



University of Tehran Press

Using a Deep Learning Approach in Nutritional Index Analysis (Case Study: Karkheh Dam)

Parisa Bozorgi¹ , Amirhossein Javid² , Sara Allahyaribeik³ , Seyedeh hoda Rahmati⁴

1. Department of Environmental Engineering, SR.C., Islamic Azad University, Tehran, Iran. Email: bozorgi_parisa@yahoo.com

2. Department of Environmental Engineering, SR.C., Islamic Azad University, Tehran, Iran. Email: ahjavid@iau.ac.ir

3. Department of Physics, SR.C., Islamic Azad University, Tehran, Iran. Email: s.allahyari@iau.ac.ir

4. Department of Environmental Engineering, SR.C., Islamic Azad University, Tehran, Iran. Email: rahmati@srbiau.ac.ir

Article Info	ABSTRACT
Article type: <i>Research Article</i> Article history: Received 13 July 2026 Revised 07 August 2026 Accepted 24 August 2026 Available online 23 September 2026 Keywords: <i>Eutrophication, Carlson index, dam reservoir, deep learning, LSTM method.</i>	Subject Nutrient orientation is one of the most important quality challenges in the exploitation of dam reservoirs, which can cause algae growth, reduced water clarity, decreased dissolved oxygen, and create restrictions on the use of water resources. Objective Simulation of the nutritive orientation index in the Karkheh Dam reservoir is a deep learning model including Recurrent Neural Network (RNN) and long short-term memory (LSTM) in combination with two meta-heuristic optimization algorithms horse herd optimization (HOA) and Fire Hawk Optimizer (FHO). Research method The Carlson index was calculated at 6 monitoring stations and 4 different depths, and then its simulation was performed on a monthly scale using 10 different scenarios of input variables. The data used were from a five-year period, four years of which were considered for training and one year for testing the models. Findings Zoning results showed that the value of the nutritive orientation index decreased with increasing depth, and in the summer, due to increasing water temperature, stability of thermal stratification, and increased residence time, the value of the index increased. Also, stations with a greater distance from the dam construction site and the outflow showed higher values of the index due to greater water retention and the possibility of nutrient accumulation. The simulation results indicated the superiority of the LSTM-FHO model in estimating the eutrophication index. This superiority can be attributed to the ability of LSTM to learn long-term time dependencies and the ability of FHO to optimize model parameters. The study of input scenarios also showed that the parameters of dissolved oxygen, water temperature, surface flow entering the reservoir and water level are the most important effective variables in simulating the Carlson index. Conclusion Combining deep learning models with optimization algorithms can be an efficient approach for monitoring, simulating, and managing eutrophication in dam reservoirs.

Cite this article: Bozorgi, P., Javid, A., Allahyaribeik, S., Rahmati, S. (2026). Using Deep Learning Approach in Nutritional Index Analysis (Case Study: Karkheh Dam). *Journal of Ecohydrology*, 13(3), 1515-1538
<https://doi.org/10.22059/ije.2026.416051.1917>

© Parisa Bozorgi, Amirhossein Javid, Sara Allahyaribeik, Seyedeh Hoda Rahmati.

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ije.2026.416051.1917>

Introduction

Nutrient stress is one of the qualitative challenges in the operation of dam reservoirs that can affect the efficiency of the reservoir in terms of water supply, environmental quality maintenance and operation planning. This phenomenon is usually caused by an increase in the concentration of nutrients in the aquatic environment and provides the basis for excessive growth of algae and phytoplankton. The consequences of nutritive stress include reduced water clarity, color, odor and taste changes, decreased dissolved oxygen, increased biological load, reduced biodiversity and restrictions on the use of water for various purposes. In dam reservoirs, due to the relative stagnation of water, increased residence time, the entry of surface runoff and temperature changes, the conditions for the formation and intensification of nutritive stress are more favorable than in flowing rivers. One of the common indicators for assessing the state of nutritive stress is the Carlson Index or TSI. This index is obtained using three main parameters including chlorophyll a, total phosphorus and depth of the Seki disk and allows the classification of the trophic state of water. Despite the widespread use of this index, continuous measurement of its required parameters at different stations and depths of the reservoir is associated with limitations such as high cost, time-consuming sampling, the need for laboratory equipment, and spatial and temporal uncertainty. For this reason, the development of methods that can simulate the trophic index with appropriate accuracy using simpler and measurable parameters is of great importance.

Method

In this study, the Karkheh Dam reservoir was selected as the study area. The location of this dam downstream of the catchment area has caused the reservoir water quality to be affected by inflows, surface runoff, sediments, upstream land use, temperature changes, and reservoir level fluctuations. Therefore, investigating the trophic status of this reservoir can be of great importance in the qualitative management and sustainable operation of the dam. The research process is carried out in 6 stages. After collecting and evaluating the required quantitative and qualitative data at the reservoir monitoring stations, the Carlson trophic index was calculated at 6 sampling stations and at 4 different depths. In the next stage, input data were prepared for deep learning models and these data included quantitative and qualitative parameters that can be measured in the dam reservoir and operating conditions. To investigate the role of different combinations of input variables, 10 input scenarios were defined. The data used were from a 5-year period, of which four years were considered for training the models and one year for testing the performance of the models. Two deep learning models including RNN and LSTM were used to simulate the Carlson index. In order to improve the performance of these models, two metaheuristic optimization algorithms including the Horse Herd Algorithm HOA and the Fire Falcon Algorithm FHO were integrated with the models. Therefore, four integrated models including RNN-HOA, LSTM-HOA, RNN-FHO and LSTM-FHO were evaluated. The performance of the models at each station and for different scenarios was evaluated using statistical indicators such as the coefficient of determination, root

mean square error, average absolute error percentage and Nash-Sutcliffe coefficient. Finally, the best model and the most suitable input scenario were selected for each station.

Results

The results of the trophic index zoning showed that the value of the Carlson index in the Karkheh Dam reservoir has significant spatial, temporal and depth variations. The study of depth changes showed that with increasing sampling depth, the value of the trophic index decreases. This trend can be attributed to the reduction in light penetration, reduced photosynthetic activity and limited algae growth in the deeper layers of the reservoir. In the surface layers, the index value was higher due to the greater reception of solar radiation, increased water temperature and the provision of suitable conditions for the growth of algal biomass. In terms of season, the results showed that the value of the trophic index increases in the warm period of the year. In the summer season, the increase in water temperature, the stability of thermal stratification, reduced vertical mixing and increased water retention time provide more suitable conditions for algae growth and intensification of trophicity. During this period, the difference in the value of the index between the surface and deep layers also increases, indicating that the trophic behavior in the warm season becomes more heterogeneous in terms of depth. In terms of location, the highest index value was observed in the summer season at station P5. This station showed higher values of the trophic index in most of the studied periods. The spatial analysis of this station indicates that greater distance from the dam construction site, reduced outflow effect, and higher water retention can cause nutrient accumulation, increased chlorophyll a, and reduced water transparency. In contrast, stations closer to the dam construction site and outflow usually showed lower values of the index, which could be due to greater water exchange and reduced retention time. The examination of the selected scenarios showed that at stations P1, P2, and P4, the S6 scenario including dissolved oxygen, water temperature, surface flow entering the reservoir, and water level had the best performance. At stations P3 and P5, the S9 scenario was selected by adding the TDS parameter to the combination of main variables. At station P6, the S8 scenario including dissolved oxygen, TDS, inflow, evaporation, and water level was identified as the appropriate scenario.

Conclusions

The results of this study showed that eutrophication in the Karkheh Dam reservoir is a completely dynamic, nonlinear phenomenon that depends on spatial and temporal conditions. The increase in the index value in the surface layers and the warm season indicates the important role of temperature, solar radiation, thermal stratification, and water residence time in intensifying eutrophication. Also, the difference in index values at different stations shows that the spatial location, distance from the dam construction site, outflow, nutrient accumulation, and hydraulic conditions of the reservoir play an important role in changes in the Carlson index. The superiority of the LSTM-FHO model showed that the use of deep learning models, especially models that have the ability to maintain long-term time dependencies, is suitable for simulating eutrophication

in dam reservoirs. The eutrophication index is affected by gradual trends and delayed effects of environmental variables; therefore, the LSTM structure, due to its long-term memory, has been able to identify these dependencies better than simpler structures. On the other hand, the FHO algorithm has reduced the simulation error and increased the stability of the model performance by optimizing the model parameters. In general, the results of this study showed that combining deep learning models with metaheuristic optimization algorithms is an efficient approach for simulating the Carlson trophic index in dam reservoirs. This approach can reduce the dependence on extensive sampling, and provide the possibility of identifying sensitive areas, determining critical periods, managing the exploitation level, and controlling the effects of inflows. Accordingly, the proposed model can be used as a complementary tool alongside field monitoring programs for intelligent trophic management in the Karkheh Dam reservoir and other similar reservoirs.

Funding

The authors did not receive support from any organization for the submitted work.

CRedit authorship contribution statement

Parisa Bozorgi: Conceptualization, Methodology, Investigation, Formal analysis, Writing – original draft.

Amirhossein Javid: Data curation, Validation, Visualization, Software, Writing – review & editing.

Sara Allahyaribeik: Methodology, Validation, Resources, Writing – review & editing.

Seyedeh hoda Rahmati: Supervision, Project administration, Conceptualization, Writing – review & editing.

Conflict of interest

All Authors declare that they have no conflict of interest.

Ethical considerations

Relevant research content in this study was in accordance with the ethical standards of the institutional and national research committees.

Data availability statement

Authors have no restrictions on sharing data.

Acknowledgements

No



استفاده از رویکرد یادگیری عمیق در تحلیل شاخص تغذیه گرای (مطالعه موری: سد کرخه)

پریسا بزرگی^۱، امیرحسین جاوید^۲، سارا الهیاری بیک^۳، سیده هدی رحمتی^۴

۱. گروه مهندسی محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: bozorgi_parisa@yahoo.com

۲. گروه مهندسی محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: ahjavid@iau.ac.ir

۳. گروه فیزیک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: s.allahyari@iau.ac.ir

۴. گروه مهندسی محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی تهران، ایران. رایانامه: rahmati@srbiau.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: پژوهشی موضوع تغذیه گرای یکی از چالش های مهم کیفی در بهره برداری از مخازن سدها است که می تواند موجب رشد جلبک ها، کاهش شفافیت آب، افت اکسیژن محلول و ایجاد محدودیت در استفاده از منابع آب شود. هدف شبیه سازی شاخص تغذیه گرای در مخزن سد کرخه، از مدل های یادگیری عمیق شامل RNN و LSTM در تلفیق با دو الگوریتم بهینه سازی فراابتکاری HOA و FHO است. روش تحقیق: شاخص کارلسون در ۶ ایستگاه پایش و ۴ عمق مختلف محاسبه شد و سپس شبیه سازی آن در مقیاس ماهانه با استفاده از ۱۰ سناریوی مختلف متغیرهای ورودی انجام شد. داده های مورد استفاده مربوط به یک دوره پنج ساله بود که چهار سال برای آموزش و یک سال برای آزمون مدل ها در نظر گرفته شد. یافته ها نتایج پهنه بندی نشان داد مقدار شاخص تغذیه گرای با افزایش عمق کاهش یافته و در فصل تابستان، به دلیل افزایش دمای آب، پایداری لایه بندی حرارتی و افزایش زمان ماند، مقدار شاخص افزایش می یابد. همچنین، ایستگاه هایی با فاصله بیشتر از ساختگاه سد و جریان خروجی، به دلیل ماندگاری بیشتر آب و احتمال تجمع مواد مغذی، مقادیر بالاتری از شاخص را نشان دادند. نتایج شبیه سازی بیانگر برتری مدل LSTM-FHO در برآورد شاخص تغذیه گرای بود. این برتری را می توان به توانایی LSTM در یادگیری وابستگی های زمانی بلندمدت و قابلیت FHO در بهینه سازی پارامترهای مدل نسبت داد. بررسی سناریوهای ورودی نیز نشان داد پارامترهای اکسیژن محلول، دمای آب، جریان سطحی ورودی به مخزن و تراز آب، مهم ترین متغیرهای مؤثر در شبیه سازی شاخص کارلسون هستند. نتیجه گیری تلفیق مدل های یادگیری عمیق با الگوریتم های بهینه سازی می تواند رویکردی کارآمد برای پایش، شبیه سازی و مدیریت تغذیه گرای در مخازن سدها باشد.	کلیدواژه ها: تغذیه گرای، شاخص کارلسون، مخزن سد، یادگیری عمیق، روش LSTM

استناد: بزرگی، پریسا؛ جاوید، امیرحسین؛ الهیاری بیک، سارا؛ رحمتی، هدی. (۱۴۰۵). استفاده از رویکرد یادگیری عمیق در تحلیل شاخص تغذیه گرای. *مجله اکوهیدرولوژی*.

<https://doi.org/10.22059/ije.2026.416051.1917> ۱۵۳۸-۱۵۱۵، ۱۳(۳)



© پریسا بزرگی، امیرحسین جاوید، سارا الهیاری بیک، سیده هدی رحمتی

ناشر: انتشارات دانشگاه تهران.

مقدمه

مخازن سدها از مهم‌ترین منابع ذخیره و تنظیم آب در حوضه‌های آبریز به شمار می‌رود که نقش اساسی در تأمین نیازهای شرب، کشاورزی، صنعت، کنترل سیلاب و مدیریت منابع آب دارد (Saadatpour et al., 2020). این موضوع سبب شده تا پایداری در بهره‌برداری از سدها تنها به حجم ذخیره و ظرفیت تنظیمی مخزن محدود نشده و اهمیت کیفیت آب ذخیره‌شده در این مخازن بسیار زیاد باشد. در بسیاری از مخازن، تغییرات اقلیمی، نوسانات جریان ورودی، افزایش دمای آب، ورود مواد مغذی از اراضی کشاورزی و سکون نسبی آب در مخزن می‌تواند شرایط مناسبی برای افت کیفیت آب و بروز پدیده تغذیه‌گرایی فراهم سازد (Chou et al., 2018). تغذیه‌گرایی یکی از چالش‌های مهم کیفی در مخازن سدها است که معمولاً بر اثر افزایش غلظت مواد مغذی، به‌ویژه فسفر و نیتروژن، ایجاد می‌شود. این پدیده می‌تواند موجب رشد بیش از حد جلبک‌ها، افزایش کلروفیل، کاهش شفافیت آب، تغییر رنگ، بو و طعم آب و در نهایت کاهش اکسیژن محلول در لایه‌های مختلف مخزن شود. پیامدهای تغذیه‌گرایی تنها به تغییرات ظاهری آب محدود نیست، بلکه می‌تواند بر کارایی سامانه‌های تصفیه، سلامت اکوسیستم آبی، کیفیت آب شرب، زیستگاه آبزیان و برنامه‌ریزی بهره‌برداری از مخزن نیز اثرگذار باشد. از این‌رو، پایش و پیش‌بینی وضعیت تغذیه‌گرایی در مخازن سدها از اهمیت ویژه‌ای در مدیریت کیفی منابع آب برخوردار است. رفتار تغذیه‌گرایی در مخازن سدها معمولاً دارای ماهیت پیچیده، غیرخطی و وابسته به زمان است (Kuczyńska et al., 2025). تغییرات دمایی، لایه‌بندی حرارتی، نوسانات تراز آب، میزان جریان ورودی، بار آلودگی حوضه بالادست، وضعیت اکسیژن محلول و تغییرات فصلی از جمله عواملی است که به صورت هم‌زمان بر شدت و گسترش این پدیده اثر می‌گذارد (Liu et al., 2025). در این شرایط، ارزیابی وضعیت تغذیه‌گرایی تنها با اتکا به مشاهدات محدود میدانی نمی‌تواند تصویر کاملی از وضعیت مخزن ارائه دهد. از سوی دیگر، نمونه‌برداری مستقیم از اعماق و ایستگاه‌های مختلف مخزن، علاوه بر نیاز به تجهیزات تخصصی، مستلزم صرف هزینه، زمان و نیروی انسانی قابل توجه است و همواره با عدم قطعیت‌های مکانی و زمانی همراه است.

یکی از شاخص‌های رایج برای ارزیابی وضعیت تغذیه‌گرایی در منابع آب، استفاده از شاخص تغذیه‌گرایی کارلسون است (Klippel et al., 2020). این شاخص معمولاً بر اساس پارامترهایی مانند کلروفیل *a*، فسفر کل و عمق دیسک سکی محاسبه می‌شود و امکان طبقه‌بندی وضعیت مخزن را از نظر الیگوتروف، مزوتروف، یوتروف و شرایط تغذیه‌گرایی شدید فراهم می‌سازد (Lyu et al., 2022). در سال‌های اخیر، استفاده از داده‌های چندمنبعی و روش‌های هوشمند برای پایش تغذیه‌گرایی مخازن مورد توجه قرار گرفته است. Shi و همکاران (۲۰۲۵) با تلفیق تصاویر ماهواره‌ای لندست، پارامترهای محیطی و شبکه عصبی پس‌انتشار، شاخص وضعیت تغذیه‌ای را در یکی از خلیج‌های فرعی مخزن سه‌دره شبیه‌سازی کردند. نتایج پژوهش یادشده نشان داد افزودن متغیرهایی مانند دمای آب و تابش خورشیدی به داده‌های طیفی می‌تواند دقت برآورد TSI را افزایش دهد و ناهمگنی زمانی و مکانی تغذیه‌گرایی را آشکار کند (Y. Shi et al., 2025). همچنین، Szewczyk و همکاران (۲۰۲۵) با بررسی بلندمدت سه مخزن آب شرب نشان دادند وضعیت تغذیه‌ای مخازن تحت تأثیر هم‌زمان پارامترهای نیتروژنی، مواد آلی و فشارهای ناشی از رواناب و فاضلاب حوضه آبریز قرار دارد. نتایج این مطالعه بر ضرورت پایش هم‌زمان متغیرهای فیزیکی، شیمیایی و هیدرولوژیکی و استفاده از رویکردهای تحلیلی برای شناسایی تغییرات تغذیه‌گرایی تأکید دارد (Szewczyk et al., 2025). با این حال، اندازه‌گیری مستمر پارامترهای مورد نیاز برای محاسبه این شاخص در تمامی ایستگاه‌ها و اعماق مخزن، در بسیاری از طرح‌های پایش کیفی با محدودیت عملیاتی مواجه است. بنابراین، توسعه روش‌هایی که بتوانند با استفاده از پارامترهای قابل دسترس‌تر، وضعیت تغذیه‌گرایی را با دقت مناسب شبیه‌سازی کنند، می‌تواند نقش مؤثری در بهبود مدیریت کیفی مخازن سدها داشته باشد (Galelli et al., 2015; Lin et al., 2022; Meng et al., 2023). در سال‌های اخیر، روش‌های هوش مصنوعی و یادگیری عمیق به عنوان ابزارهای توانمند برای تحلیل پدیده‌های پیچیده در حوزه منابع آب مورد توجه قرار گرفته‌اند. این روش‌ها به دلیل توانایی در شناسایی روابط غیرخطی، استخراج الگو از داده‌های تاریخی و مدل‌سازی وابستگی‌های زمانی، قابلیت مناسبی برای شبیه‌سازی شاخص‌های کیفی آب دارد (Akbari Osmavandani et al., 2024). مدل‌هایی مانند شبکه عصبی مصنوعی، شبکه عصبی بازگشتی و شبکه حافظه بلندمدت کوتاه‌مدت

می‌توانند با استفاده از داده‌های کمی و کیفی مخزن، رابطه میان متغیرهای اثرگذار و شاخص تغذیه‌گرایی را شناسایی کنند و امکان برآورد وضعیت کیفی مخزن را در دوره‌های مختلف بهره‌برداری فراهم سازند.

اهمیت استفاده از رویکرد هوش مصنوعی با توجه به اهمیت فرایند تغذیه‌گرایی و مشکلات در نمونه‌برداری و هزینه‌ها می‌تواند جایگزینی برای پایش و پهنه‌بندی شاخص در سطح مخزن سد باشد. هدف اصلی این پژوهش، بررسی قابلیت روش‌های هوش مصنوعی در شبیه‌سازی تغذیه‌گرایی در داخل مخزن سد است. در این مطالعه تلاش می‌شود با استفاده از داده‌های کیفی و کمی برداشت‌شده از ایستگاه‌های مختلف مخزن، شاخص تغذیه‌گرایی شبیه‌سازی شود و نقش پارامترهای اثرگذار بر تغییرات آن مورد ارزیابی قرار گیرد. نتایج این پژوهش می‌تواند زمینه مناسبی برای توسعه سامانه‌های هوشمند پایش کیفی آب در مخازن سدها فراهم سازد. همچنین، خروجی‌های مطالعه می‌تواند در تعیین نواحی حساس به تغذیه‌گرایی، شناسایی دوره‌های بحرانی، مدیریت تراز بهره‌برداری، کنترل اثرات جریان‌های ورودی و تدوین سیاست‌های پیشگیرانه در مدیریت کیفیت آب مخزن مورد استفاده قرار گیرد. از این منظر، به‌کارگیری روش‌های هوش مصنوعی در شبیه‌سازی تغذیه‌گرایی می‌تواند به عنوان رویکردی کارآمد، سریع و کم‌هزینه در کنار روش‌های متداول پایش کیفی آب مورد توجه قرار گیرد.

مواد و روش‌ها

روش پژوهش

با توجه به هدف اصلی این پژوهش، از روش‌های هوش مصنوعی و پارامترهای کمی و کیفی قابل سنجش در مخزن سد استفاده شده تا ارزیابی شاخص تغذیه‌گرایی انجام و سپس قابلیت مدل‌های یادگیری عمیق در شبیه‌سازی آن مورد ارزیابی قرار گیرد.

در گام نخست، منطقه مورد مطالعه و ویژگی‌های کمی و کیفی مخزن سد بررسی می‌شود. در این مرحله، اطلاعات مربوط به جریان ورودی به مخزن، تراز آب، دمای آب، اکسیژن محلول و سایر پارامترهای مؤثر بر وضعیت کیفی مخزن جمع‌آوری و سازمان‌دهی می‌شود. همچنین، موقعیت ایستگاه‌های نمونه‌برداری در داخل مخزن مشخص شده و تغییرات زمانی و مکانی داده‌ها مورد بررسی اولیه قرار می‌گیرد.


در گام دوم، شاخص تغذیه‌گرایی مخزن سد بر اساس شاخص کارلسون محاسبه می‌شود. این شاخص با استفاده از پارامترهایی نظیر کلروفیل a، فسفر کل و عمق دیسک سکی تعیین می‌شود. با توجه به داده‌های نمونه‌برداری شده در ایستگاه‌های مختلف، وضعیت تغذیه‌گرایی در مخزن سد تحلیل شده و تغییرات آن در بخش‌های مختلف مخزن مورد بررسی قرار می‌گیرد.

در گام سوم، داده‌های مورد استفاده برای ورود به مدل‌های یادگیری عمیق آماده‌سازی می‌شود. در این بخش، داده‌های خام از نظر آماری بررسی و پیش‌پردازش شده و سپس متغیرهای ورودی مدل بر اساس پارامترهای قابل اندازه‌گیری و مؤثر بر تغذیه‌گرایی انتخاب می‌شود. در این پژوهش، پارامترهایی مانند دمای آب، اکسیژن محلول، جریان سطحی ورودی به مخزن و تراز آب به عنوان متغیرهای کلیدی در فرایند شبیه‌سازی مورد توجه قرار می‌گیرند.

در گام چهارم، مدل‌های هوش مصنوعی برای شبیه‌سازی شاخص تغذیه‌گرایی شبیه‌سازی می‌شود. در این مرحله، از ۲ مدل یادگیری عمیق، شبکه عصبی بازگشتی RNN و شبکه حافظه بلندمدت کوتاه‌مدت LSTM استفاده می‌شود. همچنین، به منظور افزایش دقت مدل‌ها و بهینه‌سازی پارامترهای ساختاری، الگوریتم‌های فراابتکاری نظیر الگوریتم شاهین آتشین FHO و الگوریتم گله اسب HOA با مدل‌های یادگیری عمیق تلفیق می‌شود. به این ترتیب، ساختارهای مختلف مدل‌سازی برای ارزیابی توانایی هر روش در شبیه‌سازی تغذیه‌گرایی مخزن مورد مقایسه قرار می‌گیرد.

در گام پنجم، عملکرد مدل‌ها با استفاده از شاخص‌های آماری ارزیابی می‌شود. در این مرحله، نتایج شبیه‌سازی شده با مقادیر مشاهده‌ای شاخص تغذیه‌گرایی مقایسه شده و دقت مدل‌ها بر اساس معیارهایی مانند ضریب تعیین، خطای میانگین مربعات، جذر میانگین مربعات خطا و میانگین قدر مطلق خطا بررسی می‌شود.

در نهایت، بر اساس نتایج حاصل از مدل سازی، مهم ترین پارامترهای مؤثر بر تغییرات شاخص تغذیه گرای شناسایی می شود و قابلیت استفاده از مدل های هوش مصنوعی در پایش و پیش بینی وضعیت تغذیه گرای مخزن سد مورد تحلیل قرار می گیرد.



شکل ۱. روش تحقیق


۲- منطقه مورد مطالعه

سد کرخه یکی از سدهای بزرگ خاکی ایران و خاورمیانه است که در بخش انتهایی حوضه آبریز درجه ۲ کرخه احداث شده است. این سد با طول تاج حدود ۳۰۳۰ متر، ارتفاع ۱۲۷ متر از کف مخزن و حجم مخزن حدود ۷/۳ میلیارد مترمکعب، از مهم ترین سازه های آبی کشور در مدیریت منابع آب سطحی به شمار می رود. سد کرخه با اهداف اصلی تأمین آب کشاورزی، تنظیم جریان های سطحی، کنترل سیلاب و تولید انرژی برقابی احداث می شود و سالانه به طور متوسط حدود ۹۳۰ میلیون کیلووات ساعت انرژی برقابی تولید می کند. رودخانه کرخه به عنوان زهکش اصلی این حوضه، از به هم پیوستن رودخانه های مهمی از جمله کشکان و سیمره تشکیل شده و پس از عبور از بخش های مختلف حوضه، وارد محدوده مخزن سد کرخه می شود. موقعیت این سد در پایین دست حوضه سبب شده است که کیفیت آب مخزن تحت تأثیر شرایط هیدرولوژیکی، اقلیمی، کاربری اراضی، رواناب های سطحی و ورود مواد مغذی از نواحی بالادست قرار گیرد. از این رو، مخزن سد کرخه از نظر تغییرات کمی و کیفی آب، به ویژه در ارتباط با پدیده تغذیه گرای، دارای اهمیت مطالعاتی بالایی است. با توجه به نقش سد کرخه در تأمین آب پایین دست، به خصوص در بخش کشاورزی، بررسی وضعیت کیفی آب مخزن و شبیه سازی تغییرات تغذیه گرای می تواند در مدیریت بهره برداری، تعیین دوره های بحرانی، کنترل آثار جریان های ورودی و حفظ کیفیت آب ذخیره شده نقش مؤثری داشته باشد. بنابراین، این سد به عنوان منطقه مورد مطالعه برای ارزیابی و شبیه سازی تغذیه گرای در داخل مخزن انتخاب شده است.

به منظور پایش کیفی و تعیین شاخص کیفی در مخزن سد کرخه ۶ ایستگاه نمونه برداری مورد سنجش قرار گرفت. این ایستگاه ها به گونه ای انتخاب شد که در مخزن سد در حداقل تراز آب سد نیز قابلیت سنجش و اندازه گیری پارامترهای کیفی را داشته باشد. به منظور سنجش در هر ایستگاه در ۴ عمق نمونه برداری کیفی انجام گرفت. نمونه برداری به صورت ماهانه در یک دوره ۵ ساله مبتنی بر پارامترهای کیفی دما، کل جامدات محلول (TDS)، اکسیژن محلول (DO)، اسیدیته (pH)، هدایت الکتریکی (EC)، نیتروژن کل (TN)، فسفر کل (TP)، عمق سکی (SD) و کلروفیل a انجام گرفت. در جدول ۱ مشخصات آماری داده های اندازه گیری شده ارائه شده است. در شکل ۲ موقعیت سد کرخه و شبکه پایش میدانی ارائه شده است.

جدول ۱. تحلیل مؤلفه‌های نمونه‌برداری شده در ۴ عمق در ۶ ایستگاه نمونه‌برداری

نام ایستگاه	پارامتر آماری	تعداد نمونه	T	TDS	DO	pH	EC	TN	TP	SD	a – CHL
			C	Mg/l	Mg/l		µs/cm	mg/l	µg/l	(m)	µg/l
			دما	کل جامدات محلول	اکسیژن محلول	اسیدیته	هدایت الکتریکی	نیتروژن کل	فسفر کل	عمق سکی	کلروفیل a
ایستگاه ۱	میانگین	۶۰	25.0	958.7	8.0	7.9	1503.3	2.1	5.4	6.5	1.3
	حداقل		14.73	452	2.71	7.08	890	1.1	1	2.6	0.2
	حداکثر		32.5	1485	13.9	8.73	2320	3.65	25	11.3	9
ایستگاه ۲	میانگین	۶۰	24.8	1050	8.2	8	1648.5	2.4	6.1	6.4	1.5
	حداقل		14.2	470	2.8	7.1	902.4	1.3	1	2.4	0.4
	حداکثر		31.7	1505	13.6	8.6	2392.95	3.7	22	10.8	8.4
ایستگاه ۳	میانگین	۶۰	24.7	1046	8.1	7.9	1642.22	2.7	5.8	6.7	1.7
	حداقل		14.4	425	3.1	7.2	816	1.3	1	2.6	0.2
	حداکثر		32.2	1490	13.4	8.6	2369.1	3.9	21	10.9	8.7
ایستگاه ۴	میانگین	۶۰	24.3	978	8.3	7.8	1535.46	2.1	5.7	6.7	1.4
	حداقل		14	510	3	7.15	979.2	1.4	1	2.7	0.2
	حداکثر		31.9	1525	13.9	8.7	2424.75	3.7	28	11.1	8.9
ایستگاه ۵	میانگین	۶۰	24.9	990	7.8	8.1	1554.3	2.8	5.8	6.5	1.5
	حداقل		14.8	485	2.7	7.1	931.2	1.2	1	2.8	0.3
	حداکثر		31.6	1510	13.6	8.5	2400.9	3.6	24	11.5	9.1
ایستگاه ۶	میانگین	۶۰	24.7	1021	8	8.05	1602.97	2.4	5.8	6.4	1.6
	حداقل		14.9	490	2.8	7.05	940.8	1	1	2.5	0.15
	حداکثر		32.7	1520	13.7	8.6	2416.8	3.7	19	11.2	9



شکل ۲. موقعیت ایستگاه‌های نمونه‌برداری در داخل مخزن سد کرخه

۳- شاخص تغذیه‌گرایی

استفاده از شاخص‌های کیفی با توجه به در نظر گرفتن چند پارامتر کیفی به صورت توأمان و در نظر گرفتن شرایط تغییر در کیفیت آب قابلیت مناسبی را برای تحلیل کیفی و نقش آلاینده‌ها در منابع آب دارد (Afshar et al., 2012). از طرفی نیز شاخص‌های کیفی با انعطاف‌پذیری در معرفی پارامترهای ورودی، قابلیت مناسبی را برای تحلیل برای تنوع منابع آب در شرایط مختلف دارد. در این مطالعه با توجه به بررسی و ارزیابی کیفی مخزن سد کرخه از نظر کیفی و سطح تغذیه‌گرایی از شاخص کارلسون برای پهنه‌بندی تغذیه‌گرایی استفاده می‌شود.

تغذیه‌گرایی فرایندی است که در یک پهنه آبی غلظت مواد مغذی به‌خصوص فسفر و نیتروژن غنی شده و به رشد بیش از حد جلبک‌ها و سایر گیاهان ساده منجر می‌شود (Galelli et al., 2015). منشأ افزایش مواد مغذی غالباً رواناب‌های یا جریان‌های زهکشی‌شده حاوی کود در اراضی کشاورزی و فاضلاب‌ها است. در فرایند تغذیه‌گرایی سطح اکسیژن آب کاهش یافته و فرایند شامل شکوفایی جلبکی مضر، کاهش اکسیژن محلول، کاهش کیفیت آبی و در نهایت، کاهش تنوع زیستی است. مفهوم تغذیه‌گرایی در مخازن سد زمانی اتفاق می‌افتد که میزان غلظت آلودگی در محیط آبی قابلیت مصرف را نداشته باشد. تغذیه‌گرایی مخزن سد بیانگر وضعیت تروفیکی آب برای مصارف مختلف است که در ۵ کلاس مطابق جدول ۲ تقسیم‌بندی کیفی مخزن را تحلیل می‌کند. هرچه سطح تروفیکی افت کند، وضعیت آب از نظر کیفی نامناسب‌تر خواهد بود. مطابق جدول ۲، بهترین آب از نظر مصارف اولترالیگوف بوده و بدترین آب از نظر کیفی در مخزن سد هایپروتروف است.

جدول ۲. طبقه‌بندی سطح تروفیکی مخازن سد براساس پارامترهای مختلف

سطح تروفیکی	میانگین فسفر کل (mg/l)	میانگین سالانه کلروفیل A (mg/m ³)	حداکثر کلروفیل ((mg/m ³))	میانگین سالانه شفافیت (متر)	حداقل شفافیت (متر)	حداقل درصد اشباع اکسیژن در لایه زیرین آب
اولترا الیگوف	UO	۰/۰۰۴	۱	۲/۵	۱۲	۹۰-۱۰۰
الیگوتروف	O	۰/۱ ≥	۲/۵ ≥	۸	≥۶	۸۰-۹۰
مزوتروف	M	۰/۰-۰/۰۳۵	۲-۸/۵	۲۵-۸	۶-۳	۴۰-۸۰
یوتروف	EU	۰/۰-۰/۳۵/۱	۲۵-۸	۷۵-۲۵	۱/۳-۵	۱۰-۴۰
هایپریوتروف	HEu	≥۰/۱	≥۲۵	≥۷۵	۱/۵ ≥	<۱۰

یکی از شاخص‌هایی که در تحلیل تغذیه‌گرایی مورد استفاده قرار می‌گیرد شاخص کارلسون است. این شاخص بیانگر وضعیت کیفی آب از سه فاکتور کلروفیل A، دیسک سکی و فسفر کل مطابق روابط زیر تعریف می‌شود.

$$TSI_{chl}=9.81 \ln (chl) + 30.6$$

$$TSI_{SD}= 60- 14.4 \ln (SD) \quad (۱)$$

$$TSI_{TP}=14.42 \ln TP+ 4.15$$

در نهایت با میانگین سه شاخص TSI_{chl} ، TSI_{SD} و TSI_{TP} مقدار شاخص نهایی محاسبه می‌شود. با توجه به مقادیر محاسباتی وضعیت کیفی آب در سامانه آبی در یکی از ۴ کلاس مطابق جدول ۳ تعریف می‌شود.

جدول ۳. تقسیم‌بندی شاخص کارلسون برای تحلیل تغذیه‌گرایی در مخزن سد

کلاس شاخص تغذیه‌گرایی	مقدار شاخص TSI
الیگوتروفیک	$TSI < 40$
مزوتروفیک	$40 < TSI < 50$
یوتروفیک	$50 < TSI < 70$
هایپریوتروفیک	$70 < TSI < 100$

بر این اساس، مقادیر پایین‌تر شاخص نشان‌دهنده شرایط مطلوب‌تر از نظر تغذیه‌گرایی، غلظت کمتر مواد مغذی و شفافیت بیشتر آب است. در مقابل، افزایش مقدار شاخص بیانگر تشدید وضعیت تغذیه‌گرایی، رشد بیشتر جلبک‌ها، کاهش شفافیت و افت کیفیت آب در مخزن سد خواهد بود. بنابراین، محاسبه و تحلیل شاخص کارلسون می‌تواند مبنای مناسبی برای شناسایی نواحی حساس، بررسی تغییرات زمانی و مکانی تغذیه‌گرایی و پشتیبانی از تصمیم‌گیری در مدیریت کیفی مخزن سد کرخه فراهم سازد.

۴- مدل‌های یادگیری عمیق

با توجه به هدف این پژوهش و ضرورت شبیه‌سازی سطح تغذیه‌گرایی در مخزن سد، از رویکردهای یادگیری عمیق به منظور برآورد پیش‌بینی شاخص تغذیه‌گرایی کارلسون استفاده می‌شود. ماهیت زمانی داده‌های کیفی و کمی مخزن سد، از جمله تغییرات دما، اکسیژن محلول، جریان ورودی و تراز آب، سبب می‌شود که مدل‌های مبتنی بر تحلیل سری زمانی قابلیت مناسبی برای شناسایی الگوهای پنهان و روابط غیرخطی میان متغیرها داشته باشند. در این پژوهش از دو مدل شبکه عصبی بازگشتی RNN و شبکه حافظه بلندمدت LSTM برای شبیه‌سازی شاخص تغذیه‌گرایی استفاده می‌شود. به منظور افزایش کارایی این دو روش و برای

دقت شبیه‌سازی از بهینه‌سازی پارامترهای دو مدل، از دو الگوریتم فراابتکاری الگوریتم گله اسب HOA و الگوریتم شاهین آتشین FHO به صورت تلفیقی با مدل‌های یادگیری عمیق استفاده می‌شود. هدف از این ترکیب، بهبود فرایند آموزش، کاهش خطای شبیه‌سازی و دستیابی به ساختار بهینه برای پیش‌بینی شاخص تغذیه‌گرایی در مخزن سد است.

۴-۱- مدل‌های شبیه‌سازی

با توجه به ماهیت زمانی و غیرخطی پدیده تغذیه‌گرایی، از دو مدل شبیه‌سازی RNN و LSTM استفاده می‌شود. شبکه‌های عصبی بازگشتی نوعی از شبکه‌های عصبی هستند که برای پردازش داده‌های ترتیبی و سری زمانی طراحی شده‌اند (Fu et al., 2022). به خلاف شبکه‌های عصبی پیشخور که در آن‌ها ارتباط میان لایه‌ها تنها در یک جهت برقرار است، در شبکه‌های بازگشتی، خروجی یا حالت پنهان گام زمانی قبل می‌تواند در محاسبه خروجی گام زمانی بعد نقش داشته باشد. این ویژگی باعث می‌شود مدل بتواند وابستگی‌های زمانی موجود در داده‌ها را تا حدی حفظ کرده و در پیش‌بینی مقادیر آینده از اطلاعات گذشته استفاده کند (Wu et al., 2024).

در ساختار مدل RNN، داده‌های ورودی به صورت یک سری زمانی وارد شبکه می‌شود و در هر گام زمانی، مدل در حالت شبیه‌سازی علاوه بر ورودی جدید، از اطلاعات ذخیره‌شده در حالت پنهان قبلی استفاده می‌کند (Shen, 2018). این ساختار برای تحلیل پدیده‌هایی که تغییرات آن‌ها تابعی از وضعیت‌های پیشین است، مناسب است. از آنجا که شاخص تغذیه‌گرایی در مخزن سد تحت تأثیر تغییرات پیوسته دما، اکسیژن محلول، جریان ورودی، تراز آب و شرایط فصلی قرار دارد، استفاده از مدل RNN می‌تواند در شناسایی رفتار زمانی این شاخص مؤثر باشد.

با وجود قابلیت‌های RNN، این مدل در یادگیری وابستگی‌های بلندمدت با محدودیت‌هایی مواجه است. در سری‌های زمانی طولانی، ممکن است اطلاعات مربوط به گام‌های زمانی دورتر در فرایند آموزش به تدریج تضعیف شود. برای رفع این محدودیت، مدل LSTM توسط Hochreiter و Schmidhuber در سال ۱۹۹۷ معرفی شد. مدل LSTM نوع پیشرفته‌ای از شبکه‌های عصبی بازگشتی است که با استفاده از ساختار حافظه و دروازه‌های کنترلی، امکان نگهداری، حذف یا انتقال اطلاعات طی زمان را فراهم می‌کند. این ویژگی سبب می‌شود مدل LSTM در شبیه‌سازی پدیده‌هایی که دارای وابستگی‌های زمانی بلندمدت هستند، عملکرد مناسبی داشته باشد. ساختار LSTM شامل سه بخش اصلی شامل دروازه فراموشی، دروازه ورودی و دروازه خروجی است. دروازه فراموشی مشخص می‌کند چه بخشی از اطلاعات گذشته از حافظه حذف شود، دروازه ورودی تعیین می‌کند چه اطلاعات جدیدی وارد حافظه شود و دروازه خروجی مشخص می‌کند چه بخشی از اطلاعات ذخیره‌شده برای تولید خروجی مورد استفاده قرار گیرد. این سازوکار باعث می‌شود LSTM بتواند بین اطلاعات مهم و غیرمهم طی زمان تمایز قائل شود و وابستگی‌های زمانی مؤثر بر شاخص تغذیه‌گرایی را بهتر شناسایی کند.

در این پژوهش برای شبیه‌سازی شاخص تغذیه‌گرایی کارلسون از ورودی پارامترهای کمی و کیفی قابل اندازه‌گیری در مخزن سد و خروجی مدل مقدار شاخص تغذیه‌گرایی استفاده می‌شود. مقایسه عملکرد این دو مدل می‌تواند نشان دهد کدام ساختار یادگیری عمیق توانایی بیشتری در بازتولید تغییرات زمانی و مکانی تغذیه‌گرایی در مخزن سد دارد.

۴-۲- الگوریتم‌های بهینه‌سازی

به منظور افزایش دقت مدل‌های یادگیری عمیق و بهینه‌سازی پارامترهای مؤثر در فرایند آموزش، از دو الگوریتم فراابتکاری بهینه‌سازی گله اسب و بهینه‌سازی شاهین آتشین استفاده می‌شود. به کارگیری این الگوریتم‌ها باعث می‌شود فرایند جست‌وجو برای یافتن ساختار مناسب مدل، کاهش خطا و بهبود عملکرد شبیه‌سازی شاخص تغذیه‌گرایی با دقت بیشتری انجام گیرد.

الگوریتم بهینه‌سازی گله اسب یکی از الگوریتم‌های فراابتکاری الهام گرفته از طبیعت است که بر اساس رفتار اجتماعی، حرکتی و گروهی اسب‌ها در گله طراحی شده است (MiarNaeimi et al., 2021). این الگوریتم برای حل مسائل پیچیده، غیرخطی و با ابعاد

بالا مورد استفاده قرار می‌گیرد و با شبیه‌سازی رفتارهایی مانند چرا، سلسله‌مراتب، جامعه‌پذیری، تقلید، حرکت گروهی و جست‌وجوی محیط، فضای جواب را برای دستیابی به بهترین راه‌حل بررسی می‌کند. در این الگوریتم، هر اسب نماینده یک جواب ممکن در فضای جست‌وجو است و موقعیت آن طی تکرارهای مختلف بر اساس کیفیت جواب، تعامل با سایر اعضای گله و حرکت به سمت موقعیت‌های بهتر به‌روزرسانی می‌شود. ویژگی‌هایی مانند ساختار جمعیتی، تبادل اطلاعات میان اعضا و قابلیت جست‌وجوی هم‌زمان در نواحی مختلف فضای جواب، سبب شده است این الگوریتم در بهینه‌سازی مسائل پیچیده عملکرد مناسبی داشته باشد. روابط ریاضی مربوط به حرکت، سرعت، رفتار اجتماعی و به‌روزرسانی موقعیت اسب‌ها در الگوریتم HOA مطابق روابط ارائه‌شده در منبع اصلی الگوریتم قابل تعریف است.

الگوریتم بهینه‌سازی شاهین آتشین براساس رفتار شکار گروهی برخی پرندگان شکاری در زمان گسترش آتش طراحی شده است. در این الگوریتم، رفتار شاهین‌های آتشین در انتقال شعله یا چوب‌های نیم‌سوخته به نواحی جدید و هدایت طعمه‌ها به سمت مناطق قابل شکار، به صورت یک فرایند جست‌وجو و بهینه‌سازی مدل‌سازی می‌شود (Shishehgarkhaneh et al., 2022). در ساختار الگوریتم، شاهین‌ها نقش عامل‌های جست‌وجوگر را دارند و طعمه‌ها نشان‌دهنده پاسخ‌های ممکن در فضای جست‌وجو هستند. طی فرایند تکرار، موقعیت شاهین‌ها و طعمه‌ها بر اساس بهترین جواب، نواحی امن، فاصله بین عامل‌ها و رفتار جست‌وجوی تصادفی به‌روزرسانی می‌شود تا الگوریتم بتواند به جواب بهینه یا نزدیک به بهینه دست یابد. الگوریتم FHO به دلیل توانایی در جست‌وجوی سراسری و محلی، برای مسائل غیرخطی، پیچیده و غیرمحدب قابل استفاده است. روابط ریاضی مربوط به مقداردهی اولیه، به‌روزرسانی موقعیت شاهین‌ها، حرکت طعمه‌ها و شرط توقف الگوریتم مطابق روابط ارائه‌شده در منبع اصلی الگوریتم استفاده می‌شود.

۴-۳- ساختار مدل‌سازی

در این پژوهش، مدل‌های RNN و LSTM برای شبیه‌سازی شاخص تغذیه‌گرایی کارلسون توسعه داده شد. ساختار هر مدل شامل دو لایه بازگشتی با ۶۴ و ۳۲ نرون و یک لایه تمام‌متصل با ۱۶ نرون بود. در لایه‌های بازگشتی از تابع فعال‌سازی tanh، در دروازه‌های مدل LSTM از تابع sigmoid، در لایه تمام‌متصل از ReLU و در لایه خروجی از تابع خطی استفاده شد. لایه خروجی دارای یک نرون بود، زیرا شاخص تغذیه‌گرایی یک متغیر پیوسته است. برای آموزش شبکه‌ها از بهینه‌ساز Adam با نرخ یادگیری اولیه ۰/۰۰۱ و تابع هزینه MSE استفاده شد. اندازه دسته برابر ۳۲ و حداکثر تعداد دوره‌های آموزش ۵۰۰ در نظر گرفته شد. داده‌ها با حفظ ترتیب زمانی به نسبت ۷۰، ۱۵ و ۱۵ درصد به مجموعه‌های آموزش، اعتبارسنجی و آزمون تقسیم شدند. برای جلوگیری از بیش‌برازش، از Dropout با نرخ ۰/۲، منظم‌سازی L2 با ضریب 10^{-4} و روش Early Stopping با دوره انتظار ۲۰ استفاده شد. همچنین، در صورت عدم کاهش خطای اعتبارسنجی طی ۱۰ دوره، نرخ یادگیری با ضریب ۰/۵ کاهش یافت. الگوریتم‌های HOA و FHO برای آموزش مستقیم وزن‌های شبکه استفاده نشده، بلکه برای تنظیم فوق‌پارامترهای مدل استفاده و وزن‌ها توسط Adam به‌روزرسانی شد. تابع هدف الگوریتم‌های فراابتکاری، کمینه‌سازی RMSE مجموعه اعتبارسنجی بود و فرایند بهینه‌سازی برای هر ایستگاه با ۱۰۰۰ تکرار انجام شد.

۵- متغیرهای ورودی

در راستای پیش‌بینی شاخص کارلسون برای تحلیل تغذیه‌گرایی در مخزن سد از روش‌های یادگیری عمیق استفاده می‌شود. به منظور شبیه‌سازی، شناسایی متغیرهای ورودی حائز اهمیت است. با توجه به همبستگی مناسب بین پارامترهای مختلف و شاخص کارلسون و بررسی مطالعات انجام‌شده در خصوص شاخص‌های کیفی و تغذیه‌گرایی در مخازن سد متغیرهای اسیدیته (pH)، اکسیژن محلول (DO)، دمای آب (T)، کل جامدات محلول (TDS)، جریان ورودی به سد (SWi)، جریان خروجی از سد (SWo)، تبخیر از دریاچه سد (ET) و حجم یا تراز مخزن (L) مورد بررسی قرار گرفت (Majnooni et al., 2024; Yun et al., 2024). انتخاب این ۸ پارامتر در قالب ۱۰ سناریوی ورودی متغیرها برای شبیه‌سازی مطابق جدول ۴ در نظر گرفته شد.

جدول ۴. سناریوهای ورودی به مدل‌های یادگیری عمیق برای پیش‌بینی تغذیه‌گرایی

Sort	Scenarios	Parameters	Sort	Scenarios	Parameters
1	S1	pH-DO-T-TDS-SW _i -SW _o -ET-L	6	S6	DO-T-SW _i -L
2	S2	pH-DO-T-TDS	7	S7	DO-T-TDS-SW _i -SW _o -ET-L
3	S3	SW _i -SW _o -ET-L	8	S8	DO-TDS-SW _i -ET-L
4	S4	DO-T-SW _i -SW _o -ET-L	9	S9	DO-T-TDS-SW _i -L
5	S5	pH-DO-T-SW _i -ET-L	10	S10	pH-T-SW _i -SW _o -L

۶- شاخص‌های ارزیابی مدل

پس از مراحل آموزش شبکه، برای بررسی دقت و صحت پیش‌بینی‌های مدل، از شاخص‌های آماری ضریب تبیین (R^2)، میانگین مجذور مربعات خطا (RMSE)، میانگین خطای مطلق (MAPE) و شاخص نش ساتکلیف (NASH) استفاده شد.

$$R^2 = \frac{[\sum_{i=1}^n (D_i - \bar{D})(O_i - \bar{O})]^2}{\sum_{i=1}^n (D_i - \bar{D})^2 \sum_{i=1}^n (O_i - \bar{O})^2} \quad (۶)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (D_i - O_i)^2} \quad (۷)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - D_i}{O_i} \right| \quad (۸)$$

$$NASH = 1 - \frac{\sum_{i=1}^n (O_i - D_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۹)$$


در این روابط D_i و O_i به ترتیب آیین داده شبیه‌سازی شده توسط مدل و مقدار واقعی (مشاهده شده)، $\bar{D}$ و $\bar{O}$ به ترتیب میانگین کل داده‌های D_i و O_i در جامعه آماری، n تعداد نمونه‌ها است.

نتایج و بحث

۱- پهنه‌بندی شاخص تغذیه‌گرایی

به منظور ارزیابی تغذیه‌گرایی در مخزن سد، شاخص کارلسون در ۶ ایستگاه نمونه‌برداری و در ۴ عمق مختلف، در دو مقیاس زمانی فصلی و سالانه محاسبه شد. در شکل ۳ پهنه‌بندی شاخص کارلسون برای ارزیابی میزان تغذیه‌گرایی در سد ارائه شده است. نتایج حاصل از پهنه‌بندی نشان داد مقدار شاخص تغذیه‌گرایی در مخزن سد دارای تغییرات مکانی، عمقی و زمانی است. این تغییرات بیانگر آن است که وضعیت تغذیه‌گرایی در مخزن یکنواخت نبوده و تحت تأثیر عواملی مانند دمای آب، جریان ورودی، تراز مخزن، زمان ماند آب، شرایط فصلی و فاصله ایستگاه‌ها از ساختگاه سد قرار دارد. بررسی تغییرات عمقی شاخص کارلسون نشان داد بین عمق نمونه‌برداری و مقدار شاخص تغذیه‌گرایی رابطه معکوس وجود دارد. این ارتباط بیانگر این موضوع است که با افزایش عمق، مقدار شاخص کاهش یافته است. این ارتباط معکوس می‌تواند ناشی از کاهش نفوذ نور با لایه‌های عمقی در مخزن سد، کاهش فعالیت

فتوسنتزی و محدود شدن رشد جلبک‌ها در لایه‌های عمیق‌تر مخزن ارتباط داشته باشد. در لایه‌های سطحی، به دلیل دریافت بیشتر تابش خورشیدی، دمای بالاتر و فراهم بودن شرایط مناسب‌تر برای رشد فیتوپلانکتون‌ها، مقدار شاخص تغذیه‌گرایی افزایش یافته است. در مقابل، در اعماق پایین‌تر، کاهش نور و تغییر شرایط اکسیژنی باعث کاهش فعالیت زیستی و در نتیجه، کاهش مقدار شاخص می‌شود. این الگو با نتایج مطالعات Badamian و همکاران (۲۰۲۵)، Mohamed و همکاران (۲۰۲۳) و Lin و همکاران (۲۰۲۲) نیز همخوانی دارد.



شکل ۳. پهنه‌بندی شاخص کارلسون در مقیاس فصلی و سالانه در سد کرخه

نتایج تغییرات فصلی شاخص در مخزن سد نشان داد با شروع دوره گرم و افزایش دمای آب مقدار شاخص تغذیه‌گرایی افزایش یافته و این افزایش در فصل تابستان بدلیل افزایش دما، شدت تابش، پایداری لایه‌بندی حرارتی و کاهش اختلاط عمودی آب محسوس‌تر است. این شرایط می‌تواند پتانسیل مناسبی را برای رشد جلبکی و افزایش زیست‌توده گیاهی فراهم کند. اختلاف مقدار شاخص میان لایه‌های سطحی و عمقی در فصل گرم بیشتر بوده و ضریب تغییرات شاخص در اعماق مختلف افزایش می‌یابد. این مسئله نشان می‌دهد در دوره گرم، مخزن از نظر تغذیه‌گرایی حساس‌تر می‌شود و احتمال شکل‌گیری نواحی مستعد رشد جلبکی افزایش پیدا

می‌کند. بررسی نقشه‌های پهنه‌بندی شاخص کارلسون در شکل ۴ نشان می‌دهد وضعیت تغذیه‌گرایی از نظر مکانی نیز دارای الگوی مشخصی است. بیشترین مقدار شاخص در فصل تابستان مربوط به ایستگاه P5 است. این ایستگاه در بیشتر دوره‌های مورد بررسی، مقادیر بالاتری از شاخص تغذیه‌گرایی را داشته است. در این ایستگاه ماندگاری بالاتر آب، فاصله بیشتر از محل ساختگاه سد و کاهش تأثیر جریان خروجی می‌تواند از عوامل اصلی افزایش شاخص تغذیه‌گرایی باشد. این شرایط می‌تواند امکان تجمع مواد مغذی، افزایش کلروفیل a و کاهش شفافیت آب را داشته و زمینه را برای تشدید وضعیت تغذیه‌گرایی فراهم آورد. در مقابل، ایستگاه‌هایی که به ساختگاه سد و مسیر جریان خروجی نزدیک‌تر است دارای مقدار کمتر شاخص کارلسون را داشته و این موضوع به دلیل تبادل بیشتر آب، کاهش زمان ماند، کاهش تجمع مواد مغذی و محدودتر شدن شرایط رشد جلبکی ایجاد شده است. لذا نتایج پهنه‌بندی نشان می‌دهد موقعیت مکانی ایستگاه‌ها در مخزن و میزان تأثیرپذیری آن‌ها از جریان ورودی و خروجی، نقش مهمی در تغییرات شاخص تغذیه‌گرایی دارد.

نتایج در مقیاس زمانی سالانه نشان داد تغییرات شاخص تغذیه‌گرایی تابع شرایط هیدرولوژیکی و اقلیمی حوضه بوده و در دوره‌هایی که حجم جریان ورودی افزایش یافته به دلیل ورود رواناب‌های سطحی، رسوبات و مواد مغذی از اراضی بالادست می‌تواند باعث افزایش پتانسیل تغذیه‌گرایی در برخی بخش‌های مخزن شود. در دوره‌های گرم که میزان جریان محدودتر بوده با افزایش زمان ماند آب و افزایش دما می‌تواند زمینه رشد جلبک‌ها و افزایش شاخص را فراهم کند. بنابراین، تغییرات سالانه شاخص کارلسون باید در ارتباط با دمای آب، جریان ورودی، تراز مخزن و موقعیت ایستگاه‌های نمونه‌برداری تفسیر شود. نتایج پهنه‌بندی نشان داد شاخص کارلسون توانسته است تغییرات عمقی، فصلی و مکانی تغذیه‌گرایی را در مخزن سد به خوبی نشان دهد. افزایش مقدار شاخص در لایه‌های سطحی، تشدید آن در فصل تابستان و تمرکز مقادیر بالاتر در ایستگاه‌هایی با زمان ماند بیشتر، بیانگر نقش شرایط فیزیکی و هیدرولوژیکی مخزن در شکل‌گیری و گسترش تغذیه‌گرایی است.

۲- شبیه‌سازی شاخص کیفی در دریاچه سد

با توسعه روش‌های هوش مصنوعی برای شبیه‌سازی و افزایش قابلیت این نوع مدل‌ها در تحلیل داده و فرایندهای غیرخطی و پیچیده، استفاده از مدل‌های یادگیری عمیق در شبیه‌سازی و پیش‌بینی فرایندهای مرتبط با کیفیت منابع آب کارایی مناسبی داشته است. با توجه به ذات موضوع تغذیه‌گرایی در مخازن سدها، که پدیده‌ای غیرخطی، وابسته به زمان و متأثر از مجموعه‌ای از پارامترهای کمی و کیفی است، استفاده از مدل‌هایی که بتواند در تحلیل داده‌ها از منظر زمانی و مکانی در تحلیل رفتاری آن مؤثر باشد بسیار مهم است. در این پژوهش شاخص تغذیه‌گرایی کارلسون با استفاده از چهار مدل تلفیقی شامل RNN-LSTM-HOA، LSTM-FHO و FHO شبیه‌سازی شد. با توجه به شرایط بهره‌برداری از مخزن سد، ۱۰ سناریوی ورودی متغیرهای تأثیرگذار در یک دوره ۵ ساله آماری در ۶ ایستگاه و ۴ عمق در مدل‌ها اعمال شد. بهترین ترکیب مدل و سناریو بر مبنای شاخص‌های آماری مطابق جدول ۵ ارائه شد.

جدول ۵. تحلیل آماری سناریو و مدل منتخب برای شبیه‌سازی کیفی مخزن با شاخص کارلسون

Station	Selected scenario	Parameters	Selected model	Train				Test			
				R ²	RMSE	MAPE-%	NASH	R ²	RMSE	MAPE-%	NASH
P1	S6	DO-T-SWi-L	LSTM-FHO	0.82	0.23	0.05	0.77	0.78	0.25	0.03	0.72
P2	S6	DO-T-SWi-L		0.88	0.15	0.05	0.82	0.87	0.16	0.06	0.81
P3	S9	DO-T-TDS-SWi-L		0.85	0.1	0.08	0.83	0.83	0.12	0.11	0.8
P4	S6	DO-T-SWi-L		0.89	0.12	0.11	0.79	0.88	0.13	0.14	0.78

Station	Selected scenario	Parameters	Selected model	Train				Test			
				R ²	RMSE	MAPE-%	NASH	R ²	RMSE	MAPE-%	NASH
P5	S9	DO-T-TDS-SWi-L		0.88	0.06	0.08	0.86	0.86	0.08	0.09	0.85
P6	S8	DO-TDS-SWi-ET-L		0.93	0.1	0.05	0.9	0.92	0.11	0.06	0.89


نتایج جدول ۵ نشان داد مدل LSTM-FHO در تمامی ایستگاه‌ها به عنوان مدل منتخب در شبیه‌سازی تغذیه‌گرایی شناخته شده که بیانگر این موضوع است که تلفیق ساختار حافظه‌دار LSTM با الگوریتم بهینه‌سازی شاهین آتشین توانسته است الگوهای زمانی و غیرخطی شاخص تغذیه‌گرایی را بهتر شناسایی کند. برتری LSTM را می‌توان به توانایی این مدل در حفظ وابستگی‌های بلندمدت و تحلیل رفتارهای تأخیری در داده‌های سری زمانی نسبت داد. از طرفی نیز تغذیه‌گرایی تحت تأثیر تغییرات تدریجی دما، جریان ورودی، تراز آب، اکسیژن محلول و تجمع مواد مغذی قرار داشته و ساختار LSTM قابلیت مناسبی برای یادگیری این نوع وابستگی‌ها دارد. عملکرد مناسب الگوریتم FHO در تلفیق با روش شبیه‌سازی LSTM نشان داد این الگوریتم فرایند بهینه‌سازی پارامترهای مدل را به صورت مناسب تحلیل کرده است. این موضوع با توجه به ذات و خصوصیات الگوریتم شاهین آتشین بوده و این الگوریتم قابلیت جست‌وجوی سراسری و محلی را داشته و احتمال گیر افتادن مدل در پاسخ‌های محلی را کاهش می‌دهد و ساختار مناسب‌تری را برای آموزش مدل فراهم می‌کند. در نتیجه، مدل LSTM-FHO نسبت به سایر ترکیب‌ها توانسته است خطای کمتری تولید کرده و دقت بالاتری در دوره آموزش و آزمون داشته باشد.

به منظور بررسی اعتبار آماری مدل LSTM-FHO، باقیمانده‌های دوره آزمون در ایستگاه‌های مختلف تحلیل شد. بر این اساس، نتایج آزمون Shapiro-Wilk نشان داد مقدار احتمال در تمام ایستگاه‌ها بیشتر از ۰/۰۵ است و فرض نرمال بودن باقیمانده‌ها رد نشد. همچنین، نتایج آزمون Ljung-Box بیانگر نبود خودهمبستگی معنادار در باقیمانده‌ها بود. براساس آزمون Breusch-Pagan نیز فرض ثبات واریانس خطاها در سطح معناداری ۵ درصد رد نشد.

جدول ۶. اعتبار آماری مدل برتر شبیه‌سازی کیفی مخزن با شاخص کارلسون

Station	Shapiro-Wilk	Ljung-Box	Breusch-Pagan	نتیجه
P1	0.148	0.312	0.427	نرمال، مستقل و دارای واریانس ثابت
P2	0.091	0.265	0.381	نرمال، مستقل و دارای واریانس ثابت
P3	0.074	0.198	0.244	نرمال، مستقل و دارای واریانس ثابت
P4	0.126	0.356	0.419	نرمال، مستقل و دارای واریانس ثابت
P5	0.083	0.227	0.305	نرمال، مستقل و دارای واریانس ثابت
P6	0.102	0.284	0.337	نرمال، مستقل و دارای واریانس ثابت

در مجموع، مقادیر احتمال بزرگ‌تر از ۰/۰۵ در هر سه آزمون نشان داد باقیمانده‌ها از توزیع تقریباً نرمال برخوردار بوده، خودهمبستگی معناداری نداشته و واریانس آن‌ها تقریباً ثابت بوده است. همچنین، توزیع تصادفی باقیمانده‌ها در اطراف صفر، نبود سوگیری نظام‌مند در شبیه‌سازی شاخص کارلسون را تأیید کرد. همچنین، به منظور ارزیابی عملکرد مدل LSTM-FHO، نمودارهای پراکندگی مقادیر مشاهده‌ای و شبیه‌سازی‌شده شاخص تغذیه‌گرایی کارلسون برای شش ایستگاه پایش مطابق شکل ۴ ترسیم شد.



شکل ۴. تحلیل آماری مقادیر مشاهداتی و شبیه‌سازی شاخص تغذیه‌گرایی

بررسی شکل ۴ نشان می‌دهد در تمام ایستگاه‌ها، بخش عمده نقاط در اطراف خط ۱:۱ قرار گرفته‌اند که بیانگر توانایی مناسب مدل در بازتولید تغییرات شاخص تغذیه‌گرایی است. بیشترین انطباق میان مقادیر مشاهده‌ای و شبیه‌سازی‌شده در ایستگاه P6 مشاهده شد که با بیشترین ضریب تعیین دورهٔ آزمون، برابر با ۰/۹۲، مطابقت دارد. ایستگاه‌های P2، P4 و P5 نیز پراکندگی نسبتاً محدودی در اطراف خط تطابق نشان می‌دهد. در ایستگاه‌های P1 و P3 فاصلهٔ برخی نقاط از خط ۱:۱ بیشتر بود که با مقادیر پایین‌تر ضریب تعیین، به‌ترتیب برابر با ۰/۷۸ و ۰/۸۳ سازگار است. با این حال، نبود انحراف منظم نقاط به یک سمت خط ۱:۱ نشان می‌دهد مدل در بیشتر ایستگاه‌ها فاقد بیش‌برآورد یا کم‌برآورد سیستماتیک شدید بوده است. در مجموع، الگوی پراکندگی نقاط همراه با شاخص‌های آماری جدول ۵، قابلیت قابل قبول مدل LSTM-FHO را در شبیه‌سازی شاخص کارلسون در ایستگاه‌های مختلف مخزن تأیید می‌کند.

از نظر مکانی، نتایج شبیه‌سازی نشان داد ایستگاه‌های مختلف مخزن رفتار یکسانی نداشته و می‌توان آن‌ها را بر اساس سناریوی منتخب و ترکیب متغیرهای مؤثر، در چند گروه تفکیک کرد. در دو ایستگاه P3 و P5 سناریوی S9 با پارامترهای ورودی DO، T، TDS و SWi و L به عنوان سناریوی منتخب انتخاب شد. در این دو ایستگاه، علاوه بر دما، اکسیژن محلول، جریان ورودی و تراز

مخزن، پارامتر TDS نقش مؤثری در شبیه‌سازی تغذیه‌گرایی داشته است. با توجه به موقعیت مکانی این ایستگاه‌ها و احتمال ماندگاری بیشتر آب، حضور مواد محلول می‌تواند بر شرایط زیستی و تغذیه‌ای مخزن اثرگذار باشد. در ۳ ایستگاه P1، P2 و P4 سناریوی ورودی S6 با پارامترهای ورودی DO، T، SWi و L عملکرد مناسبی را داشته و انتخاب این سناریو نشان داد چهار پارامتر اکسیژن محلول، دمای آب، جریان سطحی ورودی و تراز مخزن مهم‌ترین عوامل مؤثر بر تغییرات شاخص کارلسون است. این نتیجه از نظر کاربردی اهمیت داشته، زیرا این پارامترها از نظر اندازه‌گیری و هزینه نسبت به پارامترهای کلروفیل و فسفر کل، راحت‌تر و کم‌هزینه‌تر بوده و این رویکرد می‌تواند برای پایش مستمر تغذیه‌گرایی مورد استفاده قرار گیرد. در ایستگاه P6، سناریوی S8 شامل پارامترهای ورودی DO، TDS، SWi، ET و L به عنوان برگزیده انتخاب شد که تفاوت سناریوی منتخب در این ایستگاه، می‌تواند ناشی از شرایط مکانی خاص، تفاوت در تأثیرپذیری از جریان ورودی، تغییرات تراز و شرایط تبخیر باشد. نقش پارامتر تبخیر در سناریوی ورودی S8 بیانگر این موضوع است که فرایندهای اقلیمی و تبخیری نیز می‌تواند در برخی مناطق مخزن بر رفتار تغذیه‌گرایی اثرگذار باشد.

بررسی شاخص‌های آماری نشان داد در دوره آموزش، مقدار ضریب تبیین (r^2) در ایستگاه‌های مختلف بین ۰/۸۲ تا ۰/۹۳، مقدار RMSE بین ۰/۰۶ تا ۰/۲۳، MAPE بین ۰/۰۵ تا ۰/۰۱۱ و مقدار NASH بین ۰/۷۷ تا ۰/۹ متغیر محاسبه شده است. به طور کلی، این مقادیر بیانگر عملکرد مناسب مدل یادگیری عمیق در تحلیل رفتارسنجی شاخص تغذیه‌گرایی در دوره آموزش است. در دوره آزمون مقدار کلی شاخص‌ها به دلیل کوتاه‌تر شدن طول دوره آماری تعدیل شده اما دقت مدل همچنان در محدوده قابل قبول باقی مانده است. در این دوره، ضریب تبیین بین ۰/۷۸ تا ۰/۹۲، ضریب نش — ساتکلیف بین ۰/۷۲ تا ۰/۸۹ محاسبه شده که نشان‌دهنده قابلیت مناسب مدل در شبیه‌سازی داده‌های دیده‌نشده است. کاهش نسبی دقت مدل در دوره آزمون نسبت به دوره آموزش امری قابل انتظار بوده زیرا در دوره آموزش، مدل به طور مکرر با حجم داده‌های بیشتری نسبت به دوره آزمون مواجه شده و الگوهای موجود در آن‌ها را یاد می‌گیرد. اختلاف محدود میان شاخص‌های آماری در دو دوره آموزش و آزمون نشان می‌دهد مدل دچار بیش‌برازش شدید نشده و از قابلیت تعمیم مناسبی برای رفتارسنجی برخوردار است. این موضوع در مطالعات مربوط به مخازن سد و تحلیل کیفی از این جهت حائز اهمیت است که معمولاً داده‌های کیفی تحت تأثیر تغییرات فصلی، شرایط بهره‌برداری، ورودی‌های حوضه و نوسانات اقلیمی قرار دارد.

نتایج شبیه‌سازی شاخص کارلسون برای تحلیل تغذیه‌گرایی بیانگر این موضوع است که مدل LSTM-FHO توانایی مناسبی برای شبیه‌سازی داشته و انتخاب سناریوهای متفاوت در ایستگاه‌های مختلف نیز بیانگر آن است که رفتار تغذیه‌گرایی در مخزن از نظر مکانی یکنواخت نبوده و نقش پارامترهای مؤثر بر آن می‌تواند بسته به موقعیت ایستگاه، عمق نمونه‌برداری و شرایط هیدرولوژیکی تغییر کنند.

۳- ارزیابی مقادیر بهینه

پس از ارزیابی عملکرد مدل‌های مختلف در شبیه‌سازی شاخص تغذیه‌گرایی کارلسون، مدل LSTM-FHO به عنوان مدل منتخب در ایستگاه‌های مختلف مخزن سد شناسایی شد. به منظور دستیابی به ساختار بهینه مدل و کاهش خطای شبیه‌سازی، فرایند بهینه‌سازی پارامترهای مؤثر بر عملکرد مدل با استفاده از الگوریتم شاهین آتشین انجام گرفت. در این مرحله، برای هر ایستگاه پایش، فرایند بهینه‌سازی با تعداد ۱۰۰۰ تکرار اجرا شد تا بهترین ترکیب پارامترهای کنترلی الگوریتم و ساختار مدل تعیین شود. هدف از این مرحله، تنها انتخاب مدل برتر نبود، بلکه بررسی این موضوع است که مدل منتخب در هر ایستگاه با چه مقادیری از پارامترهای بهینه‌سازی به بیشترین دقت دست یافته است. از آنجا که شرایط مکانی، عمقی و هیدرولوژیکی در ایستگاه‌های مختلف مخزن یکسان نیست، انتظار می‌رود مقادیر بهینه پارامترهای مدل نیز در ایستگاه‌های مختلف تفاوت‌هایی داشته باشد. بنابراین، تعیین مقادیر بهینه برای هر ایستگاه می‌تواند به شناخت بهتر رفتار مدل و پایداری فرایند شبیه‌سازی کمک کند. در الگوریتم FHO، پارامترهایی مانند اندازه جمعیت، بعد مسئله، نرخ اکتشاف، نرخ یادگیری، پارامتر همگرایی و نرخ جهش نقش مهمی در کیفیت جست‌وجوی فضای پاسخ و

دستیابی به جواب بهینه دارند. اندازه جمعیت نشان دهنده تعداد عامل‌های جست‌وجوگر در فرایند بهینه‌سازی است و مقدار مناسب آن می‌تواند تعادل میان دقت جست‌وجو و هزینه محاسباتی را برقرار کند. بعد مسئله نیز بیانگر تعداد متغیرها یا مؤلفه‌هایی است که در فرایند بهینه‌سازی مورد بررسی قرار می‌گیرند. نرخ اکتشاف و نرخ جهش، قابلیت الگوریتم را در جست‌وجوی نواحی جدید فضای پاسخ افزایش می‌دهند و از گیر افتادن مدل در جواب‌های محلی جلوگیری می‌کنند. در مقابل، نرخ یادگیری و پارامتر همگرایی بر سرعت نزدیک شدن الگوریتم به پاسخ بهینه و پایداری فرایند آموزش اثرگذار هستند.

جدول ۷. مقدار بهینه و کران تعریف‌شده برای مدل‌های بهینه در ایستگاه‌های پایش کیفی سد

Parameters		Hyper-parameters					
		Population Size (N)	Dimension of the Problem (D)	Exploration Rate (E)	Learning Rate (LR)	Convergence Parameter (C)	Mutation Rate (MR)
Appropriate boundaries		(10 – 100)	(2 – 30)	(0 – 1)	(0 – 1)	(0 – 2)	(0 – 1)
TSI	P1	75	14	0.7	0.42	1.09	0.2
	P2	53	16	0.75	0.44	1.2	0.15
	P3	72	18	0.78	0.41	1.15	0.17
	P4	68	15	0.76	0.48	1.18	0.16
	P5	58	17	0.75	0.5	1.07	0.2
	P6	61	15	0.8	0.45	1.11	0.11

نتایج جدول ۷ نشان داد مقادیر بهینه پارامترهای الگوریتم FHO در ایستگاه‌های مختلف دارای تغییرات محدود اما قابل تفسیر است. اندازه جمعیت بهینه بین ۵۳ تا ۷۵ و بعد مسئله بین ۱۴ تا ۱۸ قرار گرفت که بیانگر تفاوت در ویژگی داده‌ها و پیچیدگی فضای جست‌وجوی هر ایستگاه است. ضریب اکتشاف در محدوده ۰/۷۰ تا ۰/۸۰ به دست آمد و نشان داد الگوریتم برای شناسایی جواب مناسب به جست‌وجوی نسبتاً گسترده‌ای در فضای پاسخ نیاز داشته است. ضریب یادگیری FHO نیز بین ۰/۴۱ تا ۰/۵۰ و پارامتر همگرایی بین ۱/۰۷ تا ۱/۲۰ متغیر بود که بیانگر ایجاد تعادل مناسب میان حرکت عامل‌ها به سمت جواب‌های بهتر و پایداری فرایند همگرایی است. نرخ جهش نیز در محدوده ۰/۱۱ تا ۰/۲۰ قرار گرفت و سطح کنترل‌شده‌ای از تغییرات تصادفی را برای حفظ تنوع جمعیت و کاهش احتمال همگرایی زودرس فراهم کرد. در مجموع، تفاوت مقادیر بهینه می‌تولند ناشی از تغییرپذیری داده‌ها، میزان نویز، وابستگی زمانی و ترکیب متفاوت متغیرهای ورودی در ایستگاه‌های مختلف باشد و نشان می‌دهد استفاده از یک مجموعه ثابت از پارامترهای FHO برای تمام ایستگاه‌ها مناسب نیست.

بحث

برتری مدل LSTM-FHO را می‌توان به توانایی ساختار LSTM در حفظ اطلاعات گذشته و شناسایی روابط تأخیری میان متغیرهای کیفی و هیدرولوژیکی نسبت داد. تغذیه‌گرایی فرایندی تدریجی و غیرخطی است و تغییر دما، جریان ورودی، اکسیژن محلول و تراز مخزن ممکن است با فاصله زمانی بر رشد جلبکی و شاخص کارلسون اثر بگذارد.

انتخاب مکرر دمای آب، اکسیژن محلول، جریان ورودی و تراز مخزن در سناریوهای منتخب نشان دهنده ارتباط مناسب این متغیرها با تغییرات TSI است. افزایش دما می‌تواند رشد و فعالیت متابولیکی فیتوپلانکتون را تقویت کرده و هم‌زمان با افزایش پایداری لایه‌بندی، انتقال اکسیژن به آب‌های عمیق را محدود کند. رابطه اکسیژن محلول با تغذیه‌گرایی نیز دوطرفه است و فرایند فتوسنتز می‌تواند DO سطحی را افزایش دهد. این موضوع در حالی است که تجزیه مواد آلی و تنفس در لایه‌های عمیق موجب مصرف اکسیژن می‌شود. کاهش اکسیژن نزدیک بستر نیز می‌تواند آزادسازی فسفر و آمونیوم از رسوبات و در نتیجه بارگذاری داخلی مواد

مغذی را افزایش دهد. در دو مخزن یوتروفیک کالیفرنیا نیز بیشترین آزادسازی آمونیوم و فسفر محلول از رسوبات در شرایط بی‌هوازی مشاهده شد.

حضور TDS در سناریوی منتخب ایستگاه‌های P3 و P5 نشان داد تغییرات مواد محلول نیز اطلاعات مفیدی برای پیش‌بینی TSI فراهم کرده است. TDS می‌تواند تحت تأثیر رواناب، فرسایش، زه‌آب کشاورزی، ورود آلاینده‌ها و تبخیر قرار گیرد، اما تمام اجزای آن ماده مغذی نیست. لذا این موضوع را می‌توان یک نشانگر غیرمستقیم تغییرات شیمیایی آب تحلیل کرد. همچنین، انتخاب یک متغیر توسط مدل بیشتر نشان‌دهنده ارزش پیش‌بینی آن است و به‌تنهایی رابطه علت و معلولی را اثبات نمی‌کند.

بیشترین مقدار TSI در ایستگاه P5 را می‌توان با موقعیت مکانی آن تفسیر کرد. این ایستگاه نسبت به بدنه سد فاصله بیشتری داشته و بیشتر تحت تأثیر رواناب‌های سطحی، سیلاب و مواد آلاینده ورودی از حوضه قرار دارد. رواناب و سیلاب می‌توانند ترکیبات نیتروژن و فسفر، مواد آلی، جامدات محلول و ذرات معلق را وارد مخزن کند. ورود مواد مغذی زمینه رشد فیتوپلانکتون را فراهم می‌کند و افزایش مواد معلق نیز می‌تواند شفافیت آب را کاهش داده و مقدار TSI مبتنی بر دیسک سکی را افزایش دهد. این تفسیر با نتایج Shi و همکاران (۲۰۲۴) در مخزن دانجیانگو سازگار است (C. Shi et al., 2024).

با این حال، افزایش TSI در P5 نباید فقط به یک عامل نسبت داده شود. فاصله از بدنه سد و کاهش اثر تخلیه می‌تواند زمان ماند آب را افزایش دهد و فرصت بیشتری برای تجمع مواد مغذی و رشد جلبکی ایجاد کند. از طرف دیگر، سیلاب‌های شدید ممکن است با افزایش اختلاط و کاهش زمان ماند، بخشی از زی‌توده را رقیق کنند. بنابراین وضعیت P5 احتمالاً حاصل اثر هم‌زمان بارگذاری خارجی، زمان ماند، دما، شفافیت و شرایط اختلاط است. تفکیک TSI مبتنی بر کلروفیل a ، فسفر کل و دیسک سکی می‌تواند مشخص کند که افزایش شاخص بیشتر ناشی از رشد جلبکی، غنی شدن مواد مغذی یا کدورت سیلابی بوده است.

تفاوت عمقی TSI نیز می‌تواند با لایه‌بندی حرارتی مخزن مرتبط باشد. در فصل گرم، لایه سطحی به دلیل نور و دمای مناسب شرایط مطلوب‌تری برای رشد جلبک دارد؛ در حالی که در لایه عمیق، محدودیت اختلاط و تجزیه مواد آلی موجب افت اکسیژن می‌شود. کمبود اکسیژن در نزدیکی رسوبات، احتمال آزادسازی داخلی فسفر و نیتروژن را افزایش می‌دهد. پس از شکسته شدن لایه‌بندی، این مواد می‌توانند به لایه‌های سطحی منتقل شوند و رشد جلبکی دوره بعد را تقویت کنند. بنابراین، پایین بودن کلروفیل در عمق الزاماً نشان‌دهنده کیفیت مطلوب آب نیست، زیرا ممکن است هم‌زمان کم‌اکسیژنی و تجمع مواد مغذی در حال وقوع باشد.

در مجموع، نتایج نشان داد تغییرات TSI در مخزن تحت تأثیر هم‌زمان شرایط حرارتی، اکسیژن محلول، ورود رواناب و آلاینده‌ها، زمان ماند و لایه‌بندی حرارتی قرار دارد. مدل LSTM-FHO توانسته است بخش مهمی از این روابط غیرخطی و تأخیری را شناسایی کند. از نظر مدیریتی، افزایش پایش در ایستگاه P5، به‌ویژه پس از بارندگی و سیلاب و اندازه‌گیری هم‌زمان کلروفیل a ، فسفر، نیتروژن، کدورت و پروفیل عمقی دما و DO برای تشخیص منشأ تغذیه‌گرایی ضروری است.

نتیجه‌گیری

در این پژوهش، وضعیت تغذیه‌گرایی مخزن سد کرخه با استفاده از شاخص کارلسون TSI و رویکردهای یادگیری عمیق مورد ارزیابی و شبیه‌سازی قرار گرفت. با توجه به اهمیت تغذیه‌گرایی در کاهش کیفیت آب، رشد جلبکی، کاهش شفافیت، تغییر شرایط اکسیژنی و ایجاد محدودیت در بهره‌برداری از مخزن، تلاش شد رویکردی داده‌محور برای تحلیل مکانی و زمانی این پدیده ارائه شود. شاخص تغذیه‌گرایی براساس سنجش ۶ ایستگاه پایش در ۴ عمق مختلف محاسبه و سپس، با استفاده از مدل‌های تلفیقی RNN-HOA، LSTM-HOA، LSTM-FHO و RNN-FHO شبیه‌سازی شد.

نتایج پهنه‌بندی شاخص کارلسون نشان داد وضعیت تغذیه‌گرایی در مخزن سد از نظر مکانی، فصلی و عمقی یکنواخت نیست. بررسی تغییرات عمقی نشان داد با افزایش عمق نمونه‌برداری، مقدار شاخص تغذیه‌گرایی کاهش می‌یابد. این موضوع بیانگر تأثیر بیشتر تابش خورشیدی، دمای بالاتر و فعالیت زیستی شدیدتر در لایه‌های سطحی مخزن است. همچنین، نتایج فصلی نشان داد با آغاز دوره گرم

سال و افزایش دمای آب، مقدار شاخص کارلسون افزایش می‌یابد. در فصل تابستان به دلیل افزایش دما، کاهش اختلاط عمودی، پایداری لایه‌بندی حرارتی و افزایش زمان ماند آب، شرایط مساعدتری برای تشدید تغذیه‌گرایی فراهم می‌کند.

از نظر مکانی، نتایج نشان داد ایستگاه‌های نزدیک‌تر به ساختگاه سد و مسیر جریان خروجی، به دلیل تبادل بیشتر آب و زمان ماند کمتر، معمولاً مقادیر پایین‌تری از شاخص تغذیه‌گرایی را نشان می‌دهد. در مقابل، با فاصله گرفتن از ساختگاه سد و افزایش اثرپذیری از نوسانات تراز مخزن، جریان‌های ورودی و تجمع مواد مغذی، مقدار شاخص افزایش می‌یابد. ایستگاه P5 به‌ویژه در فصل تابستان بیشترین مقدار شاخص را داشته که می‌تواند ناشی از ماندگاری بیشتر آب، کاهش تبادل هیدرولیکی و استعداد بیشتر این ناحیه برای تجمع مواد مغذی و رشد جلبکی باشد.

نتایج شبیه‌سازی نشان داد مدل LSTM-FHO نسبت به سایر مدل‌های مورد بررسی، عملکرد مناسب‌تری در برآورد شاخص تغذیه‌گرایی کارلسون داشته است. همچنین، بررسی سناریوهای ورودی نشان داد پارامترهای اکسیژن محلول، دمای آب، جریان سطحی ورودی به مخزن و تراز آب مخزن از مهم‌ترین عوامل مؤثر در شبیه‌سازی شاخص تغذیه‌گرایی هستند. برتری مدل LSTM-FHO را می‌توان به تولنایی ساختار LSTM در حفظ وابستگی‌های زمانی بلندمدت و قابلیت الگوریتم FHO در بهینه‌سازی پارامترهای مدل نسبت داد. از آنجا که تغذیه‌گرایی یک پدیده تدریجی، غیرخطی و وابسته به شرایط گذشته مخزن است، استفاده از مدلی که بتواند اثر تأخیری متغیرهای کمی و کیفی را طی زمان شناسایی کند، موجب افزایش دقت شبیه‌سازی شده است.

به طور کلی، نتایج این مطالعه نشان داد استفاده از مدل‌های یادگیری عمیق تلفیق‌شده با الگوریتم‌های بهینه‌سازی، قابلیت بالایی در شبیه‌سازی شاخص تغذیه‌گرایی مخزن سد دارد. این رویکرد می‌تواند وابستگی به نمونه‌برداری‌های گسترده و پرهزینه را کاهش داده و امکان پایش پیوسته‌تر وضعیت تغذیه‌گرایی را فراهم سازد. از دیدگاه مدیریتی، مدل پیشنهادی می‌تواند برای شناسایی نواحی حساس، تعیین دوره‌های بحرانی، کنترل اثرات جریان ورودی، مدیریت تراز بهره‌برداری و تدوین سیاست‌های پیشگیرانه در مدیریت تغذیه‌گرایی مخزن سد مورد استفاده قرار گیرد.

- 1 Afshar, A., Saadatpour, M., & Marino, M. A. (2012). Development of a complex system dynamic eutrophication model: Application to Karkheh reservoir. *Environmental Engineering Science*, 29(6), 373–385. <https://doi.org/10.1089/EES.2010.0203>
- 2 Akbari Osmavandani, S., Sharafati, A., & Moghaddam, H. K. (2024). Assessing the effectiveness of artificial intelligence models in predicting Zayanderud dam inflow at different time scales. *Acta Geophysica*, 72(5), 3511–3527. <https://doi.org/10.1007/S11600-023-01257-4/METRICS>
- 3 Badamian, M. R., Noori, R., Jun, C., Bateni, S. M., Heidari, S., Bahrami, B., Mortazavi, M., Vesali Naseh, M. R., & Zhu, S. (2025). New insights on biomass production in lakes: Integration of Carlson trophic state index and vertically generalized production model. *Ecological Indicators*, 174, 113450. <https://doi.org/10.1016/J.ECOLIND.2025.113450>
- 4 Chou, J. S., Ho, C. C., & Hoang, H. S. (2018). Determining quality of water in reservoir using machine learning. *Ecological Informatics*, 44, 57–75. <https://doi.org/10.1016/J.ECOINF.2018.01.005>
- 5 Fu, G., Jin, Y., Sun, S., Yuan, Z., & Butler, D. (2022). The role of deep learning in urban water management: A critical review. *Water Research*, 223, 118973. <https://doi.org/10.1016/J.WATRES.2022.118973>
- 6 Galelli, S., Castelletti, A., & Goedbloed, A. (2015). High-Performance Integrated Control of water quality and quantity in urban water reservoirs. *Water Resources Research*, 51(11), 9053–9072. <https://doi.org/10.1002/2015WR017595>
- 7 Klippel, G., Macêdo, R. L., & Branco, C. W. C. (2020). Comparison of different trophic state indices applied to tropical reservoirs. *Lakes & Reservoirs: Research & Management*, 25(2), 214–229. <https://doi.org/10.1111/LRE.12320>
- 8 Kuczyńska-Kippen, N., Zhang, C., Mleczek, M., & Špoljar, M. (2025). Rotifers as indicators of trophic state in small water bodies with different catchments (field vs. forest). *Hydrobiologia*, 852(10), 2669–2685. <https://doi.org/10.1007/S10750-024-05760-7/TABLES/6>
- 9 Lin, J. L., Karangan, A., Huang, Y. M., & Kang, S. F. (2022). Eutrophication factor analysis using Carlson trophic state index (CTSI) towards non-algal impact reservoirs in Taiwan. *Sustainable Environment Research*, 32(1), 25-. <https://doi.org/10.1186/S42834-022-00134-X/FIGURES/9>
- 10 Liu, H., Zhang, Y., Lin, Y., & Zhou, X. (2025). A comprehensive review of eutrophication simulation and assessment in surface water: analysis and visualization. *Environment, Development and Sustainability*, 1–33. <https://doi.org/10.1007/S10668-024-05872-Z/METRICS>
- 11 Lyu, L., Lyu, L., Song, K., Song, K., Wen, Z., Liu, G., Shang, Y., Li, S., Tao, H., Tao, H., Wang, X., Wang, X., & Hou, J. (2022). Estimation of the lake trophic state index (TSI) using hyperspectral remote sensing in Northeast China. *Optics Express*, Vol. 30, Issue 7, Pp. 10329–10345, 30(7), 10329–10345. <https://doi.org/10.1364/OE.453404>
- 12 Majnooni, S., Fooladi, M., Nikoo, M. R., Al-Rawas, G., Haghighi, A. T., Nazari, R., Al-Wardy, M., & Gandomi, A. H. (2024). Smarter water quality monitoring in reservoirs using interpretable deep learning models and feature importance analysis. *Journal of Water Process Engineering*, 60, 105187. <https://doi.org/10.1016/J.JWPE.2024.105187>
- 13 Meng, D., Mao, J., Li, W., Zhu, S., & Gao, H. (2023). An Integrated Framework for Remote Sensing Assessment of the Trophic State of Large Lakes. *Remote Sensing 2023*, Vol. 15, Page 4238, 15(17), 4238. <https://doi.org/10.3390/RS15174238>
- 14 MiarNaeimi, F., Azizyan, G., & Rashki, M. (2021). Horse herd optimization algorithm: A nature-inspired algorithm for high-dimensional optimization problems. *Knowledge-Based Systems*, 213, 106711. <https://doi.org/10.1016/J.KNOSYS.2020.106711>
- 15 Mohamed, H. M., Khalil, M. T., El-Zeiny, A. M., Khalifa, N., Kafrawy, S. B. E., & Emam, W. W. M. (2023). Trophic state and potential productivity assessment for Qaroun Lake using spatial techniques. *Environmental Monitoring and Assessment*, 195(8), 987-. <https://doi.org/10.1007/S10661-023-11504-2/TABLES/5>
- 16 Saadatpour, M., Afshar, A., & Solis, S. S. (2020). Surrogate-Based Multiperiod, Multiobjective Reservoir Operation Optimization for Quality and Quantity Management. *Journal of Water Resources Planning and Management*, 146(8), 04020053. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001252](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001252)
- 17 Shen, C. (2018). A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists. *Water Resources Research*, 54(11), 8558–8593. <https://doi.org/10.1029/2018WR022643>
- 18 Shi, C., Zhuang, N., Li, Y., Xiong, J., Zhang, Y., Ding, C., & Liu, H. (2024). Identifying factors influencing reservoir eutrophication using interpretable machine learning combined with shoreline morphology and landscape hydrological features: A case study of Danjiangkou Reservoir, China. *Science of The Total Environment*, 951,

175450. <https://doi.org/10.1016/J.SCITOTENV.2024.175450>
- 19 Shi, Y., Mao, J., Liu, X., Meng, D., Zhu, J., Gao, H., & Wang, K. (2025). Remote Sensing Assessment of Trophic State in Reservoir Tributary Embayments Based on Multi-Source Data Fusion. *Remote Sensing* 2025, Vol. 17, Page 2886, 17(16), 2886. <https://doi.org/10.3390/RS17162886>
- 20 Shishehgharkhaneh, M. B., Azizi, M., Basiri, M., & Moehler, R. C. (2022). BIM-Based Resource Tradeoff in Project Scheduling Using Fire Hawk Optimizer (FHO). *Buildings* 2022, Vol. 12, Page 1472, 12(9), 1472. <https://doi.org/10.3390/BUILDINGS12091472>
- 21 Szewczyk, M., Tomczyk, P., & Wiatkowski, M. (2025). Long-term water quality assessment and trophic status trends in Dobromierz, Lubachów and Sosnówka drinking water reservoirs in southwestern Poland. *Scientific Reports* 2025 15:1, 15(1), 9804-. <https://doi.org/10.1038/s41598-025-94219-3>
- 22 Wu, M., Liu, P., Liu, L., Zou, K., Luo, X., Wang, J., Xia, Q., & Wang, H. (2024). Improving a hydrological model by coupling it with an LSTM water use forecasting model. *Journal of Hydrology*, 636, 131215. <https://doi.org/10.1016/J.JHYDROL.2024.131215>
- 23 Yun, Y. J., Jargal, N., & An, K. G. (2024). Developing practical models for predicting chlorophyll levels in the Andong Reservoir using empirical and machine learning approaches based on integrated analysis of physical, chemical, and hydrological indicators. *Ecological Indicators*, 167, 112659. <https://doi.org/10.1016/J.ECOLIND.2024.112659>