



تحقیقات آب و خاک ایران | دوره ۵۲ | شماره ۱۱ | بهمن ۱۴۰۰ (ص ۲۷۵۰-۲۷۳۹)

<https://dx.doi.org/10.22059/ijswr.2021.330656.669078>

(مقاله علمی - پژوهشی)

Hydraulic Modeling of the Water Resources using Learning Techniques

MOJTABA POURSAEID^{1*}, AMIRHOUSAIN POURSAEID², SAEID SHABANLOU³

1. Civil-Water, Plan and Budget Organization, Khorramabad, Lorestan, Iran.

2. Department of Electrical Engineering, Lorestan University, Khorramabad, Iran.

3. Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

(Received: Sep. 14, 2021- Revised: Nov. 24, 2021- Accepted: Nov. 27, 2021)

ABSTRACT

Quantitative and qualitative analysis of water resources has become one of the most widely used topics in water resources research today. In this research, data mining, artificial intelligence, mathematical techniques have been used to simulate water behavior and estimate its parameters changes. The models used to estimate hydrogeological parameters are Self-adaptive Extreme learning machine (SAELM), Least square support vector machine (LSSVM), Adaptive Neuro-Fuzzy Inference System (ANFIS) and Multiple linear regression (MLR) models. Also, to evaluate the performance of these models, the accuracy of the models was assessed in the form of 5 approaches. The results showed that the SAELM model was the best model based on the simulation and correlation diagrams. Based on accuracy evaluation indices, the SAELM model with RMSE, MAPE and, R indices equal to 0.1545, 0.0070, and 0.9979, respectively, had the highest accuracy in hydrogeological parameters prediction. Based on Uncertainty Analysis by the Wilson Score method, the performance of the top model (SAELM) was estimated to be underestimated. Also, based on the error ratio diagrams, the most accurate results were related to the SAELM model. Finally, the SAELM model was assigned the lowest error rate using the error distribution diagrams.

Keywords: Self Adaptive Extreme Learning Machine, Least Square Support Vector Machine, Adaptive Neuro Fuzzy Inference System, Multiple Linear Regression, Uncertainty Analysis.

مدل سازی هیدرولیکی منابع آب با استفاده از تکنیک های یادگیری

مجتبی پورسعید^{۱*}، امیرحسین پورسعید^۲، سعید شعبانلو^۳

۱. عمران آب، معاونت فنی سازمان برنامه و بودجه لرستان، خرم آباد، ایران.

۲. گروه مهندسی برق، دانشگاه لرستان، خرم آباد، ایران.

۳. گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران.

(تاریخ دریافت: ۱۴۰۰/۶/۲۳ - تاریخ بازنگری: ۱۴۰۰/۹/۳ - تاریخ تصویب: ۱۴۰۰/۹/۶)

چکیده

تحلیل کمی و کیفی منابع آب امروزه به یکی از موضوعات مهم در تحقیقات منابع آب تبدیل شده است. در این تحقیق از داده کاوی، تکنیک های هوش مصنوعی و ریاضی برای شبیه سازی رفتار آب و تخمین تغییرات پارامتریک آن استفاده شده است. نام مدل های بکار گرفته شده عبارتند از: مدل ماشین یادگیری نیرومند خود تطبیق SAELM، حداقل مربعات ماشین بردار پشتیبان LSSVM، مدل شبکه های عصبی نروفازی ANFIS و مدل آماری رگرسیون خطی چندگانه MLR که برای تخمین پارامترهای هیدروژئولوژیکی استفاده شده است. همچنین برای ارزیابی عملکرد مدل ها، در قالب ۵ رویکرد دقت مدل ها بررسی گردید. نتایج تحقیق نشان داد که براساس نمودارهای شبیه سازی و همبستگی مدل SAELM برترین مدل بود. براساس شاخص های ارزیابی دقت، مدل SAELM با شاخص های RMSE و MAPE و R به ترتیب برابر با ۰/۱۵۴۵، ۰/۰۰۷۰ و ۰/۹۹۷۹ دارای بالاترین دقت در تخمین پارامترهای هیدروژئولوژیکی بود. بر اساس تحلیل عدم قطعیت ویلسون (Wilson Score method) عملکرد مدل برتر (SAELM) دست پایین (Underestimated) برآورد گردید. همچنین براساس نمودارهای نسبت اختلاف خطا، دقیق ترین نتایج مربوط به مدل SAELM بود. در پایان با استفاده از نمودارهای توزیع خطا کمترین میزان خطا به مدل SAELM اختصاص یافت.

واژه های کلیدی: ماشین یادگیری نیرومند، ماشین حداقل مربعات بردار پشتیبان، شبکه های نروفازی، رگرسیون خطی چندگانه، تحلیل عدم قطعیت.

مقدمه

مدل با داده های دوساله آموزش دید و سپس به پیش بینی کیفی ۵ سال آینده پرداخته شد. (Mustapha & Abdu (2012). به شبیه سازی کیفی منابع آب با استفاده از مدل رگرسیونی پرداختند و بر روی مقادیر TDS، BOD5، CL، DO و COD در آب های سطحی رود جاکارا در کشور نیجریه با دو روش تحلیل مولفه اساسی (PCA) و نیز مدل رگرسیون چندگانه خطی اقدام کردند. (Cuest Cordoba et al. (2014). برای پیش بینی داده های سری زمانی، به شبیه سازی میزان نفوذ شوری در دلتای رودخانه کالوسایاتچی پرداختند. نتایج نشان داد که مدل سری زمانی، ابزاری مناسب و قوی برای پیش بینی تبادل شوری آبخوان است. در تحقیق دیگری (Guneshwor et al. (2018). یک مدل بهینه سازی-شبیه سازی با بهینه سازی ازدحام ذرات PSO با اتصال شبیه ساز شبکه مشبک ترکیب شد. شبیه سازی غلظت آلودگی در آبخوان با دو روش شبیه سازی شد. نتایج نشان داد که مدل شناسایی منبع می تواند در هر دو مورد به طور دقیق تاریخ انتشار از محل دفن زباله را بازسازی کند. این مطالعه نشان داد که مدل

تلاش بشر بر رفع مشکلات زندگی روزمره، اساس ابداع روش های علمی است. روش های علمی نیز مشابه با امورات دیگر دچار تغییرات و بهبود می گردند تا تبدیل به روشی جدید با توانایی بالاتر و زحمت کمتر شوند. یکی از این تلاش های علمی، ابداع روش های هوش مصنوعی و الگوریتم های فراابتکاری است. شبکه های عصبی مصنوعی و ماشین های یادگیری از زیرمجموعه های تکنیک های هوش مصنوعی بوده و از موفق ترین انواع آنها هستند. بعد از مقدمه ای در خصوص روش های هوش مصنوعی، به تعدادی از تحقیقات گذشته که در این زمینه انجام گرفته است، اشاره می شود. (Adhikary & Gupta (2011)، با مدل کردن تراز آب زیرزمینی (GWL) در کشور بنگلادش با استفاده از مدل تفاضل محدود MODFLOW، به مدل سازی تغییرات (GWL) و نفوذ جبهه آب شور به سمت آبخوان های ساحلی پرداختند. (Banerjee et al. (2011). به شبیه سازی تبادل شوری با سفره آب زیرزمینی، با استفاده از شبکه عصبی مصنوعی پرداختند. سپس

منابع آب مورد بررسی قرار دادند. آنها مدل‌های ELM و OSELM را با Wavelet-transform ترکیب کردند. در نهایت، آنها تایید کردند که برخی از مدل‌های ترکیبی عملکرد بهتری نسبت به مدل‌های اصلی دارد. (Rajaei et al. (2020)، در یک مقاله مروری، چندین مقاله در مورد استفاده از هوش مصنوعی در پیش‌بینی کیفیت منابع آب بررسی شده است. آنها ۱۳ مقاله در مورد استفاده از هوش مصنوعی در پیش‌بینی کیفیت آب را بررسی و تشریح کردند. (Kadkhodazadeh & Farzin (2021)، کیفیت منابع آب را مورد مطالعه قرار دادند. در این مقاله، آنها با استفاده از الگوریتم بهینه‌سازی ترکیب شده با LSSVM، به نام LSSVM-GBO، پارامترهای EC و TDS را شبیه‌سازی کردند و برتری این الگوریتم در شبیه‌سازی کیفیت آب را تأیید کردند. (Che Nordin et al. (2021)، در یک مقاله مروری، تأثیر و کاربرد هوش مصنوعی را بر روی مطالعات کیفیت آب مورد بررسی قرار دادند. نتایج این مطالعه برای پروژه‌های توسعه آب‌های زیرزمینی مفید اعلام شد و به بهبود کاربردهای هوش مصنوعی در کیفیت آب‌های زیرزمینی کمک می‌کند. همچنین راهکارهایی برای بهبود مدل‌سازی ارائه شد. (Yishan Zhang et al. (2021)، روش‌های تجزیه و تحلیل آزمایشگاهی، مدل‌سازی داده‌ها و یادگیری عمیق را ترکیب کردند. آنها گفتند مدل ترکیبی HF-DFM پارامترهای مختلف کیفیت آب را با دقت مناسبی تعیین می‌کند. در این مطالعه برای اولین بار در منطقه مورد مطالعه، از سه مدل معروف هوش مصنوعی از مجموعه ماشین‌های یادگیری و منطق فازی، به‌طور همزمان در کنار یک مدل آماری به منظور شبیه‌سازی و تخمین میزان تغییرات فصلی دراز مدت، در تراز منابع آب زیر زمینی استفاده گردید. همچنین با ۵ رویکرد مختلف، بصورت عددی و شماتیک، عملکرد هر مدل بطور جداگانه مورد ارزیابی قرار گرفته است. هدف اصلی این مطالعه بررسی عملکرد مدل‌های یادگیری ماشین و منطق فازی در قیاس با مدل‌های آماری است.

مواد و روش‌ها

مطالعه مورد مطالعه

منطقه جغرافیایی این تحقیق، شهرستان اراک و حوزه آبریز دشت میقان است. با توجه به نتایج آماری ایستگاه‌های سینوپتیک منطقه، بیشینه و کمینه بارش ۴۶۱ میلی‌متر در شمال شرق آن تا ۲۰۸ میلی‌متر در مرکز دشت اراک متغیر است. در شکل (۱) موقعیت جغرافیایی ناحیه مورد مطالعه دریاچه میقان و چاه مشاهداتی ویسمه قابل مشاهده است. اطلاعات پارامتر تراز آب زیرزمینی در تالاب مذکور در طی ۱۷۳ ماه برداشت شد و از

بهینه‌سازی مبتنی بر PSO می‌تواند به طور موثر برای مشکلات شناسایی آلودگی آب‌های زیرزمینی مورد استفاده قرار گیرد. (Vaheddoost & Aksoy (2018) نفوذ آب شور دریاچه ارومیه را به آبخوان‌های ساحلی و منابع آب زیرزمینی آن مطالعه کردند. آنها برای حل مشکل کاهش سطح دریاچه و تأثیر شوری بر منابع آب زیرزمینی کار کردند. در پایان اعلام شد که آب‌های زیرزمینی نقش مهم و حیاتی در احیای دریاچه ارومیه خواهند داشت. (Elkiran et al. (2019)، نویسندگان در مورد کاربرد شبکه‌های عصبی در شبیه‌سازی کیفیت آب بحث کردند. آنها با شبکه عصبی بازگشتی و مدل ARIMA مدل‌سازی لازم را انجام دادند. نتایج نشان داد که مجموعه‌های شبکه عصبی می‌توانند عملکرد متوسط مدل اعتبارسنجی را تا ۱۴٪ در واحد افزایش دهند. (Wang et al. (2019)، منابع نقطه‌ای آلودگی رودخانه را با استفاده از شبکه‌های یادگیری عمیق LSTM انجام دادند. آنها از مدل LSTM برای شناسایی آلاینده‌های آب در استان شاندونگ چین استفاده کردند. نتایج نشان داد که شبکه‌های LSTM دقت خوبی در شبیه‌سازی دارند. (Zhang et al. (2019)، مدلی را با ترکیب شبکه عصبی و الگوریتم ژنتیک توسعه دادند. نتایج نشان داد که مدل ترکیبی HANN دقت و عملکرد خوبی در پیش‌بینی پارامترهای کیفیت آب نشان داد. (Jamei et al. (2020)، روی پارامترهای کیفی آب مطالعه کردند. آنها با استفاده از برنامه‌ریزی ژنتیک (GP)، کل مواد جامد محلول در آب (TDS) را شبیه‌سازی کردند. نتایج نشان داد که WMGGP و W-GEP دارای ظرفیت پیش‌بینی برتر برای TDS هستند. (Azimi & Azhdary (2020)، Moghaddam، شاخص بارندگی استاندارد را با بررسی ماهانه ۲۶۰۲۷ چاه در ۶۰۹ منطقه مورد مطالعه، به مدت ۲۰ سال برای استان سیستان و بلوچستان در ایران محاسبه و تحلیل کردند. سپس با استفاده از مدل‌های هوش مصنوعی در پیش‌بینی، شبیه‌سازی مورد نظر انجام شد. نتایج نشان داد که شاخص "خشکسالی خفیف" شدیدتر از شاخص "خشکسالی عادی" است. (Chen et al. (2020)، پارامترهای کیفیت آب را با استفاده از ۱۰ مدل ماشین یادگیری شبیه‌سازی کردند. سپس بیان شد که برخی از مدل‌های یادگیری، نسبت به سایرین، با دقت خوبی پیش‌بینی لازم را انجام دادند. (Majumder & Eldho (2020)، برای تصفیه آب‌های زیرزمینی، مدلی با اتصال یک شبکه عصبی مصنوعی با الگوریتم بهینه‌ساز گرگ خاکستری (GW) پیشنهاد شد. نتایج نشان داد که برای عملکرد مدل شبکه عصبی مصنوعی، خطای میانگین مربع (MSE) نزدیک به صفر و ضریب همبستگی (R) نزدیک به ۰/۹۹ است. (Poursaeid et al., (2020)، کاربرد مدل‌های هوش مصنوعی را در پیش‌بینی و شبیه‌سازی کیفی

پارامترهای کل جامدات محلول TDS ، نمک $Salinity$ ، کلر CL ، زمان $Time$ و هدایت الکتریکی آب EC ، بعنوان ورودی مدل ها و از پارامتر تراز ایستایی آب زیرزمینی GWL بعنوان پارامتر خروجی مدل استفاده گردید.



شکل ۱- محدوده جغرافیایی تالاب میقان در شهرستان اراک، استان مرکزی (Wikimedia & GoogleMap)

(Schölkopf & Smola, 2002; Suykens *et al.*, 2002). تعریف ریاضی LSSVM اینگونه است که اگر x_i و y_i به عنوان ورودی ها و خروجی ها باشند، آنگاه تابع رگرسیونی غیرخطی به صورت زیر است (Valyon, J. Horvath, 2007):

$$f(x) = \sum_{i=1}^k w_i \varphi_i(x) + b = w^T \cdot \varphi(x_i) + b$$

که در اینجا w بردار وزن، b بایاس و φ ترسیم گره های غیرخطی که در فضای ویژگی عمل نمایند هستند و لذا داریم:

$$w = \begin{bmatrix} w_1 \\ \vdots \\ w_k \end{bmatrix}, \varphi = \begin{bmatrix} \varphi_1 \\ \vdots \\ \varphi_k \end{bmatrix}$$

(رابطه ۲)

با کمینه کردن مسئله بهینه سازی درجه (۲)، مسئله رگرسیون غیرخطی بصورت زیر قابل حل است:

مدل حداقل مربعات ماشین بردار پشتیبان (LSSVM) ماشین بردار پشتیبان نوعی از مدل ماشین بردار پشتیبان است که با تغییراتی بطور خودتطبیق، می تواند فاکتورهای ثابت مدل بردار پشتیبان را با رویکرد حداقل مربعات تنظیم و ارائه نماید. مدل بردار پشتیبان در ابتدا توسط شخصی به نام واپنیک بنا شد (Sapankevych & Sankar, 2009). این نوع از ماشین های یادگیری براساس مینیمم سازی ریسک ساختاری عمل کرده، درحالیکه برخی دیگر از روش های هوش مصنوعی از روش مینیمم سازی ریسک تجربی بهره می برند. به طور مختصر می توان گفت که در این نظریه، در یک مسئله برنامه ریزی درجه دوم، معادله ای بدست می آید که در آن معادله پارامترهای ثابت مدل تعیین و سپس با الگوریتم های بهینه سازی اعم از الگوریتم ژنتیک (GA) یا سایر روش های دیگر مقادیر بهینه برای این معادله را به دست آورد. (Campbell, 2002; Cristianini & Shawe-Taylor, 2000;)

(رابطه ۳)

$$Min_{w, e, b} \left\{ \Omega(w, e) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \right\}$$

که در اینجا γ به عنوان متغیر تعدیل دو قسمت معادله است:

(رابطه ۴)

$$Y_i = w^T \cdot \varphi(x_i) + b + e_i, \quad Y_i = y_i + \lambda_i$$

لازم بذکر است که λ_i به عنوان نویز شبکه تعریف می گردد.

سیس برای هر x_i ، خروجی عبارتست از مجموعه وزن دار از n تابع هسته (Kernel function) که متغیر مرکزی توابع هسته مورد نظر با استفاده از x_i آموزش مشخص می گردد. فرم لاگرانژی معادله را خواهیم داشت:

(رابطه ۵)

$$\phi(w, b, e, \alpha) = \Omega(w, e) - \sum_{i=1}^n \alpha_i (w^T \cdot \varphi(x_i) + b + e_i - Y_i)$$

α_i ها ضرایب لاگرانژی هستند. در ادامه حل، با یک مسئله

بهینه سازی مقید، مسئله را حل می کنیم. سپس بهینه سازی را با قیدهای ذیل داریم:

(رابطه ۶)

$$\frac{\partial \phi}{\partial w} = 0 \rightarrow w = \sum_{i=1}^n \alpha_i \varphi(x_i)$$

$$\frac{\partial \phi}{\partial b} = 0 \rightarrow \sum_{i=1}^n \alpha_i = 0$$

$$\frac{\partial \phi}{\partial e_i} = 0 \rightarrow \alpha_i = \gamma e_i, \quad i = 1, 2, \dots, n$$

$$\frac{\partial \phi}{\partial \alpha_i} = 0 \rightarrow w^T \varphi(x_i) + b + e_i - Y_i = 0, \quad i = 1, 2, \dots, n$$

و در پایان داریم:

(رابطه ۷)

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & \Omega_{11} + \frac{1}{\lambda} & \dots & \Omega_{1n} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \Omega_{n1} & \dots & \Omega_{nn} + \frac{1}{\lambda} \end{bmatrix} \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_n \end{bmatrix} = \begin{bmatrix} 0 \\ Y_1 \\ \vdots \\ Y_n \end{bmatrix}$$

که در معادله فوق داریم:

(رابطه ۸)

$$Y = [Y_1, \dots, Y_n], \alpha = [\alpha_1, \dots, \alpha_n], 1 = [1, \dots, 1]$$

و در معادله فوق Φ_{ij} ماتریس هسته ها و $k(x_i, x_j)$ توابع کرنل می باشند که به صورت زیر نوشته خواهند شد:

(رابطه ۹)

$$\Phi_{i,j} = K(x_i, x_j), \quad \Phi_{i,j} = \varphi^T(x_i) \cdot \varphi(x_j), \quad i, j = 1, \dots, n$$

ماشین یادگیری نیرومند خود تطبیق (SAELM)

تئوری این الگوریتم توسط دانشمندی به نام هوانگ در سال ۲۰۰۴ ارائه و پایه ریزی شد (Huang et al., 2004). این مدل از هوش مصنوعی از دسته ماشین های یادگیری بوده و در تحقیقات مختلف برتری و سرعت آن نسبت به سایر روش های هوش مصنوعی اعم از شبکه های عصبی و ماشین های یادگیری، به دلیل تک لایه بودن اثبات شده است (Huang et al., 2012; Liang et al., 2006). در شبکه این نوع از ماشین یادگیری، اگر تعداد n نرون را در لایه مخفی در نظر بگیریم، بر اساس روابط ریاضی شبکه تک لایه پیشخور ماشین یادگیری را به صورت زیر تعریف می کنیم (Poursaeid et al., 2021):

(رابطه ۱۰)

$$W_j = \sum_{i=1}^n \lambda_i f(x_k; c_i, a_i), \quad j = 1, 2, 3, \dots, k$$

به طوریکه f و λ_i به ترتیب تابع انتقال ورودی و خروجی

هستند. بردار W که همان بردار وزن است، در میان نقاط خروجی و نقاط لایه مخفی ارتباط برقرار کرده و بایاس های شبکه را بطور تصادفی مقاردهی می کنند. رابطه فوق را می توان به شکل ماتریس زیر بازنویسی کرد:

$$\sigma \lambda = W \quad (\text{رابطه ۱۱})$$

(رابطه ۱۲)

$$\sigma = \begin{bmatrix} f(x_1; c_1, w_1) & \dots & f(x_1; c_k, w_k) \\ \vdots & \ddots & \vdots \\ f(x_n; c_1, w_1) & \dots & f(x_n; c_k, w_k) \end{bmatrix}_{n \times k}$$

(رابطه ۱۳)

$$\lambda = (\lambda_1^T, \lambda_2^T, \dots, \lambda_n^T)_{h \times m}$$

$$\lambda = \sigma^+ W \quad (\text{رابطه ۱۴})$$

شبکه عصبی نروفازی تطبیقی (ANFIS)

شبکه های عصبی مصنوعی نروفازی یا به اختصار ANFIS، نوعی از شبکه های عصبی پیشخور هستند که بر اساس منطق فازی شبیه سازی می کنند. در این نوع از شبکه ها از دو نوع سیستم استنباطی مبتنی بر منطق فازی FIS استفاده می گردد (El-Shafie et al., 2006):

- شبکه مبتنی بر استنباط فازی به نام Mamdani که به

اختصار M-FIS به معروف است.

- شبکه مبتنی بر استنباط فازی Takagi-Sugeno که به

اختصار TS-FIS به معروف است.

چهارم طبق فرمول ذیل محاسبه می شود:

$$\sum Mean(w_i) f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (\text{رابطه ۱۹})$$

مدل رگرسیون چندگانه خطی (MLR)

روش‌های رگرسیون خطی چندگانه روش‌هایی مبتنی بر محاسبات آماری می‌باشند. در این روش‌ها جهت بررسی روابط متغیر ورودی و چند متغیر هدف قابل استفاده هستند. تعریف ریاضی این مدل بصورت ذیل می‌باشد:

$$y_i = a_0 + a_1 x_1 + a_2 x_2 + \dots + a_m x_m + \zeta_i \quad (\text{رابطه ۲۰})$$

که در این معادله y_i متغیر هدف، x_m متغیرهای چندگانه ورودی مدل، a_m ضرایب رگرسیونی و ζ خطای تصادفی در مدل رگرسیونی است (Camdevýren et al., 2005).

داده‌کاوی و جمع‌بندی اطلاعات

جهت بررسی و ارزیابی نتایج مربوط به دقت مدل‌های هوش مصنوعی، از روش تصادفی‌سازی داده‌ها استفاده می‌شود که به نام روش کافولد معروف است، استفاده گردید. مزیت این کار بالارفتن اطمینان و دقت شبیه‌سازی است. در آموزش مدل‌های هوش مصنوعی از داده‌های ۱۷۳ ماه نمونه‌برداری انجام گرفته (کل بانک داده)، از ۷۰٪ داده‌ها برای آموزش (Train) و ۳۰٪ مابقی داده‌ها جهت آزمون (Test) در عملیات شبیه‌سازی استفاده شد. فلوجارت مراحل مختلف این تحقیق در شکل (۲) به تصویر کشیده شده است.

تنظیم مدل‌ها

در این مطالعه، با توجه به ارتباط پارامترهای سری‌زمانی و ارتباط مفهومی غلظت کل جامدات محلول، غلظت نمک با حجم آب، ارتباط هدایت الکتریکی EC با TDS و $Salinity$ ، همچنین تاثیر زمان بر داده‌های از نوع سری‌زمانی، از پارامترهای مذکور جهت شبیه‌سازی رفتار تغییرات تراز آب زیرزمینی GWL استفاده شد. چکیده تحقیق به صورت شماتیک از ابتدا تا پایان، به ترتیب در شکل (۳) به تصویر کشیده شده است.

معیارهای سنجش عملکرد مدل‌ها

در مطالعه حاضر به منظور ارزیابی دقت مدل‌های عددی از شاخص‌های آماری خطای جذر میانگین مربعات ($RMSE$)، درصد خطای مطلق میانگین ($MAPE$)، شاخص پراکندگی (SI) و ضریب تبیین (R^2) استفاده می‌شود.

$$R^2 = \frac{\left(n \sum_{i=1}^n O_i I_i - \sum_{i=1}^n O_i \sum_{i=1}^n I_i \right)^2}{\left(n \sum_{i=1}^n (O_i)^2 - \sum_{i=1}^n (O_i) \right) \left(n \sum_{i=1}^n (I_i)^2 - \sum_{i=1}^n (I_i) \right)}$$

در این شبکه‌ها حداقل دو ورودی D_1 و D_2 وجود دارد که برای شبکه مبتنی بر سیستم استنباط فازی TS-FIS و دو اصل شرطی اگر-آنگاه (if-then) برای هر خروجی O خواهد بود و قوانین شرطی این شبکه‌های فازی بصورت زیر است (Arora & Keshari, 2021):

قانون اول: اگر x ورودی D_1 و خروجی O_1 باشد، آنگاه داریم که:

$$f_1 = a_1 x_1 + b_1 y_1 + c_1$$

قانون دوم: اگر x ورودی D_2 و خروجی O_2 باشد، آنگاه داریم که:

$$f_2 = a_2 x_2 + b_2 y_2 + c_2$$

شبکه‌های نروفازی در یک لایه ورودی و ۵ لایه دیگر خلاصه می‌گردد که این شبکه می‌تواند به نوعی بیانگر یک شبکه عصبی چند لایه باشد.

لایه صفر: لایه ورودی با n ورودی

لایه اول: این لایه توابع عضویت را با استفاده از قوانین گاوسی برای هر گره از شبکه بوسیله نقاط فازی شده فراهم می‌آورد.

$$\mu_{D_i}(x) = \exp \left\{ - \left[\frac{\left(\frac{x - h_i}{z_i} \right)^2}{t_i} \right] \right\} \quad (\text{رابطه ۱۵})$$

که در اینجا z_i ، t_i و h_i پارامترهای توابع خودتطبیق شبکه هستند. **لایه دوم:** در این لایه کلیه مقادیر فازی شده نقاط شبکه از اپراتورها رد می‌گردد. O_i و D_i به عنوان پارامترهای عضویت و نیز $\mu_{D_i}(x)$ و $\mu_{O_i}(x)$ هم به عنوان پارامترهای پیشین لایه اول می‌باشند.

$$w_i = \mu_{D_i}(x) \times \mu_{O_i}(x) \quad (\text{رابطه ۱۶})$$

لایه سوم: در این لایه کلیه مقادیر بر اساس فرمول ذیل نرمالیزه می‌شوند.

$$Mean(w_i) = \frac{w_i}{\sum_{t=1}^T w_t} \quad (\text{رابطه ۱۷})$$

که در اینجا $Mean(w_i)$ معرف مجموع مقادیر اپراتورهای مرتبه n ام در لایه دوم است.

لایه چهارم: در این لایه مقدار تابع خطی هر گره محاسبه شده و مقادیر خطا نیز با استفاده از روش محاسبه خطا در شبکه‌های عصبی انتشار عقب‌گرد (BNN-error) به دست می‌آید.

(رابطه ۱۸)

$$Mean(w_i) f_i = Mean(w_i) \cdot (a_0 x_0 + a_1 x_1 + a_2)$$

که در اینجا نیز a_i به عنوان پارامتر ورودی i و $Mean(w_i)$ خروجی لایه قبلی (لایه سوم) می‌باشد.

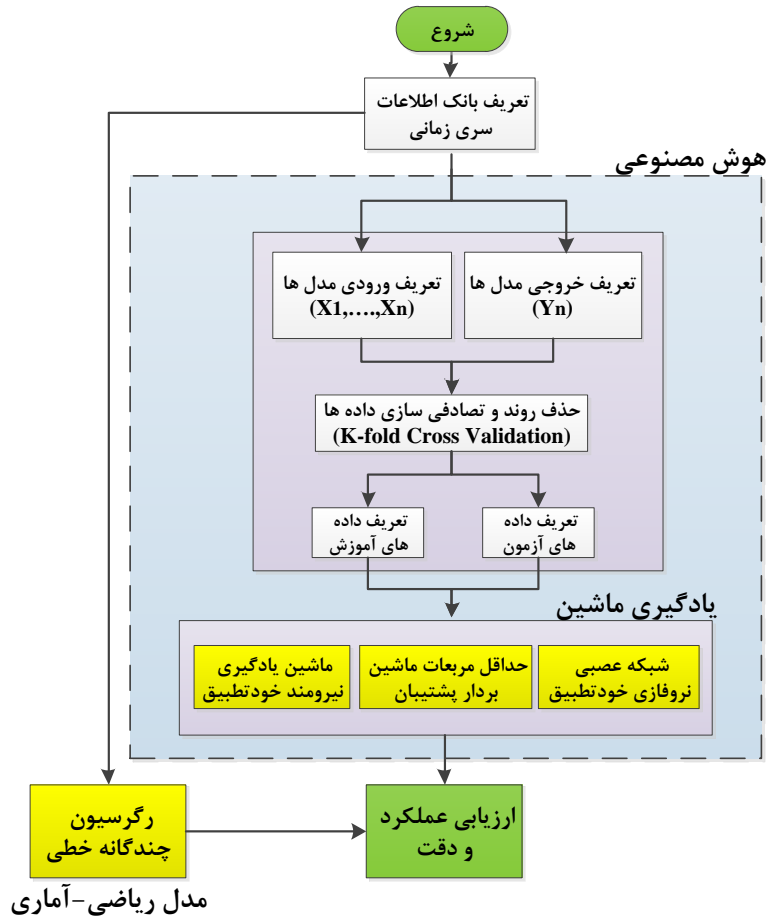
لایه پنجم: در این لایه مجموع مقادیر خروجی هر گره از لایه

$$SI = \frac{RMSE}{\bar{I}}$$

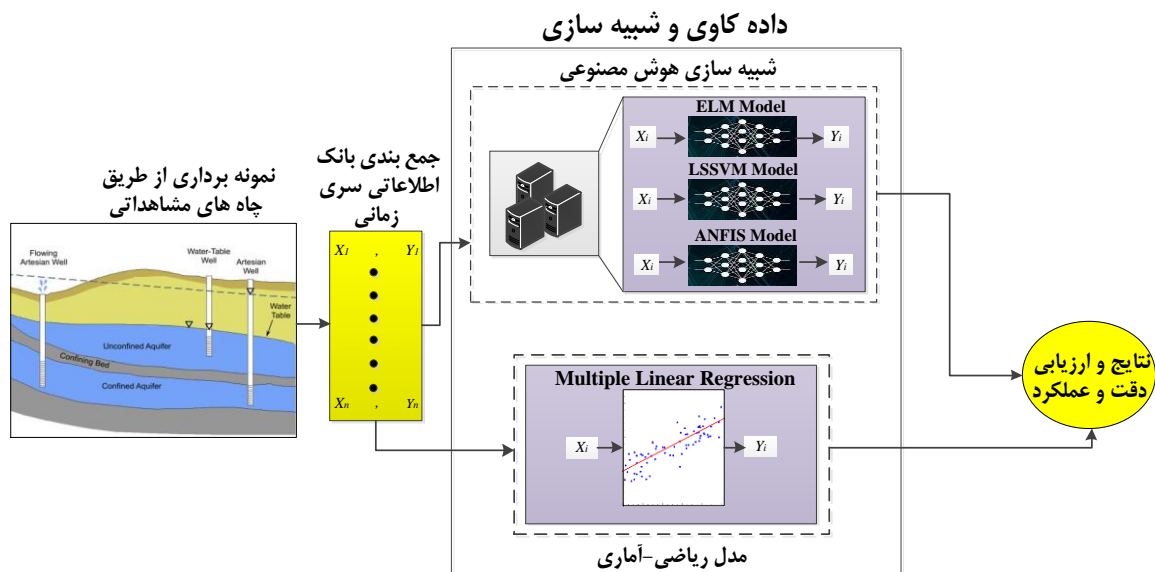
که در کلیه مدل‌ها، I_i ورودی‌های مدل، O_i خروجی‌های مدل، \bar{I} مقدار میانگین مقادیر واقعی و n تعداد داده‌های واقعی است.

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

$$MAPE = \frac{\sum_{i=1}^n |O_i - I_i|}{n} \times 100$$



شکل ۲- فلوچارت مراحل مختلف تحقیق

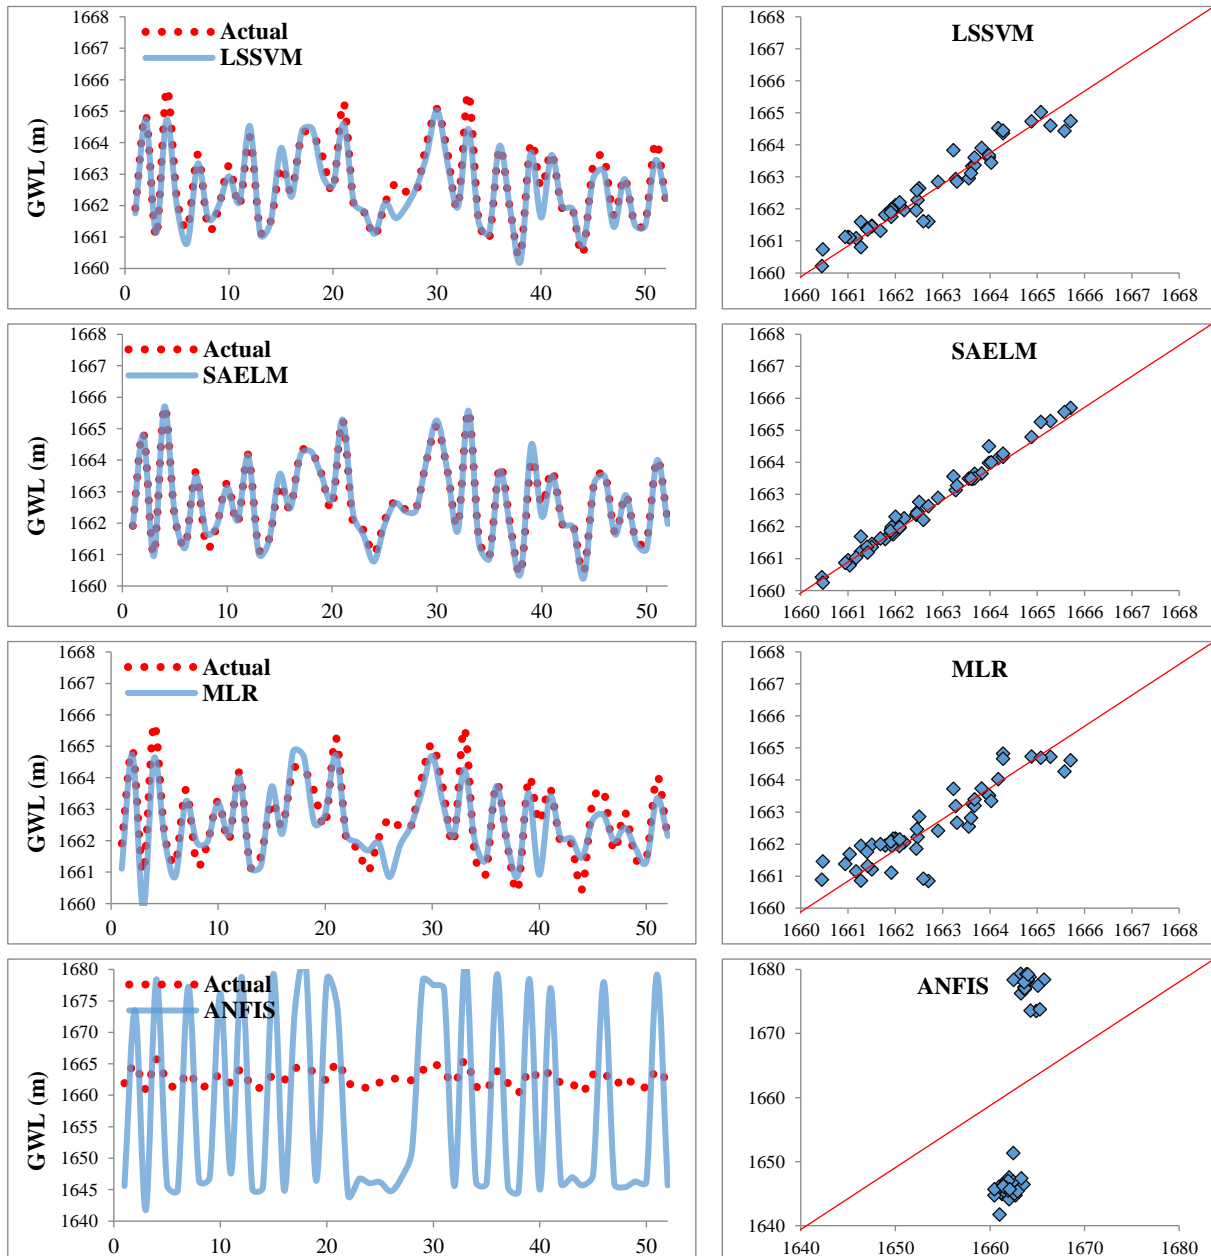


شکل ۳- چکیده تصویری تحقیق

نتایج و بحث

و محور افقی تعداد آزمون‌های نمونه‌گیری یا تعداد خروجی‌های شبیه‌سازی شده توسط مدل‌ها، که عدد ۵۲ می‌باشد را نشان می‌دهند.

مقادیر ورودی به مدل‌ها وارد و شبیه‌سازی انجام گرفت. در هر نمودار محور قائم مقادیر شبیه‌سازی شده یا مقادیر واقعی



شکل ۴- نمودارهای سنجش مدل‌ها، الف) همبستگی مشاهدات با خروجی‌ها و ب) نمودار دقت تخمین مدل‌ها

جدول ۲- نتایج معیارهای ارزیابی عملکرد مدل‌های آموزش

نام مدل	MAPE	RMSE	SI	R ²
SAELM	۰/۰۰۶۱	۰/۱۵۱۲	۰/۰۰۰۰۸۴	۰/۹۸۸۷
LSSVM	۰/۰۱۰۷	۰/۳۹۲۴	۰/۰۰۰۱	۰/۹۲۸۹
MLR	۰/۰۲۶۶	۰/۶۰۹	۰/۰۰۰۲	۰/۸۱۰۳
ANFIS	۸/۴۱۷۴	۳۲۴۱/۱۴	۰/۰۰۸۵	۰/۶۸۷۴

براساس نمودارهای فوق دقیق‌ترین تخمین با توجه به اختلاف ناچیز میان نمودار مشاهدات و پیش‌بینی، همچنین تمرکز بالاتر نقاط در نمودار همبستگی مشاهدات و خروجی‌های مدل‌ها، به مدل SAELM اختصاص می‌یابد. همچنین، جهت مقایسه عملکرد هر یک از مدل‌ها در پیش‌بینی برای داده‌های آموزش و آزمون به ازای معیارهای ارزیابی عملکرد مختلف، در جداول (۲) و (۳) نشان داده شده است.

نتایج نشان داد که مدل SAELM بهترین مدل با کمترین میانگین خطا به مقدار ۰/۰۲۷ و انحراف استاندارد ۰/۱۶۳۳۸ بوده است. عملکرد مدل بر اساس علامت میانگین خطا، دست پایین Underestimated برآورد گردید.

نرخ اختلاف خطا (Discrepancy Ratio)

با توجه به مفهوم ریاضی نسبت اختلاف، نمودار نسبت اختلافی نتایج شبیه سازی شده مدل های تحقیق، در شکل (۵) نشان داده شده است. این نمودار بیانگر دقت مدل ها می باشد. هر قدر نتایج تمرکز بیشتری بر این خط داشته باشند، نشان از دقت بیشتر شبیه سازی خواهد داشت.

با توجه به نمودارهای مندرج در شکل (۵)، به وضوح دقت بالای مدل ماشین یادگیری نیرومند تطبیقی در مدل سازی قابل مشاهده است. میزان پراکندگی داده های شبیه سازی شده (نقاط روی نمودار)، میزان خطای مدل را نشان می دهد. تمرکز نقاط در نمودار مدل SAELM به خط $DR=1$ نشان از دقت بالای ماشین یادگیری نیرومند تطبیقی نسبت به سایر مدل ها دارد. هر چند میزان تمرکز داده های خروجی مدل LSSVM نیز مناسب بوده و دقت بالایی دارد. مدل های ANFIS و MLR نیز به ترتیب در رتبه های بعدی دقت بر اساس نمودار شاخص نسبت اختلاف خطا قرار می گیرند.

نمودار توزیع خطا

در نمودارهای شکل (۶) بر اساس میزان درصد خطای هر مدل، دقت آن ها در تخمین و مدل سازی آب زیرزمینی به نمایش گذاشته شده است. براساس این نمودار، باتوجه به کمترین درصد خطا بالای ۰/۲۰ و بیشترین میزان خطای کمتر از ۰/۱۰، دقیق ترین مدل SAELM می باشد.

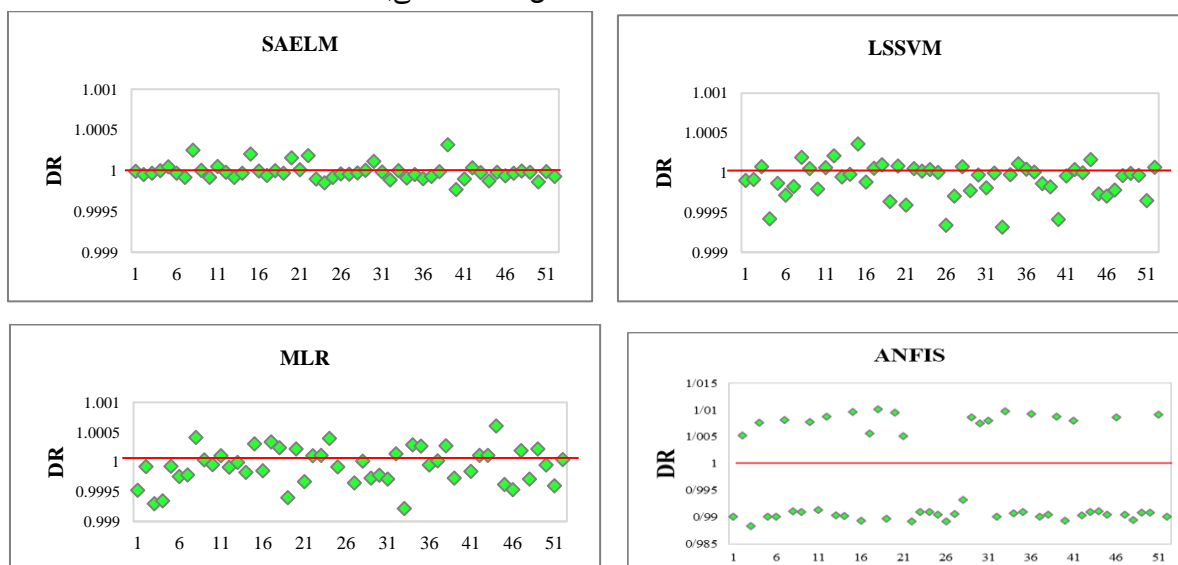
جدول ۳- نتایج معیارهای ارزیابی عملکرد مدل های آزمون

نام مدل	MAPE	RMSE	SI	R ²
SAELM	۰/۰۰۷۰	۰/۱۵۴۵	۰/۰۰۰۰۹۴	۰/۹۹۵۸
LSSVM	۰/۰۱۶۵	۰/۳۹۵۲	۰/۰۰۰۲	۰/۹۲۷۵۶
MLR	۰/۰۲۸۰	۰/۶۱۶۱	۰/۰۰۰۳	۰/۸۰۴۶۱
ANFIS	۸/۵۶۶	۱۵/۲۴۰	۰/۰۰۹۱	۰/۶۸۴۵۹

بر اساس جدول فوق، دقیق ترین نتایج و کمترین مقادیر خطا مربوط به مدل SAELM با شاخص های RMSE ، MAPE ، SI و R² به ترتیب برابر با ۰/۱۵۴۵ ، ۰/۰۰۷ ، ۰/۰۰۰۰۹۴ و ۰/۹۹۵۸ می باشد.

تحلیل عدم قطعیت ویلسون برای مدل ها (Uncertainty Analysis)


بعد از شبیه سازی مدل های هوش مصنوعی و رگرسیونی و به منظور بررسی میزان خطا در پیش بینی مجهولات، میزان عدم قطعیت هر مدل قابل محاسبه بوده و بر اساس آن می توان عملکرد هر مدل را در تخمین مقادیر هدف مورد ارزیابی قرار داد. در تحقیق حاضر به روش تحلیل عدم قطعیت ویلسون (Wilson Score Method)، برای مدل های کاربردی موجود این محاسبات انجام گردید. میزان خطای تخمین δ_i ، میانگین خطا $\bar{\delta}_i$ و انحراف استاندارد مقادیر خطا s_i ، که در جدول زیر نتایج تحلیل عدم-قطعیت بروش امتیاز ویلسون با مقادیر باند اطمینان (WUB) درج شده است. مقادیر مذکور با احتساب سطح معناداری ۰/۰۵ (PEI 95%) محاسبه گردید. همچنین در صورتی که مقدار خزای میانگین یک مدل مثبت باشد، مدل دارای عملکرد دست بالا (Overestimated) و در صورت منفی بودن آن مدل دارای عملکرد دست پایین (Underestimated) خواهد بود.



شکل ۵- نمودار نرخ خطای مدل ها

جدول ۲- نتایج تحلیل عدم قطعیت برای مدل‌های آزمون شده

نام مدل	مقدار دقت پهنای باند محاسباتی	$\bar{\delta}_i$	S_i	سطح اطمینان ۹۵٪ (PEI 95%)	
				حداقل	حداکثر
SAELM	۰/۰۴۸	-۰/۰۲۷۴۴	۰/۱۶۳۳	-۰/۰۷۵۴۴	۰/۰۲۰۵۶
LSSVM	۰/۱۲۶۳	-۰/۱۵۶۲	۰/۳۶۶۶	-۰/۱۴۱۹۲	۰/۱۱۰۶۸
MLR	۰/۲۵۹۸	-۰/۱۸۱۸	۰/۵۹۴۵	-۰/۰۷۸	۰/۴۴۱۶
ANFIS	۱/۶۵۸۹	۵/۱۴۱۴	۱۴/۴۸۲۸	۳/۴۸۲۵	۶/۸۰۰۳



نتیجه‌گیری

در تحقیق حاضر از کمیت‌های کیفی آب‌های زیرزمینی برای شبیه‌سازی و تخمین پارامتر تراز ایستایی آب زیرزمینی (GWL) استفاده شد. هدف از انجام این تحقیق بررسی و ارزیابی عملکرد مدل‌های هوش مصنوعی و ریاضی در مدل‌سازی آب زیرزمینی بود. منطقه مورد نظر در تحقیق، تالاب میقان واقع در دشت اراک، در استان مرکزی بود. ورودی‌های مدل‌ها، زمان (t)، (TDS)، (EC)، (CI) و (Salinity) بودند. مدل‌های هوش مصنوعی، مدل SAELM، مدل LSSVM، مدل ANFIS و مدل MLR بودند. بعد از بررسی و تحلیل نتایج مدل‌سازی، در قالب ۵ رویکرد دقت مدل‌ها بررسی و ارزیابی شد. این رویکردها عبارت بودند از: (۱) بهره‌گیری از نمودارهای شبیه‌سازی و همبستگی (۲) استفاده از شاخص‌های ارزیابی دقت مدل‌ها (شاخص‌های RMSE، MAPE، SI و R^2) (۳) استفاده از تحلیل عدم قطعیت ویلسون (۴) استفاده از نمودارهای نسبت اختلاف خطا و (۵) استفاده از نمودارهای توزیع خطا. بعد از تعریف هر رویکرد و بیان اصول آن در هر قسمت، به ترتیب کارآمدترین مدل‌ها در شبیه‌سازی معرفی گردیدند. در ادامه بر اساس هر رویکرد، کلیه نتایج عددی و نموداری بررسی گردید و مشخص شد که:

بر اساس رویکرد دوم و بهره‌گیری از معیارهای سنجش دقت، مطابق با جدول (۱)، نتایج شاخص‌های سنجش عملکرد نیز برتری SAELM مشخص گردید. (۳) طبق رویکرد سوم، نتایج تحلیل عدم قطعیت ویلسون نیز انجام گرفت (جدول ۲) که بر این اساس عملکرد دست‌بالای (Overestimated) مدل ANFIS و MLR، همچنین عملکرد دست‌پایین (Underestimated) مدل SAELM و LSSVM در تخمین پارامتر خروجی تعیین شد. همچنین کمترین مقادیر قدرمطلق خطای میانگین در پیش‌بینی برای دو مدل SAELM و LSSVM به ترتیب با مقادیر -۰/۰۲۷۴۴ و -۰/۱۵۶۲ تعیین گردید. (۴) در رویکرد چهارم براساس مفهوم نسبت اختلاف خطا، طبق نمودارهای شکل ۵، بنا بر تمرکز بیشتر نقاط محاسبه شده بر اساس مفهوم نرخ اختلاف خطا به خط $DR=1$ و آرایش خطی دقیق‌تر این نقاط، بیشترین دقت به مدل SAELM اختصاص یافت. (۵) در رویکرد پنجم با استفاده از نمودارهای توزیع خطا مشخص گردید که در داده‌های شبیه‌سازی شده توسط مدل SAELM، تعداد ۳۰ داده در بازه خطای زیر ۱۰٪، تعداد ۹ داده در محدود خطای بین ۱۰ تا ۲۰٪ و تعداد ۱۳ داده شبیه‌سازی شده در محدوده خطای بالای ۲۰٪ قرار گرفته است. این نتیجه نسبت به سایر مدل‌ها، دقت بالاتر مدل SAELM را نشان می‌دهد. در نهایت و براساس روش‌های پنج‌گانه سنجش عملکرد مذکور برای مدل‌های استفاده شده در این تحقیق، برترین مدل‌ها به ترتیب، مدل SAELM، مدل LSSVM، مدل MLR و مدل ANFIS تعیین می‌گردد. همچنین در خصوص دقت مدل‌ها،

(۱) بر اساس رویکرد اول نمودارهای شبیه‌سازی و همبستگی در شکل (۴) به نمایش گذاشته شد. در این نمودارها با عنایت به مجاورت نمودار پیش‌بینی نسبت به نمودار مشاهدات، دقت بالای مدل SAELM نسبت به سایر مدل‌ها تایید گردید. (۲)

Huang *et al.* 2004; 2012;) دیگر محققان در این زمینه دارد (Barzegar *et al.* 2018).

"هیچ گونه تعارض منافع توسط نویسندگان وجود ندارد"

REFERENCES

- Adhikary, S., & Gupta, A. (2011). modeling groundwater flow and salinity intrusion by advective transport in the regional unconfined aquifer of southwest bangladesh.
- Arora, S., & Keshari, A. K. (2021). ANFIS-ARIMA modelling for scheming re-aeration of hydrologically altered rivers. *Journal of Hydrology*, 601, 126635. <https://doi.org/10.1016/J.JHYDROL.2021.126635>.
- Azimi, S., & Azhdary Moghaddam, M. (2020). Modeling Short Term Rainfall Forecast Using Neural Networks, and Gaussian Process Classification Based on the SPI Drought Index. *Water Resources Management* 2020 34:4, 34(4), 1369–1405. <https://doi.org/10.1007/S11269-020-02507-6>.
- Banerjee, P., Singh, V. S., Chattopadhyay, K., Chandra, P. C., & Singh, B. (2011). Artificial neural network model as a potential alternative for groundwater salinity forecasting. *Journal of Hydrology*, 398(3–4), 212–220. <https://doi.org/10.1016/J.JHYDROL.2010.12.016>
- Çamdevýren, H., Demýr, N., Kanik, A., & Keskýn, S. (2005). Use of principal component scores in multiple linear regression models for prediction of Chlorophyll-a in reservoirs. *Ecological Modelling*, 181(4), 581–589. <https://doi.org/10.1016/J.ECOLMODEL.2004.06.043>
- Campbell, C. (2002). Kernel methods: A survey of current techniques. *Neurocomputing*, 48(1–4), 63–84. [https://doi.org/10.1016/S0925-2312\(01\)00643-9](https://doi.org/10.1016/S0925-2312(01)00643-9)
- Che Nordin, N. F., Mohd, N. S., Koting, S., Ismail, Z., Sherif, M., & El-Shafie, A. (2021). Groundwater quality forecasting modelling using artificial intelligence: A review. *Groundwater for Sustainable Development*, 14, 100643. <https://doi.org/10.1016/J.GSD.2021.100643>
- Chen, K., Chen, H., Zhou, C., Huang, Y., Qi, X., Shen, R., Liu, F., Zuo, M., Zou, X., Wang, J., Zhang, Y., Chen, D., Chen, X., Deng, Y., & Ren, H. (2020). Comparative analysis of surface water quality prediction performance and identification of key water parameters using different machine learning models based on big data. *Water Research*, 171, 115454. <https://doi.org/10.1016/J.WATRES.2019.115454>
- Cristianini, N., & Shawe-Taylor, J. (2000). An Introduction to Support Vector Machines and Other Kernel-based Learning Methods. *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. <https://doi.org/10.1017/CBO9780511801389>
- Cuest Cordoba, G. A., Tuhovčák, L., & Tauš, M. (2014). Using Artificial Neural Network Models to Assess Water Quality in Water Distribution Networks. *Procedia Engineering*, 70, 399–408. <https://doi.org/10.1016/J.PROENG.2014.02.045>
- El-Shafie, A., Taha, M. R., & Nouredin, A. (2006). A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. *Water Resources Management* 2006 21:3, 21(3), 533–556. <https://doi.org/10.1007/S11269-006-9027-1>
- Elkiran, G., Nourani, V., & Abba, S. I. (2019). Multi-step ahead modelling of river water quality parameters using ensemble artificial intelligence-based approach. *Journal of Hydrology*, 577, 123962. <https://doi.org/10.1016/J.JHYDROL.2019.123962>
- Guneshwor, L., Eldho, T. I., & Vinod Kumar, A. (2018). Identification of Groundwater Contamination Sources Using Meshfree RPCM Simulation and Particle Swarm Optimization. *Water Resources Management* 2018 32:4, 32(4), 1517–1538. <https://doi.org/10.1007/S11269-017-1885-1>
- Huang, G. Bin, Zhou, H., Ding, X., & Zhang, R. (2012). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 42(2), 513–529. <https://doi.org/10.1109/TSMCB.2011.2168604>
- Huang, G. Bin, Zhu, Q. Y., & Siew, C. K. (2004). Extreme learning machine: A new learning scheme of feedforward neural networks. *IEEE International Conference on Neural Networks - Conference Proceedings*, 2, 985–990. <https://doi.org/10.1109/IJCNN.2004.1380068>
- Jamei, M., Ahmadianfar, I., Chu, X., & Yaseen, Z. M. (2020). Prediction of surface water total dissolved solids using hybridized wavelet-multigene genetic programming: New approach. *Journal of Hydrology*, 589, 125335. <https://doi.org/10.1016/J.JHYDROL.2020.125335>
- Kadkhodazadeh, M., & Farzin, S. (2021). A Novel LSSVM Model Integrated with GBO Algorithm to Assessment of Water Quality Parameters. <https://doi.org/10.21203/RS.3.RS-465707/V1>
- Liang, N. Y., Huang, G. Bin, Saratchandran, P., & Sundararajan, N. (2006). A fast and accurate online sequential learning algorithm for feedforward networks. *IEEE Transactions on Neural Networks*, 17(6), 1411–1423. <https://doi.org/10.1109/TNN.2006.880583>
- Majumder, P., & Eldho, T. I. (2020). Artificial Neural

مشخص شد که بازه تغییرات داده‌ها، تاثیر مستقیم بر دقت مدل‌ها و نیز مقدار شاخص‌های سنجش دقت دارد. کلیه یافته‌های رویکردهای بکار گرفته شده در این تحقیق، برتری مدل ماشین یادگیری نیرومند SAELM را تأیید نمود که مطابقت با یافته‌های



- Network and Grey Wolf Optimizer Based Surrogate Simulation-Optimization Model for Groundwater Remediation. *Water Resources Management* 2020 34:2, 34(2), 763–783. <https://doi.org/10.1007/S11269-019-02472-9>
- Mustapha, A., & Abdu, A. (2012). Application of Principal Component Analysis & Multiple Regression Models in Surface Water Quality Assessment. *Journal of Environment and Earth Science*, 2(2), 16–23. <https://www.iiste.org/Journals/index.php/JEES/article/view/1516>
- Poursaeid, M., Mastouri, R., Shabanlou, S., & Najarchi, M. (2020). Estimation of total dissolved solids, electrical conductivity, salinity and groundwater levels using novel learning machines. *Environmental Earth Sciences* 2020 79:19, 79(19), 1–25. <https://doi.org/10.1007/S12665-020-09190-1>
- Poursaeid, M., Mastouri, R., Shabanlou, S., & Najarchi, M. (2021). Modelling qualitative and quantitative parameters of groundwater using a new wavelet conjunction heuristic method: wavelet extreme learning machine versus wavelet neural networks. *Water and Environment Journal*, 35(1), 67–83. <https://doi.org/10.1111/WEJ.12595>
- Rajaei, T., Khani, S., & Ravansalar, M. (2020). Artificial intelligence-based single and hybrid models for prediction of water quality in rivers: A review. *Chemometrics and Intelligent Laboratory Systems*, 200, 103978. <https://doi.org/10.1016/J.CHEMOLAB.2020.103978>
- Sapankevych, N., & Sankar, R. (2009). Time series prediction using support vector machines: A survey. *IEEE Computational Intelligence Magazine*, 4(2), 24–38. <https://doi.org/10.1109/MCI.2009.932254>
- Schölkopf, B., & Smola, A. J. (2002). *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. Adaptive computation and machine learning. 626.
- Suykens, J. A. K., Van Gestel, T., De Brabanter, J., De Moor, B., & Vandewalle, J. (2002). *Least Squares Support Vector Machines*. <https://doi.org/10.1142/5089>
- Vaheddoost, B., & Aksoy, H. (2018). Interaction of groundwater with Lake Urmia in Iran. *Hydrological Processes*, 32(21), 3283–3295. <https://doi.org/10.1002/hyp.13263>
- Valyon, J. Horvath, G. (2007). (PDF) Extended Least Squares LS-SVM. *World Academy of Science, Engineering and Technology*, 36. https://www.researchgate.net/publication/242532586_Extended_Least_Squares_LS-SVM
- Wang, P., Yao, J., Wang, G., Hao, F., Shrestha, S., Xue, B., Xie, G., & Peng, Y. (2019). Exploring the application of artificial intelligence technology for identification of water pollution characteristics and tracing the source of water quality pollutants. *Science of The Total Environment*, 693, 133440. <https://doi.org/10.1016/J.SCITOTENV.2019.07.246>
- Zhang, Yanyang, Gao, X., Smith, K., Inial, G., Liu, S., Conil, L. B., & Pan, B. (2019). Integrating water quality and operation into prediction of water production in drinking water treatment plants by genetic algorithm enhanced artificial neural network. *Water Research*, 164, 114888. <https://doi.org/10.1016/J.WATRES.2019.114888>
- Zhang, Yishan, Wu, L., Deng, L., & Ouyang, B. (2021). Retrieval of Water Quality Parameters from Hyperspectral Images Using a Hybrid Feedback Deep Factorization Machine Model. *Water Research*, 117618. <https://doi.org/10.1016/J.WATRES.2021.117618>