

A hybrid SNIP-ANN model: A novel approach for accurate river flow prediction

Fatemeh Vosoughi¹, Mohammad Ali Ghorbani^{2*}, Sabereh Darbandi³

¹ M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

² Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

³ Associate Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

Abstract

Introduction

River flow prediction is crucial for water resource management, environmental protection, and flood control, yet the nonlinear nature of hydrological data poses challenges. Previous studies using models like Random Forest and LSTM faced limitations in accuracy and computational complexity. This research introduces the hybrid SNIP-ANN model, combining the novel SNIP algorithm with Artificial Neural Networks, to enhance prediction accuracy. The study focuses on time-series analysis of monthly flows in the Columbia and Niger Rivers, vital freshwater sources. The goal is to improve forecasting precision for better water management and to reduce uncertainties.

Materials and Methods

The SNIP-ANN model is an advanced hybrid method for analyzing river discharge time series. In this model, the SNIP algorithm first preprocesses the raw streamflow data; it separates meaningful signal components from background noise by eliminating fluctuations and enhancing significant peaks. Then, an artificial neural network (ANN), inspired by the parallel processing nature of the human brain, learns the nonlinear relationships between past and present discharge values using the processed data. In this study, a three-month lag ($Q(t-3)$) was selected as the optimal input. By combining SNIP's strength in feature extraction and ANN's ability to recognize, the SNIP-ANN model demonstrated high accuracy in prediction. The model was trained and validated using historical monthly discharge data from the Columbia and Niger rivers. Evaluation metrics such as RMSE and the correlation coefficient (R) indicated high precision and low error. The model's simplicity and use of only discharge data make it suitable for real-time water resource management and applications in other domains like meteorology and economics. Additionally, its lightweight structure and short training time allow for implementation in systems lacking advanced computational facilities. The model's generalizability also makes it a reliable choice for time series analysis under diverse climatic conditions. Applying this approach in other data-driven fields can improve prediction accuracy while reducing computational costs. Overall, the SNIP-ANN model offers an effective, lightweight, and intelligent solution for predicting streamflow behavior in complex hydrological systems.

Results and Discussion

In this study, in the first stage, the temporal modeling and in the second stage, the performance evaluation of monthly streamflow prediction for the Columbia and Niger rivers during the study period were carried out using the Artificial Neural Network (ANN) model and the hybrid SNIP-enhanced ANN (SNIP-ANN) model. To model the time-dependent behavior of streamflow, three time-lagged discharge values (one-, two-, and three-month delays) were used as input parameters. Among them, the three-month lag ($Q(t-3)$) was selected as the optimal input based on its stronger correlation with hydrological patterns such as seasonal variability, rainfall fluctuations, and groundwater storage. Seventy percent of the data was used for training and thirty percent was used for testing the models. Based on the evaluation results from R , RMSE, and other metrics such as the Taylor diagram, violin plot, and observed versus predicted plots, it was found that the SNIP-ANN model significantly outperformed the standard ANN in temporal modeling. For instance, in the Columbia River, the SNIP-ANN model achieved an R value of 0.7503 and an RMSE of 865.23, while the ANN model had an R of 0.3249 and a much higher RMSE of 1325.99. Similarly, for the Niger River, the SNIP-ANN reached an R of 0.9286 and an RMSE of 231.49, surpassing the ANN model, which scored an R of 0.8014 and an RMSE of 487.88. Moreover, the scatter plots revealed that the predicted values in the SNIP-ANN model were more concentrated along the ideal line ($y = x$), indicating higher prediction accuracy. The violin plots further supported this finding by showing that the SNIP-ANN predictions closely matched the actual distribution of flow values, while the ANN model showed greater deviations. In general, the SNIP-ANN model demonstrated superior capability in capturing nonlinear patterns, reducing prediction error, and improving generalization performance. These results highlight the model's potential for real-time hydrological forecasting, especially under extreme flow conditions. Future research may focus on integrating ensemble learning strategies or additional preprocessing techniques to further enhance prediction accuracy across diverse hydrological scenarios.

Conclusion

In this study, the hybrid SNIP-ANN model was introduced as an innovative approach for river discharge prediction and compared with the traditional ANN model. The results showed that the hybrid model significantly improved prediction accuracy compared to the ANN model. By using a three-month time delay in the input data, the model was able to effectively

simulate seasonal fluctuations and periodic changes in river discharge. The correlation coefficient for the hybrid model increased from 0.3249 to 0.7503 for the Columbia River and from 0.8014 to 0.9286 for the Niger River, while the prediction error (RMSE) decreased from 1325.99 to 865.23 and from 487.88 to 231.49, respectively. This performance improvement was particularly noticeable in simulating extreme discharge fluctuations and filtering out additional noise in the data. The results indicate that the SNIP-ANN model is an effective tool for river discharge prediction and has high potential for applications in water resource management and flood prediction. This model can be highly beneficial in long-term forecasting and addressing challenges related to climate change and hydrological fluctuations.

Keywords: SNIP Algorithm, Artificial Neural Network (ANN), River flow, Prediction

Article Type: Research Article

Acknowledgment

The authors acknowledge the countries of Colombia and Niger for providing access to the data.

Conflicts of interest

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

Data availability statement

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

Authors' contribution

Fatemeh Vosoughi: Conceptualization, Performing software/statistical analyses; **Mohammad Ali Ghorbani:** Supervision, Editing and reviewing the manuscript, Result validation; **Sabereh Darbandi:** Conceptualization, Statistical and software analyses.

Article Type: Research Article

*Corresponding Author, E-mail: ghorbani@tabrizu.ac.ir

Citation: Vosoughi, F., Ghorbani, MA., & Darbandi, S. (2025). A hybrid SNIP-ANN model: A novel approach for accurate river flow prediction. *Water and Soil Management and Modelling*, 5(3), 197-211.

doi: 10.22098/mmws.2025.17235.1585

Received: 21 April 2025, Received in revised form: 26 May 2025, Accepted: 26 May 2025, Published online: 23 September 2025.

Water and Soil Management and Modeling, Year 2025, Vol. 5, No. 3, pp. 197-211.

Publisher: University of Mohaghegh Ardabili

© Author(s)





مدل هیبریدی SNIP-ANN: رویکردی نوین جهت پیش‌بینی دقیق دبی جریان رودخانه

فاطمه وثوقی^۱، محمدعلی قربانی^{۲*}، صابره دربندی^۳

^۱ دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

^۲ استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

^۳ دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

چکیده

پیش‌بینی جریان رودخانه برای تأمین نیازهای آبی اکوسیستم‌های آبی و همچنین برنامه‌ریزی و مدیریت بهینه منابع آب، به‌ویژه در شرایط خشکسالی، بسیار حیاتی است. این پیش‌بینی‌ها به حفظ تعادل بوم‌شناختی رودخانه‌ها کمک می‌کند. مدل‌های پیش‌بینی دقیق برای ارزیابی الگوهای جریان آینده و اجرای راهبردهای مدیریتی مؤثر ضروری هستند. در این مطالعه، از یک مدل ترکیبی شامل الگوریتم حساس تکراری غیرخطی پیک (SNIP) به همراه شبکه‌های عصبی مصنوعی (ANN) و همچنین مدل‌های مستقل ANN برای پیش‌بینی جریان رودخانه‌های کلمبیا (۲۰۰۰ تا ۲۰۲۲) و نیجر (۲۰۰۰ تا ۲۰۲۳) استفاده شده است. یکی از مزایای استفاده از الگوریتم SNIP در کنار ANN، کاهش پیچیدگی مدل در عین بهبود کارایی آن است. همچنین، ترکیب تحلیل سری‌های زمانی با تکنیک‌های یادگیری ماشین، پیشرفتی چشم‌گیر در زمینه پیش‌بینی جریان رودخانه محسوب می‌شود. این رویکرد نه تنها دقت پیش‌بینی‌ها را افزایش می‌دهد، بلکه توانایی مدیریت و واکنش مؤثر به نوسانات دبی رودخانه را نیز تقویت می‌کند. تحلیل کمی نتایج نشان داد که مدل ترکیبی SNIP-ANN نسبت به سایر مدل‌ها عملکرد بهتری دارد. برای رودخانه کلمبیا، مدل ANN ضریب همبستگی $R=0.9249$ و مقدار $RMSE=1325.99$ را به دست آورد، در حالی که مدل ترکیبی SNIP-ANN با بهبود قابل توجه، به $R=0.9503$ و $RMSE=865.23$ دست یافت و کاهش $RMSE$ به میزان $34/75$ درصد را نشان داد. به طور مشابه، برای رودخانه نیجر، مدل ANN به $R=0.801$ و $RMSE=487.883$ رسید، در حالی که مدل ترکیبی SNIP-ANN نتایج را تا $R=0.9286$ و $RMSE=231.497$ بهبود داد که کاهش $RMSE$ به میزان $52/56$ درصد را نشان می‌دهد. این نتایج بیانگر آن است که استفاده از مدل ترکیبی SNIP-ANN می‌تواند دقت پیش‌بینی را نسبت به مدل‌های مستقل ANN به طور قابل توجهی افزایش دهد. این مزیت، قابلیت اطمینان و اثربخشی این رویکرد را اثبات می‌کند. با بهره‌گیری از روش‌های ترکیبی، می‌توان به پیش‌بینی‌های دقیق‌تری نه تنها برای رودخانه‌های منتخب، بلکه برای مناطق دیگر نیز دست یافت و پتانسیل بالای این تکنیک را برای کاربردهای گسترده‌تر نشان داد.

واژه‌های کلیدی: الگوریتم SNIP، شبکه عصبی مصنوعی (ANN)، جریان رودخانه، پیش‌بینی

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: ghorbani@tabrizu.ac.ir

استاد: وثوقی، فاطمه، قربانی، محمدعلی، و دربندی، صابره (۱۴۰۴). مدل هیبریدی SNIP-ANN: رویکردی نوین جهت پیش‌بینی دقیق دبی جریان رودخانه. *مدل سازی و مدیریت آب و خاک*، ۵(۳)، ۱۹۷-۲۱۱.

doi: 10.22098/mmws.2025.17235.1585

تاریخ دریافت: ۱۴۰۴/۰۲/۰۱، تاریخ بازنگری: ۱۴۰۴/۰۳/۰۵، تاریخ پذیرش: ۱۴۰۴/۰۳/۰۵، تاریخ انتشار: ۱۴۰۴/۰۷/۰۱

مدل سازی و مدیریت آب و خاک، سال ۱۴۰۴، دوره ۵، شماره ۳، صفحه ۱۹۷ تا ۲۱۱.

© نویسندگان

ناشر: دانشگاه محقق اردبیلی



۱- مقدمه

پیش‌بینی و مدل‌سازی جریان رودخانه از جنبه‌های بنیادی چرخه هیدرولوژیکی محسوب می‌شود (Porporato and Ridolfi, 2001). به‌عنوان منبع اصلی داده‌های هیدرولوژیکی، پیش‌بینی جریان رودخانه نقشی حیاتی و اساسی در حوزه‌هایی نظیر منابع آبی پایدار، حفاظت از محیط زیست، تولید نیروی برق آبی و کنترل سیلاب ایفا می‌کند (Elbeltagi et al., 2022). دستیابی به داده‌های دقیق در مورد جریان رودخانه برای پیشگیری از سیلاب، مدیریت منابع آبی و پایداری محیط زیستی بسیار ضروری است. با این حال، ماهیت غیرخطی و تصادفی فرایندهای هیدرولوژیکی، چالش‌هایی برای مدل‌های سنتی پیش‌بینی به‌همراه دارد. استفاده از مدل‌های هیبریدی می‌تواند راه‌حلی مؤثرتر و قابل‌اعتمادتر برای غلبه بر این چالش‌ها و افزایش دقت پیش‌بینی ارائه دهد. (Hamlet and Lettenmaier 1999) مدلی را برای پیش‌بینی جریان رودخانه کلمبیا با استفاده از سیگنال‌های اقلیمی ال‌نینو/لانینا (ENSO) و نوسان دهه‌ای اقیانوس آرام (PDO) توسعه دادند. این مدل موفق شد ۹۵ درصد جریان‌های ماهانه از آوریل تا سپتامبر را در محدوده پیش‌بینی‌شده پیش‌بینی کند. این دقت نسبت به روش‌های سنتی اقلیم‌محور، که محدوده‌های وسیع‌تری ارائه می‌دادند، پیشرفت چشم‌گیری محسوب می‌شود. (Bolshakov 2013) بر پیش‌بینی جریان رودخانه Daugava با استفاده از داده‌های جریان آب از سال ۲۰۰۸ تا ۲۰۱۳ تمرکز داشت. در این مطالعه از دو مدل رگرسیون خطی و رگرسیون نمادین^۱ استفاده شد. نتایج نشان داد که مدل رگرسیون خطی در شرایط سیلاب عملکرد ضعیفی داشت؛ درحالی‌که مدل رگرسیون نمادین پیش‌بینی‌های دقیق‌تری ارائه کرد و رابطه‌ای چندجمله‌ای بین سطح آب و جریان برقرار نمود. (Adnan et al. 2017) در مطالعه‌ای دقت مدل‌های MARS، M5RT و CMLR را با مدل هیبریدی HLGSا برای پیش‌بینی دبی ماهانه رودخانه‌های آستوره و شیوک مقایسه کردند. نتایج نشان داد که مدل‌های HLGSا و LHLGSا توانایی بالایی در پیش‌بینی جریان رودخانه‌ها داشتند. (Hayder et al. 2020) جریان رودخانه کلانتان در مالزی را با استفاده از شبکه عصبی کسکید-فوروارد (CFNN) بهینه‌شده با الگوریتم ازدحام ذرات (PSO) مدل‌سازی کردند. نتایج با الگوریتم‌های لونبرگ-مارکوارت (LM) و تنظیم بیزی (BR) مقایسه شد. مدل CFNNPSO دقت پیش‌بینی مطلوبی را ارائه داد. (Back and Bae, 2023) به مطالعه‌ای بر روی پیش‌بینی دبی رودخانه‌ها با استفاده از داده‌های جمع‌آوری‌شده از سه رودخانه مختلف در کره جنوبی، شامل

پل‌های هانگ، یوجو و گانگچونگ، طی یک دوره زمانی ۲۰۱۰ تا ۲۰۲۰ پرداختند. در این پژوهش، از مدل یادگیری عمیق پرسپترون مثبت و منفی (PNP) و LSTM برای پیش‌بینی دبی رودخانه‌ها استفاده شد. نتایج نشان داد که الگوریتم PNP در مقایسه با الگوریتم LSTM عملکرد بهتری در پیش‌بینی دبی رودخانه‌ها داشت. (Kedam et al. 2024) مطالعه‌ای بر روی پیش‌بینی جریان رودخانه با استفاده از داده‌های پنج ایستگاه رودخانه‌ای در رودخانه نرمد هند، طی یک بازه ۴۲ ساله (۱۹۷۸ تا ۲۰۲۰) انجام دادند. در این پژوهش از مدل‌های یادگیری ماشین شامل LGBM، CatBoost، جنگل تصادفی (Random Forest)، و XGBoost استفاده شد. نتایج نشان داد که مدل Random Forest قدرتمندترین مدل در شبیه‌سازی جریان رودخانه بود. (Albared et al. 2024) عملکرد پنج مدل یادگیری عمیق شامل LSTM، GRU، DCNN1، Bi-LSTM و ConvLSTM2 را برای پیش‌بینی جریان رودخانه در رودخانه Kille در غرب آلمان، طی یک دوره ۳۰ ساله (۱۹۹۳-۲۰۲۳) بررسی کردند. یافته‌ها نشان داد که مدل DCNN1 بهترین عملکرد را در پیش‌بینی جریان رودخانه داشت. (Ogunjo et al. 2024) از چهار الگوریتم یادگیری عمیق مختلف شامل GRY، TCN، LSTM و RNN برای پیش‌بینی جریان ماهانه رودخانه در امتداد رود نیجر در غرب آفریقا طی دوره‌ای ۴۰ ساله (۱۹۹۰-۱۹۵۰) استفاده کردند. نتایج نشان داد که مدل LSTM عملکرد بهتری داشت.

تمام مدل‌های ذکرشده در پیش‌بینی جریان رودخانه دارای سطوح مختلفی از دقت و خطا هستند. مرور ادبیات نشان می‌دهد که مدل‌های متنوعی مانند رگرسیون خطی، تکنیک‌های یادگیری ماشین مانند Random Forest و روش‌های یادگیری عمیق مانند (LSTM) برای پیش‌بینی جریان رودخانه به‌کار گرفته شده‌اند اما با چالش‌هایی مانند دقت پایین در شرایط نوسانی و پیچیدگی محاسباتی بالا مواجه هستند. این محدودیت‌ها، نیاز به روش‌های کارآمدتر را برجسته می‌کنند. بنابراین، در این مطالعه از مدل ترکیبی SNIP-ANN استفاده شده است؛ مدلی که الگوریتم نوآورانه حساس غیرخطی تکراری قله‌ای (SNIP) را با شبکه‌های عصبی مصنوعی (ANN) ترکیب می‌کند. الگوریتم پیش از این در مسائل مرتبط با منابع آبی مورد استفاده قرار نگرفته و این مطالعه، قابلیت کاربرد و عملکرد آن را در پیش‌بینی جریان رودخانه، از طریق کاهش پیچیدگی محاسباتی و بهبود در مدیریت داده‌های نوسانی، ارزیابی می‌کند. این مدل ترکیبی، راه‌حلی نویدبخش برای رفع کمبودهای مدل‌های پیشین ارائه می‌دهد.

¹ Symbolic Regression

تجزیه جریان ماهانه این رودخانه‌ها استفاده می‌کند و به بهبود مدیریت منابع آب، تولید انرژی و حفاظت زیستگاه‌ها کمک می‌کند. در نهایت، به دلیل عدم قطعیت در پیش‌بینی جریان رودخانه، استفاده از روش‌های جدید که بتواند دقت مدل را افزایش دهند، ضروری به نظر می‌رسد. هدف خاص این مطالعه، ارزیابی عملکرد مدل ترکیبی SNIP-ANN در بهبود دقت پیش‌بینی جریان ماهانه رودخانه‌های کلمبیا و نیجر است تا برنامه‌ریزی و مدیریت منابع آبی بهینه‌تری انجام شود.


۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

این مطالعه بر دو رودخانه بزرگ و کلیدی، کلمبیا و نیجر، متمرکز است. رودخانه کلمبیا با حوضه‌ای به مساحت ۷۲۴,۰۲۵ کیلومتر مربع و طولی بیش از ۲۰۰۰ کیلومتر، از کوه‌های راکی کانادا سرچشمه گرفته و به اقیانوس آرام می‌ریزد. این رودخانه، یکی از بزرگ‌ترین رودخانه‌های آمریکای شمالی، منبع اصلی آب برای کشاورزی، تولید برق آبی و زیستگاه گونه‌های آبی مانند ماهی سالمون در شمال غرب اقیانوس آرام و جنوب غرب کانادا است (Stanford et al., 2023). رودخانه نیجر با طول ۴۲۰۰ کیلومتر و حوضه‌ای حدود ۲ میلیون کیلومتر مربع، از کشورهای گینه، مالی، نیجر، نیجریه و بنین عبور کرده و منبع کلیدی آب شیرین در غرب آفریقا محسوب می‌شود. این رودخانه در کشاورزی، حمل‌ونقل، تولید برق آبی و حمایت از اکوسیستم‌ها و توسعه اقتصادی-اجتماعی منطقه نقش مهمی دارد (Abdoulaye et al. 2021). مدیریت پایدار این رودخانه‌ها برای حفظ اکوسیستم‌ها و تأمین نیازهای جوامع محلی حیاتی است. داده‌های جریان ماهانه برای ایستگاه Below Rock Island در رودخانه کلمبیا (۲۰۲۲-۲۰۰۰) و ایستگاه Niamey در رودخانه نیجر (۲۰۲۳-۲۰۰۰) از وبسایت مرکز جهانی داده‌های رودخانه‌ای (GRDC)، جمع‌آوری شد. این داده‌ها شامل جریان ماهانه (بر حسب متر مکعب بر ثانیه) است که برای تحلیل سری زمانی و مدل‌سازی استفاده شد. ویژگی‌های آماری داده‌ها در جدول ۱ ارائه شده است و شکل ۱ نیز موقعیت جغرافیایی رودخانه‌های کلمبیا و نیجر را در مناطق مورد مطالعه نشان می‌دهد.

کاربرد الگوریتم SNIP در حوزه منابع آب محدود بوده و بیش‌تر در تصویربرداری پزشکی مورد استفاده قرار گرفته است (Arbic II and Bukshtynov, 2024). این الگوریتم توانایی بالایی در پردازش نواحی پیچیده و غیرمنتظم سرطانی، حتی نقاط کوچک، دارد و کیفیت تصویر بالایی ارائه می‌دهد. افزون بر این، از مدل SNIP در سیستم‌های تعامل انسان و رایانه برای افزایش بهره‌وری و تجربه کاربری از طریق بهبود در مدل‌های تشخیص گفتار استفاده شده است. در سیستم‌های تعاملی چندوجهی، این مدل عملکردی به مراتب بهتر از روش‌های دیگر از خود نشان داده و موجب بهبود کیفیت تعامل می‌شود (Zhang, 2024). همچنین این مدل در مدل‌های پیچیده در فیزیک، زمین‌شناسی، و شیمی نیز به کار رفته و انعطاف‌پذیری بالای آن در حوزه‌های علمی مختلف را نشان می‌دهد (Arbic II and Bukshtynov, 2024). افزون بر این، مدل SNIP در مطالعات اقتصادی نیز مورد توجه قرار گرفته و کاربرد آن در مدیریت عملکرد شرکت‌های متوسط و بزرگ پیشنهاد شده است.

با وجود پژوهش‌های گسترده در زمینه پایش و شبیه‌سازی جریان رودخانه با استفاده از مدل‌های مختلف، هیچ‌یک از مطالعات پیشین بر تجزیه و تحلیل سری زمانی جریان رودخانه تمرکز نداشته‌اند. در این پژوهش، ما از الگوریتم حساس غیرخطی تکراری پیک (SNIP) به عنوان روشی نوین در آمار برای تجزیه سری زمانی جریان ماهانه رودخانه استفاده می‌کنیم. این الگوریتم با توانایی بالای خود در مدیریت داده‌های غیرخطی و نوسانی، گزینه‌ای مناسب برای کاربردهای پیش‌بینی جریان ماهانه به شمار می‌رود. به‌ویژه، توانایی الگوریتم SNIP در شناسایی و ساده‌سازی الگوهای غیرخطی پیچیده، اثربخشی آن را در تجزیه و تحلیل داده‌های سری زمانی جریان رودخانه افزایش می‌دهد. تجزیه سری زمانی به کمک این الگوریتم، موجب بهبود و بهینه‌سازی عملکرد مدل‌های یادگیری عمیق در پیش‌بینی جریان رودخانه می‌شود. این مطالعه از داده‌های مربوط به رودخانه‌های کلمبیا و نیجر استفاده می‌کند، چراکه هر دو رودخانه منابع حیاتی آب شیرین در مناطق خود به‌شمار می‌روند و نقش مهمی در سیاست‌های آبی، اقتصاد و مدیریت منابع طبیعی دارند. با توجه به اهمیت آن‌ها و کمبود مطالعات جامع در زمینه تجزیه سری زمانی جریان آن‌ها، این پژوهش از روش آماری نوآورانه SNIP برای



شکل ۱- نقشه موقعیت جغرافیایی رودخانه های کلمبیا و نیجر
Figure 1. Geographical location of the Columbia and Niger rivers

جدول ۱- مشخصات آماری و مختصات جغرافیایی رودخانه ها

Table 1. Statistical characteristics and geographic coordinates of the rivers

River	Station	Geographical Latitude	Geographical Longitude	Number of Data (month)	Mean (m ³ /s)	Min (m ³ /s)	Max (m ³ /s)	Standard Deviation
Columbia	Below Rock Island	36.91	54.41	276	3168.29	1515.55	7738.03	1175.83
Niger	Niamey	13.52	2.09	288	936.45	8.51	2239.32	621.374

میانگین شمارش ها در دو انتهای یک بازه نمونه برداری و هم چنین مقدار شمارش کانال در مرکز بازه جایگزین می شود که به این بازه، پنجره برش (w) گفته می شود و اندازه آن به صورت متغیر انتخاب می شود. در مرحله بعد، این عملیات در چندین مرحله تکرار می شود تا زمانی که همگرایی حاصل شود و تخمین پس زمینه به صورت دقیق و قابل قبولی انجام شود و بخش پس زمینه از داده ها حذف شود. پس از آن، به دلیل گستردگی دامنه شمارش ها در داده های طیفی و سری های زمانی، یک مرحله پیش پردازش به نام عملگر ریشه مربع لگاریتمی (LLS) بر داده ها اعمال می شود که این عمل باعث فشردگی دامنه مقادیر شده و در عین حال موجب افزایش وضوح و آشکارسازی قله های کوچک موجود در داده ها می شود (Morháč and Matoušek 2008).

گام اصلی الگوریتم شامل پیش پردازشی به نام عملگر لگاریتمی ریشه دوم (LLS) است که برای فشردگی دامنه داده و تقویت

۲-۲- الگوریتم (SNIP)

الگوریتم SNIP به عنوان روشی برای جداسازی اطلاعات مفید در قله ها از داده های پس زمینه یا نامربوط معرفی شده است. هدف این الگوریتم، برآورد پس زمینه ناشی از مؤلفه های خطی و غیرخطی در نواحی پایین تر قله ها در نمودارهاست (Omer, 2013). این روش با استفاده از مکانیزم "برش قله" به صورت تکراری، سطح پس زمینه را تخمین زده و هم زمان ویژگی های مهم سیگنال را حفظ می کند. در این فرآیند، مقدار هر کانال بر اساس مقادیر همسایه تنظیم می شود تا بازنمایی دقیق تری از سیگنال اصلی و کاهش نویز حاصل شود (Wang et al., 2020). در مقایسه با سایر روش ها، الگوریتم SNIP دقت بالاتری در تحلیل سیگنال، به ویژه در حوزه هایی مانند هیدرولوژی، پزشکی و تحلیل فلورسانس پرتو ایکس دارد. الگوریتم SNIP در چند مرحله متوالی اجرا می شود. در اولین مرحله که مربوط به تخمین اولیه پس زمینه است، مقدار شمارش در هر کانال با حداقل مقدار

غیرخطی میان متغیرها هستند (Aichouri et al., 2015). ساختار پایه شبکه‌های عصبی شامل سه بخش اصلی است: لایه ورودی که داده‌های خام را دریافت می‌کند، لایه‌های پنهان که پردازش اصلی اطلاعات را انجام می‌دهند، و لایه خروجی که نتایج نهایی مدل را تولید می‌کند. هر نورون در یک لایه به تمام نورون‌های لایه بعد متصل است و این اتصالات دارای وزن‌هایی (Weights) هستند که اهمیت هر ورودی را تعیین می‌کنند. مجموع ورودی‌های وزن‌دار به همراه یک بایاس (bias) به یک تابع فعال‌ساز (Activation Function) مانند سیگموئید، ReLU یا تانژانت هایپربولیک وارد می‌شود تا خروجی نهایی آن نورون تولید شود. معماری شبکه می‌تواند بسته به نوع مسئله تغییر کند. به طور مثال، در پیش‌بینی سری‌های زمانی مانند جریان رودخانه، معمولاً از شبکه‌های پرسپترون چندلایه (MLP) به صورت Feedforward استفاده می‌شود، در حالی که برای داده‌های ترتیبی یا وابسته به زمان، ممکن است از شبکه‌های بازگشتی (RNN) بهره گرفته شود. در کاربردهای هیدرولوژیکی، شبکه‌های عصبی مصنوعی به طور گسترده برای مدل‌سازی و پیش‌بینی دبی جریان رودخانه‌ها مورد استفاده قرار گرفته‌اند (Hsieh and Bartos, 2000; Araujo et al., 2011; Roshni et al., 2020). این مدل‌ها توانایی تحلیل داده‌های مختلف از جمله بارش، دما، تبخیر و دبی را داشته و می‌توانند الگوهای پنهان در داده‌ها را استخراج کنند. یکی از مهم‌ترین مزایای ANN، توانایی یادگیری از داده‌های گذشته و تعمیم آن برای پیش‌بینی‌های آینده است. همچنین این شبکه‌ها مقاومت بالایی در برابر داده‌های نویزی یا ناقص دارند و در شرایط پیچیده محیطی، عملکرد قابل‌قبولی ارائه می‌دهند. در مدل ANN رابطه بین ورودی و خروجی به صورت رابطه ۴ نوشته می‌شود:

$$Y = f(W_1X_1 + W_2X_2 + \dots + W_nX_n + b) \quad (4)$$

در رابطه فوق f تابع تحریک، b خطاها و w وزن گرہ‌ها می‌باشد.

۲-۴- الگوریتم هیبریدی SNIP-ANN

مدل ترکیبی SNIP-ANN با تلفیق الگوریتم حساس و تکرارشونده SNIP و شبکه‌های عصبی مصنوعی (ANN) دقت بالاتری در تحلیل سری‌های زمانی پیچیده مانند جریان رودخانه ارائه می‌دهد. الگوریتم SNIP با حذف نویز و جداسازی مؤلفه‌های پایه و پیک، به ANN کمک می‌کند تا الگوهای غیرخطی را بهتر شناسایی کند. از سوی دیگر، ترکیب این الگوریتم با ANN منجر به ساده‌سازی معماری شبکه، کاهش بیش‌برازش، و افزایش سرعت یادگیری و دقت مدل می‌شود. این مدل ترکیبی با بهره‌گیری از توانایی الگوریتم SNIP در شناسایی دقیق ویژگی‌های سیگنال و قدرت ANN در یادگیری عمیق، به مدلی

قله‌های کوچک‌تر استفاده می‌شود. تبدیل داده‌ها با استفاده از رابطه ۱ انجام می‌شود:

$$T_l(i) = \log \left(\log \sqrt{T_s(i)} + 1 + 1 \right) + 1 \quad (1)$$

که در آن، (i) شماره کانال مورد نظر است و تعداد کانال‌های قبل از تبدیل و $T_l(i)$ تعداد کانال‌های تبدیل شده جدید می‌باشد.

مقدار جدید کانال i با در نظر گرفتن حداقل تعداد کانال و میانگین تعداد w طبق رابطه ۲ بدست می‌آید:

$$\text{Min} \left\{ T_l(i), \frac{(T_l(i+w) + T_l(i-w))}{2} \right\} = T_c(i) \quad (2)$$

پس‌زمینه تخمینی $B(i)$ به سادگی با اعمال عملگر معکوس LLS از طریق رابطه ۳ به‌دست می‌آید.

$$B(i) = LLS^{-1}(T_c(i)) \quad (3)$$

این مرحله نقش کلیدی در بهبود عملکرد الگوریتم، خصوصاً در داده‌هایی که دارای نویز شدید و هم‌پوشانی سیگنال‌ها هستند، ایفا می‌کند.

همانطور که در شکل ۲ نشان داده شده، ابتدا الگوریتم SNIP سری زمانی مشاهده‌شده را به دو مؤلفه جدا تقسیم می‌کند. سپس هر مؤلفه به صورت جداگانه با استفاده از شبکه عصبی مصنوعی (ANN) پردازش می‌شود و در نهایت خروجی‌ها برای بازسازی سری زمانی پیش‌بینی‌شده ترکیب می‌شوند. این رویکرد با تفکیک داده به اجزای معنادار و بهره‌گیری از ANN، دقت پیش‌بینی را افزایش می‌دهد. الگوریتم SNIP در تحلیل سری‌های زمانی پیچیده و چندبعدی بسیار مؤثر است، به‌ویژه جایی که شناسایی دقیق قله‌ها و حذف نویز اهمیت زیادی دارد.

مدل SNIP یک رویکرد نوآورانه است که برای حذف نویز پس‌زمینه و شناسایی ویژگی‌های کلیدی در سری‌های زمانی و دیگر مجموعه داده‌های پیچیده طراحی شده است. این مدل امکان استخراج اطلاعات معنادار را فراهم می‌کند درحالی‌که داده‌های غیرمرتبط را فیلتر می‌کند. این مدل شامل سطوح مختلف تجزیه نمی‌شود و به‌جای آن از مکانیزم برش پیک و تصحیح تکراری برای جداسازی سیگنال از نویز استفاده می‌کند. در این مطالعه، داده‌ها با استفاده از نرم‌افزار Mathematica پردازش و تقسیم‌بندی شدند.

۲-۳- شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی دسته‌ای از الگوریتم‌های محاسباتی هستند که با الهام از ساختار مغز انسان، توانایی پردازش و تحلیل داده‌ها را به شیوه‌ای مشابه سیستم عصبی بیولوژیکی دارند. این شبکه‌ها از مجموعه‌ای از واحدهای پردازشی به هم‌پیوسته به نام نورون مصنوعی تشکیل شده‌اند که به صورت موازی و لایه‌ای عمل می‌کنند و قادر به شناسایی و مدل‌سازی روابط خطی و

۲-۵- پارامترهای ارزیابی

به منظور بررسی عملکرد مدل های مذکور، از ۲ پارامتر ارزیابی ریشه میانگین مربع خطا (RMSE)، ضریب همبستگی (R)، استفاده شده است. رابطه پارامترهای مذکور به شرح زیر است:


$$R = \frac{\sum_{i=1}^{i=N} (o(i) - \bar{o})(p(i) - \bar{p})}{\sqrt{\sum_{i=1}^{i=N} (o(i) - \bar{o})^2} \sqrt{\sum_{i=1}^{i=N} (p(i) - \bar{p})^2}} \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^{i=N} (o(i) - p(i))^2} \quad (6)$$

در معادلات فوق، $o(i)$ مقادیر مشاهداتی، $p(i)$ مقادیر محاسباتی، N تعداد کل داده ها، $\bar{o}$ میانگین مقادیر مشاهداتی و $\bar{p}$ میانگین مقادیر محاسباتی می باشند. هرچه قدر نتایج RMSE به عدد صفر نزدیک تر باشد عملکرد مدل بهتر است. ضریب همبستگی (r) عددی بین -۱ تا ۱ است. مقدار ($r=1$) نشان دهنده یک رابطه خطی کاملاً مثبت بین دو متغیر است، درحالی که مقدار ($r=-1$) بیانگر یک رابطه خطی کاملاً منفی است. اگر ضریب همبستگی برابر با صفر باشد، یعنی هیچ رابطه خطی بین دو متغیر وجود ندارد (Mahaki et al. 2024).


مراحلی که برای پیش بینی و ارزیابی مدل ها انجام شده است، از جمله جمع آوری داده ها، مدل سازی با الگوریتم SNIP و شبکه عصبی مصنوعی (ANN)، و ارزیابی با استفاده از معیارهایی مانند RMSE و R، در شکل ۳ نشان داده شده است.

قدرتمند و دقیق برای تحلیل داده های سری زمانی تبدیل شده است. همچنین، توان پردازش بالا و ساختار بهینه شده آن، استفاده از این مدل را در شرایط پیچیده و داده های حجیم تسهیل می کند. در این مطالعه، مدل SNIP-ANN برای پیش بینی دبی ماهانه رودخانه های کلمبیا و نیجر به کار گرفته شد. تنها ورودی مدل، دبی (Q) بود و تحلیل تأخیر زمانی حداکثر سه ماهه ($Q(t-1)$ ، $Q(t-2)$ ، $Q(t-3)$) انجام گرفت. نتایج نشان داد تأخیر سه ماهه ($Q(t-3)$) بهترین عملکرد را در پیش بینی دارد و به عنوان ورودی اصلی انتخاب شد. برای تحلیل تأخیرها از روش ACF (Autocorrelation Function) استفاده شد، که به کمک آن مشخص شد که بیشترین همبستگی زمانی مربوط به تأخیر سه ماهه است. به طور کلی، ACF برای شناسایی الگوهای همبستگی در داده های زمانی و تعیین تأخیرهای بهینه در مدل های پیش بینی به کار می رود. برای آموزش مدل، از ۲۰۵ ماه داده برای رودخانه کلمبیا و ۲۰۲ ماه برای رودخانه نیجر استفاده شد، و به ترتیب ۶۸ و ۸۳ ماه برای اعتبارسنجی اختصاص یافت. هدف اصلی، طراحی مدلی ساده، کاربردی و دقیق تنها با استفاده از داده های تاریخی دبی بود تا به راحتی در شرایط واقعی قابل پیاده سازی باشد. همچنین، این روش قابلیت تعمیم پذیری خوبی برای سایر حوزه های کاربردی مانند هواشناسی و اقتصاد دارد. استفاده از مدل های کم پارامتر و سریع، امکان پیاده سازی در محیط های فاقد زیرساخت های پیچیده را فراهم می کند. این ویژگی ها، مدل SNIP-ANN را به گزینه ای مناسب برای پیش بینی های بلندمدت و مدیریت منابع آب تبدیل کرده اند.



شکل ۲- نمودار کلی جریان برای بخش بندی داده های سری زمان

Fig 2-The overall flowchart for time series data sementation



شکل ۳- فلوچارت مراحل انجام پژوهش


Figure 3- Research process flowchart

۳- نتایج و بحث

ارزیابی مدل‌های پیش‌بینی این امکان را فراهم می‌آورد که دقت پیش‌بینی آن‌ها با مقایسه مقادیر پیش‌بینی‌شده و نتایج واقعی سنجیده شود (Armstrong, 2001). برای برآورد دبی جریان در رودخانه‌های کلمبیا و نیجر، از داده‌های ماهانه ایستگاه‌های منتخب استفاده شد که شامل داده‌های دبی جریان با سه تأخیر زمانی بود. شکل ۴ داده‌های ورودی و دبی ماهانه رودخانه‌های نیجر و کلمبیا را در دوره مطالعه نشان می‌دهد. این نمودار با نمایش نوسانات زمانی جریان، به انتخاب بخش‌های مناسب داده برای مدل‌سازی و بهبود دقت پیش‌بینی کمک می‌کند. در این مطالعه، دبی ماهانه جریان با استفاده از تأخیرهای زمانی یک، دو و سه ماهه مدل‌سازی شد که تأثیر مقادیر گذشته بر دبی جاری رودخانه را نشان می‌دهند. با این حال، تحلیل نتایج نشان داد که تأخیر سه‌ماهه $Q(t-3)$ بهترین عملکرد را داشت و به‌عنوان ورودی مناسب برای این مطالعه انتخاب شد. استفاده از تأخیرهای بیش‌تر (۴ یا ۵ ماهه) ممکن است به افزایش نویز، کاهش دقت، پیش‌بینی‌های پیچیده‌تر و کاهش کارایی مدل منجر شود. این انتخاب بر اساس همبستگی قوی بین دبی جریان و عوامل مؤثر در یک بازه زمانی سه‌ماهه، از جمله الگوهای فصلی، تغییرات

بارش، ذخیره آب‌های زیرزمینی و دیگر پارامترهای هیدرولوژیکی بود. استفاده از تأخیر سه‌ماهه به مدل کمک می‌کند تا روابط بلندمدت موجود در داده‌ها را به‌طور دقیق‌تر شبیه‌سازی کند و منجر به بهبود قابل‌توجه در دقت پیش‌بینی و کاهش خطای مدل (RMSE) شود. علاوه بر این، تأخیر سه‌ماهه هم در داده‌های آموزشی و هم در داده‌های آزمایشی اعمال شد تا اطمینان حاصل شود که مدل به‌طور مؤثر روابط دینامیکی موجود در داده‌ها را یاد می‌گیرد و از مشکلاتی مانند بیش‌برازش^۱ جلوگیری می‌کند. این مقایسه به انتخاب مناسب‌ترین مدل برای مجموعه داده‌های خاص و چالش‌های پیش‌بینی کمک می‌کند و عملکرد مدل را بهبود می‌بخشد. علاوه بر این، ۷۰ درصد از داده‌ها برای آموزش و ۳۰ درصد برای آزمایش اختصاص داده شد. برای پیش‌بینی دبی جریان دو رودخانه، ابتدا مدل شبکه عصبی مصنوعی (ANN) پیاده‌سازی شد که سپس با استفاده از مدل نوآورانه SNIP تقویت شد. علاوه بر این، پارامترهای داخلی مانند تعداد مراحل تکرار و استفاده از عملگر ریشه مربعی لگاریتمی (LLS) قابل تنظیم هستند تا عملکرد مدل بهینه شود.

¹ Overfitting



شکل ۴- نمودار سری زمانی دبی جریان رودخانه های کلمبیا و نیجر
Figure 4- Monthly input data for Columbia River and Niger River

همبستگی ۱۳۰/۹ درصد برای کلمبیا و ۱۵/۸۷ درصد برای نیجر نشان دهنده توان بالاتر مدل SNIP-ANN در شناسایی روابط اساسی بین متغیرهای ورودی و دینامیک جریان رودخانه است. در مقابل، مدل ANN به تنهایی نتوانست دقت مشابهی را به دست آورد، به ویژه برای رودخانه کلمبیا که RMSE آن بسیار بالا بود و ضریب همبستگی آن نشان دهنده ارتباط ضعیف تری بین مقادیر پیش بینی شده و مشاهده شده است. این موضوع حاکی از آن است که مدل ANN به تنهایی ممکن است بیش تر در معرض بیش برآزش یا تأثیر نویز قرار گیرد که منجر به عملکرد ضعیف تری در تعمیم پذیری پیش بینی های هیدرولوژیکی می شود. در مجموع، بهبود چشم گیر عملکرد پیش بینی با استفاده از مدل SNIP-ANN پتانسیل بالای آن را برای کاربرد در مدل سازی هیدرولوژیکی، به ویژه در پیش بینی دبی رودخانه، نشان می دهد. این مدل به دلیل توانایی بالا در مدیریت الگوهای پیچیده جریان، به ویژه در زمان رخداد های شدید هیدرولوژیکی، به عنوان ابزاری نوید بخش برای مدیریت منابع آب و پیش بینی سیلاب مطرح است. پژوهش های آینده می توانند به بررسی ادغام روش های پیش پردازش اضافی یا رویکردهای یادگیری گروهی^۱ برای افزایش بیش تر دقت پیش بینی در شرایط متنوع هیدرولوژیکی بپردازند.


جدول ۲ ارزیابی عملکرد مدل های مورد مطالعه را با استفاده از دو معیار آماری کلیدی، یعنی ضریب همبستگی (R) و ریشه میانگین مربعات خطا (RMSE) ارائه می دهد. نتایج نشان می دهد که مدل ترکیبی SNIP-ANN به طور پیوسته عملکرد بهتری نسبت به مدل تنها ANN در هر دو رودخانه مورد بررسی، یعنی کلمبیا و نیجر، داشته است. برای رودخانه کلمبیا، مدل SNIP-ANN به ضریب همبستگی ۰/۷۵۰۳ و RMSE معادل ۸۶۵/۲۳ دست یافت، در حالی که مدل ANN به طور قابل توجهی R پایین تری معادل ۰/۳۲۴۹ و RMSE بالاتری معادل ۱۳۲۵/۹۹ داشت. به طور مشابه، برای رودخانه نیجر نیز مدل SNIP-ANN عملکرد پیش بینی بهتری از خود نشان داد و به ضریب همبستگی ۰/۹۲۸۶ و RMSE برابر با ۲۳۱/۴۹۷ دست یافت، در حالی که مدل ANN دارای R معادل ۰/۸۰۱۴ و RMSE معادل ۴۸۷/۸۸۳ بود. این یافته ها نشان می دهد که استفاده از تکنیک پیش پردازش SNIP، توان پیش بینی مدل ANN را از طریق حذف نویز پس زمینه و استخراج ویژگی های کلیدی از داده های سری زمانی هیدرولوژیکی به طور مؤثری افزایش داده است. کاهش قابل توجه RMSE به میزان ۳۴/۷۵ درصد برای رودخانه کلمبیا و ۵۲/۵۶ درصد برای رودخانه نیجر، توانایی مدل ترکیبی را در کاهش خطاهای پیش بینی نشان می دهد. همچنین، بهبود ضریب

¹ Ensemble

جدول ۲- معیارهای عملکرد در فرایند آزمایش برای مدل‌های ANN و SNIP-ANN

Table 2-Performance Metric in the Experimental Process for ANN and SNIP-ANN Models

River	Model	RMSE	R
Columbia	SNIP-ANN	865.23	0.7503
	ANN	1325.99	0.3249
Niger	SNIP-ANN	231.497	0.9286
	ANN	487.883	0.8014



شکل ۵- نمودار سری زمانی مقادیر مشاهداتی نسبت به محاسباتی در مرحله آزمون

Figure 5- Time series plot of observed versus predicted values in the test stage


در شکل ۶، نمودارهای پراکندگی نشان می‌دهند که مدل SNIP-ANN در پیش‌بینی دبی ماهان رودخانه‌های کلمبیا و نیجر عملکرد دقیق‌تری نسبت به مدل ANN دارد؛ زیرا نقاط در این مدل به‌صورت متمرکزتر اطراف خط $x=y$ (خط ۱:۱) و خط رگرسیون خطی قرار گرفته‌اند، درحالی‌که در مدل ANN نقاط پراکندگی بیش‌تری نسبت به هر دو خط $x=y$ و خط رگرسیون خطی نشان می‌دهند. در شکل ۷، نمودارهای ویولون توزیع داده‌های پیش‌بینی‌شده توسط مدل‌ها را نشان می‌دهند. در این نمودار، توزیع دبی پیش‌بینی‌شده توسط SNIP-ANN با توزیع داده‌های واقعی تطابق بیش‌تری دارد، درحالی‌که مدل ANN انحراف بیش‌تری از توزیع واقعی دارد. این نتایج نشان می‌دهند که مدل SNIP-ANN در استخراج ویژگی‌های مهم و حذف نویز موفق‌تر بوده و توانایی بیش‌تری در پیش‌بینی دقیق جریان

شکل ۵ مقایسه‌ای از سری زمانی بین مدل‌های ANN و SNIP-ANN برای پیش‌بینی دبی ماهانه رودخانه‌های کلمبیا و نیجر را نشان می‌دهد که تفاوت‌های موجود در دقت پیش‌بینی این مدل‌ها را برجسته می‌سازد. این مقایسه بینش‌های ارزشمندی درباره عملکرد هر دو مدل و توانایی آن‌ها در شناسایی الگوهای هیدرولوژیکی ارائه می‌دهد. نتایج نشان می‌دهند که مدل ANN در نقاط متعددی اختلاف قابل‌توجهی بین مقادیر واقعی و پیش‌بینی‌شده دارد. در برخی موارد، این مدل دچار بیش‌برآورد می‌شود، به‌گونه‌ای که بیش از حد به داده‌های آموزش وابسته شده و توانایی تعمیم به ورودی‌های جدید را از دست می‌دهد. در مقابل، در برخی شرایط دیگر مدل دچار کم‌برآورد می‌شود و از تشخیص الگوهای اساسی در داده‌های سری زمانی ناتوان می‌ماند. همچنین، مدل ANN در مواجهه با نوسانات شرایط جریان شدید عملکرد ضعیفی دارد و در دوره‌های اوج و افت جریان، انحرافات بیش‌تری را نشان می‌دهد. این محدودیت‌ها باعث کاهش قابلیت اطمینان مدل در پیش‌بینی تغییرات ناگهانی در دبی جریان می‌شود. در مقابل، مدل SNIP-ANN پیش‌بینی‌هایی ارائه می‌دهد که با مقادیر واقعی هماهنگی بیش‌تری دارند و حاشیه خطای به‌مراتب پایین‌تری در هر دو رودخانه نشان می‌دهد. این عملکرد بهبود یافته را می‌توان به توانایی این مدل در فیلتر کردن نویز، استخراج ویژگی‌های مهم و درک بهتر وابستگی‌های غیرخطی بین مقادیر گذشته و فعلی جریان نسبت داد. علاوه بر این، مدل SNIP-ANN انعطاف‌پذیری بیش‌تری در مقابله با الگوهای پیچیده هیدرولوژیکی از خود نشان می‌دهد و پیش‌بینی‌های دقیق‌تری را در طول نوسانات فصلی و رخداد‌های شدید ارائه می‌دهد. این یافته‌ها بر اثربخشی مدل هیبریدی SNIP-ANN در غلبه بر محدودیت‌های مدل‌های سنتی ANN تأکید دارند. دقت بالاتر و پایداری بیش‌تر این مدل، آن را به ابزاری امیدبخش برای پیش‌بینی هیدرولوژیکی، مدیریت ریسک سیلاب و برنامه‌ریزی پایدار منابع آبی تبدیل کرده است. پژوهش‌های آینده می‌توانند مقایسه این مدل را با سایر تکنیک‌های یادگیری ماشین بررسی کرده و تأثیر ویژگی‌های ورودی مختلف بر عملکرد مدل را برای بهبود بیش‌تر قابلیت‌های پیش‌بینی تحلیل کنند.


استفاده از مدل شبکه عصبی مصنوعی (ANN) و الگوریتم بهینه‌سازی فراابتکاری (CS-ANN) پرداختند. نتایج نشان داد که مدل هیبریدی دقت قابل توجهی در پیش‌بینی دبی ماهانه نسبت به مدل ANN داشت. به‌طور کلی، می‌توان گفت که تلفیق شبکه‌های عصبی مصنوعی با الگوریتم‌های هوشمند بهینه‌سازی موجب ارتقای چشم‌گیر دقت در پیش‌بینی دبی رودخانه‌ها می‌شود. در پژوهش حاضر، برای اولین بار الگوریتم SNIP به‌عنوان روشی نوین در ترکیب با ANN به‌منظور پیش‌بینی دبی رودخانه استفاده شد که نشان‌دهنده پتانسیل بالای این الگوریتم در بهبود دقت پیش‌بینی است.

رودخانه دارد. این مدل توانست عملکرد پیش‌بینی را به‌طور چشم‌گیری بهبود بخشد. کاهش چشم‌گیر RMSE و افزایش ضریب همبستگی (R) در نتایج نشان‌دهنده دقت بالای مدل SNIP-ANN نسبت به ANN معمولی است. در پژوهش (Yadav et al. (2020) به‌منظور پیش‌بینی دبی روزانه رودخانه، از مدل‌های شبکه عصبی مصنوعی ANN، الگوریتم ژنتیک (GA) و مدل هیبریدی GA-ANN استفاده شد. طبق نتایج به‌دست آمده، مدل هیبریدی GA-ANN عملکرد بهتری نسبت به ANN به‌تنهایی داشت. در پژوهشی دیگر، Zaniyal et al. (2023) به پیش‌بینی دبی ماهانه رودخانه‌ای در مالزی با


Columbia river



Niger river



شکل ۶- نمودار پراکندگی مقادیر مشاهداتی نسبت به محاسباتی در مرحله آزمون
Figure 6- Scatter plot of the observed versus predicted values in the test stage



شکل ۷- نمودار ویولونی مقادیر مشاهداتی نسبت به محاسباتی در مرحله آزمون

Figure 7-Violin plot of the observed versus predicted values in the test stage

۴- نتیجه گیری

در این مطالعه، مدل هیبریدی SNIP-ANN به‌عنوان یک رویکرد نوآورانه برای پیش‌بینی دبی رودخانه‌ها بررسی و با مدل ANN مقایسه شد. نتایج نشان داد که مدل هیبریدی به‌طور قابل‌توجهی دقت پیش‌بینی را نسبت به مدل ANN بهبود بخشیده است. این مدل با استفاده از تأخیر زمانی سه ماهه در داده‌های ورودی، توانست نوسانات فصلی و تغییرات دوره‌ای جریان رودخانه را با دقت بالا شبیه‌سازی کند. در مقایسه با مدل ANN، مدل هیبریدی ضریب همبستگی را به‌طور چشم‌گیری افزایش داد و خطای پیش‌بینی را به میزان قابل‌توجهی کاهش داد. این بهبود به‌ویژه در شبیه‌سازی نوسانات شدید جریان رودخانه و حذف نویزهای اضافی داده‌ها مشهود بود. یافته‌ها نشان می‌دهد که مدل SNIP-ANN ابزاری کارآمد برای پیش‌بینی دبی رودخانه‌ها است و پتانسیل بالایی در مدیریت منابع آب، پیش‌بینی سیلاب و پیش‌بینی‌های هیدرولوژیکی بلندمدت دارد. مطالعه Zanial et al. (2023) در نیروگاه سلطان محمود شاه مالزی

نشان داد که مدل ترکیبی CS-ANN نسبت به ANN دقت بالاتری در پیش‌بینی جریان رودخانه برای تولید برق آبی دارد، که نشان دهنده دقت و عملکرد بالای مدل هیبریدی می‌باشد. با این حال، الگوریتم SNIP تاکنون در پیش‌بینی دبی جریان رودخانه استفاده نشده است، اما در حوزه‌های دیگر کاربردهای موفق داشته است. Omer (2013) با استفاده از SNIP در طیف‌سنجی مواد رادیواکتیو، وضوح انرژی را تا ۵۰ درصد بهبود دادند. همچنین Tomarchio et al. (2023) نشان دادند که SNIP در تحلیل طیف‌های پرتو گاما دقت و کارایی بالایی دارد و برای تخمین مقادیر پایه در طیف‌های هیدرولوژیکی قابل استفاده است. این یافته‌ها نشان‌دهنده پتانسیل بالای SNIP در بهبود دقت مدل‌های پیش‌بینی است و کاربرد آن در مطالعه حاضر، نوآوری قابل‌توجهی در پیش‌بینی دبی جریان رودخانه محسوب می‌شود. همچنین، این مدل می‌تواند در مقابله با چالش‌های ناشی از تغییرات اقلیمی و نوسانات هیدرولوژیکی نقش مؤثری ایفا کند.

سپاسگزاری

نویسندگان از کشورهای کلمبیا و نیجر برای در دسترس قرار دادن داده‌ها، قدردانی می‌نمایند.

تضاد منافع نویسندگان

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

دسترسی به داده‌ها

داده‌های دبی دو رودخانه از وبسایت مرکز جهانی داده‌های رودخانه‌ای (GRDC) تهیه، و کدهای ANN و SNIP-ANN Elbeltagi, A., Di Nunno, F., Kushwaha, N. L., et al. (2022). River flow rate prediction in the Des Moines watershed (Iowa, USA): A machine learning approach. *Stochastic Environmental Research and Risk Assessment*, 36(11), 3835–3855. doi: 10.1007/s00477-022-02240-3

Hamlet, A. F., & Lettenmaier, D. P. (1999). Columbia River streamflow forecasting based on ENSO and PDO climate signals. *Journal of Water Resources Planning and Management*, 125(6), 333–341.

Hayder, G., Solihin, M. I. (2020). Modelling of River Flow Using Particle Swarm Optimized Cascade-Forward Neural Networks: A Case Study of Kelantan River in Malaysia, *Applied Sciences*. doi: 10.3390/app10238670

Hsieh, B., & Bartos, C. L. (2000). Riverflow/River stage prediction for military applications using artificial neural network modeling. doi: 10.21236/ADA382991

Stanford, J. A., Thompson, A., Asher, E., Gregory, S. V., Reeves, G., Ratliff, D., Bouwes, N., Frissell, C., & Williams, R. N. (2023). Columbia River Basin. In *Rivers of North America* (2nd ed., pp. 558–615). Academic Press. doi: 10.1016/B978-0-12-818847-7.00020-3

Kedam, N., Tiwari, D., Kumar, V., Kh M., & Salem, M. A. (2024). River stream flow prediction through advanced machine learning models for enhanced accuracy. *Results in Engineering*, 22, 102215. doi: 10.1016/j.rineng.2024.102215

Mahaki, B., Jafari, S., Rezaei, M., & Solooki, L. (2024). Types of correlation coefficients in medical research using SPSS and R software. *Isfahan Medical School Journal*, 42(773), 560–573.

Morhác, M., Matoušek, V. (2008). Peak clipping algorithms for background estimation in spectroscopic data. *Applied spectroscopy*, 62(1), 91–106.

Ogunjo, S., Olusola, A., & Olusegun, C. (2024). Predicting river discharge in the Niger River

توسط نرم‌افزار Mathematica و اکسل اجرا شدند. همچنین نقشه موقعیت جغرافیایی رودخانه‌ها توسط ArcGIS و نمودارهای ویولونی و پراکندگی و سری زمانی توسط Mathematica اجرا شدند.

مشارکت نویسندگان

فاطمه وئوقی: مفهوم سازی، انجام تحلیل‌های نرم‌افزاری/آماري؛ محمدعلی قربانی: راهنمایی، ویرایش و بازبینی مقاله، کنترل نتایج، صابره دربندی: مفهوم سازی، تحلیل‌های آماری و نرم‌افزار.

References

- Abdoulaye, O. O., & Lu, H. (2021). Future irrigation water requirements of the main crops cultivated in the Niger River Basin. *Atmosphere*. doi: 10.3390/atmos12040439.
- Adnan, R., Yuan, X., et al. (2017). Improving Accuracy of River Flow Forecasting Using LSSVR with Gravitational Search Algorithm, *Advances in Meteorology*, 2017, 1–23. doi: 10.1155/2017/2391621
- Aichouri, I., Hani, A., Bougherira, N., Djabri, L., Chaffai, H., & Lallahem, S. (2015). River flow model using artificial neural networks. *Energy Procedia*, 74, 1007–1014. doi: 10.1016/j.egypro.2015.07.785
- Albared, M., Beise, H. P., & Stuber, M. (2024). Deep learning models for small rivers stream-flow forecasting and flood prediction. *Research Square (Preprint, Version 1)*.
- Armstrong, J. S. (2001). Evaluating forecasting methods. In *Principles of forecasting: A handbook for researchers and practitioners* (pp. 443–472).
- Araujo, P., Astray, G., Ferrerio-Lage, J. A., Mejuto, J. C., Rodriguez-Suárez, J. A., & Soto, B. (2011). Multilayer perceptron neural network for flow prediction. *Journal of Environmental Monitoring*, 13(1), 35–41. doi: 10.1039/C0EM00478B
- Arbic II, P. R., & Bukshtynov, V. (2024). Efficient gradient-based optimization for reconstructing binary images in applications to electrical impedance tomography. *Computational Optimization and Applications*, 88(1), 379–403. doi: 10.1007/s10589-024-00553-z
- Bak, G., Bae, Y. (2023). Deep learning algorithm development for river flow prediction: PNP algorithm, *Soft Computing*, 27, 13487–13515. doi: 10.1007/s00500-023-08254-1
- Bolshakov, V. (2013). *Regression-based Daugava River flood forecasting and monitoring*. Information Technology and Management Science, 16(1), 59–63. doi: 10.2478/itms-2013-0021

- Basin: A deep learning approach. *Applied Sciences*, 14(1), 12. doi: 10.3390/app14010012
- Omer, M. (2013). Analysis of SNIP algorithm for background estimation in spectra measured with LaBr3:Ce detectors. In *Proceedings of the XYZ Conference* (pp. 123-130). Springer. doi: 10.1007/978-4-431-54264-3_27
- Porporato, A., & Ridolfi, L. (2001). Multivariate nonlinear prediction of river flows. *Journal of Hydrology*, 248, 109–122.
- Roshni, T., Jha, M. K., & Drisya, J. (2020). Neural network modeling for groundwater-level forecasting in coastal aquifers. *Neural Computing and Applications*, 32, 12737–12754. doi: 10.1007/s00521-020-04722-z
- Wang, J., Pan, X., Li, W., & Zhang, M. (2020, December). PDSR: Optimization of SNIP pre-pruning algorithm based on dynamic sparsity rate. In *2020 2nd International Conference on Information Technology and Computer Application (ITCA)* (pp. 119–124). doi: 10.1109/ITCA52113.2020.00032
- Yadav, A., Prasad, B. B. V. S., Mojjada, R. K., Kothamasu, K. K., & Joshi, D. (2020). Application of artificial neural network and genetic algorithm based artificial neural network models for river flow prediction. *Rev. d'Intelligence Artif.*, 34(6), 745–751. doi: 10.18280/ria.340608
- Zanial, W. N. C., Abdul Malek, M. B., Md Reba, M. N., Zaini, N., Ahmed, A. N., Sherif, M., & Elshafie, A. (2023). River flow prediction based on improved machine learning method: Cuckoo Search-Artificial Neural Network. *Applied Water Science*, 13 (28), 1–10. doi: 10.1007/s13201-022-01830-0
- Zhang, Y. (2024). Application of speech recognition technology based on multimodal information in human-computer interaction. *International Journal of Advanced Computer Science and Applications*, 15(9). doi: 10.14569/IJACSA.2024.0150911