



## Technical Note

Prediction of Groundwater Level Using  
MODFLOW, Extreme Learning Machine and  
Wavelet-Extreme Learning Machine Models

M. Malekzadeh<sup>1</sup>, S. Kardar<sup>2\*</sup>, K. Saeb<sup>3</sup>,  
S. Shabanlou<sup>4</sup> and L. Taghavi<sup>5</sup>

## Abstract

In this study, the groundwater level of the Kabodarhang aquifer located in Hamadan Province, Iran, is simulated using MODFLOW, Extreme Learning Machine (ELM), and Wavelet-Extreme Learning Machine (WA-ELM) Models. The correlation coefficient and scatter index values for the MODFLOW model are calculated 0.917 and 0.0004, respectively. Then, by different input combination and using the stepwise selection, 10 different models are introduced for the ELM and WA-ELM models with different lags. By evaluating all activation functions of the ELM model, the sigmoid activation function predicts groundwater level values with more accuracy. Also, Daubechies2 is selected as the mother wavelet of the WA-ELM models. According to different numerical models results, the WA-ELM model is selected as the superior model in prediction of groundwater level. For the superior model, the correlation coefficient and Nash-Sutcliffe efficiency coefficient are calculated 0.959 and 0.915, respectively. These values for ELM model was respectively computed as 0.828 and 0.672.

**Keywords:** Groundwater level, MODFLOW, Extreme Learning Machine, Wavelet, Wavelet-Extreme Learning Machine.

Received: February 7, 2018

Accepted: July 27, 2018

## یادداشت فنی

پیش‌بینی تراز آب زیرزمینی با استفاده از  
مدل‌های MODFLOW، ماشین آموزش نیرومند و  
ویولت-ماشین آموزش نیرومند

مریم ملک‌زاده<sup>۱</sup>، سعید کاردار<sup>۲\*</sup>، کیوان صائب<sup>۳</sup>،  
سعید شعبانلو<sup>۴</sup> و لعبت تقوی<sup>۵</sup>

## چکیده

در این مطالعه تراز آب زیرزمینی منطقه کیودر آهنگ واقع در استان همدان، ایران با استفاده از مدل‌های MODFLOW، ماشین آموزش نیرومند و ویولت-ماشین آموزش نیرومند شبیه‌سازی می‌شود. مقادیر ضریب همبستگی و ضریب نش برای مدل MODFLOW به ترتیب مساوی ۰/۹۱۷ و ۰/۰۰۰۴ به دست آمد. با ترکیب گام‌های زمانی و با تأخیرهای متفاوت ده مدل مختلف برای مدل‌های ELM و WA-ELM تعریف می‌شوند. با ارزیابی کلیه نتایج فعال‌سازی مدل ELM، تابع فعال‌سازی Sigmoid مقادیر تراز آب زیرزمینی را با دقت بیشتری پیش‌بینی می‌کند. همچنین Daubechies2 به عنوان خانواده ویولت مدل‌های WA-ELM انتخاب می‌شود. بر اساس نتایج مدل‌های عددی مختلف، مدل WA-ELM به عنوان مدل برتر در پیش‌بینی تراز آب زیرزمینی انتخاب می‌شود. برای مدل برتر مقادیر ضریب همبستگی و ضریب نش به ترتیب برابر ۰/۹۵۹ و ۰/۹۱۵ محاسبه شده است. این در حالی است که مقادیر مذکور برای مدل ELM به ترتیب برابر با ۰/۸۲۸ و ۰/۶۷۲ به دست آمد.

**کلمات کلیدی:** تراز آب زیرزمینی، MODFLOW، ماشین آموزش نیرومند، ویولت، ویولت-ماشین آموزش نیرومند.

تاریخ دریافت مقاله: ۹۶/۱۱/۱۸

تاریخ پذیرش مقاله: ۹۷/۵/۵

1- Ph.D. Candidate, Department of Environmental Science and Engineering, Faculty of Natural Resources and Environment, Science and Research Branch, Islamic Azad University, Tehran, Iran

2- Assistant Professor, Department of Architecture, Science and Research branch, Islamic Azad University, Tehran, Iran. Email: Saied.Kardar@gmail.com

3- Associate Professor, Department of Environment, Tonekabon Branch, Islamic Azad University, Tonekabon, Iran.

4- Associate Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

5- Associate Professor, Department of Environmental Science and Engineering, Faculty of Natural Resources and Environment, Science and Research Branch, Islamic Azad University, Tehran, Iran.

\*- Corresponding Author

۱- دانشجوی دکتری، گروه علوم و مهندسی محیط زیست، دانشکده منابع طبیعی و محیط‌زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

۲- استادیار گروه معماری، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

۳- دانشیار گروه محیط زیست، واحد تنکابن، دانشگاه آزاد اسلامی، تنکابن، ایران.

۴- دانشیار گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران.

۵- دانشیار گروه علوم و مهندسی محیط زیست، دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

\*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۳۹۸ امکان‌پذیر است.

۱-۲- MODFLOW 2000

MODFLOW یک برنامه کامپیوتری است که به صورت عددی معادلات جریان آب زیرزمینی را برای محیط‌های متخلخل با بهره‌گیری از روش تفاضلات محدود به صورت زیر حل می‌کند (McDonald and Harbaugh, 1988):

$$\frac{\partial}{\partial x} \left( K_{xx} \frac{\partial h}{\partial x} \right) + \frac{\partial}{\partial y} \left( K_{yy} \frac{\partial h}{\partial y} \right) + \frac{\partial}{\partial z} \left( K_{zz} \frac{\partial h}{\partial z} \right) - W = S_s \frac{\partial h}{\partial t} \quad (1)$$

که در این معادله  $K_{xx}$ ،  $K_{yy}$  و  $K_{zz}$  به ترتیب عبارتند از مقادیر هدایت هیدرولیکی در راستای محورهای مختصات  $X$ ،  $Y$  و  $Z$  معرف شار حجمی در واحد حجم،  $S_s$  ذخیره ویژه محیط متخلخل و  $t$  نشان دهنده زمان می‌باشد. دوره‌های تنش هیدرولوژیکی به تناسب دوره زمانی مدل‌سازی ۱۰ سال انتخاب گردیده است. به بیان دیگر، به دلیل آماده‌سازی مدل آبخوان دشت کبودآهنگ به منظور مطالعات کیفی آبی بر آن، در هر سال ۱۲ دوره تنش در راستای انطباق گام‌های زمانی کمی و کیفی انتخاب گردید که در مجموع ۱۰ سال ۱۲۰ گام زمانی برای حل‌گر تعریف گردیده است. لازم به ذکر است که مدل در شرایط ناپایدار اجرا شد و حد اطمینان حداقل ۹۵ درصد به عنوان شرط پذیرش تعیین گردید. چاه بابا نظر در واسنجی‌ها دارای کمترین مقدار خطا بوده و در موقعیت مکانی خاصی قرار دارد به صورتی که تمامی شرایط مرزی در دسترس است. بنابراین و به عنوان بهترین نقطه قابل اتکا برای تجزیه و تحلیل نتایج انتخاب شد.

۲-۲- محدوده مورد مطالعه

دشت کبودآهنگ یکی از محدوده‌های مطالعاتی حوضه رودخانه قره‌چای است که با وسعت ۳۴۷۰ کیلومتر مربع در شمال استان همدان واقع شده که از شمال با دشت زنجان و قزوین، از جنوب با دشت بهار و قهاوند، از شرق با دشت رزن و از غرب با محدوده مطالعاتی گل‌تپه-زرین آباد در ارتباط می‌باشد. متوسط بارندگی دشت کبود آهنگ براساس آمار درازمدت (۳۶ ساله) ایستگاه پایگاه نوژه ۳۳۲/۷ میلی‌متر بوده و متوسط بارندگی در دشت کبودآهنگ ۲۸۱/۵ میلی‌متر می‌باشد. در شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه و چاه بابانظر نشان داده شده است.

۲-۳- ماشین آموزش نیرومند

ماشین آموزش نیرومند (ELM) یک نوع شبکه عصبی پیشخور تک‌لایه است که ابتدا توسط Huang et al. (2004) ارائه شد.

تخمین تراز آب زیرزمینی یکی از مهمترین موضوعات مدیریت منابع آب محسوب می‌شود. به طور کلی روش‌های عددی مختلفی برای پیش‌بینی تراز سفره‌های آب زیرزمینی وجود دارد. مدل‌های عددی یک بعدی یا دو بعدی و روش‌های هوش مصنوعی به صورت گسترده‌ای برای شبیه‌سازی تراز آب زیرزمینی در بازه‌های زمانی مختلف مورد استفاده قرار گرفته‌اند. به عنوان مثال، به علت آنکه طراحی و درک مدل‌های تفاضل محدود، آسان‌تر و دارای پیچیدگی‌های ریاضی کمتری هستند، (Nikmanesh and Rakhshandehro 2009) توانایی شبکه‌های مختلف عصبی مصنوعی در پیش‌بینی تراز آب زیرزمینی در آبخوان محدوده سعادت شهر فارس را مورد ارزیابی قرار دادند و نتیجه گرفتند شبکه‌های عصبی مصنوعی پیشرو با الگوریتم لونیگ-مارکواریت بهترین نتایج را ارائه می‌دهد. (Ramezani and Zonemat 2015) نوسانات سطح آب زیرزمینی دشت شهرکرد را با روش‌های ماشین بردار پشتیبان، تحلیل تفکیک خطی و درجه دوم شبیه‌سازی نمودند. نتایج نشان داد که ماشین بردار پشتیبان با داشتن کمترین میانگین خطای نسبی در دوره‌های ۱ و ۳ ساله و دقت قابل قبول در دوره‌های ۵ و ۱۰ ساله دارای برتری بر سایر روش‌ها بوده است. (Barzegar et al. 2017) به منظور ارزیابی عملکرد روش  $WA-GMDH^1$  و مدل‌های  $WA-ELM^2$  و ترکیب کردن مدل‌های مبتنی بر طول موج برای پیش‌بینی تراز آب زیرزمینی، دست به شبیه‌سازی آبخوان دشت مراغه-بناب زدند. آنها بیان نمودند که ویولت دقت مدل‌های هوش مصنوعی را افزایش داد. (Chen et al. 2017) در مطالعه‌ای روش  $BMARS^3$  را در یک چهارچوب شبیه‌سازی-بهبوده‌سازی ادغام کردند تا یک مدل سه بعدی MODFLOW را که به منظور شبیه‌سازی جریان آب زیرزمینی در یک ناحیه خشک ابرفتی در شمال غربی کشور عمان توسعه یافته بود را واسنجی نماید. لذا مطالعات مختلفی در ارتباط با پیش‌بینی تراز آب زیرزمینی انجام شده است. مرور مطالعات گذشته نشان می‌دهد که بررسی تراز آب زیرزمینی با استفاده از نرم‌افزار MODFLOW و مدل ویولت-ماشین آموزش نیرومند نیازمند بررسی بیشتر بوده و مقایسه نتایج مدل‌های مورد نظر حاوی نکات جدیدی برای محققین است. از طرف دیگر، این مدل‌ها دارای توانایی قابل قبولی در پیش‌بینی مسائل هیدرولوژیکی دارند. بنابراین در مطالعه حاضر، تراز آب زیرزمینی با استفاده از مدل MODFLOW، ماشین آموزش نیرومند و ویولت-ماشین آموزش نیرومند شبیه‌سازی می‌گردند و با مقادیر مشاهداتی مقایسه می‌شوند. در انتها مدل برتر برای تخمین تراز آب زیرزمینی ارائه می‌شود.

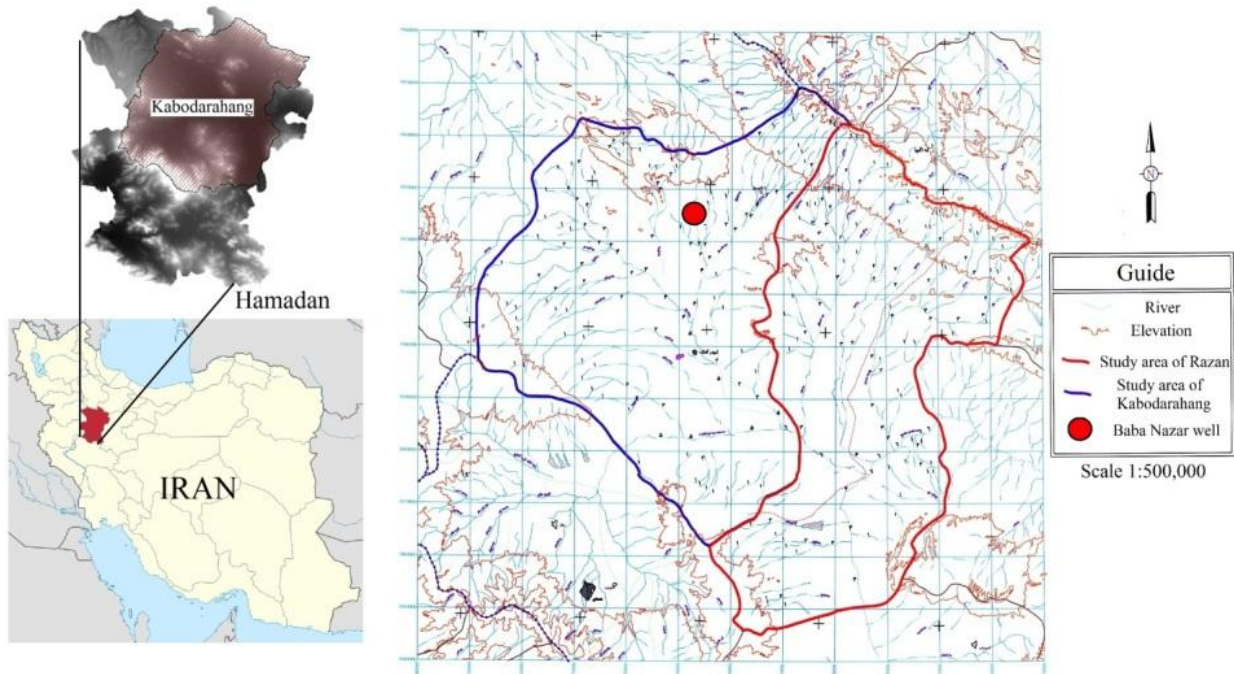


Fig. 1- Geographical location of the study area and Baba Nazar well

شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه و چاه بابانظر

می‌گیرند. در ELM، وزن‌ها و بایاس‌ها بین نرون‌های لایه ورودی و مخفی به صورت تصادفی تعیین می‌شوند (Huang et al., 2004).

#### ۲-۴- ویولت

ویولت تبدیلی است که به منظور تجزیه فرکانس‌های یک سری زمانی مورد استفاده قرار می‌گیرد. تبدیل ویولت همانند تبدیل فوریه، سری زمانی را به صورت ترکیب خطی از چند تابع اصلی (base)، در نظر می‌گیرد. یکی از مشخصات اصلی تبدیل ویولت این است که این تبدیل توانایی بدست آوردن اطلاعات در زمان، تناوب و موقعیت را به طور همزمان دارد (Misiti et al., 1996). در این مطالعه، تبدیل ویولت با مقادیر مشاهداتی از چاه بابا نظر در بازه زمانی مورد نظر به صورت سری زمانی رفتار می‌کند. انتخاب ترکیب‌های ورودی بر اساس تأخیرهای مختلف انجام می‌شوند. به طور کلی برای تعیین گام‌های زمانی مؤثر از تابع خود همبستگی<sup>۵</sup> و تابع خود همبستگی نسبی<sup>۶</sup> استفاده می‌شود. به طور کلی، ترکیب‌های ورودی انتخاب شده با استفاده از انتخاب گام به گام<sup>۷</sup> که به صورت تأخیرهای مختلف در قالب ۱۰ مدل مختلف به شکل زیر ارائه می‌شود انجام شده است:

$$\text{Model 1: } \text{GWL}(t) = f(\text{GWL}(t-1)) \quad (۴)$$

$$\text{Model 2: } \text{GWL}(t) = f(\text{GWL}(t-1), \text{GWL}(t-2))$$

$$\text{Model 3: } \text{GWL}(t) = f(\text{GWL}(t-1), \text{GWL}(t-2), \text{GWL}(t-3))$$

$$\text{Model 4: } \text{GWL}(t) = f(\text{GWL}(t-1), \text{GWL}(t-2), \text{GWL}(t-5))$$

$$\text{Model 5: } \text{GWL}(t) = f(\text{GWL}(t-1), \text{GWL}(t-3), \text{GWL}(t-9))$$

به طور کلی ELM وزن‌های ورودی را به صورت تصادفی تعیین می‌کند و وزن‌های خروجی را به صورت تحلیلی محاسبه می‌نماید. تنها تفاوت ELM با شبکه عصبی پیشخور تک لایه<sup>۴</sup> (SLFFNN)، عدم استفاده از بایاس برای نرون خروجی است. به عبارت دیگر، نرون‌های لایه ورودی با همه نرون‌های لایه مخفی در ارتباط هستند. توصیف ریاضی شبکه عصبی پیشخور تک لایه با تعداد n نود مخفی، به صورت زیر بیان می‌شود:

$$f_n(x) = \sum_{i=1}^n \beta_i G(a_i, b_i, x) \quad (۲)$$

که در اینجا  $\beta_i$  وزن بین نود مخفی  $a_m$  و نود خروجی،  $a_i \in R^n$  و  $(a_i$  و  $b_i)$  فاکتورهای آموزش گره‌های مخفی و  $G(a_i, b_i, x)$  خروجی گره  $a_m$  برای ورودی  $x$  است. تابع فعال‌سازی  $G(x)$  که دارای انواع مختلفی می‌باشد، برای گره مخفی افزاینده  $G(a_i, b_i, x)$  را می‌توان به شکل زیر بازنویسی کرد:

$$G(a_i, b_i, x) = g(a_i \cdot x + b_i) \quad (۳)$$

از توابع فعال‌سازی جهت محاسبه خروجی پاسخ نرون‌ها استفاده می‌شود. توابع فعال‌سازی غیرخطی ELM شامل تابع پل‌های (Hardlim)، سیگموئید (Sig)، سینوسی (Sin)، بایاس مثلثی (Tribas) و بایاس شعاعی (Radbas) هستند که در این مطالعه مورد بررسی قرار

- Model 6:  $GWL(t) = f(GWL(t-1), GWL(t-3), GWL(t-10))$   
 Model 7:  $GWL(t) = f(GWL(t-1), GWL(t-3), GWL(t-6))$   
 Model 8:  $GWL(t) = f(GWL(t-1), GWL(t-3), GWL(t-12))$   
 Model 9:  $GWL(t) = f(GWL(t-1), GWL(t-3), GWL(t-6), GWL(t-12))$   
 Model 10:  $GWL(t) = f(GWL(t-1), GWL(t-2), GWL(t-3), GWL(t-6), GWL(t-12))$

مدل MODFLOW و مدل‌های هوش مصنوعی برتر با هم مقایسه می‌شوند.

### ۳-۱- انتخاب تابع فعال‌سازی

در ابتدا برای مدل ELM به بررسی توابع فعال‌سازی پرداخته می‌شود. همانگونه که بیان شد، مدل ELM دارای پنج تابع فعال‌سازی با عنوان‌های Sigmoid، Hardlimit، Triangle basis و Radial basis است. به عنوان مثال مقادیر R، RMSE و NSC برای تابع فعال‌سازی Sigmoid به ترتیب برابر ۰/۷۵۱، ۰/۹۵۴ و ۰/۳۳۳ محاسبه شده است.

### ۳-۲- خانواده ویولت

تبدیل ویولت دارای پنج خانواده مختلف است. این خانواده‌ها شامل haar، db، dmey، sym و coif هستند. خانواده haar یک جزء دارد و خانواده db ده جزء (db1، db2، ...، db10) دارد. این در حالی است که خانواده‌های dmey، sym و coif به ترتیب یک، هفت (sym1، sym2، ...، sym7) و پنج (coif1، coif2، ...، coif7) جزء دارند. با تجزیه و تحلیل خانواده‌های مختلف نشان داده شد که خانواده ویولت تحت عنوان db2 مقادیر تراز آب زیرزمینی را با دقت بیشتری شبیه‌سازی می‌کند. برای این جزء از خانواده db مقادیر R و RMSE به ترتیب برابر ۰/۸۲۷ و ۰/۸۲۸ پیش‌بینی شده‌اند. با توجه به مطالب عنوان شده، در ادامه شبیه‌سازی از db2 به عنوان جزء بهینه‌سازی شده خانواده‌های مختلف ویولت استفاده می‌شود.

### ۳-۳- مدل‌های برتر

در بین کلیه مدل‌های ELM، مدل 2 ELM مقادیر تراز آب زیرزمینی را با دقت بیشتری در مقایسه با سایر مدل‌های ELM شبیه‌سازی می‌کند. به عنوان مثال، مقدار R برای 2 ELM مساوی ۰/۸۲۸ بدست آمده است. علاوه بر این، در میان کلیه مدل‌های WA-ELM، مدل 2 WA-ELM در مقایسه با سایر مدل‌های تعریف شده دارای دقت بیشتری است. به عنوان مثال، مقدار ضریب همبستگی برای 2 WA-ELM برابر ۰/۹۵۹ بدست آمده است. همچنین مقدار شاخص آماری RMSE برای 2 ELM و 2 WA-ELM به ترتیب مساوی با

### ۲-۵- معیارهای ارزیابی عملکرد مدل پیشنهادی

در این مطالعه برای بررسی دقت مدل‌های عددی مختلف از شاخص‌های آماری ضریب همبستگی  $R^2$ ، ریشه میانگین مربعات خطا<sup>۹</sup> (RMSE)، شاخص پراکندگی<sup>۱۰</sup> (SI) و ضریب نش<sup>۱۱</sup> (NSC) استفاده می‌شود:

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F}_i)(O_i - \bar{O}_i)}{\sqrt{\sum_{i=1}^n (F_i - \bar{F}_i)^2 \sum_{i=1}^n (O_i - \bar{O}_i)^2}} \quad (5)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (6)$$

$$SI = \frac{RMSE}{\bar{O}} \quad (7)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \quad (8)$$

در اینجا  $O_i$  مقادیر مشاهداتی،  $F_i$  مقادیر دبی پیش‌بینی شده به وسیله مدل‌های عددی،  $\bar{O}$  میانگین مقادیر مشاهداتی و  $n$  برابر تعداد مقادیر مشاهداتی است. نزدیک بودن شاخص آماری R به عدد یک نشان‌دهنده همبستگی بالای نتایج مدل عددی با مقادیر مشاهداتی است. همچنین نزدیک بودن مقادیر RMSE و SI به عدد صفر حاکی از عملکرد مناسب مدل عددی مورد نظر است. علاوه بر این، شاخص NSC بین مثبت یک و منفی بی‌نهایت متغیر بوده که نزدیک بودن این مقدار به عدد مثبت یک به معنای دقت بیشتر مدل عددی است.

### ۳- نتایج و تحلیل نتایج

در ادامه به بررسی توابع فعال‌سازی مختلف مدل ماشین آموزش نیرومند پرداخته می‌شود و بهینه‌ترین تابع فعال‌سازی برای مدل‌سازی انتخاب می‌گردد. سپس با تجزیه و تحلیل نتایج خانواده‌های مختلف تبدیل ویولت، به معرفی بهینه‌ترین جزء این خانواده‌ها که مقادیر مشاهداتی را با دقت بیشتری تخمین می‌زند پرداخته می‌شود. در ادامه، مدل‌های برتر برای هر یک از مدل‌های ماشین آموزش نیرومند و ویولت- ماشین آموزش نیرومند معرفی می‌شوند. در بخش بعدی، نتایج

نتایج مدل MODFLOW مقایسه می‌شود. مقایسه مدل‌های WA-ELM 2 و MODFLOW در پیش‌بینی تراز آب زیرزمینی در شکل ۳ قابل مشاهده است. بر اساس نتایج مدل‌سازی، مدل ELM 2 مقادیر تراز آب زیرزمینی را با دقت بیشتری در مقایسه با مدل MODFLOW شبیه‌سازی کرده است. به عنوان مثال مقدار R برای مدل‌های WA-ELM 2 و MODFLOW به ترتیب مساوی ۰/۹۵۹ و ۰/۹۱۷ پیش‌بینی شده است. علاوه بر این، مقدار NSC برای مدل‌های WA-ELM 2 و MODFLOW به ترتیب مساوی با ۰/۹۱۵ و ۰/۷۲۷ محاسبه شده است.

۰/۸۲۵ و ۰/۴۱۸ محاسبه شده است. در شکل ۲ نمودارهای پراکندگی و نتایج شبیه‌سازی شده برای مدل‌های برتر ELM 2 و WA-ELM 2 به تصویر کشیده شده است.

۴-۳- مقایسه مدل MODFLOW و مدل برتر هوش مصنوعی بر اساس نتایج مدل MODFLOW، مقادیر ضریب همبستگی و شاخص پراکندگی به ترتیب مساوی ۰/۹۱۷ و ۰/۰۰۴ پیش‌بینی شده است. همچنین نتایج مدل برتر هوش مصنوعی (WA-ELM 2) با

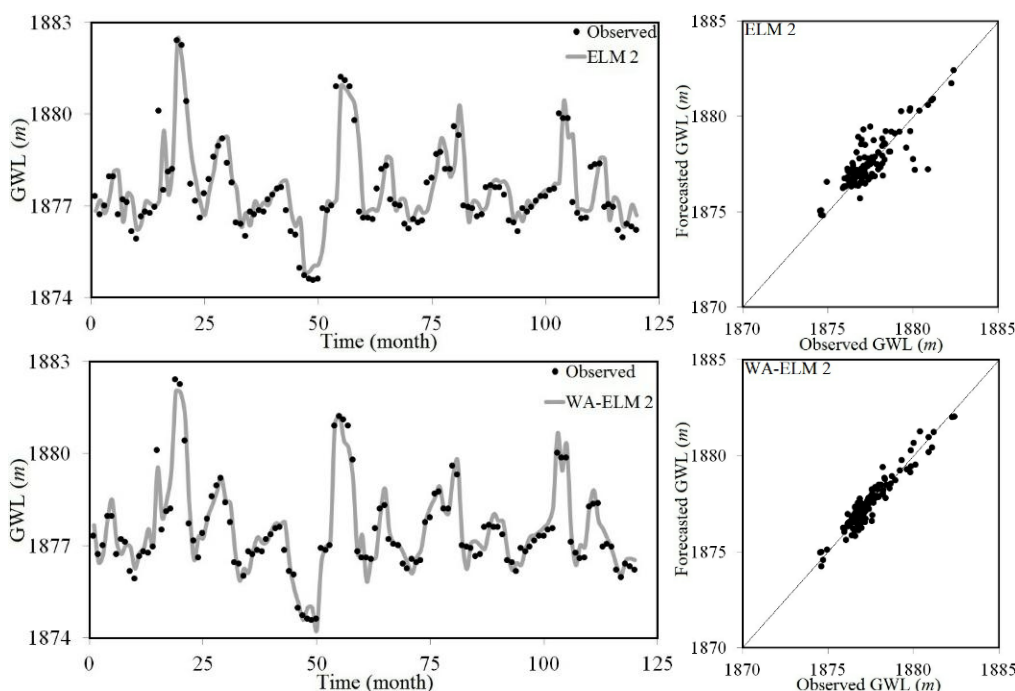


Fig. 2- Predicted groundwater level for superior models of ELM and WA-ELM

شکل ۲- تراز آب زیرزمینی پیش‌بینی شده برای مدل‌های برتر ELM و WA-ELM

#### ۴- خلاصه و جمع‌بندی

به طور کلی پیش‌بینی تراز آب زیرزمینی یکی از مهمترین موضوعات مدیریت منابع آب محسوب می‌شود. در مطالعه حاضر تراز آب زیرزمینی در منطقه کبودر آهنگ، همدان، ایران با استفاده از سه مدل عددی MODFLOW، ماشین آموزش نیرومند و ویولت ماشین آموزش نیرومند شبیه‌سازی شد. برای هر یک مدل‌های ELM و WA-ELM و با استفاده از گام‌های زمانی مختلف، ده مدل متمایز توسعه داده شد. ابتدا بهینه‌ترین تابع فعال‌سازی برای مدل‌های هوش مصنوعی به دست آمد. سپس با توجه به خانواده‌های مختلف ویولت، بهترین جزء برای این خانواده‌ها شناسایی شد. سپس به بررسی مدل‌های مختلف ELM




Fig. 3- Comparison of WA-ELM and MODFLOW model in simulating groundwater level

شکل ۳- مقایسه نتایج مدل WA-ELM و MODFLOW در شبیه‌سازی تراز آب زیرزمینی

Chen M, Izady A, Abdalla OA (2017) An efficient surrogate-based simulation-optimization method for calibrating a regional MODFLOW model. *Journal of Hydrology* 544:591-603

Huang GB, Zhu QY, Siew CK (2004) Extreme learning machine: A new learning scheme of feed forward neural networks. In *Neural Networks, Proceedings. International Joint Conference on*, IEEE 2:985-990

McDonald MG, Harbaugh AW (1988) A modular three-dimensional finite-difference ground-water flow model. *pen-File Report* 83-875, <https://doi.org/10.3133/ofr83875>

Misiti M, Misiti Y, Oppenheim G, Poggi JM (1996) *Wavelet toolbox for use with Matlab*. The Mathworks, Inc.:Natick, Massachusetts, USA

Nikmanesh MR, Rakhshandehroo GR (2009) Forecasting groundwater level in Saadat-Shahr Plain, Iran, using artificial neural networks. *Iran-Water Resources Research* 7:82-86

Ramezani Charmahineh A, Zounemat Kermani M (2015) Evaluation of support vector machine, and linear and quadratic discriminant analysis for groundwater level variations in Shahrekord Plain. *Iran-Water Resources Research* 11:97-105

و WA-ELM پرداخته شد. با تجزیه و تحلیل نتایج مدل‌های عددی نشان داده شد که مدل WA-ELM تراز آب زیرزمینی را با دقت بیشتری در مقایسه با مدل MODFLOW و ELM تخمین می‌زند.

#### پی‌نوشت‌ها

1. Wavelet-Group Method of Data Handling
2. Wavelet-Extreme Learning Machine
3. Bagging Mars
4. Single Hidden-Layer Feedforward Network
5. Autocorrelation Function (ACF)
6. Partial Autocorrelation Function (PACF)
7. Stepwise Selection
8. Correlation Coefficient
9. Root-Mean-Square Error
10. Scatter Index
11. Nash-Sutcliffe Model Efficiency Coefficient

#### ۵- مراجع

Barzegar R, Fijani E, Moghaddam AA, Tziritis E (2017) Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *Science of the Total Environment* 599:20-31