی‌تر از مقادیر تبخیر-تعرق لحظه‌ای در زمان تصویربرداری ماهواره است. بنابراین در روش METRIC با فرض این که ET_rF لحظه‌ای محاسبه شده در زمان تصویربرداری برابر با میانگین ET_rF بیست و چهار ساعته است، ET_{r24} با استفاده از رابطه زیر محاسبه می‌شود.

$$ET_{24} = ET_rF \times ET_{r24} \quad \text{رابطه ۴}$$

که در آن، ET_{r24} برابر است با مجموع تبخیر-تعرق‌های ساعتی در طول یک روز.

۴. پیش‌بینی با استفاده از ماشین بردار ارتباط (RVM)

در این مقاله، RVM برای پیش‌بینی تبخیر-تعرق روزانه (ET) با استفاده از تصاویر روزهای قبل (X) به عنوان پیش‌بینی‌کننده مورد استفاده قرار گرفته است. مفهوم ماشین بردار ارتباط به عنوان یک مدل پیش‌بینی‌کننده ابتدا توسط تیپینگ برای بازنویسی ایده‌های اولیه الگوریتم ماشین بردار پشتیبان با یک رهیافت بیزی مطرح شد. توضیح مختصری از RVM در اینجا ارائه شده است، جزئیات بیشتر در کارهای تیپینگ قابل پیگیری است (Tipping, 2001). شکل کلی مدل به صورت زیر است:

$$ET = f(X; w) + \epsilon_n \quad \text{رابطه ۵}$$

در این رابطه، $\epsilon_n = N(0, \sigma^2)$ نویز با توزیع نرمال با میانگین صفر و واریانس σ^2 ، و $w = (w_0, \dots, w_N)^T$ بردار وزن‌هاست. تابع شباهت مجموعه داده به صورت رابطه ۶ نوشته می‌شود

$$p(ET | w, \sigma^2) = (2\pi\sigma^2)^{N/2} \exp\left\{-\frac{1}{2\sigma^2} \|ET - \Phi w\|^2\right\} \quad \text{رابطه ۶}$$

که در آن $ET = (ET_1, \dots, ET_N)^T$ ، و $\Phi = [\phi(x_1), \phi(x_2), \dots, \phi(x_N)]^T$ ماتریس طراحی است، به طوری که $\phi(x_n) = [1, K(x_n, x_1), K(x_n, x_2), \dots, K(x_n, x_N)]^T$ در اینجا شمارنده‌های ۱ تا N مربوط به شماره پیکسل‌ها در تصاویر ماهواره‌ای است، به طوری که هر پیکسل به عنوان یک داده آموزشی به کار می‌رود. بدون اعمال فرآیندهای روی وزن‌ها، تابع بیشترین شباهت ۳ به شدت دچار بیش‌برازش می‌شود. بنابراین، با اضافه کردن یک شرط به تابع بیشترین شباهت یا تابع خطا یک محدودیت ایجاد می‌شود. در اینجا یک توزیع نرمال احتمال پیشین ۴ با میانگین صفر و کوواریانس قطری روی وزن‌ها اعمال شده است

$$p(w | \alpha) = \prod_{i=0}^N N(w_i | 0, \alpha_i^{-1}) \quad \text{رابطه ۷}$$

که α بردار فرآیندهای با طول N+1 است. قانون بیز برای محاسبه احتمال پسین ۵ روی تمام مجهول‌ها به صورت رابطه ۸ است

$$p(w, \alpha, \sigma^2 | ET) = \frac{p(ET | w, \alpha, \sigma^2) \cdot p(w, \alpha, \sigma^2)}{\int p(ET | w, \alpha, \sigma^2) p(w, \alpha, \sigma^2) dw d\alpha d\sigma^2} \quad \text{رابطه ۸}$$

حل تحلیلی معادله ۸ امکان‌پذیر نیست، بنابراین با توجه به اینکه $p(w, \alpha, \sigma^2 | ET) = p(w | ET, \alpha, \sigma^2) p(\alpha, \sigma^2 | ET)$ تجزیه احتمال پسین برای حل آن مورد استفاده قرار می‌گیرد. در نتیجه احتمال پسین روی وزن‌ها به صورت رابطه ۹ نوشته می‌شود

$$p(w | ET, \alpha, \sigma^2) = \frac{p(ET | w, \sigma^2) p(w | \alpha)}{p(ET | \alpha, \sigma^2)} = (2\pi)^{-(N+1)/2} |\Sigma|^{-1/2} \exp\left\{-\frac{1}{2} (w - \mu)^T \Sigma^{-1} (w - \mu)\right\} \quad \text{رابطه ۹}$$

کوواریانس و میانگین توزیع به ترتیب به صورت $\Sigma = (\sigma^2 \Phi^T \Phi + A)^{-1}$ و $\mu = \sigma^2 \Sigma \Phi^T ET$ بیان می‌شوند که در آن A ماتریس قطری بصورت $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$ است. با یکپارچه‌سازی وزن‌ها، احتمال حاشیه‌ای برای پارامترهای فوق بدست می‌آید

$$p(ET|\alpha, \sigma^2) = \left((2\pi)^{-N/2} / \sqrt{|\sigma^2 + \Phi A^{-1} \Phi^T|} \right) \times \exp \left\{ -\frac{1}{2} ET^T (\sigma^2 + \Phi A^{-1} \Phi^T)^{-1} ET \right\} \quad \text{رابطه ۱۰}$$

برای تخمین فراپارامترها از روش گرادیان کاهشی بر روی تابع هدف استفاده می‌شود. در نتیجه، بیشتر اجزای بردار α به سمت صفر میل می‌کنند، زیرا w تنها شامل تعداد اندکی وزن غیرصفر است که به عنوان بردار مرتبط شناخته می‌شوند. در این مقاله، همه تصاویر ET ابتدا بصورت بردارهای یک بعدی درآمده و سپس برای آموزش الگوریتم RVM و LSTM مورد استفاده قرار گرفتند. بنابراین، از آنجا که تصاویر ET با ابعاد 53×49 پیکسل در این آزمایشات مورد استفاده قرار گرفته‌اند، ورودی الگوریتم بصورت برداری به طول ۲۵۹۷ خواهد بود.

۵. پیش‌بینی با استفاده از LSTM

یادگیری عمیق از شبکه‌های عصبی مصنوعی استفاده می‌کند که در هر لایه از آن، یک تبدیل خطی را به داده‌های ورودی اعمال می‌کنند و نتیجه تبدیل خطی هر لایه، به یک تابع فعال‌ساز غیرخطی وارد می‌شود. واژه "عمیق" به وجود لایه‌های بسیار اشاره دارد، هرچند، مقالات موجود بر سر تعداد مشخصی از لایه‌ها اتفاق نظر ندارند. همچنین، آرایش‌های مختلفی از لایه‌ها می‌تواند به عنوان ساختار شبکه‌های عصبی عمیق به کار گرفته شود. در این پژوهش از یک روش پیش‌بینی مبتنی بر حافظه‌های کوتاه-مدت طولانی استفاده شده، که نوع خاصی از شبکه‌های عصبی بازگشتی (RNN) است و می‌تواند وابستگی‌های بلند مدت نمونه‌ها را نیز در نظر بگیرد. یک RNN در حالت استاندارد، شامل یک لایه پنهان $h(t)$ یک خروجی X و دنباله ورودی $x = x(1), \dots, x(T)$ است. حالت پنهان $h(t)$ در هر گام زمانی با استفاده از رابطه (۱۱) به روز می‌شود.

$$h(t+1) = \psi(x(t), h(t)) \quad \text{رابطه ۱۱}$$

که در آن، ψ یک تابع فعال‌ساز غیرخطی، مانند تابع سیگموئید لجستیک ۲ است. RNN می‌تواند توزیع احتمال یک دنباله را بیاموزد و در مرحله آزمایش، نمونه بعدی یک دنباله دیگر را پیش‌بینی کند. در مسائل پیش‌بینی از نوع دنباله به دنباله ۳، دنباله بعدی بطور کامل و با توجه به دنباله قبلی پیش‌بینی می‌شود. در این تحقیق برای پیاده‌سازی پیش‌بینی‌کننده، از واحدهای LSTM آماده، که در جعبه ابزار شبکه‌های عصبی نرم افزار MATLAB قابل دستیابی هستند، استفاده شد. از آنجا که مسئله پیش‌بینی جزو مسائل استاندارد رگرسیون است، می‌توان از پیکره بندی‌های رایج، مانند پیکره بندی ارائه شده در شکل ۲، برای حل مسئله استفاده کرد. این ساختار با یک لایه ورودی، یک لایه LSTM و یک لایه کاملاً متصل (FC) آغاز شده و در نهایت، با یک لایه رگرسیون به پایان می‌رسد. در این پژوهش از رهیافت جعبه سیاه برای LSTMها استفاده شد، یعنی از چگونگی ساختار داخلی لایه‌ها صرف‌نظر و تنها به تحلیل ورودی و خروجی آن‌ها اکتفا می‌شود.



شکل ۲. معماری کلی یک پیش‌بینی‌کننده مبتنی بر LSTM

ارزیابی نتایج

نتایج پیش‌بینی‌های انجام شده در مراحل قبل توسط پنج شاخص متداول شامل ریشه میانگین مربعات خطا^۱، ضریب تبیین، شاخص نش-ساتکلیف^۲، شاخص سازگاری^۳ و میانگین قدر مطلق خطا^۴ ارزیابی شده است. در تمامی این شاخص‌ها مقدار پیش‌بینی شده توسط مدل با مقدار تبخیر-تعرق محاسبه شده توسط الگوریتم METRIC مقایسه می‌شود.

یافته‌های پژوهشی

پس از تولید تصاویر مصنوعی لندست برای بازه زمانی از اول ماه می تا پایان آگوست ۲۰۱۸ با استفاده از الگوریتم STARFM، با توجه به توالی تصاویر به دست آمده، داده‌های ورودی برای مدل پیش‌بینی انتخاب شدند. برای مثال، از آنجا که تصویر اصلی لندست در روز ۱۸۱ (مقصود روز ژولوسی است) موجود نبود با استفاده از تلفیق تصویر لندست روز ۱۸۱ و تصویر مودیس در روزهای ۱۸۰ و ۱۸۱ تصویر مصنوعی لندست در روز ۱۸۱ تولید شده است. این مراحل برای همه روزهای بدون ابر و همه باندهای متناظر تصاویر لندست و مودیس (مطابق جدول ۱) انجام شد. از میان تصاویر به دست آمده، تصاویر روزهای ۱۸۱، ۱۸۲، ۱۸۳، ۱۸۶، ۱۸۷ و ۱۹۳ برای استفاده در مدل‌های پیش‌بینی انتخاب شدند. با توجه به اینکه آموزش و تست مدل‌های پیش‌بینی در این مقاله با استفاده از تصاویر تبخیر-تعرق روزانه انجام می‌شود، تبخیر-تعرق روزانه برای این روزها با استفاده از الگوریتم METRIC محاسبه شد. دو سناریو برای آموزش مدل پیش‌بینی به کار گرفته شد.

۱. سناریوی اول

در این سناریو، مراحل آموزش و آزمایش بدین صورت تنظیم شدند که مدل ابتدا تصاویر ET مربوط به دو روز مشخص از سال با فاصله زمانی ۶ روز (در اینجا روزهای ۱۸۱ و ۱۸۷ سال) را بعنوان داده‌های آموزشی دریافت کند و بر اساس این تصاویر آموزش ببیند. در مرحله آزمایش، پیش‌بینی‌کننده‌ای که به طور کامل آموزش داده شده می‌تواند تصویر ۶ روز بعد (یعنی روز ۱۹۳) را پیش‌بینی کند. مقادیر واقعی تبخیر-تعرق روز ۱۹۳ برای سنجش عملکرد مدل استفاده شد. در جدول ۲، پارامترهای در نظر گرفته شده برای مدل‌های LSTM و RVM نمایش داده شده است. در این جدول، P_{sparse} احتمال استفاده نشدن تابع پایه توسط مدل مولد است. به عنوان مثال، اگر $P_{sparse} = 0.9$ باشد، تنها ۱۰ درصد از توابع پایه (به طور متوسط) برای سنتز داده‌ها استفاده می‌شود. توزیع نرمال به عنوان توزیع اولیه وزن‌ها انتخاب شده است.

جدول ۲. پارامترهای انتخاب شده برای مدل‌های LSTM و RVM

مدل		پارامتر
LSTM	RVM	
۵۳×۴۹	۵۳×۴۹	ابعاد تصاویر ET
-	۰/۹	P_{sparse}
۱۰۰	۱۰۰	تعداد تکرارها (Iterations)
-	۲	عرض توابع پایه (Basis width)
۱	-	تعداد واحدهای پنهان ۵
۳	-	سایز ریز-قطعه‌ها ۶
۰/۰۱	-	نرخ آموزش

شکل ۳ (الف)، مقادیر ET ورودی و هدف در مرحله آموزش را نشان می‌دهد. در اینجا مدل می‌آموزد که تصویر روز $t+6$ را با استفاده از تصویر روز t -م پیش‌بینی کند. بنابراین در این شکل، ورودی، تصویر تبخیر-تعرق محاسبه شده توسط METRIC در روز ۱۸۱، و هدف تصویر تبخیر-تعرق محاسبه شده توسط METRIC در روز ۱۸۷ است. ذکر این نکته ضروری است که تصاویر ET ابتدا بصورت بردارهای

1. Root Mean Square Error
 2. Nash-Sutcliffe Index
 3. Index of Agreement
 4. Mean Absolute Error
 5. Number of hidden units
 6. Mini-batch size


یک بعدی درآمده و سپس برای آموزش مدل RVM استفاده شدند. بنابراین، از آنجا که تصاویر ET ورودی و هدف دارای ابعاد ۵۳×۴۹ پیکسل بودند، برای استفاده در مدل تبدیل به بردارهایی به طول ۲۵۹۷ شدند. در شکل ۳، برای اینکه مقادیر ET ورودی و هدف به لحاظ بصری از یکدیگر قابل تشخیص باشند، تنها ۴۰۰ مقدار نخست از بردارهای ET نمایش داده شده است. در سناریوی اول، مرحله آموزش بدین صورت تنظیم شده که الگوریتم RVM مقادیر ET مربوط به دو روز مشخص از سال با فاصله زمانی ۶ روز (در اینجا روزهای ۱۸۱ و ۱۸۷ سال) را دریافت کند و با استفاده از ۱۰۰ تکرار، فرآیند آموزش انجام شود. بعد از آنکه پیش‌بینی‌کننده توسط مقادیر ET مربوط به روزهای ۱۸۱ و ۱۸۷ سال آموزش دید، می‌توان مرحله آزمایش را آغاز کرد. در مرحله آزمایش الگوریتم با دریافت تصویر روز ۱۸۷ تصویر ۶ روز بعد (یعنی روز ۱۹۳) را پیش‌بینی می‌کند. شکل ۳ (ب)، مقادیر ET پیش‌بینی شده و محاسبه شده توسط METRIC را در مرحله آزمایش نشان می‌دهد. از آنجا که مدل به خوبی آموزش دیده، مقادیر پیش‌بینی شده (خطوط توپر) به مقادیر واقعی (مقادیر مشخص شده با نقطه چین) بسیار نزدیک است.

۲. سناریوی دوم

پیش‌بینی در گام‌های یک روزه دارای این مزیت ذاتی است که می‌تواند پیش‌بینی را برای تمام روزهای سال، از جمله روزهایی که هیچ اطلاعات دقیقی در مورد مقادیر ET در دسترس نیست فراهم کند. بنابراین در سناریوی دوم مراحل آموزش و آزمایش بدین صورت تنظیم شدند که الگوریتم ابتدا تصاویر ET مربوط به دو روز پیاپی را دریافت و در مرحله آزمایش، تصاویر ۳ روز بعد (یعنی روز ۱۸۶) را پیش‌بینی کند. به عبارت دیگر، در مرحله آموزش مدل مورد نظر می‌آموزد که تصویر روز ۱۸۳ در پی تصویر روز ۱۸۲ خواهد بود و سپس در فاز آزمایش، با داشتن تصویر روز ۱۸۳ به ترتیب تصاویر شماره ۱۸۴، ۱۸۵ و ۱۸۶ را یکی پس از دیگری پیش‌بینی می‌کند. در این سناریو نیز پارامترهای مدل‌های RVM و LSTM مطابق با جدول ۲ تنظیم شدند.


بحث

در شکل ۴ (الف)، مقادیر ET پیش‌بینی شده توسط RVM در مقابل مقادیر واقعی ET در سناریوی اول رسم شده و شکل ۴ (ب) نیز مقادیر ET پیش‌بینی شده توسط RVM در مقایسه با مقادیر واقعی ET را در سناریوی دوم نشان می‌دهد. خط مشکی رنگ، نیمساز ربع اول است. همانطور که ملاحظه می‌شود، داده‌ها در سناریوی دوم پراکنش بهتری حول نیمساز ربع اول دارند. با این حال، بر اساس نتایج آزمون t-student در هر دو سناریو، تفاوت معنی‌داری بین مقدار پیش‌بینی شده و مقدار واقعی مشاهده نمی‌شود. با توجه به مقادیر ضریب همبستگی در جداول ۳ و ۴، مقادیر پیش‌بینی شده توسط RVM و مقادیر واقعی در هر دو سناریو، دارای ضریب همبستگی نسبتاً بالایی هستند (به ترتیب $۰/۸۹$ و $۰/۸۴$ برای سناریوی اول و دوم) و این نشان می‌دهد که استفاده از این دو سناریو به پیش‌بینی دقیق ET کمک می‌کند. در هر دو روش RVM و LSTM ضریب همبستگی مقداری مثبت است، یعنی با افزایش مقادیر واقعی مقادیر پیش‌بینی نیز افزایش یافته و پیش‌بینی‌کننده به خوبی می‌تواند مقادیر واقعی را دنبال کند. در سناریوی اول، مقادیر R^2 برای دو روش RVM و LSTM به ترتیب برابر با $۰/۸$ و $۰/۵۹$ ثبت شده، که این مقادیر نشان می‌دهد پیش‌بینی مقادیر روزانه ET به روش RVM نسبت به روش LSTM دارای دقت بیشتری است.



شکل ۳. مقادیر ET ورودی و هدف در مرحله آموزش (الف)؛ مقادیر ET پیش‌بینی شده و محاسبه شده در مرحله آزمایش (ب)

در جدول ۳، عملکرد دو روش LSTM و RVM در سناریوی اول مقایسه شده است. برای مقایسه از شاخص‌های RMSE، ضریب تبیین (R^2)، شاخص نش-ساتکلیف (E)، شاخص سازگاری (IA)، ضریب همبستگی (R) و میانگین قدر مطلق خطا (MAE) استفاده شده است. با مقایسه تصویر ۱۹۳ که توسط الگوریتم پیش‌بینی شده و تصویر واقعی مربوط به روز ۱۹۳، معیارهای اندازه‌گیری محاسبه و در جدول ۳ درج شده‌اند.



شکل ۴. مقادیر ET پیش‌بینی شده توسط RVM در مقابل مقادیر واقعی در سناریوی اول (الف) و در سناریوی دوم (ب)

جدول ۴ مقایسه‌ای از عملکرد دو روش LSTM و RVM در سناریوی دوم ارائه می‌دهد. با مقایسه تصویر ۱۸۶ که توسط الگوریتم پیش‌بینی شده با تصویر واقعی مربوط به روز ۱۸۶، شاخص‌های RMSE، R^2 ، E ، IA و R محاسبه و در این جدول درج شده‌اند.

جدول ۳. مقایسه نتایج دو روش LSTM و RVM در سناریوی اول

روش پیش‌بینی		معیار اندازه‌گیری
LSTM	RVM	
۰/۹۴	۰/۵۶	RMSE
۰/۵۹	۰/۸۰	R^2
۰/۲۳	۰/۷۲	E
۰/۶۹	۰/۹۳	IA
۰/۶۷	۰/۸۹	R
۰/۸۱	۰/۴۳	MAE

اگر مقادیر بدست آمده برای RMSE را برای روش RVM در سناریوی اول و دوم مقایسه شود، مشاهده می‌شود که این مقدار برای سناریوی اول و دوم به ترتیب برابر با ۰/۵۶ و ۰/۸۲ ثبت شده است. این مقادیر نشان می‌دهد که پیکره‌بندی انجام شده در سناریوی اول منجر به خطای کمتری در پیش‌بینی شده است. مقادیر بدست آمده برای MAE برای روش RVM در سناریوی اول و دوم نیز به ترتیب برابر با ۰/۴۳ و ۰/۶۶ است و این مقادیر نتایج مربوط به RMSE را تأیید می‌کند.

جدول ۴. مقایسه نتایج دو روش LSTM و RVM در سناریوی دوم

روش پیش‌بینی		معیار اندازه‌گیری
LSTM	RVM	
۱/۱۷	۰/۸۲	RMSE
۰/۷۰	۰/۷۸	R^2
۰/۴۰	۰/۷۰	E
۰/۸۲	۰/۹۳	IA
۰/۸۸	۰/۸۴	R
۰/۸۸	۰/۸۴	MAE

نتیجه گیری

تبخیر-تعرق مهمترین عامل تلفات آب در کشاورزی است. بکارگیری راهبردهای کارآمدتر کاهش تبخیر-تعرق برای دستیابی به مدیریت پایدار آب در مناطق کشاورزی مهم است. بنابراین، بهبود کارایی مصرف آب و مدیریت پایدار آب در کشاورزی باید بر اساس پیش‌بینی هرچه دقیق‌تر تبخیر-تعرق باشد. در این مقاله، روشی برای پیش‌بینی کوتاه مدت تصاویر تبخیر-تعرق روزانه گیاه برنج با استفاده از تصاویر ماهواره‌ای و الگوریتم‌های مبتنی بر RVM و LSTM ارائه، و از شاخص‌های آماری رایج برای مقایسه و تجزیه و تحلیل مدل‌های پیش‌بینی استفاده شد. نتایج این پژوهش نشان می‌دهد که استفاده از این تکنیک‌ها منجر به پیش‌بینی دقیق‌تر تبخیر و تعرق می‌شوند، اما در بین این دو، مدل مبتنی بر RVM عملکردهای آماری بهتری را ارائه کرد و برای تخمین ET برای منطقه مورد مطالعه توصیه شد. همچنین بررسی و مقایسه شاخص‌های آماری برای دو سناریوی متفاوت انجام شد که در سناریوی نخست پیش‌بینی به صورت گام‌های زمانی شش روزه و در سناریوی دوم پیش‌بینی به صورت گام‌های متوالی یک روزه در نظر گرفته شد. در هر دو سناریو، مدل RVM پیش‌بینی دقیق‌تری نسبت به LSTM ارائه داد. هرچند سناریوی دوم پیش‌بینی را به صورت گام به گام و در گام‌های زمانی یک روزه ارائه می‌دهد، ولی در نهایت برای پیش‌بینی روز هدف (روز ششم) سناریوی اول دارای دقت بیشتری است. با توجه به نتایج به‌دست‌آمده در این تحقیق، می‌توان مدیریت آبیاری را با استفاده از داده‌های روزانه در دسترس مانند تصاویر مودیس و لندست انجام داد. استفاده از سایر سنسورها، و نیز روش‌های دیگر تلفیق تصاویر ماهواره‌ای برای تولید داده‌های با توان جداسازی زمانی و مکانی بهتر، می‌تواند زمینه مناسبی برای پژوهش‌های آتی باشد. همچنین، استفاده از انواع مدل‌های ترکیبی یادگیری عمیق، مثل ConvLSTM و LSTM+CNN، که قابلیت پردازش داده‌های چندبعدی را دارند نیز می‌تواند در پژوهش‌های آینده در نظر گرفته شود.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

منابع

اسمعیلی، سرور؛ خوشخو، یونس؛ بابایی، خالد؛ اسعدی اسکویی، ابراهیم. (۱۳۹۶). برآورد تبخیر و تعرق واقعی محصول برنج با به کارگیری الگوریتم METRIC در بخشی از شمال ایران. نشریه پژوهش‌های حفاظت آب و خاک، ۲۴ (۶). ۱۰۵-۱۲۲

REFERENCES

- Ahmed AM, Deo RC, Feng Q, Ghahramani A, Raj N, Yin Z, Yang L. (2021). Hybrid deep learning for week-ahead evapotranspiration forecasting. *Stoch Environ Res Risk Assess* 36, 831–849.
- Allen RG, Tasumi M, Morse A, Trezza R, Wright JL, Bastiaanssen W, Kramber W, Lorite I, Robison CW. (2007a). Satellite-based energy balance for mapping evapotranspiration with internalized calibration (metric)—applications. *Journal of irrigation and drainage engineering*. 133(4):395–406.
- Allen RG, Tasumi M, Trezza R. (2007b). Satellite-based energy balance for mapping evap-otranspiration with internalized calibration (metric)—model. *Journal of irrigation and drainage engineering*. 133(4):380–394.
- Althoff D, Bazame HC, Filgueiras R, Dias SHB. (2018). Heuristic methods applied in reference evapotranspiration modeling. *Ciência e Agrotecnologia*. 42:314–324.
- Babaeian E, Paheding S, Siddique N, Devabhaktuni VK, Tuller M. (2021). Forecasting of evapotranspiration from ground and remote sensing observations with deep learning. In: *AGU Fall Meeting 2021*. AGU.
- Bchir, A., M'nassri, S., Dhib, S., Amri, A. E., & Mulla, D. (2021). Estimating and mapping evapotranspiration in olive groves of semi-arid Tunisia using empirical formulas and satellite remote sensing. *Arabian Journal of Geosciences*, 14(24), 1-9.
- Bhandari SK. (2021). Application of machine learning for estimating reference evapotranspiration and crop yield based on climatological data [Master dissertation]. Kansas State University, Manhattan, Kansas
- Bhattarai N, Quackenbush LJ, Im J, Shaw SB. (2017). A new optimized algorithm for automating endmember pixel selection in the sebal and metric models. *Remote Sensing of Environment*. 196:178–192.
- Carter C, Liang S. (2019). Evaluation of ten machine learning methods for estimating terrestrial evapotranspiration from remote sensing. *International Journal of Applied Earth Observation and Geoinformation*. 78:86–92.
- Chen, J. M., & Liu, J. (2020). Evolution of evapotranspiration models using thermal and shortwave remote sensing data. *Remote Sensing of Environment*, 237, 111594.
- Damavandi, H.G., Shah, R., Stampoulis, D., Wei, Y., Bosovic, D. and Sabo, J. (2019). Accurate prediction

- of streamflow using long short-term memory network: a case study in the Brazos River Basin in Texas. *International Journal of Environmental Science and Development*, 10(10), pp.294-300.
- Dingre, S. K., & Gorantiwar, S. D. (2020). Determination of the water requirement and crop coefficient values of sugarcane by field water balance method in semiarid region. *Agricultural Water Management*, 232, 106042.
- Dong, J., Zhu, Y., Jia, X., Han, X., Qiao, J., Bai, C., & Tang, X. (2022). Nation-scale reference evapotranspiration estimation by using deep learning and classical machine learning models in China. *Journal of Hydrology*, 604, 127207.
- Dou X, Yang Y. (2018). Evapotranspiration estimation using four different machine learning approaches in different terrestrial ecosystems. *Computers and Electronics in Agriculture*. 148:95-106.
- Elbeltagi, A., Kumari, N., Dharpure, J. K., Mokhtar, A., Alsafadi, K., Kumar, M., ... & Kuriqi, A. (2021). Prediction of combined terrestrial evapotranspiration index (CTEI) over large river basin based on machine learning approaches. *Water*, 13(4), 547.
- Ferreira LB, da Cunha FF, de Oliveira RA, Fernandes Filho EI. (2019). Estimation of reference evapotranspiration in brazil with limited meteorological data using ann and svm—a new approach. *Journal of Hydrology*. 572:556-570.
- Filgueiras R, Mantovani EC, Dias SHB, Fernandes Filho EI, da Cunha FF, Neale CMU. (2019). New approach to determining the surface temperature without thermal band of satellites. *European Journal of Agronomy*. 106:12-22.
- Gao F, Masek J, Schwaller M, Hall F. (2006). On the blending of the landsat and modis surface reflectance: Predicting daily landsat surface reflectance. *IEEE Transactions on Geoscience and Remote sensing*. 44(8):2207-2218.
- Liakos KG, Busato P, Moshou D, Pearson S, Bochtis D. (2018). Machine learning in agriculture: A review. *Sensors*. 18(8):2674.
- Luo, J., Dou, X., & Ma, M. (2022). Evaluation of Empirical and Machine Learning Approaches for Estimating Monthly Reference Evapotranspiration with Limited Meteorological Data in the Jialing River Basin, China. *International Journal of Environmental Research and Public Health*, 19(20), 13127.
- Newcome, M. E. (2021). The application of unmanned aerial vehicle to precision agriculture: chlorophyll, nitrogen, and evapotranspiration estimation. *Advance Journal of Science, Engineering and Technology*, 6(5), 9-13.
- Numata I, Khand K, Kjaersgaard J, Cochrane MA, Silva SS. (2017). Evaluation of landsat-based metric modeling to provide high-spatial resolution evapotranspiration estimates for amazonian forests. *Remote Sensing*. 9(1):46.
- Patil AP, Deka PC. (2016). An extreme learning machine approach for modeling evapotran-spiration using extrinsic inputs. *Computers and Electronics in Agriculture*. 121:385-392.
- Reyes-González A, Kjaersgaard J, Trooien T, Hay C, Ahiablame L. (2017). Comparative analysis of metric model and atmometer methods for estimating actual evapotranspiration. *International Journal of Agronomy*.
- Roy DK. (2021). Long short-term memory networks to predict one-step ahead reference evapotranspiration in a subtropical climatic zone. *Environmental Processes*. 8(2):911-941.
- Roy DK, Sarkar TK, Kamar SSA, Goswami T, Muktedir MA, Al-Ghobari HM, Alataway A, Dewidar AZ, El-Shafei AA, Mattar MA. (2022). Daily prediction and multi-step forward forecasting of reference evapotranspiration using lstm and bi-lstm models. *Agronomy*. 12(3):594.
- Sheffield, J., Wood, E. F., Pan, M., Beck, H., Coccia, G., Serrat-Capdevila, A., & Verbist, K. (2018). Satellite remote sensing for water resources management: Potential for supporting sustainable development in data-poor regions. *Water Resources Research*, 54(12), 9724-9758.
- Talib A, Desai AR, Huang J, Griffis TJ, Reed DE, Chen J. (2021). Evaluation of prediction and forecasting models for evapotranspiration of agricultural lands in the midwest us. *Journal of Hydrology*. 600:126579.
- Tikhmarine Y, Malik A, Kumar A, Souag-Gamane D, Kisi O. (2019). Estimation of monthly reference evapotranspiration using novel hybrid machine learning approaches. *Hydrological sciences journal*. 64(15):1824-1842.
- Tipping ME. (2001). Sparse bayesian learning and the relevance vector machine. *Journal of machine learning research*. 1(Jun):211-244.
- Vapnik VN. (1999). An overview of statistical learning theory. *IEEE transactions on neural networks*. 10(5):988-999.
- Yang R, Singh SK, Tavakkoli M, Amiri N, Karami MA, Rai R. (2022). Continuous video stream pixel sensor:



A cnn-lstm based deep learning approach for mode shape prediction. *Structural Control and Health Monitoring*. 29(3): e2892.

Esmaili S, Khoshkhoo Y, Babaei Kh, Asadi Oskouei E. (2018). Estimating rice actual evapotranspiration using METRIC algorithm in a part of the north of Iran. *J. of Water and Soil Conservation*. 24(6): 105-122.

Prediction of daily evapotranspiration images of rice using machine learning

Extended Abstract

Introduction

Short-term prediction of actual evapotranspiration (ET) during the growing season is of great importance in precision agriculture, water requirements and irrigation demands estimation and irrigation management. In this paper, a method for short-term prediction of daily ET images of rice is presented using satellite images fusion and machine learning algorithms. Satellite imaging in cloudy days leads to the loss of information, especially when we work on a farm-scale at a coastal region. For example, Landsat or Modis original images alone cannot be used for prediction due to the presence of clouds and low temporal/spatial resolution. Therefore, in order to reach desired spatial and temporal resolutions, a spatiotemporal method of satellite image fusion was used in this study.

Research method

This study was carried out in the following steps. First, the consequent VNIR and SWIR bands of Landsat-8 and Modis images were merged using the STARFM method to generate Landsat-like images on days when Landsat data acquisition is not available. This was also done for a generated LST band from both satellites. Then, Using the resulting bands, daily ET maps were produced using METRIC algorithm. ET maps from this step were applied as input to relevance vector machine (RVM) and long short-term memory (LSTM) in order to predict the ET maps of the following days. We performed the experiments organizing two different scenarios. In the first scenario, model is trained using image of a given day of the growth period as input, and the image of 6 days after that as target. Using this configuration, the model can predict ET images at a six-day timestep. In the second scenario, the model received two consecutive days' images as training data, and the prediction was made for up to six days. Prediction results were assessed using common assessment indices such as RMSE, MAE, Nash-Sutcliffe index, index of agreement, correlation coefficient (r) and coefficient of determination (R^2). Furthermore, the results obtained from RVM in both scenarios were compared with the results obtained from LSTM.

Findings

The correlation coefficient between the values obtained by RVM and ET estimated by METRIC for the first and second scenario was 0.89 and 0.84, respectively. These results confirm that both two scenarios are able to accurately predict ET. In the first scenario, the values of R^2 for the RVM and LSTM methods were 0.8 and 0.59, respectively, which show that the RVM-based method is more accurate for prediction compared to the LSTM-based method. The RMSE values for the RVM method in the first and second scenarios were 0.56 and 0.82, respectively. Moreover, the MAE values in the first and second scenarios were 0.43 and 0.66, respectively. These results show that the configuration performed in the first scenario leads to less error compared to the second scenario.

Conclusion

As a general result, the values of the RMSE, R^2 , Nash-Sutcliffe index, and index of agreement show that for both scenarios, the RVM model provides more accurate predictions than the LSTM. The first scenario is more accurate for the prediction of the target day (the sixth day from a given date). However, predicting in one-day steps can potentially predict all days of the growing season and provide valuable information for agricultural and water resources managers.

Keywords: LSTM, METRIC Algorithm, Relevance Vector Machine, Satellite Image Fusion.