

## تخمین پارامترهای کیفی آب با استفاده از ترکیب روش ماشین یادگیری قدرتمند و تئوری موجک

سیده زهره احمدپور<sup>۱</sup>، ایمان احمدیان فر<sup>۲\*</sup>، سید امین اصغری پری<sup>۳</sup>

۱. دانشجوی کارشناسی ارشد عمران، دانشگاه صنعتی خاتم‌الانبیاء، بهبهان

۲. استادیار گروه عمران، دانشگاه صنعتی خاتم‌الانبیاء، بهبهان

۳. دانشیار گروه عمران، دانشگاه صنعتی خاتم‌الانبیاء، بهبهان

(تاریخ دریافت ۱۳۹۷/۰۸/۳۱؛ تاریخ تصویب ۱۳۹۷/۱۲/۲۳)

## چکیده

هریک از مصارف گوناگون آب مانند کشاورزی، شرب و صنعت نیازمند آب با کیفیتی مشخص هستند که حدود کیفی آن، با نمونه‌برداری‌های مکرر، آزمایش و تحلیل نتایج مشخص می‌شود. هزینه نمونه‌برداری از آب‌های سطحی، اندازه‌گیری پارامترهای کیفی در محیط آزمایشگاه و خطاهای انسانی، از جمله مشکلات موجود در تخمین غلظت پارامترهای کیفی اند. به همین منظور، برای الگوبندی پارامترهای کیفی آب، روش‌های مختلفی وجود دارد که در این بین، روش‌های داده‌مبنا در دهه‌های اخیر مورد توجه پژوهشگران قرار گرفته است. بنابراین، هدف اصلی در تحقیق حاضر، تخمین و مدل‌سازی پارامترهای کیفی آب با استفاده از روش‌های داده‌کاوی نوین، بهبود عملکرد روش‌های داده‌کاوی با کمک تئوری موجک و مقایسه آنها با سایر روش‌های داده‌کاوی متداول است. به‌یانی دیگر، با استفاده از روش داده‌کاوی ماشین یادگیری قدرتمند (ELM) و شبکه عصبی پرسپترون چندلایه (MLP)، پارامترهای کیفی آب (Mg, EC, Cl, TDS) مدل‌سازی شد. ارزیابی این دو مدل توسط معیارهای آماری ضریب همبستگی (R)، ریشه میانگین مربع خطا (RMSE) و میانگین قدر مطلق خطا (MAE) و خطای استاندارد نسبی (RSE) برای داده‌های دوره آماری ۲۰ ساله، انجام شد. با توجه به نتایج، مشخص شد که روش ELM توانسته است به طور متوسط ضریب همبستگی معادل ۰/۹۷ را ارائه کند. با وجود آنکه هر دو مدل نتایج قابل قبولی به همراه داشتند، اما در نهایت نتایج نشان داد مدل ELM نسبت به مدل MLP دقت بیشتری برای پیش‌بینی پارامترهای کیفی آب دارد.

**کلیدواژگان:** پارامترهای کیفی آب، روش ماشین یادگیری قدرتمند، شبکه عصبی پرسپترون چندلایه.

## مقدمه

اهمیت کیفیت آب‌های سطحی، به عنوان مهم‌ترین آسیب‌پذیرترین منابع تأمین آب، امری کاملاً بدیهی است. متأسفانه، ورود آلاینده‌ها به پیکره‌های آبی طی سال‌های اخیر به دلیل رشد شهرنشینی، توسعه اقتصادی و افزایش تولیدات صنعتی، افزایش یافته است. بنابراین، امروزه بررسی کیفی منابع آب، یکی از چالش‌های مهم در بیشتر مناطق ایران و حتی جهان است. برای رسیدن به این هدف باید آزمایش‌های فراوان و پرهزینه‌ای را متحمل شد، ولی با پیشرفت علم و استفاده از روش‌های داده‌کاوی تا حد زیادی در زمان و هزینه صرفه‌جویی شده است. استفاده از روش‌های داده‌کاوی سبب کاهش چشم‌گیر هزینه‌های نمونه‌برداری آزمایشگاهی می‌شود و این امکان را برای کارشناسان مهیا می‌کند تا در مدت بسیار کوتاه و با استفاده از تعداد کمتری پارامترهای هیدروشیمیایی، کلاس کیفیت آب<sup>۱</sup> را تعیین کنند. با گسترش روزافزون روش‌های رایانه‌ای، از جمله هوش مصنوعی<sup>۲</sup> و شبکه‌های عصبی مصنوعی و استفاده از آنها در علوم مختلف، این روش‌ها در مطالعات مربوط به تخمین پارامترهای کیفی آب نیز مورد استفاده قرار گرفته و محققان بر دقت زیاد این روش‌ها نسبت به روش‌های تجربی و رگرسیونی<sup>۳</sup> تأکید کرده‌اند [۱]. در سال‌های اخیر مطالعات متعددی در زمینه استفاده از این روش‌های کارآمد به منظور تخمین پارامترهای کیفی آب انجام شده است که در ادامه به معرفی آنها پرداخته خواهد شد.

بازنژاد و همکارانش (۱۳۹۲) دو مدل شبکه عصبی مصنوعی و شبکه عصبی موجک<sup>۴</sup> را برای تخمین سه پارامتر کیفی EC (هدایت الکتریکی)، SAR (نسبت جذبی سدیم) و TDS (کل جامدات محلول) در رودخانه‌های جاجرود و قره‌سو طی یک دوره آماری ۲۴ ساله مقایسه کردند. آنها نشان دادند مدل بهینه شبکه عصبی موجکی با ضریب همبستگی بیش از ۰/۹ قابلیت زیادی در تخمین پارامتر SAR در ایستگاه‌های مطالعه‌شده دارد [۲]. ستاری و همکارانش (۱۳۹۳) براساس نمونه‌برداری‌های انجام‌شده در شش رودخانه دامنه جنوبی کوه سهند، برای هریک از رودخانه‌ها ۱۲ دبی و پارامتر

هیدروشیمیایی به عنوان ورودی مدل درخت تصمیم<sup>۵</sup> و کلاس کیفیت آب به عنوان خروجی و ویژگی هدف در نظر گرفتند. نتایج به‌دست‌آمده از پژوهش آنها نشان داد روش تصمیم‌گیری درختی عمدتاً با کمترین پارامترهای شیمیایی قادر به طبقه‌بندی کلاس کیفیت آب با دقت بسیار زیاد است [۳]. احمدی و بهزادی (۱۳۹۵) از شبکه عصبی مصنوعی و سیستم اطلاعات مکانی برای تعیین آلودگی پارامتر منیزیم در آب‌های روستاهای گنبد از استان گلستان استفاده کردند. در این مدل شبکه عصبی مصنوعی در ساختار پرسپترون<sup>۶</sup> با تعداد لایه‌های پنهان و نرون‌های<sup>۷</sup> مختلف، ارزیابی شد. در مجموع، مطالعه انجام‌شده روش برنامه‌ریزی شبکه عصبی را به عنوان نوعی روش دقیق و عملی برای مدل‌سازی و تعیین آلودگی معرفی کرد [۴]. اسدالله فردی و همکارانش (۲۰۱۲) طی تحقیقی از شبکه عصبی مصنوعی برای پیش‌بینی TDS در تلخه‌رود استفاده کردند. آنها در پژوهش خود شبکه عصبی پرسپترون چندلایه (MLP)<sup>۸</sup> و شبکه عصبی مکرر (RNN)<sup>۹</sup> که بیشتر به عنوان شبکه المن نامیده می‌شوند، را توسعه دادند و برای تخمین TDS رودخانه تلخه‌رود اعمال کردند. با مقایسه نتایج به‌دست‌آمده از TDS در دو ایستگاه، مشاهده شد که شبکه المن TDS نتایج بسیار نزدیک به مقادیر مشاهده‌شده پیش‌بینی می‌کند [۵].

محمودی و همکارانش (۲۰۱۶) طی پژوهشی ترکیب الگوریتم جهش قورباغه (SFLA)<sup>۱۰</sup> و رگرسیون بردار پشتیبان (SVR)<sup>۱۱</sup> برای پیش‌بینی پارامترهای کیفیت آب را بررسی کردند. نتایج پژوهش آنها نشان داد روش ترکیبی SFLA-SVR نسبت به روش برنامه‌ریزی ژنتیک (GP)<sup>۱۲</sup> مقادیر کمتری را برای RMSE به دست آورد [۶]. بزرگ حداد و همکارانش (۲۰۱۷) پژوهشی درباره مدل‌سازی پارامترهای کیفیت آب با استفاده از دو مدل ترکیب الگوریتم ژنتیک با روش کمترین مربعات رگرسیون بردار پشتیبان (GA-LSSVR)<sup>۱۳</sup>، و برنامه‌ریزی ژنتیک (GP) انجام دادند. نتایج تحقیق آنها نشان داد الگوریتم

5. Decision tree method

6. Perceptron

7. Neurons

8. Multi-Layer Perceptron (MLP)

9. Recurrent Neural Network (RNN)

10. Shuffled Frog Leaping Algorithm (SFLA)

11. Support Vector Regression (SVR)

12. Genetic Programming (GP)

13. Least Square Support Vector Regression (LSSVR)

1. Water quality class

2. Artificial Intelligence (AI)

3. Regression method

4. Wavelet neural network

روش شبکه عصبی چندلایه (MLP)

یکی از خواص مهم و اساسی شبکه عصبی، توانایی آموزش آن است. هر شبکه عصبی شامل پارامترهایی به عنوان پارامترهای آزاد (وزن‌ها و بایاس‌ها) است که می‌توانند مقادیر مختلفی داشته باشند [۱۱]. عملکرد مناسب و جواب‌دهی دقیق شبکه عصبی به مقداردهی درست این پارامترها بستگی دارد. بنابراین، آموزش یک شبکه عصبی پرسپترون چندلایه به این معناست که پارامترهای آزاد طوری بهینه شوند که خطای بین مقادیر هدف و مقادیر خروجی شبکه به کمترین مقدار برسد. برای حل معادلات ریاضی و مسائل بسیار پیچیده می‌توان از شبکه پرسپترون چندلایه استفاده کرد که به سادگی و با تعریف وزن‌ها و توابع مناسب می‌تواند به حل مسائل کمک کند [۱۲]. این شبکه شامل سه لایه ورودی، پنهان و خروجی است که در نهایت، پاسخ مسئله را ارائه می‌دهد.

برای فعال‌سازی نرون‌ها در لایه‌های میانی و خروجی از روابط ۱ و ۲ استفاده می‌شود [۱۳]:

$$a_i = \sigma \left( \sum_j w_{ij} o_j \right) \quad (1)$$

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

که  $a_i$  = میزان فعال‌سازی نرون  $i$ ، مجموعه نرون‌های لایه پیشین،  $w_{ij}$  = وزن ارتباط بین نرون  $i$  و نرون  $j$ ،  $o_j$  = خروجی نرون  $j$  و  $\sigma(x)$  تابع انتقال سیگموئید هستند.

میزان تغییر در وزن‌ها از رابطه ۳ به دست می‌آید [۱۳]:

$$\Delta w_{ij}(n+1) = \eta \delta_{pj} o_{pi} + \alpha \Delta w_{ij}(n) \quad (3)$$

که  $\eta$  = پارامتر سرعت آموزش،  $\delta_{pj}$  = خطای پخش شده،  $o_{pi}$  = خروجی نرون  $i$  برای رکورد  $p$ ،  $\alpha$  = پارامتر مومنتوم،  $\Delta w_{ij}(n)$  = میزان تغییر در  $w_{ij}$  در چرخه قبل و  $n$  = شماره چرخه هستند.

مقدار خطای پخش انتشار  $\delta_{pj}$  مطابق رابطه ۴ محاسبه می‌شود [۱۳]:

$$\delta_{pi} = (t_{pi} - o_{pi}) o_{pi} (1 - o_{pi}) \quad (4)$$

که  $t_{pj}$  = مقدار خروجی واقعی  $j$  برای رکورد است. برای وزن‌هایی که ارتباطی با نرون‌های خروجی ندارند،  $\delta_{pj}$  براساس خطای انتشار بالادست محاسبه می‌شود (رابطه ۵) [۱۳]:

GA-LSSVR دقت بیشتری دارد [۷]. علی‌ضمیر و همکارانش (۲۰۱۷) در مطالعه‌ای نوسانات آب‌های زیرزمینی را با استفاده از ELM مدل‌سازی کردند. همچنین، آنها روش یادشده را با روش‌های عملکرد پایه شعاعی (RBF) <sup>۱</sup>، میانگین متحرک خودکار رگرسیون (ARMA) <sup>۲</sup> و شبکه عصبی مصنوعی مقایسه کردند. نتایج پژوهش آنها نشان‌دهنده برتر بودن روش ELM نسبت به روش‌های یادشده بود [۸]. نجف‌زاده و همکارانش (۲۰۱۸) به تخمین سه شاخص کیفی آب  $BOD^3$ ،  $DO^4$  و  $COD^5$  با استفاده از روش‌های  $EPR^7$ ،  $GEP^6$  و  $MT^8$  پرداختند. آنها نشان دادند روش EPR نتایج دقیق‌تری در مقایسه با دو روش دیگر ارائه می‌کند [۹]. هدام و کیسی (۲۰۱۸) با استفاده از سه روش هوش مصنوعی LSSVM،  $MARS^9$  و  $MT$  و چندین پارامتر کیفی آب، پارامتر  $DO$  را تخمین زدند. آنها نشان دادند سه روش مد نظر توانایی لازم برای تخمین پارامتر کیفی  $DO$  را دارند [۱۰].

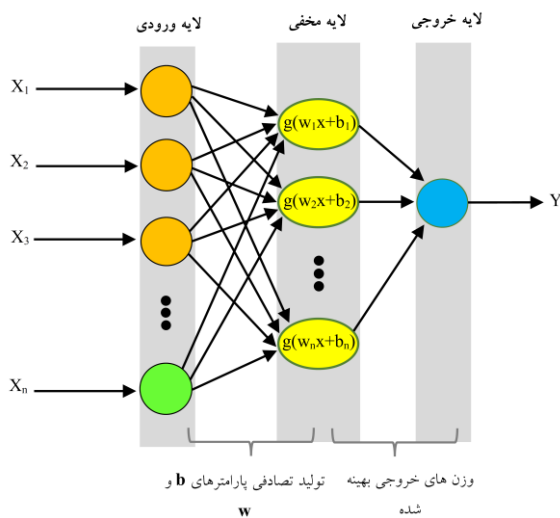
هدف از پژوهش حاضر، تخمین پارامترهای کیفی آب با استفاده از روش‌های ماشین یادگیری قدرتمند (ELM) و MLP است. با توجه به اینکه برای تخمین دقیق پارامترهای کیفی آب، به تعدادی ورودی (پارامترهای کیفی) نیاز است و شاید این تعداد داده در دسترس نباشد، با توجه به این محدودیت در تحقیق حاضر سعی شده است با تعداد پارامتر کم به دقت زیادی دست یافت. به این منظور، از تلفیق تئوری موجک و روش‌های ELM و MLP (W-MLP و W-ELM) برای تخمین پارامترهای EC، Mg و TDS برای یک دوره ۲۰ ساله استفاده خواهد شد.

مواد و روش‌ها

در تحقیق حاضر دو روش مدل‌سازی MLP و ELM بررسی شده است که در این قسمت به اختصار توضیح داده می‌شوند. سپس، تئوری موجک و مفاهیم اصلی آن تشریح می‌شوند.

1. Radial Basis Function (RBF)
2. Auto-Regressive Moving Average (ARMA)
3. Biochemical Oxygen Demand (BOD)
4. Dissolved Oxygen (DO)
5. Chemical Oxygen Demand (COD)
6. Gene Expression Programming (GEP)
7. Evolutionary Polynomial Regression (EPR)
8. Model Tree (MT)
9. Multivariate Adaptive Regression Splines (MARS)
10. Extreme Learning Machine (ELM)

خروجی و لایه پنهان،  $w$  = وزن بین لایه پنهان و لایه ورودی و  $b$  = بایاس نرون پنهان هستند.



شکل ۱. معماری روش ELM

برای نمایش ماتریس اتصال بین لایه مخفی و لایه خروجی از ماتریس  $H$  استفاده می‌شود،  $Y$  نشان‌دهنده ماتریس هدف داده‌های آموزش است. بنابراین، رابطه ۸ می‌تواند به صورت زیر بیان شود [۱۵]:

$$H = \begin{bmatrix} g(w_1, b_1, x_1) & g(w_2, b_2, x_1) & \dots & g(w_l, b_l, x_1) \\ g(w_1, b_1, x_2) & g(w_2, b_2, x_2) & \dots & g(w_l, b_l, x_2) \\ \vdots & \vdots & \ddots & \vdots \\ g(w_1, b_1, x_N) & g(w_2, b_2, x_N) & \dots & g(w_l, b_l, x_N) \end{bmatrix}_{N \times l} \quad (8)$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_l^T \end{bmatrix}_{l \times m}, \quad Y = \begin{bmatrix} Y_1^T \\ Y_2^T \\ \vdots \\ Y_N^T \end{bmatrix}_{N \times m}$$

در این روش، شبکه فقط نیاز به تنظیم تعداد لایه‌های مخفی دارد و نیازی به تنظیم وزن‌های ورودی‌ها و بایاس لایه‌های مخفی ندارد. همان‌طور که گفته شد، وزن‌های ورودی به وسیله مقادیر تصادفی تعیین می‌شوند، بنابراین می‌توان گفت که عملکرد شبکه به صورت خطی است. همچنین، وزن‌های خروجی با استفاده از ماتریس  $H$  برای مجموعه داده‌های آموزش به دست می‌آیند. مراحل زیر فرایند اصلی آموزش ELM هستند [۱۵]:

مرحله ۱: مشخص کردن تعداد نرون‌های لایه مخفی، تولید اعداد تصادفی برای بایاس ( $b$ ) و تنظیم وزن‌های  $w$  بین لایه ورودی و لایه مخفی.

$$\delta_{pj} = o_{pj} (1 - o_{pj}) \sum_k \delta_{pk} w_{kj} \quad (5)$$

که  $K$  = مجموعه نرون‌هایی که به نرون خروجی  $j$  مرتبط‌اند،  $w_{kj}$  = وزن بین نرون جاری و نرون  $k$  و  $\delta_{pk}$  = خطای انتشار یافته برای وزن مربوط به رکورد ورودی جاری‌اند.

### روش ماشین یادگیری قدرتمند (ELM)

ELM نوعی الگوریتم با درصد زیاد و آسان به لحاظ پیاده‌سازی است که نخستین بار توسط هاونگ و همکارانش (۲۰۰۵) پیشنهاد شد [۱۴]. این روش برای غلبه بر ضعف‌های روش‌های یادگیری سنتی مانند الگوریتم‌های آموزش محور مبتنی بر تبادل گرادیان به وجود آمده است. این الگوریتم شامل سه لایه ورودی، پنهان و خروجی است. ماشین یادگیری قدرتمند (ELM) در واقع نوعی روش یادگیری برای آموزش شبکه ANN است که به طور تصادفی وزن‌های ورودی ( $w$ ) و بایاس ( $b$ ) را تولید می‌کند [۱۵]. این روش وزن لایه پنهان را در یک شبکه عصبی به صورت تصادفی تولید می‌کند. همچنین، در این روش فقط وزن خروجی در فاز آموزش باید تنظیم شود. تفاوت‌های اساسی بین روش ELM و ANN وجود دارد که عبارت‌اند از:

۱. در روش ELM این امکان وجود دارد که از توابع غیر خطی<sup>۱</sup> و کرنل<sup>۲</sup> استفاده شود.
۲. ELM به پارامترهای بهینه‌سازی (مانند سرعت حرکت<sup>۳</sup> و میزان یادگیری<sup>۴</sup>) نیاز ندارد.
۳. در ELM به دلیل اینکه فقط وزن‌های خروجی نیاز به تنظیم دارند، نسبت به روش ANN سریع‌تر عمل می‌کند [۱۶]. شکل ۱ معماری ELM را نشان می‌دهد.

برای  $N$  نمونه یادگیری مختلف  $(x_i, y_i) \in R_n \times R_m$  و خروجی لایه مخفی می‌تواند به صورت رابطه ۶ و خروجی نرون در لایه خروجی می‌تواند به صورت رابطه ۷ بیان شود [۱۵]:

$$h = g(wx + b) \quad (6)$$

$$h(x_i)\beta = y_i^T, \quad i = 1, 2, \dots, N \quad (7)$$

که  $g(x)$  = تابع فعال‌سازی پنهان لایه ELM،  $\beta$  = وزن بین

1. Non-linear Function  
2. Kernel Function  
3. Momentum  
4. Learning rate

که  $\Psi_{a,b}(t) =$  موجک‌های پی‌درپی،  $a =$  مقیاس یا فاکتور فرکانس،  $b =$  فاکتور زمان و  $R$  دامنه اعداد حقیقی است. انتقال موجک گسسته تابع  $f(t)$  به صورت رابطه ۱۳ نوشته می‌شود:

$$W_{\psi} f(j, k) = a^{-\frac{j}{v}} \int f(t) \bar{\Psi}(a^{-j}t - kb) dt \quad (13)$$

که معمولاً برای متغیرهای  $a_0$  و  $b_0$  به ترتیب مقادیر ۲ و ۱ به کار برده می‌شود. پس از جای‌گذاری این مقادیر در سری زمانی گسسته  $f(t)$  که در گام‌های زمانی حسابی رخ می‌دهد، انتقال موجک گسسته به صورت رابطه ۱۴ تعریف می‌شود [۱۸]:

$$W_{\psi} f(j, k) = \sum_{i=-\frac{j}{v}}^{\frac{j}{v}} f(t) \bar{\Psi}\left(\frac{t}{a} - k\right) dt \quad (14)$$

که  $W_{\psi} f(j, k) =$  ضریب موجک گسسته با مقیاس  $2^j a$  و  $b = b^j k$  و  $\bar{\Psi} =$  تابع پدر (یا فیلتر میانگین) است. بعد از اعمال تبدیل موجک گسسته، داده‌ها به دو دسته تقریب<sup>۲</sup> و جزئیات<sup>۳</sup> تقسیم می‌شوند. داده‌های تقریب دارای فرکانس کم هستند که روند کلی تغییرات داده‌ها را نشان می‌دهد و داده‌های جزئیات فرکانس بالا دارند که تغییرات موضعی داده‌ها را نشان می‌دهند. به طور کلی، تجزیه سیگنال‌ها (داده‌های ورودی) با کمک تئوری موجک، موجب ساده‌تر شدن این سیگنال‌ها شده و منجر به بهبود تخمین‌ها می‌شود.

#### معیارهای ارزیابی خطا

برای ارزیابی و مقایسه نتایج به دست آمده توسط روش‌های MLP و ELM از پارامترهای جذر میانگین مربعات خطا (RMSE)، ضریب تعیین  $(R^2)$  خطای استاندارد نسبی (RSE)<sup>۴</sup> و میانگین خطای مطلق (MAE)<sup>۵</sup> استفاده شده که در ادامه به معرفی آنها پرداخته می‌شود [۱۹ و ۱۳]:

$$RMSE = \sqrt{\sum_{k=1}^n \frac{(Y_k - X_k)^2}{n}} \quad (15)$$

که  $N =$  تعداد مجموعه داده‌ها،  $c =$  مقدار خروجی محاسبه شده و  $m =$  مقدار خروجی اندازه‌گیری شده هستند.

مرحله ۲: انتخاب نوعی تابع فعال‌سازی متناسب با مسئله و سپس، محاسبه ماتریس  $H$ .  
مرحله ۳: وزن  $\beta$  بین لایه مخفی و لایه خروجی محاسبه شود:  $\beta = H^T H$ ، که  $H^T$  معکوس ماتریس خروجی  $H$  است.

#### تئوری موجک<sup>۱</sup>

موجک‌ها دسته‌ای از توابع ریاضی هستند که برای تجزیه سیگنال‌ها به مؤلفه‌های فرکانسی آن به کار می‌روند که رزولوشن هر مؤلفه برابر با مقیاس آن است. تبدیل موجک، تجزیه یک تابع بر مبنای توابع موجک است. در تبدیل موجک یک سری توابع خاص به عنوان توابع اصلی (همانند سینوسی‌ها در سری فوریه) انتخاب می‌شوند. این توابع در سطوح مختلف از مقیاس کردن و شیفت دادن موجک‌های خاصی به نام موجک مادر به دست می‌آیند. به طور کلی، تبدیل موجک به دو دسته پیوسته و گسسته تقسیم می‌شود که در ادامه روابط آنها آمده است.  
تبدیل موجک پیوسته سیگنال ارتعاشی  $f(t)$ ، براساس روابط ۹ و ۱۰ به دست می‌آید [۱۷]:

$$W_{\psi} f(a, b) = \int f(t) \times \Psi^*(t) dt = f, \Psi_{a,b} \quad (9)$$

$$\Psi_{a,b} = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (10)$$

که  $W$  تبدیل موجک پیوسته،  $a$  و  $b$  به ترتیب پارامترهای مقیاس و مکان،  $\psi$  تابع موجک مادر و علامت \* معرف مزدوج مختلط هستند.

تبدیل موجک گسسته با عبور دادن داده‌های ورودی (که همان سیگنال‌ها هستند) از فیلترهای بالاگذر و پایین‌گذر، فرکانس‌های مختلف آن را تحلیل می‌کند. موجک مادر به صورت رابطه ۱۱ تعریف می‌شود:

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0 \quad (11)$$

$\Psi_{a,b}(t)$  با فشردگی‌سازی و کشیدن  $\Psi(t)$  به دست می‌آید و به صورت رابطه ۱۲ تعریف می‌شود [۱۷]:

$$\Psi_{a,b}(t) = |a|^{-\frac{1}{2}} \Psi\left(\frac{t-a}{b}\right), a, b \in R, a \neq 0 \quad (12)$$

2. Approximations  
3. Details  
4. Relative Standard Error (RSE)  
5. Mean Absolute Error (MAE)

1. Wavelet theory

که  $X$  و  $Y$  به ترتیب مقادیر مشاهده شده و شبیه سازی شده و  $n$  تعداد داده هاست.

**منطقه مطالعه شده و داده ها**

برای تحقیق حاضر از داده های کیفیت آب مربوط به ایستگاه آستانه در مسیر رودخانه سفیدرود که در شهر رشت قرار دارد و به دریای خزر می ریزد، استفاده شده است. در شکل ۲ نمایی از حوضه سفیدرود ارائه شده است. پارامترهایی که در تحقیق حاضر استفاده شده اند، عبارت اند از:  $\text{mg}^{2+}$ ،  $\text{Cl}^-$ ،  $\text{EC}$  و  $\text{TDS}$  که مربوط به یک دوره آماری ۲۰ ساله (۱۳۶۴-۱۳۸۴) هستند. در جدول ۱ خصوصیات آماری داده ها بررسی می شوند:

$$R^r = \left[ \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sum (X - \bar{X})^r \sum (Y - \bar{Y})^r} \right]^r \quad (16)$$

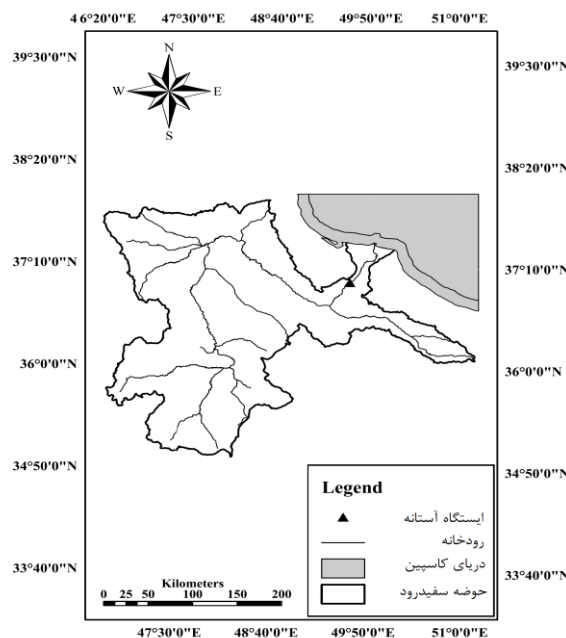
روابطی که برای RSE استفاده می شود به صورت زیر است (روابط ۱۷ و ۱۸):

$$RSE = \frac{SE}{E} \times 100 \quad (17)$$

$$SE = \frac{s}{\sqrt{n}} \quad (18)$$

$SE$  خطای استاندارد،  $E$  مقادیر تخمین زده شده،  $S$  انحراف معیار و  $n$  تعداد کل نمونه هاست.

$$MAE = \frac{\sum_{i=1}^n |Y_i - X_i|}{n} \quad (19)$$



شکل ۲. نمایی از حوضه مطالعه شده (حوضه سفیدرود)

جدول ۱. خصوصیات آماری داده های دسته آموزش و آزمون متغیرهای کیفیت آب رودخانه سفیدرود در ایستگاه آستانه

متغیر	مجموعه داده ها	کمینه	میانگین	بیشینه	انحراف معیار	ضریب تغییرات
Cl <sup>-</sup>	آموزش	۰/۴۰	۵/۷۰	۱۵/۶۰	۲/۷۰	۴۷/۴۶
	آزمون	۰/۲۰	۴/۴۴	۱۰/۹۰	۲/۵۵	۵۷/۴۴
EC	آموزش	۲۴۴/۰۰	۱۲۱۸/۴۹	۲۳۳۶/۰۰	۳۸۷/۲۶	۳۱/۷۸
	آزمون	۲۵۲/۰۰	۱۰۳۹/۳۱	۲۰۱۸	۳۹۵/۹۳	۳۸/۱۰
Mg <sup>2+</sup>	آموزش	۰/۲۰	۲/۳۱	۵/۵۰	۰/۹۱	۳۹/۶۷
	آزمون	۰/۳۸	۲/۰۹	۵/۵۲	۱/۰۳	۴۹/۴۱
TDS	آموزش	۲۶۱/۰۰	۷۶۸/۷۰	۱۴۷۲	۲۳۸/۵۸	۳۱/۰۴
	آزمون	۱۵۹/۰۰	۶۵۱/۳۱	۱۲۷۱	۲۴۵/۳۴	۳۷/۶۷

نتایج

در تحقیق حاضر ۷۰ درصد از داده‌ها به عنوان داده‌های دسته آموزش و ۳۰ درصد باقی مانده به عنوان داده‌های آزمون در نظر گرفته شدند. همچنین، به منظور تخمین و پیش‌بینی پارامترهای کیفی آب (EC, Cl, mg و TDS) به مقایسه دو مدل شبکه عصبی پرسپترون چندلایه و مدل یادگیری ماشین قدرتمند (MLP و ELM) پرداخته که برای دستیابی به دقیق‌ترین جواب از سناریوی ذیل به عنوان ورودی این دو مدل استفاده شده است:


$$x_{(t-2)}, x_{(t-1)}, Q_{(t-2)}, Q_{(t-1)}, Q_{(t)}$$

که  $x$  پارامتر مد نظر برای پیش‌بینی،  $x_{(t-1)}$  تأخیر اول پارامتر مد نظر برای پیش‌بینی،  $x_{(t-2)}$  تأخیر دوم پارامتر مد نظر برای پیش‌بینی،  $x_{(t-3)}$  تأخیر سوم پارامتر مد نظر برای پیش‌بینی،  $Q_t$  دبی،  $Q_{(t-1)}$  تأخیر اول دبی،  $Q_{(t-2)}$  تأخیر دوم دبی هستند. به منظور تعیین


دقیق‌ترین و کم‌خطاترین حالت مدل‌سازی، سناریوی یادشده برای ورودی‌ها در دو حالت مختلف یعنی استفاده از تئوری موجک و بدون استفاده از این تئوری بررسی شدند. در ادامه، به پیش‌بینی پارامترهای کیفی مد نظر پرداخته خواهد شد.

چگونگی عملکرد تئوری موجک برای پارامتر Q


این قسمت به ارائه برخی از خروجی‌های حاصل از تئوری موجک پرداخته خواهد شد. همان‌طور که قبلاً نیز بیان شد، این تئوری داده‌ها را می‌تواند به دو دسته تقریب و جزئیات تقسیم کند، بنابراین در تحقیق حاضر نمودارهای دسته تقریب و دسته جزئیات برای پارامتر دبی در شکل ۳ قابل مشاهده است. همان‌طور که در شکل ۳ مشخص است، موجک سیگنال پارامتر دبی را به دو دسته تقریب (شکل ۳ a و b) و دو دسته جزئیات (شکل ۳ c و d) تبدیل کرده است. این داده‌ها به عنوان ورودی به مدل‌های مد نظر داده می‌شوند تا دقت تخمین توسط آنها افزایش یابد.




(a)



(b)



(c)



(d)

شکل ۳. تجزیه سیگنال‌های پارامتر دبی توسط تئوری موجک به دو دسته تقریب (a و b) و جزئیات (c و d)

## شبیه‌سازی و پیش‌بینی کلراید (CI)

در این قسمت به تخمین پارامتر CI توسط روش‌های ELM و MLP پرداخته می‌شود. نتایج به‌دست‌آمده از تخمین دسته آموزش پارامتر CI با استفاده از هر دو مدل یادشده در جدول ۲ قابل مشاهده است. در جدول ۲ مشاهده می‌شود که نتایج هر دو مدل با استفاده از تئوری موجک به مراتب بهتر و دقیق‌تر از حالت بدون استفاده از تئوری موجک است. همچنین، در حالت استفاده از تئوری موجک می‌توان مشاهده کرد که ضریب همبستگی برای داده‌های آموزش در روش ELM، ۰/۹۷ و در روش MLP، ۰/۹۶ است. دیگر پارامترهای خطا یعنی RMSE، MAE و RSE در روش ELM به ترتیب ۰/۶۳، ۰/۴۲ و ۰/۰۷ و در روش MLP، ۰/۷۸، ۰/۶۲ و ۰/۰۸ هستند که این نتایج نشان‌دهنده برتری روش ELM در تخمین پارامتر CI است. در شکل ۴ (a) و (b) ارزیابی عملکرد مدل‌های ELM و MLP نشان داده شده است که محور عمودی، داده‌های محاسباتی حاصل از مدل‌ها و محور افقی آن نتایج مشاهداتی است. در شکل‌های یادشده برای هر یک از نمودارها معادله برازش بین نقاط نشان داده شده است. در شکل ۵ (a) نیز نمودار تغییرات داده‌های مشاهداتی و نمودار تغییرات داده‌های محاسباتی طی سری زمانی با هم مقایسه شده‌اند. در کنار هم بودن این دو نمودار به خوبی می‌تواند مقدار خطای مدل‌ها را به تصویر بکشد.

جدول ۳ نیز نتایج به‌دست‌آمده برای دسته آزمون پارامتر CI را نشان می‌دهد. با توجه به این جدول می‌توان مشاهده کرد که تئوری موجک به خوبی نتایج هر دو مدل را بهبود داده است. از طرفی، تمامی معیارهای خطای به‌دست‌آمده از مدل ELM جواب‌های مناسب‌تری نسبت به مدل MLP دارند. پس می‌توان با قطعیت گفت که مدل ELM داده‌های آزمون پارامتر CI را با دقت بیشتری تخمین می‌کند.

## شبیه‌سازی و پیش‌بینی هدایت الکتریکی (EC)

این قسمت به تخمین پارامتر کیفی EC با استفاده از روش‌های ELM و MLP می‌پردازد. به این منظور، ابتدا

پارامتر مد نظر بدون استفاده از تئوری موجک به عنوان ورودی به روش‌های یادشده داده می‌شود. سپس، از تبدیلات موجک استفاده کرده و ورودی‌های مد نظر را به دو دسته داده تقریب و جزئیات تقسیم می‌کند و به روش‌های مد نظر داده می‌شود تا تأثیر تئوری موجک بررسی شود. با مقایسه نتایج مدل‌های ELM و MLP برای پارامتر هدایت الکتریکی که در جدول‌های ۴ و ۵ آورده شده است، مشاهده می‌شود که مدل یادگیری ماشین قدرتمند در تخمین این پارامتر نسبت به روش پرسپترون چندلایه پیشی گرفته است و دقت قابل قبول‌تری را از خود نشان می‌دهد. همچنین، با توجه به نتایج ارائه‌شده در این جدول‌ها مشخص است که استفاده از تئوری موجک به مقدار درخور توجهی توانسته دقت تخمین را زیاد ببرد.

در شکل ۴ (c) و (d) رگرسیون خطی بین مقادیر مشاهداتی و مقادیر تخمین زده‌شده پارامتر EC توسط مدل‌های ELM و MLP آمده است. همان‌طور که از مقایسه این دو شکل معلوم است، در شکل مدل MLP داده‌ها پراکنده هستند و به منظمی و یک‌دستی شکل مدل ELM نیستند. این امر بیان می‌کند که روش MLP نتوانسته به خوبی و با دقت روش ELM، داده‌ها را تخمین بزند. شکل ۵ (b) نیز مقایسه بین مقادیر مشاهداتی و مقادیر تخمین زده‌شده پارامتر EC توسط هر دو مدل را به تصویر کشیده است. همان‌طور که دیده می‌شود، نمودار مدل ELM با مقادیر مشاهداتی انطباق بیشتری دارد. این موضوع دلالت بر دقت بیشتر مدل ELM در تخمین پارامتر EC دارد.

در مدل ELM معیارهای خطای R، RMSE، MAE و RSE برای داده‌های آموزش به ترتیب برابر با مقادیر ۰/۹۷، ۰/۲۴/۱۰، ۶۶/۶۱ و ۰/۰۹ و برای داده‌های آزمون برابر با ۰/۹۳، ۱۴۳/۵۹، ۱۱۸/۷۴ و ۰/۱۳ به‌دست آمدند. همین معیارها در روش MLP برای داده‌های آموزش برابر با ۰/۹۷، ۹۴/۲۱، ۷۵/۶۹، ۰/۰۶ و برای داده‌های آزمون برابر با ۰/۸۹، ۲۰۲/۷۶، ۱۶۶/۷۹ و ۰/۲۷ به‌دست آمدند که در جدول‌های ۴ و ۵ دیده می‌شوند.



جدول ۲. آماره‌های به‌دست‌آمده برای دسته آموزش پارامتر CI

معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۷	۰/۷۸	۰/۹۶	۰/۶۱
RMSE	۰/۶۳	۱/۵۸	۰/۷۸	۲/۷۱
MAE	۰/۴۱	۱/۳۳	۰/۶۲	۲/۱۰
RSE	۰/۰۷	۰/۵۱	۰/۰۸	۱/۰۱

جدول ۳. آماره‌های به‌دست‌آمده برای دسته آزمون پارامتر CI

معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۸	۰/۶۶	۰/۸۹	۰/۴۲
RMSE	۰/۵۳	۱/۹۴	۱/۳۱	۲/۶۲
MAE	۰/۴۱	۱/۴۵	۱/۰۶	۱/۹۹
RSE	۰/۰۴	۰/۵۹	۰/۲۷	۱/۰۷

جدول ۴. آماره‌های به‌دست‌آمده برای دسته آموزش پارامتر EC

معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۷	۰/۷۵	۰/۹۷	۰/۴۸
RMSE	۱۰۲/۲۴	۲۴۰/۸۸	۹۴/۲۱	۳۸۸/۹۶
MAE	۶۶/۶۱	۱۸۵/۴۷	۷۵/۶۹	۲۹۴/۷۲
RSE	۰/۰۹	۰/۷۸	۰/۰۶	۱/۰۱

جدول ۵. آماره‌های به‌دست‌آمده برای دسته آزمون پارامتر EC

معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۳	۰/۶۴	۰/۸۹	۰/۳۹
RMSE	۱۴۳/۵۹	۳۰۴/۴۴	۲۰۲/۷۶	۳۶۶/۵۶
MAE	۱۱۸/۷۴	۲۳۹/۳۶	۱۶۶/۷۹	۲۹۳/۶۸
RSE	۰/۱۳	۱/۲۱	۰/۲۷	۰/۸۷

همچنین، پارامترهای خطای یعنی RMSE، MAE و RSE در مدل ELM به ترتیب برابر با ۰/۳۷، ۰/۳۰ و ۰/۱۵ و در مدل MLP برابر با ۰/۷۲، ۰/۵۸ و ۰/۴۹ هستند. در شکل ۴ نمودار (e) و (f) تحلیل رگرسیون خطی بین مقادیر مشاهداتی و محاسباتی پارامتر Mg هستند، مشهود است که در نمودار مدل ELM فاصله نقاط از خط برازش داده شده کمتر است و نقاط نسبت به نمودار مدل MLP یکدست تر و منظم تر هستند. بنابراین، در نمودار مدل MLP، پراکندگی و نامنظمی نقاط به طور محسوس گویای این امر است که این مدل نتوانسته به دقت مدل ELM داده‌ها را شبیه‌سازی کند. در شکل ۵ (c) نمودار تغییرات داده‌های مشاهداتی و نمودار تغییرات داده‌های محاسباتی منیزیم طی سری زمانی با هم مقایسه شده‌اند. در کنار هم بودن این دو نمودار به خوبی می‌تواند مقدار خطای مدل‌ها را به تصویر بکشد. در این نوع شکل‌ها هرچه انطباق نمودارها بیشتر باشد، نشان دهنده دقت بیشتر و خطای کمتر مدل مد نظر است. بنابراین از شکل ۵ به وضوح مشخص است که مدل یادگیری ماشین قدرتمند در تخمین پارامتر منیزیم دقت بیشتری از خود نشان می‌دهد.

شبیه‌سازی و پیش‌بینی منیزیم ( $Mg^{2+}$ ) به منظور ارزیابی بیشتر توانایی روش‌های ELM و MLP برای تخمین پارامترهای کیفی آب، این قسمت به تخمین پارامتر  $Mg^{2+}$  توسط روش‌های یاد شده می‌پردازد. در اینجا نیز مانند دو قسمت قبل روش‌های مد نظر توسط دو دسته داده ورودی (با در نظر گرفتن تئوری موجک و بدون استفاده از آن) بررسی می‌شوند. بعد از اجرای روش‌های مد نظر، برای بررسی دقت آنها در تخمین پارامتر مد نظر، نتایج به دست آمده از روش‌های ELM و MLP توسط معیارهای خطای R، RMSE، MAE و RSE بررسی و تحلیل شدند که نتایج به دست آمده در جدول‌های ۶ و ۷ قابل مشاهده‌اند. نتایج به دو دسته آموزش (جدول ۶) و آزمون (جدول ۷) تقسیم شدند. برای داده‌های آموزش و آزمون، هم ضریب همبستگی R و هم معیارهای خطا در مدل ELM نسبت به مدل MLP مقادیر بهینه‌تری را دارند و این موضوع را نشان می‌دهد که مدل ELM با دقت بیشتری این داده‌ها را شبیه‌سازی کرده است و نسبت به مدل دیگر ارجحیت دارد. این امر به خصوص برای داده‌های آزمون محسوس است، به طوری که ضریب همبستگی برای این داده‌ها در مدل ELM ۰/۹۳ و در مدل MLP ۰/۸۵ به دست آمده است.

جدول ۶. آماره‌های به دست آمده برای دسته آموزش پارامتر Mg

معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۸	۰/۷۲	۰/۹۷	۰/۵۵
RMSE	۰/۲۱	۰/۶۲	۰/۳۷	۰/۸۱
MAE	۰/۱۶	۰/۴۵	۰/۳۲	۰/۶۳
RSE	۰/۰۶	۰/۴۸	۰/۱۷	۰/۷۸

جدول ۷. آماره‌های به دست آمده برای دسته آزمون پارامتر Mg

معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۳	۰/۵۹	۰/۸۵	۰/۴۰
RMSE	۰/۳۷	۰/۸۵	۰/۷۲	۰/۹۹
MAE	۰/۳۰	۰/۶۴	۰/۵۸	۰/۷۴
RSE	۰/۱۵	۰/۶۹	۰/۴۹	۰/۹۳

TDS را در مدل ELM نسبت به مدل MLP نشان دهند. همان طور که در قسمت‌های قبلی نیز گفته شد این برتری مدل ELM، از انطباق بیشتری که نمودار آن در شکل ۵ دارد، قابل استنتاج است.

نتایج مدل‌سازی پارامتر TDS در جدول های ۸ و ۹ نشان می‌دهد مدل ELM قادر به تخمین و شبیه‌سازی این پارامتر با ضریب همبستگی بسیار زیاد و خطای بسیار کم است. به طوری که ضریب همبستگی به‌دست‌آمده از این مدل برای داده‌های آموزش برابر با ۰/۹۷ و برای داده‌های آزمون برابر با ۰/۹۰ است. همچنین، ضرایب خطای RMSE، MAE و RSE برای داده‌های آموزش به ترتیب برابر با ۶۵/۰۳، ۴۲/۶۶ و ۰/۱۰ و برای داده‌های آزمون برابر با ۱۰۵/۴۰، ۸۲/۵۵ و ۰/۲۱ به دست آمده است.


شبیه‌سازی و پیش‌بینی کل مواد جامد محلول (TDS) آخرین پارامتری که در تحقیق حاضر بررسی شده، پارامتر TDS است. برای پیش‌بینی این پارامتر نیز مانند دیگر پارامترها، دبی و ۲ تأخیر از آن و ۳ تأخیر از خود پارامتر TDS به عنوان ورودی‌های مدل در نظر گرفته شدند. همچنین، به منظور بهبود تخمین پارامتر مد نظر توسط روش‌های ELM و MLP ورودی‌ها را به‌وسیله تئوری موجک گسسته کرده تأثیر آن بررسی خواهد شد. در شکل ۴ (g) و (h) ارزیابی عملکرد مدل‌های ELM و MLP نشان داده شده است که از مقایسه این دو شکل به‌راحتی این نتیجه به دست می‌آید که مدل ELM برای پارامتر TDS نیز مانند دیگر پارامترها، بهترین پیش‌بینی را انجام داده است. شکل ۵ (d) به‌خوبی می‌تواند میزان خطای اندک و اختلاف کم بین داده‌های مشاهداتی و محاسباتی پارامتر

جدول ۸. آماره‌های به‌دست‌آمده برای دسته آموزش پارامتر TDS


معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۷	۰/۷۶	۰/۹۴	۰/۴۶
RMSE	۶۵/۰۳	۱۷۲/۰۲	۱۰۰/۱۹	۲۶۱/۵۲
MAE	۴۲/۶۶	۱۰۱/۶۵	۷۵/۶۷	۲۰۳/۹۰
RSE	۰/۱۰	۰/۵۱	۰/۱۸	۱/۲۱

جدول ۹. آماره‌های به‌دست‌آمده برای دسته آزمون پارامتر TDS

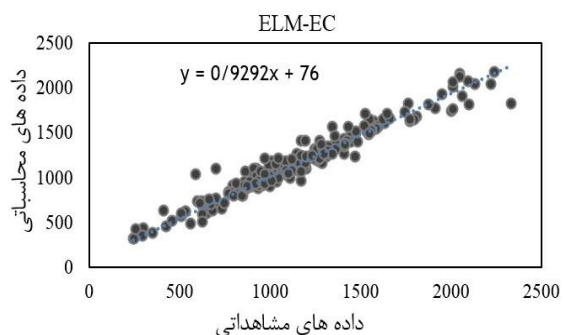
معیارهای ارزیابی	روش			
	ELM		MLP	
	با تئوری موجک	بدون تئوری موجک	با تئوری موجک	بدون تئوری موجک
R	۰/۹۰	۰/۶۲	۰/۸۲	۰/۲۹
RMSE	۱۰۵/۴۰	۱۹۳/۱۷	۱۷۶/۵۱	۲۶۰/۹۲
MAE	۸۲/۵۵	۱۵۰/۱۰	۱۴۱/۳۵	۲۱۱/۱۶
RSE	۰/۲۱	۰/۶۳	۰/۵۲	۱/۱۵




(b)



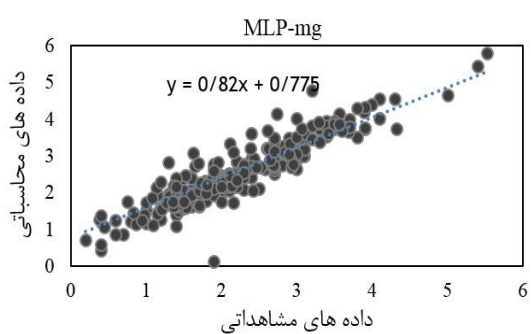
(a)



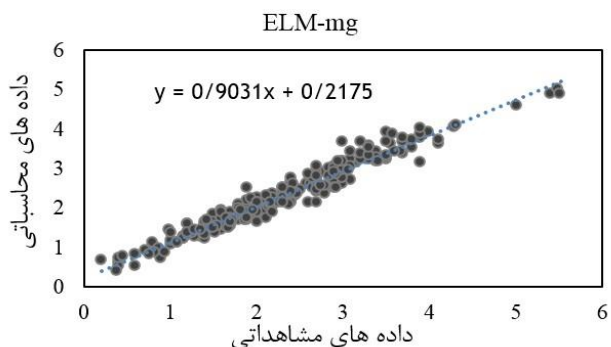
(d)



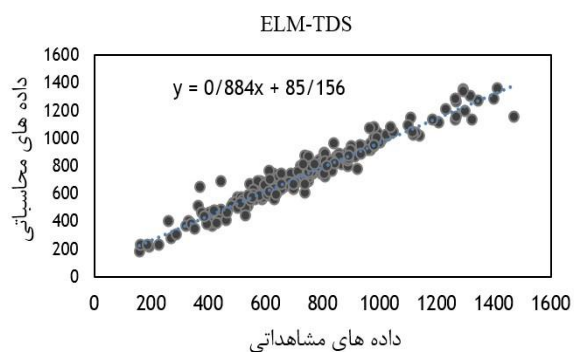
(c)




(f)



(e)




(h)




(g)

شکل ۴. رگرسیون خطی بین مقادیر مشاهداتی و محاسباتی پارامترها با استفاده از مدل های ELM و MLP




----- داده های مشاهداتی    ——— داده های محاسباتی ELM    • داده های محاسباتی MLP

(a)




----- داده های مشاهداتی    ——— داده های محاسباتی ELM    • داده های محاسباتی MLP

(b)



----- داده های مشاهداتی    ——— داده های محاسباتی ELM    • داده های محاسباتی MLP

(c)



----- داده های مشاهداتی    ——— داده های محاسباتی ELM    • داده های محاسباتی MLP

(d)

شکل ۵. مقایسه مقادیر مشاهداتی و محاسباتی پارامترها با استفاده از مدل های ELM و MLP

using decision tree method. *Journal of Irrigation & Water Engineering* 2014;4(15):76-88.

- [4]. Ahmadi MZ, Behzadi S. The process of evaluation of magnesium changes using the neural network and spatial information system in the villages of Gonbad city (Golestan province). *Scientific - Research Quarterly of Geographical Data (SEPEHR)*. 2016;25(99):29-42.
- [5]. Asadollahfardi G, Taklify A, Ghanbari A. Application of artificial neural network to predict TDS in Talkkeh Rud River. *Journal of Irrigation and Drainage Engineering*. 2011;138(4):363-70.
- [6]. Mahmoudi N, Orouji H, Fallah-Mehdipour E. Integration of shuffled frog leaping algorithm and support vector regression for prediction of water quality parameters. *Water resources management*. 2016;30(7):2195-211.
- [7]. Bozorg-Haddad O, Soleimani S, Loáiciga HA. Modeling Water-Quality Parameters Using Genetic Algorithm-Least Squares Support Vector Regression and Genetic Programming. *Journal of Environmental Engineering*. 2017;143(7):04017021.
- [8]. Alizamir M, Kisi O, Zounemat-Kermani M. Modelling long-term groundwater fluctuations by extreme learning machine using hydro-climatic data. *Hydrological Sciences Journal*. 2018;63(1):63-73.
- [9]. Najafzadeh M, Ghaemi A, Emamgholizadeh S. Prediction of water quality parameters using evolutionary computing-based formulations. *International Journal of Environmental Science and Technology*. 2018:1-20.
- [10]. Heddami S, Kisi O. Modelling daily dissolved oxygen concentration using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*. 2018;559:499-509.
- [11]. Haykin S. *Neural networks*: Prentice hall New York; 1994.
- [12]. Coppola E, Poulton M, Charles E, Dustman J, Szidarovszky F. Application of artificial neural networks to complex groundwater management problems. *Natural Resources Research*. 2003;12(4):303-20.
- [13]. Lee T, Jeng D, Zhang G, Hong J. Neural network modeling for estimation of scour depth around bridge piers. *Journal of hydrodynamics*. 2007;19(3):378-86.
- [14]. Huang G-B, Siew C-K. Extreme learning machine with randomly assigned RBF kernels. *International Journal of Information Technology*. 2005;11(1):16-24.

## نتیجه گیری

در حال حاضر، آلودگی آب رودخانه‌ها به دلیل فعالیت‌های شیمیایی و صنعتی در حال افزایش است. بنابراین، آگاهی از کیفیت آب‌ها امری ضروری است. از طرفی، با توجه به تحقیقات مختلف انجام شده در زمینه تخمین پارامترهای کیفی آب با استفاده از روش‌های داده‌کاوی مشخص می‌شود که استفاده از این روش‌ها در بررسی و پیش‌بینی ساختارهای طبیعت مفید است. بنابراین، در تحقیق حاضر به تخمین و مدل‌سازی پارامترهای کیفی آب با استفاده از روش‌های داده‌کاوی نوین یعنی روش‌های یادگیری ماشین قدرتمند (ELM) و پرسپترون چندلایه (MLP) برای مدل‌سازی پارامترهای کیفی آب (EC, Cl, mg و TDS) با دقت مناسبی پرداخته شد. در پژوهش حاضر از داده‌های مربوط به ایستگاه آستانه رودخانه سفیدرود که در شهر رشت قرار دارد، استفاده شد و با استفاده از دو روش ELM و MLP مدل‌سازی شدند. به این منظور، سه تأخیر از پارامتر مد نظر، دبی و دو تأخیر از آن به عنوان ورودی مدل در نظر گرفته شدند (یک بار به صورت ادغام شده با تئوری موجک و یک بار بدون آن). هدف از به‌کارگیری تئوری موجک، تجزیه داده‌های ورودی به منظور بهبود عملکرد مدل‌های مد نظر است. به طوری که مدل W-ELM ضریب همبستگی داده‌های آموزش و آزمون را برای پارامتر Cl، ۰/۹۷ و ۰/۹۸، برای پارامتر EC، ۰/۹۷ و ۰/۹۳، برای پارامتر mg، ۰/۹۸ و ۰/۹۳ و برای پارامتر TDS، ۰/۹۷ و ۰/۹۰ به دست آورد. پس از پایان یافتن این بررسی‌ها، نتایج به‌وضوح نشان‌دهنده برتری روش W-ELM نسبت به روش W-MLP است، به طوری که هر چهار پارامتر کیفی آب را دقیق‌تر مدل‌سازی کرد.

## منابع

- [1]. Soleimani S, Bozorg-Haddad O, Moravej M. Modeling Water Quality Parameters Using Data-driven Methods. *Journal of Water and Soil*. 2016;30(3):743-57.
- [2]. Banejad H, Kamali M, Amirmoradi K, Olyaei E. Forecasting Some of the Qualitative Parameters of Rivers Using Wavelet Artificial Neural Network Hybrid (W-ANN) Model. *Iran j Health & Environ*. 2012;6(3):277-94.
- [3]. Sattari MT, Abbasgoli Naebzad M, Mirabbasi Najafabadi R. Surface water quality prediction

- [15]. Ding S, Guo L, Hou Y. Extreme learning machine with kernel model based on deep learning. *Neural Computing and Applications*. 2017;28(8):1975-84.
- [16]. Ertuğrul ÖF, Kaya Y. A detailed analysis on extreme learning machine and novel approaches based on ELM. *American Journal of computer science and engineering*. 2014;1(5):43-50.
- [17]. Zhang L, Zhou W, Jiao L. Wavelet support vector machine. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*. 2004;34(1):34-9.
- [18]. Kisi O, Cimen M. Precipitation forecasting by using wavelet-support vector machine conjunction model. *Engineering Applications of Artificial Intelligence*. 2012;25(4):783-92.
- [19]. Wang W-C, Chau K-W, Cheng C-T, Qiu L. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*. 2009;374(3-4):294-306.