



Evaluating of the efficiency of hybrid artificial neural network models and Particle Swarm Optimization (PSO) algorithm in estimating suspended sediment, a case study of Kozehtopraghi and Hir chai hydrometric stations in Ardabil Province

Seyed Ahmad Hosseini^{1*} and Mahmoud Reza Tabatabaei²

¹ Associate Professor, , Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

² Associate Professor, , Soil Conservation and Watershed Management Research Institute, Agricultural Research, Education and Extension Organization (AREEO), Tehran, Iran

Received: 22 April 2024

Accepted: 25 September 2024

Extended abstract

Introduction

Simulating suspended sediment in hydrological systems has always been challenging due to inherent complexities and uncertainties. This issue has led to the use of intelligent models such as Artificial Neural Networks (ANNs) as a suitable approach for predicting suspended sediment load. Therefore, the use of intelligent models like ANNs has expanded in this field. However, determining the optimal network structure (including the number of neurons, layers, weights, and biases) is usually done through trial and error, which is both time-consuming and inefficient. In this study, a multilayer perceptron neural network was used to simulate the daily suspended sediment load in the Qarasu Sarab watershed (Quri Chay and Hir Chai rivers) located in Ardabil province, Iran.

Materials and methods

In this research, an Artificial Neural Network (ANN) of the Multilayer Perceptron (MLP) type was utilized to simulate the daily suspended sediment load in the Sarab Qareh Su watershed (including the Quri Chay and Hir Chay rivers) in Ardabil province. The neural network models were trained not only with the conventional backpropagation algorithm but also using the Particle Swarm Optimization (PSO) algorithm to optimize the weights and biases of the neurons. Furthermore, to increase the models' generalization capability, a Self-Organizing Map (SOM) clustering was employed. In addition to the backpropagation algorithm, the Particle Swarm Optimization (PSO) algorithm was also employed to optimize the network weights and biases. Furthermore, to enhance the model's generalization power, SOM clustering was used. The use of evolutionary algorithms such as PSO in training neural networks is an effective approach to improve the accuracy of intelligent models, especially in simulating river suspended sediment and applications related to water resources and watershed management structures.

Results and discussion

Using SOM clustering and the Davies-Bouldin index, the optimal number of clusters was determined as 12 for Koozeh Toupraqi station and 15 for Hir Chai station. Statistical analysis and the Kolmogorov-Smirnov (KS) test showed that data distributions across training, validation, and testing sets were similar, which enhances the generalization capability of the models. Training the neural network models with PSO yielded better performance and lower prediction errors compared to backpropagation. The ANN-PSO-Sig and ANN-PSO-Tan models achieved the best results at Koozeh Toupraqi and Hir Chai stations, respectively. Bias analysis further confirmed that PSO-trained models had lower errors in total sediment load estimation. Overall, results showed that PSO-based training outperforms pure backpropagation training. At Koozeh Toupraqi station, the hybrid ANN-PSO model with sigmoid activation function (ANN-PSO-Sig), and at Hir-Hirchai Topraghi station, the hybrid model with hyperbolic tangent activation function (ANN-PSO-Tan) were selected as optimal models, showing biases of +5.25% and -19.2% and RMSE values of 86.28

* Corresponding author: sahosseini@yahoo.com

and 89.2 tons per day, respectively. These findings demonstrate the improvement in suspended sediment load prediction accuracy by using PSO in neural network training.

Conclusion

The use of the PSO metaheuristic algorithm in training neural network models improved their performance in simulating suspended sediment load. This method outperformed gradient-based error algorithms and provided more accurate weight optimization. The improved bias accuracy in PSO-trained models is crucial for designing hydraulic structures and water resource management. Furthermore, SOM clustering helped select homogeneous and representative datasets for model training, enhancing model generalizability. Overall, considering the complexities and uncertainties in hydrological systems, employing intelligent models combined with evolutionary optimization algorithms like PSO is an effective approach for simulating and monitoring suspended sediment loads. The obtained results can be applied in planning and implementing watershed engineering measures and water resource management.

Keywords: Artificial neural network, Clustering, Self-organizing map, Sarab Qarasu, Suspended load

Cite this article: Hosseini, S.A., Tabatabaei, M.R., 2025. Evaluating of the efficiency of hybrid artificial neural network models and Particle Swarm Optimization (PSO) algorithm in estimating suspended sediment, a case study of Kozehtopraghi and Hir chai hydrometric stations in Ardabil Province. *Water. Eng. Manag.* 17(3), 285-301.

© 2025, The Author(s). Published by Soil Conservation and Watershed Management Research Institute (SCWMRI). This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>)



ارزیابی کارایی مدل‌های ترکیبی شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) در برآورد رسوبات معلق، مطالعه موردی ایستگاه‌های هیدرومتری کوزه توپراقی و هیرچای استان اردبیل

سید احمد حسینی^{۱*} و محمود رضا طباطبایی^۲

^۱ دانشیار پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

^۲ دانشیار پژوهشکده حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران

تاریخ پذیرش: ۱۴۰۳/۰۷/۰۴

تاریخ دریافت: ۱۴۰۳/۰۲/۰۳

چکیده مبسوط

مقدمه

شبیه‌سازی رسوب معلق در سیستم‌های هیدرولوژیکی به دلیل پیچیدگی‌ها و عدم قطعیت‌های ذاتی، همواره چالش‌برانگیز بوده است. این مسأله موجب شده تا استفاده از مدل‌های هوشمند مانند شبکه‌های عصبی مصنوعی به عنوان راهکاری مناسب برای پیش‌بینی بار رسوب معلق مطرح شود. به همین دلیل، استفاده از مدل‌های هوشمند نظیر شبکه‌های عصبی مصنوعی (ANN) در این زمینه گسترش یافته است. با این حال، تعیین ساختار بهینه شبکه (شامل تعداد نوروها، لایه‌ها، وزن‌ها و بایاس‌ها) معمولاً به روش آزمون و خطا انجام می‌شود که هم زمان‌بر و هم ناکارآمد است. در این پژوهش، به منظور شبیه‌سازی بار رسوب معلق روزانه در حوزه آبخیز سراب قره‌سو (رودخانه‌های قوری‌چای و هیرچای) واقع در استان اردبیل، از شبکه عصبی پرسپترون چندلایه بهره گرفته شد.

مواد و روش‌ها

در این پژوهش، به منظور شبیه‌سازی بار رسوب معلق روزانه در حوزه آبخیز سراب قره‌سو (رودخانه‌های قوری‌چای و هیرچای) در استان اردبیل، از شبکه عصبی پرسپترون چندلایه بهره گرفته شد. آموزش مدل‌های شبکه عصبی علاوه بر روش متداول پس‌انتشار خطا، با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات (PSO) برای بهینه‌سازی وزن‌ها و بایاس‌های نوروها انجام شد. همچنین به منظور افزایش قدرت تعمیم‌دهی مدل‌ها، از خوشه‌بندی نگاشت خودسازمان‌ده (SOM) استفاده شد. برای بهینه‌سازی وزن‌ها و بایاس‌های شبکه، علاوه بر روش پس‌انتشار خطا، الگوریتم بهینه‌سازی ازدحام ذرات (PSO) نیز به کار رفت. همچنین جهت افزایش قدرت تعمیم مدل‌ها، از خوشه‌بندی نگاشت خودسازمان‌ده (SOM) استفاده شد. استفاده از الگوریتم‌های تکاملی نظیر PSO در آموزش شبکه‌های عصبی، راهکاری مؤثر برای بهبود دقت مدل‌های هوشمند و به خصوص در شبیه‌سازی رسوب معلق رودخانه‌ها و کاربردهای منابع آبی و سازه‌های آبخیزداری است.

نتایج و بحث

با استفاده از خوشه‌بندی SOM و شاخص دیویس-بولدین، تعداد بهینه خوشه‌ها برای ایستگاه کوزه توپراقی ۱۲ و برای ایستگاه هیرچای ۱۵ تعیین شد. تحلیل آماری و آزمون KS نشان داد داده‌ها در مجموعه‌های آموزش، اعتبارسنجی و

* مسئول مکاتبات: sahosseini@yahoo.com

آزمون، از توزیع مشابهی برخوردارند که باعث افزایش قدرت تعمیم‌دهی مدل‌ها می‌شود. آموزش مدل‌های شبکه عصبی با الگوریتم PSO نسبت به پسانتشار خطا، عملکرد بهتری داشت و خطاهای پیش‌بینی کاهش یافت. مدل‌های ANN-Sig و PSO-Tan بهترین عملکرد را در ایستگاه‌های کوزه توپراقی و هیرچای به ترتیب داشتند. بررسی بایاس مدل‌ها نیز نشان داد مدل‌های آموزش دیده با PSO خطای کمتری در برآورد کل رسوب دارند. به طور کلی نتایج نشان داد، آموزش شبکه‌های عصبی با الگوریتم PSO عملکرد بهتری نسبت به روش آموزش صرف با پسانتشار خطا دارد. در ایستگاه کوزه توپراقی، مدل هیبرید شبکه عصبی و PSO با تابع فعال‌سازی سیگموئیدی (ANN-PSO-Sig) و در ایستگاه هیر-هیرچای توپراقی مدل مشابه با تابع فعال‌سازی تانژانت هیپربولیک (ANN-PSO-Tan) به ترتیب با بایاس‌های ۲۵/۵ و ۲/۱۹ درصد و شاخص RMSE برابر با ۸۶/۲۸ و ۸۹/۲ تن در روز به عنوان مدل‌های بهینه انتخاب شدند. این نتایج، نشان‌دهنده بهبود دقت پیش‌بینی بار رسوب معلق با استفاده از الگوریتم PSO در آموزش شبکه عصبی است.

نتیجه‌گیری

استفاده از الگوریتم فراابتکاری PSO در آموزش مدل‌های شبکه عصبی، عملکرد آنها را در شبیه‌سازی بار رسوب معلق بهبود بخشیده است. این روش نسبت به الگوریتم‌های مبتنی بر گرادینان خطا برتری دارد و می‌تواند بهینه‌سازی وزن‌ها را با دقت بالاتری انجام دهد. نتایج نشان داد که دقت برآورد شاخص بایاس در مدل‌های آموزش دیده با PSO بهتر است که این امر در طراحی سازه‌های آبی و مدیریت منابع آب اهمیت زیادی دارد. همچنین خوشه‌بندی داده‌ها با الگوریتم SOM باعث انتخاب مجموعه داده‌های همگن و نماینده برای آموزش مدل‌ها شده است که به افزایش قابلیت تعمیم مدل‌ها کمک کرده است. به طور کلی، با توجه به پیچیدگی‌های سیستم‌های هیدرولوژیکی و عدم قطعیت‌های موجود، به کارگیری مدل‌های هوشمند همراه با الگوریتم‌های بهینه‌سازی تکاملی مانند PSO راهکاری مؤثر در شبیه‌سازی و پایش بار رسوب معلق است. نتایج حاصل می‌تواند در برنامه‌ریزی و اجرای اقدامات سازه‌ای آبخیزداری و مدیریت منابع آبی کاربرد داشته باشد.

واژه‌های کلیدی: بار معلق، خوشه‌بندی، سراب قره‌سو، شبکه عصبی مصنوعی، نگاشت خود سازمان‌ده

مقدمه

است. در این رابطه، استفاده از الگوریتم PSO به عنوان یکی از روش‌های بهینه‌سازی تکاملی کارآمد می‌تواند به عنوان یک‌روال اتوماتیک با به کارگیری توابع هدف مختلف و بدون صرف هزینه، در فرایند آموزش شبکه عصبی MLP مورد استفاده قرار گیرد (Shah Hosseini, et al., 2018).

مدل منحنی سنج رسوب، به دلیل سادگی استفاده و موجود بودن داده‌های مدل که اغلب در ایستگاه‌های آب‌سنجی وجود دارند، نسبت به مدل‌های فیزیکی و تجربی ارجحیت دارند (Ulke et al., 2009). علیرغم سادگی استفاده از مدل منحنی سنج رسوب، این مدل با محدودیت‌های اساسی روبرو است. یکی از محدودیت‌های اصلی این مدل وجود بایاس ذاتی در مقادیر برآورده شده رسوب توسط این مدل است که به منظور رفع آن تاکنون، ضرایب تصحیح متنوعی

برآورد صحیح مقدار بار رسوب معلق نقش مهمی در مطالعات فرسایش و رسوب و مدیریت منابع آب حوزه‌های آبخیز دارد. به نحوی که عمر بسیاری از سازه‌های آبی، به برآوردی صحیح از میزان بار رسوب حمل شده در رودخانه‌ها وابسته است. با توجه به اهمیت برآورد متغیرهای پایش‌پذیر حوزه‌های آبخیز نظیر بارش، رواناب، رسوب و همچنین شبیه‌سازی فرایندهای پیچیده هیدرولوژیکی نظیر فرایندهای بارش-رواناب و فرسایش و رسوب، سبب کاربرد روزافزون مدل‌های هوشمند (نظیر شبکه‌های عصبی مصنوعی، فازی، نروفازی و غیره) در این مقوله شده است. در سال‌های اخیر کاربرد الگوریتم‌های تکاملی و فرا اکتشافی (نظیر الگوریتم ژنتیک^۱ و الگوریتم بهینه‌سازی انبوه ذرات^۲) در حل مشکلات مهندسی منابع آب بسیار رایج شده

^۲ Particle Swarm Optimization (PSO)

^۱ Genetic Algorithms (GAs)

گرفته شده از مدل‌های شبکه عصبی پرسپترون چند لایه، شبکه عصبی تابع پایه شعاعی^۴ و منحنی سنجه رسوب، حاکی از برتری مدل نروفازی بود. Rajae et al., (2009) از مدل‌های نروفازی، شبکه عصبی پرسپترون چند لایه^۵، رگرسیون خطی چندمتغیره و منحنی سنجه رسوب به منظور برآورد مقدار رسوب معلق روزانه در ایستگاه‌های اندازه‌گیری رودخانه‌های شور و سیاه در آمریکا استفاده نمودند. نتایج نشان داد که مدل‌های نروفازی و شبکه عصبی دارای دقت بیشتری نسبت به مدل‌های رگرسیونی و منحنی سنجه رسوب بودند و در مجموع، مدل نروفازی، عملکرد بهتری نسبت به مدل شبکه عصبی داشته است.

در ارتباط با بهینه‌سازی وزن و بایاس مدل‌های یادگیری ماشینی، پژوهش‌هایی انجام شده است که در ادامه به برخی از آنها به اختصار اشاره می‌شود. (Kuok et al., 2010)، در حوضه سانگای بداپ در کشور مالزی، به منظور بهینه‌سازی یک مدل شبکه عصبی بارش-رواناب روزانه، از الگوریتم PSO استفاده نمودند. آنها نشان دادند که آموزش شبکه عصبی از طریق الگوریتم یاد شده، موفقیت آمیز بوده است.

(Güven and Kişi, 2011)، به منظور برآورد مقدار بار رسوب معلق روزانه در دو ایستگاه کوابرادا بلانسا و ریو والنسیانو در آمریکا، از مدل‌های برنامه‌ریزی ژنتیک خطی، نروفازی، شبکه عصبی و منحنی سنجه رسوب استفاده نمودند. نتایج نشان از برتری مدل برنامه‌ریزی ژنتیک خطی نسبت به سایر مدل‌ها بود. (Güven and Kişi, 2011)، در پژوهشی مشابه (Aytekin and Kisi, 2008)، به منظور برآورد مقدار رسوب معلق روزانه در دو ایستگاه واقع در رودخانه تونگو در مونتانا آمریکا، از مدل‌های مختلف الگوریتم ژنتیک (LGP و GEP) و شبکه عصبی استفاده نمودند. نتایج نشان داد که مدل برنامه‌ریزی ژنتیک خطی (LGP) نسبت به سایر مدل‌ها، عملکرد بهتری داشته است. پس از آن، مدل GEP عملکرد بهتری نسبت به شبکه عصبی داشته است. (Ebrahimi, et al., 2013)، به منظور برآورد رسوب معلق رودخانه مد در ایالت کالیفرنیا آمریکا، از الگوریتم‌های

پیشنهاد شده است که استفاده از هر یک نتایج متفاوتی در پی دارد. از سوی دیگر، این مدل رگرسیونی تک متغیره بوده و صرفاً براساس دبی جریان، رسوب معلق را برآورد می‌نماید و حال آنکه متغیرهای دیگری (نظیر بارش، دما و غیره) در تولید رسوب، در حوضه نقش داشته که می‌بایست مد نظر قرار گیرند (Tabatabaei et al., 2017).

استفاده از روش‌های محاسبات نرم نظیر سیستم استنتاج فازی-عصبی تطبیقی^۱، شبکه‌های عصبی مصنوعی^۲، الگوریتم‌های فرامکاشفه‌ای^۳ (نظیر الگوریتم‌های ژنتیک و الگوریتم بهینه‌سازی انبوه ذرات)، توسط بسیاری از محققین در برآورد رسوب معلق رودخانه‌ها مورد استفاده قرار گرفته است.

(Zhua et al., 2007)، با به کارگیری شبکه عصبی و استفاده از داده‌های هواشناسی (متوسط بارش و دمای ماهانه) و متوسط دبی جریان ماهانه، متوسط دبی رسوب رودخانه لونگچوانجیانگ در حوزه آبخیز یانگ‌تسه در چین را برآورد نمودند. نتایج این پژوهش، عملکرد بهتر روش شبکه عصبی نسبت به روش رگرسیونی مورد استفاده را نشان داد.

(Alpa et al., 2007)، در پژوهشی به منظور برآورد مقدار رسوب معلق روزانه حوزه آبخیز جونیاتا در آمریکا، از شبکه‌های عصبی (پرسپترون چند لایه پیشخور و تابع پایه شعاعی) و مدل رگرسیون استفاده نمودند. آنها از داده‌های دبی جریان و رسوب معلق روزانه جهت برآورد رسوب معلق استفاده کردند. نتایج پژوهش، عملکرد بهتر شبکه‌های عصبی نسبت به مدل رگرسیونی را نشان داد. (Aytekin and Kisi, 2008)، عملکرد مدل‌های برنامه‌ریزی ژنتیک (GP)، رگرسیون و منحنی سنجه رسوب در برآورد مقدار رسوب معلق در رودخانه تونگو در مونتانا آمریکا، را بررسی نمودند. نتایج نشان داد مدل برنامه‌ریزی ژنتیک (GP) در تخمین مقدار رسوب معلق نسبت به سایر مدل‌ها عملکرد بهتری داشته است. (Cobaner et al., 2009)، با استفاده از مدل نروفازی تطبیقی، مقدار رسوب معلق روزانه رودخانه مد در آمریکا را برآورد نمودند. مقایسه نتایج مدل با نتایج

³ Meta-Heuristic Algorithms

⁴ Radial Basis Function (RBF)

⁵ Multi-layer Perceptron (MLP)

¹ Artificial Neural Networks Fuzzy Inference System (ANFIS)


² Artificial Neural Networks (ANNs)

بررسی سوابق پژوهش‌های نشان داد، دقت و کارایی روش‌های مبتنی بر محاسبات نرم (شبکه‌های عصبی، منطق فازی، نروفازی، الگوریتم‌های فرا مکاشفه‌ای و غیره) در مقایسه با روش‌های کلاسیک رگرسیونی (نظیر منحنی سنج رسوب) بالاتر است. در مجموع هدف از این پژوهش به‌کارگیری الگوریتم PSO در بهینه‌سازی ضرایب مدل‌های شبکه عصبی است. از سوی دیگر، یکی از نوآوری‌های این پژوهش توجه آن به تعمیم‌پذیری مدل‌های شبکه عصبی بوده که در این راستا آموزش مدل‌ها با استفاده از داده‌های خوشه‌بندی شده و توجه به همگن بودن این داده‌ها در سه بخش آموزش، اعتبارسنجی متقاطع و آزمون بوده است.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده: پژوهش حاضر در دو ایستگاه هیدرومتری منتخب واقع در حوزه آبخیز سراب قره‌سو در استان اردبیل انجام شد. موقعیت حوضه و ایستگاه‌های هیدرومتری حوزه توپراقی و هیر-هیرچای در شکل ۱ نشان داده شده است.

تکاملی و منحنی سنج رسوب استفاده نمودند. در این پژوهش، از داده‌های غلظت رسوب معلق روزانه و دبی جریان استفاده شد. نتایج تحقیق نشان داد که بهینه‌سازی ضرایب منحنی سنج رسوب با استفاده از الگوریتم‌های تکاملی، موجب افزایش کارایی مدل منحنی سنج رسوب در برآورد رسوب معلق شده است. Chiang, et al., (2014) در پژوهشی در حوزه آبخیز گودوین کریک در آمریکا، جهت برآورد بار رسوب معلق، از شبکه عصبی مصنوعی، ماشین بردار پشتیبان و مدل رگرسیون استفاده نمودند. نتایج نشان داد که کارایی مدل ماشین بردار پشتیبان در برآورد رسوب معلق بهتر از شبکه عصبی و مدل رگرسیونی بوده است. (Tabatabaei and Salehpour Jam, (2017) از الگوریتم‌های ژنتیک و PSO ضرایب مدل منحنی سنج رسوب را برای رودخانه شلمان‌رود در استان گیلان بهینه نمودند. نتایج نشان داد که کارایی مدل‌های بهینه شده با کمک این دو الگوریتم بهتر از روش‌های مشتق مبنا بوده که به‌طور معمول جهت محاسبه ضرایب مدل‌های رگرسیونی نظیر مدل منحنی سنج رسوب و در فرایند واسنجی استفاده می‌شود.



شکل ۱- موقعیت حوزه‌های آبخیز منتخب و ایستگاه‌های هیدرومتری مورد پژوهش

Fig. 1. Location of selected watersheds and hydrometric stations under study

به منظور انتخاب ایستگاه‌های هیدرومتری معیارهایی نظیر دارا بودن آمار رسوب‌سنجی مناسب و عدم قرارگیری موقعیت ایستگاه در پایین‌دست سد مدنظر قرار گرفت. در جدول ۱، مشخصات ایستگاه‌های

هیدرومتری منتخب در حوضه سراب قره‌سو و در جدول ۲ ویژگی‌های آماری داده‌های مورد استفاده منتخب طی دوره آماری ۳۵ ساله ارائه شده است.

جدول ۱- اسامی ایستگاه‌های هیدرومتری منتخب در حوضه سراب قره‌سو مورد مطالعه

Table 1. Names of selected hydrometric stations in the Sarab Gharesu basin

No	Hydrometric station name	Station code	River name	Station rank	Station establishment year
1	Koozeh Toupraqi	059-19	Qorichay	3	1974
2	Hir Chai	093-19	Hir chai	3	1974


جدول ۲- ویژگی‌های آماری داده‌های آب‌سنجی در ایستگاه‌های هیدرومتری منتخب طی دوره آماری ۳۵ ساله

Table 2. Statistical characteristics of hydrometric data at selected hydrometric stations during the 35-year statistical period

Statistical properties	Hydrometry Station Hir Chai (249 Sample)		Hydrometry Station Koozeh Toupraqi (198 Sample)	
	Suspended Sediment Discharge (ton/day)	Instantaneous Discharge (m ³ /s)	Suspended Sediment Discharge (ton/day)	Instantaneous Discharge (m ³ /s)
Maximum	75.10	2.21	1800.33	11.81
Minimum	0.00	0.00	0.00	0.00
Mean	3.32	0.25	73.99	1.32
Standard Deviation	7.91	0.26	226.94	2.31
Skewness	5.18	3.06	4.65	2.39
Coefficient of Variation (percent)	238.17	104.19	306.73	174.74

۲ و در ادامه روش‌ها و الگوریتم‌های به کار رفته در پژوهش به تفصیل ارائه شده است.


نمودار گردش شبیه سازی رسوب معلق: نمودار گردش کلی شبیه‌سازی رسوب معلق در ایستگاه‌های هیدرومتری منتخب استان اردبیل در شکل



شکل ۲- نمودار گردش شبیه‌سازی رسوب معلق در یک نگاه

Fig. 2. Suspended sediment simulation flow chart at a glance

خود سازمانده استفاده شد (Kohonen, 1998). در این رابطه به منظور تهیه داده‌های همگن در بخش‌های مختلف مدل آموزش و آزمون مدل‌های شبکه عصبی از مدل شبکه عصبی نگاشت خودسازمانده (یک شبکه عصبی مصنوعی غیر نظارتی جهت خوشه‌بندی داده‌ها استفاده شد. در این مدل الگوریتم آموزش، به صورت رقابتی و بدون ناظر انجام می‌شود. در شکل ۳ ساختار SOM که از یک لایه ورودی (با شش متغیر) و یک لایه خروجی (لایه کوهنن) که از یک شبکه 8×8 با ۶۴ نورون تشکیل شده، نشان داده شده است.



شکل ۳- نمایش ساختار SOM با دو لایه ورودی و خروجی (Shahin, 2004)
Fig. 3. Representation of the SOM structure with two input and output layers (Shahin, 2004)

به منظور نمونه‌گیری از خوشه‌ها، مطابق رابطه (۲)، از روش تخصیص متناسب استفاده شد. در این روش، تعداد نمونه‌ها، متناسب با اندازه خوشه تغییر کرده بدین نحو که با افزایش اندازه هر خوشه، تعداد نمونه‌گیری از آنها افزایش یافته و بالعکس (May et al., 2010).

$$nh = n \frac{Nh}{\sum_{j=1}^H Nj} \quad (2)$$

که در آن، Nh ، تعداد نمونه گرفته شده از خوشه h ، n ، تعداد داده مورد نیاز، Nh تعداد داده‌ها در خوشه h و Nj تعداد داده در سایر خوشه‌ها است.

در این پژوهش، ۷۰ درصد داده‌ها برای آموزش مدل‌های شبکه عصبی، ۱۵ درصد داده‌ها برای

شبکه عصبی نگاشت خودسازمانده^۱: به منظور آموزش و آزمون مدل‌های شبکه عصبی، لازم است تا داده‌های مورد استفاده در مجموعه داده‌های آموزش، اعتبارسنجی متقاطع و آزمون، مشابه و همگن باشند (Li et al., 2010). عدم استفاده از داده‌های مشابه و همگن در مجموعه‌های یاد شده، تأثیرات زیادی در میزان صحت و کارایی نهایی مدل‌ها دارد، به طوری که سبب کاهش قدرت تعمیم‌دهی آنها خواهد شد (May et al., 2010). بدین علت در این پژوهش، برای ایجاد مجموعه داده‌های همگن و مشابه از شبکه عصبی نگاشت

در پژوهش حاضر، از خوشه‌بندی SOM، جهت ساخت مجموعه‌های واسنجی، اعتبارسنجی متقاطع و آزمون در مدل‌های شبکه عصبی استفاده شد.

در این رابطه به منظور بی‌بعد نمودن داده‌ها در محاسبات فاصله (در عملیات خوشه‌بندی) و به منظور جلوگیری از کوچک شدن بیش از حد وزن‌های تخصیص یافته به نورون‌ها، از رابطه (۱) جهت نرمال‌سازی داده‌ها در بازه ۰/۹ تا ۰/۹- استفاده شد.

$$z = \left(\frac{1.8(X_i - X_{imin})}{X_{imax} - X_{imin}} \right) - 0.9 \quad (1)$$

که در آن، Z متغیر نرمال شده، X_i متغیر اولیه، X_{imax} و X_{imin} به ترتیب مقادیر کمینه و بیشینه متغیر X_i هستند.

¹ Self-Organizing Map (SOM)

بهینه پارامترهای مدل شبکه عصبی استفاده شده و هر ذره‌ای که این تابع را بیشتر کمینه نماید از شایستگی بیشتری برخوردار است.

در الگوریتم PSO، ذرات برای رسیدن به یک هدف مشترک، با یکدیگر همکاری نموده و در نتیجه این روش، مؤثرتر از هنگامی است که ذرات به‌طور جداگانه عمل می‌نمایند (Shah Hosseini et al., 2018). در الگوریتم PSO، رفتار جمعی فقط وابسته به رفتار فرد در اجتماع نیست بلکه به چگونگی تعامل میان افراد گروه نیز مربوط می‌شود. در این روش، ذرات در فضای جستجو گسترده شده و سپس به‌منظور رسیدن به بهترین راه‌حل‌ها، تحت تأثیر تجربه و دانش خود و دانش دیگر ذرات همسایگانشان رفته‌رفته به سمت نواحی موفق (راه‌حل‌های بهینه) میل می‌نمایند. در مقایسه با دیگر الگوریتم‌های تکاملی (نظیر الگوریتم ژنتیک (GAs)، الگوریتم PSO دارای ویژگی‌های جالبی نظیر همکاری سازنده و حافظه مشترک میان افراد است. بنابراین در این الگوریتم، حرکت به سمت نواحی دربرگیرنده راه‌حل‌های بهتر، از شانس بیشتری برخوردار بوده و کشف راه‌حل‌های باکیفیت مطلوب، سریع‌تر انجام می‌شود. علاوه بر آن، این الگوریتم بسیار ساده، دارای سرعت بالا و حافظه‌ای کم‌هزینه است. شکل ۴، مراحل الگوریتم PSO را نشان می‌دهد (Yarkiani, 2010).


اعتبارسنجی متقاطع و ۱۵ درصد کل داده‌ها برای آزمون در نظر گرفته شد.

به‌منظور بررسی همگنی و مشابهت توزیع داده‌ها در مجموعه‌های آموزش، اعتبارسنجی متقاطع و آزمون، علاوه بر مقایسه پارامترهای آماری (میانگین، انحراف معیار، چولگی) از آزمون ناپارامتری دو نمونه‌ای کولموگروف-اسمیرنوف (به‌دلیل نرمال نبودن توزیع داده‌ها) استفاده شد.

الگوریتم بهینه‌سازی انبوه ذرات: الگوریتم بهینه‌سازی انبوه ذرات^۱، یک الگوریتم جستجوی اجتماعی است که از رفتار اجتماعی دسته پرندگان و ماهی‌ها، به هنگام جستجوی غذا الهام گرفته شده است. در این الگوریتم، هر ذره یا راه‌حل، در واقع ماتریس اوزان شبکه عصبی بوده و معادل یک پرنده در الگوی حرکت جمعی پرندگان فرض شده و شایستگی آن توسط یک تابع هدف (نظیر رابطه ۳) تعیین می‌شود.

$$OF(\gamma) = \sqrt{\frac{1}{n} \sum_{i=1}^n (SSL_o - SSL_e)^2} \quad (3)$$

که در آن، γ ، بردار اوزان مدل شبکه عصبی، SSL_o و SSL_e به‌ترتیب مقدار غلظت یا دبی رسوب معلق مشاهده‌ای و محاسبه‌شده (ton/day) به‌ازای دبی متوسط جریان داده‌های واسنجی، و n تعداد داده‌های واسنجی است. از تابع هدف (OF)، جهت ارزیابی مقادیر



شکل ۴- روند نمای الگوریتم PSO (Yarkiani, 2010)

Fig. 4. PSO algorithm flow chart (Yarkiani, 2010)

¹ Particle Swarm Optimization (PSO)

جواب بهینه نزدیک شود (Shah Hosseini et al., 2018).

جهت استفاده از الگوریتم PSO در این پژوهش، تعداد ذرات اولیه ۵۰ عدد، ضرایب C1 و C2، مقدار دو، ضریب اینرسی ۰/۹ و تعداد تولید نسل تا رسیدن به همگرایی نهایی، ۵۰۰ نسل در نظر گرفته شد.

در مجموع، همان‌طور که پیش‌تر بیان شد، هدف از به‌کارگیری الگوریتم فرامکاشفه‌ای PSO، بهینه‌سازی ماتریس وزن‌های به‌کار رفته در مدل شبکه عصبی بوده که نتایج آن سپس، با مدل‌های دیگر شبکه عصبی که از الگوریتم‌های مرسوم پس انتشار خطا برای آموزش مدل استفاده می‌نمایند، مورد مقایسه و تحلیل قرار می‌گیرد.

شاخص دیویس بولدین: از شاخص دیویس بولدین مطابق رابطه (۶) به‌منظور ارزیابی شباهت بین دو خوشه که بر اساس پراکندگی هر خوشه و عدم شباهت بین دو خوشه بیان می‌شود، استفاده شد. هر چه مقدار محاسبه‌شده این شاخص کمتر باشد خوشه‌بندی باکیفیت بهتری انجام شده است.

$$R_{ij} = \frac{s_i + s_j}{d_{ij}} \quad (6)$$

که در آن، R_{ij} شباهت بین دو خوشه i و j ، s_i و s_j به‌ترتیب پراکندگی خوشه‌ها و d_{ij} فاصله مراکز دو خوشه هستند.

در رابطه (۶)، پراکندگی یک خوشه و فاصله بین دو خوشه به‌ترتیب با استفاده از رابطه‌های (۷) و (۸) محاسبه می‌شوند.

$$d_{ij} = d(v_i + v_j) \quad (7)$$

که در آن، d_{ij} فاصله بین دو خوشه i و j ، v_i و v_j به‌ترتیب مراکز دو خوشه مذکور هستند.

$$s_i = \frac{1}{|c_i|} \sum_{x \in c_i} d(x, v_i) \quad (8)$$

در این رابطه، $|c_i|$ ، تعداد داده‌ها در i امین خوشه است.

نهایتاً شاخص دیویس بولدین مطابق رابطه (۹) محاسبه می‌شود.

$$DB = \frac{1}{n_c} \sum_{i=1}^{n_c} R_i \quad (9)$$

که در آن، DB شاخص دیویس بولدین، n_c تعداد خوشه و R_i بیشترین مقدار شباهت بین دو خوشه بوده که با استفاده از رابطه (۱۰)، محاسبه می‌شود.

روش کار این الگوریتم بدین صورت است که ابتدا تعدادی ذره با موقعیت و سرعت تصادفی ایجادشده، سپس در هر تکرار، ذرات برحسب بهترین موقعیت گذشته خود و همسایگان‌شان حرکت به‌سوی هدف را اصلاح می‌نمایند. پس از تکرارهای متوالی، مسأله به جواب بهینه همگرا می‌شود. اصلاح سرعت و موقعیت هر ذره به‌این‌ترتیب توسط رابطه‌های (۴) و (۵) انجام می‌شود.

$$V_i(t+1) = \omega V_i(t) + C_1 * rand_1 (pbest_i(t) - x_i(t)) + C_2 * rand_2 (gbest_i(t) - x_i(t)) \quad (4)$$

$$x_i(t+1) = x_i(t) + V_i(t+1) \quad (5)$$

که در آنها، gbest نشان‌دهنده بهترین موقعیتی است که توسط جمعیت ذرات به‌دست‌آمده و pbest بهترین موقعیت خود ذره است که تا به حال آن را تجربه نموده است، t نمایانگر تعداد تکرار، c ثابت شتاب و $rand_1$ و $rand_2$ ، اعدادی تصادفی در بازه [۰ و ۱] هستند. ضرایب C_1 و C_2 ، به‌این‌ترتیب پارامتر شناختی (تجربه شخصی) و پارامتر اجتماعی (تجربه جمعی) بوده و شیب حرکت در جستجوی محلی را مشخص می‌نمایند. مقدار این دو ضریب در بازه [۰ و ۲] تعیین می‌شود که در غالب موارد برای هر دو ضریب، مقدار دو و یا ۱/۴۹ در نظر گرفته می‌شود. ضریب ω ، ضریب اینرسی بوده که به‌صورت خطی کاهش‌یافته و معمولاً در بازه [۰ و ۱] تعریف می‌شود.

به‌طور خلاصه، رابطه (۴)، از سه قسمت تشکیل می‌شود. قسمت اول بیانگر سرعت فعلی ذره، قسمت دوم، باعث تغییر سرعت و چرخش ذره به سمت بهترین تجربه شخصی و قسمت سوم موجب تغییر سرعت و چرخش ذره به‌طرف بهترین تجربه گروهی می‌شود. در مجموع، هر ذره دارای یک موقعیت، سرعت و مقدار شایستگی است. ذرات، سرعتشان را بر اساس بهترین موقعیت تاکنون و بهترین موقعیت به‌دست‌آمده در نسل فعلی تغییر می‌دهند (رابطه ۵). این سرعت با موقعیت ذره جمع شده و موقعیت جدید ذره را به‌دست می‌دهد (رابطه ۴). اگر بهترین موقعیت به‌دست‌آمده در نسل فعلی، از بهترین موقعیت تاکنون بهتر باشد جایگزین آن می‌شود. این عمل، به تعداد نسل‌های از پیش تعیین‌شده تکرار شده و یا تا زمانی انجام می‌پذیرد که مسأله به

خطا تعیین شد. آموزش شبکه عصبی با استفاده از الگوریتم یادگیری لونیگ مارکواردت و PSO انجام شده که در ادامه به آن اشاره شده است.

مدلسازی رسوب معلق: در پژوهش حاضر، در راستای شبیه‌سازی رسوب معلق ایستگاه‌های هیدرومتری منتخب استان اردبیل، از مدل شبکه عصبی مصنوعی MLP و در مرحله بعدی، از مدل هیبرید آن یعنی ترکیب مدل MLP با الگوریتم بهینه‌سازی انبوه ذرات (PSO) استفاده شد. در ابتدا، پس از بازبینی داده‌های رسوب سنجی ایستگاه‌های هیدرومتری منتخب، داده‌ها با حذف مقادیر پوچ، رشته و نظایر آن اصلاح شد و سپس با استفاده از شبکه عصبی SOM، داده‌های هر ایستگاه، خوشه‌بندی و پس از آن با روش نمونه‌گیری از خوشه‌ها (روش تخصیص متناسب)، نسبت به ساخت سه مجموعه داده آموزش، اعتبارسنجی متقاطع و آزمون اقدام شد.

سهم داده‌های موجود در سه مجموعه داده آموزش، اعتبارسنجی متقاطع و آزمون به ترتیب ۷۰، ۱۵ و ۱۵ درصد داده‌های هر خوشه بود که به صورت تصادفی انتخاب شد. پس از این مرحله، آموزش مدل‌های شبکه عصبی با دو روش مرسوم پس انتشار خطا و الگوریتم PSO انجام و پس از آن با کمک معیارهای ارزیابی، مدل‌های ساخته شده برای هر ایستگاه مورد صحت سنجی و مقایسه با یکدیگر قرار گرفت، و در نهایت مدل بهینه شبکه عصبی در هر ایستگاه معرفی شد.

سناریوهای مدل‌سازی و اسامی مدل‌ها: باتوجه به آنکه در پژوهش حاضر از دو الگوریتم لونیگ مارکواردت و PSO به ترتیب جهت آموزش و بهینه‌سازی مدل‌های شبکه عصبی استفاده شده است و همچنین دو تابع سیگموئید و تانژانت هایپربولیک به عنوان توابع فعال‌سازی در این مدل‌ها به کار گرفته شدند (مجموعاً ۴ مدل). لذا، به منظور تسهیل در مقایسه و ارزیابی نتایج مدل‌های مختلف شبکه عصبی، از اسامی مدل‌های ANN-LM-Tan و ANN-LM-Sig به ترتیب مدل‌های شبکه عصبی با الگوریتم آموزشی لونیگ مارکواردت (LM) با توابع فعال‌سازی سیگموئید و تانژانت هایپربولیک و مدل‌های ANN-PSO-Sig و ANN-

$$R_i = \max_{j=1 \dots n_c, i \neq j} (R_{ij}) \quad , \quad i=1, \dots, n_c \quad (10)$$

شبکه عصبی مصنوعی پرسپترون چند لایه روبه جلو^۱: شبکه عصبی مصنوعی پرسپترون چند لایه، از عناصر عملیاتی ساده‌ای به نام نرون ساخته شده که به صورت موازی و در کنار هم، عمل می‌کنند. شبکه‌های عصبی چند لایه، از یک لایه ورودی (در ارتباط با داده‌های ورودی)، یک یا چند لایه پنهان (جهت سازمان‌دهی نرون‌ها) و یک لایه خروجی (در رابطه با داده خروجی) تشکیل می‌شوند.

عملکرد شبکه عصبی، از طریق نحوه اتصال بین اجزاء، با تنظیم مقادیر هر اتصال که به نام وزن اتصال بیان می‌شود، تعیین می‌شود. یکی از انواع شبکه‌های عصبی پرکاربرد در هیدرولوژی و منابع آب، شبکه‌های عصبی پرسپترون چند لایه روبه جلو با الگوی آموزش پس انتشار^۲ خطا است (Ulke et al., 2009). در این نوع از شبکه‌های عصبی، جهت جریان داده، از لایه ورودی به سمت لایه پنهان و از لایه پنهان به سمت لایه خروجی بوده و از این نظر به آنها شبکه‌های عصبی روبه جلو یا پیش‌خور گفته می‌شود. به منظور آموزش شبکه عصبی، مقدار خطا در جهت بیشترین شیب تابع خطا محاسبه شده و این مقدار، به لایه‌های قبل (لایه یا لایه‌های پنهان) فرستاده شده تا با تنظیم مجدد مقادیر وزن نرون‌ها، مقدار خطا را کاهش دهند (قانون دلتا) (Tayfur, 2012). رابطه (۱۱).

$$w_{ij}^{new} = w_{ij}^{old} - \eta \frac{\partial E}{\partial w_{ij}} \quad (11)$$

که در آن، w_{ij}^{old} و w_{ij}^{new} به ترتیب وزن بین نرون‌های i و j قبل و بعد از یک تکرار معین، η نرخ یادگیری و E تابع خطا است.

آموزش شبکه و کاهش خطا تا ایجاد همگرایی در شبکه ادامه می‌یابد. شبکه‌های عصبی می‌توانند دارای چندین لایه پنهان باشند. با این وجود، تحقیقات انجام شده نشان می‌دهد که شبکه‌های عصبی پیش‌خور، با دارا بودن یک لایه پنهان، قادر به تقریب زدن هر نوع تابع غیرخطی هستند (Hornik et al., 1989). در پژوهش حاضر، از یک شبکه عصبی پرسپترون سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) استفاده شده و تعداد بهینه نرون‌ها با سعی و

² Back Propagation


¹ Feed-forward Multi-layer Perceptron (FFMLP)

نتایج و بحث

نتایج خوشه‌بندی در ایستگاه‌های هیدرومتری منتخب: با استفاده از خوشه‌بندی SOM و محاسبه شاخص دیویس-بولدین، تعداد بهینه خوشه‌ها برای مجموعه داده‌های مورد بررسی در ایستگاه کوزه توپراقی، تعداد ۱۲ عدد و در ایستگاه هیرچای ۱۵ عدد تعیین شد (شکل‌های ۵ و ۶).


به ترتیب مدل‌های شبکه عصبی با الگوریتم PSO-Tan بهینه‌سازی PSO و توابع فعال‌سازی سیگموئید و تانژانت هایپربولیک استفاده شد.

به منظور صحت سنجی و بررسی بایاس مدل‌های مختلف شبکه عصبی و مقایسه آنها با یکدیگر، از شاخص‌های ریشه میانگین مربعات خطا^۱، میانگین قدرمطلق خطا^۲، اشتباه معیار تخمین^۳ خط رگرسیون داده‌های مشاهداتی در مقابل داده‌های محاسباتی و درصد بایاس^۴ استفاده شد.



شکل ۵- تعیین تعداد خوشه‌های بهینه با استفاده از خوشه‌بندی به روش SOM و شاخص دیویس-بولدین در ایستگاه هیدرومتری کوزه توپراقی

Fig. 5. Determining the optimal number of clusters using SOM clustering and the Davis-Bouldin index at the Koozeh Toupraqi hydrometric station



شکل ۶- تعیین تعداد خوشه‌های بهینه با استفاده از خوشه‌بندی به روش SOM و شاخص دیویس-بولدین در ایستگاه هیدرومتری هیرحیرچای

Fig. 6. Determining the optimal number of clusters using SOM clustering and the Davis-Bouldin index at the Hir-Hirchai hydrometric station

³ Standard error of the Estimate

⁴ PBIAS

¹ Root Mean Square error (RMSE)

² Mean Absolute Error (MAE)

خوشه‌بندی داده‌ها به روش تخصیص متناسب، در دو ایستگاه هیدرومتری کوزه توپراقی و هیر-هیرچای، در جدول ۳ نشان داده شده است.

نتایج تحلیل آماری داده‌های حاصل از خوشه‌بندی: نتایج پارامترهای آماری و آزمون‌های ناپارامتری دو نمونه‌ای (KS) بر روی سه مجموعه آموزش، اعتبارسنجی متقاطع و آزمون حاصل از

جدول ۳- پارامترهای آماری داده‌های سه مجموعه آموزش، ارزیابی متقاطع و آزمون در مدل شبکه عصبی در ایستگاه‌های منتخب مورد پژوهش

Table 3. Statistical parameters of the three training, cross-validation, and testing data sets in the neural network model at the selected stations under study

Hydrometry station name	Model variables and data sets	Statistical parameters					
		Mean	Standard deviation	Maximum	Minimum	Skewness	Coefficient of variation (percent)
Koozeh Toupraqi	Instantaneous discharge (Q_{w_i}) (m^3/s)						
	Training Set	1.38	2.37	11.81	0.00	2.25	171.93
	Cross-Validation Set	1.37	2.61	11.68	0.00	2.66	188.47
	Test Set	0.98	1.62	6.37	0.00	2.04	166.17
	Suspended Sediment Discharge (SSL) (ton/day)						
	Training Set	8.43	256.23	1800.23	0.00	4.28	296.5
Hir Chai	Cross-Validation Set	4.54	143.54	598.43	0.00	3.30	302.02
	Test Set	3.79	105.53	492.03	0.00	3.43	272.1
	Instantaneous Discharge (Q_{w_i}) (m^3/s)						
	Training Set	0.25	0.27	2.21	0.00	3.41	106.54
	Cross-Validation Set	0.27	0.28	1.28	0.00	2.14	104.50
	Test Set	0.24	0.22	1.01	0.00	1.90	92.59
	Suspended Sediment Discharge (SSL) (ton/day)						
	Training Set	3.08	8.00	75.1	0.00	6.02	259.32
	Cross-Validation Set	4.95	9.84	41.47	0.00	2.50	198.9
	Test Set	2.64	4.17	19.44	0.00	2.47	158.16

واسنجی، آزمون و ارزیابی متقاطع در دو ایستگاه منتخب در جدول ۵ خلاصه شده است.

مقایسه نتایج شاخص‌های صحت سنجی به دست آمده از مدل‌ها نشان داد، مدل‌های شبکه عصبی که با الگوریتم PSO آموزش دیده‌اند (مدل‌های ANN- PSO-Sig و ANN- PSO-Tan) در مقایسه با مدل‌های شبکه عصبی پس انتشار خطا (ANN-LM-Sig، ANN-LM-Tan) وضعیت بهتری داشته و خطای آن‌ها کمتر است. به طوری که استفاده از الگوریتم PSO در آموزش شبکه عصبی توانسته است شاخص‌های صحت سنجی مدل‌های شبکه عصبی را بهبود بخشد.

همچنین نتایج اخذ شده از آزمون KS (جدول ۴) که در سطح خطای یک درصد (سطح اطمینان ۹۹ درصد) انجام شد، مشخص نمود توزیع داده‌های نظیر به نظیر در هر سه مجموعه، یکسان و مشابه است (تائید فرض H_0 آزمون). نتایج مذکور ثابت نمود داده‌های مورد استفاده در آموزش مدل‌ها، معرف و نماینده داده‌ها در کل دوره آماری هستند. این مسأله قدرت تعمیم‌دهی مدل‌های ساخته شده را افزایش داد.

نتایج مدل‌سازی برآورد بار رسوب معلق: نتایج آموزش و آزمون مدل‌های مختلف شبکه عصبی با استفاده از داده‌های خوشه‌بندی شده در سه مجموعه

علاوه بر صحت‌سنجی مدل‌های مختلف شبکه عصبی، از نظر مقدار برآورد کل رسوب معلق و میزان بیش برآوردی یا کم برآوردی (PBIAS) در دوره آزمون

جدول ۴- نتایج آزمون ناپارامتری دو نمونه‌ای KS بر روی سه مجموعه آموزش، ارزیابی متقاطع و آزمون در ایستگاه‌های هیدرومتری

مورد پژوهش

Table 4. Results of the two-sample nonparametric KS test on the three training, cross-validation, and test sets at the hydrometric stations under study

Hydrometry station name	Variables	Statistical Parameters			
		Comparison sets	P-value	Computational statistic Dc (or k)	MATLAB index (h)
Koozeh Toupraqi	Instantaneous Discharge (Q_{wt})	Training-Cross Validation	0.97	0.10	0.00
		Training-Test	0.73	0.14	0.00
		Cross-Validation and Test	0.66	0.19	0.00
	Suspended Sediment Discharge (SSL)	Training-Cross Validation	0.64	0.15	0.00
		Training-Test	0.85	0.12	0.00
		Cross-Validation and Test	1.00	0.06	0.00
Hir Chai	Instantaneous Discharge (Q_{wt})	Training-Cross Validation	0.83	0.10	0.00
		Training-Test	1.00	0.07	0.00
		Cross-Validation and Test	0.73	0.15	0.00
	Suspended Sediment Discharge (SSL)	Training-Cross Validation	0.46	0.14	0.00
		Training-Test	0.91	0.10	0.00
		Cross-Validation and Test	0.80	0.14	0.00

** معنی‌داری در سطح خطای یک درصد ($\alpha = 1\%$) و با اطمینان ۹۹ درصد

جدول ۵- ساختار و نتایج ارزیابی مدل‌های مختلف شبکه عصبی در برآورد بار رسوب معلق داده‌های آزمون در ایستگاه‌های هیدرومتری

مورد پژوهش

Table 5. Structure and evaluation results of different neural network models in estimating suspended sediment load of test data at the hydrometric stations under study

Hydrometry Station Name	Model	Structure of the Network / Regression Model	MAE (t/day)	RMSE (t/day)	S_{xy} (t/day)	PBIAS
Koozeh Toupraqi	ANN-LM-Sig	1:6:1	12.00	31.76	32.96	19.77
	ANN-PSO-Sig	1:6:1	11.7	28.86	29.95	5.25
	ANN-LM-Tan	1:6:1	11.75	32.16	33.38	21.48
	ANN-PSO-Tan	1:6:1	11.00	30.21	31.46	-6.30
	ANN-LM-Sig	1:5:1	1.62	3.16	3.25	34.57
Hir Chai	ANN-PSO-Sig	1:5:1	1.58	2.94	3.02	9.16
	ANN-LM-Tan	1:5:1	1.66	2.97	3.05	32.64
	ANN-PSO-Tan	1:5:1	1.65	2.89	2.97	-2.19

جدول ۶- مقایسه رسوب معلق مشاهده‌ای و برآورد شده توسط مدل‌های مختلف در دوره آزمون در ایستگاه‌های هیدرومتری مورد

پژوهش

Table 6. Comparison of observed and estimated suspended sediment by different models during the test period at the hydrometric stations under study

Total estimated suspended sediment load (t/day)					
Hydrometry station name	Total observed suspended sediment load (t/day)	ANN-LM-Sig	ANN-PSO-Sig	ANN-LM-Tan	ANN-PSO-Tan
Koozeh Toupraqi	1086	871.21	1029	852.71	1154.46
	PBIAS (percent)	19.77	5.25	21.48	-6.30
Hir Chai	100.24	65.58	91.05	67.52	102.44
	PBIAS (percent)	34.57	9.16	32.64	-2.19

یکی از نتایج مشهود در به‌کارگیری الگوریتم PSO در بهینه‌سازی مدل‌های شبکه عصبی، تأثیر آن در کارایی مدل‌ها خصوصاً در شاخص بایاس مدل‌ها است. این امر در طراحی سازه‌های آبی واقع در پایین‌دست ایستگاه‌های هیدرومتری، نقش مهمی در تعیین ویژگی‌های هندسی و برآورد دقیق حجم مخازن سازه‌ها دارد، به‌نحوی که هر چه برآورد این شاخص دقیق‌تر و مقدار آن کمتر باشد ارزیابی صحیح‌تری از مقدار رسوب درازمدت حمل شده به پایین‌دست خواهیم داشت. باتوجه‌به این موضوع، در این پژوهش مدل‌هایی که با الگوریتم PSO آموزش داده شده‌اند از شاخص PBIAS بهتری (کمتر) برخوردار بودند.

همچنین نتایج نشان داد در مدل‌سازی متغیرهای محیطی (نظیر برآورد رسوب معلق) بایستی به انتخاب مناسب داده‌ها جهت واسنجی (آموزش) مدل‌ها توجه کافی مبذول شود. این داده‌ها بایستی به‌گونه‌ای انتخاب شوند که ضمن آنکه معرف داده‌ها در کل دوره آماری باشند، با دیگر مجموعه‌های داده (نظیر مجموعه‌های ارزیابی یا آزمون)، مشابه و از توزیع یکسانی برخوردار باشند. عدم همگنی و مشابهت داده‌ها در مجموعه‌های یادشده با یکدیگر، باعث کاهش قدرت تعمیم‌دهی^۱ مدل‌های طراحی‌شده می‌شود. در این راستا، استفاده از الگوریتم‌های خوشه‌بندی نظیر خوشه‌بندی به روش شبکه عصبی نگاشت خودسازمانده (SOM) ابزار مناسبی در خوشه‌بندی داده‌ها و ساخت مجموعه داده‌های مشابه و همگن تشخیص داده شد.

پیچیده بودن سیستم‌های هیدرولوژیکی و حاکم بودن روابط غیرخطی نامشخص بین مجموعه داده‌های ورودی و خروجی از یک سو، و وجود عدم قطعیت در درک و دانش ما از اجزاء و فرایندهای درون آنها از سوی دیگر، موجب کاربرد مدل‌های هوشمند (نظیر مدل‌های شبکه عصبی مصنوعی) در شبیه‌سازی و پایش متغیرهای محیطی به‌خصوص بررسی میزان رسوب معلق رودخانه‌ها شده است. وجود مشکلاتی در زمینه آموزش شبکه‌های عصبی، پژوهشگران را بر آن داشته است که از الگوریتم‌های جانشین دیگری برای آموزش این شبکه‌ها استفاده شود.

همان‌طوری که در جدول ۶ آمده است، مجموع رسوب معلق مشاهده‌ای در دو ایستگاه هیدرومتری کوزه توپراقی و هیر-هیرچای برای داده‌های مشاهده‌ای آزمون به‌ترتیب ۱۰۸۶/۰ و آزمون ۱۰۰/۲۴ تن است که این مقدار برای ایستگاه هیدرومتری کوزه توپراقی در مدل‌های ANN- PSO-Sig، ANN-LM-Sig، ANN- LM-Tan به‌ترتیب با ۱۹/۷۷، ۵/۲۵ و ۴۸/۲۱ درصد کم برآوردی و مدل ANN- PSO-Tan با ۳۰/۶- درصد بیش برآوردی همراه بوده است. همچنین برای ایستگاه هیر-هیرچای در مدل‌های ANN- PSO-Sig، ANN-LM-Tan به‌ترتیب با ۳۴/۵۷، ۹/۱۶ و ۳۲/۶۴ درصد کم برآوردی و در مدل ANN- PSO-Tan با ۱۹/۲- درصد بیش برآوردی همراه است.

از مجموع نتایج به‌دست‌آمده از شاخص‌های صحت‌سنجی و بایاس مدل‌ها، در ایستگاه کوزه توپراقی مدل هیبرید شبکه عصبی و الگوریتم PSO با تابع فعال‌سازی سیگموئیدی (ANN- PSO-Sig) و در ایستگاه هیر-هیرچای توپراقی مدل هیبرید شبکه عصبی و الگوریتم PSO با تابع فعال‌سازی سیگموئیدی (ANN- PSO-Tan)، به‌عنوان مدل بهینه شبکه عصبی ایستگاه‌ها انتخاب شدند.

نتیجه‌گیری

در پژوهش حاضر که باهدف شبیه‌سازی بار رسوب معلق روزانه در حوزه‌های آبخیز منتخب استان اردبیل انجام شد، از الگوریتم فرا ابتکاری PSO به‌منظور آموزش مدل‌های شبکه عصبی استفاده شد و نتایج به‌دست‌آمده نشان داد که این روش آموزش نسبت به الگوریتم‌های مبتنی بر گرادینان خطا، برتری داشته و مدل‌های شبکه عصبی حاصل از آن، از کارایی بیشتری در برآورد بار رسوب معلق برخوردار هستند. نتایج پژوهش انجام شده در زمینه به‌کارگیری الگوریتم PSO در بهینه‌سازی ماتریس اوزان مدل‌های شبکه عصبی و نقش مثبت آن در بهبود نتایج شبیه‌سازی با پژوهش‌های Alizamir and Sobhanardakani, (2018)، Zounemat- (2010) Guo and Wang, Kermani et al., (2016) مطابقت می‌نماید.

¹ Generalizability

تشکر و قدردانی

نویسندگان مقاله از تمامی حمایت‌های مالی و معنوی صورت گرفته توسط سازمان جهادکشاورزی استان اردبیل و همچنین مدیران پژوهشکده حفاظت خاک و آبخیزداری کمال تشکر را به‌عمل می‌آورند.

تعارض منافع

در این مقاله تضاد منافی وجود ندارد و این مسأله مورد تأیید همه نویسندگان است.

گفتنی است داده‌های سری‌های زمانی دبی-رسوب در مقایسه با دیگر متغیرهای هیدرولوژیکی حوضه (نظیر بارش، دما، دبی و غیره) از کیفیت و کمیت کمتری برخوردار بوده و لذا، در برخی مواقع، تعداد این داده‌ها به‌اندازه کافی نیست تا بتوان از آنها در بهینه‌سازی ماتریس‌های اوزان شبکه‌های عصبی استفاده نمود. در چنین مواقعی وجود یک الگوریتم کارآمد تکاملی (نظیر الگوریتم PSO) می‌تواند نقش مهمی در آموزش صحیح مدل‌های شبکه عصبی داشته باشد.

منابع مورد استفاده

- Alizamir, M., Sobhanardakani, S., 2018. An Artificial Neural Network - Particle Swarm Optimization (ANN- PSO) approach to predict heavy metals contamination in groundwater resources. *Jundishapur J. Health Sci.* 10(2), e67544. doi: 10.5812/jjhs.67544.
- Alpa, M., Cigizoglu H.K., 2007. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Environ. Model. Software* 22(1), 2-13.
- Aytek, A., Kisi, O., 2008. A genetic programming approach to suspended sediment modeling. *J. Hydrol.* 351(3-4), 288-298.
- Chiang, J.L., Tsai, K.J., Chen, Y.R., Lee, M.H., Sun, J.W., 2014. Suspended sediment load prediction using support vector machines in the Goodwin Creek experimental watershed. In *EGU General Assembly Conference Abstracts*, 16, 5285.
- Cobaner, M., Unal, B., Kisi, O., 2009. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data. *J. Hydrol.* 367(1-2), 52-61.
- Ebrahimi, H., Jabbari, E., Ghasemi, M., 2013. Application of honey-bees mating optimization algorithm on estimation of suspended sediment concentration. *World Appl. Sci. J.* 22(11), 1630-1638.
- Guo, W., Wang, H., 2010. August PSO optimizing neural network for the Yangtze river sediment entering estuary prediction. In *2010 6th International Conference on Natural Computation*, 4, 1769-1772 pages.
- Güven, A., Kisi, O., 2011. Estimation of suspended sediment yield in natural rivers using machine-coded linear genetic programming. *Water Resour. Manage.* 25(2), 691-704.
- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Network.* 2(5), 359-366.
- Kisi, O., Fedakar, H.I., 2014. Modeling of suspended sediment concentration carried in natural streams using fuzzy genetic approach. *Computational Intelligence Techniques in Earth and Environmental Sciences*, Springer Netherlands, 175-196.
- Kohonen, T., 1998. The self-organizing map. *Neurocomput.* 21(1), 1-6.
- Kuok, K.K., Harun, S., Shamsuddin, S.M., 2010. Particle swarm optimization feedforward neural network for modeling runoff. *Int. J. Environ. Sci. Technol.* 7, 67-78.
- Li, X., Nour, M.H., Smith, D.W., Prepasc, A.A., 2010. Neural networks modeling of nitrogen export: model development and application to unmonitored boreal forest watersheds. *Environ. Technol.* 31(5), 495-510.
- May, R.J., Maier, H.R., Dandy, G.C., 2010. Data splitting for artificial neural networks using SOM-based stratified sampling. *Neural Network.* 23(2), 283-294.
- Rajaei, T., Mirbagheri, S.A., Zounemat-Kermani, M., Nourani, V., 2009. Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. *Sci. Total Environ.* 407(17), 4916-4927.
- Shah Hosseini, H., Mousavi Mirkalai, S.M.R., Molajafari, M., 2018. *Evolutionary algorithms; Fundamentals, applications and implementation*. Publications of the University of Science and Technology. 590 pages.
- Tabatabaei, M., Salehpour Jam, A., 2017. Optimization of sediment rating curve coefficients using evolutionary algorithms and unsupervised artificial neural network. *Caspian J. Environ. Sci.* 15(4), 387-401.

- Tayfur, G., 2012. Soft computing in water resources engineering-artificial neural networks, fuzzy logic and genetic algorithms. WIT Press, Southampton, England, UK, 267 pages.
- Ulke, A., Tayfur, G., Ozkul, S., 2009. Predicting suspended sediment loads and missing data for Gediz River, Turkey. J. Hydrol. Engin. 14(9), 954-965.
- Yarkiani, A., 2019. Intelligent systems (volumes 1 and 2). Publication of Pouyesh Andisheh. 438 pages.
- Zhua, Y.M., Lua, X.X., Zhoub, Y., 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment, China. Geomorphol. 84(1-2), 111-125.
- Zounemat-Kermani, M., Kişi, O., Adamowski, J., Ramezani-Charmahineh, A., 2016. Evaluation of data driven models for river suspended sediment concentration modeling. J. Hydrol. 16(2), pages 1-40.