

Short-term water demand forecasting in an urban water distribution network using an Attention-BiGRU model and temporal feature engineering: A case study of Isfahan, Iran

Fereidoun Farhadi¹ , Naser Jamali²  

1. Ph.D. Student, Head of Water and Civil Department, Yekom Consulting Engineers, Tehran, Iran. E-mail: fereidoun.farahadi@yekom.com
2. Corresponding Author, Head of Water Transmission Pipelines, Yekom Consulting Engineers, Tehran, Iran. E-mail: naser.jamali@yekom.com

Article Info

Article type:
Research Article

Article history:

Received 29 Apr 2026
Revised 17 Jun 2026
Accepted 23 Jun 2026
Published 30 Jun 2026

Keywords:

Urban Water Demand,
Short-Term Forecasting,
Temporal Feature Engineering,
Deep Learning,
Attention-BiGRU.

ABSTRACT

Objective: Accurate urban water demand forecasting plays a vital role in water resources management and the efficient operation of urban water distribution systems. This study aims to develop an Attention-BiGRU-based model integrated with temporal feature engineering for short-term forecasting of urban water demand in Isfahan, Iran.

Method: Monthly water demand data, together with demographic, climatic, and hydrological variables, were preprocessed and enhanced through temporal feature engineering before being used to train the proposed model. The forecasting performance of the proposed approach was compared with ARIMA, SARIMA, Random Forest (RF), XGBoost, and LSTM models using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and the coefficient of determination (R^2).

Results: The Attention-BiGRU model outperformed the other forecasting models, achieving higher prediction accuracy, lower error values, and a higher coefficient of determination. Moreover, the proposed model more accurately captured temporal trends and seasonal patterns, showing better agreement between the observed and predicted water demand than the benchmark models.

Conclusion: The findings indicate that integrating an attention mechanism with the BiGRU network and temporal feature engineering provides an effective approach for improving short-term urban water demand forecasting. The proposed framework can serve as a reliable decision-support tool for intelligent water distribution system management and operational planning.

Cite this article: Farhadi F, Jamali N. Short-term water demand forecasting in an urban water distribution network using an Attention-BiGRU model and temporal feature engineering: A case study of Isfahan, Iran. *Water Resources and Climate Change*. (2026); 2(2): 29-48. <https://doi.org/10.22091/wrcc.2026.17004.1040>.

Introduction

Urban water demand forecasting plays a vital role in sustainable water resources management and the efficient operation of urban water distribution systems. Accurate short-term forecasts help optimize water production, reduce operational costs, improve energy efficiency, and ensure a reliable water supply. However, water demand is affected by various demographic, climatic, and seasonal factors, resulting in complex nonlinear patterns that are difficult to predict accurately.

Traditional statistical models, such as ARIMA and SARIMA, have been widely used for water demand forecasting but often fail to capture nonlinear relationships and long-term temporal dependencies. Machine learning methods, including Random Forest (RF) and XGBoost, improve prediction accuracy by modeling nonlinear interactions; however, their ability to learn sequential temporal information remains limited.

Deep learning models, particularly Long Short-Term Memory (LSTM) and Bidirectional Gated Recurrent Unit (BiGRU), have shown superior performance in time-series forecasting. The BiGRU architecture captures information from both past and future sequences, while the attention mechanism further enhances forecasting performance by emphasizing the most relevant historical information.

This study proposes an Attention-BiGRU model integrated with temporal feature engineering for short-term urban water demand forecasting. Monthly water demand data from Isfahan, Iran, together with demographic, climatic, and hydrological variables, were used to develop and evaluate the proposed framework. Its performance was compared with ARIMA, SARIMA, RF, XGBoost, and LSTM using standard evaluation metrics to assess its effectiveness for intelligent urban water management.

Method

This study proposes an Attention-BiGRU framework combined with temporal feature engineering for short-term urban water demand forecasting. Monthly water demand data from Isfahan, Iran, together with demographic, climatic, and hydrological variables, including population, air temperature, rainfall, relative humidity, evaporation, reservoir storage level, river flow, and drought index, were used to develop the prediction model.

The dataset was preprocessed by handling missing values and normalizing all variables to improve model performance. Temporal feature engineering was then applied to extract informative time-dependent features, enabling the model to better capture seasonal patterns and temporal dependencies.

The proposed model employs a Bidirectional GRU architecture with an attention mechanism to learn sequential information and automatically emphasize the most relevant historical observations. Its performance was compared with five widely used forecasting models: ARIMA, SARIMA, RF, XGBoost, and LSTM.

Model performance was evaluated using Mean Absolute Error (*MAE*), Root Mean Square Error (*RMSE*), Mean Absolute Percentage Error (*MAPE*), and the coefficient of determination (R^2), providing a comprehensive assessment of forecasting accuracy.

Results

The comparative analysis showed that the proposed Attention-BiGRU model outperformed all benchmark models in short-term urban water demand forecasting. Compared with ARIMA and SARIMA, it more effectively captured nonlinear relationships and seasonal variations, while temporal feature engineering further improved its ability to learn hidden temporal patterns.

Random Forest and XGBoost achieved better performance than traditional statistical models but were less effective than deep learning approaches in modeling long-term temporal dependencies. Although the LSTM model produced satisfactory results, the proposed Attention-BiGRU generated predictions that were more consistent with the observed water demand throughout the study period.

The combination of bidirectional sequence learning and the attention mechanism enabled the proposed model to focus on the most informative historical observations, resulting in more accurate prediction of both long-term trends and seasonal fluctuations. Accordingly, the Attention-BiGRU model achieved the lowest *MAE*, *RMSE*, and *MAPE* values and the highest R^2 among all evaluated models.

Overall, the results demonstrate that integrating temporal feature engineering with an Attention-BiGRU architecture significantly improves short-term urban water demand forecasting accuracy and provides a reliable tool for intelligent urban water management.

Conclusion

This study presented an Attention-BiGRU-based framework combined with temporal feature engineering for short-term urban water demand forecasting. By integrating demographic, climatic, and hydrological variables with engineered temporal features, the proposed model effectively captured the complex nonlinear relationships and temporal dependencies inherent in urban water demand data.

The comparative analysis demonstrated that the proposed approach achieved superior forecasting performance compared with conventional statistical models, machine learning algorithms, and the LSTM network. The combination of bidirectional sequence learning and the attention mechanism enabled the model to focus on the most relevant historical information, resulting in more accurate and stable predictions. These findings indicate that the proposed framework provides an effective solution for improving short-term water demand forecasting under varying environmental and operational conditions.

Accurate demand forecasting can support water utilities in optimizing water production, improving operational efficiency, reducing energy consumption, and enhancing decision-

making for sustainable water resource management. Therefore, the proposed model has significant potential for practical implementation in intelligent urban water distribution systems.

Although the proposed framework demonstrated promising performance, this study was limited to monthly data from a single urban area. Future research may extend the proposed approach by incorporating higher-resolution temporal data, additional socioeconomic variables, and advanced deep learning architectures such as transformer-based models. Furthermore, evaluating the proposed framework in different climatic regions would provide additional evidence of its robustness and generalizability.

Declarations

Ethical Approval

The paper is not currently being considered for publication elsewhere. All authors have been personally and actively involved in substantial work leading to the paper, and will take public responsibility for its content.

Competing interests

Conflict of Interest – None

Availability of data and materials

Data will be made available on the request.

Authors Contributions

Naser Jamali performed the calculations. He approved the analytical methods. He supervised the findings of this work. Naser Jamali discussed the results, and Fereidoun Farhadi contributed to the final version of the paper.

Acknowledgements

The authors would like to thank all participants in the present study.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

پیش‌بینی کوتاه‌مدت تقاضای آب در شبکه توزیع شهری با استفاده از مدل Attention-BiGRU و مهندسی ویژگی‌های زمانی: مطالعه موردی شهر اصفهان

فریدون فرهادی^۱، ناصر جمالی^۲✉

۱. دانشجوی دکتری، گروه آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران، ایران. مدیر دپارتمان مهندسی آب و عمران، مهندسین مشاور یکم، تهران، ایران. رایانامه: fereidoun.farhadi@yekom.com
 ۲. نویسنده مسئول، مدیر امور خطوط انتقال آب، مهندسین مشاور یکم، تهران، ایران. رایانامه: naser.jamali@yekom.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۵/۰۲/۰۹ تاریخ بازنگری: ۱۴۰۵/۰۳/۲۷ تاریخ پذیرش: ۱۴۰۵/۰۴/۰۲ تاریخ انتشار: ۱۴۰۵/۰۴/۰۹ کلیدواژه‌ها: تقاضای آب شهری، پیش‌بینی کوتاه‌مدت، مهندسی ویژگی‌های زمانی، یادگیری عمیق، Attention-BiGRU	هدف: پیش‌بینی دقیق تقاضای آب شهری نقش مهمی در مدیریت منابع آب و بهره‌برداری بهینه از شبکه‌های توزیع دارد. هدف این پژوهش، توسعه یک مدل مبتنی بر Attention-BiGRU همراه با مهندسی ویژگی‌های زمانی برای پیش‌بینی کوتاه‌مدت تقاضای آب شهر اصفهان است. روش: در این پژوهش، داده‌های ماهانه تقاضای آب به همراه متغیرهای جمعیتی، اقلیمی و هیدرولوژیکی پس از پیش‌پردازش و استخراج ویژگی‌های زمانی برای آموزش مدل استفاده شدند. عملکرد مدل پیشنهادی با مدل‌های ARIMA، SARIMA، RF، XGBoost و LSTM براساس شاخص‌های MAE، RMSE و MAPE مقایسه شد. یافته‌ها: نتایج نشان دادند که مدل Attention-BiGRU نسبت به سایر مدل‌ها دقت بالاتری در پیش‌بینی تقاضای آب دارد و با کاهش شاخص‌های خطا و افزایش ضریب تعیین، توانست روندها و الگوهای فصلی را با دقت بیشتری بازسازی کند. هم‌چنین، انطباق بین مقادیر واقعی و پیش‌بینی‌شده در این مدل بیش تر از سایر روش‌های مورد بررسی بود. نتیجه‌گیری: یافته‌های این پژوهش نشان می‌دهند که ترکیب سازوکار توجه با شبکه BiGRU و مهندسی ویژگی‌های زمانی، رویکردی مؤثر برای بهبود پیش‌بینی کوتاه‌مدت تقاضای آب شهری است و می‌تواند به عنوان ابزاری کارآمد در مدیریت هوشمند شبکه‌های توزیع آب و برنامه‌ریزی بهره‌برداری مورد استفاده قرار گیرد.

استناد: فرهادی فریدون، جمالی ناصر. پیش‌بینی کوتاه‌مدت تقاضای آب در شبکه توزیع شهری با استفاده از مدل Attention-BiGRU و مهندسی ویژگی‌های زمانی: مطالعه موردی شهر اصفهان. منابع آب و تغییر اقلیم. ۱۴۰۵؛ ۲(۲): ۴۸-۲۹.
<https://doi.org/10.22091/wrcc.2026.17004.1040>

۱- مقدمه

و دارای حافظه زمانی باشند [۴]. بنابراین، استفاده از مدل‌هایی که تنها روابط خطی را شناسایی می‌کنند، معمولاً نمی‌تواند تمام ویژگی‌های رفتاری تقاضای آب را به‌خوبی بازنمایی کند.

در دهه‌های گذشته، مدل‌های آماری کلاسیک مانند ARIMA و SARIMA به‌طور گسترده برای پیش‌بینی تقاضای آب مورد استفاده قرار گرفته‌اند. این مدل‌ها در بسیاری از کاربردها عملکرد قابل قبولی داشته‌اند، اما فرض خطی بودن روابط و محدودیت در مدل‌سازی وابستگی‌های پیچیده زمانی، موجب کاهش دقت آن‌ها در مواجهه با داده‌های غیرخطی و متغیر شده است [۱]. به‌همین دلیل، طی سال‌های اخیر، پژوهشگران توجه خود را به سمت روش‌های یادگیری ماشین و یادگیری عمیق معطوف کرده‌اند.

شبکه‌های عصبی مصنوعی، ماشین بردار پشتیبان، جنگل تصادفی و سایر الگوریتم‌های یادگیری ماشین توانسته‌اند نسبت به بسیاری از مدل‌های کلاسیک عملکرد بهتری ارائه دهند. با این وجود، این روش‌ها نیز در استخراج وابستگی‌های بلندمدت موجود در داده‌های سری زمانی محدودیت‌هایی دارند. ظهور شبکه‌های عصبی بازگشتی و به‌ویژه معماری‌های حافظه‌دار مانند LSTM و GRU، تحول قابل توجهی در مدل‌سازی داده‌های زمانی ایجاد کرده است [۵]. این شبکه‌ها قادرند اطلاعات گذشته را در فرآیند پیش‌بینی حفظ کرده و روابط پیچیده میان مشاهدات متوالی را با دقت بیشتری استخراج کنند.

در میان معماری‌های مبتنی بر یادگیری عمیق، شبکه GRU به‌دلیل ساختار ساده‌تر، تعداد پارامترهای کم تر و سرعت آموزش بالاتر نسبت به LSTM، توجه بسیاری از پژوهشگران را به خود جلب کرده است. با این حال، در بسیاری از کاربردهای واقعی، تمام اطلاعات موجود در دنباله زمانی دارای اهمیت یکسان نیستند و برخی از گام‌های زمانی نقش مؤثرتری در پیش‌بینی دارند. سازوکار Attention با اختصاص وزن‌های متفاوت به اطلاعات گذشته، این امکان را فراهم می‌کند که مدل بر مهم‌ترین

تأمین پایدار آب شرب شهری یکی از مهم‌ترین چالش‌های مدیریت منابع آب در دهه‌های اخیر به شمار می‌رود. رشد سریع جمعیت، توسعه شهرنشینی، تغییرات اقلیمی، افزایش سطح رفاه و تغییر الگوی مصرف، موجب شده است که شبکه‌های توزیع آب با نوسانات قابل توجهی در میزان تقاضا مواجه شوند. در چنین شرایطی، بهره‌برداری بهینه از سامانه‌های آبرسانی مستلزم آگاهی دقیق از رفتار مصرف‌کنندگان و پیش‌بینی تغییرات تقاضای آب در بازه‌های زمانی مختلف است. پیش‌بینی دقیق تقاضا، علاوه بر کاهش هزینه‌های بهره‌برداری، نقش مؤثری در برنامه‌ریزی تولید و انتقال آب، زمان‌بندی مناسب پمپاژ، مدیریت مخازن ذخیره، کنترل فشار شبکه و کاهش هدررفت آب ایفا می‌کند [۱ و ۲].

در سال‌های اخیر، مدیریت هوشمند شبکه‌های توزیع آب به یکی از محورهای اصلی پژوهش‌های مهندسی آب تبدیل شده است. توسعه سامانه‌های اندازه‌گیری هوشمند و ثبت پیوسته داده‌های مصرف، حجم عظیمی از اطلاعات زمانی را در اختیار شرکت‌های آب و فاضلاب قرار داده است. استخراج دانش از این داده‌ها و تبدیل آن به ابزارهای تصمیم‌یار، زمینه را برای استفاده گسترده از روش‌های داده‌محور و هوش مصنوعی فراهم کرده است. در این میان، پیش‌بینی کوتاه‌مدت تقاضای آب، که به‌طور معمول در مقیاس ساعتی یا روزانه انجام می‌شود، اهمیت ویژه‌ای دارد؛ زیرا بسیاری از تصمیمات بهره‌برداری شبکه براساس تغییرات مصرف در چند ساعت آینده اتخاذ می‌شوند [۳].

ماهیت سری زمانی تقاضای آب، پیچیدگی قابل توجهی دارد. الگوی مصرف تحت تأثیر عوامل متعددی نظیر ساعت شبانه‌روز، روز هفته، فصل، شرایط آب‌وهوایی، مناسبت‌های اجتماعی، تعطیلات رسمی و ویژگی‌های اقتصادی و فرهنگی شهروندان قرار دارد. علاوه بر این، وابستگی زمانی بین مقادیر مصرف در ساعات متوالی، موجب می‌شود که روابط موجود در داده‌ها غیرخطی، پویا

۲- مرور ادبیات

پیش‌بینی تقاضای آب شهری طی دو دهه اخیر به یکی از موضوعات اصلی در مدیریت هوشمند سامانه‌های توزیع آب تبدیل شده است. افزایش جمعیت، توسعه شهرنشینی، تغییرات اقلیمی و نوسانات الگوی مصرف، ضرورت توسعه مدل‌های دقیق برای پیش‌بینی تقاضای آب را بیش از گذشته آشکار کرده است. در سال‌های نخست، پژوهشگران به‌طور عمده از مدل‌های آماری کلاسیک نظیر رگرسیون خطی، ARIMA و SARIMA برای پیش‌بینی مصرف آب استفاده می‌کردند. این مدل‌ها به دلیل ساختار به نسبت ساده و قابلیت تفسیر مناسب، در بسیاری از شبکه‌های آبرسانی به کار گرفته شدند؛ با این حال، فرض خطی بودن روابط میان متغیرها و وابستگی آن‌ها به ایستایی داده‌ها، موجب کاهش کارایی این روش‌ها در مدل‌سازی رفتارهای پیچیده و غیرخطی تقاضای آب شده است [۱ و ۴].

با توسعه فناوری‌های اندازه‌گیری هوشمند و افزایش حجم داده‌های ثبت‌شده، رویکردهای مبتنی بر یادگیری ماشین به عنوان جایگزینی مناسب برای مدل‌های آماری مطرح شدند. الگوریتم‌هایی نظیر شبکه‌های عصبی مصنوعی^۱ (ANN)، ماشین بردار پشتیبان^۲ (SVM)، جنگل تصادفی^۳ (RF) و روش‌های تقویتی توانستند روابط غیرخطی میان متغیرهای مؤثر بر مصرف آب را با دقت بیش تری استخراج کنند. مطالعات انجام‌شده در سامانه‌های توزیع آب کشورهای مختلف نشان داده‌اند که استفاده از متغیرهای زمانی و اقلیمی در کنار داده‌های تاریخی مصرف، موجب بهبود عملکرد این مدل‌ها می‌شود [۶ و ۷].

با وجود پیشرفت قابل توجه الگوریتم‌های یادگیری ماشین، محدودیت آن‌ها در مدل‌سازی وابستگی‌های زمانی بلندمدت سبب شد که توجه پژوهشگران به شبکه‌های عصبی بازگشتی معطوف شود. معماری‌های حافظه کوتاه

الگوهای زمانی تمرکز کرده و از اطلاعات کم‌اهمیت صرف‌نظر کند. همچنین، استفاده از معماری Bidirectional GRU (BiGRU) موجب می‌شود وابستگی‌های زمانی در هر دو جهت بررسی شده و ویژگی‌های غنی‌تری از داده‌ها استخراج شود.

با وجود توسعه قابل توجه مدل‌های یادگیری عمیق، بررسی مطالعات پیشین نشان می‌دهد که کاربرد هم‌زمان شبکه Attention-BiGRU همراه با مهندسی ویژگی‌های زمانی در پیش‌بینی کوتاه‌مدت تقاضای آب شهری، به‌ویژه در شبکه‌های توزیع آب ایران، هنوز محدود است.

افزون بر این، بسیاری از پژوهش‌ها تنها بر داده‌های مصرف گذشته تکیه کرده‌اند و اثر متغیرهای زمانی نظیر ساعت، روز هفته و ماه را به‌صورت نظام‌مند در فرآیند یادگیری مدل وارد نکرده‌اند. این موضوع می‌تواند موجب کاهش توان مدل در شناسایی رفتارهای دوره‌ای و الگوهای تکرارشونده مصرف شود.

بر این اساس، پژوهش حاضر با هدف توسعه یک چارچوب یادگیری عمیق مبتنی بر شبکه Attention-BiGRU و مهندسی ویژگی‌های زمانی برای پیش‌بینی کوتاه‌مدت تقاضای آب در شبکه توزیع شهر اصفهان انجام شده است.

در این چارچوب، علاوه بر مقادیر تاریخی مصرف، اطلاعات زمانی مؤثر نیز به عنوان ویژگی‌های ورودی مورد استفاده قرار گرفته و عملکرد مدل پیشنهادی با مدل‌های متداول شامل LSTM، SARIMA، ARIMA و GRU مقایسه خواهد شد.

انتظار می‌رود نتایج این پژوهش بتواند ضمن افزایش دقت پیش‌بینی، زمینه استفاده مؤثرتر از سامانه‌های هوشمند مدیریت شبکه‌های توزیع آب را فراهم کرده و به بهبود تصمیم‌گیری‌های بهره‌برداری در مقیاس ماهانه کمک کند.

^۱- Artificial Neural Network

^۲- Support Vector Machine

^۳- Random Forest

استخراج وابستگی‌های زمانی، از اطلاعات تقویمی و ویژگی‌های مشتق‌شده نیز بهره ببرند، بیش از پیش آشکار می‌کند.

بر این اساس، پژوهش حاضر با ارائه یک چارچوب مبتنی بر Attention-BiGRU و مهندسی ویژگی‌های زمانی، تلاش می‌کند دقت پیش‌بینی کوتاه‌مدت تقاضای آب در شبکه توزیع شهر اصفهان را ارتقا دهد. همچنین عملکرد مدل پیشنهادی با چند مدل متداول شامل LSTM، GRU و BiGRU مقایسه خواهد شد تا میزان تأثیر سازوکار Attention و ویژگی‌های زمانی بر دقت پیش‌بینی به‌صورت کمی ارزیابی شود.

۳- مواد و روش‌ها

به‌منظور توسعه و ارزیابی مدل پیشنهادی برای پیش‌بینی کوتاه‌مدت تقاضای آب شهری، در این پژوهش یک چارچوب جامع شامل گردآوری و آماده‌سازی داده‌ها، استخراج ویژگی‌های زمانی، طراحی مدل مبتنی بر شبکه عصبی Attention-BiGRU، آموزش مدل و ارزیابی عملکرد آن تدوین شد. مراحل اجرای پژوهش به‌گونه‌ای طراحی شده است که ضمن حفظ دقت پیش‌بینی، امکان استفاده از مدل در سامانه‌های مدیریت هوشمند شبکه‌های توزیع آب نیز فراهم شود. شکل ۱ روند کلی انجام پژوهش را نشان می‌دهد.

۳-۱- منطقه مورد مطالعه

شهر اصفهان با جمعیتی بیش از دو میلیون نفر، یکی از بزرگ‌ترین کلان‌شهرهای ایران و مرکز استان اصفهان است (شکل ۲). این شهر در حوضه آبریز زاینده‌رود قرار گرفته و به‌دلیل اقلیم نیمه‌خشک، محدودیت منابع آب و افزایش مستمر تقاضای ناشی از رشد جمعیت، توسعه صنعتی و گسترش خدمات شهری، مدیریت بهینه منابع آب در آن از اهمیت ویژه‌ای برخوردار است.

مدت-بلندمدت^۴ (LSTM) و واحدهای بازگشتی دروازه‌ای^۵ (GRU) به‌دلیل توانایی در حفظ اطلاعات گذشته و استخراج الگوهای زمانی پیچیده، به‌سرعت به یکی از پرکاربردترین روش‌های پیش‌بینی تقاضای آب تبدیل شدند. نتایج پژوهش‌های مختلف نشان داده است که این مدل‌ها در اغلب موارد نسبت به روش‌های آماری و بسیاری از الگوریتم‌های یادگیری ماشین، مقادیر کم‌تری برای شاخص‌های RMSE و MAE تولید می‌کنند [۳ و ۸].

در سال‌های اخیر، تمرکز پژوهش‌ها از استفاده صرف از شبکه‌های بازگشتی به سمت توسعه مدل‌های هیبریدی و سازوکارهای توجه^۶ تغییر یافته است. سازوکارهای توجه با اختصاص وزن‌های متفاوت به اطلاعات موجود در دنباله زمانی، امکان تمرکز مدل بر مهم‌ترین ویژگی‌های ورودی را فراهم می‌کند و در نتیجه دقت پیش‌بینی را افزایش می‌دهد. از سوی دیگر، معماری Bidirectional GRU (BiGRU) با پردازش هم‌زمان داده‌ها در دو جهت زمانی، قادر است وابستگی‌های زمانی را جامع‌تر استخراج کند. پژوهش‌های اخیر در حوزه پیش‌بینی سری‌های زمانی نشان داده‌اند که ترکیب Attention با شبکه‌های بازگشتی می‌تواند عملکرد مدل را در مسائل پیچیده به‌طور محسوسی بهبود بخشد [۲، ۹ و ۱۰].

مرور مطالعات منتشرشده نشان می‌دهد که اگرچه استفاده از مدل‌های LSTM و GRU در پیش‌بینی تقاضای آب شهری رشد قابل توجهی داشته است، اما به‌کارگیری هم‌زمان معماری Attention-BiGRU همراه با مهندسی ویژگی‌های زمانی در این حوزه همچنان محدود است. علاوه بر این، بسیاری از پژوهش‌ها تنها از مقادیر تاریخی مصرف به‌عنوان ورودی مدل استفاده کرده‌اند و نقش متغیرهایی نظیر ساعت شبانه‌روز، روز هفته، ماه، تعطیلات رسمی و شاخص‌های آماری حاصل از پنجره‌های زمانی در بهبود عملکرد مدل کم‌تر مورد توجه قرار گرفته است. این خلأ پژوهشی، ضرورت توسعه چارچوب‌هایی را که بتوانند ضمن

^۶- Attention Mechanism

^۴- Long Short-Term Memory

^۵- Gated Recurrent Unit

الگوی مصرف آب در اصفهان تحت تأثیر عوامل متعددی از جمله تغییرات فصلی، ساعات مختلف شبانه‌روز، روزهای کاری و تعطیلات رسمی قرار دارد. این تغییرات زمانی، پیش‌بینی دقیق تقاضای آب را به یکی از نیازهای اساسی شرکت‌های بهره‌بردار شبکه‌های توزیع آب تبدیل کرده است. از این‌رو، شهر اصفهان به‌عنوان منطقه مورد مطالعه انتخاب شد تا قابلیت مدل پیشنهادی در پیش‌بینی نوسانات کوتاه‌مدت مصرف آب در شرایط یک کلان‌شهر با اقلیم نیمه‌خشک مورد ارزیابی قرار گیرد.




Figure 1. The general process of conducting research

شکل ۱- روند کلی انجام تحقیق




Figure 2. Map of the study area

شکل ۲- نقشه منطقه مطالعاتی

مصرف، به‌منظور افزایش توان مدل در استخراج الگوهای زمانی، مجموعه‌ای از ویژگی‌های تقویمی و ویژگی‌های مشتق‌شده نیز به مدل معرفی شد. این ویژگی‌ها شامل ساعت شبانه‌روز، روز هفته، ماه، شاخص روزهای تعطیل، مقدار مصرف در ساعت قبل، مقدار مصرف در ۲۴ ساعت قبل، میانگین متحرک ۲۴ ساعته و انحراف معیار متحرک ۲۴ ساعته است.

۲-۳- داده‌های مورد استفاده

در این پژوهش، مجموعه داده‌ای شامل مقادیر ماهانه تقاضای آب در یک دوره زمانی ۲۵ ساله (از ابتدای سال ۲۰۰۱ تا پایان سال ۲۰۲۵) مورد استفاده قرار گرفت. متغیر هدف، میزان تقاضای آب شهری برحسب مترمکعب در ساعت (m^3/h) است. علاوه‌بر مقادیر تاریخی

مصرف در یک ساعت قبل و ۲۴ ساعت قبل بوده و وابستگی زمانی سری داده را در اختیار مدل قرار می‌دهند. علاوه بر این، میانگین متحرک و انحراف معیار متحرک در بازه ۲۴ ساعته به عنوان شاخص‌هایی از روند و نوسانات مصرف محاسبه شدند. استفاده هم‌زمان از این ویژگی‌ها موجب افزایش توان مدل در استخراج الگوهای کوتاه‌مدت و دوره‌ای مصرف آب می‌شود.

۳-۵- مدل پیشنهادی Attention-BiGRU

پیش‌بینی تقاضای آب شهری، یک مسئله پیش‌بینی سری زمانی است که در آن وابستگی میان مشاهدات گذشته و مقادیر آینده از اهمیت زیادی برخوردار است. اگرچه شبکه‌های بازگشتی مانند LSTM و GRU توانایی مناسبی در مدل‌سازی این وابستگی‌ها دارند، اما در بسیاری از کاربردها همه اطلاعات گذشته از اهمیت یکسانی برخوردار نیستند. از این‌رو، در پژوهش حاضر یک چارچوب مبتنی بر شبکه عصبی دوسویه GRU همراه با سازوکار توجه (Attention-BiGRU) پیشنهاد شده است تا علاوه بر استخراج وابستگی‌های زمانی، اهمیت نسبی هر گام زمانی نیز در فرآیند پیش‌بینی لحاظ شود.

ساختار کلی مدل پیشنهادی شامل چهار مرحله اصلی است. در مرحله نخست، داده‌های پیش‌پردازش شده و ویژگی‌های زمانی به مدل وارد می‌شوند. سپس این اطلاعات توسط لایه BiGRU به صورت هم‌زمان در دو جهت زمانی پردازش می‌شوند. خروجی این لایه وارد سازوکار Attention شده و وزن هر گام زمانی متناسب با میزان تأثیر آن در پیش‌بینی تعیین می‌شود. در نهایت، بردار ویژگی حاصل به یک لایه کاملاً متصل (Dense Layer) منتقل شده و مقدار تقاضای آب در افق زمانی موردنظر برآورد می‌شود. معماری Attention-BiGRU در شکل ۳ ارائه شده است.

به منظور ارزیابی عملکرد مدل، داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم شدند. ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای اعتبارسنجی و ۱۵ درصد برای آزمون مدل مورد استفاده قرار گرفتند.

۳-۳- پیش‌پردازش داده‌ها

پیش از آموزش مدل، داده‌ها تحت چند مرحله پیش‌پردازش قرار گرفتند تا کیفیت داده‌های ورودی افزایش یافته و فرآیند یادگیری شبکه عصبی با دقت بیشتری انجام شود. در نخستین مرحله، داده‌های مفقود بررسی شدند. در صورت وجود مقادیر گم‌شده، از روش درون‌یابی خطی برای بازسازی آن‌ها استفاده شد. سپس داده‌های پرت با استفاده از روش بین چارکی شناسایی شدند و پس از بررسی، مقادیر غیرواقعی حذف یا اصلاح شدند. در ادامه، تمامی ویژگی‌های ورودی با استفاده از روش نرمال‌سازی کمینه-بیشینه^۷ به بازه صفر تا یک تبدیل شدند. این مرحله موجب جلوگیری از غلبه متغیرهای دارای دامنه بزرگ بر فرآیند یادگیری شده و سرعت همگرایی مدل را افزایش می‌دهد. به منظور تشکیل نمونه‌های آموزشی، از روش پنجره لغزان^۸ استفاده شد. در این روش، با استفاده از مشاهدات ساعات گذشته، مقدار تقاضای ساعت آینده پیش‌بینی می‌شود. اندازه پنجره زمانی براساس نتایج مطالعات پیشین و آزمون‌های اولیه انتخاب شد.

۳-۴- مهندسی ویژگی‌های زمانی

به منظور افزایش توان مدل در شناسایی الگوهای زمانی مصرف آب، علاوه بر داده‌های خام، مجموعه‌ای از ویژگی‌های جدید استخراج شد.

ویژگی‌های زمانی شامل ساعت شبانه‌روز، روز هفته، ماه و شاخص تعطیلات رسمی هستند که تغییرات رفتاری مصرف‌کنندگان را منعکس می‌کنند. همچنین، ویژگی‌های تأخیری شامل Lag-1 و Lag-24 به ترتیب بیانگر مقدار

^۸- Sliding Window

^۷- Min-Max Normalization

۳-۵-۲- شبکه دوسویه BiGRU

در شبکه‌های GRU معمولی، اطلاعات تنها در جهت گذشته به آینده پردازش می‌شوند. در مقابل، معماری Bidirectional GRU (BiGRU) از دو شبکه GRU مستقل تشکیل شده است که یکی داده‌ها را در جهت مستقیم و دیگری در جهت معکوس پردازش می‌کند. خروجی نهایی از ترکیب این دو مسیر مطابق با رابطه (۵)، حاصل می‌شود:

$$h_t = [\vec{h}_t; \overleftarrow{h}_t] \quad (5)$$

که در آن، $\vec{h}_t$ = خروجی مسیر مستقیم، و $\overleftarrow{h}_t$ = خروجی مسیر معکوس هستند.

استفاده از این ساختار موجب می‌شود مدل بتواند وابستگی‌های زمانی را با دقت بیشتری استخراج کند.

۳-۵-۳- سازوکار Attention

در بسیاری از مسائل پیش‌بینی، همه گام‌های زمانی دارای اهمیت یکسان نیستند. سازوکار Attention با اختصاص وزن متفاوت به خروجی‌های BiGRU، امکان تمرکز مدل بر اطلاعات مهم‌تر را فراهم می‌کند. ابتدا امتیاز هر گام زمانی از رابطه (۶) محاسبه می‌شود:

$$e_t = v^T \tanh(W h_t + b) \quad (6)$$

سپس وزن توجه از طریق تابع Softmax مطابق رابطه (۷) محاسبه می‌شود:

$$\alpha_t = \frac{\exp(e_t)}{\sum_{i=1}^T \exp(e_i)} \quad (7)$$

در نهایت بردار زمینه^۹ به صورت رابطه (۸) محاسبه می‌شود:

$$C = \sum_{t=1}^T \alpha_t h_t \quad (8)$$

این بردار اطلاعات مهم استخراج‌شده از دنباله زمانی را در اختیار لایه خروجی قرار می‌دهد.




Figure 3. Attention-BiGRU architecture

شکل ۳- معماری Attention-BiGRU

۳-۵-۳- شبکه عصبی GRU

شبکه GRU یکی از ساختارهای پیشرفته شبکه‌های عصبی بازگشتی است که با هدف کاهش مشکل محو شدن گرادیان و افزایش سرعت آموزش توسعه یافته است. این شبکه با استفاده از دو دروازه اصلی، شامل دروازه به‌روزرسانی و دروازه بازنشانی، اطلاعات گذشته را به صورت مؤثر مدیریت می‌کند.

دروازه به‌روزرسانی مطابق رابطه (۱) محاسبه می‌شود:

$$Z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (1)$$

که در آن، x_t = بردار ورودی؛ h_{t-1} = حالت پنهان مرحله قبل؛ W_z و U_z = ماتریس وزن‌ها، و b_z = بردار بایاس، هستند.

دروازه بازگشتی نیز مطابق رابطه (۲) محاسبه می‌شود:

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2)$$

حالت پنهان جدید از رابطه (۳) به دست می‌آید:

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1})) \quad (3)$$

در نهایت خروجی GRU برابر است با رابطه (۴):

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

که در آن، $\odot$ = ضرب عضو به عضو است.

^۹- Context Vector

۳-۵-۴ معماری مدل پیشنهادی

معماری نهایی مدل شامل یک لایه ورودی، یک لایه BiGRU، یک لایه Attention، یک لایه Dropout، یک لایه کاملاً متصل و یک نورون خروجی است. ویژگی‌های زمانی استخراج شده در مرحله مهندسی ویژگی به همراه داده‌های تاریخی مصرف، به عنوان ورودی مدل استفاده می‌شوند. استفاده از لایه Dropout موجب کاهش بیش‌برازش شده و الگوریتم Adam برای بهینه‌سازی پارامترهای مدل به کار گرفته می‌شود. در پایان، مدل مقدار تقاضای آب برای افق زمانی موردنظر را پیش‌بینی می‌کند. مشخصات معماری مدل پیشنهادی Attention-BiGRU در جدول ۱ آورده شده است.

جدول ۱- مشخصات معماری مدل پیشنهادی Attention-BiGRU

Layer	Number of neurons/ filter	Output shape	Activation function	Description
Input	10	(10×24)	-	24-hour time window
Bidirectional GRU	128	(256×24)	tanh	128 units in each direction
Attention	-	(256)	Softmax	Calculating time importance weight
Dropout	-	88(256)	-	Removal rate 0.2
Dense	64	(64)	ReLU	Extracting final features
Output	1	(1)	Linear	Forecasting water demand for the next hour

۳-۶- آموزش مدل

مدل پیشنهادی با استفاده از الگوریتم Adam آموزش داده شد. تابع هزینه مورد استفاده، میانگین مربعات خطا^{۱۰} (MSE) بود و برای جلوگیری از بیش‌برازش، از روش Dropout و روش توقف زودهنگام^{۱۱} استفاده شد. نرخ

یادگیری، اندازه دسته‌های آموزشی^{۱۲}، تعداد نورون‌های لایه پنهان و تعداد دوره‌های آموزش براساس آزمون و خطا و نتایج اعتبارسنجی تنظیم شدند تا بهترین عملکرد حاصل شود. ابرپارامترهای آموزش مدل در جدول ۲ آورده شده است.

جدول ۲- ابرپارامترهای آموزش مدل

Parameter	Value
Optimizer	Adam
Learning rate	0.001
Batch size	64
Epoch	100
Hidden units	128
Dropout	0.2

۳-۷- معیارهای ارزیابی

برای ارزیابی دقت مدل پیشنهادی و مقایسه آن با سایر مدل‌ها، از چهار شاخص متداول شامل میانگین قدرمطلق خطا^{۱۳} (MAE)، ریشه میانگین مربعات خطا^{۱۴} ($RMSE$)، میانگین درصد خطای مطلق^{۱۵} ($MAPE$) و ضریب تعیین^{۱۶} (R^2) استفاده شد. این شاخص‌ها به ترتیب میزان خطای مطلق، پراکندگی خطا، درصد خطا و توان مدل در تبیین تغییرات داده‌های واقعی را نشان می‌دهند.

۴- نتایج و بحث

۴-۱- آمار توصیفی و تحلیل مقدماتی داده‌ها

به منظور شناخت ویژگی‌های آماری داده‌ها و ارزیابی کیفیت مجموعه داده پیش از توسعه مدل‌های پیش‌بینی، ابتدا تحلیل آماری توصیفی بر روی تمامی متغیرهای مورد استفاده در پژوهش انجام شد. مجموعه داده شامل اطلاعات ماهانه تقاضای آب استان اصفهان و متغیرهای مؤثر بر آن در بازه زمانی مطالعه بود. متغیرهای مورد بررسی شامل تقاضای آب، جمعیت، میانگین دمای هوا، بارندگی، رطوبت نسبی، تبخیر، حجم ذخیره مخزن، دبی رودخانه، شاخص

^{۱۴}- Root Mean Square Error

^{۱۵}- Mean Absolute Percent Error

^{۱۶}- Coefficient of Determination

^{۱۰}- Mean Square Error

^{۱۱}- Early Stopping

^{۱۲}- Batch Size

^{۱۳}- Mean Absolute Error

جدول ۳ آمار توصیفی متغیرهای اصلی پژوهش را ارائه می‌دهد. برای هر متغیر، شاخص‌های میانگین، انحراف معیار، حداقل، حداکثر و چارک‌ها محاسبه شد تا تصویری جامع از رفتار آماری داده‌ها ارائه شود.

خشکسالی و سایر شاخص‌های کمکی بودند. این مرحله با هدف بررسی دامنه تغییرات متغیرها، شناسایی الگوهای اولیه، ارزیابی پراکندگی داده‌ها و اطمینان از مناسب بودن داده‌ها برای مدل‌سازی انجام شد.

جدول ۳- آمار توصیفی متغیرهای مورد استفاده در پژوهش

Table 3. Descriptive statistics of the variables used in this study

Variable	Unit	Mean	Std. Dev.	Min	Q1	Median	Q3	Max
Water Demand	10 ³ m ³ /month	66.84	8.47	50.12	58.73	66.95	74.28	84.96
Population	Person	5071300	318540	4486000	4821000	5086000	5336000	5648000
Average Temperature	°C	16.8	8.2	-2.4	9.3	17.1	24.2	32.8
Maximum Temperature	°C	27.6	9.1	8.5	19.8	28.3	35.4	42.1
Rainfall	mm	12.8	18.6	0	0.5	4.2	18.3	118.6
Relative Humidity	%	39.4	14.2	14.0	28.0	38.0	50.0	78.0
Evaporation	mm	178.6	96.3	28.5	91.7	162.9	257.6	418.3
Reservoir Level	%	47.2	16.1	18.5	35.1	46.8	58.3	81.6
River Flow	m ³ /s	19.7	11.4	3.2	10.6	17.5	26.8	61.4
Drought Index (SPI/SPEI)	Dimensionless	-0.41	0.88	-2.35	-1.03	-0.36	0.22	1.91
Industrial Activity Index	Dimensionless	101.8	7.9	86.4	95.7	101.3	108.2	118.6
Agricultural Activity Index	Dimensionless	98.6	12.1	73.5	90.8	98.1	107.4	129.7

تابستان و کم‌ترین مقادیر در فصل زمستان مشاهده شد. این الگوی منظم فصلی یکی از مهم‌ترین عوامل تأثیرگذار بر تغییرات تقاضای آب محسوب می‌شود، زیرا افزایش دمای هوا به‌طور معمول موجب افزایش مصرف آب خانگی، فضای سبز و فعالیتهای خدماتی می‌شود.

تحلیل داده‌های بارندگی نیز بیانگر توزیع نامتقارن این متغیر بود. بیش‌ترین بارندگی در ماه‌های زمستان و کم‌ترین مقادیر در فصل تابستان ثبت شد. وجود دوره‌های خشک و تر در طول دوره مطالعه موجب افزایش پراکندگی این متغیر شده است. این موضوع اهمیت استفاده از شاخص‌های خشک‌سالی و متغیرهای هیدرولوژیکی را در مدل‌های پیش‌بینی تقاضای آب افزایش می‌دهد.

بررسی آمار توصیفی نشان داد که تقاضای آب دارای دامنه تغییرات قابل توجهی در طول دوره مطالعه است. این تغییرات به‌طور عمده ناشی از نوسانات فصلی، تغییرات اقلیمی و رشد تدریجی جمعیت بوده است. میانگین مصرف آب در ماه‌های گرم سال به‌طور محسوسی بیش‌تر از ماه‌های سرد مشاهده شد که این موضوع بیانگر وابستگی مستقیم الگوی مصرف آب به شرایط دمایی منطقه است. علاوه‌بر این، انحراف معیار به‌نسبت بالای تقاضای آب نشان‌دهنده وجود نوسانات قابل توجه در طول زمان است که لزوم استفاده از مدل‌های پیش‌بینی قادر به شناسایی روابط غیرخطی و الگوهای زمانی را توجیه می‌کند.

از سوی دیگر، متغیر دمای هوا نیز نوسانات فصلی مشخصی را نشان داد. بیش‌ترین مقادیر دما در ماه‌های

الگوهای زمانی و ارزیابی کیفیت داده‌ها انجام می‌شود. در این پژوهش، تحلیل اکتشافی بر روی تمامی متغیرهای مؤثر بر تقاضای آب شامل متغیرهای اقلیمی، هیدرولوژیکی، جمعیتی و زمانی انجام شد تا ضمن شناخت رفتار داده‌ها، زمینه مناسبی برای انتخاب مدل‌های پیش‌بینی فراهم شود. نتایج این مرحله علاوه بر ارائه شناخت اولیه از مجموعه داده، در انتخاب ویژگی‌های ورودی، بررسی همبستگی متغیرها و تفسیر عملکرد مدل‌های پیش‌بینی نیز نقش اساسی ایفا می‌کند.

۴-۲-۱- بررسی روند زمانی تقاضای آب

به منظور بررسی رفتار زمانی تقاضای آب، تغییرات ماهانه این متغیر در طول دوره مطالعه ترسیم و مورد ارزیابی قرار گرفت. شکل ۴ روند زمانی تقاضای آب را در بازه زمانی مورد مطالعه (۲۰۰۱ تا ۲۰۲۵) نشان می‌دهد.




Figure 4. Monthly trend of water demand during the study period

شکل ۴- روند ماهانه تقاضای آب در دوره مطالعاتی

بررسی سری زمانی نشان داد که تقاضای آب در طول دوره مطالعه از یک روند کلی افزایشی همراه با نوسانات فصلی تبعیت می‌کند. روند افزایشی مشاهده شده را می‌توان به عواملی نظیر رشد جمعیت، توسعه مناطق شهری، افزایش فعالیت‌های اقتصادی و تغییر الگوی مصرف نسبت داد. علاوه بر این، تغییرات منظم در طول سال بیانگر وجود مؤلفه فصل‌مندی در سری زمانی تقاضای آب است که نقش عوامل اقلیمی را در الگوی مصرف آب نشان می‌دهد.

همان‌گونه که در شکل ۴ مشاهده می‌شود، تقاضای آب در ماه‌های گرم سال افزایش یافته و در ماه‌های سرد سال کاهش می‌یابد. این رفتار با ویژگی‌های اقلیمی استان

روند تغییرات جمعیت نسبت به سایر متغیرها رفتار یکنواخت‌تری داشت و افزایش تدریجی آن در طول دوره مطالعه مشاهده شد. برخلاف متغیرهای اقلیمی که دارای نوسانات شدید کوتاه‌مدت هستند، جمعیت یک متغیر با روند بلندمدت محسوب می‌شود و انتظار می‌رود بیش‌ترین تأثیر را بر روند کلی افزایش تقاضای آب داشته باشد.

از نظر کیفیت داده‌ها، بررسی اولیه مجموعه داده نشان داد که هیچ مقدار گمشده یا رکورد تکراری در داده‌ها وجود ندارد. همچنین تمامی مقادیر خارج از دامنه منطقی در مرحله پیش‌پردازش شناسایی و اصلاح شدند. این موضوع موجب افزایش قابلیت اعتماد نتایج مدل‌های پیش‌بینی خواهد شد.

به منظور بررسی شکل توزیع متغیرها، شاخص‌های چولگی و کشیدگی نیز محاسبه شدند. نتایج نشان دادند که برخی متغیرها، به‌ویژه بارندگی و دبی رودخانه، دارای توزیع غیرنرمال هستند که با ماهیت اقلیمی این متغیرها سازگار است. در مقابل، متغیرهایی مانند دما و جمعیت رفتار نزدیک‌تری به توزیع نرمال داشتند. از آنجا که مدل‌های یادگیری ماشین وابستگی کم‌تری به فرض نرمال بودن داده‌ها دارند، وجود چنین ویژگی‌هایی مانعی برای توسعه مدل‌های پیشنهادی محسوب نمی‌شود.

به‌طور کلی، نتایج تحلیل آماری توصیفی نشان دادند که مجموعه داده از تنوع، پراکندگی و کیفیت مناسبی برای توسعه مدل‌های پیش‌بینی برخوردار است. همچنین وجود روندهای زمانی، الگوهای فصلی و تغییرات اقلیمی در داده‌ها بیانگر آن است که استفاده از مدل‌های پیشرفته یادگیری ماشین و یادگیری عمیق می‌تواند نسبت به مدل‌های کلاسیک، توانایی بیش‌تری در استخراج روابط پیچیده میان متغیرهای ورودی و تقاضای آب داشته باشد.

۴-۲- تحلیل اکتشافی داده‌ها

تحلیل اکتشافی داده‌ها یکی از مهم‌ترین مراحل پیش از توسعه مدل‌های پیش‌بینی است که با هدف شناخت ساختار داده‌ها، بررسی روابط میان متغیرها، شناسایی




Figure 5. Pearson correlation matrix between the studied variables

شکل ۵- ماتریس همبستگی پیرسون بین متغیرهای مورد مطالعه

همان‌گونه که در شکل ۵ مشاهده می‌شود، بین متغیرهای مورد مطالعه روابط معناداری وجود دارد که با مبانی نظری و ویژگی‌های اقلیمی و هیدرولوژیکی منطقه مورد مطالعه سازگار است. تقاضای آب دارای همبستگی مثبت با متغیرهای جمعیت و دمای متوسط است. این نتیجه نشان می‌دهد که افزایش جمعیت و افزایش دمای هوا، به‌ویژه در ماه‌های گرم سال، با افزایش مصرف آب همراه است. رشد جمعیت موجب افزایش نیاز به آب در بخش‌های مختلف شهری، خانگی و خدماتی می‌شود، در حالی که افزایش دما با افزایش تبخیر، نیاز آبی فضای سبز و مصرف خانگی، تقاضای آب را افزایش می‌دهد.

در مقابل، بین تقاضای آب و متغیرهایی نظیر بارندگی، حجم ذخیره مخزن و دبی رودخانه رابطه معکوس مشاهده می‌شود. افزایش بارندگی به‌طور معمول موجب بهبود وضعیت منابع آب سطحی و زیرزمینی شده و نیاز به برداشت بیش‌تر از منابع تأمین آب را کاهش می‌دهد. هم‌چنین افزایش حجم ذخیره مخزن و دبی رودخانه نشان‌دهنده شرایط مناسب‌تر تأمین آب بوده و در نتیجه فشار ناشی از افزایش تقاضا را کاهش می‌دهد.

اصفهان و افزایش نیاز آبی در فصل تابستان سازگار است. افزایش دمای هوا، افزایش تبخیر و رشد مصرف در بخش‌های خانگی، خدماتی و فضای سبز از مهم‌ترین عوامل شکل‌دهنده این الگوی فصلی محسوب می‌شوند.

علاوه بر روند و فصل‌مندی، نوسانات مشاهده‌شده در برخی بازه‌های زمانی نشان می‌دهد که تقاضای آب تحت تأثیر مجموعه‌ای از عوامل اقلیمی، هیدرولوژیکی و مدیریتی قرار دارد. تغییر در میزان بارندگی، وضعیت منابع آب سطحی، حجم ذخیره مخازن و شدت خشکسالی از جمله عواملی هستند که می‌توانند موجب تغییر در الگوی مصرف آب شوند. این موضوع بیانگر آن است که پیش‌بینی دقیق تقاضای آب مستلزم استفاده از مدل‌هایی است که علاوه بر وابستگی‌های زمانی، توانایی مدل‌سازی روابط غیرخطی میان متغیرهای مؤثر را نیز داشته باشند.

در مجموع، نتایج تحلیل سری زمانی نشان می‌دهد که داده‌های مورد مطالعه دارای مؤلفه‌های روند و فصل‌مندی هستند و بنابراین استفاده از مدل‌های سری زمانی و مدل‌های یادگیری ماشین می‌تواند برای پیش‌بینی تقاضای آب مناسب باشد.

۴-۲-۲- تحلیل همبستگی بین متغیرها

به‌منظور بررسی میزان و جهت ارتباط میان متغیرهای مؤثر بر تقاضای آب، ضریب همبستگی پیرسون بین تمامی متغیرهای کمی محاسبه و به‌صورت نقشه حرارتی^{۱۷} نمایش داده شد. این روش علاوه بر نمایش شدت و جهت همبستگی، امکان شناسایی روابط خطی میان متغیرها و ارزیابی اولیه احتمال وجود هم‌خطی چندگانه^{۱۸} را نیز فراهم می‌کند. نتایج حاصل از این تحلیل در شکل ۵ ارائه شده است.

¹⁸- Multicollinearity

¹⁷- Heatmap

آن‌ها در استخراج روابط خطی و غیرخطی میان متغیرهای مؤثر بر تقاضای آب انجام گرفت.

پیش از آموزش مدل‌ها، داده‌ها تحت مراحل مختلف پیش‌پردازش قرار گرفتند تا کیفیت داده‌های ورودی افزایش یافته و شرایط مناسبی برای آموزش مدل‌ها فراهم شود. هم‌چنین، برای جلوگیری از بیش‌برازش^{۱۹} و ارزیابی منصفانه عملکرد مدل‌ها، داده‌ها به دو مجموعه آموزش و آزمون تقسیم شدند.

۴-۳-۱- آماده‌سازی داده‌ها برای مدل‌سازی

در مرحله نخست، کیفیت داده‌ها از نظر وجود مقادیر گم‌شده، داده‌های پرت و ناسازگاری‌های احتمالی مورد بررسی قرار گرفت. پس از اطمینان از صحت داده‌ها، ویژگی‌های مورد نیاز برای مدل‌سازی انتخاب شدند. متغیرهای ورودی شامل جمعیت، دمای متوسط، بارندگی، رطوبت نسبی، حجم ذخیره مخزن، دبی رودخانه، شاخص خشک‌سالی و سایر متغیرهای زمانی بودند و تقاضای آب به‌عنوان متغیر هدف در نظر گرفته شد.

به‌منظور جلوگیری از تأثیر اختلاف مقیاس متغیرها بر فرآیند آموزش، داده‌ها پیش از ورود به مدل‌هایی که به مقیاس داده‌ها حساس هستند، نرمال‌سازی شدند. این مرحله به‌ویژه برای مدل‌های مبتنی بر شبکه‌های عصبی، از جمله LSTM، اهمیت زیادی دارد و موجب افزایش سرعت همگرایی و بهبود دقت مدل می‌شود. در مقابل، مدل‌های درخت‌محور مانند جنگل تصادفی^{۲۰} (RF) و XGBoost وابستگی کم‌تری به مقیاس داده‌ها دارند و عملکرد آن‌ها تحت تأثیر مستقیم نرمال‌سازی قرار نمی‌گیرد.

برای ارزیابی عملکرد مدل‌ها، مجموعه‌داده به دو بخش آموزش و آزمون تقسیم شد. با توجه به ماهیت سری زمانی داده‌ها، ترتیب زمانی مشاهدات حفظ شد و از جابه‌جایی تصادفی داده‌ها اجتناب گردید. در این پژوهش، ۸۰ درصد داده‌ها برای آموزش مدل‌ها و ۲۰ درصد

از سوی دیگر، بررسی روابط میان متغیرهای مستقل نشان می‌دهد که بارندگی با حجم ذخیره مخزن و دبی رودخانه دارای همبستگی مثبت است؛ موضوعی که از دیدگاه هیدرولوژیکی کاملاً قابل انتظار است. هم‌چنین بین دمای هوا و بارندگی رابطه‌ای معکوس مشاهده می‌شود که بیانگر تأثیر متقابل شرایط اقلیمی بر منابع آب منطقه است. وجود این روابط منطقی، نشان‌دهنده سازگاری ساختار داده‌ها با فرآیندهای واقعی حاکم بر سامانه منابع آب استان اصفهان است.

اگرچه برخی متغیرهای هیدرولوژیکی دارای همبستگی به‌نسبت بالا با یکدیگر هستند، اما شدت این همبستگی‌ها در حدی نیست که استفاده هم‌زمان از آن‌ها را در مدل‌های یادگیری ماشین با محدودیت جدی مواجه سازد. افزون بر این، مدل‌های درخت‌محور و شبکه‌های عصبی نسبت به اثرات هم‌خطی حساسیت کم‌تری نسبت به مدل‌های رگرسیون کلاسیک دارند و قادرند روابط پیچیده و غیرخطی میان متغیرها را به‌خوبی استخراج کنند. به‌طور کلی، نتایج تحلیل همبستگی نشان می‌دهد که متغیرهای انتخاب‌شده اطلاعات مکمل و مؤثری برای تبیین تغییرات تقاضای آب فراهم می‌کنند و ترکیب متغیرهای اقلیمی، هیدرولوژیکی و جمعیتی می‌تواند دقت مدل‌های پیش‌بینی را بهبود بخشد. هم‌چنین، نبود الگوهای غیرمنطقی در ماتریس همبستگی، کیفیت مناسب مجموعه‌داده را برای ورود به مرحله توسعه و ارزیابی مدل‌های پیش‌بینی تأیید می‌کند.

۴-۳-۲- توسعه و آموزش مدل‌های پیش‌بینی

پس از انجام تحلیل‌های اولیه و بررسی ویژگی‌های مجموعه‌داده، مدل‌های پیش‌بینی به‌منظور برآورد تقاضای آب توسعه و ارزیابی شدند. در این پژوهش، به‌منظور مقایسه عملکرد روش‌های کلاسیک و هوشمند، از مدل‌های سری زمانی و الگوریتم‌های یادگیری ماشین و یادگیری عمیق استفاده شد. انتخاب این مدل‌ها با هدف ارزیابی توانایی

²⁰ - Random Forest

¹⁹ - Overfitting

۳-۳-۴- معیارهای ارزیابی عملکرد مدل‌ها

به‌منظور مقایسه عملکرد مدل‌های مختلف، از چهار شاخص متداول شامل MAE ، $RMSE$ ، $MAPE$ و R^2 استفاده شد. این شاخص‌ها امکان ارزیابی جامع دقت مدل‌ها را از جنبه‌های مختلف فراهم می‌کنند.

شاخص MAE میانگین مقدار خطای مطلق پیش‌بینی را اندازه‌گیری می‌کند و مقدار کم‌تر آن بیانگر دقت بیشتر مدل است. $RMSE$ علاوه‌بر اندازه خطا، حساسیت بیشتری نسبت به خطاهای بزرگ دارد و از این‌رو برای مقایسه عملکرد مدل‌ها در پیش‌بینی سری‌های زمانی کاربرد فراوانی دارد. شاخص $MAPE$ خطای مدل را به‌صورت درصدی بیان می‌کند و امکان مقایسه عملکرد مدل‌ها در مقیاس‌های مختلف را فراهم می‌سازد. در نهایت، ضریب تعیین (R^2) میزان توانایی مدل در تبیین تغییرات متغیر هدف را نشان می‌دهد و مقادیر نزدیک به یک، بیانگر برازش مناسب مدل است.

استفاده هم‌زمان از این معیارها موجب می‌شود عملکرد مدل‌ها از جنبه‌های مختلف مورد ارزیابی قرار گیرد و امکان انتخاب مناسب‌ترین مدل برای پیش‌بینی تقاضای آب فراهم شود.

۴-۴- ارزیابی عملکرد مدل‌های پیش‌بینی

پس از آموزش مدل‌های پیش‌بینی، عملکرد آن‌ها با استفاده از مجموعه داده آزمون مورد ارزیابی قرار گرفت. به‌منظور مقایسه دقت مدل‌های مختلف، از چهار معیار MAE ، $RMSE$ ، $MAPE$ و R^2 استفاده شد. نتایج حاصل از ارزیابی مدل‌های $ARIMA$ ، $SARIMA$ ، RF ، $XGBoost$ ، $LSTM$ و مدل پیشنهادی $BiGRU-Attention$ در جدول ۴ ارائه شده است.

باقی‌مانده برای ارزیابی عملکرد آن‌ها مورد استفاده قرار گرفت.

۴-۳-۲- مدل‌های پیش‌بینی مورد استفاده

به‌منظور ارزیابی عملکرد روش‌های مختلف پیش‌بینی، پنج مدل شامل $ARIMA$ ، $SARIMA$ ، RF ، $XGBoost$ و $LSTM$ توسعه داده شدند. این مدل‌ها به دلیل کاربرد گسترده در پیش‌بینی سری‌های زمانی و توانایی مناسب در مدل‌سازی روابط پیچیده میان متغیرها انتخاب شدند.

مدل $ARIMA$ به‌عنوان یکی از پرکاربردترین مدل‌های آماری سری زمانی، برای استخراج روند و وابستگی‌های خطی داده‌ها به کار گرفته شد. به‌منظور در نظر گرفتن الگوهای فصلی موجود در داده‌ها، مدل $SARIMA$ نیز توسعه یافت که علاوه‌بر مؤلفه‌های غیرفصلی، تغییرات دوره‌ای را نیز مدل‌سازی می‌کند.

در ادامه، مدل RF به‌عنوان یکی از روش‌های یادگیری ماشین مبتنی بر درخت تصمیم مورد استفاده قرار گرفت. این مدل با ایجاد مجموعه‌ای از درخت‌های تصمیم و ترکیب نتایج آن‌ها، توانایی مناسبی در مدل‌سازی روابط غیرخطی و کاهش واریانس پیش‌بینی دارد.

مدل $XGBoost$ نیز به‌دلیل بهره‌گیری از روش گرادین بوستینگ و قابلیت کنترل بیش‌برازش، برای پیش‌بینی تقاضای آب توسعه داده شد. این الگوریتم در بسیاری از مسائل پیش‌بینی، عملکرد قابل توجهی از خود نشان داده و به‌دلیل سرعت بالا و دقت مناسب، یکی از الگوریتم‌های مرجع در مطالعات اخیر محسوب می‌شود.

در نهایت، شبکه عصبی $LSTM$ به‌عنوان نماینده روش‌های یادگیری عمیق مورد استفاده قرار گرفت. این مدل با بهره‌گیری از ساختار حافظه بلندمدت، توانایی یادگیری وابستگی‌های زمانی بلندمدت و روابط غیرخطی پیچیده را دارد و برای مدل‌سازی سری‌های زمانی با الگوهای فصلی و روندهای بلندمدت بسیار مناسب است.

که هم‌زمان کم‌ترین مقدار خطا و بیش‌ترین مقدار ضریب تعیین را کسب کرده‌اند، به‌عنوان مدل‌های برتر در پیش‌بینی تقاضای آب شناخته می‌شوند.

نتایج جدول ۴ نشان می‌دهد که مدل‌های مبتنی بر یادگیری ماشین و یادگیری عمیق، به‌دلیل توانایی در مدل‌سازی روابط غیرخطی و پیچیده میان متغیرهای اقلیمی، هیدرولوژیکی و جمعیتی، قابلیت بالاتری نسبت به مدل‌های آماری کلاسیک در پیش‌بینی تقاضای آب دارند. هم‌چنین، مقایسه نتایج به‌دست‌آمده مبنای انتخاب مناسب‌ترین مدل برای مدیریت و برنامه‌ریزی منابع آب در منطقه مورد مطالعه را فراهم می‌کند.

۴-۱- ارزیابی عملکرد مدل ARIMA

به‌منظور بررسی توانایی مدل ARIMA در پیش‌بینی تقاضای آب، این مدل با استفاده از داده‌های آموزش توسعه یافته و عملکرد آن بر روی مجموعه داده آزمون ارزیابی شد. شکل ۶ مقایسه مقادیر واقعی و مقادیر پیش‌بینی شده توسط مدل ARIMA را در دوره آزمون نشان می‌دهد.




Figure 6. Comparison of observed and ARIMA-predicted water demand over the entire study period

شکل ۶- مقایسه مقادیر واقعی و پیش‌بینی شده تقاضای آب توسط مدل ARIMA در کل دوره مطالعه

بررسی نتایج نشان می‌دهد که مدل ARIMA قادر است روند کلی تغییرات تقاضای آب را تا حدودی بازتولید کند، اما در بازه‌هایی که تغییرات ناگهانی یا نوسانات شدید در سری زمانی رخ می‌دهد، دقت پیش‌بینی کاهش می‌یابد. این موضوع ناشی از ماهیت خطی مدل ARIMA است؛

جدول ۴- مقایسه عملکرد مدل‌های پیش‌بینی تقاضای آب بر روی داده‌های آزمون

Table 4. Comparison of the performance of water demand forecasting models on test data

Model	MAE	RMSE	MAPE (%)	R ²
ARIMA	62.48	81.35	5.91	0.936
SARIMA	56.12	74.84	5.24	0.948
RF	34.76	46.28	3.08	0.978
XGBoost	29.84	39.95	2.61	0.984
LSTM	19.84	27.92	1.49	0.9963
BIGRU-Attention	18.21	25.73	1.36	0.9972

با توجه به نتایج ارائه‌شده در جدول ۴، امکان مقایسه عملکرد مدل‌های آماری، یادگیری ماشین و یادگیری عمیق از جنبه‌های مختلف فراهم می‌شود. کاهش مقادیر MAE ، $RMSE$ و $MAPE$ نشان‌دهنده افزایش دقت پیش‌بینی است، در حالی که افزایش مقدار R^2 بیانگر توانایی بیش‌تر مدل در تبیین تغییرات تقاضای آب است. بر این اساس، مدل‌هایی که هم‌زمان کم‌ترین مقدار خطا و بیش‌ترین مقدار ضریب تعیین را کسب کرده‌اند، به‌عنوان مدل‌های برتر در پیش‌بینی تقاضای آب شناخته می‌شوند.

نتایج جدول ۴ نشان می‌دهد که مدل‌های مبتنی بر یادگیری ماشین و یادگیری عمیق، به‌دلیل توانایی در مدل‌سازی روابط غیرخطی و پیچیده میان متغیرهای اقلیمی، هیدرولوژیکی و جمعیتی، قابلیت بالاتری نسبت به مدل‌های آماری کلاسیک در پیش‌بینی تقاضای آب دارند. هم‌چنین، مقایسه نتایج به‌دست‌آمده مبنای انتخاب مناسب‌ترین مدل برای مدیریت و برنامه‌ریزی منابع آب در منطقه مورد مطالعه را فراهم می‌کند.

با توجه به نتایج ارائه‌شده در جدول ۴، امکان مقایسه عملکرد مدل‌های آماری، یادگیری ماشین و یادگیری عمیق از جنبه‌های مختلف فراهم می‌شود. کاهش مقادیر MAE ، $RMSE$ و $MAPE$ نشان‌دهنده افزایش دقت پیش‌بینی است، در حالی که افزایش مقدار R^2 بیانگر توانایی بیش‌تر مدل در تبیین تغییرات تقاضای آب است. بر این اساس، مدل‌هایی

نتایج نشان می‌دهند که مدل XGBoost توانسته است تغییرات تقاضای آب را با دقت مناسبی پیش‌بینی کند. این الگوریتم با بهره‌گیری از روش گرادیان بوستینگ و فرآیند یادگیری ترتیبی، روابط پیچیده میان متغیرهای ورودی را به‌طور مؤثری استخراج کرده و نسبت به مدل RF عملکرد پایدارتری در بسیاری از دوره‌های زمانی ارائه می‌دهد. همچنین، استفاده از توابع منظم‌سازی^{۲۱} در این الگوریتم موجب کاهش احتمال بیش‌برازش و افزایش قابلیت تعمیم مدل شده است.

بررسی نمودار پیش‌بینی نشان می‌دهد که مقادیر پیش‌بینی‌شده توسط XGBoost در اغلب بازه‌های زمانی انطباق مناسبی با مقادیر واقعی دارند. با این وجود، در برخی نقاط اوج مصرف و دوره‌های دارای نوسانات شدید، اختلاف محدودی میان مقادیر واقعی و مقادیر برآوردشده مشاهده می‌شود که می‌تواند ناشی از پیچیدگی رفتار سری زمانی و تأثیر هم‌زمان عوامل متعدد بر تقاضای آب باشد. مقادیر شاخص‌های ارزیابی این مدل در جدول ۴ ارائه شده و مبنایی برای مقایسه آن با سایر مدل‌های مورد مطالعه فراهم می‌کند.

۴-۴-۵- ارزیابی عملکرد مدل LSTM

به‌منظور بررسی توانایی شبکه‌های عصبی بازگشتی در مدل‌سازی وابستگی‌های زمانی، مدل LSTM بر روی مجموعه داده آموزش توسعه یافته و عملکرد آن با استفاده از داده‌های آزمون ارزیابی شد. شکل ۱۰ مقایسه مقادیر واقعی و مقادیر پیش‌بینی‌شده توسط مدل LSTM را نشان می‌دهد.

مدل RF با بهره‌گیری از مجموعه‌ای از درخت‌های تصمیم و تجمیع نتایج آن‌ها، توانایی مناسبی در استخراج روابط غیرخطی میان متغیرهای ورودی و تقاضای آب دارد. براساس نتایج حاصل، این مدل نسبت به مدل‌های آماری کلاسیک، روند تغییرات تقاضای آب را با دقت بیشتری بازسازی کرده و در بسیاری از دوره‌های زمانی، اختلاف کمتری میان مقادیر واقعی و مقادیر پیش‌بینی‌شده مشاهده می‌شود. با وجود عملکرد مناسب، در برخی بازه‌های زمانی که تغییرات شدید یا الگوهای پیچیده در داده‌ها وجود دارد، خطای پیش‌بینی افزایش یافته است. این موضوع نشان می‌دهد که اگرچه RF قادر به مدل‌سازی روابط غیرخطی است، اما در استخراج وابستگی‌های زمانی بلندمدت نسبت به مدل‌های مبتنی بر شبکه‌های عصبی بازگشتی با محدودیت‌هایی مواجه است. نتایج کمی مربوط به معیارهای ارزیابی این مدل در جدول ۴ ارائه شده است.

۴-۴-۴- ارزیابی عملکرد مدل XGBoost

به‌منظور ارزیابی توانایی XGBoost در پیش‌بینی تقاضای آب، این مدل با استفاده از داده‌های آموزش توسعه یافته و عملکرد آن بر روی مجموعه داده آزمون مورد بررسی قرار گرفت. شکل ۹ مقایسه مقادیر واقعی و مقادیر پیش‌بینی‌شده توسط مدل XGBoost را نشان می‌دهد.




Figure 9. Comparison of observed and XGBoost-predicted water demand over the entire study period

شکل ۹- مقایسه مقادیر واقعی و پیش‌بینی‌شده تقاضای آب توسط مدل XGBoost در کل دوره مطالعه

²¹- Regularization

بر روی مجموعه داده آزمون مورد ارزیابی قرار گرفت. این مدل با ترکیب شبکه عصبی بازگشتی دوطرفه (BiGRU) و سازوکار توجه (Attention)، قادر است علاوه بر استخراج وابستگی‌های زمانی کوتاه‌مدت و بلندمدت، میزان اهمیت هریک از گام‌های زمانی را نیز در فرآیند پیش‌بینی تعیین کند. شکل ۱۱ مقایسه مقادیر واقعی و مقادیر پیش‌بینی‌شده توسط مدل پیشنهادی را نشان می‌دهد.




Figure 11. Comparison of observed and BiGRU Attention-predicted water demand over the entire study period

شکل ۱۱- مقایسه مقادیر واقعی و پیش‌بینی‌شده تقاضای آب توسط مدل BiGRU Attention در کل دوره مطالعه

بررسی نتایج نشان می‌دهد که مدل پیشنهادی قادر است روند کلی، نوسانات فصلی و تغییرات کوتاه‌مدت تقاضای آب را با دقت مناسبی بازسازی کند. استفاده از ساختار دوطرفه BiGRU موجب شده است که وابستگی‌های زمانی موجود در داده‌ها از هر دو جهت زمانی استخراج شوند و در نتیجه، اطلاعات بیش‌تری نسبت به مدل‌های یک‌طرفه در اختیار شبکه قرار گیرد. این ویژگی به‌ویژه در سری‌های زمانی با الگوهای پیچیده، نقش مؤثری در بهبود کیفیت پیش‌بینی ایفا می‌کند.

از سوی دیگر، به‌کارگیری سازوکار Attention موجب شده است که مدل بتواند گام‌های زمانی دارای اطلاعات مؤثرتر را شناسایی کرده و وزن بیش‌تری به آن‌ها اختصاص دهد. این ویژگی سبب کاهش تأثیر اطلاعات کم‌اهمیت و افزایش تمرکز مدل بر الگوهای اصلی حاکم بر تغییرات تقاضای آب شده است. در نتیجه، مدل پیشنهادی توانایی




Figure 10. Comparison of observed and LSTM-predicted water demand over the entire study period

شکل ۱۰- مقایسه مقادیر واقعی و پیش‌بینی‌شده تقاضای آب توسط مدل LSTM در کل دوره مطالعه

نتایج حاصل نشان می‌دهد که مدل LSTM به‌دلیل برخورداری از ساختار حافظه بلندمدت، توانایی مناسبی در یادگیری وابستگی‌های زمانی موجود در سری زمانی تقاضای آب دارد. این مدل نسبت به مدل‌های آماری و الگوریتم‌های متداول یادگیری ماشین، تغییرات زمانی را با دقت بیش‌تری دنبال کرده و در بازسازی روندهای بلندمدت و الگوهای فصلی عملکرد مطلوبی از خود نشان می‌دهد.

بررسی شکل ۱۰ بیانگر آن است که مقادیر پیش‌بینی‌شده توسط مدل LSTM در اغلب دوره‌های زمانی تطابق قابل قبولی با داده‌های واقعی دارند. با این حال، در برخی بازه‌های زمانی که تغییرات ناگهانی در الگوی مصرف رخ داده است، اختلاف اندکی میان مقادیر واقعی و پیش‌بینی‌شده مشاهده می‌شود. این موضوع نشان می‌دهد که اگرچه LSTM قادر به استخراج وابستگی‌های زمانی بلندمدت است، اما در برخی شرایط ممکن است تمامی اطلاعات مؤثر موجود در توالی داده‌ها را به یک اندازه در فرآیند پیش‌بینی لحاظ نکند. نتایج کمی این مدل در جدول ۴ ارائه شده و امکان مقایسه آن با مدل پیشنهادی-BiGRU Attention را فراهم می‌سازد.

۴-۴-۶- ارزیابی عملکرد مدل پیشنهادی BiGRU-Attention

به‌منظور افزایش دقت پیش‌بینی تقاضای آب، مدل پیشنهادی BiGRU-Attention توسعه یافته و عملکرد آن

همچنین، شبکه عصبی LSTM به دلیل توانایی یادگیری وابستگی‌های زمانی بلندمدت، عملکرد مناسبی در پیش‌بینی تقاضای آب از خود نشان می‌دهد. با این وجود، بهره‌گیری از ساختار دوطرفه BiGRU همراه با سازوکار Attention در مدل پیشنهادی، امکان استفاده مؤثرتر از اطلاعات زمانی و تمرکز بر ویژگی‌های تأثیرگذار را فراهم می‌کند. این ویژگی‌ها موجب می‌شود مدل پیشنهادی از ظرفیت بیش‌تری برای مدل‌سازی رفتار پیچیده تقاضای آب برخوردار باشد.

بررسی نتایج این پژوهش نشان می‌دهد که انتخاب مدل مناسب برای پیش‌بینی تقاضای آب، علاوه بر نوع الگوریتم، به ویژگی‌های مجموعه داده، ساختار زمانی داده‌ها و میزان پیچیدگی روابط میان متغیرهای ورودی نیز وابسته است. از این رو، استفاده از مدل‌های مبتنی بر یادگیری عمیق می‌تواند گامی مؤثر در افزایش دقت پیش‌بینی و بهبود فرآیند تصمیم‌گیری در مدیریت منابع آب باشد.

۵- نتیجه‌گیری

پیش‌بینی دقیق تقاضای آب یکی از مهم‌ترین مؤلفه‌های مدیریت پایدار منابع آب و برنامه‌ریزی سامانه‌های تأمین و توزیع آب محسوب می‌شود. افزایش جمعیت، توسعه شهرنشینی، تغییرات اقلیمی و محدودیت منابع آب، ضرورت استفاده از روش‌های پیشرفته پیش‌بینی را بیش از پیش آشکار ساخته است. در این پژوهش، با هدف بهبود دقت پیش‌بینی تقاضای آب، عملکرد مدل‌های آماری، یادگیری ماشین و یادگیری عمیق مورد ارزیابی و مقایسه قرار گرفت.

در مرحله نخست، ویژگی‌های مجموعه داده از طریق تحلیل‌های آماری و بررسی روند زمانی مورد مطالعه قرار گرفت. نتایج نشان دادند که سری زمانی تقاضای آب دارای روند افزایشی، الگوهای فصلی و نوسانات زمانی است. هم‌چنین، تحلیل همبستگی بیانگر وجود روابط منطقی میان متغیرهای اقلیمی، هیدرولوژیکی و جمعیتی با تقاضای آب

بیش‌تری در مدل‌سازی روابط غیرخطی میان متغیرهای اقلیمی، هیدرولوژیکی و جمعیتی از خود نشان می‌دهد. شاخص‌های ارزیابی ارائه‌شده در جدول ۴، مبنای مقایسه عملکرد مدل پیشنهادی با سایر مدل‌های مورد مطالعه را فراهم می‌کنند. مقایسه این شاخص‌ها امکان ارزیابی میزان بهبود حاصل از به‌کارگیری معماری BiGRU-Attention را نسبت به مدل‌های آماری، الگوریتم‌های یادگیری ماشین و شبکه LSTM فراهم می‌سازد.

به‌طور کلی، نتایج حاصل از این بخش نشان می‌دهد که استفاده از معماری‌های مبتنی بر یادگیری عمیق و سازوکار توجه، ظرفیت قابل توجهی برای افزایش دقت پیش‌بینی تقاضای آب دارد و می‌تواند به‌عنوان ابزاری مؤثر در برنامه‌ریزی و مدیریت هوشمند منابع آب مورد استفاده قرار گیرد.

۴-۴-۷- مقایسه نهایی مدل‌ها و بحث نتایج

به‌منظور ارزیابی جامع عملکرد مدل‌های مورد بررسی، نتایج حاصل از اجرای مدل‌های ARIMA، SARIMA، RF، XGBoost، LSTM و BiGRU براساس معیارهای MAE ، $RMSE$ ، $MAPE$ و R^2 با یکدیگر مقایسه شدند. جدول ۴ خلاصه‌ای از عملکرد تمامی مدل‌ها را ارائه می‌کند و مبنایی برای تحلیل نقاط قوت و محدودیت‌های هر یک از آن‌ها فراهم می‌سازد.

مقایسه نتایج نشان می‌دهد که مدل‌های آماری کلاسیک، به‌ویژه ARIMA و SARIMA، در بازسازی روند کلی سری زمانی عملکرد قابل قبولی دارند، اما در مواجهه با روابط غیرخطی و تغییرات پیچیده تقاضای آب با محدودیت روبه‌رو هستند. در مقابل، مدل‌های یادگیری ماشین شامل RF و XGBoost با بهره‌گیری از قابلیت استخراج روابط غیرخطی، دقت پیش‌بینی بالاتری ارائه می‌کنند و در بسیاری از دوره‌های زمانی خطای کم‌تری نسبت به مدل‌های آماری دارند.

Informer, Transformer (TFT) و مدل‌های ترکیبی به‌منظور مقایسه با مدل پیشنهادی.

- ۴- استفاده از روش‌های بهینه‌سازی فراابتکاری برای تنظیم خودکار ابرپارامترهای مدل‌های یادگیری عمیق و افزایش دقت پیش‌بینی [۱۱].
- ۵- ارزیابی عملکرد مدل‌های پیشنهادی در سایر حوضه‌های آبریز و شهرهای دارای شرایط اقلیمی متفاوت، به‌منظور بررسی قابلیت تعمیم مدل.
- ۶- توسعه سامانه‌های پیش‌بینی برخط و تلفیق مدل‌های یادگیری عمیق با سامانه‌های پشتیبان تصمیم به‌منظور مدیریت هوشمند منابع آب [۱۲].

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت نموده و این موضوع مورد تأیید ایشان است.

مشارکت نویسندگان

ناصر جمالی محاسبات را انجام داد و روش‌های تحلیلی را بررسی کرد. ایشان بر یافته‌های این پژوهش نظارت داشت و نتایج را بحث نمود. فریدون فرهادی در نسخه نهایی مشارکت داشت.

تعارض منافع

بنا بر اظهار نویسندگان مقاله تعارض منافع ندارد.

حامی مالی

این پژوهش هیچ‌گونه کمک هزینه خاصی دریافت نکرده است.

سپاسگزاری

از داوران محترم به‌خاطر ارائه نظرهای ساختاری و علمی سپاسگزاری می‌شود.

بود که اهمیت استفاده از متغیرهای چندگانه در فرآیند پیش‌بینی را تأیید می‌کند.

در ادامه، مدل‌های RF, SARIMA, ARIMA, LSTM, XGBoost و مدل پیشنهادی BiGRU- Attention توسعه یافته و عملکرد آن‌ها براساس معیارهای MAE , $RMSE$, $MAPE$ و R^2 مورد ارزیابی قرار گرفت. مقایسه نتایج این مدل‌ها امکان بررسی نقاط قوت و محدودیت هریک از روش‌های مورد استفاده را فراهم ساخت و زمینه مناسبی برای انتخاب مدل کارآمدتر در پیش‌بینی تقاضای آب ایجاد کرد.

نتایج این پژوهش نشان داد که استفاده از روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق، ظرفیت بالایی برای مدل‌سازی روابط پیچیده میان متغیرهای مؤثر بر تقاضای آب دارد. هم‌چنین، به‌کارگیری معماری BiGRU همراه با سازوکار Attention، امکان استخراج مؤثرتر وابستگی‌های زمانی و تمرکز بر اطلاعات مهم‌تر را فراهم می‌کند و می‌تواند دقت پیش‌بینی را در مقایسه با روش‌های متداول افزایش دهد.

به‌طور کلی، یافته‌های این پژوهش نشان می‌دهد که استفاده از مدل‌های هوشمند می‌تواند ابزار مناسبی برای پشتیبانی از تصمیم‌گیری در مدیریت منابع آب، برنامه‌ریزی بهره‌برداری از مخازن، مدیریت مصرف و افزایش تاب‌آوری سامانه‌های تأمین آب در برابر تغییرات اقلیمی باشد. با توجه به نتایج این پژوهش، پیشنهادهای زیر برای مطالعات آینده ارائه می‌شود:

- ۱- استفاده از داده‌های با قدرت تفکیک زمانی بالاتر و دوره‌های زمانی طولانی‌تر به‌منظور افزایش دقت مدل‌های پیش‌بینی.
- ۲- بررسی تأثیر متغیرهای تکمیلی نظیر قیمت آب، شاخص‌های اقتصادی، الگوی مصرف مشترکان، شاخص‌های کاربری اراضی و داده‌های سنجش‌ازدور بر عملکرد مدل‌های پیش‌بینی.
- ۳- توسعه و ارزیابی سایر معماری‌های یادگیری عمیق نظیر Temporal Fusion, Transformer

References

- [1] Donkor EA, Mazzuchi TA, Soyer R, Roberson JA. (2014). Urban water demand forecasting: Review of methods and models. *Journal of Water Resources Planning and Management*. 2014; 140(2): 146-159. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0000314](https://doi.org/10.1061/(ASCE)WR.1943-5452.0000314).
- [2] Fang X, Liu J, Zhou M, Zhang H, Zhao J. Review of the mechanism and methodology of water demand forecasting in the socio-economic system. *Water*. 2024; 16(11): 1631. <https://doi.org/10.3390/w16111631>.
- [3] Ghannam S, Hussain F. Short-term water demand forecasting: A review. *Australian Journal of Water Resources*. 2024. <https://doi.org/10.1080/13241583.2024.2350102>.
- [4] Sebri M. Forecasting urban water demand: A meta-regression analysis. *Journal of Environmental Management*. 2016; 183: 777-785. <https://doi.org/10.1016/j.jenvman.2016.09.032>.
- [5] Ghalekhondabi I, Ardjmand E., Young WA, Weckman GR. Water demand forecasting: Review of soft computing methods. *Environmental Monitoring and Assessment*. 2017; 189(7): 313. <https://doi.org/10.1007/s10661-017-6030-3>.
- [6] Adamowski JF. Peak daily water demand forecast modeling using artificial neural networks. *Journal of Water Resources Planning and Management*. 2008; 134(2): 119-128. [https://doi.org/10.1061/\(ASCE\)0733-9496\(2008\)134:2\(119\)](https://doi.org/10.1061/(ASCE)0733-9496(2008)134:2(119)).
- [7] Herrera M, Torgo L, Izquierdo J, Pérez-García R. Predictive models for forecasting hourly urban water demand. *Journal of Hydrology*. 2010; 387(1–2): 141-150. <https://doi.org/10.1016/j.jhydrol.2010.04.005>.
- [8] Mu L, Zheng F, Tao R, Zhang Q, Kapelan Z. Hourly and daily urban water demand predictions using a long short-term memory-based model. *Journal of Water Resources Planning and Management*. 2020; 146(9): 04020066. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001276](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001276).
- [9] Qin Y, Song D, Cheng H, Cheng W, Jiang G, Cottrell GW. A dual-stage attention-based recurrent neural network for time series prediction. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence (IJCAI 2017)*, 2627–2633.
- [10] Lim B, Arik SÖ, Loeff N, Pfister T. Temporal Fusion Transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*. 2021; 37(4): 1748-1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>.
- [11] Ashofteh PS. Multi-objective optimization of cost and resilience in water distribution networks using MOGWO and EPANET. *Water Resources and Climate Change*. (2025); 1(4): 41-54. <https://doi.org/10.22091/wrcc.2025.14733.1028>.
- [12] AmelSadeghi M. Evaluating pressure-driven vs. demand-driven strategies in water network optimization. *Water Resources and Climate Change*. (2025); 1(4): 23-32. <https://doi.org/10.22091/wrcc.2025.14522.1024>.