

## Estimation of Quantity and Quality Parameters of Groundwater Using Numerical Models (Case Study: Mighan Desert Basin, Arak)

MOJTABA POURSAEID<sup>1</sup>, REZA MASTOURI<sup>1\*</sup>, SAEID SHABANLOU<sup>2</sup>, MOHSEN NAJARCHI<sup>1</sup>

1. Department of Civil Engineering, Faculty of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran.

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

(Received: Apr. 23, 2019- Revised: Aug. 13, 2019- Accepted: Aug. 25, 2019)

### ABSTRACT

In this paper, salinity, total dissolved solids (TDS), groundwater level (GWL) and electrical conductivity (EC) of the Arak Plain, located in Markazi Province, Iran, were simulated using four novel artificial intelligence models including extreme learning machine (ELM), wavelet extreme learning machine (WELM), online sequential extreme learning machine (OSELM) and wavelet online sequential extreme learning machine (OSELM) as well as the MODFLOW software (MT3D model). In order to develop the hybrid artificial intelligence models, the wavelet transform was employed. First, the effective lags in estimating the quality and quantity parameters of the groundwater were identified using the autocorrelation function (ACF) and the partial autocorrelation function (PACF) analysis. After that, four different models were developed using the effective lags for each of the artificial intelligence methods. Then, the superior models in simulating the groundwater quality and quantity parameters were detected by conducting a sensitivity analysis. Subsequently, the most effective lags in estimating these parameters were introduced. In addition, the results of The MODFLOW model were compared with the artificial intelligence models, and it was concluded that the latter were more accurate. For instance, the scatter index and Nash-Sutcliffe efficiency coefficient values for TDS simulation by the superior model were 5.34E-03 and 0.991, respectively. Additionally, RMSE and MAE for estimating groundwater level using the superior model were obtained 0.078 and 0.061, respectively. Finally, uncertainty analysis for the superior models was carried out.

**Keywords:** Salinity, Electrical conductivity, Groundwater level, Total dissolved solids, MODFLOW, Extreme learning machine

## تخمین پارامترهای کیفی و کمی آب زیرزمینی توسط مدل‌های عددی: مطالعه موردی حوضه آبریز میقان در دشت اراک

مجتبی پورسعید<sup>۱</sup>، رضا مستوری<sup>۱\*</sup>، سعید شعبانلو<sup>۲</sup>، محسن نجارچی<sup>۱</sup>

۱. گروه مهندسی عمران، دانشکده تحصیلات تکمیلی مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران

۲. استادیار، گروه مهندسی آب، دانشکده کشاورزی، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

(تاریخ دریافت: ۱۳۹۸/۲/۳ - تاریخ بازنگری: ۱۳۹۸/۵/۲۲ - تاریخ تصویب: ۱۳۹۸/۶/۳)

### چکیده

در این مطالعه، مقادیر شوری، هدایت الکتریکی، تراز آب زیرزمینی و کل جامدات محلول در محدوده مطالعاتی اراک توسط چهار مدل نوین هوش مصنوعی ماشین آموزش نیرومند، ویولت- ماشین آموزش نیرومند، ماشین آموزش نیرومند ترتیبی آنلاین و ویولت- ماشین آموزش نیرومند ترتیبی آنلاین و همچنین نرم افزار مادفلو (مدل MT3D) شبیه‌سازی شدند. لازم به ذکر است که برای توسعه مدل‌های ترکیبی از تبدیل ویولت استفاده شد. در ابتدا، با استفاده از تابع خودهمبستگی و تابع خودهمبستگی جزئی، تاخیرهای موثر برای برآورد پارامترهای کیفی و کمی آب زیرزمینی شناسایی شدند. سپس با استفاده از این تاخیرها، چهار مدل مختلف برای هر یک از روش‌های هوش مصنوعی توسعه داده شدند. در ادامه، با انجام تحلیل حساسیت، مدل‌های برتر برای شبیه‌سازی پارامترهای کیفی و کمی آب زیرزمینی شناسایی شدند. همچنین موثرترین تاخیرها برای تخمین این پارامترها معرفی گردیدند. علاوه بر این، نتایج مدل مادفلو با مدل‌های هوش مصنوعی مقایسه شد که مدل‌های هوش مصنوعی دارای دقت بالاتری بودند. به‌عنوان مثال، مقادیر شاخص پراکندگی و ضریب نش برای کل جامدات محلول توسط مدل هوش مصنوعی برتر به ترتیب برابر با  $3-34E-5$  و  $0/991$  محاسبه شدند. همچنین، مقادیر RMSE و MAE برای تخمین تراز آب زیرزمینی توسط مدل برتر به ترتیب مساوی با  $0/078$  و  $0/061$  بدست آمدند. در انتها تحلیل عدم قطعیت برای مدل‌های برتر اجرا شد.

**واژه‌های کلیدی:** شوری، هدایت الکتریکی، تراز آب زیرزمینی، کل جامدات محلول، مادفلو، ماشین آموزش نیرومند

### مقدمه

لازم به ذکر است که روش‌های هوش مصنوعی و محاسبات نرم توانایی مدل‌سازی مسائل مختلف غیرخطی و پیچیده را دارند که اخیراً به‌صورت گسترده برای تخمین و شبیه‌سازی نحوه هجوم آب‌های شور به سمت آبخوان‌های شیرین استفاده شده‌اند. به‌عنوان مثال، Yang et al. (2014) یک مدل هیبریدی برای تخمین شوری حوضه رودخانه Qiantang را با استفاده از داده‌های سری زمانی توسعه دادند. مدل ترکیبی آن‌ها، از ترکیب مدل‌های شبکه عصبی مصنوعی و تبدیل ویولت به‌دست آمد. آن‌ها با تجزیه و تحلیل نتایج مدل‌های هوش مصنوعی خود نشان دادند که مدل ترکیبی در شبیه‌سازی شوری این رودخانه، با دقتی قابل قبول موفق بوده است. (Kheradpisheh et al. (2015) پارامترهای کیفی آب زیرزمینی شامل کلر، هدایت الکتریکی، سولفات و نیترات را به وسیله شبکه عصبی مصنوعی درون آبخوان‌های واقع در دشت بهاباد واقع در استان یزد، شبیه‌سازی کردند. آنها تعداد نرون‌های لایه مخفی را با استفاده از روش سعی و خطا تعیین کردند. علاوه

در سال‌های اخیر به علت خشکسالی‌های پیاپی و تغییر اقلیم در مناطق مختلف کره زمین، تراز آب زیرزمینی در این نواحی دچار تغییرات محسوسی شده است. کاهش تراز آب‌های زیرزمینی با افزایش تراز آب‌های شور باعث آلوده شده آب‌های شیرین به نمک شده‌اند. به‌عنوان مثال، بخشی از این آب‌های زیرزمینی در مجاورت دریاچه‌های شور واقع شده‌اند که تغییرات تراز آب زیرزمینی باعث نفوذ آب شور دریاچه به داخل آبخوان‌های شیرین و آلوده شدن آن‌ها می‌گردند. بنابراین، تخمین و شبیه‌سازی روند نفوذ آب شور به داخل آبخوان‌های شیرین دارای اهمیت فراوانی است که در سال‌های اخیر توسط محققین مختلف مورد مطالعه قرار گرفته‌اند. به‌عنوان مثال، (Chelsea and Wan (2013); Nofal et al. (2015); Priyanka and Mahesha (2015); Vaheddoost and Aksoy (2018) مطالعات میدانی و تحلیلی را پیرامون پارامترهای کمی و کیفی آب‌های زیرزمینی انجام دادند.

مادفלו براي تخمين و شبیه‌سازی پارامترهای کمی و کیفی سفره-های آب زیرزمینی است.

#### منطقه مورد مطالعه

محدوده مطالعاتی در این مطالعه، دشت اراک با مساحت ۵۵۲۰ کیلومتر مربع در حوضه آبریز میقان در حد فاصل طول‌های جغرافیایی ۴۹ درجه و ۲۹ دقیقه تا ۵۰ درجه و ۱۸ دقیقه شرقی و عرض جغرافیایی ۳۲ درجه و ۴۸ دقیقه تا ۳۴ درجه و ۴۴ دقیقه شمالی است. با توجه به نتایج بدست آمده در ایستگاه‌های واقع در حوضه مطالعاتی بیشترین بارش مربوط به ایستگاه الرج با میانگین سالانه بلند مدت ۴۶۱ میلی‌متر در شمال شرقی حوضه و کمترین بارش مربوط به ایستگاه داوودآباد با میانگین بلند مدت سالانه ۲۰۸ میلی‌متر در مرکز حوضه مطالعاتی به‌وقوع پیوسته است. در محدوده آبخوان دشت اراک سازندهای متنوعی وجود دارند. در بخش جنوبی و غرب دشت، سازندهای آهکی رسی و سیلتی وجود دارند که از نظر هیدروژئولوژیکی آب‌بند بوده و نمی‌توان انتظار داشت که آبخوان فراتر از آن گسترش داشته باشد. لذا مرز جنوبی آن فاقد جریان است. در سمت شرق آن سازندهای آهکی هفتاد قله رخنمون دارند که بررسی‌های بیلان انجام شده نشان می‌دهد که آب تاقدیس آهکی وارد آبخوان می‌شود اما بخاطر تفاوت شرایط هیدروژئولوژیکی تاقدیس مزبور و آبخوان اراک، این دو آبخوان مجزا لحاظ شده و مرز آبخوان به مرز کوه و دشت در شرق محدود می‌گردد. سازندهایی که در شمال شرق و شمال آبخوان قرار دارند نیز دارای هدایت هیدرولیکی بسیار کمی می‌باشند که می‌توان آن‌ها را مجزا از آبخوان دشت اراک در نظر گرفت. در نواحی حاشیه‌ای دشت مرزها فاقد جریان هستند و یا اینکه تغذیه کننده آبخوان هستند. محل تخلیه آبخوان به کویر میقان در مرکز دشت واقع شده است که باعث تشکیل یک حوضه بسته خواهد شد. آب ورودی به کویر میقان تحت تاثیر تبخیر از سطح ایستابی از سیستم خارج می‌شود. لازم به ذکر است که در این مطالعه، از پارامترهای کمی و کیفی مشاهداتی چاه ویسمه که تقریباً کامل‌ترین چاه مشاهداتی در یک بازه زمانی ۱۵ ساله است استفاده می‌گردد. در شکل (۱) موقعیت جغرافیایی ناحیه مورد مطالعه دریاچه میقان و چاه مشاهداتی ویسمه قابل مشاهده است. علاوه بر این مقادیر حداکثر، حداقل، میانگین، انحراف معیار و واریانس مقادیر مشاهداتی چاه ویسمه که برای یک دوره زمانی ۱۵ ساله برداشت شده در جدول (۱) مرتب گردیده است.

بر این، آنها نشان دادند که مدل عددی می‌تواند مقادیر کیفی آب زیرزمینی را با دقت بالایی شبیه‌سازی کند. Salami Shahid and Ehteshami (2016) مقادیر اکسیژن محلول<sup>۱</sup> و شوری آب در حوضه رودخانه San Joaquin واقع در ایالات متحده را توسط شبکه عصبی مصنوعی تخمین زدند. آن‌ها همچنین با تجزیه و تحلیل مقادیر مشاهداتی، یک رابطه برای محاسبه شوری آب پیشنهاد دادند. همچنین، Azari and Samani (2018) با استفاده از شبکه عصبی مصنوعی پارامترهای سفره آب زیرزمینی نامحدود را تعیین نمودند. آن‌ها برای آموزش مدل عصبی از تکنیک پس-خور استفاده نمودند. Roshni et al. (2019) نوسانات تراز آب زیرزمینی درون سفره‌های مرکب را توسط شبکه عصبی مصنوعی پیش‌خور و مدل ترکیبی ویولت- شبکه عصبی مصنوعی تخمین زدند. آن‌ها با بررسی نتایج مدل‌های عددی بیان نمودند که مدل ترکیبی مقادیر تابع هدف را با دقت بهتری شبیه‌سازی کرد. از یک طرف، به دلیل برداشت زیاد از سفره‌های آب زیرزمینی، مدل-ساز پارامترهای کمی و کیفی این منابع تامین آب شرب از اهمیت به‌سزایی برخوردار هستند. از طرف دیگر، تکنیک‌های هوش مصنوعی و مدل‌های عددی از دقت قابل قبولی برخوردار هستند. علاوه بر این، سرعت بالای محاسبات و کاهش هزینه‌های آزمایشگاهی و مطالعات میدانی از دیگر مزایای استفاده از روش-های عددی محسوب می‌شوند. همچنین، اخیراً مدل‌های عددی به صورت گسترده‌ای برای شبیه‌سازی مسائل مختلف به کاربرد گرفته شده‌اند و روز به روز بر محبوبیت آنها افزوده می‌شود.

در مطالعه حاضر، با استفاده از تبدیل ویولت و مدل‌های هوش مصنوعی شامل: ماشین آموزش نیرومند<sup>۲</sup> و ماشین آموزش نیرومند ترتیبی آنلاین<sup>۳</sup> مدل‌های ترکیبی ویولت- ماشین آموزش نیرومند<sup>۴</sup> و ویولت- ماشین آموزش نیرومند ترتیبی آنلاین<sup>۵</sup> توسعه داده می‌شوند. در ابتدا با استفاده از تابع خودهمبستگی<sup>۶</sup> و تابع خودهمبستگی نسبی<sup>۷</sup> تاخیرهای موثر شناسایی خواهند شد. سپس چهار مدل برای هر یک از روش‌های هوش مصنوعی تعریف می‌شوند. علاوه بر این، نتایج مدل‌های هوش مصنوعی با مدل مادفلو<sup>۸</sup> مقایسه خواهند شد. همچنین، با انجام یک تحلیل حساسیت، مدل برتر و موثرترین تاخیرها برای شبیه‌سازی پارامترهای کیفی و کمی سفره آب زیرزمینی دشت میقان شناسایی می‌گردند.

به بیان دیگر، هدف اصلی این مطالعه، بررسی دقیق عملکرد مدل‌های عددی مختلف اعم از هوش مصنوعی و سه‌بعدی مانند



شکل ۱. محدوده مورد مطالعه در استان مرکزی

جدول ۱. مقادیر حداکثر، حداقل، میانگین، انحراف معیار و واریانس مقادیر مشاهداتی چاه ویسمه

مقدار	شاخص آماری	پارامتر
۴۰۶۶	حداکثر	TDS (mg/L)
۱۷۷۷	حداقل	
۲۶۲۸/۳۹۴	میانگین	
۵۵۶/۴۰۴	انحراف معیار	
۳۰۹۵۸۵/۱	واریانس	
۶۰۸۳	حداکثر	EC ( $\mu\text{S}/\text{cm}$ )
۲۹۸۵	حداقل	
۴۴۷۴/۰۵۱	میانگین	
۱۰۵۹/۰۳	انحراف معیار	
۱۱۲۱۵۴۵	واریانس	
۴۳۷۲۰/۹۳	حداکثر	Salinity (mg/L)
۱۰۵۸۶/۹۷	حداقل	
۲۷۸۷۸/۲۶	میانگین	
۱۰۷۸۹/۲۴	انحراف معیار	
+۰۸E۱/۱۶	واریانس	
۱۶۶۶/۶۷۳	حداکثر	GWL (m)
۱۶۶۰/۲۵	حداقل	
۱۶۶۲/۷۸۷	میانگین	
۱/۴۰۸۲۳۹	انحراف معیار	
۱/۹۸۳۱۳۷	واریانس	

$$H = \begin{bmatrix} g(x_1; c_1, w_1) & \cdots & g(x_1; c_M, w_M) \\ \vdots & \ddots & \vdots \\ g(x_N; c_1, w_1) & \cdots & g(x_N; c_M, w_M) \end{bmatrix}_{N \times M} \quad (\text{رابطه ۳})$$

$$\beta = (\beta_1^T, \beta_2^T, \dots, \beta_M^T)^T \quad (\text{رابطه ۴})$$

وزن بردار خروجی به وسیله راه حل حداقل مربعات و معکوس پینوس- مور تعمیم یافته بردار لایه پنهان محاسبه می شود.

$$\beta = H^+ Y \quad (\text{رابطه ۵})$$

### ماشین آموزش نیرومند ترتیبی آنلاین (OSELM)

ماشین آموزش نیرومند ترتیبی آنلاین یک روش مدل سازی ترتیبی قابل اعتماد و قوی برای شبکه های عصبی پیش خور تک- لایه محسوب می شود (Liang et al. 2006). ماشین آموزش نیرومند ترتیبی آنلاین قادر است بخش به بخش با داده های مشاهداتی آموزش ببیند و یا تک به تک داده های اضافی را حذف کند. این مدل از گره های پنهان تابع پایه شعاعی و افزایش یافته استفاده می کند. خروجی گره های لایه مخفی برای گره مخفی افزایش یافته با استفاده از تابع فعال سازی سیگموئید، به صورت زیر تعریف می شود:

$$G(a_i, b_i, x) = g(b_i \|x - a_i\|) \quad (\text{رابطه ۶})$$

در اینجا  $b_i$  و  $a_i$  به ترتیب فاکتور تاثیر و مرکز گره هستند. همچنین،  $H^+$  در مدل OSELM به صورت زیر تعریف می شود:

$$H^+ = (H^T H)^{-1} H^T \quad (\text{رابطه ۷})$$

با جایگذاری رابطه ۷ در رابطه ۵، مقدار  $\beta$  به صورت زیر محاسبه می شود:

$$\beta = (H^T H)^{-1} H^T T \quad (\text{رابطه ۸})$$

پس از تعیین پارامترهای ورودی، محاسبه ماتریس خروجی لایه مخفی و برآورد وزن خروجی اولیه، ماتریس خروجی لایه پنهان نسبی در شرایط آموزش ترتیبی به شکل زیر محاسبه می گردد:

$$(\text{رابطه ۹})$$

$$H = \begin{bmatrix} G(a_1; b_1, x_{(\sum_{j=0}^k N_j)+1}) & \cdots & G(a_{\tilde{N}}; b_{\tilde{N}}, x_{(\sum_{j=0}^k N_j)+1}) \\ \vdots & \ddots & \vdots \\ G(a_1; b_1, x_{(\sum_{j=0}^k N_j)+1}) & \cdots & G(a_{\tilde{N}}; b_{\tilde{N}}, x_{(\sum_{j=0}^k N_j)+1}) \end{bmatrix}_{N_{k+1} \times \tilde{N}}$$

$$\beta^{(k+1)} = \beta^{(k)} + P_{k+1} H_{k+1}^T (T_{k+1} - H_{k+1} \beta^{(k)}) \quad (\text{رابطه ۱۰})$$

ویولت<sup>۳</sup>

### متدولوژی

در این قسمت، ابتدا مدل های هوش مصنوعی شامل ماشین آموزش نیرومند، ماشین آموزش نیرومند ترتیبی و نحوه ترکیب این دو مدل با تبدیل ویولت تشریح شده و مدل های ترکیبی ویولت ماشین آموزش نیرومند و ویولت ماشین آموزش نیرومند ترتیبی توسعه داده می شوند. سپس با استفاده از تابع خودهمبستگی و تابع خودهمبستگی نسبی موثرترین تاخیرها شناسایی می گردند. با استفاده از این تاخیرهای موثر، برای هر یک از این مدل های هوش مصنوعی چهار مدل متمایز تعریف می شود. در انتها توضیحات مربوط به مدل مادفلو ارائه می گردد.

### ماشین آموزش نیرومند (ELM)

جهت غلبه بر مشکلات الگوریتم های کلاسیک در آموزش شبکه های عصبی پیش خور تک لایه الگوریتم ماشین آموزش نیرومند ارائه شده است (Huang et al. 2006). این الگوریتم نسبت به الگوریتم های کلاسیک مانند شبکه عصبی مصنوعی، دارای مزایای قابل توجه زیر هستند:

- ۱) این الگوریتم نسبت به الگوریتم های دیگر سرعت بالایی دارد (۲) پارامترهای شبکه در طول آموزش مدل، به صورت تکرارشونده تنظیم می شود به طوری که دقت مدل سازی را افزایش می دهد، (۳) استفاده از ELM منجر به تعمیم یافتگی بهتر می شود، (۴) استفاده از این الگوریتم می تواند منجر به کاربرد توابع انتقال غیر قابل تغییر در آموزش شبکه های عصبی پیش خور تک لایه شود، (۵) استفاده از این الگوریتم شکل مینیمم های محلی یا بیش از حد مناسب را ندارد و (۶) الگوریتم ELM وزن های لایه مخفی را به صورت تصادفی تعیین می کند و تنها وزن های خروجی را با استفاده از یک رابطه خطی برآورد می کند. با فرض تعداد  $N$  نرون در لایه مخفی، یک شبکه SLFFNN به صورت تعریف می شود (Huang et al. 2006):

$$y_k = \sum_{i=1}^N \beta_i g(x_k; c_i, a_i) \quad k = 1, 2, 3, \dots, M \quad (\text{رابطه ۱})$$

در اینجا  $g(\cdot)$  و  $\beta_i$  به ترتیب تابع انتقال و تعداد نمونه های آموزش دلخواه هستند. بردار وزنی که بین گره های خروجی و گره های لایه مخفی اتصال برقرار می کند و بایاس ها به صورت تصادفی مقدار دهی می شوند. رابطه فوق را می توان به شکل ماتریس زیر بازنویسی کرد:

$$H\beta = Y \quad (\text{رابطه ۲})$$

خودهمبستگی نسبی برای شرایطی که روند از سری‌های زمانی حذف می‌شود ترسیم خواهند شد. لازم به ذکر است که برای سایر مدل‌ها، هیچ‌گونه پیش‌پردازشی بر روی داده‌ها انجام نمی‌شود. در انتها با استفاده از تاخیرهای موثر شناسایی شده در مرحله قبل، ترکیبات مختلف برای پارامترهای کیفی و کمی آب زیرزمینی به شکل زیر ارائه می‌شوند:

**Groundwater level (GWL)**

- M1:  $GWL(t) = f(GWL(t-1))$
- M2:  $GWL(t) = f(GWL(t-1), GWL(t-12))$
- M3:  $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-12))$
- M4:  $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-12))$

**TDS, EC, Salinity**

- M1:  $TS(t) = f(TS(t-1))$
- M2:  $TS(t) = f(TS(t-1), TS(t-2))$
- M3:  $TS(t) = f(TS(t-1), TS(t-2), TS(t-3))$
- M4:  $TS(t) = f(TS(t-1), TS(t-2), TS(t-3), TS(t-4))$

پارامتر TS معرف تابع هدف شامل کل جامدات محلول، هدایت الکتریکی و شوری است. در شکل (۳) نیز نتایج تحلیل تابع خودهمبستگی برای کلیه سری‌های زمانی نشان داده شده است. لازم به ذکر است که برای آموزش مدل‌های هوش مصنوعی مقادیر مشاهداتی مربوط به ۱۳۲ ماه و برای آزمون از ۴۳ ماه چاه ویسمه استفاده شد.

**مادفلو**

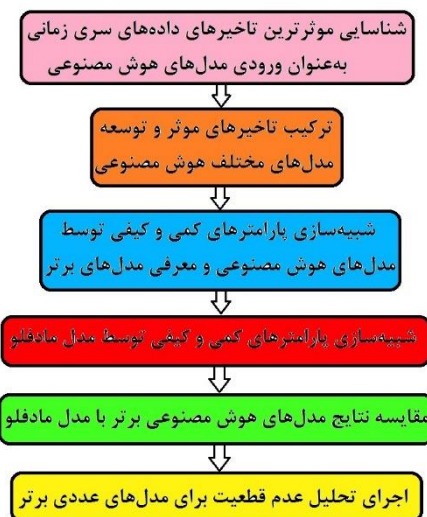
مادفلو یک برنامه کامپیوتری است که به صورت عددی توسط کد کامپیوتری MT3D معادلات جریان آب زیرزمینی را برای محیط‌های متخلخل با بهره‌گیری از روش تفاضلات محدود به صورت زیر حل می‌کند (McDonald and Harbaugh, 1998):

(رابطه ۱)

$$\frac{\partial}{\partial x} \left( K_{xx} \frac{\partial h}{\partial x} \right) + \frac{\partial}{\partial y} \left( K_{yy} \frac{\partial h}{\partial y} \right) + \frac{\partial}{\partial z} \left( K_{zz} \frac{\partial h}{\partial z} \right) - W = S_s \frac{\partial h}{\partial t}$$

که در این معادله  $K_{xx}$ ،  $K_{yy}$  و  $K_{zz}$  به ترتیب عبارتند از مقادیر هدایت هیدرولیکی در راستای محورهای X، Y و Z همچنین W معرف شار حجمی در واحد حجم،  $S_s$  ذخیره ویژه محیط متخلخل و t نشان دهنده زمان می‌باشد. مادفلو دربرگیرنده فرآیندهای جریان آب زیرزمینی، مشاهدات، تحلیل حساسیت و بهینه‌سازی پارامتر می‌باشد (Harbaugh et al., 2000). به منظور شناسایی و برآورد روند انتقال املاح در آبخوان، حرکت املاح با مینا قرار دادن جریان شبیه‌سازی کیفی انجام می‌شود. فرآیندهای دخیل در انتقال سه‌بعدی آلاینده‌ها در آب زیرزمینی شامل انتقال، پراکندگی و واکنش‌های شیمیایی می‌باشند که در قالب معادله

ویولت تبدیلی است که جهت بهینه‌سازی مدل‌های هوش مصنوعی مورد استفاده قرار می‌گیرد. این روش یک آنالیز طیفی مستقل از زمان است که به منظور توصیف مقیاس زمانی فرایندها و روابط آن‌ها، سری‌های زمانی را در فضای زمان-فرکانس از هم جدا می‌کند. تبدیل ویولت همانند تبدیل فوریه، سری زمانی را به صورت ترکیب خطی از چند تابع اصلی، در نظر می‌گیرد. یکی از مشخصات اصلی تبدیل ویولت این است که این تبدیل توانایی به دست آوردن اطلاعات در زمان، تناوب و موقعیت را به طور همزمان، دارد. تبدیل ویولت پیوسته توانایی عملکرد در هر مقیاس را دارد هرچند که محاسبه ضرایب ویولت در هر مقیاس بسیار مشکل بوده و نیازمند زمان محاسباتی بالا و تولید مقدار زیادی داده است. در انفصال تبدیل ویولت تنها یک زیر مجموعه از مقیاس‌ها و موقعیت‌ها به منظور انجام محاسبات، انتخاب می‌شود. در شکل (۲) فلوجارت کار حاضر ارائه شده است.



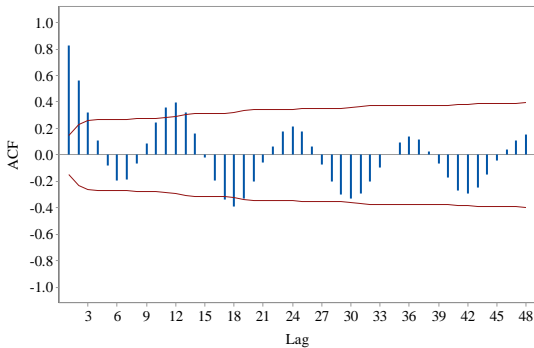
شکل ۲. فلوجارت مطالعه حاضر

**ترکیب مدل‌ها**


در این بخش، نحوه توسعه مدل‌های هوش مصنوعی برای تخمین شوری، هدایت الکتریکی، تراز آب زیرزمینی و کل جامدات محلول مورد بحث قرار می‌گیرد. به منظور مدل‌سازی، ابتدا نیاز است که ترکیب‌های مختلف ورودی تعریف شوند. به بیان دیگر، با توجه به ماهیت سری زمانی داده‌ها، کلیه تاخیرها در نظر گرفته می‌شوند. سپس با استفاده از توابع خودهمبستگی و خودهمبستگی نسبی جهت انتخاب موثرترین تاخیرها مورد استفاده قرار می‌گیرند. با توجه به مشهود بودن روند در سری زمانی تراز آب زیرزمینی، قبل از شروع مدل‌سازی اقدام به حذف روند می‌شود و سپس مدل‌سازی انجام می‌شود. بنابراین، توابع خودهمبستگی و

$$\frac{\partial}{\partial x_i} \left( \theta D_{ij} \frac{\partial c}{\partial x_j} \right) - \frac{\partial}{\partial x_i} (q_i C) + q_s C_s + R = \frac{\partial \theta_c}{\partial t}$$


دیفرانسیل جزئی زیر بیان می گردند:  
(رابطه ۱۲)




تراز آب زیرزمینی (بعد از حذف روند)



کل جامدات محلول



هدایت الکتریکی



شوری

شکل ۳. نمودار تابع خودهمبستگی برای کلیه سری های زمانی

نواحی خشک و نیمه خشک که در آنجا فشار کاپیلاری خاک نقش عمده ای در جریان ناحیه هوادهی ایفا می کند پرسش برانگیز است (Lerner et al., 1990; Hendrickx and Walker, 1997). مطالعه حاضر، به منظور پیاده سازی مدل آبخوان دشت اراک شبکه بندی محدوده مطالعاتی در مادفلو ۲۰۰۵ انجام شد. شبکه تفاضلات محدود در ابتدا به صورت ۲۰۰ در ۲۰۰ به تناسب محدوده مطالعاتی و شرایط مرزی دخیل در مدل سازی تعریف گردید و سپس با توجه به نیاز مدل در مراحل مختلف تراکم سطر و ستون ها ویرایش گردید تا مدل همگرا شد. با در نظر گرفتن اهداف تحقیق که مشتمل بر شبیه سازی هیدرولیک آب زیرزمینی و همچنین انتقال و انتشار پارامترهای کیفی انتخابی بود، رژیم جریان ناپایدار به منظور شبیه سازی جریان آب زیرزمینی انتخاب گردید. دوره های تنش هیدرولوژیکی به تناسب دوره زمانی مدل سازی که ۱۵ سال انتخاب گردیده است به مدل اعمال گردیدند. ضرائب هیدرولیکی آبخوان شامل هدایت هیدرولیکی و ضرائب ذخیره بر اساس داده های حاصل از آزمایش پمپاژ در محدوده آبخوان درون یابی گردیدند و در مراحل پایانی مدل سازی به واسطه

که در این معادله  $C$  غلظت آلاینده ( $ML^{-3}$ )،  $D_{ij}$  ضریب پخش هیدرودینامیکی ( $L^2T^{-1}$ )،  $q_i$  شار داری ( $LT^{-1}$ )،  $C_s$  غلظت در شار حجمی ورودی ( $ML^{-3}$ )،  $R$  واکنش آلاینده ( $ML^{-3}L^{-1}$ ) و  $\theta$  تخلخل می باشد که پارامتری بدون بعد است. در مادفلو، بسته های تغذیه (RCH) و تبخیر تعرق (EVT) به صورت گسترده ای به منظور تعیین فرآیندهای جریان ناحیه هوادهی مورد استفاده قرار می گیرند (Dong et al. 2012). نرخ تغذیه اغلب مستقیماً توسط کاربر به عنوان شار در بسته تغذیه مشخص می گردد. در حالی که تبخیر تعرق به عنوان یک شار مستقل از هد بین عمق سفره آبی و نرخ تبخیر تعرق در مادفلو تلقی می گردد. عمق اثر و بیشینه نرخ تبخیر تعرق تعیین شده توسط کاربر در شبیه سازی مورد استفاده قرار می گیرند. با این حال، تغذیه و تبخیر تعرق آب زیرزمینی از طریق ناحیه هوادهی با عمق سفره آبی، تیپ خاک، کاربری زمین و اقدامات مدیریت آب تغییر می کنند. بنابراین به دلیل شرایط پیچیده میدانی، مادفلو کماکان نمی تواند به صورت کاملاً دقیق تأثیر ناحیه هوادهی را بر سیستم جریان آب زیرزمینی شرح دهد. کاربرد روش های ذکر شده فوق به صورت واضح برای

$$VAF = \left( 1 - \frac{\text{var}(P_i - O_i)}{\text{var}(P_i)} \right) \times 100 \quad (\text{رابطه ۱۴})$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (\text{رابطه ۱۵})$$

$$SI = \frac{RMSE}{\bar{O}} \quad (\text{رابطه ۱۶})$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (\text{رابطه ۱۷})$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (\text{رابطه ۱۸})$$

در اینجا  $O_i$  مقادیر مشاهداتی،  $P_i$  مقادیر شبیه‌سازی شده به‌وسیله مدل‌های عددی،  $\bar{O}$  میانگین مقادیر مشاهداتی و  $n$  برابر تعداد مقادیر مشاهداتی است. در ادامه، به بررسی دقت مدل‌های عددی ELM، OSELM، WELM و WOSELM مختلف برای تخمین مقادیر EC، TDS، شوری و GWL پرداخته می‌شود. همچنین موثرترین تاخیرها و مدل‌های برتر معرفی می‌شوند. سپس نتایج مدل‌های هوش مصنوعی برتر با مدل مادفلو مورد مقایسه قرار می‌گیرند.

### بحث و نتیجه‌گیری

موثرترین تاخیرها که به‌وسیله توابع خودهمبستگی و خودهمبستگی نسبی شناسایی شدند به‌عنوان ورودی مدل‌های عددی در نظر گرفته می‌شوند و توابع هدف شامل شوری، هدایت الکتریکی، کل جامدات محلول و تراز آب زیرزمینی چاه مشاهداتی ویسمه با استفاده از این ورودی‌ها توسط مدل‌های هوش مصنوعی شبیه‌سازی خواهند شد. دلیل اصلی استفاده از چاه مشاهداتی ویسمه این است که مقادیر مشاهداتی این چاه در مقایسه با سایر چاه‌های منطقه در بازه زمانی مورد نظر کامل‌تر بود.

### کل جامدات محلول

در این بخش به ارزیابی دقت مدل‌های هوش مصنوعی توسعه داده شده برای شبیه‌سازی TDS چاه مشاهداتی ویسمه پرداخته می‌شود. لازم به ذکر است که کلیه تحلیل‌ها بر اساس نتایج تست ارائه می‌شوند. با توجه به ترکیب تاخیرهای مختلف، مدل ۱ تابعی از تاخیر (t-1) است. علاوه بر این، مدل ۲ مقادیر تابع هدف را با ترکیبی از تاخیرهای شماره (t-1) و (t-2) شبیه‌سازی می‌کند.

آنالیز حساسیت مقادیر آن‌ها تا حد ممکن اصلاح شدند. چاه‌های پمپاژ کشاورزی و صنعتی از طریق بسته WEL و رودخانه‌ها و آبراهه‌های موجود در محدوده اطلاعاتی از طریق بسته RIV متناسب با گام‌های زمانی به مدل معرفی شدند. ضریب تغذیه ناشی از بارش و رواناب و همچنین آب برگشتی حاصل از فعالیت‌های کشاورزی در هر دوره تنش از طریق مدل HEC-HMS برآورد گردید و از طریق بسته تغذیه (RCH) به مدل اعمال شد. همچنین مشخصات فیزیکی و هیدرولیکی دریاچه آب شور واقع در محدوده مطالعاتی به‌واسطه بسته دریاچه (LAK) به مدل معرفی شدند. مقادیر شار غلظت نیز در گام‌های زمانی مختلف به شبکه تفاضلات محدود وارد شدند. باید اضافه کرد که فرآیند کالیبراسیون در این مطالعه به این شکل انجام شده است که ابتدا مدل در شرایط پایدار اجرا گردید که در این راستا دوره زمانی سه ماهه پاییز سال ۱۳۷۷ که در آن تغییرات و نوسانات سطح ایستابی در حداقل حالت ممکن ارزیابی گردیدند اجرا شد. برای انجام کالیبراسیون از نرم افزار PEST استفاده شد به این‌صورت که دو پارامتر هدایت هیدرولیکی و تغذیه انتخاب شده و مقادیر اولیه آن‌ها بر اساس مرحله کالیبراسیون دستی به مدل وارد شد، سپس با معرفی مقادیر ماکزیمم و مینیمم مجاز برای هر یک از پارامترها و اعمال سایر تنظیمات در نرم افزار PEST، عملیات کالیبراسیون خودکار انجام شد. پس از کالیبراسیون، مدل در رژیم ناپایدار منطبق بر گام‌های زمانی تعریف شده اجرا گردید، و مدل با استفاده از داده‌های مشاهداتی هد و غلظت ۴۴ چاه با پراکندگی قابل قبول در محدوده دشت صحت‌سنجی گردید و خطای مقادیر هد محاسباتی در برابر مشاهداتی در محدوده قابل قبول قرار گرفت. در پایان به منظور بدست آوردن مقادیر تراز آب زیرزمینی در ۱۷۵ ماه، مقادیر سری زمانی چاه ویسمه واقع در مختصات  $Utmx = 384551$  و  $Utmy = 3798163$  استخراج گردیدند تا نوسانات تراز آب زیرزمینی و غلظت در این نقطه مورد ارزیابی قرار گیرند.

### معیارهای عملکرد مدل‌های عددی

در مطالعه حاضر به‌منظور ارزیابی دقت مدل‌های عددی از شاخص‌های آماری ضریب تبیین ( $R^2$ )، شاخص عملکرد (VAF)، جذر میانگین مربعات خطا (RMSE)، شاخص پراکندگی ( $SI$ )<sup>۲</sup>، میانگین قدرمطلق خطا (MAE) و ضریب نش (NSC) استفاده می‌شود:

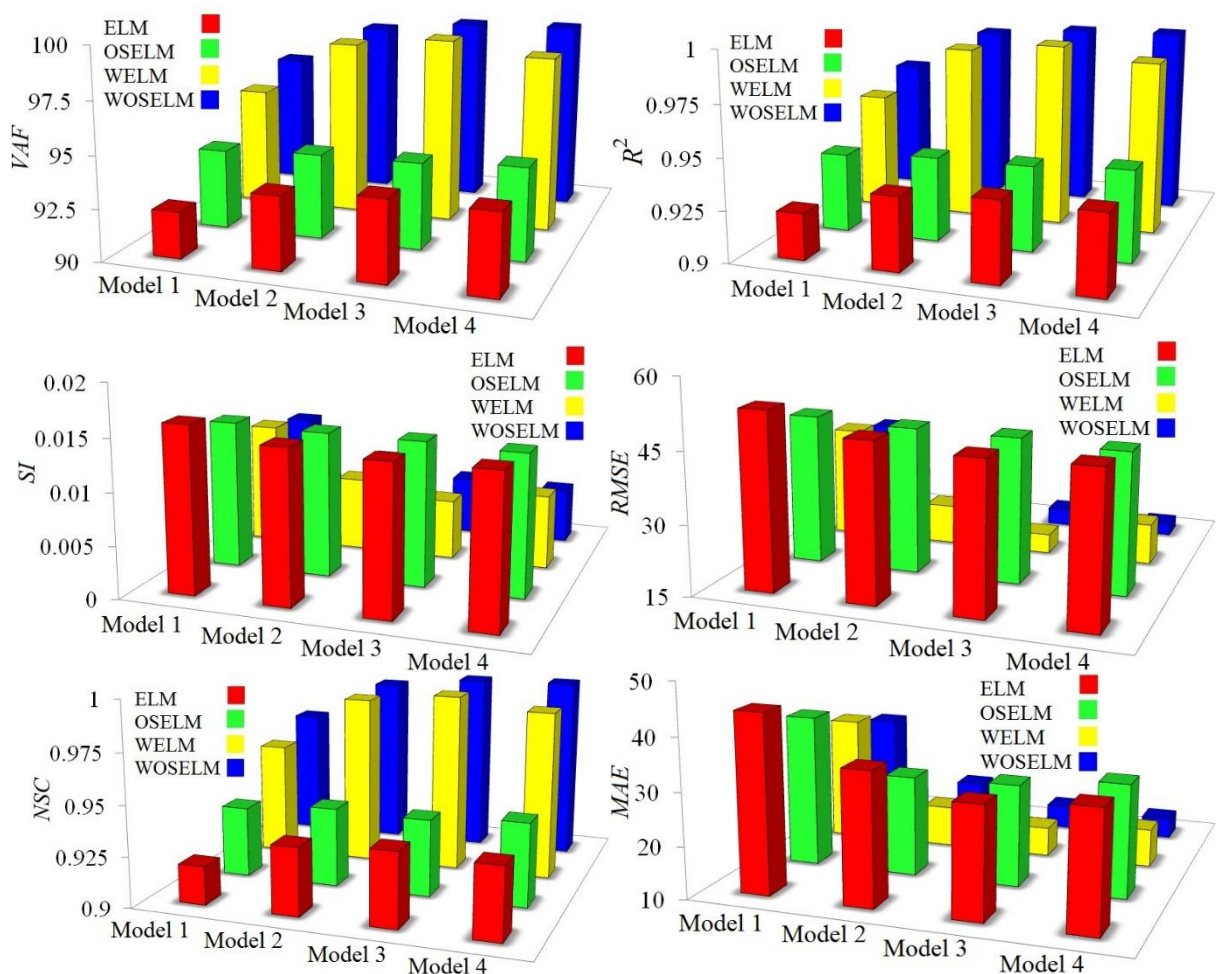
(رابطه ۱۳)

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



و همچنین، مدل ۳ با ترکیب تاخیرهای شماره (t-1)، (t-2) و (t-3) مقادیر تابع هدف را تخمین می‌زند. در مقابل، مدل ۴ بر حسب تاخیرهای (t-1)، (t-2)، (t-3) و (t-4) مقادیر EC، شوری و GWL را مدل‌سازی می‌کند. نتایج شاخص‌های آماری مختلف کلیه مدل‌های هوش مصنوعی برای تخمین TDS در شکل (۴) نشان داده شده است. بر اساس نتایج مدل‌سازی، در بین کلیه مدل‌های ELM مدل ۲ مقادیر TDS را با دقت بیشتری شبیه‌سازی کرد. به‌عنوان مثال، مقدار شاخص پراکندگی برای این مدل برابر با ۰/۰۱۴ میلی‌گرم بر لیتر محاسبه شد. همچنین، مقادیر MAE، RMSE و NSC برای ELM ۲ به ترتیب مساوی با ۳۱/۱۴۶، ۴۶/۹۵۶ و ۰/۹۳۷ میلی‌گرم بر لیتر محاسبه شدند. با توجه به نتایج مدل‌های OSELM، مدل ۴ مقادیر TDS را با دقت بیشتری برآورد نمود. بر اساس نتایج مدل‌سازی، مقادیر

همچنین، مدل ۳ با ترکیب تاخیرهای شماره (t-1)، (t-2) و (t-3) مقادیر تابع هدف را تخمین می‌زند. در مقابل، مدل ۴ بر حسب تاخیرهای (t-1)، (t-2)، (t-3) و (t-4) مقادیر EC، شوری و GWL را مدل‌سازی می‌کند. نتایج شاخص‌های آماری مختلف کلیه مدل‌های هوش مصنوعی برای تخمین TDS در شکل (۴) نشان داده شده است. بر اساس نتایج مدل‌سازی، در بین کلیه مدل‌های ELM مدل ۲ مقادیر TDS را با دقت بیشتری شبیه‌سازی کرد. به‌عنوان مثال، مقدار شاخص پراکندگی برای این مدل برابر با ۰/۰۱۴ میلی‌گرم بر لیتر محاسبه شد. همچنین، مقادیر MAE، RMSE و NSC برای ELM ۲ به ترتیب مساوی با ۳۱/۱۴۶، ۴۶/۹۵۶ و ۰/۹۳۷ میلی‌گرم بر لیتر محاسبه شدند. با توجه به نتایج مدل‌های OSELM، مدل ۴ مقادیر TDS را با دقت بیشتری برآورد نمود. بر اساس نتایج مدل‌سازی، مقادیر




شکل ۴. نتایج شاخص‌های آماری مدل‌های هوش مصنوعی مختلف برای برآورد TDS

و ۳ و WOSELM ۴ در مقایسه با سایر مدل‌ها بیشتر بود. به‌عنوان مثال، مقدار R<sup>2</sup> برای مدل‌های ELM ۳ و OSELM ۴ به ترتیب مساوی با ۰/۹۳۹ و ۰/۹۴۵ میلی‌گرم بر لیتر بدست آمدند. در مقابل، مقدار شاخص آماری ضریب تبیین برای WELM ۳ و

علاوه بر این، مقایسه مقادیر TDS شبیه‌سازی شده با مقادیر مشاهداتی و نمودارهای پراکندگی مدل برتر هوش مصنوعی در شکل (۵) قابل مشاهده است. با توجه به نتایج مدل‌سازی، مقدار R<sup>2</sup> برای مدل‌های ELM ۳، OSELM ۴، WELM

2)، (t-3) و (t-4) بود. بنابراین برای شبیه‌سازی TDS مدل WOSELM 4 مدل برتر و تاخیرهای (t-1)، (t-2)، (t-3) و (t-4) موثرترین تاخیرها شناسایی شدند.

WOSELM 4 به ترتیب برابر با ۰/۹۹۰ و ۰/۹۹۱ میلی‌گرم بر لیتر محاسبه شدند. بنابراین بر اساس تحلیل حساسیت کلیه مدل‌ها، مدل WOSELM 4 مقادیر TDS را با بیشترین همبستگی و کمترین خطا تخمین زد. این مدل تابعی از تاخیرهای (t-1)، (t-2)



شکل ۵. مقایسه مقادیر TDS برآورد شده با مشاهداتی و نمودارهای پراکندگی مدل برتر هوش مصنوعی WOSELM 4

در شکل (۷) نیز مقایسه مقادیر هدایت الکتریکی شبیه‌سازی شده با مشاهداتی و نمودارهای پراکندگی برای مدل برتر هوش مصنوعی قابل مشاهده است. مقادیر ضریب تبیین برای مدل‌های OSELM 4، WELM 3 و ELM 3 به ترتیب برابر با ۰/۹۵۷، ۰/۹۶۵ و ۰/۹۸۹ میکرو موس بر سانتی‌متر محاسبه شدند. در مقابل، مقدار  $R^2$  برای WOSELM 4 برابر با ۰/۹۹۱ میکرو موس بر سانتی‌متر بود. بنابراین با توجه به تجزیه و تحلیل مدل‌های هوش مصنوعی، مدل WOSELM 4 دارای بهترین عملکرد برای شبیه‌سازی پارامتر EC چاه مشاهداتی EC بود. این مدل مقادیر EC را با ترکیبی از تاخیرهای (t-1)، (t-2)، (t-3) و (t-4) شبیه‌سازی کرد.

#### شوری


در شکل (۸) مقایسه شاخص‌های آماری مختلف کلیه مدل‌های هوش مصنوعی جهت مدل‌سازی شوری نشان داده شده است. بر اساس نتایج مدل‌سازی، در میان همه مدل‌های ELM، مدل ELM 2 مقادیر شوری را با عملکرد بهتری شبیه‌سازی نمود. برای ELM 2 مقادیر SI، VAF و NSC به ترتیب برابر با ۰/۰۱۴، ۸۸/۹۸۶ و ۰/۸۶۹ میلی‌گرم بر لیتر محاسبه شدند. این در حالی است که در بین همه مدل‌های OSELM، مدل OSELM 2 دارای دقت بیشتری بود. به عنوان مثال، مقادیر MAE، RMSE و VAF برای OSELM 2 به ترتیب برابر با ۳۷۴/۲۷۹، ۵۰۸/۲۷۷ و ۹۰/۰۲۲ میلی‌گرم بر لیتر تخمین زده شدند. با بررسی نتایج کلیه مدل‌های WELM مشخص شد که WELM 2 مقادیر تابع هدف را با عملکرد بهتری در مقایسه با سایر مدل‌ها برآورد کرد. برای

#### هدایت الکتریکی


در این قسمت به ارزیابی دقت مدل‌های ELM، OSELM، WELM و WOSELM برای مدل‌سازی هدایت الکتریکی پرداخته می‌شود. نتایج کلیه شاخص‌های آماری همه این مدل‌ها در شکل (۶) به تصویر کشیده شده است. با توجه به نتایج مدل‌سازی، مدل ELM 3 دارای دقت بیشتری در مقایسه با سایر مدل‌های ELM بود. به عنوان مثال، مقادیر SI، VAF و MAE برای ELM 3 به ترتیب مساوی با ۰/۰۰۵، ۹۸/۸۹۴ و ۲۰/۳۹۲ میکرو موس بر سانتی‌متر محاسبه شدند. این در حالی است که در میان همه مدل‌های OSELM، مدل OSELM 4 مقادیر هدایت الکتریکی را با دقت بالاتری شبیه‌سازی کرد. برای این مدل، مقادیر RMSE و MAE به ترتیب مساوی با ۲۴/۲۹۷ و ۱۸/۰۰۵ میکرو موس بر سانتی‌متر به دست آمدند. با توجه به نتایج کلیه مدل‌های WELM، مدل WELM 3 عملکرد بهتری داشت. به عنوان مثال، مقادیر شاخص‌های آماری SI، NSC و VAF برای WELM 3 به ترتیب برابر با ۰/۰۰۵، ۹۸/۸۹۴ و ۹۸/۸۹۴ میکرو موس بر سانتی‌متر بودند. این در حالی است که در میان همه مدل‌های WOSELM، مدل WOSELM 4 دارای کمترین مقدار خطا بود. به عنوان مثال، مقادیر NSC، MAE و SI برای WOSELM 4 به ترتیب مساوی با ۰/۹۹۱، ۱۸/۰۰۵ و ۴/۲۸۸-۰۳ میکرو موس بر سانتی‌متر تخمین زده شدند. همچنین مقادیر RMSE و VAF برای این مدل به ترتیب برابر با ۲۴/۲۹۷ و ۹۹/۰۵۷ میکرو موس بر سانتی‌متر بودند.

این مدل مقادیر RMSE و VAF به ترتیب برابر با ۲۷۳/۹۱۲ و ۹۷/۱۷۰ میلی گرم بر لیتر بودند. علاوه بر این، شاخص‌های NSC، SI و MAE برای WOSELM 2 به ترتیب مساوی با ۰/۹۷۲، ۰/۰۰۷ و ۲۱۴/۱۳۷ میلی گرم بر لیتر محاسبه شدند.

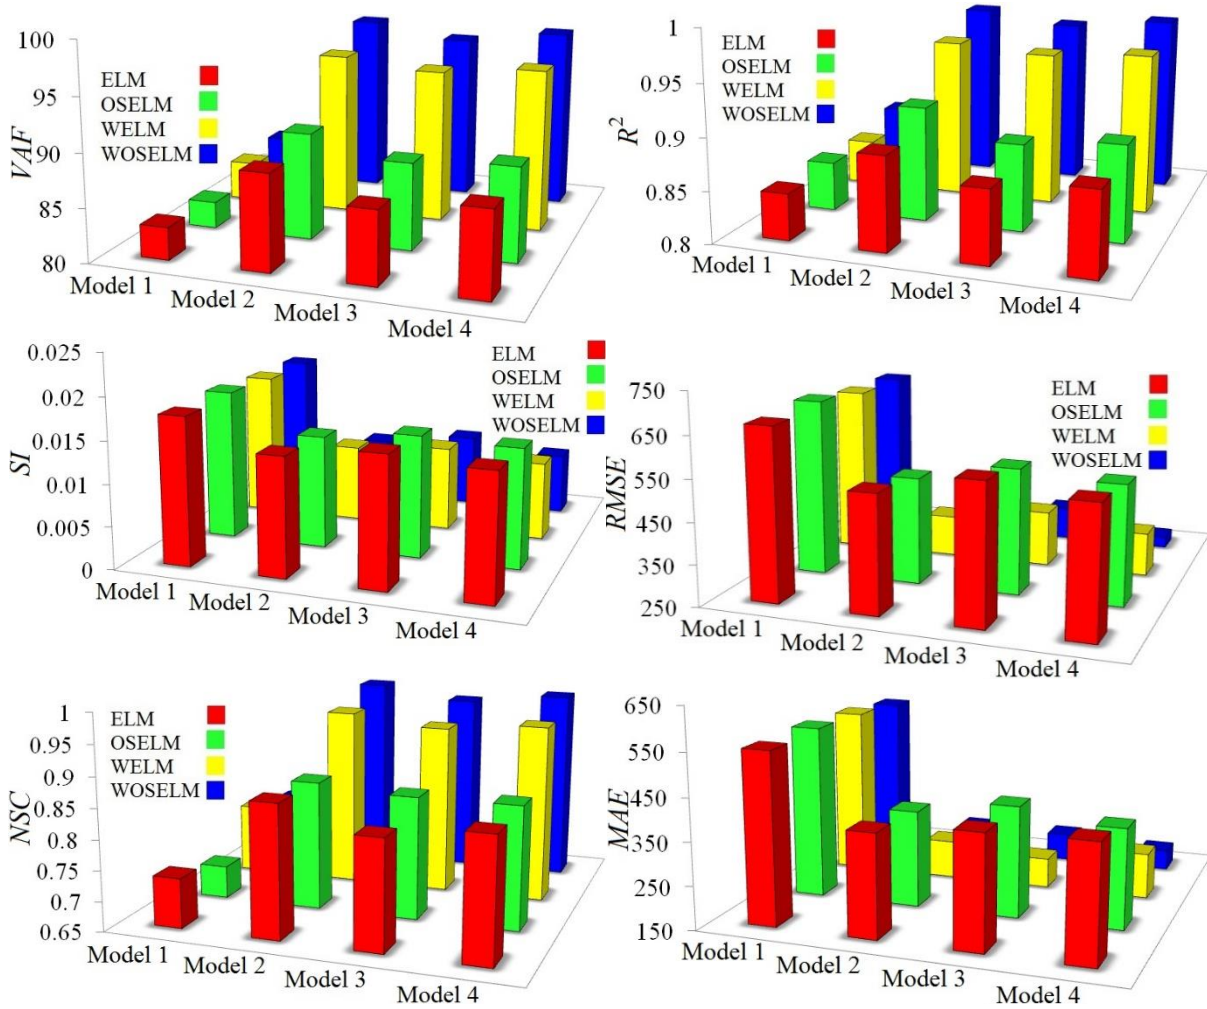
WELM 2 مقادیر شاخص‌های آماری SI، MAE و NSC به ترتیب مساوی با ۰/۰۰۹، ۲۳۸/۵۱۱ و ۰/۹۴۷ میلی گرم بر لیتر محاسبه شدند. در مقابل، در بین کلیه مدل‌های WOSELM، مدل WOSELM 2 مقدار شوری را با کمترین خطا برآورد نمود.



شکل ۶. نتایج شاخص‌های آماری مدل‌های هوش مصنوعی مختلف برای برآورد EC



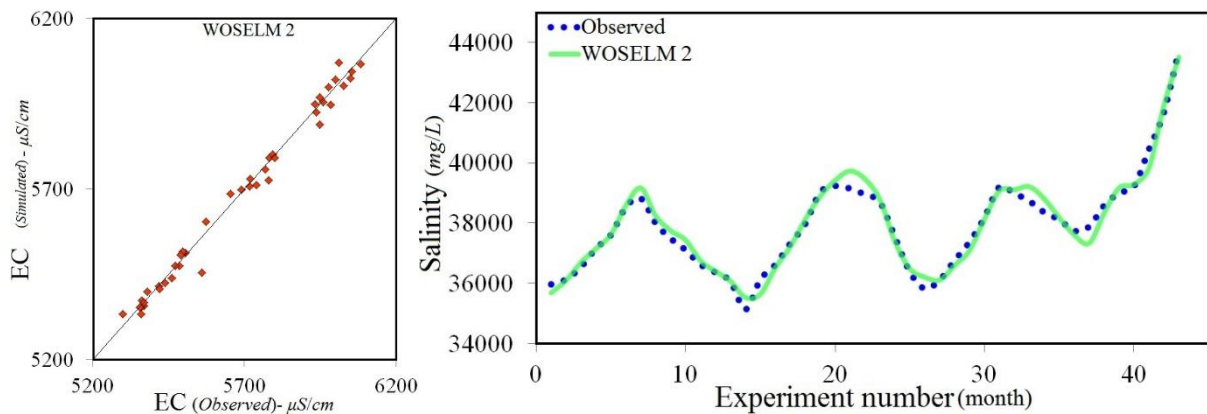
شکل ۷. مقایسه مقادیر EC برآورد شده با مشاهداتی و نمودارهای پراکندگی مدل برتر هوش مصنوعی WOSELM 4



شکل ۸. نتایج شاخص‌های آماری مدل‌های هوش مصنوعی مختلف برای برآورد شوری

برای این مدل مساوی با ۰/۹۷۲ میلی‌گرم بر لیتر بود. این در حالی است که مقدار ضریب تبیین برای مدل‌های ۲ ELM، ۲ WELM و ۲ OSELM به ترتیب مساوی با ۰/۸۹۱، ۰/۹۵۴ و ۰/۹۱۱ میلی‌گرم بر لیتر بودند. بنابراین مدل ۲ WOSELM به عنوان مدل برتر برای تخمین شوری معرفی شد و تاخیرهای شماره (t-1) و (t-2) نیز موثرترین تاخیرها شناسایی شدند.

در ادامه به بررسی همبستگی مدل‌های مختلف هوش مصنوعی برای شبیه‌سازی شوری پرداخته می‌شود. در شکل (۹) مقایسه مقادیر شوری برآورد شده با مشاهداتی و نمودارهای پراکندگی مدل برتر هوش مصنوعی قابل مشاهده است. بر اساس نتایج شبیه‌سازی‌ها، مدل ۲ WOSELM دارای بیشترین همبستگی با مقادیر مشاهداتی است. به‌عنوان مثال مقدار R<sup>2</sup>

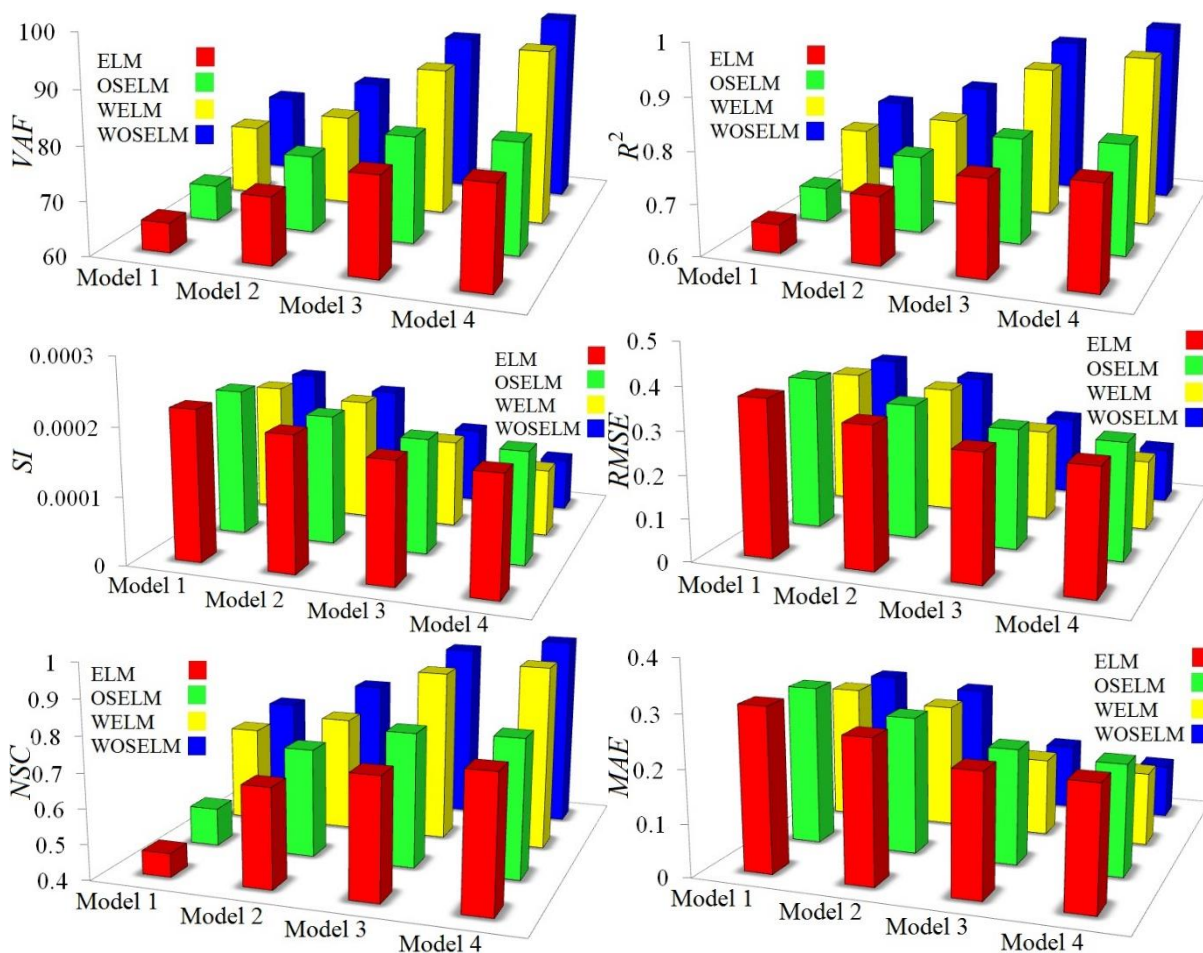


شکل ۹. مقایسه مقادیر شوری برآورد شده با مشاهداتی و نمودارهای پراکندگی مدل برتر هوش مصنوعی ۲ WOSELM

تراز آب زیرزمینی

برای OSELM 4 به ترتیب مساوی با ۰/۰۰۰۲، ۰/۲۱۰ و ۸۰/۶۸۳ متر به دست آمدند. لازم به ذکر است که در بین کلیه مدل‌های ترکیبی WELM، مدل WELM 4 نیز دارای دقت بالایی برای برآورد تراز آب زیرزمینی بود. مقادیر شاخص‌های آماری NSC و VAF برای این مدل به ترتیب مساوی با ۰/۹۳۱ و ۹۲/۹۰۷ متر محاسبه شدند. همچنین مقدار RMSE برای WELM 4 مساوی با ۰/۱۶۷ متر تخمین زده شد. در میان همه مدل‌های WOSELM نیز مدل WOSELM 4 مقادیر تراز آب زیرزمینی را با دقت بالاتری شبیه‌سازی نمود. برای این مدل مقادیر SI، MAE و NSC به ترتیب برابر با  $7/94E-05$ ، ۰/۱۰۴ و ۰/۹۵۶ متر بدست آمدند.

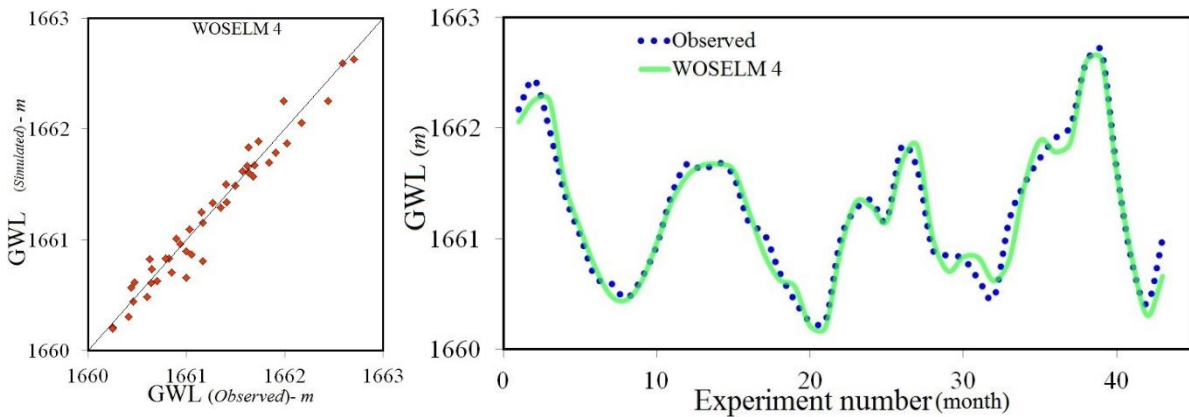
در این قسمت به بررسی نتایج مدل‌سازی‌ها برای تخمین تراز آب زیرزمینی پرداخته می‌شود. همچنین مقایسه شاخص‌های آماری کلیه مدل‌های هوش مصنوعی برای تخمین تراز آب زیرزمینی در شکل (۱۰) به تصویر کشیده شده است. بر اساس نتایج مدل‌سازی، در بین همه مدل‌های ELM، مدل ELM 4 بهترین مدل بود زیرا مقادیر شاخص‌های آماری NSC و SI برای آن به ترتیب مساوی با ۰/۷۸۱ و ۰/۰۰۰۲ متر محاسبه شدند. علاوه بر این، برای ELM 4 مقادیر RMSE و MAE به ترتیب برابر با ۰/۲۸۸ و ۰/۲۲۹ متر بودند. این در حالی است که در میان کلیه مدل‌های OSELM، مدل OSELM 4 مقادیر تغییرات تراز آب زیرزمینی را با دقت بیشتری شبیه‌سازی کرد. به عنوان مثال، شاخص‌های SI، MAE و VAF



شکل ۱۰. نتایج شاخص‌های آماری مدل‌های هوش مصنوعی مختلف برای برآورد تراز آب زیرزمینی

ضریب تبیین برای WOSELM 4 مساوی با ۰/۹۵۷ متر تخمین زده شد. بنابراین مدل WOSELM 4 به عنوان مدل برتر و تاخیرهای (t-1)، (t-2)، (t-3) و (t-4) نیز به عنوان موثرترین تاخیرها برای شبیه‌سازی تراز آب زیرزمینی معرفی شدند.

در شکل (۱۱) نیز مقایسه مقادیر تراز آب زیرزمینی برآورد شده با مشاهداتی و نمودارهای پراکندگی مدل برتر هوش مصنوعی قابل مشاهده است. برای مدل‌های ELM 4، OSELM 4 و WELM 4 مقدار شاخص آماری R<sup>2</sup> به ترتیب برابر با ۰/۷۹۷، ۰/۸۱۲ و ۰/۸۳۲ متر بدست آمدند. این در حالی است که مقدار



شکل ۱۱. مقایسه مقادیر تراز آب زیرزمینی برآورد شده با مشاهداتی و نمودارهای پراکندگی مدل‌های مختلف هوش مصنوعی WOSELM 4

مقابل مقادیر SI و  $R^2$  این مدل برای شبیه‌سازی شوری به ترتیب برابر با ۰/۰۲۲ و ۰/۷۳۷ میلی‌گرم بر لیتر تخمین زده شدند. همچنین شاخص‌های آماری NSC، SI و MAE برای تراز آب زیرزمینی مدل‌سازی شده توسط مدل مادفلو به ترتیب مساوی با ۰/۸۶۶، ۰/۰۰۱ و ۰/۱۷۶ متر بودند. بنابراین همان‌گونه که مشاهده می‌شود مدل مادفلو مقادیر EC، TDS، شوری و GWL را با دقت قابل قبولی شبیه‌سازی کرده است. بنابراین بر اساس نتایج مدل‌سازی‌ها، مدل WOSELM 4 مقدار TDS، WOSELM 4 مقدار EC، WOSELM 4 مقدار شوری و WOSELM 4 مقدار GWL را با دقت بیشتری در مقایسه با مدل مادفلو شبیه‌سازی کردند.

نتایج مادفلو

در ادامه نتایج مدل مادفلو برای شبیه‌سازی مقادیر کمی و کیفی چاه مشاهداتی ویسمه مورد بررسی قرار می‌گیرد. نتایج کلیه شاخص‌های آماری برای مدل مادفلو در جدول (۲) مرتب شده است. به‌عنوان مثال، مقادیر  $R^2$ ، SI و NSC مدل مادفلو برای تخمین پارامتر کل جامدات محلول به ترتیب مساوی با ۰/۹۸۷، ۰/۰۰۷ و ۰/۹۸۷ میلی‌گرم بر لیتر بدست آمدند. این در حالی است که شاخص‌های آماری VAF، RMSE و MAE برای برآورد هدایت الکتریکی توسط مدل مادفلو به ترتیب مساوی با ۹۸/۲۱۸، ۳۴/۷۵۵ و ۲۸/۷۸۶ میکرو موس بر سانتی‌متر محاسبه شدند. در

جدول ۲. نتایج شاخص‌های آماری برای مدل مادفلو

	$R^2$	MAE	RMSE	SI	NSC	VAF
TDS	۰/۹۸۷	۱۳/۷۱۹	۲۱/۷۸۱	۰/۰۰۷	۰/۹۸۷	۹۸/۶۶۵
EC	۰/۹۸۳	۲۸/۷۸۶	۳۴/۷۵۵	۰/۰۰۶	۰/۹۸۱	۹۸/۲۱۸
Salinity	۰/۷۳۷	۱۷۶/۸۸۴	۸۳۶/۶۲۶	۰/۰۲۲	۰/۷۳۰	۶۲/۳۰۹
GWL	۰/۹۸۶	۰/۱۷۶	۰/۲۲۹	۰/۰۰۰۱	۰/۸۶۶	۸۹/۳۰۱

$(e_i = P_i - O_i)$ . علاوه بر این، میانگین خطای برآورد شده به صورت  $\bar{e} = \sum_{i=1}^n e_i$  به دست می‌آید. همچنین، انحراف استاندارد مقادیر خطای برآورد شده نیز به صورت  $S_e = \sqrt{\sum_{i=1}^n (e_i - \bar{e})^2 / n - 1}$  است. لازم به ذکر است که منفی بودن مقدار  $\bar{e}$  نشان می‌دهد که مدل عددی عملکرد کمتر از مقدار واقعی دارد و مثبت بودن  $\bar{e}$  به معنای عملکرد بیشتر از مقدار واقعی<sup>۲</sup> مدل مذکور است. همچنین، با استفاده از پارامترهای  $\bar{e}$  و  $S_e$  یک باند اطمینان در اطراف مقادیر خطای برآورد توسط روش ویلسون<sup>۳</sup> بدون اصلاح پیوسته ایجاد می‌شود.

تحلیل عدم قطعیت

در ادامه تحلیل عدم قطعیت مدل‌های هوش مصنوعی برتر (WOSELM 2، WOSELM 4) و مادفلو برای پارامترهای کمی و کیفی اجرا می‌شود. در جدول (۳) نتایج تحلیل عدم قطعیت برای این مدل‌ها مرتب شده است. تحلیل عدم قطعیت جهت ارزیابی خطای برآورد شده توسط مدل‌های عددی و تعیین نحوه عملکرد این مدل‌ها انجام می‌شود. به طور کلی خطای برآورد شده مدل عددی برابر با مقادیر شبیه‌سازی شده توسط مدل عددی ( $P_i$ ) منهای مقادیر مشاهداتی ( $O_i$ ) در نظر گرفته می‌شود

3Wilson score method

1Underestimated  
2Overestimated

برای مدل‌سازی هدایت الکتریکی، شوری و تراز آب زیرزمینی عملکردی بیشتر از واقعی داشت. علاوه بر این WOSELM 4 برای تخمین کل جامدات محلول، هدایت الکتریکی و تراز آب زیرزمینی با یک عملکرد بیشتر از مقدار واقعی این پارامترها را تخمین زد. این در حالی است که مقدار شوری با عملکردی کمتر از مقدار واقعی توسط مدل WOSELM 2 مدل‌سازی شد.

سپس با استفاده از  $\pm 1.64S_e$  به صورت تقریبی منجر به ۹۵ درصد باند اطمینان می‌گردد که با PEI ۹۵٪ نشان داده می‌شود. در جدول (۳) پارامترهای تحلیل عدم قطعیت مدل‌های هوش مصنوعی برتر و مادفلو برای پارامترهای مختلف مرتب شده‌اند. در این جدول عرض باند عدم قطعیت با WUB نشان داده می‌شود. با توجه به نتایج تحلیل عدم قطعیت، مدل مادفلو برای شبیه‌سازی کل جامدات محلول دارای عملکردی کمتر از واقعی بود و در مقابل

جدول ۳. پارامترهای تحلیل عدم قطعیت مدل‌های هوش مصنوعی برتر و مادفلو برای پارامترهای مختلف

مدل عددی	پارامتر	$\bar{e}$	$S_e$	WUB	95% PEI
WOSELM 4	کل جامدات محلول	-۱/۵۸۰	۳/۳۵۰	-۶/۷۶۵	۵/۱۹۰ تا -۸/۳۴۰
		۰/۰۸۰	۲/۷۱۰	-۵/۴۷۵	۵/۵۶۰ تا -۵/۳۹۰
WOSELM 4	هدایت الکتریکی	۷/۱۳۰	۵/۲۵۰	-۱۰/۵۹۰	۱۷/۷۲۰ تا -۳/۴۶۰
		۱/۱۵۰	۳/۷۴۰	-۷/۵۶۰	۸/۷۱۰ تا -۶/۴۱۰
WOSELM 2	شوری	۱۳۳	۱۲۷	-۲۵۷	۳۹۰ تا -۱۲۴
		-۴۱/۹	۴۱/۸	-۸۴/۳	۴۲/۴ تا -۱۲۶/۲
WOSELM 4	تراز آب زیرزمینی	۰/۰۱۰	۰/۰۳۵	-۰/۰۷۱	۰/۰۸۱ تا -۰/۰۶۱
		۰/۰۱۹	۰/۰۲۰	-۰/۰۴۱	۰/۰۶۰ تا -۰/۰۲۱

ادامه با تجزیه و تحلیل نتایج شبیه‌سازی، موثرترین مدل‌ها برای تخمین TDS، EC، شوری و GWL معرفی شدند. مدل‌های هوش مصنوعی پارامترهای کیفی و کمی آب زیرزمینی را با دقت قابل قبولی شبیه‌سازی کردند. به‌عنوان مثال، مقادیر  $R^2$ ، SI و VAF برای تخمین شوری توسط مدل WOSELM 2 به ترتیب برابر با ۰/۹۷۲، ۰/۰۰۷ و ۹۷/۱۷۰ محاسبه شدند. لازم به ذکر است که تبدیل ویولت دقت مدل‌های هوش مصنوعی را به شکل قابل توجهی افزایش داد. همچنین، عملکرد مدل‌های OSELM در مقایسه با مدل‌های ELM بهتر بود. علاوه بر این، بر اساس تحلیل حساسیت، تاخیرهای شماره (t-1)، (t-2)، (t-3) و (t-4) موثرترین تاخیرها برای مدل‌سازی GWL توسط مدل WOSELM 4 شناسایی شدند. همچنین نتایج مدل‌های هوش مصنوعی با مدل مادفلو مقایسه شد که تجزیه و تحلیل نتایج این مدل‌های عددی نشان داد که مدل‌های هوش مصنوعی دارای بیشترین همبستگی با مقادیر مشاهداتی بودند. در انتها یک تحلیل عدم قطعیت برای مدل‌های عددی ارائه شده اجرا گردید.

### جمع بندی

هدف از این تحقیق، بررسی عملکرد مدل‌های عددی مختلف اعم از هوش مصنوعی و سه‌بعدی برای تخمین و شبیه‌سازی پارامترهای کمی و کیفی سفره‌های آب زیرزمینی است. به عبارت دیگر، در این مطالعه، پارامترهای کیفی و کمی آب زیرزمینی دشت اراک، استان مرکزی ایران، شامل شوری، هدایت الکتریکی (EC)، تراز آب زیرزمینی (GWL) و کل جامدات محلول (TDS) توسط چهار مدل نوین هوش مصنوعی شبیه‌سازی شدند. مدل‌های هوش مصنوعی ماشین آموزش نیرومند (ELM)، ویولت-ماشین آموزش نیرومند (WELM)، ماشین آموزش نیرومند ترتیبی آنالین (OSELM) و ویولت-ماشین آموزش نیرومند ترتیبی آنالین (OSELM) توسعه داده شد. برای توسعه مدل‌های ترکیبی هوش مصنوعی از تبدیل ویولت استفاده شد. سپس توسط تحلیل تابع خودهمبستگی، تابع خودهمبستگی نسبی و تاخیرهای موثر برای هر یک از مدل‌های ELM، WELM، OSELM و WOSELM چهار مدل مختلف تعریف گردید. در

### REFERENCES

- Azari, T. and Samani, N. (2018). Modeling the Neuman's well function by an artificial neural network for the determination of unconfined aquifer parameters. *Computational Geosciences*, 22(4), 1135-1148.
- Chelsea, Q. and Wan, Y. (2013). Time series modeling and prediction of salinity in the Caloosahatchee River Estuary. *Water Resources Research*, 49(9), 5804-5816.
- Dong, Y., Li, G. and Xu, H. (2012). An aerial recharge and discharge simulating method for MODFLOW. *Computers & geosciences*, 42, 203-205
- Harbaugh, A.W., Banta, E.R., Hill, M.C. and McDonald, M.G. (2000). MODFLOW-2000, The U. S. Geological Survey Modular Ground-Water Model-User Guide to Modularization Concepts and the Ground-Water Flow Process. Open-file Report. *U. S. Geological Survey*, (92), 134.

- Hendrickx, J.M.H. and Walker, G.R. (1997). Recharge from precipitation. In: Simmers, I., Balkema, A.A. (Eds.), Recharge of Phreatic Aquifers in (Semi-) Arid Areas. Rotterdam, *The Netherlands*, 19–111.
- Huang, G.-B., Zhu, Q.-Y. and Siew, C.-K. (2006). Extreme learning machine: theory and applications. *Neurocomputing* 70, 489–501.
- Kheradpisheh, Z., Talebi, A., Rafati, L., Ghaneian, M.T. and Ehrampoush, M.H. (2015). Groundwater quality assessment using artificial neural network: A case study of Bahabad plain, Yazd, Iran. *Desert*, 20(1), 65-71.
- Lerner, D. N., Issar, A. S., Simmers, I. (1990). Groundwater recharge: a guide to understanding and estimating natural recharge. *Hannover: Heise*, (8), 99-228.
- Liang, N.Y., Huang, G.B., Saratchandran, P. and Sundararajan, N. (2006). A fast and accurate online sequential learning algorithm for feedforward networks. *IEEE Trans. Neural Networks*, 22 (17), 1411–1423.
- McDonald M.G. and Harbaugh A.W. (1988). A modular three-dimensional finite-difference ground-water flow model. *Techniques of Water-Resources Investigations*, 06-A1, USGS.
- Nofal, E.R., Amer, M.A., El-Didy, S.M. and Fekry, A.M. (2015). Delineation and modeling of seawater intrusion into the Nile Delta Aquifer: a new perspective. *Water Science*, 29(2), 156-166.
- Priyanka, B.N. and Mahesha, A. (2015). Parametric studies on saltwater intrusion into coastal aquifers for anticipate sea level rise. *Aquatic Procedia*, 4, 103-108.
- Roshni, T., Jha, M.K., Deo, R.C., and Vandana, A. (2019). Development and evaluation of hybrid artificial neural network architectures for modeling spatio-temporal groundwater fluctuations in a complex aquifer system. *Water Resources Management*, 1-17. doi.org/10.1007/s11269-019-02253-4
- Salami Shahid, E. and Ehteshami, M. (2016). Application of artificial neural networks to estimating DO and salinity in San Joaquin River basin. *Desalination and Water Treatment*, 57(11), 4888-4897.
- Vaheddoost, B. and Aksoy, H. (2018). Interaction of groundwater with Lake Urmia in Iran. *Hydrological Processes*, 32(21), 3283-3295.
- Yang, X., Zhang, H. and Zhou, H. (2014). A hybrid methodology for salinity time series forecasting based on wavelet transform and NARX neural networks. *Arabian Journal for Science and Engineering*, 39(10), 6895-6905.