



## Investigating the Impact of Wavelet Network on the Efficiency of Artificial Neural Network in Predicting Flood Sediments

Halimeh Yar <sup>a</sup>, Mehdi Hayatzadeh <sup>b\*</sup>, Ali Fathzadeh <sup>c</sup>, Hamideh Afkhami <sup>d</sup>

<sup>a</sup> MA in Watershed Management, Ardakan University, Ardakan, Iran

<sup>b</sup> Assistant Professor in Watershed Management, Ardakan University, Ardakan, Iran

<sup>c</sup> Associate Professor in Watershed Management, Ardakan University, Ardakan, Iran

<sup>d</sup> PhD in Watershed Management, Tehran Regional Water Company, Ministry of Energy, Tehran, Iran

Received: 11 March 2023

Revised: 13 May 2023

Accepted: 20 May 2023

### Abstract

A significant amount of the damages caused by floods is usually due to suspended sediments in the flood and dredging costs due to their subsidence in natural, residential and industrial areas. Therefore, sediment monitoring is very important when the water discharges. On the other hand, the non-linear nature of sediment data have made it difficult to predict this parameter. Wavelet theory is one of the pre-processing methods that can help we lead to a better resolution of the internal relationships of non-linear data by breaking down the main time series into sub-signals. In this research, the sediment data values in two stations of Abnama and Minab from Hormozgan River watershed were broken through wavelet conversion into sub-signals, and then the prediction process was carried out by the artificial neural network. Moreover, in order to investigate the impact of wavelet transform on the performance of the neural network model, the results obtained from this combined model were compared with the results obtained from the single neural network model, and their efficiency was evaluated using multi-part validation method, correlation, and root-mean-square error. The results showed that the artificial neural network in the two studied stations is able to simulate the sediment discharge with a correlation of 0.89 and 0.68 as well as the wavelet neural network with a correlation of 0.9 and 0.8. Moreover, the normalized root-mean-square error statistics were 0.104 and 0.35 in artificial neural networks and 0.124 and 0.18 in combined networks, respectively. The results showed that the impact of the wavelet on identifying sub-signals and thus improving the performance of the model compared to individual neural networks on predicting the amount of sediments in floods is clearly significant.

**Keywords:** Suspended Sediment, Data Mining, Machine Learning, Artificial Neural Network, Wavelet Network

\*. Corresponding author: Mehdi Hayatzadeh E-mail: mhayatzadeh@ardakan.ac.ir Tel: + 989132569577

**How to cite this Article:** Yar, H., Hayatzadeh, M., Fathzadeh, A., Afkhami, H. (2023). Investigating the impact of wavelet network on the efficiency of artificial neural network in predicting flood sediments. *Journal of Geography and Environmental Hazards*, 12(4), 161-186.

DOI: 10.22067/geoeh.2023.80745.1342



Journal of Geography and Environmental Hazards are fully compliant With open access mandates, by publishing its articles under Creative Commons Attribution 4.0 International License (CC BY 4.0).



Creative Commons Attribution 4.0 International License (CC BY 4.0)

## Geography and Environmental Hazards

Volume 12, Issue 4 - Number 48, Winter 2024

<https://geoeh.um.ac.ir>

<https://doi.org/10.22067/geoeh.2023.80745.1342>

جغرافیا و مخاطرات محیطی، سال دوازدهم، شماره چهارم و هشتم، زمستان ۱۴۰۲، صص ۱۸۶-۱۶۱  
مقاله پژوهشی

### بررسی تأثیر شبکه موجک بر کارایی شبکه عصبی مصنوعی در پیش‌بینی رسوبات سیلابی

حلیمه یار - کارشناسی ارشد آبخیزداری، دانشگاه اردکان، اردکان، ایران

مهدی حیات زاده<sup>۱</sup> - استادیار آبخیزداری، دانشگاه اردکان، اردکان، ایران

علی فتح‌زاده - دانشیار آبخیزداری، دانشگاه اردکان، اردکان، ایران

حمیده افخمی - دکتری آبخیزداری، شرکت آب منطقه‌ای تهران، وزارت نیرو، تهران، ایران

تاریخ دریافت: ۱۴۰۱/۱۲/۲۰ تاریخ بازنگری: ۱۴۰۲/۲/۲۳ تاریخ تصویب: ۱۴۰۲/۲/۳۰

#### چکیده

معمولاً سهم قابل ملاحظه‌ای از خسارت‌های ناشی از سیلاب، به رسوبات معلق در جریان سیل و هزینه‌های لایروبی ناشی از نشست آن‌ها در مناطق طبیعی، مسکونی و صنعتی برمی‌گردد. از این رو هنگام وقوع سیلاب علاوه بر پارامتر دبی آب، پایش دبی رسوبات حمل شده در آب نیز بسیار حائز اهمیت است. امروزه شبکه‌های عصبی مصنوعی به‌خوبی برای پیش‌بینی سری‌های زمانی غیرخطی توسعه یافته‌اند، اما ماهیت غیرخطی داده‌های رسوب و تأثیر گسترده‌ای از عوامل مختلف بر میزان دبی رسوب، منجر شده تا پیش‌بینی این داده‌ها همواره با چالش‌هایی مواجه باشند. تئوری موجک از جمله روش‌های پیش‌پردازشی است که می‌تواند با تجزیه سری‌های زمانی اصلی به سیگنال‌های فرعی منجر به وضوح بهتر روابط درونی داده‌های غیرخطی گردد. در تحقیق حاضر مقادیر داده‌های رسوب در دو ایستگاه آبنا و میناب از حوزه آبخیز رودان هرمزگان قبل از ورود به شبکه عصبی مصنوعی از طریق تبدیل موجک به سیگنال‌های فرعی شکسته شد و سپس توسط شبکه عصبی مصنوعی فرایند پیش‌بینی صورت پذیرفت. همچنین به‌منظور بررسی تأثیر تبدیل موجک در عملکرد مدل شبکه عصبی، نتایج حاصل از این مدل ترکیبی با نتایج به دست آمده از

Email: [mhayatzadeh@ardakan.ac.ir](mailto:mhayatzadeh@ardakan.ac.ir)

۱ نویسنده مسئول: ۰۹۱۳۲۵۶۹۵۷۷

نحوه ارجاع به این مقاله:

یار، حلیمه؛ حیات زاده، مهدی؛ فتح‌زاده، علی؛ افخمی، حمیده؛ ۱۴۰۳. بررسی تأثیر شبکه موجک بر کارایی شبکه عصبی مصنوعی در پیش‌بینی رسوبات سیلابی. جغرافیا و مخاطرات محیطی. ۱۲(۴). صص ۲۱-۱

<https://doi.org/10.22067/geoeh.2023.80745.1342>

مدل شبکه عصبی منفرد مقایسه گردید و کارایی آن‌ها با استفاده از روش اعتبارسنجی چندتکه، همبستگی و ریشه میانگین مربعات خطا مورد ارزیابی قرار گرفت. نتایج حاصله نشان داد شبکه عصبی مصنوعی در دو ایستگاه مورد مطالعه به ترتیب با همبستگی ۰/۸۹ و ۰/۶۸ و شبکه عصبی موجکی با همبستگی ۰/۹ و ۰/۸ قادر به شبیه‌سازی میزان رسوبات هستند. همچنین آماره نرمال شده ریشه میانگین مربعات خطا به ترتیب در شبکه‌های عصبی مصنوعی ۰/۱۰۴ و ۰/۳۵ و در شبکه‌های ترکیبی ۰/۱۲۴ و ۰/۱۸ به دست آمد. با توجه به نتایج داده‌ها، تأثیر موجک در شناسایی سیگنال‌های فرعی و در نتیجه بهبود عملکرد مدل نسبت به شبکه‌های عصبی منفرد در پیش‌بینی میزان رسوبات قابل حمل در سیلاب به‌وضوح قابل توجه است.

**کلیدواژه‌ها:** رسوب معلق، داده‌کاو، یادگیری ماشین، شبکه عصبی مصنوعی، شبکه موجک.

#### ۱- مقدمه

بسیاری از مخاطرات مهم زندگی بشر از قبیل آلودگی، تغییرات آب و هوایی و شهرنشینی در درجه اول ناشی از فعالیت‌های انسانی است. اگرچه هرکدام از این تهدیدات دارای اثرات خاصی هستند، لکن اغلب آن‌ها مستقیماً بر روی اکوسیستم اثر می‌گذارند (عبدا و همکاران، ۲۰۲۱). یکی از پیامدهای مخرب سیل‌های ناگهانی که چندان مورد توجه قرار نگرفته است، از دست دادن قابل توجه و دائمی خاک به دلیل فرسایش آن و تولید رسوب است (کفاس و همکاران، ۲۰۲۲). انتقال رسوب در رودخانه‌ها به‌عنوان یک موضوع مهم برای طراحی و برنامه‌ریزی پروژه‌های منابع آبی مطرح بوده و می‌تواند به محیط‌زیست نیز آسیب برساند. به همین دلیل مدل‌سازی اجزای بار رسوب شامل بار رسوب معلق، بار بستر و بار کل در رودخانه‌ها از اهمیت بالایی برخوردار است (روشنگر و همکاران<sup>۱</sup>، ۲۰۲۳). از جمله خسارت‌هایی که رسوبات موجود در رودخانه‌ها و سیلاب‌ها به بار می‌آورند می‌توان به انباشت رسوبات در پشت سدها و کاهش حجم مفید آن‌ها، تخریب سازه‌ها، خسارت به سواحل و بنادر، کاهش ظرفیت و افزایش هزینه نگهداری کنال‌های آبیاری و غیره اشاره نمود (زو و همکاران<sup>۲</sup>، ۲۰۰۷). از سویی حمل رسوب روی شاخص‌های کیفی آب به لحاظ شرب و کشاورزی تأثیرگذار است لذا برآورد مقدار رسوب در پروژه‌های حفاظت خاک، طراحی و اجرای سازه‌های آبی، آبخیزداری و نیز بهره‌برداری از منابع آب مورد نیاز است. بخش مهمی از بار رسوبی حمل شده توسط رودخانه و جریان‌های سیلابی به بار معلق اختصاص دارد. انتقال مواد به‌صورت بار معلق تابعی از هیدرولیک جریان، خصوصیات فیزیکی دانه رسوب و محیط قرارگیری رسوب است. برآورد بار رسوبی در رودخانه‌ها با توجه به خسارات ناشی از آن، یکی از مهم‌ترین و مشکل‌ترین قسمت‌های مطالعات انتقال رسوب و مهندسی رودخانه است (حسین و شولز<sup>۳</sup>، ۲۰۱۷). در رسوب‌شناسی، انتقال رسوب در رودخانه

1 Roushangar et al.

2 Zhu et al.

3 Hussein & Scholz

پدیده‌های غیرخطی و پیچیده‌ای بوده و در رخدادهای سیلابی که همراه با مقدار قابل توجهی رسوب می‌شود این فرایند پیچیده‌تر می‌شود. پارامترهای زمین‌شناسی، هیدرولوژیکی و مورفولوژیکی حوزه آبخیز رودخانه اثرات قابل توجهی بر فعالیت رسوب در داخل رودخانه دارند (خان و همکاران، ۲۰۱۹). در سال‌های اخیر جهت برآورد بار معلق رسوب علاوه بر استفاده از منحنی سنججه از مدل‌های غیرخطی دیگری تحت عنوان مدل‌های هوش مصنوعی که مبتنی بر فرآیند یادگیری از طریق داده‌های مشاهداتی هستند، استفاده شده است (کیسی<sup>۱</sup>، ۲۰۰۶)، شبکه‌های عصبی مصنوعی<sup>۲</sup> زیر مجموعه‌ای از تکنیک‌های هوش مصنوعی است که امروزه در طیف وسیعی برای به‌کارگیری در حل بسیاری از مسائل، شامل شبیه‌سازی، بهینه‌سازی، پیش‌بینی، تشخیص و کنترل رایج شده‌اند (اسدی و فتحزاده، ۱۳۹۷). فلامکی و همکاران (۱۳۹۲) در مدل‌سازی بار رسوب کل رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی به این نتایج دست یافتند که دقت شبکه‌های عصبی مصنوعی به‌ویژه مدل پرسپترون چندلایه در تخمین بار رسوب کل با ضریب همبستگی ۰/۹۶ بیش از سایر مدل‌هاست. همچنین مشخص شد که برای افزایش دقت مدل نیاز به آموزش آن با هر دو نوع داده‌های هیدرولوژیکی و رسوب است و درنهایت اینکه رابطه ایگر و وایت در برآورد مقدار بار رسوب کل این رودخانه نسبت به بقیه مدل‌ها دقت بهتری می‌تواند داشته باشد. افخمی و همکاران (۱۳۹۵) تأثیر توزیع‌های احتمالاتی در افزایش دقت پیش‌بینی رسوب معلق را با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی عصبی پیش‌بینی نمودند. نتایج شبیه‌سازی‌ها در دو مدل، کارایی بهتر و خطای کمتر را در شرایط استفاده از لگاریتم داده‌های رسوب نشان داد. باباعلی و دهقانی (۱۳۹۶) برای پیش‌بینی دبی سیلابی با استفاده از شبکه عصبی موجک در ایستگاه کهمان‌الشر از پارامترهای حداکثر بارش ۲۴ ساعته طی دوره زمانی ۱۳۹۱-۱۳۸۰ استفاده کردند و نتایج را با مدل‌های شبکه عصبی مصنوعی دیگر مقایسه کردند. نتایج نشان داد که مدل شبکه عصبی موجک دقت بسیار بهتری از شبکه عصبی دارد. حیات‌زاده و همکاران (۱۳۹۶) جهت بهینه‌سازی میزان رسوب معلق در حوضه فخرآباد مهریز یزد از روش‌های سنججه چندخطی، حد وسط دسته‌ها، منحنی‌سنججه حد وسط دسته‌ها، در یک دوره ۲۳ ساله با ۴۸ واقعه مشاهداتی دبی و رسوب متناظر پرداختند. آن‌ها جهت صحت‌سنجی بهینه‌یابی، این روش‌ها را با ضرایب اصلاحی QMLE<sup>۳</sup>، SMEARING و فائو مقایسه کردند. نتایج ضمن تأیید کارایی بالاتر شبکه عصبی مصنوعی نشان داد که مدل‌های شبکه عصبی مصنوعی انعطاف‌پذیری بالایی دارند و ابزاری مناسب برای مدل‌سازی در شرایط کمبود داده هستند. باباعلی و دهقانی (۱۳۹۸) با بررسی عملکرد مدل شبکه عصبی موجک در تخمین دبی روزانه ایستگاه بادآور نورآباد لرستان از داده‌های بارش ۲۴ ساعته طی دوره آماری ۱۳۹۱-۱۳۸۱ شمسی استفاده کردند. با مقایسه روند شبکه عصبی موجک و شبکه عصبی متوجه شدند که دو مدل قابلیت خوبی در تخمین دبی روزانه دارد و به‌طورکلی مدل

1 Kisi

2 Artificial Neural Networks (ANNs)

3 Quasi-Maximum Likelihood Estimator

شبکه عصبی موجک کارایی بهتری در مقایسه با شبکه عصبی در مدل‌سازی نشان داد. عطانی و همکاران (۱۳۹۸) در پژوهش خود از مدل‌های سنجه رسوب، شبکه‌های عصبی مصنوعی و برنامه‌ریزی بیان ژن (GEP)<sup>۱</sup> برای تخمین بار معلق ایستگاه هیدرومتری مشیران واقع در رودخانه دره رود استفاده کردند. نتایج نشان داد که مدل GEP با دارا بودن بیشترین مقدار ضریب تعیین ( $r^2=0/8$ ) و کمترین ریشه میانگین مربعات خطا ( $RMSE=1962$ ) تطابق بهتری با مقادیر مشاهداتی دارند. محمدی (۱۳۹۸) به منظور بهینه‌سازی برآورد میزان رسوب معلق دبی جریان ایستگاه بالادست هلیل‌رود از روش‌های شبکه عصبی مصنوعی، عصبی-فازی و منحنی‌سنجه رسوب استفاده کردند. نتایج نشان داد که مدل عصبی-فازی در همه‌ی حالات مدلی مناسب برای شبیه‌سازی است. چوی و لی<sup>۲</sup> (۲۰۱۴) با استفاده از یک مدل توزیع عرضی سرعت، بار کل رسوب را در رودخانه‌های شنی و ماسه‌ای برآورد نمودند. نتایج آن‌ها نشان داد که محاسبات مدل شبه دوبعدی دارای دقت بیشتری نسبت به معادلات تجربی انتقال رسوب است. زونمات کرمانی و همکاران<sup>۳</sup> (۲۰۱۶) به مدل‌سازی غلظت رسوب معلق بر اساس مدل‌های داده محور پرداختند. در این مطالعه با استفاده از اطلاعات سری هشت‌ساله از ایستگاه هیدرومتری واقع در آرکانزاس، دلاور و آیداهو، توانایی مدل‌های شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان (SVR)<sup>۴</sup> و منحنی‌سنجه رسوب برای پیش‌بینی غلظت معلق روزانه رسوبات مورد مقایسه قرار دادند. نتایج بر اساس معیارهای ارزیابی در این مدل‌ها نشان داد که مدل SVR با تابع RBF دارای عملکرد مناسب‌تری به‌منظور پیش‌بینی بار رسوبی معلق است. درودی و همکاران (۲۰۲۱) در تخمین بار رسوب معلق روزانه با استفاده از مدل رگرسیون بردار پشتیبانی ترکیبی جدید با روش بهینه‌سازی مبتنی بر مشاهده‌گر و یادگیرنده نشان دادند که مدل SVR-OTLBO<sup>۵</sup> عملکرد پیش‌بینی بالاتری نسبت به سایر مدل‌های به‌کاررفته در زمینه تخمین بار رسوبی را دارد. به‌طور خاص، مدل مذکور بالاترین ضریب همبستگی ( $r=0/976$ ) را نشان داد. اسدی و همکاران (۲۰۲۱) با استفاده از الگوریتم‌های مبتنی بر یادگیری ماشین و پارامترهای ژئومرفومتريک به‌عنوان پارامترهای کمکی به پیش‌بینی بار رسوب معلق در چند حوزه آبخیز پرداختند. آن‌ها در تحقیق خود از ۶ مدل یادگیری ماشین از قبیل رگرسیون خطی چندگانه، شبکه عصبی مصنوعی، K نزدیک‌ترین همسایه، فرایند گوسی، ماشین بردار پشتیبان و الگوریتم فرگشتی ماشین بردار پشتیبان استفاده کردند و نتیجه گرفتند که مدل‌های فرایند گوسی و الگوریتم فرگشتی ماشین بردار پشتیبان نتایج مناسب‌تری در برآورد بار معلق به همراه دارند. هانون و همکاران<sup>۶</sup> (۲۰۲۲) در تحقیق خود به مقایسه عملکرد روش‌های مختلف یادگیری ماشین برای پیش‌بینی بار رسوب معلق پرداختند. آن‌ها چهار تکنیک

1 Gene expression programming

2 Choi and Lee

3 Zounemat-Kermani et al.

4 Support vector regression

5 Support vector regression-observer teacher learner-based optimization

6 Hanoon et al.

رگرسیون تقویت گرادیان (GBT)<sup>۱</sup>، جنگل تصادفی (RF)<sup>۲</sup>، ماشین بردار پشتیبان و شبکه عصبی مصنوعی را برای پیش‌بینی بار رسوب معلق در رودخانه جوهور مالزی به کار گرفتند. نتایج پژوهش آن‌ها نشان داد که همه‌ی مدل‌های پیشنهادی یادگیری ماشین عملکرد برتری در پیش‌بینی بار رسوبی دارند و از بین آن‌ها مدل شبکه عصبی مصنوعی از دقت بالاتری برخوردار بود. **ساهوو و همکاران**<sup>۳</sup> (۲۰۲۳) با هدف پیش‌بینی رسوب معلق مدل محاسباتی سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)<sup>۴</sup> را با الگوریتم ازدحام سالپ بهینه‌سازی نمودند. در مقایسه نتایج مدل‌های مورد استفاده، مدل بهینه‌سازی شده برتری خود را نسبت به مدل ساده‌ی سیستم استنتاج عصبی- فازی تطبیقی به اثبات رساند. از آنجاکه مدل‌سازی فرایندهای بار رسوب جریان به دلیل ماهیت پیچیده آن با عدم قطعیت بیشتری نسبت به سایر فرایندهای اقلیمی و هیدرولوژیکی برخوردار است، لذا انتخاب مدلی که بتواند به‌صورت نسبی بر این مشکل فائق آید بسیار حائز اهمیت است. از طرفی انعطاف‌پذیری و کارایی مناسب مدل‌های هوش مصنوعی در مدل‌سازی‌های فرایندهای اقلیمی و هیدرولوژیکی در مطالعات زیادی به اثبات رسیده است (مختاری و آخوندزاده هنزائی، ۱۳۹۸). ولی مشکل اصلی در زمینه مدل‌سازی بار رسوب معلق عدم‌کفایت داده‌های ثبت شده و کوتاه بودن سری زمانی داده‌های مشاهداتی است که با وجود انعطاف‌پذیری مدل‌های شبکه عصبی مصنوعی ولی باز هم مدل‌سازی‌ها با خطای نسبی روبرو می‌باشد. از طرفی کارایی مدل‌های موجک در مدل‌سازی فرایندها و متغیرهای با توزیع نرمال به اثبات رسیده است (نورانی و عندلیب، ۱۳۹۶). لذا در این تحقیق با در نظر گرفتن نقاط ضعف و قوت مدل‌های مختلف هوش مصنوعی و همچنین ماهیت داده‌های رسوب معلق سعی بر آزمون کارایی این مدل‌ها به شکل تفکیک شده و همچنین در حالت تلفیق شده را در حوزه آبخیز رودان دارد.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

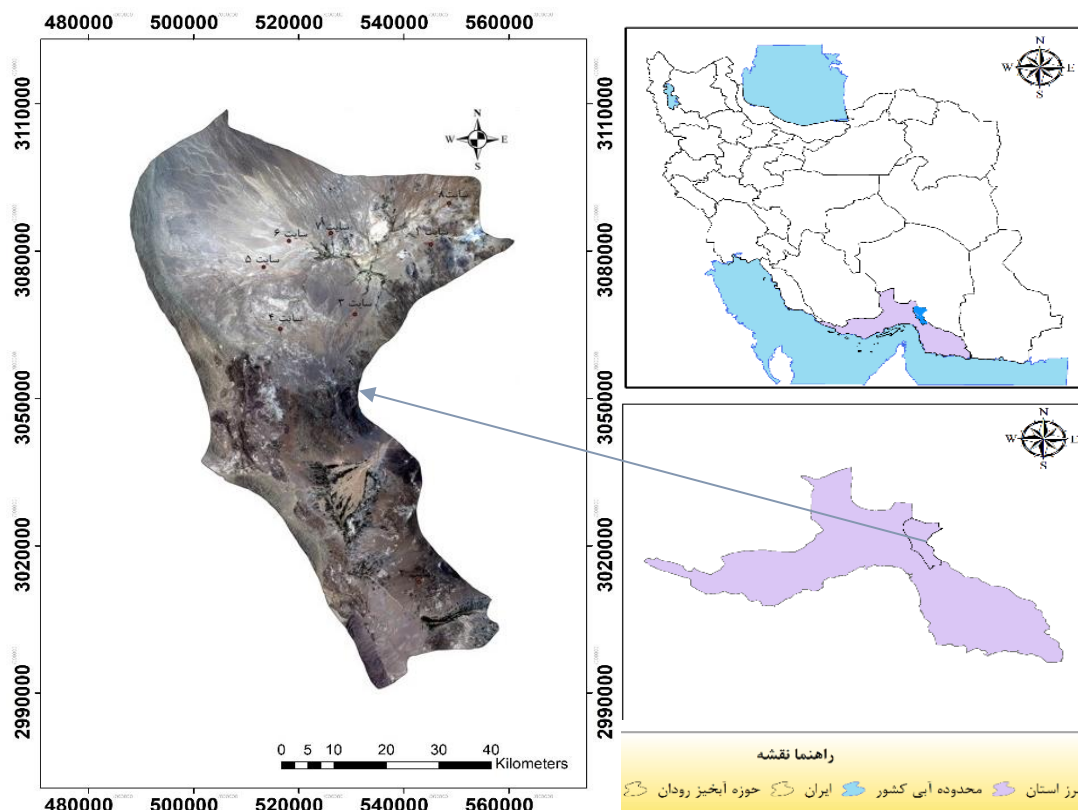
حوزه آبخیز رودان در بخش شمال شرقی استان هرمزگان با مختصات ۲۷ درجه و ۲۷ دقیقه عرض شمالی و ۵۷ درجه و ۱۱ دقیقه طول شرقی با مساحتی معادل ۳۰۴۴/۵ کیلومتر مربع و در فاصله ۱۰۰ کیلومتری بندرعباس قرار دارد. ارتفاع حوزه از سطح دریا حدود ۱۹۰ متر است و بر اساس طبقه اقلیمی دومارتن دارای اقلیم گرم و خشک است، میانگین بارش سالانه در این منطقه ۲۵۰ میلی‌متر و متوسط دمای بلندمدت آن ۲۷ درجه سانتی‌گراد می‌باشد. شکل (۱) موقعیت منطقه مورد مطالعه را نشان داده است.

1 Gradient boost regression

2 Random forest

3 Sahoo et al.

4 Adaptive Neuro-Fuzzy Inference System



شکل ۱- موقعیت منطقه مورد مطالعه

رودخانه‌های اصلی زیر حوضه رودان شامل رودخانه کندر که از کوه‌های شمالی منطقه (جنوب استان کرمان) سرچشمه گرفته و از شمال به جنوب جریان دارد و رودخانه فاریاب که از شمال غرب وارد حوضه می‌شود. این دو رودخانه بعد از شهر رودان (جنوب شهر) به هم متصل شده، پس از پیمودن مسیری به طول حدود ۳۰ کیلومتر، نهایتاً به سد میناب سرازیر می‌شوند. سیلاب‌های فصلی نواحی اطراف نیز پس از سرازیر شدن از ارتفاعات به پهنه آبرفتی رودخانه دهباز (رودان) می‌ریزند. با توجه به حضور سازندهای فرسایش پذیر در حوضه و افزایش بار معلق در هنگام بارندگی، معضل رسوب‌گذاری و تخریب اراضی همواره از دغدغه‌های بهره‌برداران در حوضه می‌باشد. لذا به منظور پیش‌بینی میزان بار معلق برای مدیریت حوضه در سال‌های آتی، اطلاعات موردنیاز از دو ایستگاه هیدرومتری میناب و آبنا مشتمل بر مقادیر دبی، رسوبدهی، غلظت رسوب، ارقام اشل و بارندگی از شرکت آب منطقه‌ای استان هرمزگان جمع‌آوری گردید. این داده‌ها با ترکیبات و سناریوهای مختلف جهت ورود به مدل آماده‌سازی شده سپس مورد تجزیه و تحلیل قرار گرفت. پیش‌پردازش‌های لازم نیز از جمله حذف داده‌های پرت و نرمال‌سازی بر روی داده‌ها انجام

شد. جدول (۱) و (۲) برخی از جزئیات داده‌های مورد استفاده را نشان می‌دهد. شکل (۲) وضعیت رودخانه‌های ایستگاه‌های مورد استفاده را در مواقع سیلابی نشان می‌دهد.

جدول ۱- مشخصات ایستگاه‌های دبی و رسوب‌سنجی

نام ایستگاه	X (UTM)	Y (UTM)	دوره آماری
میناب	۵۳۵۰۸۹	۳۰۳۸۷۷	۱۳۳۸-۸۸
آبنا	۵۱۳۷۶۷	۳۰۷۱۷۹۱	۱۳۷۴-۸۷



شکل ۲- وضعیت رودخانه میناب و رودخانه آبنا رودان در مواقع سیلابی

جدول ۲- اطلاعات وارد شده به مدل مورد استفاده

پارامتر	نام ایستگاه	اشل (سانتی‌متر)	آبدهی (مترمکعب بر ثانیه)	متوسط مقاطع اندازه‌گیری (میلی‌گرم در لیتر)	نقطه ثابت (میلی‌گرم در لیتر)	پردار هدف (تن در روز)
بیشترین مقدار	میناب	۸۰۰	۱۳۰۰	۳۸۹۰۰	۴۱۱۰۰	۱۶۵۳۰۰۰
	آبنا	۲۷۰	۴۲۰	۱۹۰۳۰	۱۹۳۰	۴۵۵۵۰۰
کمترین مقدار	میناب	۱۹	۱/۲۱	۲/۳۳	۲	۰/۶۴
	آبنا	۹۶	۱	۵/۳۳	۵	۰/۵۹
انحراف استاندارد	میناب	۹۰	۱۹۰	۶۹۶۰	۶۵۹۰	۲۳۹۹۹۰
	آبنا	۳۳	۶۲	۴۱۱۷	۴۱۷۲	۷۱۱۸۶
میانگین	میناب	۱۱۴	۸۳	۴۴۴۷	۴۱۷۴	۷۵۷۹۱
	آبنا	۱۳۹	۳۲	۲۲۶۲	۲۳۳۴	۱۹۵۰۴



## ۲-۲- پیش پردازش داده‌ها

در این پژوهش برای آماده‌سازی داده‌ها جهت مدل‌سازی از روش نرمال‌سازی داده‌ها استفاده شده است. لذا از روش بیشترین-کمترین<sup>۱</sup> استفاده شده است. پس از انجام نرمال‌سازی می‌توان مشاهده کرد که تمامی داده‌ها در یک محدوده قرار دارند. برای نرمال‌سازی از رابطه ۱ استفاده گردیده است (آرمین و قربانیان، ۱۳۸۸):

$$\frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

که در آن:  $x$ : بیانگر داده‌ای است که باید نرمال شود،  $\min(x)$ : کمترین مقدار در داده‌ها،  $\max(x)$ : بیشترین مقدار در داده‌ها و  $Z$ : نتیجه نرمال‌سازی داده می‌باشد.

بر اساس رابطه (۱) مقدار خروجی  $Z$  در بازه صفر (اگر  $x$  برابر مقدار  $\min$  باشد) و ۱ (اگر  $x$  برابر مقدار  $\max$ ) قرار خواهد گرفت.

ورودی‌های شبکه با نام لایه ورودی و خروجی‌های شبکه با نام لایه خروجی و در صورت نیاز، لایه‌های میان این دو لایه، لایه نهان نامیده می‌شود. شکل شماره ۳ نشان‌دهنده یک ساختار ساده از شبکه عصبی می‌باشد (بهزادفر، ۱۳۹۱). ساختار شبکه عصبی موجک یا WNN<sup>۲</sup> همانند ساختار شبکه عصبی پس انتشار است (شکل ۴) و تفاوت آن با شبکه عصبی معمولی در تابع گذر آن است. در شبکه عصبی موجک تابع گذر لایه‌های نهان، تابع موجک مادر است (پیری و همکاران، ۱۳۸۴).

## ۲-۳- مدل‌سازی شبکه

در پژوهش حاضر به منظور انجام مدل‌سازی از الگوریتم و توابع آموزشی مختلف استفاده شد. شبکه عصبی پرسپترون چندلایه<sup>۳</sup> با روش آموزش پس انتشار خطا<sup>۴</sup> و تابع فعال‌سازی تانژانت سیگموئید<sup>۵</sup> و شبکه عصبی پرسپترون چندلایه با روش آموزش پیش انتشار خطا و تابع فعال‌سازی موجک ملقب به شبکه عصبی موجک طراحی گردیدند. شکل ۵ ساختار شبکه‌های عصبی مورد استفاده در این پژوهش (چه الگوریتم MLP و چه الگوریتم WNN) را نشان می‌دهد.


1 Max-Min

2 Wavelet neural network

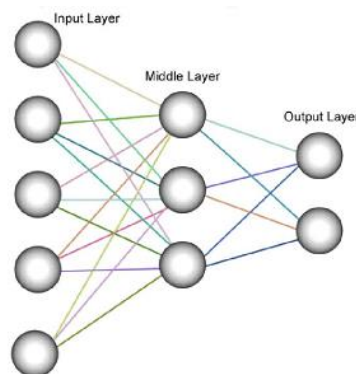
3 Multilayer Perceptron (MLP)

4 Error Backpropagation


5 Tangent sigmoid



شکل ۴- ساختار شبکه عصبی موجک



شکل ۳- ساختار یک شبکه عصبی ساده



شکل ۵- ساختار شبکه عصبی مورد استفاده

همچنین در این مدل تعداد ۴ ورودی در نظر گرفته شد که برابر تعداد ویژگی‌ها یا مؤلفه‌های داده‌های جمع‌آوری شده است. تعداد لایه‌های نهان ۳ عدد بوده که تعداد نرون‌ها در لایه نهان اول، دوم و سوم به ترتیب برابر ۱۳، ۹ و ۴ در نظر گرفته شد. تابع آستانه گذار در لایه نهان اول و دوم تانژانت سیگموئید و برای لایه نهان سوم خطی (با توجه به ماهیت کار که رگرسیون است) در نظر گرفته شد (برای شبکه عصبی ساده یا MLP). تابع گذار در هر سه لایه نهان در WNN تابع موجک در نظر گرفته شد و نتایج تا حصول نتیجه نهایی از طریق آزمون و خطا ادامه یافت. در مرحله آموزش مدل، حداکثر تعداد تکرار الگوریتم برابر ۱۰۰، معیار ارزیابی کارایی در حین آموزش شبکه عصبی، معیار MSE، نرخ یادگیری برابر ۰/۰۱، ضریب کاهش نرخ یادگیری ۰/۹۹، الگوریتم آموزش شبکه عصبی، تابع لونبرگ-مارکواریت<sup>۱</sup>، در نظر گرفت شد. این روش برای حوضه‌هایی با تعداد کم داده مناسب است. همچنین روند اعتبارسنجی مبتنی بر K-fold C.V<sup>۲</sup> مطابق شکل (۶) در نظر گرفته شد.

1 Levenberg–Marquardt (LM)

2 K-fold Cross Validation (K-fold C.V)

## ۲-۴- معیارهای ارزیابی

برای بررسی کارایی روش شبکه عصبی موجک، از معیارهای ارزیابی میانگین خطای مربعات (RMSE)<sup>۱</sup>، ضریب همبستگی<sup>۲</sup>، میانگین خطای مربعات نرمال شده (NRMSE)<sup>۳</sup> و استفاده می‌شود (جدول ۳). برای بررسی کارایی روش پیشنهادی، بر اساس معیارهای ارزیابی معرفی شده در بخش قبل، از روش برش چندنقطه‌ای استفاده شد. تعداد برش‌ها یا مقدار k در K-fold CV برابر ۵ در نظر گرفته شد. در این روش ارزیابی ابتدا مجموعه داده‌های مورد استفاده به پنج (k) قسمت مساوی تقسیم شد که چهار (k-1) قسمت آن برای آموزش (ساخت) مدل و قسمت باقی‌مانده جهت ارزیابی (آزمون) مدل مورد استفاده قرار می‌گیرد. این فرآیند پنج (k) بار به صورت مستقل انجام می‌شود به گونه‌ای که در هر تکرار چهار قسمت برای ساخت مدل و قسمت باقی‌مانده جهت ارزیابی انتخاب می‌شوند. در این روش در هر تکرار، تکه‌ای (برشی) از داده که تاکنون برای آزمون به کار نرفته است، جهت آزمون مدل و برش‌های دیگر جهت ساخت مدل به کار می‌رود. در هر بار ساخت مدل، معیارهای ارزیابی روی داده‌های آزمون ذخیره شده و میانگین آن‌ها برای پنج بار تکرار به عنوان کارایی نهایی گزارش می‌گردد.

جدول ۳- معیارهای ارزیابی روش پیشنهادی

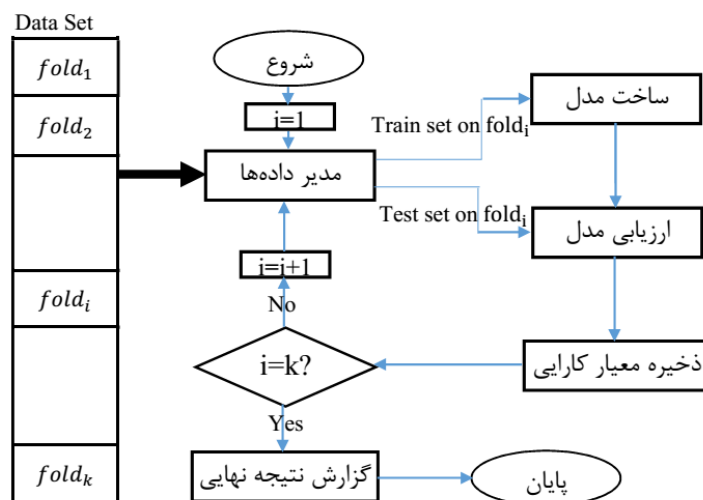
معیار ارزیابی	نماد	فرمول محاسبه	هدف پژوهش (رگرسیون)
ریشه دوم میانگین خطای مربعات	MRSE	$\sqrt{\frac{\sum_{i=1}^n (y_i - t_i)^2}{n}}$	کاهش مقدار
ضریب همبستگی	Corr	$\frac{cov(y_i, t_i)}{\sqrt{Var(y_i) * Var(t_i)}}$	افزایش مقدار
ریشه دوم میانگین خطای مربعات نرمال شده	NRMSE	$\frac{MRSE}{(t_{max} - t_{min})}$	کاهش مقدار
ضریب تعیین	R <sup>2</sup>	$1 - \frac{\sum (t_i - y_i)^2}{\sum (t_i - \bar{t})^2}$	افزایش مقدار

بردار t خروجی مورد انتظار نمونه‌ها، بردار y خروجی مدل برای نمونه‌ها و n بیانگر تعداد نمونه‌هاست.

1 Root means square error

2 Correlation Coefficient

3 Normalized root-mean-square deviation



شکل ۶- فلوچارت روش ارزیابی K-fold CV

## ۳- نتایج و بحث

## ۳-۱- نتایج شبکه MLP

جدول (۴) نتایج حاصل از اجرای الگوریتم MLP در ایستگاه‌های آبنا و میناب بر اساس 5-fold CV را نشان

می‌دهد.

جدول ۴- نتایج مدل‌سازی رسوب با الگوریتم MLP

معیار/ شماره تکه	RMSE		NRMSE		R	
	آبنا	میناب	آبنا	میناب	آبنا	میناب
۱	۱۲۶۸۸	۲۰۴۷	۰/۱۸	۰/۰۰۶	۰/۹۸	۰/۹۹
۲	۱۴۹۷	۲۱۱۲۰۰	۰/۳۹	۰/۱۲	۰/۷۵	۰/۸۱
۳	۵۶۱.۲۰	۱۸۴۳۶۰	۰/۰۶	۰/۱۲	۰/۹۹	۰/۹۵
۴	۲۴۶۷۲	۱۴۴۲۲۰	۰/۸۲	۰/۲۱	۰/۱۰	۰/۷۱
۵	۱۴۶۰۸۰	۲۶۷۳۶	۰/۳۲	۰/۰۴	۰/۶۱	۰/۹۸
میانگین نتایج	۳۷۱۰۰	۱۱۳۷۱۰	۰/۳۵	۰/۱۰۴	۰/۶۸	۰/۸۹۴

نتایج ارزیابی در جدول (۳) نشان داد که متوسط همبستگی در مدل MLP در ایستگاه آبنا ۰/۶۸ و در ایستگاه میناب ۰/۸۹۴ می‌باشد همچنین مقدار RMSE و NRMSE در ایستگاه میناب به ترتیب ۱۱۳۷۱۰ و ۰/۱۰۴ گزارش شده در حالی که در ایستگاه آبنا این مقدار معادل ۳۷۱۰۰ و ۰/۳۵ تخمین زده شده است. با توجه به مقادیر ذکر شده

پیش‌بینی مدل شبکه عصبی پرسپترون در ایستگاه میناب از همبستگی بالاتر و خطای کمتری برخوردار است که با توجه به کثرت داده در ایستگاه فوق قابل توجه می‌باشد. همچنین قابل ذکر است مقادیر و واحد دو آماره خطای RMSE و NRMSE تابع نوع داده است و متناسب با مقادیر واقعی داده‌ها می‌باشد.


### ۲-۳- نتایج شبکه WNN

در جدول (۵) نتایج حاصل از اجرای الگوریتم WNN در ایستگاه آبنا و میناب بر اساس 5-fold CV آورده شده است.

جدول ۵- نتایج WNN در ایستگاه آبنا و میناب

معیار/شماره تکه	RMSE		NRMSE		R	
	آبنا	میناب	آبنا	میناب	آبنا	میناب
۱	۱۳۰۸۹	۱۰۱۹۵	۰/۱۹	۰/۰۳۳	۰/۸	۰/۹
۲	۵۴۷/۵۷	۲۶۱۸۲۰	۰/۱۴	۰/۱۵	۰/۹	۰/۸
۳	۸۶۰/۹۹	۲۳۷۶۹	۰/۰۹۶	۰/۱۵	۰/۹	۰/۹
۴	۴۹۹۴	۱۰۴۲۷۰	۰/۱۶	۰/۱۵	۰/۸	۰/۹
۵	۱۴۲۸۷۰	۶۴۳۷۲	۰/۳۱	۰/۱۱۳	۰/۸	۰/۹
میانگین نتایج	۳۲۴۷۲	۱۳۵۶۷۰	۰/۱۸	۰/۱۲۴	۰/۸	۰/۹


نتایج حاصل از جدول ۴ نشان می‌دهد میزان همبستگی با استفاده از مدل‌های ترکیبی عصبی-موجکی در دو ایستگاه میناب و آبنا به ترتیب ۰/۹ و ۰/۸ می‌باشد که این مقادیر در مقایسه با مقادیر مشابه در مدل منفرد پرسپترون بهبود قابل توجهی داشته است. همچنین مقادیر NRMSE در دو ایستگاه به ترتیب ۰/۱۲۴ و ۰/۱۸ و مقادیر RMSE در دو ایستگاه به ترتیب ۱۳۵۶۷۰ و ۳۲۴۷۲ برآورد شده است. مقدار آماره خطای NRMSE و RMSE در مدل ترکیبی و در ایستگاه آبنا نسبت به مدل پرسپترون کاهش قابل توجهی داشته ولی این میزان در ایستگاه میناب اندکی افزایش یافته است که با توجه به بزرگی مقادیر رسوب ورودی در این ایستگاه قابل چشم‌پوشی می‌باشد. مقادیر ضریب همبستگی در دو مدل جهت مقایسه در شکل ۶ آورده شده است.




شکل ۷- مقایسه کارایی MLP و WNN بر اساس معیار همبستگی

با توجه به نتایج به دست آمده و شکل ۷ مشخص است مدل WNN در ارزیابی و پیش‌بینی مقدار رسوب بهتر عمل کرده است.

شکل ۸ و ۹ نتایج حاصل از آموزش دو مدل در دو ایستگاه را نشان می‌دهد. همان‌طور که مشاهده می‌شود در مرحله آموزش نیز شبیه‌سازی و آموزش در ایستگاه میناب نسبت به آبنما بهتر انجام شده است. بطوریکه در ایستگاه آبنما در مرحله آموزش مدل ANN دارای همبستگی برابر با ۰/۶۱ است درحالی‌که این ضریب برای مدل WNN برابر ۰/۷۲ می‌باشد. ایستگاه میناب دارای شرایط متفاوت‌تر از ایستگاه آبنما است. در این ایستگاه مقدار R برای مدل ANN برابر است با ۰/۹۴ و برای مدل WNN برابر با ۰/۹۹ می‌باشد. با توجه به اینکه نمونه‌ها اطراف خط رگرسیون با فاصله کمتر و همبستگی بالایی پراکنش دارند لذا در این ایستگاه جمع داده‌ها در مرکز مختصات بالاست و همانند ایستگاه آبنما به تعداد نمونه‌های بیشتری برای ساخت مدل نیاز است. کارایی مدل ANN در ایستگاه میناب نسبت به ایستگاه آبنما بهتر بوده است. به‌طورکلی در ایستگاه میناب، کارایی ANN از کارایی WNN بهتر می‌باشد.



شکل ۸- مقایسه نتایج ANN و WNN در ایستگاه آبنا در برش پنجم داده‌ها



شکل ۹- مقایسه نتایج ANN و WNN در ایستگاه میناب در برش پنجم داده‌ها

#### ۴- نتیجه گیری

با توجه به اهمیت رسوب به‌عنوان یک پدیده پیچیده، استفاده از مدل‌های هوشمند جعبه سیاه مانند شبکه‌های عصبی مصنوعی و الگوریتم‌های مختلف آن می‌تواند به برآورد دقیق‌تر رسوب منجر شود. در تحقیق حاضر که به‌منظور پیش‌بینی داده‌های رسوب معلق در دو ایستگاه میناب و آبنا انجام گرفت، کارایی دو مدل شبکه عصبی پرسپترون و شبکه عصبی موجکی مورد آزمون قرار گرفت. در این راستا به‌منظور افزایش عملکرد شبکه‌های عصبی

این مدل با آنالیز موجک ترکیب گردید، بدیهی است مدل‌های هیبرید ایجاد شده از توانایی بالای شبکه‌های عصبی و همچنین موجک، هر دو بهره می‌برد. لذا مقادیر خروجی موجک به‌عنوان مقادیر ورودی شبکه‌های عصبی به کار گرفته شد. به‌منظور تأثیر عملکرد موجک در مدل‌های هیبریدی، نتایج به دست آمده از دو مدل هیبرید با نتایج حاصل از مدل شبکه عصبی و در شرایط منفرد و بدون تلفیق با مدل موجک مقایسه گردید. بر اساس نتایج به دست آمده تلفیق موجک با مدل شبکه عصبی پرسپترون منجر به افزایش چشمگیری در بهبود کارایی آن بخصوص در ایستگاه آبنما شده است؛ به‌طوری‌که ضریب همبستگی شبکه‌های عصبی در شرایط بدون تلفیق از  $0/68$  و  $0/89$  در ایستگاه آبنما و میناب به  $0/8$  و  $0/9$  در مدل ترکیبی ارتقا یافت. این در حالی است که مقادیر  $RMSE$  و  $NRMSE$  در دو ایستگاه آبنما کاهش و در ایستگاه میناب تفاوت قابل ملاحظه‌ای نداشت. اگرچه این کارایی مدل در ایستگاه آبنما مشهودتر می‌باشد ولی در مجموع افزایش عملکرد مدل‌های ترکیبی در پیش‌بینی رسوب نسبت به مدل‌های منفرد به اثبات رسید. نتایج تحقیق حاضر با نتایج تحقیق **حیات زاده و همکاران (۱۳۹۶)** و **افخمی و همکاران (۱۳۹۵)** مقایسه گردید و عملکرد مناسب و انعطاف‌پذیری مدل‌های شبکه عصبی به‌ویژه به‌صورت تلفیقی در پیش‌بینی بار رسوب جریان همسو با آن‌ها به اثبات رسید.

همچنین نتایج تحقیق **نورانی و همکاران (۱۳۹۶)** در به‌کارگیری مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی و ماشین بردار پشتیبان در پیش‌بینی بار رسوب معلق آجی جای کارایی بالاتر مدل‌های تلفیقی شبکه عصبی با شبکه موجک را تأیید می‌نماید. نتایج به دست آمده از تحقیق حاضر با به‌کارگیری ترکیب‌های مختلف شبکه‌های عصبی با الگوریتم‌های مختلف و در تلفیق با شبکه موجک که وجه تمایز این تحقیق با سایرین نیز می‌باشد، نشان می‌دهد که با به‌کارگیری شبکه عصبی از نوع پرسپترون چندلایه و تابع تحریک از نوع تانژانت سیگموئید، می‌توان با دقت مناسبی میزان دبی بار معلق رسوب را پیش‌بینی نمود و دقت به‌دست آمده از مدل تلفیقی باز هم نتایج بهتری را ارائه می‌دهد. همچنین مدل تلفیقی مورد استفاده، مقادیر دبی رسوب را اندکی بیش‌برآورد می‌کند که در مطالعات فرسایش و رسوب این بیش‌برآورد می‌تواند در جهت اطمینان باشد. نتایج حاصل از پژوهش نشان داد که افزایش تعداد پارامترهای مؤثر در مدل‌های مختلف برای شبیه‌سازی دبی رسوبی به‌ویژه پارامترهای مقطع جریان، موجب عملکرد بهتر در مدل‌سازی می‌شود که با نتایج پژوهش **Satari و همکاران (۲۰۱۵)** و **ترابی‌پوده و همکاران (۱۳۹۸)** همخوانی دارد. همچنین تجزیه و تحلیل پژوهش‌های مذکور بیان‌کننده این است که افزایش تعداد پارامترهای مؤثر در ورودی موجب گسترش حافظه مدل برای تخمین مقادیر خروجی می‌باشد و همچنین باعث شده تعداد داده‌ها برای آموزش شبکه بیشتر شده و شبکه به‌خوبی تعمیم داده شود. همچنین نتایج حاکی از کارایی بالاتر مدل شبکه عصبی موجک و خطای کمتر آن نسبت به شبکه عصبی مصنوعی می‌باشد. در تبیین نتایج می‌توان بیان کرد که شبکه عصبی موجک در پیش‌بینی دبی رسوبی در حجم بالا که اندازه‌گیری و کارهای آزمایشگاهی آن‌ها پرهزینه و زمان‌بر است، کارایی مناسبی دارد.



همچنین دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال‌ها با کمک تابع گسسته موجک منجر به ساده‌تر شدن این سیگنال‌ها شده باعث ایجاد برتری محسوس نسبت به سایر مدل‌های شبکه می‌گردد.

#### کتابنامه

- اسدی، مریم؛ فتحزاده، علی؛ ۱۳۹۷. بررسی کارایی مدل‌های مبتنی بر هوش محاسباتی در برآورد بار معلق رودخانه‌ها (مطالعه موردی: استان گیلان). مرتع و آبخیزداری (منابع طبیعی ایران)، ۷۱ (۱): ۶۰-۴۵.  
<https://10.22059/JRWM.2018.222810.1083>
- افخمی، حمیده؛ دستورانی، محمدتقی؛ فتوحی، فرزانه؛ ۱۳۹۵. تأثیر توزیع‌های احتمالاتی در افزایش دقت پیش‌بینی رسوب معلق با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی-عصبی (مطالعه موردی: حوزه آبخیز سد دز). مرتع و آبخیزداری (منابع طبیعی ایران)، ۶۹ (۲): ۳۳۸-۳۲۳.  
<https://10.22059/JRWM.2016.61686>
- آرمین، محسن؛ قربان‌نیا، وجیهه؛ ۱۳۸۸. بررسی رابطه دبی آب و دبی رسوب با استفاده از آمار طولانی‌مدت ایستگاه‌های هیدرومتری (مطالعه موردی: رودخانه‌های چالوس و هریجان در استان مازندران)، هشتمین سمینار بین‌المللی مهندسی رودخانه، دانشگاه شهید چمران، اهواز.  
<https://civilica.com/doc/86206/>
- باباعلی، حمیدرضا؛ دهقانی، رضا؛ ۱۳۹۶. پیش‌بینی دبی سیلابی با استفاده از شبکه‌ی عصبی موجک. هیدروژئومورفولوژی، ۱۱: ۱۶۸-۱۴۹.  
[https://hyd.tabrizu.ac.ir/article\\_6719.html](https://hyd.tabrizu.ac.ir/article_6719.html)
- باباعلی، حمیدرضا؛ دهقانی، رضا؛ ۱۳۹۸. بررسی عملکرد مدل شبکه عصبی موجک در تخمین دبی روزانه. مجله علوم و مهندسی آبیاری، ۴۲ (۳): ۱۱۶-۱۰۵.  
<https://10.22055/JISE.2017.22047.1580>
- بهادفر، مرتضی؛ صادقی، حمیدرضا؛ خانجانی، محمد جواد؛ حزباوی، زینب؛ ۱۳۹۱. تأثیرپذیری تولید روان آب و رسوب خاک‌های تحت چرخه انجماد-ذوب در شرایط شبیه‌ساز باران. نشریه حفاظت منابع آب و خاک. ۲ (۱): ۱۳-۲۳.  
[https://wsrj.srbiau.ac.ir/article\\_1974.html](https://wsrj.srbiau.ac.ir/article_1974.html)
- پیروی، علی؛ حبیب‌نژاد، محمد؛ احمدی، مرتضی؛ سلیمانی، کریم؛ مساعدی، ابوالفضل؛ ۱۳۸۴. بهینه‌سازی رابطه دبی آب و رسوب در حوضه معرف امامه، پژوهشنامه علوم کشاورزی و منابع طبیعی خزر، ۳ (۳): ۴۰-۳۰.  
<https://www.magiran.com/volume/32830>
- ترابی‌پوده، حسن؛ گودرزی، احمد؛ دهقانی، رضا؛ ۱۳۹۸. کاربرد شبکه عصبی موجک در تخمین رسوبات معلق رودخانه‌ها، مطالعه موردی: رودخانه کشکان-لرستان. نشریه مهندسی و مدیریت آبخیز. ۱۱ (۳): ۶۶۰-۶۵۰.  
<https://doi.org/10.22092/ijwmse.2018.116846.1411>
- حیات‌زاده، مهدی؛ اختصاصی، محمد رضا؛ ملکی‌نژاد، حسین؛ فتحزاده، علی؛ ۱۳۹۶. بهینه‌یابی برآورد میزان رسوب معلق در مناطق خشک مطالعه موردی: حوضه فخرآباد مهریز (یزد)، فصلنامه علوم آب و خاک. ۲۱ (۱): ۱۳-۱.  
<https://10.18869/acadpub.jstnar.21.1.113>

عطائی، یاسمن؛ نیک‌پور، محمد رضا؛ کانونی، امین؛ حسینی، یاسر؛ ۱۳۹۸. برآورد بار معلق رودخانه با استفاده از مدل‌های ANN، GEP و منحنی‌سنجه (مطالعه موردی: ایستگاه مشیران، رودخانه دره‌رود)، دومین کنفرانس بین‌المللی و ششمین کنفرانس ملی کشاورزی ارگانیک و مرسوم، اردبیل، دانشگاه محقق اردبیلی، ۱۰-۱.

<https://repository.uma.ac.ir/id/eprint/9461/>

فلامکی، امین؛ اسکندری، مهناز؛ بغلانی، عبدالحسین؛ احمدی، سید احمد؛ ۱۳۹۲. مدل‌سازی بار رسوب کل رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی. نشریه حفاظت منابع آب و خاک، ۲ (۳): ۲۵-۱۳.

[https://journals.srbiau.ac.ir/article\\_1986.html](https://journals.srbiau.ac.ir/article_1986.html)

محمدی، صدیقه؛ ۱۳۹۸. شبیه‌سازی بار رسوب معلق با استفاده از روش‌های شبکه عصبی مصنوعی، عصبی-فازی و منحنی‌سنجه رسوب در حوزه آبخیز هلیل‌رود. نشریه علمی-پژوهشی مهندسی و مدیریت آبخیز. ۱۱ (۲): ۴۵۲-۴۶۶

<https://doi.org/10.22092/ijwmse.2017.108140.1219>

مختاری، رامین؛ آخوندزاده هنزائی، مهدی؛ ۱۳۹۸. ترکیب شبکه عصبی و تبدیل موجک به‌منظور پیش‌بینی خشکسالی کشور ایران با استفاده از داده‌های ماهواره‌ای مادیس و TRMM. نشریه مهندسی فناوری اطلاعات مکانی، ۷ (۴): ۱۷۵-۱۹۱

<https://jgit.kntu.ac.ir/article-1-769-fa.html>

نورانی، وحید؛ عندلیب، غلامرضا؛ ۱۳۹۶. بکارگیری مدل‌های ترکیبی موجک- شبکه عصبی مصنوعی و ماشین بردار پشتیبان در پیش‌بینی بار رسوب معلق آجی‌چای. رویکردهای نوین در مهندسی عمران، ۱ (۲): ۵۵-۴۶.

<https://10.30469/JNACE.2018.63079>

Abda, Z., Zerouali, B., Alqurashi, M., Chettih, M., Santos, C.A.G., Hussein, E.E., 2021. Suspended Sediment Load Simulation during Flood Events Using Intelligent Systems: A Case Study on Semiarid Regions of Mediterranean Basin. *Water*, 13, 3539. <https://doi.org/10.3390/w13243539>.

Asadi, M., Fathzadeh, A., Kerry, R., 2021. Prediction of river suspended sediment load using machine learning models and geo-morphometric parameters. *Arab J Geosci* 14, 1926. <https://doi.org/10.1007/s12517-021-07922-6>.

Choi, S.U., and Lee, J., 2014. Prediction of Total Sediment Load in Sand-Bed Rivers in Korea Using Lateral Distribution Method. *Journal of the American Water Resources Association*, 51 (1): 214-225. <https://doi.org/10.1111/jawr.12249>.

Doroudi, S., Sharafati, A., Mohajeri, S.H., 2021. Estimation of Daily Suspended Sediment Load Using a Novel Hybrid Support Vector Regression Model Incorporated with Observer-Teacher-Learner-Based Optimization Method. *Hindawi- Complexity*. <https://doi.org/10.1155/2021/5540284>.

Hanoon, M.S., Abdullatif B, A.A., Ahmed, A.N., 2022. A comparison of various machine learning approaches performance for prediction suspended sediment load of river systems: a case study in Malaysia. *Earth Sci Inform* 15, 91-104. <https://doi.org/10.1007/s12145-021-00689-0>.

Hussein, A., Scholz, M., 2017. Dye wastewater treatment by vertical-flow constructed wetlands. *Ecological Engineering*, 101: 28-38. <https://doi.org/10.1016/j.ecoleng.2017.01.016>.

Khan, M.Y.A., Tian, F., Hasan, F. and Chakrapani, G.J., 2019. Artificial neural network simulation for prediction of suspended sediment concentration in the River Ramganga, Ganges

- Basin, India. *International journal of sediment research*, 34 (2), pp.95-107. <https://doi.org/10.1016/j.ijsrc.2018.09.001>.
- Kaffas, K., Papaioannou, G., Varlas, G., Al Sayah, M.J., Papadopoulos, A., Dimitriou, E., Katsafados, P., and Righetti, M., 2022. Forecasting soil erosion and sediment yields during flash floods: The disastrous case of Mandra, Greece, 2017. *Earth Surface Processes and Landforms*. <https://doi.org/10.1002/esp.5344>.
- Kisi, O., Karahan, M., and Sen, Z., 2006. River suspended sediment modeling using fuzzy logic approach. *Hydrological Process*. 20 (2) : 4351-4362. <https://onlinelibrary.wiley.com/doi/10.1002/hyp.6166>.
- Roushangar, K., Shahnazi, S., Azamathulla, H.M., 2023. Sediment Transport Modeling through Machine Learning Methods: Review of Current Challenges and Strategies. In: Pandey, M., Azamathulla, H., Pu, J.H. (eds) *River Dynamics and Flood Hazards. Disaster Resilience and Green Growth*. Springer, Singapore. [https://doi.org/10.1007/978-981-19-7100-6\\_13](https://doi.org/10.1007/978-981-19-7100-6_13).
- Sahoo, G.K., Sahoo, A., Samantara, S., Satapathy, D.P., Satapathy, S.C., 2023. Application of Adaptive Neuro-Fuzzy Inference System and Salp Swarm Algorithm for Suspended Sediment Load Prediction. In: Bhateja, V., Sunitha, K.V.N., Chen, YW., Zhang, YD. (eds) *Intelligent System Design. Lecture Notes in Networks and Systems*, vol 494. Springer, Singapore. [https://link.springer.com/chapter/10.1007/978-981-19-4863-3\\_32](https://link.springer.com/chapter/10.1007/978-981-19-4863-3_32).
- Satari, M.T., Rezazade Jodi, A., Safdari, F. & Ghahremanzadeh, F., 2015. Performance evaluation of M5 tree model and support vector regression methods in suspended sediment load modeling. *Journal of Water and Soil Conservation*, 6 (1) : 109-124 (in Persian). [https://wsrj.srbiau.ac.ir/article\\_9469.html?lang=en](https://wsrj.srbiau.ac.ir/article_9469.html?lang=en)
- Zhu, Y.M., Lu, X.X., & Zhou, Y., 2007. Suspended sediment flux modeling with artificial neural network: an example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology*, 84 (3): 111-125. <https://doi.org/10.1016/j.geomorph.2006.07.010>.
- Zounemat-Kermani, M., Kisi, O., Adamowski, J. and Ramezani-Charmahineh, A., 2016. Evaluation of data driven models for river suspended sediment concentration modeling. *Journal of Hydrology*, 535, pp. 457-472. <https://doi.org/10.1016/j.jhydrol.2016.02.012>.