

Self-attention mechanism-long short-term memory neural network models for irrigation demand prediction: an evaluation and performance analysis

Elham Ghanbari Adivi^{*1} , Shahrzad Hajizadeh² 

¹ Associate Professor, Department of Water Engineering, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran

² Former M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran

Extended Abstract

Introduction

Predicting irrigation demand provides valuable information for agricultural planning and decision-making. By accurately predicting irrigation needs, farmers can optimize water distribution and avoid wasting water. Farmers can use this information to set planting schedules, crop rotation, and optimize land use based on water availability. This study introduces a new model for predicting irrigation demand. This study introduces a new model for predicting irrigation demand. The self-attention mechanism (SA) is coupled with the long short-term memory (LSTM) neural network to predict irrigation demand. The SALSTM incorporates self-attention mechanisms, which enable the model to focus on the most relevant parts of the input sequence while making predictions. The attention mechanism allows SALSTM to assign different weights to different time steps or features, emphasizing the most informative ones for predicting irrigation demand. SALSTM can capture complex non-linear relationships between different input features, such as meteorological data, soil conditions, and crop characteristics. By comparing the performance of SALSTM models implemented in Python, MATLAB, R, and JavaScript, the study provides insights into the advantages and drawbacks of different programming languages for implementing machine learning models in climate studies. In this research, the self-attention mechanism was integrated with the LSTM model to forecast irrigation demands for agricultural planning.

Materials and Methods

By combining the power of LSTM and attention mechanisms, SALSTM can learn intricate patterns and interactions between these factors, enabling it to make more accurate predictions of irrigation demands. This ability is particularly beneficial in capturing the nuanced relationships that exist in agricultural systems. Relative humidity, temperature, wind speed, rainfall, and potential crop evapotranspiration were used as the inputs to the models. The SALSTM model was benchmarked against the LSTM, recurrent neural network (RNN), Radial Basis Function Neural Network (RBFN), and multiple linear regression (MLR) models. The study also evaluates and compares the performance of SALSTM models for irrigation demand prediction in multiple programming languages, including Python, MATLAB, R, and JavaScript. Accurate prediction of irrigation demand is crucial for efficient water management in agriculture and can contribute to sustainable engineering practices. Overall, the study contributes to advanced engineering informatics by providing a comparative analysis of SALSTM models, incorporating self-attention mechanisms, and exploring their application in irrigation demand prediction. The study combines concepts from various disciplines, including data science, machine learning, and irrigation engineering. By applying advanced informatics techniques to irrigation demand prediction, the study bridges the gap between these areas and encourages interdisciplinary collaboration. In this study, the LSTM model is benchmarked against the RNN, RBFNN, and multiple linear regression models.

Results and Discussion

In this research, the self-attention mechanism was integrated with the LSTM model to forecast irrigation demands. The SALSTM model leverages self-attention mechanisms, allowing it to concentrate on the most pertinent segments of the input sequence during predictions. This attention mechanism enables SALSTM to allocate varying weights to different time steps or features, highlighting the most significant ones for predicting irrigation needs. The findings showed that the SALSTM model surpassed the performance of other models. By comparing the

performance of SALSTM models implemented in Python, MATLAB, R, and JavaScript, the study provides insights into the advantages and drawbacks of different programming languages for implementing machine learning models in climate studies. This knowledge can aid researchers and practitioners in selecting appropriate programming languages for their specific needs, promoting the efficient and effective utilization of computational resources in climate studies. The results indicated that the SALSTM model outperformed other models. The SALSTM model has the lowest MAE of 1.212, followed by LSTM (1.345), RNN (1.555), RBFN (1.678), and MLR (1.879). The median value of the observed data, SALSTM, LSTM, RNN, RBF, and MLR, was 18.5, 18.5, 23, 22, and 27.5, respectively. SALSTM could capture complex non-linear relationships between different input features, such as meteorological data, soil conditions, and crop characteristics.

Conclusion

By combining the power of LSTM and attention mechanisms, SALSTM could learn intricate patterns and interactions between these factors, enabling it to make more accurate predictions of irrigation demands. By accurately predicting irrigation demands, SALSTM enables farmers to avoid excessive water usage. By proactively adjusting irrigation plans based on SALSTM predictions, managers can minimize the risk of crop losses due to under- or over-irrigation. Future research can build upon this study by focusing on several key areas: performing a comparative analysis of the SALSTM model against other prediction models, including deep learning, traditional machine learning, and hybrid approaches; discovering and engineering new features to enhance the SALSTM model's prediction accuracy, identifying the most influential factors in irrigation demand; improving model interpretability through techniques like attention visualization or feature importance analysis; exploring the transferability of the SALSTM model to different geographical regions, crops, or irrigation systems via transfer learning; and incorporating uncertainty estimation methods to quantify prediction uncertainty, thus aiding decision-makers in assessing the reliability of irrigation demand forecasts.

Keywords: Irrigation management, Hybrid models, Smart agriculture, Important features.

Article Type: Research Article

Acknowledgement

We would like to express our sincere gratitude to the University of Shahrekord for the financial support.

Conflicts of interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Data availability statement

The datasets are available upon a reasonable request to the corresponding author.

Authors' contribution

Elham Ghanbari-Adivi: Writing - original draft preparation, Conceptualization, methodology, Resources, Software, Manuscript editing; **Shahzad Hajizadeh:** Resources, Manuscript editing.

*Corresponding Author, E-mail: elhamgh44@gmail.com

Citation: Ghanbari Adivi, E., & Hajizadeh, Sh. (2025). Self-attention mechanism- long short-term memory neural network models for irrigation demand prediction: an evaluation and performance analysis. *Water and Soil Management and Modeling*, 5(1), 283-300.
doi:10.22098/mmws.2024.15492.1481

Received: 21 July 2024., Received in revised form: 02 September 2024, Accepted: 03 September 2024,
Published online: 21 March 2025

Water and Soil Management and Modeling, Year 2025, Vol. 5, No. 1, pp. 283-300

Publisher: University of Mohaghegh Ardabili

© Author(s)





مکانیسم توجه به خود در مدل های شبکه عصبی حافظه طولانی کوتاه مدت برای پیش بینی تقاضای آبیاری: ارزیابی و تحلیل عملکرد

الهام قنبری عدیوی^{۱*}، شهرزاد حاجی زاده^۲

^۱ دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران

^۲ دانش آموخته کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران

چکیده

پیش بینی تقاضای آبیاری، اطلاعات ارزشمندی را برای برنامه ریزی و تصمیم گیری کشاورزی فراهم می کند. کشاورزان با پیش بینی دقیق نیازهای آبیاری می توانند توزیع آب را بهینه کرده و از هدررفت آب جلوگیری کنند. این مطالعه یک مدل جدید برای پیش بینی تقاضای آبیاری معرفی می کند. مکانیسم خودتوجهی، با شبکه عصبی حافظه طولانی کوتاه مدت (LSTM) برای پیش بینی تقاضای آبیاری همراه است. SALSTM مکانیسم های خودتوجهی را در بر می گیرد، که مدل را قادر می سازد در حین انجام پیش بینی ها، بر مرتبط ترین بخش های دنباله ورودی تمرکز کند. مکانیسم SALSTM، اجازه می دهد تا وزن های مختلف را به مراحل یا ویژگی های زمانی مختلف اختصاص دهد و بر آموزنده ترین آن ها، برای پیش بینی نیاز آبیاری، تأکید دارد. SALSTM می تواند روابط غیرخطی پیچیده ای را بین ویژگی های ورودی مختلف، مانند داده های هواشناسی، شرایط خاک، و ویژگی های محصول ثبت کند. با ترکیب قدرت LSTM و مکانیسم های توجه به خود، SALSTM می تواند الگوهای پیچیده و تعاملات بین این عوامل را بیاموزد و آن را قادر می سازد تا پیش بینی دقیق تری از نیازهای آبیاری انجام دهد. این توانایی به ویژه در گرفتن روابط ظریفی که در سیستم های کشاورزی وجود دارد مفید است. در این بررسی رطوبت نسبی، دما، سرعت باد، بارندگی و تبخیر و تعرق پتانسیل محصول، به عنوان ورودی مدل ها استفاده شد. مدل SALSTM با مدل های LSTM، شبکه عصبی بازگشتی (RNN)، شبکه عصبی تابع پایه شعاعی (RBFN) و رگرسیون خطی چندگانه (MLR) محک گذاری شد. همچنین، در این مطالعه عملکرد مدل های SALSTM در پیش بینی دقیق میزان تقاضای آبیاری با کمک چندین زبان برنامه نویسی از جمله Python، MATLAB و R ارزیابی و مقایسه شد. این مطالعه با مقایسه عملکرد مدل های SALSTM پیاده سازی شده در پایتون، متلب، R و جاوا اسکریپت، بینش هایی در مورد مزایا و معایب زبان های برنامه نویسی مختلف برای پیاده سازی مدل های یادگیری ماشین در مطالعات آب و هوا ارائه می کند. برای زبان برنامه نویسی پایتون، نتایج نشان داد که مدل SALSTM، بهتر از سایر مدل ها عمل می کند. مدل SALSTM دارای کمترین میانگین خطای مطلق (MAE) با مقدار ۱/۲۱ بود، در مقابل آن ۱/۳۴ برای مدل LSTM، مقدار ۱/۵۵ برای مدل RNN مقدار ۱/۶۸ برای مدل RBFN و مقدار ۱/۸۸ برای مدل MLR به دست آمد.

واژه های کلیدی: مدیریت آبیاری، مدل های ترکیبی، کشاورزی هوشمند، پیش بینی تقاضا

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: elhamgh44@gmail.com

استناد: قنبری عدیوی، الهام، و حاجی زاده، شهرزاد (۱۴۰۴). مکانیسم توجه به خود در مدل های شبکه عصبی حافظه طولانی کوتاه مدت برای پیش بینی تقاضای آبیاری: ارزیابی و تحلیل عملکرد. *مدل سازی و مدیریت آب و خاک*، ۱۵(۱)، ۲۸۳-۳۰۰.
doi: 10.22098/mmws.2024.15492.1481

تاریخ دریافت: ۱۴۰۳/۰۴/۳۱، تاریخ بازنگری: ۱۴۰۳/۰۶/۱۲، تاریخ پذیرش: ۱۴۰۳/۰۶/۱۳، تاریخ انتشار: ۱۴۰۴/۰۱/۰۱

مدل سازی و مدیریت آب و خاک، سال ۱۴۰۴، دوره ۵، شماره ۱، صفحه ۲۸۳ تا ۳۰۰

© نویسندگان

ناشر: دانشگاه محقق اردبیلی



۱- مقدمه

تقاضای آبیاری، به مقدار آب مورد نیاز برای رفع نیاز آبی محصولات یا گیاهان در یک مزرعه کشاورزی اشاره دارد. مرحله رشد محصول، تعیین‌کننده زمان و شدت آبیاری است. آب و هوای محلی شامل دما، رطوبت، باد و تابش خورشیدی بر میزان تبخیر و تعرق تأثیر می‌گذارد (Emami et al., 2022). دماهای بالاتر و شرایط خشک‌تر، سرعت تبخیر را افزایش می‌دهد و منجر به آبیاری بیش‌تر می‌شود. نوع خاک، بافت، محتوای مواد آلی و ظرفیت نگهداری آب، بر مقدار آبی که می‌تواند توسط گیاهان نگهداری شود تأثیر می‌گذارد. در دسترس بودن منابع آبی مانند آب‌های زیرزمینی، آب‌های سطحی یا آب‌های ذخیره شده بر تقاضای آبیاری تأثیر می‌گذارد. پیش‌بینی تقاضای آبیاری به کشاورزان کمک می‌کند تا با استفاده از مقدار مناسب آب در زمان مناسب، مصرف آب را بهینه کنند (Peng et al., 2019). با برآورد دقیق تقاضای آبیاری، کشاورزان می‌توانند از مدیریت کارآمد آب اطمینان حاصل کنند و از اتلاف غیرضروری آب جلوگیری کنند (Perea et al., 2019). آب یک منبع با ارزش و محدود، به‌ویژه در مناطق مستعد خشکسالی یا دارای کمبود در منابع آب است. کشاورزان با پیش‌بینی نیاز آبیاری می‌توانند از منابع آب به درستی استفاده کنند، هدررفت آب را کاهش دهند و منابع آبی را حفظ کنند (Majumdar et al., 2023). همچنین، کشاورزان می‌توانند با پیش‌بینی دقیق‌تر تقاضای آبیاری و استفاده از شیوه‌های آبیاری کارآمد، رواناب را به حداقل برسانند و خطر آلودگی آب را کاهش دهند. از طرفی الگوهای آب و هوا می‌تواند به طور گسترده‌ای متفاوت باشد و پیش‌بینی دقیق میزان بارش و تبخیر و تعرق در آینده را دشوار نماید. عواملی مانند دما، رطوبت، باد و تابش خورشیدی بر تقاضای آب تأثیر می‌گذارند. توجه به این نکته حائز اهمیت است که تغییرات آب و هوایی می‌تواند با تغییر الگوهای آب و هوای بلند مدت، عدم قطعیت‌های جدیدی را در مدل‌های پیش‌بینی ایجاد کند. برای برآورد نیاز آبی گیاهان، از مدل‌ها و معادلات ریاضی مختلفی که دارای ساده‌سازی‌های بسیاری هستند، استفاده می‌شود مانند روش پنمن مونتیتش، هارگریوز، مدل‌های رطوبت خاک و مدل‌های هیدرودینامیکی. این مدل‌ها اغلب متغیرهای متعددی را در نظر می‌گیرند، از جمله داده‌های آب و هوا، ضرایب محصول، سطوح رطوبت خاک و شیوه‌های مدیریتی (Emami et al., 2022). پیاده‌سازی و تفسیر صحیح این مدل‌ها می‌تواند پیچیده باشد و نیاز به تخصص در کشاورزی، هیدرولوژی و تحلیل داده‌ها دارد. مدل‌های یادگیری ماشین، می‌توانند منابع داده‌های متنوعی از جمله داده‌های آب و هوای تاریخی، اندازه‌گیری‌های رطوبت خاک، تصاویر ماهواره‌ای و اطلاعات مربوط به محصول را ادغام کنند (Emami et al.,

2023; Mokhtar et al., 2022). با ترکیب و تحلیل این منابع داده، مدل‌ها می‌توانند درک کامل‌تری از عوامل موثر بر تقاضای آبیاری به دست آورند و پیش‌بینی‌های دقیق‌تری ارائه دهند. مدل‌های آماری نمی‌توانند به راحتی روابط غیرخطی بین متغیرهای ورودی چندگانه را ثبت کنند (Emami et al., 2022). اما مدل‌های یادگیری ماشین، می‌توانند چندین متغیر ورودی را به‌طور همزمان تحلیل کنند.

حافظه کوتاه‌مدت طولانی، نوعی مدل یادگیری ماشین است. مدل‌های LSTM به‌طور گسترده برای پردازش داده‌های متوالی، مانند تحلیل سری‌های زمانی استفاده می‌شوند (Sherstinsky, 2020). بر خلاف شبکه‌های عصبی بازگشتی سنتی (RNN)، که ممکن است از مشکل توالی اطلاعات رنج ببرند، LSTM از سلول‌های حافظه و گیت‌ها^۱ برای حفظ و انتشار اطلاعات در توالی‌های طولانی‌تر استفاده می‌کند. مدل‌های LSTM، می‌توانند داده‌های متوالی را مدیریت کنند، که ممکن است دارای گپ یا مقادیر گمشده در سری‌های زمانی باشند (Sherstinsky, 2020). این مدل‌ها، توانایی تعمیم خوبی به دنباله‌های جدید، پس از آموزش بر روی داده‌های متنوع دارند (Chen et al., 2022).

در مطالعه‌ای (Mokhtar et al., 2023) برای رسیدگی به چالش‌های کمبود آب و داده‌های هواشناسی محدود، نیاز آبیاری (IWR) لوییا را پیش‌بینی نمودند. تحقیقات آن‌ها با هدف ارزیابی پتانسیل مدل‌های یادگیری ماشین و بررسی تأثیر پارامترهای هواشناسی، محصول و خاک، بر نیاز آبی آبیاری انجام شد. مدل‌های ترکیبی LSTM و شبکه عصبی کانولوشن، بالاترین دقت را در بین همه مدل‌ها نشان دادند، در حالی که مدل SVR کم‌ترین دقت برآورد را نشان داد (Mokhtar et al., 2023). همچنین، Perea et al. (2023) یک مدل ترکیبی جدید به نام LSTMHybrid ایجاد کردند که منطق فازی (FL)، الگوریتم ژنتیک (GA)، رمزگشای رمزگذار LSTM و شبکه عصبی متراکم (DNN) را، برای پیش‌بینی تقاضای آب آبیاری یک هفته‌ای یکپارچه می‌کند. نتایج نشان داد که مدل LSTMHybrid به‌طور موثر تقاضای آب آبیاری را پیش‌بینی می‌کند. Zou et al. (2023) مطالعه‌ای در مورد پیش‌بینی دقیق و قابل اعتماد مصرف آب آبیاری انجام دادند. آن‌ها شبکه عصبی اطلاع‌رسانی، شبکه LSTM و مدل SARIMA را برای پیش‌بینی مصرف آب آبیاری توسعه دادند. با در نظر گرفتن عوامل محرک و غلبه بر روابط نادرست، همه روش‌ها درک مکانیسم‌های فیزیکی را افزایش دادند. با این حال، مطالعات کمی وجود دارد که از مدل LSTM به‌طور خاص برای پیش‌بینی

¹ Gate

وابستگی‌های زمانی مربوطه تمرکز کند و توجه مناسب را به عوامل مهمی که در تقاضای آب نقش دارند، اختصاص دهد. این مکانیسم به مدل اجازه می‌دهد تا با توجه به عناصر مختلف، توالی ورودی به صورت پویا با شرایط متغیر سازگار شود (Yi et al., 2023). این سازگاری در زمینه مدیریت آبیاری، بسیار مهم است؛ زیرا نیازهای آب می‌تواند به دلیل عوامل مختلفی مانند تغییرات آب و هوایی، مراحل رشد گیاهان و غیره، متفاوت باشد. با ارائه پیش‌بینی‌های قابل اعتماد، مدل خودتوجهی LSTM، مدیران را قادر می‌سازد تا تخصیص آب را بهینه کرده، برنامه آبیاری را برنامه‌ریزی کنند و منابع را به طور کارآمدتر تخصیص دهند. با پیش‌بینی دقیق نیازهای آبی، می‌توان مدیریت آبیاری را برای اطمینان از تأمین منابع آب کافی، کاهش ضایعات و حمایت از شیوه‌های آبیاری پایدار بهینه کرد. هم‌چنین، این مطالعه یک تحلیل عملکرد کامل از مدل‌های SALSTM پیاده‌سازی شده در زبان‌های برنامه‌نویسی مختلف انجام می‌دهد. این مطالعه با مقایسه دقت پیش‌بینی، کارایی محاسباتی و سایر معیارهای مرتبط، به شناسایی نقاط قوت و ضعف هر زبان برای آن برنامه خاص، کمک می‌کند. این تحلیل، می‌تواند به محققان و متخصصان کمک کند تا مناسب‌ترین زبان برنامه‌نویسی را جهت پیش‌بینی تقاضای آبیاری انتخاب کنند. هدف این مطالعه، شناسایی مؤثرترین راه برای پیاده‌سازی این کار خاص است. (از طریق مقایسه پیاده‌سازی‌های مختلف شبکه‌های LSTM در پایتون، متلب، R و جاوا اسکریپت). بر اساس ارزیابی و تحلیل عملکرد، مطالعه حاضر می‌تواند توصیه‌های عملی برای پیاده‌سازی مدل‌های SALSTM، در برنامه‌های کاربردی دنیای واقعی ارائه دهد. این توصیه‌ها می‌تواند به محققان و متخصصان کمک کند تا مناسب‌ترین زبان برنامه‌نویسی و پیکربندی مدل را برای نیازهای خاص خود انتخاب کنند. این مطالعه از متغیرهای آب و هوایی مختلف، از جمله سرعت باد، رطوبت نسبی، بارندگی، دما و تبخیر و تعرق بالقوه محصول، به‌عنوان ویژگی‌های ورودی برای پیش‌بینی تقاضای آبیاری استفاده می‌کند. با ترکیب این متغیرها، این تحقیق به کاربرد عملی دانش اقلیم‌شناسی در زمینه مدیریت آب کشاورزی کمک می‌کند.

۲- مواد و روش‌ها

۲-۱- مکانیسم توجه به خود^۱

توجه به خود، مکانیسمی است که در معماری شبکه‌های عصبی، به‌ویژه در مدل‌های تبدیل‌کننده، برای ثبت وابستگی‌های بین

تقاضای آب آبیاری استفاده کرده باشد. مدل‌های LSTM محدودیت‌هایی دارند، این مدل‌ها توانایی محدودی برای گرفتن وابستگی بین عناصر دور در یک دنباله دارند (Ehteram et al., 2023). این محدودیت می‌تواند منجر به مشکلاتی در درک روابط و وابستگی‌های طولانی مدت شود. مدل‌های LSTM برای انتشار اطلاعات در طول زمان بر اتصالات مکرر تکیه می‌کنند، که می‌تواند توانایی آن‌ها را برای گرفتن اطلاعات بصورت کلی (غیرمحلی) محدود کند. مدل‌های LSTM را می‌توان جعبه سیاه در نظر گرفت، زیرا بینش صریحی از فرآیند تصمیم‌گیری ارائه نمی‌دهند. تفسیر پیش‌بینی‌های مدل و درک ویژگی‌ها یا عناصر مهم در توالی ورودی می‌تواند چالش برانگیز باشد. هدف اصلی مطالعه حاضر، غلبه بر محدودیت‌های مدل LSTM و توسعه بیشتر آن برای پیش‌بینی تقاضای آبیاری است. این مطالعه از مکانیسم توجه به خود، برای رفع اشکالات مدل LSTM استفاده می‌کند. در واقع ایجاد امکان تمرکز همزمان روی بخش‌های مختلف دنباله ورودی، به رفع اشکالات خاصی از مدل LSTM منجر می‌شود. مدل‌های LSTM می‌توانند در جذب مؤثر وابستگی‌هایی که توالی طولانی را در بر می‌گیرند، با چالش‌هایی مواجه شوند. این محدودیت می‌تواند منجر به مشکلاتی در مدل‌سازی روابط و الگوهای پیچیده در داده‌ها شود. مکانیسم توجه به خود، به مدل اجازه می‌دهد تا به بخش‌های مختلف توالی ورودی توجه کند و وابستگی‌های دوربرد را به‌طور مؤثرتری ثبت کند (An et al., 2019). هدف اصلی مکانیسم توجه به خود، این است که وابستگی‌ها و روابط بین عناصر در یک دنباله را به‌طور مؤثرتری ثبت کند. با تخصیص وزن توجه به عناصر مختلف، مکانیسم خودتوجهی به مدل اجازه می‌دهد تا بر مرتبط‌ترین اطلاعات برای یک کار معین تمرکز کند و تفسیرپذیری را فراهم می‌کند؛ بنابراین، اهمیت نسبی آن‌ها در فرآیند پیش‌بینی را نشان می‌دهد (Li et al., 2020). با گنجاندن مکانیسم توجه به خود، این اشکالات مدل LSTM را می‌توان کاهش داد و مدل را قادر ساخت تا وابستگی‌های دوربرد را به‌دست آورد، به مشکل گرادیان ناپدیدشدن، رسیدگی کند و قابلیت تفسیر را در پیش‌بینی‌های خود ارائه دهد. مدل‌های LSTM، چون توالی‌ها را به‌طور متوالی پردازش می‌کند، قابلیت‌های موازی‌سازی آن‌ها را محدود می‌کند و می‌تواند منجر به زمان‌های محاسباتی کندتر شود (Zang et al., 2021). در مقابل، مکانیسم توجه به خود، امکان پردازش موازی را فراهم می‌کند؛ زیرا مدل را قادر می‌سازد تا به تمام عناصر دنباله، به‌طور همزمان توجه کند. ترکیبی از توجه به خود و LSTM، می‌تواند دقت پیش‌بینی تقاضای آبیاری را افزایش دهد. مکانیسم توجه به خود، این مدل را قادر می‌سازد تا بر

¹ Self-attention mechanism

دروازه ورودی: جریان اطلاعات جدید را به سلول حافظه کنترل می‌کند. این گیت تصمیم می‌گیرد که کدام بخش از ورودی باید در سلول حافظه ذخیره شود (Yan et al., 2022).

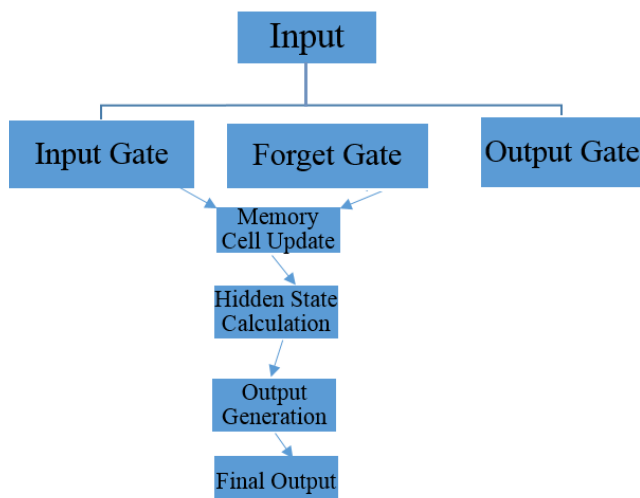
دروازه فراموشی: تعیین می‌کند که کدام اطلاعات از سلول حافظه حذف شود و کدام بخش از حالت حافظه قبلی باید فراموش شود (Jing et al., 2019).

دروازه خروجی: گیت خروجی تعیین می‌کند که کدام قسمت از سلول حافظه باید خروجی باشد.

به‌روزرسانی سلول حافظه: LSTM سلول حافظه را بر اساس ورودی، حالت پنهان قبلی و مکانیسم دروازه به‌روز می‌نماید (Ehteram et al., 2023).

محاسبه وضعیت پنهان: LSTM یک حالت پنهان را، بر اساس سلول حافظه به‌روز شده محاسبه می‌کند. این حالت پنهان، اطلاعات مربوطه را از توالی ورودی به بالا می‌گیرد.

تولید خروجی: حالت پنهان به‌عنوان حالت مخفی قبلی، به مرحله زمانی بعدی منتقل می‌شود و این فرآیند برای عنصر بعدی در دنباله ورودی، تکرار می‌شود. خروجی نهایی مدل LSTM را، می‌توان پس از پردازش کل توالی ورودی به‌دست آورد. شکل ۱ ساختار مدل LSTM را نشان می‌دهد.



شکل ۱- ساختار مدل LSTM

Figure 1- Structure of the LSTM model

۲-۳- مکانیسم توجه به خود - مدل LSTM

توجه به خود می‌تواند، به‌ویژه هنگام برخورد با دنباله‌های طول متغیر، مفید باشد. مدل‌های LSTM به‌طور سنتی به ورودی‌هایی با طول ثابت یا بالشتک نیاز دارند، که می‌تواند منجر به ناکارآمدی شود. توجه به خود، به مدل اجازه می‌دهد تا توالی‌هایی با طول‌های مختلف را بدون نیاز به بالشتک مدیریت کند. از آنجایی که مکانیسم توجه می‌تواند ورودی‌های طول متغیر را

عناصر مختلف در یک دنباله استفاده می‌شود. مکانیسم توجه به خود، بر اساس سطوح زیر ایجاد می‌شود:

نمایش ورودی: دنباله ورودی به سه بردار تقسیم می‌شود: پرسش‌ها، کلیدها و مقادیر. هر عنصر در دنباله، با این سه بردار مرتبط است. این بردارها را می‌توان با پیش‌بینی‌های خطی دنباله ورودی اصلی به‌دست آورد.

محاسبه شباهت: مکانیسم توجه به خود، شباهت یا سازگاری بین بردارهای پرس و جو و بردارهای کلیدی را محاسبه می‌کند (Fu et al., 2022). این معمولاً با محاسبه حاصل ضرب نقطه‌ای بین هر بردار پرس و جو و هر بردار کلید انجام می‌شود. حاصل آن، ارتباط یا شباهت بین بردارهای پرس و جو و کلید را نشان می‌دهد.

وزن‌های توجه: نمرات شباهت، با ضریب جذر ابعاد بردارهای پرس و جو مقیاس می‌شوند تا از بزرگ شدن بیش از حد آن‌ها جلوگیری شود (Jing, 2019). سپس، امتیازها از یک تابع softmax عبور می‌کنند، که امتیازات را در سراسر بردارهای کلیدی برای هر بردار پرس و جو نرمال می‌کند. مقادیر به دست آمده نشان‌دهنده وزن توجه است و نشان‌دهنده اهمیت یا توجهی است که به هر یک از موارد ورودی برای هر پرس‌وجو داده شده است.

بردار زمینه: وزن توجه، برای محاسبه جمع وزنی بردارهای ارزش، استفاده می‌شود. هر بردار ارزش در وزن توجه متناظر آن ضرب می‌شود و نتایج برای تولید یک بردار زمینه جمع می‌شود. بردار زمینه، اطلاعات موجود از توالی ورودی را نشان می‌دهد و مرتبط‌ترین موارد را بر اساس وزن توجه به تصویر می‌کشد (Fahim et al., 2021).

مکانیسم توجه به خود، به مدل اجازه می‌دهد تا به‌صورت پویا، به بخش‌های مختلف توالی ورودی بر اساس ارتباط یا اهمیتی که توسط وزن‌های توجه جذب می‌شود، بپردازد. این، مدل را قادر می‌سازد تا وابستگی‌های دوربرد را جذب کند و بر عناصر مرتبط در طول فرآیند تولید یا پیش‌بینی تمرکز کند.

۲-۲- مدل LSTM

مدل LSTM برای غلبه بر محدودیت‌های RNN‌های سنتی، در گرفتن وابستگی‌های بلندمدت طراحی شده است (Fahim et al., 2021). اطلاعات از طریق یک سری سلول‌های حافظه جریان می‌یابد، که ساختار پیچیده‌تری در مقایسه با واحدهای بازگشتی ساده در RNN‌های سنتی دارند. در هر مرحله زمانی، مدل LSTM، ورودی و حالت پنهان قبلی (که نشان‌دهنده اطلاعات گذشته است) را ارزیابی می‌کند تا تعیین کند چه مقدار اطلاعات ذخیره یا فراموش شود. این کار با استفاده از سه دروازه انجام می‌شود:

خروجی: در هر مرحله زمانی، مدل خروجی تولید می‌کند که می‌تواند برای کارهای مختلفی مانند پیش بینی، طبقه‌بندی یا تولید استفاده شود. همچنین، خروجی می‌تواند به‌عنوان ورودی برای مرحله زمانی بعدی باشد.

۲-۴-۲- مدل‌های شبکه عصبی تابع پایه شعاعی

مدل‌های شبکه عصبی تابع پایه شعاعی (RBFN) نوعی شبکه عصبی مصنوعی هستند که از توابع پایه شعاعی به‌عنوان توابع فعال‌سازی استفاده می‌کنند (Zhang et al., 2022). لایه ورودی یک RBFN، ویژگی‌ها یا داده‌های ورودی را دریافت می‌کند. لایه پنهان یک RBFN از واحدهای تابع پایه شعاعی تشکیل شده است. بردار مرکز نشان‌دهنده مرکز هر تابع پایه در لایه پنهان است. پارامتر عرض یا گسترش اندازه، تأثیر هر تابع پایه را تعیین می‌کند. بردار وزن، لایه پنهان را به لایه خروجی متصل می‌کند (Hao et al., 2022). لایه خروجی یک RBFN، خروجی نهایی را بر اساس مجموع وزنی فعال‌سازی‌ها محاسبه می‌کند.

۲-۴-۳- مدل‌های رگرسیون خطی چندگانه

مدل‌های رگرسیون خطی چندگانه، مدل‌های آماری هستند که برای بررسی رابطه بین یک متغیر وابسته و چند متغیر مستقل استفاده می‌شوند (Oukawa et al., 2022). این مفهوم رگرسیون خطی ساده را، که تنها با یک متغیر مستقل سروکار دارد، گسترش می‌دهد تا پیش‌بینی‌کننده‌های متعدد را در خود جای دهد. معادله رگرسیون نشان‌دهنده رابطه ریاضی بین متغیر وابسته و متغیر مستقل است. ضرایب $\beta_1, \beta_2, \dots, \beta_n$ در معادله رگرسیون، رابطه بین هر متغیر مستقل و متغیر وابسته را کمی می‌کند. مدل‌های رگرسیون خطی چندگانه بر چندین فرض متکی هستند، از جمله خطی بودن (رابطه بین متغیرها خطی است)، استقلال خطاها (خطاها با یکدیگر همبستگی ندارند)، واریانس ثابت خطاها (He et al., 2022). ضرایب معادله رگرسیون، با استفاده از روش‌های مختلفی مانند روش حداقل مربعات برآورد می‌شود که مجموع اختلاف مجذور بین مقادیر مشاهده شده و پیش‌بینی شده متغیر وابسته را به حداقل می‌رساند.

۲-۵- محاسبه تقاضای واقعی آبیاری

برای محاسبه تقاضای واقعی آبیاری با استفاده از روش‌ها و معادلات سنتی، معمولاً چندین مرحله به شرح زیر دنبال می‌شود: ابتدا نیاز آبی محصول، بر اساس محصول خاصی که کشت می‌شود تعیین می‌شود. این اطلاعات را می‌توان از دستورالعمل‌های خاص محصول، تحقیقات کشاورزی، یا منابع استاندارد شده مانند معادله پنمن-مونتیث (Ashofteh et al.,

مدیریت کند، می‌تواند توجه خود را به قسمت‌های مختلف دنباله، صرف نظر از طول آن‌ها، تطبیق دهد. وزن‌های توجه، برای نشان دادن این که کدام عناصر ورودی بیش‌ترین تأثیر را بر هر عنصر خروجی داشتند، تولید می‌شوند (Zang et al., 2021). این شفافیت می‌تواند به درک فرآیند تصمیم‌گیری مدل کمک کند و بینش‌هایی را ارائه دهد که برای پیش‌بینی قسمت‌های مهم از دنباله در نظر گرفته می‌شوند. مدل‌های LSTM می‌توانند از نظر محاسباتی، به‌خصوص برای توالی‌های بسیار طولانی گران باشند. با گنجاندن توجه به خود، این مدل به‌طور بالقوه می‌تواند پیچیدگی محاسباتی را کاهش دهد؛ زیرا توجه به خود، امکان پردازش موازی عناصر را در دنباله فراهم می‌کند (Li et al., 2020). با ترکیب توجه به خود، مدل LSTM می‌تواند به‌طور انتخابی به عناصر مرتبط توجه کند و سهم آن‌ها را در پیش‌بینی یا خروجی نهایی بسنجد.

۲-۴-۴- مدل‌های بنج مارک

در این مطالعه، مدل SALSTM در برابر مدل‌های RNN، RBFNN و رگرسیون خطی چندگانه (MLR) محک زده می‌شود.

۱-۴-۲- مدل‌های شبکه عصبی بازگشتی

مدل‌های شبکه عصبی بازگشتی (RNN) نوعی شبکه عصبی مصنوعی هستند که برای پردازش داده‌های متوالی طراحی شده‌اند (Bonatti et al., 2022). این مدل دارای لایه‌های زیر است: لایه‌های ورودی و خروجی: مدل‌های RNN، دنباله‌هایی با طول متغیر را به‌عنوان ورودی دریافت می‌کنند. هر عنصر از دنباله به‌عنوان یک ویژگی ورودی یا بردار نشان داده می‌شود (Silka et al., 2022). لایه خروجی یک RNN، بسته به کار می‌تواند متفاوت باشد.

حالت پنهان: حالت پنهان جزء کلیدی یک RNN است. به‌عنوان حافظه‌ای عمل می‌کند که اطلاعات را در طول مراحل زمانی ذخیره می‌کند. در هر مرحله زمانی، حالت پنهان بر اساس ورودی فعلی و حالت پنهان قبلی با استفاده از توابع فعال‌سازی مانند مماس هذلولی (\tanh) یا واحد خطی اصلاح شده (ReLU) به‌روز می‌شود. حالت پنهان به‌روز شده، دانش لازم را از مراحل زمانی قبلی ضبط می‌کند و به مدل اجازه می‌دهد تا وابستگی‌ها را در دنباله یاد بگیرد و استنباط کند (Vu et al., 2022).

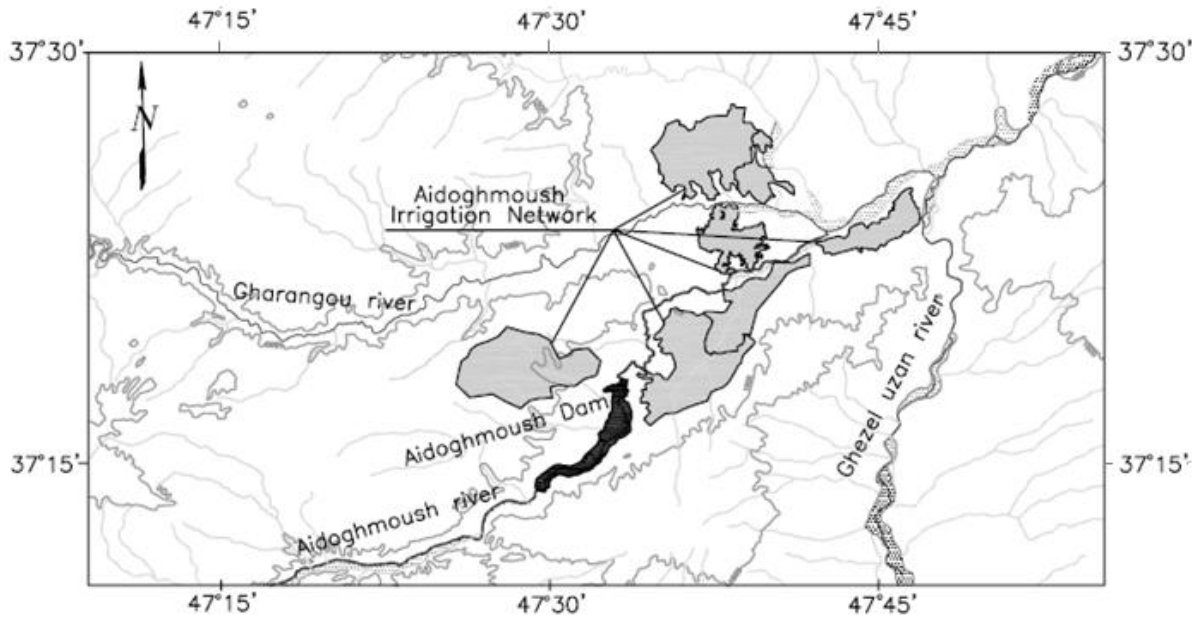
اتصالات مکرر: این اتصالات به حالت پنهان اجازه می‌دهد تا اطلاعات را از طریق دنباله ضبط و منتشر کند و مدل را قادر می‌سازد اطلاعات گذشته را به خاطر بسپارد و از آن استفاده کند (Yadav et al., 2022).

آیدوغموش نقش حیاتی در مدیریت آب، آبیاری و تولید برق در منطقه دارد. اهداف اولیه این سد ذخیره آب برای مصارف کشاورزی، مهار سیلاب و تولید برق آبی است. هدف اصلی شبکه آبیاری آیدوغموش تأمین آب برای مصارف کشاورزی به‌ویژه برای آبیاری زمین‌های کشاورزی اطراف است. این شبکه شامل مجموعه‌ای از کانال‌ها و خطوط لوله است که آب را از سد به زمین‌های کشاورزی منتقل می‌کند و به کشاورزان این امکان را می‌دهد تا محصولات خود را به طور موثر آبیاری کنند. شبکه آبیاری آیدوغموش با تسهیل آبیاری، نقش مهمی در حمایت از کشاورزی، افزایش بهره‌وری محصولات کشاورزی و کمک به توسعه اقتصادی اجتماعی منطقه ایفا می‌کند. شکل‌های ۲ و ۳ مکان مطالعه موردی، جزئیات محصول، نیاز آب و مقادیر پارامتر ورودی را نشان می‌دهد. در این بررسی باغات گردو با ۴۷۲۵ هکتار بیش‌ترین مساحت را دارند و پس از آن گندم، یونجه و سیب‌زمینی قرار دارند. ذرت علوفه‌ای و خوراکی، دارای سطح زیر کشت نسبتاً کم‌تری هستند و به‌ترتیب با ۱۰۸۰ هکتار و ۶۷۵ هکتار، ۸ و ۵ درصد از کل سطح زیر کشت برای هر محصول را تشکیل می‌دهند. جو، سویا و علوفه دارای سطح زیر کشت یکسانی هستند. هر کدام ۸ درصد از کل سطح زیر کشت را تشکیل می‌دهند. گندم و جو نیاز آبی نسبتاً کم‌تری نسبت به سایر محصولات دارند. یونجه بیش‌ترین نیاز آبی را در بین محصولات ذکر شده دارد. سویا، ذرت خوراکی و سیب‌زمینی نیاز آبی مشابهی دارند. شکل ۴ نقاط داده ماهانه را نشان می‌دهد. داده‌های ماهانه از آبان ۸۲ تا مهر ۹۷ جمع‌آوری شد. مدل‌ها برای پیش‌بینی تقاضای آبیاری ماهانه استفاده شدند. دما، بارندگی، رطوبت نسبی، تبخیر و تعرق بالقوه محصول، سرعت باد و تابش خورشیدی برای پیش‌بینی تقاضای آبیاری استفاده شد.

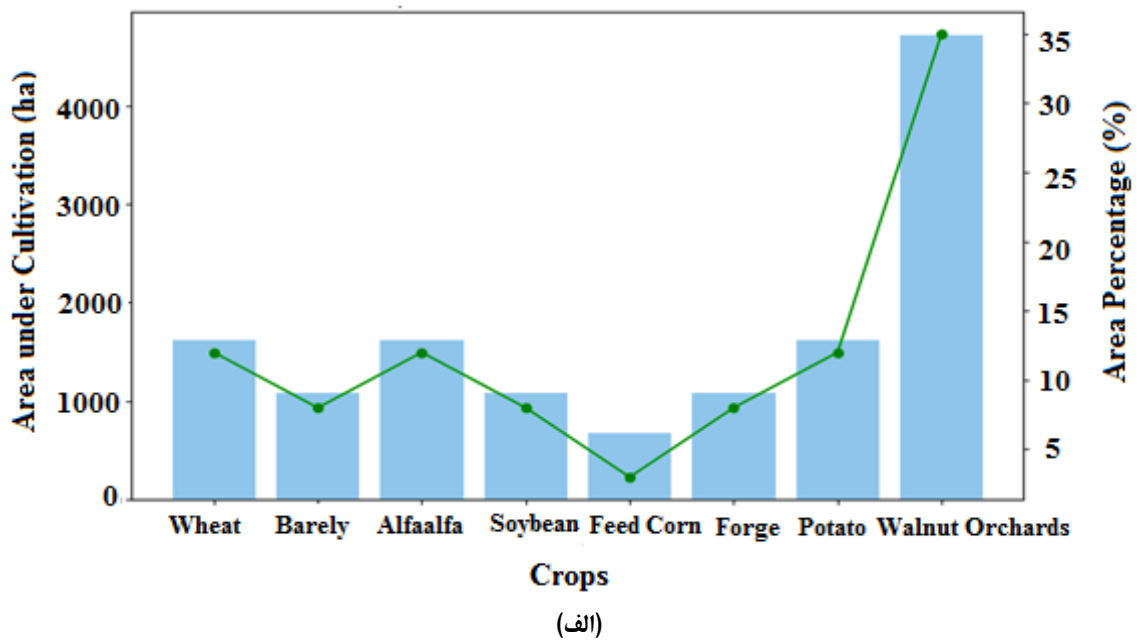
(2013) به‌دست آورد. سپس تبخیر و تعرق محصول (ETc) با کمک تبخیر تعرق گیاه مرجع و با استفاده از معادلات یا روش‌هایی مانند روش پنمن-مونتیث، روش FAO 56 یا روش هارگریوز محاسبه می‌شود (Ashofteh et al., 2013). این روش‌ها عواملی مانند دما، رطوبت، سرعت باد، تابش خورشیدی و ویژگی‌های محصول را برای تخمین مصرف آب محصول در نظر می‌گیرند. بارندگی موثر که بخشی از بارندگی است که به خاک نفوذ می‌کند و می‌تواند توسط محصول استفاده شود، از تبخیر و تعرق محاسبه شده محصول (ETc) کم می‌شود که مقدار بارش موثر را می‌توان بر اساس اندازه گیری‌های بارندگی، ویژگی‌های خاک و شیوه‌های مدیریت زمین تخمین زد. در ادامه کمبود رطوبت خاک باید ارزیابی شود، که تفاوت بین سطح رطوبت خاک موجود و سطح رطوبت مطلوب خاک، برای رشد بهینه گیاه است (Ashofteh et al., 2015). این کمبود را می‌توان با پایش سطوح رطوبت خاک با استفاده از حس‌گرها یا با استفاده از روش‌های تعیین شده بر اساس ویژگی‌های خاک و شیوه‌های آبیاری قبلی تعیین کرد. در نهایت نیاز آبیاری را به‌عنوان مقدار آب مورد نیاز برای پر کردن کمبود رطوبت خاک و تأمین نیاز آبی محصول باید تعیین نمود. این پارامتر را می‌توان با کم کردن بارندگی موثر از تبخیر و تعرق محصول (ETc) و اضافه کردن کمبود رطوبت خاک محاسبه کرد. البته برای تعیین حجم واقعی آب مورد نیاز برای آبیاری، باید عواملی مانند راندمان تحویل آب، تلفات تبخیر و ناکارآمدی سیستم در یکنواختی توزیع نیز در نظر گرفته شود.

۶-۲- مطالعه موردی

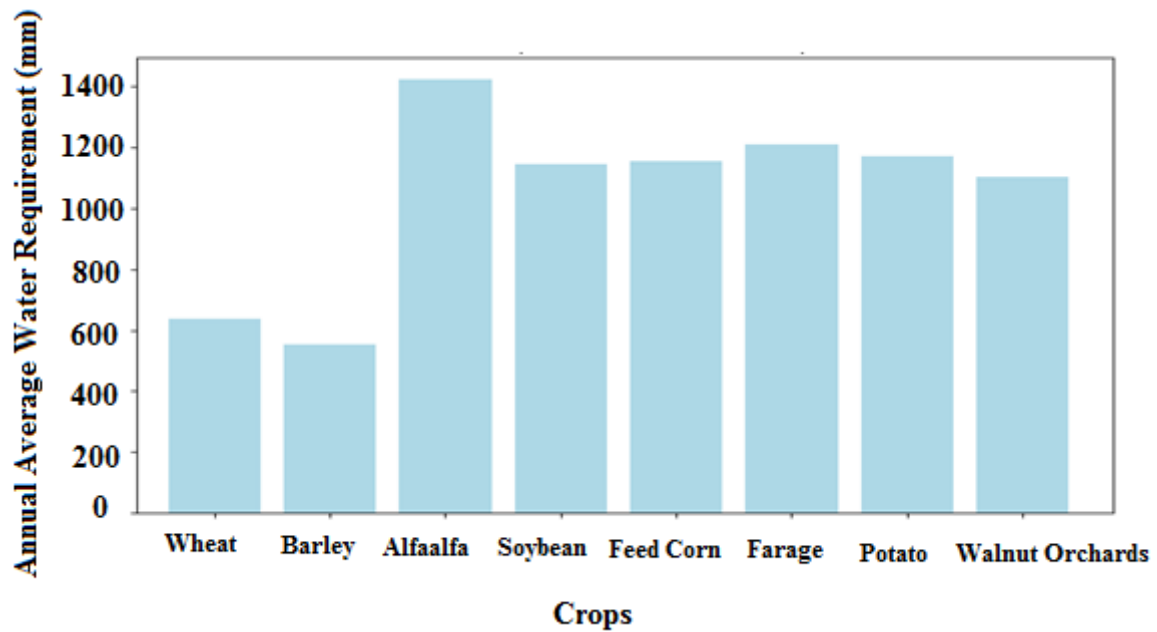
سد آیدوغموش یکی از سدهای مهم ایران است. رودخانه آیدوغموش در استان آذربایجان غربی در شمال غربی ایران واقع شده است. سد



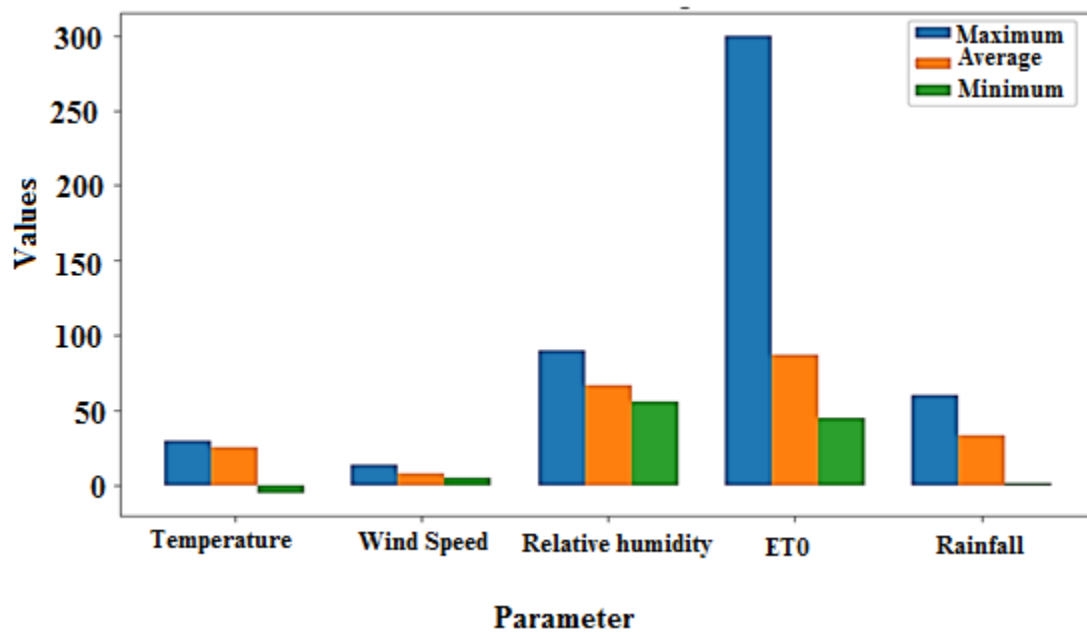
شکل ۲- محل مورد مطالعه (سد آیدوغموش)
 Figure 2- Study area (Aidoghmosh dam)



(الف)

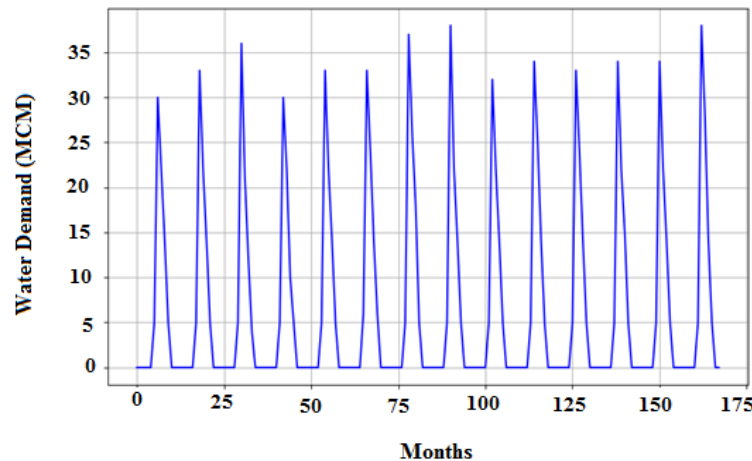


(ب)



(ج)

شکل ۳- الف) نوع محصولات مورد بررسی و درصد زیر کشت آن‌ها، ب) نیاز آبی (میلی‌متر)، و ج) مقادیر ورودی به مدل‌ها
 Figure 2- a) The type of crops and the percentage of their cultivation, b) water requirements (mm), and c) input values to the models



شکل ۴- نیازهای آبیاری ماهانه
Figure 4- Monthly irrigation demands

مربعات خطا (CRMSE) و انحراف استاندارد متغیرها یا مدل‌های مختلف را نشان می‌دهد که امکان مقایسه جامع را فراهم می‌کند. هر مدل یا مجموعه داده با یک نشانگر در نمودار نشان داده می‌شود. فاصله از نقطه مرجع در محور x، نشان‌دهنده انحراف استاندارد، فاصله شعاعی نشان‌دهنده ضریب همبستگی و زاویه امتدادی ازیموتال^۱ نشان‌دهنده CRMSE است. مزیت اصلی نمودار تیپلور، توانایی آن برای نمایش چندین معیار عملکرد در یک نمودار است (Sattari et al., 2024)

۳- نتایج و بحث

۳-۱- رابطه بین پارامترهای ورودی و خروجی

شکل ۴، مقادیر همبستگی بین نهاده‌ها و تقاضای آبیاری را نشان می‌دهد. بین دما و نیاز آبیاری همبستگی مثبت قوی (۰/۹۱) وجود دارد. آب و هوای گرم‌تر و مناطق خشک اغلب نیاز به آبیاری بیشتری دارند. تغییرات دما می‌تواند به طور قابل توجهی بر تقاضای آبیاری تأثیر بگذارد. توجه به این نکته ضروری است که، رابطه بین بارندگی و تقاضای آبیاری می‌تواند تحت تأثیر عوامل دیگری مانند شرایط آب و هوایی محلی، نوع خاک، نوع محصول و شیوه‌های مدیریت آب باشد. بین بارندگی و تقاضای آبیاری همبستگی منفی قوی (۰/۹۱-) وجود دارد. در نتیجه آب کم‌تری از طریق تبخیر از دست می‌رود و در نتیجه نیاز آبیاری کاهش می‌یابد. افزایش سرعت باد باعث افزایش تبخیر خاک و گیاه و نهایتاً منجر به اتلاف آب و نیاز آبیاری بیشتر می‌شود. همبستگی بین تبخیر و تعرق محصول (ETc) و تقاضای آبیاری بسته به عوامل مختلف می‌تواند متفاوت باشد. یک همبستگی مثبت قوی (۰/۹۰) بین تبخیر و تعرق محصول (ETc) و تقاضای آبیاری

۷-۲- ارزیابی مدل

در این بررسی برای ارزیابی عملکرد مدل‌ها از رابطه‌های (۱) تا (۳) و نمودارهای جعبه‌ای و تیپلور استفاده شد (Taylor, 2001; Alempour Rajabi et al., 2024). میانگین خطای مطلق (MAE):

$$MAE = \frac{\sum_{i=1}^n |ID_{es} - ID_{ob}|}{N} \quad (1)$$

راندمان (Nash-Sutcliffe):

$$NSE = 1 - \frac{\sum_{i=1}^n (ID_{es} - ID_{ob})^2}{\sum_{i=1}^n (ID_{ob} - \bar{ID})^2} \quad (2)$$

درصد سوگیری (PBIAS):

$$PBIAS = \frac{\sum_{i=1}^n (ID_{ob} - ID_{es})}{\sum_{i=1}^n ID_{ob}} \times 100 \quad (3)$$

MAE پایین‌تر، نشان‌دهنده دقت بهتر و پیش‌بینی‌های نزدیک به مقادیر واقعی است. NSE، تناسب بین مقادیر پیش‌بینی‌شده و مشاهده‌شده را در محدوده ۰-∞ تا ۱ اندازه‌گیری می‌کند. مقدار NSE بالاتر، نشان‌دهنده برآزش بهتر پیش‌بینی‌های مدل با داده‌های مشاهده‌شده است.

۷-۲-۱- نمودار جعبه‌ای

نمودار جعبه‌ای، نوعی نمایش گرافیکی است که خلاصه‌ای از توزیع یک مجموعه داده را ارائه می‌دهد. میانه، چارک‌ها و نقاط پرت احتمالی داده‌ها را نمایش می‌دهد. خط افقی داخل کادر نشان‌دهنده میانه است که مقدار وسط مجموعه داده است. نمودارهای جعبه‌ای برای درک تمایل مرکزی، گسترش و چولگی داده‌ها مفید هستند.

۷-۲-۲- نمودار تیپلور

گراف تیپلور، یک ابزار گرافیکی است که برای ارزیابی عملکرد مدل‌ها یا داده‌های مختلف در برابر یک مجموعه داده مرجع استفاده می‌شود. این نمودار همبستگی، ریشه متمرکز میانگین

¹ Azimuthal

پس از آن مدل LSTM با مقدار ۰/۹۵، RNN با مقدار ۰/۹۴، RBFN با مقدار ۰/۹۰ و MLR با مقدار ۰/۸۹ قرار گرفتند. در بین مدل‌های داده شده، SALSTM دارای کم‌ترین PBIAS با هفت بود و و پس از آن مدل LSTM با مقدار ۰/۹، RNN با مقدار ۰/۱۲، RBFN با مقدار ۰/۱۴ و MLR با مقدار ۰/۱۵ قرار گرفتند.

شکل ۵، نمودارهای جعبه‌ای مدل‌ها را نشان می‌دهد. مقدار میانه داده‌های مشاهده شده SALSTM، LSTM، RNN، RBF، و MLR به ترتیب ۱۸/۵۴، ۱۸/۵۲، ۱۸/۵۳، ۲۳/۰۲، ۲۲/۰۴ و ۲۷/۵۳ بود. نتایج نشان داد که حداکثر مقدار داده‌های مشاهده شده SALSTM، LSTM، RNN، RBF و MLR به ترتیب ۳۷، ۳۸، ۳۹، ۴۱، ۴۳ و ۴۴ بود. بنابراین مدل SALSTM بیش‌ترین تطابق را با داده‌های مشاهده شده داشت. شکل ۶ یک گراف تیلور را نشان می‌دهد. مقدار CRMSE برای SALSTM، LSTM، RNN، RBFN و MLR به ترتیب ۰/۱۱، ۰/۹۹، ۰/۹۴، ۰/۹۰، ۰/۸۳ و ۰/۷۵ بود. ضریب همبستگی مدل‌های SALSTM، LSTM، RNN، RBFN و MLR به ترتیب ۰/۹۹، ۰/۹۴، ۰/۹۰، ۰/۸۳ و ۰/۷۵ بود.

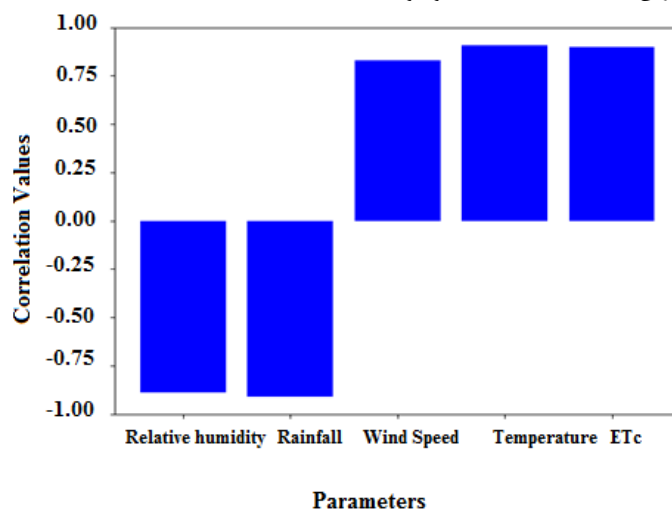
نتایج تحلیل مدل‌های مختلف نشان می‌دهد که مدل SALSTM به‌عنوان بهترین مدل در ارزیابی‌های مختلف عمل کرده است. نمودارهای جعبه‌ای نشان می‌دهند که مدل SALSTM به‌طور کلی بیش‌ترین تطابق را با داده‌های مشاهده شده دارد. همچنین، گراف تیلور نیز نشان می‌دهد که مدل SALSTM دارای کم‌ترین CRMSE (خطای ریشه‌ای) و بالاترین ضریب همبستگی با داده‌هاست که این نیز نشان‌دهنده برتری مدل نسبت به دیگر مدل‌های مورد بررسی است. به طور خلاصه، با توجه به تمامی بازخوردها و ارزیابی‌ها، SALSTM به‌طور معناداری عملکرد بهتری نسبت به سایر مدل‌ها دارد.

وجود دارد. به‌طور کلی، بین تبخیر و تعرق محصول و تقاضای آبیاری همبستگی مثبت وجود دارد. با افزایش مقادیر ETC، سیستم محصول آب بیش‌تری از دست می‌دهد و آبیاری اضافی برای جبران کمبود آب، ضروری است. از آنجایی که مقادیر همبستگی قوی بین نهاده‌ها و نیازهای آبیاری وجود دارد، همه پارامترها به‌عنوان ورودی مدل‌ها استفاده می‌شوند.

۲-۳- بررسی دقت مدل‌ها

در این قسمت، از نرم‌افزار پایتون برای اجرای تمامی مدل‌ها استفاده شده است. بنابراین تمامی مدل‌های جدول ۱، در نرم افزار پایتون پیاده‌سازی شدند. در بخش‌های بعدی دقت کد پایتون با کد R، کد جاوا اسکریپت و کد Matlab بررسی می‌شود. جدول ۱ نتایج آموزش و آزمون مدل‌های مورد بررسی را نشان می‌دهد. مدل SALSTM کم‌ترین MAE را با مقدار معادل ۱/۲۱ داشت، پس از آن مدل LSTM با مقدار ۱/۳۴، RNN با مقدار ۱/۵۵، RBFN با مقدار ۱/۶۸ و MLR با مقدار ۱/۸۸ قرار گرفتند. در بین مدل‌ها، SALSTM بالاترین مقدار NSE با مقدار معادل ۰/۹۸ داشت و پس از آن مدل LSTM با مقدار معادل ۰/۹۷، RNN با مقدار ۰/۹۵، RBFN با مقدار ۰/۹۴ و MLR با مقدار ۰/۹۲ قرار گرفتند. همچنین، کم‌ترین مقدار PBIAS مربوط به مدل SALSTM با مقدار معادل پنج بود. بیش‌ترین مقدار PBIAS نیز مربوط به مدل MLR با مقدار معادل ۱۰ بود.

بر اساس نتایج ارائه شده در مرحله آزمون، SALSTM دارای کم‌ترین MAE با مقدار معادل ۱/۳۴۵ بوده و پس از آن مدل LSTM با مقدار ۱/۶۷۸، RNN با مقدار ۱/۸۲۳، RBFN با مقدار ۱/۹۴۵ و MLR با مقدار ۲/۰۱۲ قرار گرفتند. بر اساس نتایج داده شده، SALSTM دارای بالاترین NSE با مقدار ۰/۹۶ بود و



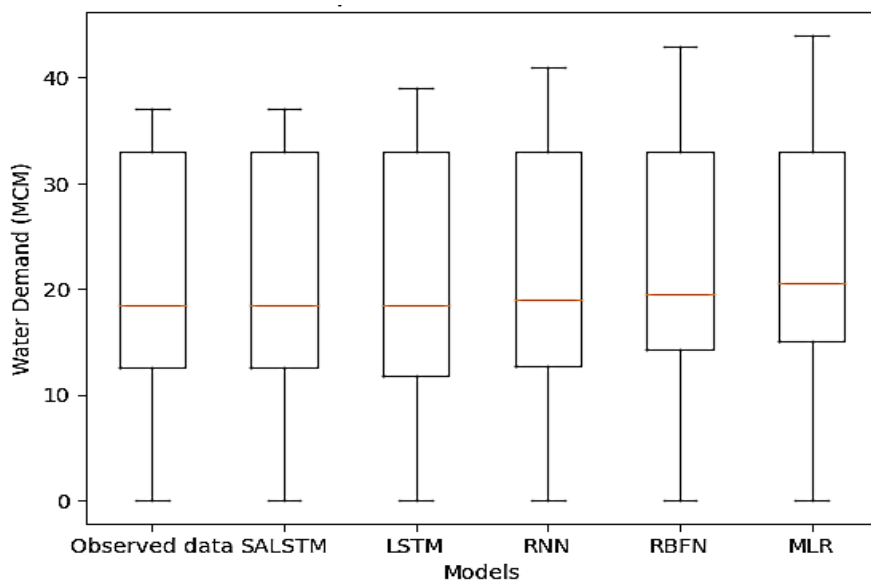
شکل ۵- مقادیر همبستگی بین ورودی‌ها و خروجی

Figure 5- Correlation values between inputs and output

جدول ۱- نتایج عملکرد مدل‌های مختلف در مرحله آموزش و آزمون

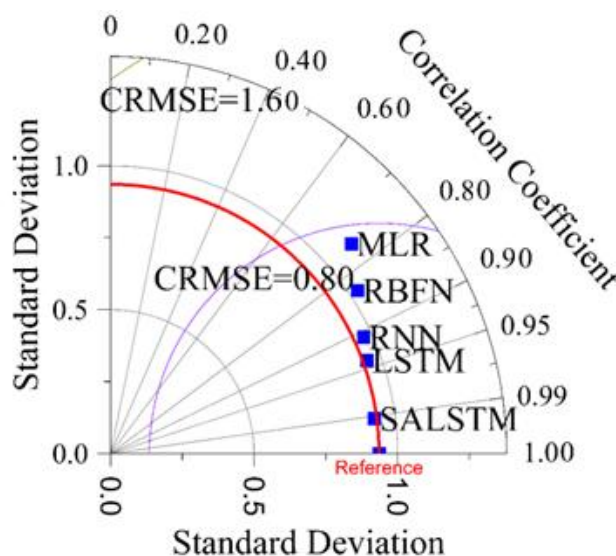
Table 1- Performance results of different models in the training and test phases

Train			
Models	MAE	NSE	PBIAS
SALSTM	1.21	0.98	5
LSTM	1.34	0.97	7
RNN	1.55	0.95	8
RBFN	1.68	0.94	9
MLR	1.8	0.92	10
Test			
SALSTM	1.34	0.96	7
LSTM	1.68	0.95	9
RNN	1.82	0.94	12
RBFN	1.94	0.90	14
MLR	2.01	0.89	15



شکل ۶- مقایسه عملکرد مدل‌های مختلف با استفاده از نمودار جعبه‌ای

Figure 6- Comparing the performance of different models using box plots



شکل ۷- گراف تیلور برای مقایسه عملکرد مدل‌ها

Figure 7- Taylor diagram for comparing model performance

می‌دهند و تکنیک‌های بهینه‌سازی، که می‌توانند به عملکرد بهتر مدل و کاهش MAE کمک کنند. در این مورد خاص، پایتون ممکن است MAE کمی پایین‌تر از خود نشان داده باشد، اما عوامل دیگری مانند سهولت استفاده، منابع موجود و تخصص فردی باید هنگام انتخاب نرم‌افزار در نظر گرفته شوند. هر پلتفرم نرم‌افزاری، دارای نقاط قوت و ضعف منحصر به فردی است و مناسب‌ترین انتخاب با توجه به نیازهای خاص پروژه تعیین خواهد شد. پایتون به دلیل سادگی، خوانایی و سهولت استفاده، شناخته شده است.

برتری پایتون در این مطالعه خاص، به این معنا نیست که همیشه در هر زمینه‌ای از زبان‌های دیگر بهتر عمل می‌کند. عملکرد یک زبان برنامه‌نویسی به عوامل مختلفی از جمله وظیفه خاص، جزئیات پیاده‌سازی و تخصص توسعه‌دهنده بستگی دارد. زبان‌های مختلف، نقاط قوت و ضعف خاص خود را دارند و انتخاب زبان باید بر اساس الزامات و محدودیت‌های پروژه باشد. این مطالعه، با ارزیابی عملکرد مدل‌های SALSTM پیاده‌سازی شده در پایتون، متلب، R و جاوا اسکریپت، به تحلیل مقایسه‌ای زبان‌های برنامه‌نویسی مختلف برای پیش‌بینی تقاضای آبیاری می‌پردازد. پیش‌بینی دقیق تقاضای آبیاری برای مدیریت کارآمد آب در کشاورزی بسیار مهم است و می‌تواند به شیوه‌های مهندسی پایدار کمک کند. به‌طور کلی، این مطالعه با ارائه یک تحلیل مقایسه‌ای از مدل‌های SALSTM، ترکیب مکانیسم‌های توجه به خود و بررسی کاربرد آن‌ها در پیش‌بینی تقاضای آبیاری، به مهندسی انفورماتیک پیشرفته کمک می‌کند و برای این منظور مفاهیمی

۳-۳- بررسی دقت نرم‌افزارهای Python، JavaScript، R، Matlab

بررسی دقت در زمینه زبان‌های برنامه‌نویسی مانند پایتون، جاوا اسکریپت، متلب و R می‌تواند به چندین مفهوم مختلف، مانند دقت عددی برای محاسبات، صحت کد، یا دقت مدیریت داده ارتباط داشته باشد (Giorgi et al., 2022; Yatsenko et al., 2015). از آنجایی که هر زبان برنامه‌نویسی کتابخانه‌های مختلفی برای محاسبات عددی دارد بر اساس موضوع مورد بررسی می‌تواند بر دقت محاسبات تأثیر بگذارد. لذا در این جا برای موضوع تعیین مقدار تقاضای آبیاری به مقایسه نتایج خروجی از زبان‌های مختلف برنامه‌نویسی اقدام شد.

جدول ۲، عملکرد محیط‌های برنامه‌نویسی مختلف را نشان می‌دهد در این مقایسه، پایتون کم‌ترین مقدار MAE را هم برای آموزش و هم برای آزمون داشت. MATLAB و R دارای مقادیر MAE کمی بالاتر بودند که نشان‌دهنده دقت کمی کم‌تر در مقایسه با پایتون است. جاوا اسکریپت بالاترین مقادیر MAE را در بین نرم‌افزارها داشت که نشان‌دهنده دقت نسبتاً کم‌تری نسبت به سه نرم‌افزار دیگر است. بنابراین، در این مطالعه پایتون عملکرد بهتر نسبت به سایر زبان‌های برنامه‌نویسی مورد استفاده داشت اما تفاوت معناداری در این نتایج وجود نداشت. پایتون یک سیستم قوی از کتابخانه‌های یادگیری ماشین مانند TensorFlow، PyTorch، و Scikit-learn دارد. انتخاب نرم‌افزار در نهایت به عواملی مانند ترجیح شخصی، آشنایی و نیازهای خاص پروژه بستگی دارد. این کتابخانه‌ها اغلب پیاده‌سازی‌های کارآمدی از الگوریتم‌ها را ارائه

از رشته‌های مختلف از جمله علم داده، یادگیری ماشین و مهندسی آبیاری را ترکیب می‌کند.

جدول ۲- مقادیر MAE برای مقایسه محیط‌های مختلف نرم‌افزار بر اساس مدل SALSTM

Table 2- MAE values for comparing different software environments based on the SALSTM model

	Python	MATLAB	R	JavaScript
Train	1.21	1.23	1.24	1.25
Test	1.35	1.36	1.36	1.36

۴-۳- مقایسه با مطالعات پیشین

در مطالعه‌ای (Mohammadi et al. (2024) در راستای تعیین نیاز آبیاری و مدیریت منابع آب به پیش‌بینی ماهانه تبخیر از تشت با استفاده از رویکردهای انفرادی و ترکیبی مدل‌های داده‌کاوی پرداختند. نتایج بررسی آن‌ها مشابه تحقیق حاضر (مدل ترکیبی LSTM با مکانیسم خودتوجهی) تاییدکننده دقت مدل‌های ترکیبی نسبت به مدل‌های انفرادی در مقایسه با داده‌های واقعی است. (Emami et al. (2022) در تلاش برای تخمین تقاضای آب آبیاری، ابتدا همبستگی متغیرهای تأثیرگذار بالقوه با آب آبیاری را تحلیل نمودند. سپس مدل‌های یادگیری ماشین را برای پیش‌بینی تقاضای آب آبیاری سالانه در سطح ایالت کالیفرنیا بر اساس یافته‌های تحلیل آماری در یک بازه زمانی ۱۸ ساله توسعه دادند. متغیرهای ورودی ترکیبات مختلفی از پارامترهای هواشناسی، ویژگی‌های جغرافیایی، منطقه کشت شده و نوع محصول هستند. پس از بررسی روش‌های مختلف یادگیری ماشین، نتایج آن‌ها نشان داد که رگرسیون فرآیند گاوسی^۱ (R^2 بالاتر از ۰/۹۷ و RMSE کم‌تر از ۰/۰۶ کیلو مترمکعب) بهترین نتایج را در پیش‌بینی تقاضای آب آبیاری ایجاد می‌کند. این تحقیقات نشان داد که روش‌های مختلف یادگیری ماشین مشابه نتایج تحقیقات حاضر دقت بالایی در پیش‌بینی تقاضای آب آبیاری دارد.

۴- نتیجه‌گیری

پیش‌بینی تقاضای آبیاری اطلاعات ارزشمندی را برای برنامه‌ریزی و تصمیم‌گیری کشاورزی فراهم می‌کند. کشاورزان می‌توانند از این اطلاعات برای تنظیم برنامه‌های کاشت، تناوب زراعی و بهینه‌سازی استفاده از زمین بر اساس در دسترس بودن آب استفاده کنند. این مطالعه، یک مدل جدید برای پیش‌بینی تقاضای آبیاری معرفی می‌کند. در این مطالعه، مکانیسم خودتوجهی با مدل LSTM، برای پیش‌بینی نیاز آبیاری همراه شد. SALSTM، مکانیسم‌های خودتوجهی را در بر می‌گیرد که

مدل را قادر می‌سازد تا در حین انجام پیش‌بینی‌ها، روی مرتبط‌ترین بخش‌های دنباله ورودی تمرکز کند. مدل SALSTM کم‌ترین MAE را دارد. SALSTM می‌تواند روابط غیرخطی پیچیده‌ای را بین ویژگی‌های ورودی مختلف، مانند داده‌های هواشناسی، شرایط خاک، و ویژگی‌های محصول ثبت کند. با ترکیب قدرت LSTM و مکانیسم خود توجهی، SALSTM می‌تواند الگوهای پیچیده و تعاملات بین این عوامل را بیاموزد و آن را قادر می‌سازد تا پیش‌بینی دقیق‌تری از نیازهای آبیاری انجام دهد. با پیش‌بینی دقیق نیازهای آبیاری، SALSTM کشاورزان را قادر می‌سازد تا از مصرف بیش از حد آب اجتناب کنند. با تنظیم پیشگیرانه برنامه‌های آبیاری بر اساس پیش‌بینی‌های SALSTM، مدیران می‌توانند خطر تلفات محصول به دلیل آبیاری کم یا بیش از حد را به حداقل برسانند. مطالعات بعدی می‌تواند مطالعه فعلی را بر اساس نظرات زیر توسعه دهد:

تحلیل مقایسه‌ای: یک تحلیل مقایسه‌ای از مدل‌های مختلف برای پیش‌بینی تقاضای آبیاری، از جمله دیگر ساختارهای یادگیری عمیق، مدل‌های سنتی یادگیری ماشین، یا مدل‌های ترکیبی.

مهندسی ویژگی: ویژگی‌های اضافی که می‌تواند دقت پیش‌بینی مدل SALSTM را بهبود بخشد را کشف نماید. بررسی شود که چگونه مجموعه ویژگی‌های مختلف بر عملکرد مدل تأثیر می‌گذارد و معنادارترین ویژگی‌ها برای پیش‌بینی نیازهای آبیاری شناسایی شود.

آموزش انتقال و تعمیم: قابلیت انتقال مدل SALSTM از پیش‌آموزش دیده را در مناطق مختلف جغرافیایی، محصولات زراعی یا سیستم‌های آبیاری بررسی شود. بررسی اثربخشی یادگیری انتقال با تنظیم دقیق مدل از پیش‌آموزش دیده، روی مجموعه داده‌های جدید.

تخمین عدم قطعیت: تکنیک‌های تخمین عدم قطعیت را در مدل SALSTM، برای تعیین کمیت عدم قطعیت پیش‌بینی بررسی نماید. این می‌تواند به تصمیم‌گیرندگان کمک کند تا قابلیت اطمینان پیش‌بینی‌ها را ارزیابی کنند و بر اساس سطح

¹ Gaussian process regression

منابع

- ستاری، محمدتقی، شیرینی، کیمیا، و جاویدان، سحر (۱۴۰۳). ارزیابی کارایی روش‌های کاهش پارامترها در بهبود دقت مدل‌سازی شاخص کیفی آب در رودخانه قزل اوزن با استفاده از الگوریتم‌های یادگیری ماشین. *مدل‌سازی و مدیریت آب و خاک*، ۴(۲)، ۸۹-۱۰۴. doi: 10.22098/mmws.2023.12434.1241
- عالم‌پور رجبی، فرناز، قربانی، محمد علی، و اسدی، اسماعیل (۱۴۰۳). مدل‌سازی فرآیند تبخیر با استفاده از الگوریتم هیبریدی پرندۀ کوت و شبکه عصبی مصنوعی. *مدل‌سازی و مدیریت آب و خاک*، ۴(۲)، ۲۷۹-۲۹۴. doi: 10.22098/mmws.2023.12692.1266
- محمدی، مجتبی، جهان‌تبخ، حسین، و ذوالفقاری، فرهاد. (۱۴۰۳). پیش‌بینی ماهانه تبخیر از تشت با استفاده از رویکردهای انفرادی و ترکیبی مدل‌های داده‌کاوی در مناطق خشک. *مدل‌سازی و مدیریت آب و خاک*، ۴(۲)، ۲۷۹-۲۹۴. doi: 10.22098/mmws.2023.12728.1270

عدم قطعیت مرتبط با پیش‌بینی تقاضای آبیاری، تصمیمات آگاهانه بگیرند.

سپاسگزاری

نویسندگان از معاونت پژوهشی دانشگاه شهرکرد بخاطر تأمین مالی هزینه‌های این تحقیق قدردانی می‌نمایند.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این تحقیق ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این تحقیق از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

الهام قنبری عدیوی: مفهوم‌سازی، تحلیل‌های نرم‌افزاری و آماری، کنترل نتایج، نگارش نسخه اولیه و نهایی مقاله؛ **شهرزاد حاجی‌زاده:** ویرایش.

References

- Alempour Rajabi, F., Ghorbani, M. A., & Asadi, E. (2024). Modeling of the evaporation process using the hybrid algorithm of the COOT bird and artificial neural network. *Water and Soil Management and Modelling*, 4(2), 279-294. [In Persian] doi:10.22098/mmws.2023.12692.1266
- An, N. N., Thanh, N. Q., & Liu, Y. (2019). Deep CNNs with self-attention for speaker identification. *IEEE access*, 7, 85327-85337. doi:10.1109/ACCESS.2019.2917470
- Ashofteh, P. S., Haddad, O. B., & A. Mariño, M. (2013). Climate change impact on reservoir performance indexes in agricultural water supply. *Journal of Irrigation and Drainage Engineering*, 139(2), 85-97. doi:10.1061/(asce)jir.1943-4774.0000496
- Ashofteh, P. S., Haddad, O. B., & Marino, M. A. (2015). Risk analysis of water demand for agricultural crops under climate change. *Journal of Hydrologic Engineering*, 20(4), 04014060. doi: 10.1061/(asce)he.1943-5584.0001053
- Bonatti, C., Berisha, B., & Mohr, D. (2022). From CP-FFT to CP-RNN: Recurrent neural network surrogate model of crystal plasticity. *International Journal of Plasticity*, 158, 103430. doi:10.1016/j.ijplas.2022.103430
- Chen, X., & Liu, Z. (2022). A long short-term memory neural network based Wiener process model for remaining useful life prediction. *Reliability Engineering & System Safety*, 226, 108651. doi.org/10.1016/j.ress.2022.108651
- Ehteram, M., Ahmed, A. N., Khozani, Z. S., & El-Shafie, A. (2023). Graph convolutional network-Long short term memory neural network-multi layer perceptron-Gaussian progress regression model: A new deep learning model for predicting ozone concentration. *Atmospheric Pollution Research*, 14(6), 101766. doi:10.1016/j.apr.2023.101766
- Emami, M., Ahmadi, A., Daccache, A., Nazif, S., Mousavi, S. F., & Karami, H. (2022). County-level irrigation water demand estimation using machine learning: Case study of California. *Water*, 14(12), 1937. doi:10.3390/w14121937
- Fahim, A., Tan, Q., Mazzi, M., Sahabuddin, M., Naz, B., & Ullah Bazai, S. (2021). Hybrid LSTM self - attention mechanism model for forecasting the reform of scientific research in Morocco. *Computational Intelligence and Neuroscience*, 2021(1), 6689204. doi:10.1155/2021/6689204
- Fu, E., Zhang, Y., Yang, F., & Wang, S. (2022). Temporal self-attention-based Conv-LSTM network for multivariate time series prediction. *Neurocomputing*, 501, 162-173. doi:10.1016/j.neucom.2022.06.014
- Giorgi, F.M., Ceraolo, C. and Mercatelli, D., (2022). The R language: an engine for bioinformatics

- and data science. *Life*, 12(5), p.648. doi.org/10.3390/life12050648
- Hao, G., Guo, J., Zhang, W., Chen, Y., & Yuen, D. A. (2022). High-precision chaotic radial basis function neural network model: Data forecasting for the Earth electromagnetic signal before a strong earthquake. *Geoscience Frontiers*, 13(1), 101315. doi:10.1016/j.gsf.2021.101315
- He, Z., Liu, P., Zhao, X., He, X., Liu, J., & Mu, Y. (2022). Responses of surface O3 and PM2.5 trends to changes of anthropogenic emissions in summer over Beijing during 2014–2019: A study based on multiple linear regression and WRF-Chem. *Science of The Total Environment*, 807, 150792. doi:10.1016/j.scitotenv.2021.150792
- Jin, Y., Xie, J., Guo, W., Luo, C., Wu, D., & Wang, R. (2019). LSTM-CRF neural network with gated self attention for Chinese NER. *IEEE Access*, 7, 136694-136703. doi:10.1109/ACCESS.2019.2942433
- Jing, R. (2019, April). A self-attention based LSTM network for text classification. In *Journal of Physics: Conference Series* (Vol. 1207, p. 012008). IOP Publishing. doi:10.1088/1742-6596/1207/1/012008
- Li, W., Qi, F., Tang, M., & Yu, Z. (2020). Bidirectional LSTM with self-attention mechanism and multi-channel features for sentiment classification. *Neurocomputing*, 387, 63-77. doi:10.1016/j.neucom.2020.01.006
- Majumdar, P., Bhattacharya, D., Mitra, S., Solgi, R., Oliva, D., & Bhusan, B. (2023). Demand prediction of rice growth stage-wise irrigation water requirement and fertilizer using Bayesian genetic algorithm and random forest for yield enhancement. *Paddy and Water Environment*, 21(2), 275-293. doi:10.1007/s10333-023-00930-0
- Mohammadi, M., Jahantigh, H., & Zolfahari, F. (2024). Monthly prediction of pan evaporation using individual and combined approaches of data mining models in arid regions. *Water and Soil Management and Modeling*, 4(2), 227-240. doi: 10.22098/mmws.2023.12728.1270 [In Persian]
- Mokhtar, A., Al-Ansari, N., El-Ssawy, W., Graf, R., Aghelpour, P., He, H., Hafez, S.M., & Abuarab, M. (2023). Prediction of irrigation water requirements for green beans-based machine learning algorithm models in arid region. *Water Resources Management*, 37(4), 1557-1580. doi:10.1007/s11269-023-03443-x
- Oukawa, G. Y., Krecl, P., & Targino, A. C. (2022). Fine-scale modeling of the urban heat island: A comparison of multiple linear regression and random forest approaches. *Science of the total environment*, 815, 152836. doi:10.1016/j.scitotenv.2021.152836
- Peng, Y., Xiao, Y., Fu, Z., Dong, Y., Zheng, Y., Yan, H., & Li, X. (2019). Precision irrigation perspectives on the sustainable water-saving of field crop production in China: Water demand prediction and irrigation scheme optimization. *Journal of Cleaner Production*, 230, 365-377. doi:10.1016/j.jclepro.2019.04.347
- Perea, R. G., García, I. F., Poyato, E. C., & Díaz, J. R. (2023). New memory-based hybrid model for middle-term water demand forecasting in irrigated areas. *Agricultural Water Management*, 284, 108367. doi:10.1016/j.agwat.2023.108367
- Perea, R. G., Poyato, E. C., Montesinos, P., & Díaz, J. R. (2019). Prediction of irrigation event occurrence at farm level using optimal decision trees. *Computers and Electronics in agriculture*, 157, 173-180. doi:10.1016/j.compag.2018.12.043
- Sattari, M. T., Shirini, K., & Javidan, S. (2024). Evaluating the efficiency of dimensionality reduction methods in improving the accuracy of water quality index modeling in Qizil-Uzen River using machine learning algorithms. *Water and Soil Management and Modelling*, 4(2), 89-104. doi:10.22098/mmws.2023.12434.1241 [In Persian]
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. doi:10.1016/j.physd.2019.132306
- Siłka, J., Wiczorek, M., & Woźniak, M. (2022). Recurrent neural network model for high-speed train vibration prediction from time series. *Neural Computing and Applications*, 34(16), 13305-13318. doi:10.1007/s00521-022-06949-4
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, 106(D7), 7183-7192. doi:10.1029/2000JD900719
- Vu, H. L., Ng, K. T. W., Richter, A., & An, C. (2022). Analysis of input set characteristics and variances on k-fold cross validation for a Recurrent Neural Network model on waste disposal rate estimation. *Journal of Environmental Management*, 311, 114869. doi:10.1016/j.jenvman.2022.114869
- Yadav, S. P., Zaidi, S., Mishra, A., & Yadav, V. (2022). Survey on machine learning in speech emotion recognition and vision systems using a recurrent neural network (RNN). *Archives of Computational Methods in Engineering*, 29(3), 1753-1770. doi:10.1007/s11831-021-09647-x
- Yan, X., Gan, X., Wang, R., & Qin, T. (2022). Self-attention edetic 3D-LSTM: Video prediction models for traffic flow forecasting. *Neurocomputing*, 509, 167-176. doi:10.1016/j.neucom.2022.08.060

- Yatsenko, D., Reimer, J., Ecker, A.S., Walker, E.Y., Sinz, F., Berens, P., Hoenselaar, A., James Cotton, R., Siapas, A.S., & Tolia, A.S., (2015). Data Joint: managing big scientific data using MATLAB or Python. *BioRxiv*, p.031658. doi: 10.1101/031658
- Yi, S., Liu, H., Chen, T., Zhang, J., & Fan, Y. (2023). A deep LSTM-CNN based on self-attention mechanism with input data reduction for short-term load forecasting. *IET Generation, Transmission & Distribution*, 17(7), 1538-1552. doi:10.1049/gtd2.12763
- Zang, H., Xu, R., Cheng, L., Ding, T., Liu, L., Wei, Z., & Sun, G. (2021). Residential load forecasting based on LSTM fusing self-attention mechanism with pooling. *Energy*, 229, 120682. doi:10.1016/j.energy.2021.120682
- Zhang, Q., Abdullah, A. R., Chong, C. W., & Ali, M. H. (2022). A Study on Regional GDP Forecasting Analysis Based on Radial Basis Function Neural Network with Genetic Algorithm (RBFNN-GA) for Shandong Economy. *Computational Intelligence and Neuroscience*, 2022(1), 8235308. doi:10.1155/2022/8235308
- Zou, L., Zha, Y., Diao, Y., Tang, C., Gu, W., & Shao, D. (2023). Coupling the causal inference and informer networks for short-term forecasting in irrigation water usage. *Water Resources Management*, 37(1), 427-449. doi:10.1007/s11269-022-03381-0