

Reservoir Water Level Prediction Using Supervised Intelligent Committee Machine Method, Case Study: Karaj Amirkabir Dam

M. Mohammad Rezapour Tabari^{1*} and
M.M. Malekpour Shahraki²

Abstract

The proper prediction of water level variation in dam reservoirs is considered as one of the important issues for design and operation of dams and water supply management. In this study, based on five soft models such as support vector regression (SVR), Adaptive Neuro-Fuzzy Inference System (ANFIS), artificial neural network (ANN), radial basis function neural network (RBFNN), and generalized regression neural network (GRNN) and the combined use of their results as input to one of these five models, a new structure called supervised intelligent committee machine (SICM) was proposed to predict the monthly reservoir water level of Karaj Amirkabir dam. The data used in this paper are water level, precipitation, evaporation, and inflow to and outflow from the dam. The evaluation of these models was done by nine error indexes and also the best model among all was selected using Vikor decision maker method. Evaluations showed that among the used soft models, the ANN was the best model with Nash-Sutcliffe efficiency (NS) and mean square error (MSE) equal to 0.89 and 23.37 square meters, respectively. The results of the proposed approach showed that the supervised (hybrid) neural network (SICM-ANN) has been able to provide high performance in predicting the monthly reservoir water level in Karaj dam with increasing the NS coefficient to 0.94 and decreasing the MSE index to 12.85 square meters (more than 45 percent decrease). Accordingly, hybrid use of soft models can effectively be applied for a significant reduction in the predicted error of water level compared to single models.

Keywords: Prediction, Reservoir Water Level, Karaj Amirkabir Dam, Supervised Intelligent Committee Machine, Soft Models.

Received: December 29, 2017

Accepted: June 21, 2018

پیش‌بینی تراز سطح آب مخزن سد با استفاده از روش ماشین هوشمند نظارت شده، مطالعه موردی: سد امیرکبیر کرج

محمود محمدرضاپور طبری^{۱*} و محمدمهدی ملک‌پور شهرکی^۲

چکیده

پیش‌بینی صحیح تغییرات تراز سطح آب مخازن به عنوان یکی از مسائل مهم جهت طراحی و بهره‌برداری از سدها و مدیریت تأمین نیازهای آبی مطرح می‌باشد. در این مطالعه بر پایه پنج مدل نرم رگرسیون بردار پشتیبان (SVR)، سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)، شبکه عصبی (ANN)، شبکه عصبی شعاعی (RBFNN) و شبکه عصبی مبتنی بر رگرسیون عمومی (GRNN) و استفاده تلفیقی از نتایج آن‌ها به عنوان ورودی به یکی از این پنج مدل، ساختاری تحت عنوان ماشین هوشمند نظارت شده (SICM) جهت برآورد تراز سطح آب ماهانه مخزن سد امیرکبیر کرج پیشنهاد گردید. داده‌های مورد استفاده شامل تراز سطح آب، بارندگی، تبخیر، حجم ورودی و خروجی از مخزن سد بوده و ارزیابی مدل‌های مذکور توسط ۹ شاخص خطا صورت گرفت و با استفاده از روش تصمیم‌گیرنده ویکور، بهترین مدل از میان مدل‌های مذکور انتخاب شد. پس از انجام بررسی‌های لازم در میان مدل‌های نرم مورد استفاده، مدل ANN با ضریب راندمان نش و میانگین مجذور خطای به ترتیب ۰/۸۹ و ۲۳/۳۷ متر مربع به عنوان بهترین مدل شناخته شد. نتایج بدست آمده از رویکرد پیشنهادی نشان می‌دهد که مدل نظارت شده (هیبریدی) شبکه عصبی (SICM-ANN) با افزایش ضریب راندمان نش به ۰/۹۴ و کاهش میانگین مجذور خطا به ۱۲/۸۵ متر مربع (بیش از ۴۵ درصد کاهش) توانسته عملکرد بالایی را در پیش‌بینی صحیح میزان تراز سطح آب ماهانه مخزن سد کرج ارائه نماید. بر این اساس استفاده هیبریدی از مدل‌های نرم می‌تواند در کاهش چشمگیر خطای پیش‌بینی تراز سطح آب نسبت به مدل‌های منفرد به طور مؤثری بکار گرفته شود.

کلمات کلیدی: پیش‌بینی، تراز سطح آب مخزن، سد امیرکبیر کرج، ماشین هوشمند نظارت شده، مدل‌های نرم.

تاریخ دریافت مقاله: ۹۶/۱۰/۸

تاریخ پذیرش مقاله: ۹۷/۳/۳۱

1- Associate Professor, Department of Engineering, Shahrekord University, Shahrekord, Iran. Email: mrtabari@sku.ac.ir

2- M.Sc. Graduate of Civil Engineering, Hydraulic Structures, Shahrekord University, Shahrekord, Iran.

*- Corresponding Author

۱- دانشیار گروه مهندسی عمران، دانشکده فنی، دانشگاه شهرکرد.

۲- دانش‌آموخته کارشناسی ارشد مهندسی منابع آب و سازه‌های هیدرولیکی، دانشکده فنی، دانشگاه شهرکرد.

*- نویسنده مسئول

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

بردار پشتیبان (SVR) از پتانسیل بالایی نسبت به مدل‌های استنتاج عصبی- فازی تطبیقی، PSO-ANN^{۱۱}، MLP^{۱۲} و RBFNN در پیش‌بینی تراز سطح آب دریاچه Beysehir برخوردار می‌باشد (Buyukyildiz et al., 2014). تعیین مناسب‌ترین ورودی با استفاده از آزمون گاما جهت پیش‌بینی ماهانه تراز سطح آب مخزن سد Khanpur در پاکستان بر پایه مدل‌های ANN و مدل رگرسیون محلی توسط (Ali Shamim et al., 2016) مورد مطالعه قرار گرفت. نتایج مطالعه نشان داد که استفاده از آزمون گاما منجر به بهبود قابل توجه مقادیر پیش‌بینی شده تراز به دلیل انتخاب ورودی‌های متناسب می‌شود (Ali Shamim et al., 2016). Das et al. (2016) از مدل غیرخطی احتمالاتی (شبکه بیزین هیبریدی) برای تخمین تراز سطح آب مخزن Mayurakshi استفاده کرده‌اند. نتایج بیانگر دقت بالای رویکرد پیشنهادی در مقایسه با مدل‌های متداولی همچون ANN، شبکه بیزین استاندارد و ARIMA^{۱۳} می‌باشد. Soleymani et al. (2016) اقدام به توسعه مدل RBF-FFA جهت پیش‌بینی تراز سطح آب رودخانه نمودند. در این مطالعه با استفاده از الگوریتم کرم شبتاب اقدام به آموزش مدل نرم RBF گردید. نتایج بیانگر عملکرد بالای این مدل در پیش‌بینی تراز آب رودخانه است (Soleymani et al., 2016). با توجه به مزایای هر یک از مدل‌های نرم، محققین مختلفی همانند (Fijani et al., 2013)، (Tayfur et al., 2014)، (Ghorbani et al., 2015)، (Nadiri et al., 2017a) و (Gavili et al., 2018) جهت دستیابی همزمان به قابلیت‌های هر یک از این مدل‌ها اقدام به استفاده هیبریدی از مدل‌های مذکور و توسعه مدل ماشین هوشمند نظارت شده (SICM)^{۱۵} نمودند. بر اساس سوابق تحقیقاتی قبلی، رویکرد پیشنهادی که نتایج سایر مدل‌های نرم را به عنوان ورودی دریافت و اقدام به پیش‌بینی پارامتر مورد نظر با استفاده از مدل نرم مناسب می‌نماید تا کنون در زمینه پیش‌بینی تراز سطح آب مخزن سد مورد استفاده و ارزیابی قرار نگرفته است. لذا در این مطالعه جهت دستیابی به هدف تحقیق، که توسعه مدل پیش‌بینی کارا جهت بررسی صحیح رفتار مخزن سد می‌باشد، اقدام به استفاده از مزایای مدل‌های ANN، ANFIS، SVR، RBFNN و GRNN در جهت تدوین مدل SICM گردید. بر پایه اطلاعات بلندمدت ماهانه سد امیرکبیر کرج که مشتمل بر تراز سطح آب، ورودی به مخزن، خروجی از مخزن، بارش و تبخیر می‌باشد، مدل پیشنهادی مورد ارزیابی قرار گرفت. نتایج نشان‌دهنده قابلیت بالای رویکرد پیشنهادی در بهبود نتایج پیش‌بینی و افزایش دقت شبیه‌سازی تراز ماهانه سطح آب مخزن می‌باشد. بر این اساس ساختار توسعه داده شده این تحقیق را می‌توان جهت پیش‌بینی سایر پارامترهای هیدرولوژیکی و هیدروژئولوژیکی مورد استفاده و کاربرد قرار داد.

بحران آب و کمبود منابع آب شیرین در دهه‌های اخیر منجر به بروز مشکلات زیادی جهت مدیریت و برنامه‌ریزی منابع آب به خصوص در طی دوره‌های خشک شده است. در این راستا مخازن آب سطحی سدها، به عنوان یکی از زیرساخت‌های ضروری، نقش کلیدی جهت تأمین نیازهای آبی پایین‌دست ایفا می‌نمایند. با توجه به وابستگی ذخیره‌سازی مطلوب حجم آب در مخازن به پارامترهای هیدرولوژیکی و نمایش آن در قالب تراز سطح آب مخزن، توسعه مدل‌های پیش‌بینی جهت بررسی دقیق رفتار تراز آب از اهمیت بالایی برخوردار می‌باشد (Sammen et al., 2017; Hipni et al., 2013). برای این منظور استفاده از مدل‌های هوش مصنوعی (AI)^۱ در سالیان اخیر جهت پیش‌بینی پارامترهای هیدرولوژیکی توسعه قابل توجهی یافته است. این مدل‌ها نیازی به توصیف دقیق پارامترهای فیزیکی ندارند و به سادگی سیستم‌های مبتنی بر روابط بین ورودی‌ها و خروجی‌ها را مورد آموزش قرار می‌دهند (Barzegar et al., 2017; Das et al., 2016). این مدل‌ها که تحت عنوان مدل‌های نرم (SM)^۲ نیز نامگذاری می‌شوند دارای انواع مختلفی می‌باشند که شبکه‌های عصبی مصنوعی (ANN)^۳، سیستم استنتاج فازی (FIS)^۴، مدل استنتاج عصبی- فازی تطبیقی (ANFIS)^۵، مدل رگرسیون بردار پشتیبان (SVR)^۶، مدل درخت تصمیم (DT)^۷، مدل برنامه‌ریزی بیان ژن (GEP)^۸، شبکه عصبی مبتنی بر رگرسیون (GRNN)^۹، شبکه عصبی تابع پایه شعاعی (RBFNN)^{۱۰}، نمونه‌ای از این مدل‌ها به شمار می‌رود. لازم به ذکر است توسعه هیبرید مدل‌های نرم مورد اشاره نیز به عنوان راهکاری جهت بهبود نتایج پیش‌بینی پارامترهای هیدرولوژیکی توسط محققینی همانند (Mwale et al., 2014)، (Kisi et al., 2015) و (Eliza (2017) و (El-Diasty et al., 2018) پیشنهاد شده است. در این بخش با مروری بر مطالعات صورت گرفته در خصوص نحوه استفاده از مدل‌های نرم و هیبرید آن‌ها، کاربرد مدل‌های مذکور و اهمیت استفاده از آن‌ها در پیش‌بینی متغیرهای هیدرولوژیکی مورد بررسی قرار می‌گیرد. Kisi et al. (2012) با استفاده از مدل‌های ANN، ANFIS و GEP اقدام به پیش‌بینی تراز سطح آب دریاچه Iznik در غرب ترکیه نمودند. نتایج حاکی از عملکرد بالای مدل GEP نسبت به دو مدل مورد استفاده دارد (Kisi et al., 2012). بر پایه دو نوع تابع عضویت گوسی و زنگوله‌ای، Valizadeh and El-Shafie (2013) توسعه مدل استنتاج عصبی- فازی تطبیقی (ANFIS) جهت پیش‌بینی تراز سطح آب مخزن سد Klang Gates در مالزی نمودند. نتایج بیانگر دقت بالای مدل پیشنهادی در مقایسه با مدل‌های رایج موجود می‌باشد (Valizadeh and El-Shafie, 2013). بررسی‌های صورت گرفته توسط Buyukyildiz et al. (2014) نشان می‌دهد که مدل رگرسیون

۲- مواد و روش‌ها

۲-۱- محدوده مورد مطالعه

با توجه به اهمیت سدهای استراتژیک در تأمین نیازهای آبی مناطق حساس و لزوم توجه تحقیقاتی به آن‌ها، در این مطالعه رویکرد پیشنهادی بر روی سد بتنی دو قوسی امیرکبیر کرج اعمال گردید. این سد در استان البرز و در شمال شهر کرج و در ۲۵ کیلومتری جاده کرج به چالوس قرار دارد (شکل ۱). سد کرج اولین سد چندمنظوره کشور ایران و یکی از منابع تأمین آب شهر تهران می‌باشد. این سد وظیفه کنترل سیلاب‌های بهاره و جلوگیری از خسارت‌های ناشی از سیل را بر عهده دارد و به علاوه دریاچه این سد، تولید انرژی برقی جهت کمک به شبکه سراسری برق، تأمین بخشی از آب آشامیدنی شهر تهران، تأمین آب کشاورزی اراضی حومه کرج و شرایط پرورش ماهی را نیز به وجود آورده است و حتی موجب استفاده‌های ورزشی و تفریحی شده و یکی از بهترین مناطق دیدنی و گردشگری را در خود جای داده است (<https://fa.wikipedia.org>). جهت پیش‌بینی تراز سطح آب مخزن این سد، از اطلاعات ۳۲ ساله (۱۳۶۳-۹۵) ارائه شده در سایت شرکت مدیریت منابع آب ایران (<http://dams.wrm.ir>) استفاده شده است. داده‌های مورد استفاده به عنوان ورودی شامل تراز سطح آب (متر)، ورودی به مخزن (مترمکعب بر ثانیه)، خروجی از مخزن (مترمکعب بر ثانیه)، بارش (میلی‌متر) و تبخیر (میلی‌متر) هستند که از حالت روزانه به ماهانه تبدیل شده و تبدیل واحدهای مورد نظر (مطابق واحدهای فوق)، روی آنها اعمال گردید. با توجه به اینکه پارامترهای مورد استفاده دارای واحدهای مختلف می‌باشند، جهت عملکرد بهتر مدل‌های نرم مورد استفاده، پارامترها با استفاده از رابطه ۱ به مقادیر نرمال شده تبدیل شدند:

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

که در این رابطه X_n داده نرمال شده، X داده خام، X_{\max} بیشترین مقدار و X_{\min} کمترین مقدار می‌باشند.

۲-۲- مدل رگرسیون بردار پشتیبان (SVR)

روش SVR بر پایه اصل حداقل‌سازی خطای ساختاری استوار می‌باشد. در این روش بردار ورودی x با استفاده از تصویرسازی غیرخطی به فضایی با ابعاد بالاتر منتقل می‌شود. در این فضا رگرسیون خطی به بردار ورودی اعمال می‌شود. در صورتی که مجموعه داده (X_n, Y_n) که در آن X_n و Y_n به ترتیب بردار متغیرهای مستقل و وابسته می‌باشند و $n = 1, 2, \dots, N$ است که N ، تعداد کل جفت اطلاعات ورودی-خروجی در نظر گرفته شوند، در این صورت تابع رگرسیون خطی زیر را می‌توان نوشت (Vapnik, 1998):

$$f(x) = \sum_{n=1}^N w_n \phi_n(x) + b \quad (2)$$

در این رابطه $\{\phi_n(x)\}_{n=1}^N$ نشان‌دهنده خصوصیات ورودی و $\{w_n\}_{n=1}^N$ و b ضرایبی هستند در نتیجه حداقل نمودن معادله زیر (تابع ریسک تنظیم شده) تعیین می‌شوند:

$$P(f(x)) = \frac{C}{N} \sum_{n=1}^N E_\varepsilon(y_n, f(x_n)) + \frac{\|w\|^2}{2} \quad (3)$$

$$E_\varepsilon(y_n, f(x_n)) = \begin{cases} 0 & \text{if } |y - f(x_n)| \leq \varepsilon \\ |y - f(x_n)| - \varepsilon & \text{otherwise} \end{cases} \quad (4)$$

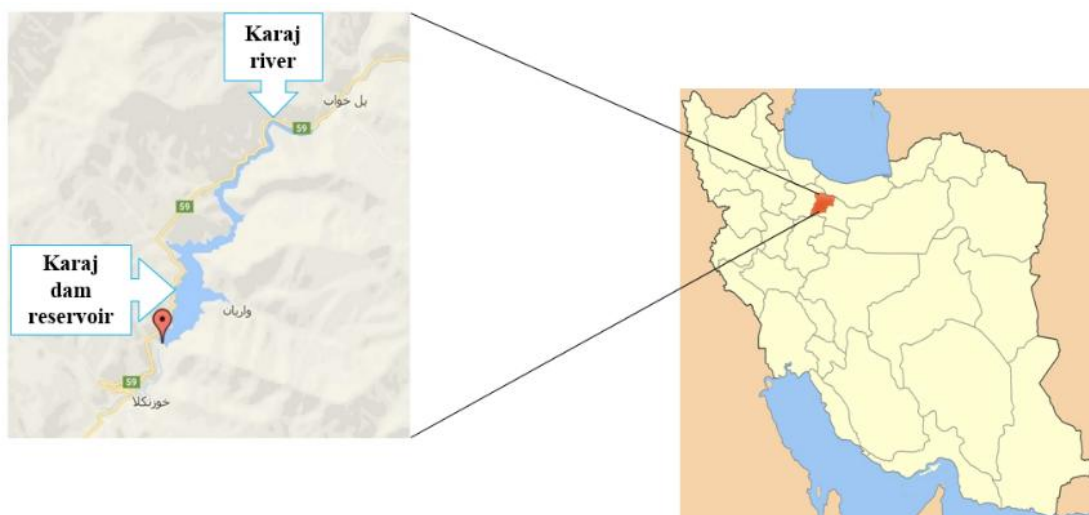


Fig. 1- Location of Karaj Amirkabir dam

شکل ۱- موقعیت سد امیرکبیر کرج

در رابطه ۴، $E_{\varepsilon}(y_n, f(x_n))$ تابع خسارت غیرحساس ε وینیک نام دارد و پارامتر C ثابت تنظیم کننده است که توسط کاربر تعریف شده و منحنی تبادل بین مدل هموارساز و ریسک تجربی را تعیین می نماید. ε ، اختلاف بین مقادیر مشاهده ای و محاسباتی است. $0.5\|w\|^2$ نیز جزء هموارساز است. با معرفی متغیرهای کمبود ξ و ξ^* در رابطه ۳، شکل کلی روابط بهینه سازی که لازم است در این روش مورد استفاده قرار گیرد به صورت زیر خواهد بود (Shirzad et al., 2014):

$$\text{Minimize} \left(\varphi(w, \xi, \xi^*) = C \sum_{n=1}^N (\xi + \xi^*) + \frac{\|w\|^2}{2} \right) \quad (5)$$

محدودیت های تابع هدف فوق عبارتند از:

$$\begin{cases} y_i - w \cdot \varphi(x) - b \leq \varepsilon + \xi_i, & \xi_i \geq 0 \\ w \cdot \varphi(x) - y_i + b \leq \varepsilon + \xi_i^*, & \xi_i^* \geq 0 \end{cases} \quad (6)$$

جهت حل مسأله بهینه سازی فوق لازم است بر اساس روش لاگرانژ، شکل لاگرانژی معادلات به صورت زیر تهیه شود (Elbisy, 2015):

$$\text{Maximize} \left(\begin{aligned} & H(\alpha, \alpha^*) = -0.5 \\ & \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) K(x_i, x_j) + \\ & \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^N y_i (\alpha_i + \alpha_i^*) \end{aligned} \right) \quad (7)$$

$$\sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0, \quad 0 \leq \alpha_i, \alpha_i^* \leq C \quad (8)$$

که α_n و α_n^* ضرایب لاگرانژ بوده و در آن $\alpha_i, \alpha_i^* \geq 0$ و $\alpha_i, \alpha_i^* = 0$ می باشد. بر اساس روابط ارائه شده می توان دریافت که تابع رگرسیون باید به صورت رابطه ۹ در نظر گرفته شود:

$$f(x) = \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (9)$$

همچنین، $K(x, x_i) = \varphi(x_i) \varphi(x)$ ، تابع کرنل است که بیانگر ضرب داخلی در فضای N بعدی است. در این تحقیق از ۶ تابع کرنل معمول در این روش یعنی: تابع کرنل پایه شعاعی (Rbf)، کرنل چندجمله ای (PoL)، تابع کرنل پایه شعاعی گوسی (Gau)، تابع کرنل پایه شعاعی نمایی (Exp) و خطی (Lin) و غیرخطی (MLP) استفاده گردید.

۲-۳- مدل استنتاج عصبی-فازی تطبیقی (ANFIS)

در طی دهه گذشته، تلاش های متعددی در زمینه کاربردهای منطق فازی و سیستم های شبکه عصبی در تحقیقات محققین مختلف مشاهده می گردد. سیستم استنتاج فازی عصبی تطبیقی توسط Jang در سال ۱۹۹۳ پیشنهاد شد. این ساختار، شبکه های تطبیقی چند لایه است که از عناصر اصلی و توابع سیستم های منطق فازی حاصل

شده اند. با بهره گیری از مفاهیم معماری شبکه و الگوریتم آموزش در مباحث شبکه عصبی در سیستم های فازی عصبی، موفقیت های زیادی در مدل سازی و کنترل سیستم های پیچیده بدست آمده است. این روش بر اساس مفاهیم روش های شبکه عصبی در سیستم های فازی توسعه یافته است. هدف اصلی در این روش آموزش شکل توابع عضویت برای سیستم فازی است که از خصوصیات تطابقی روش های شبکه عصبی حاصل می شود (Rezapour Tabari and Mazak Mari, 2015). جهت اطلاع از جزئیات این مدل نرم می توان به Valizadeh and El-Shafie (2013) مراجعه نمود.

۲-۴- مدل شبکه عصبی (ANN)

شبکه های عصبی مصنوعی ساختار ریاضی انعطاف پذیری است که برگرفته از سیستم نرون بیولوژیکی است. به طور کلی، معمول ترین ساختار ANN تحت عنوان شبکه های پرسپترون چندلایه است که مشتمل بر لایه های ورودی، مخفی و خروجی و توابع محرک می باشد. جهت آموزش شبکه، الگوریتم پس انتشار خطا (BPA) که توسط Rumelhart et al. (1986) ارائه شده است به نحوه مناسبی می تواند اقدام به آموزش شبکه در بسیاری از مسائل غیرخطی نماید. این روش در بسیاری از تحقیقات انجام شده در تعیین ارتباط غیرخطی بین پارامترهای ورودی و خروجی مورد استفاده قرار گرفته و توصیه شده است. شکل ریاضی الگوریتم MLPN به صورت زیر می باشد:

$$y_j = f \left(\sum_{i=1}^N W_{ji} X_i + b_j \right) \quad (10)$$

در این رابطه X_i ، مقدار گره i ام در لایه قبلی، y_j ، مقدار گره j ام در لایه فعلی، b_j بردار اریب مرتبط با گره j ام در لایه فعلی، W_{ji} ارتباطات وزنی بین مقادیر گره ایی X_i و y_j و N تعداد گره ها (نرون ها) در لایه قبلی و f تابع محرک در لایه فعلی است. همانطور که در رابطه ۱۰ نشان داده شده است، مقادیر اولیه بردارهای وزن و بردار اریب می تواند نقش تعیین کننده ای در ایجاد ساختار مناسب جهت پیش بینی پارامتر خروجی را ایفا نماید. جهت جلوگیری از گرفتار شدن ساختار شبکه در مقادیر بهینه محلی، در این مطالعه ۵۰ مجموعه تصادفی از بردارهای وزن و اریب تولید و شبکه جهت تعیین بهترین وزن ها مورد آموزش قرار گرفت. جزئیات ریاضی این مدل نرم را می توان در (ASCE (2000) مشاهده نمود.

۲-۵- مدل شبکه عصبی شعاعی (RBFNN)

این مدل که اولین بار توسط Broomhead and Lowe (1988) ارائه گردید به عنوان یک مدل شبکه عصبی نظارت نشده است که دارای ساختار شبکه پیش خور بوده و مشتمل بر سه لایه ورودی، یک لایه

می‌گیرد. لایه سوم که به عنوان لایه جمع‌کننده مطرح می‌باشد دارای $N_0 + 1$ نرون است که N_0 تعداد نرون‌ها در لایه خروجی است. با توجه به اینکه این مدل دارای یک خروجی است لذا تعداد نرون در لایه جمع‌کننده برابر با دو (نرون‌های جمع‌کننده S و D) می‌باشد. نرون‌های جمع‌کننده S و D به ترتیب مجموع خروجی‌های وزن‌دار و بدون وزن لایه الگو را در قالب روابط زیر مورد محاسبه قرار می‌دهند (Csabragi et al., 2017):

$$S = \sum_{j=1}^k y_j f(D_j) \quad (14)$$

$$D = \sum_{j=1}^k f(D_j) \quad (15)$$

بر اساس روابط فوق، لایه چهارم (لایه خروجی) صرفاً با تقسیم نرون جمع S بر نرون جمع D مورد شبیه‌سازی قرار می‌گیرد (Csabragi et al., 2017).

$$y = \frac{S}{D} \quad (16)$$

۲-۷- روش ماشین هوشمند نظارت شده (SICM)

با توجه به ضعفی که در هر یک از مدل‌های شبیه‌سازی نرم وجود دارد، محققین مختلفی سعی در بهبود نتایج شبیه‌سازی با استفاده از روش‌هایی همچون وزن‌دهی ساده و یا وزن‌دهی بر مبنای الگوریتم‌های بهینه‌سازی بر روی نتایج سایر مدل‌های شبیه‌سازی نرم نمودند. این روش که تحت عنوان روش ماشین هوشمند نظارت شده (SICM) نام گرفته است توسط محققین مختلفی مورد استفاده قرار گرفته است که از جمله این تحقیقات می‌توان به مطالعات (Chen and Lin (2006) و همچنین Labani et al. (2010) اشاره نمود. با توجه به اینکه این تحقیقات نیز تا حدودی منجر به بهبود نتایج شبیه‌سازی گردید؛ اما همچنان مقدار خطای ارائه شده توسط این روش‌ها تا حد قابل توجه بالا می‌باشد که در این راستا و در جهت کاهش میزان خطای شبیه‌سازی، (Tayfur et al. (2014) با استفاده از شبکه عصبی مصنوعی اقدام به ترکیب نتایج سایر مدل‌های شبیه‌سازی نمودند. این روش مشتمل بر تعدادی مدل شبیه‌سازی نرم که قابلیت تخمین پارامتر مورد نظر را دارا می‌باشند، است و طی دو مرحله ساخته می‌شود. در مرحله اول لازم است با استفاده از مدل‌های شبیه‌سازی نرم و با توجه به مجموعه ورودی-خروجی در نظر گرفته شده، مقدار پارامتر مورد نظر (که در این مطالعه تراز سطح آب مخزن است) مورد شبیه‌سازی قرار گیرد. سپس خروجی هر یک از این مدل‌ها به عنوان پارامترهای ورودی در روش SICM در نظر گرفته می‌شود. در این روش از پنج مدل به عنوان ساختار ترکیب‌کننده سایر مدل‌ها استفاده شده که منجر به جواب مناسب گردید. مطابق شکل ۲، در

مخفی و یک لایه خروجی است. مدل RBFNN جهت مدل‌سازی غیرخطی داده‌ها از عملکرد خوبی برخوردار بوده و برخلاف مدل MLPNN، در یک مرحله اقدام به آموزش ساختار خود می‌نماید. در این مدل آموزش میان لایه ورودی و مخفی با تعریف وزن‌هایی صورت می‌گیرد بر اساس الگوریتم‌های خوشه‌بندی تولید شده‌اند. بر این اساس فاصله اقلیدسی آمین بردار ورودی و بردار وزن مرتبط با گره j ام لایه مخفی در قالب پارامتر D_j و به صورت رابطه زیر تعریف می‌شود (Csabragi et al., 2017):

$$D_j = \sqrt{\sum_{i=1}^N (w_{ij} - x_i)^2} \quad (11)$$

در این رابطه، N تعداد پارامترهای ورودی است. بر مبنای پارامتر D_j محاسبه شده لازم است مقدار پارامتر خروجی با استفاده از یک تابع محرک مناسب مورد شبیه‌سازی قرار گیرد. با توجه به توصیه مطالعات قبلی، مناسب‌ترین تابع محرک برای این مدل، تابع کرنل گوسی است که شکل تابع آن به صورت زیر است:

$$f(D_j) = e^{-\frac{D_j^2}{2\sigma^2}} \quad (12)$$

در این رابطه، σ به عنوان عامل پخش و یا عامل هموارساز^{۱۸} شناخته می‌شود. در واقع این پارامتر بر اساس آموزش شبکه تعیین می‌شود. در نهایت مطابق رابطه (۱۳)، خروجی مدل شبکه عصبی شعاعی با m گره در لایه مخفی قابل محاسبه می‌باشد:

$$Y = \sum_{j=1}^m w_j f(D_j) + b \quad (13)$$

که w_j وزن مرتبط با لایه مخفی و لایه خروجی می‌باشد و b یک مقدار ثابت است.

۲-۶- مدل شبکه عصبی مبتنی بر رگرسیون عمومی (GRNN)

این مدل برای اولین بار توسط Specht (1991) معرفی شد و در واقع این مدل نسخه اصلاح شده مدل RBFNN می‌باشد. این مدل به عنوان شبکه آموزشی نظارت شده بدون برگشت است که برای تقریب توابع نرم مورد استفاده قرار می‌گیرد. این شبکه نیز دارای فاکتور هموارساز است که مقدار بهینه آن در طی چندین اجرای متوالی با توجه به میانگین مربعات خطا بدست می‌آید. این مدل در واقع شبکه عصبی چهار لایه پیش‌خور می‌باشد که دارای ویژگی‌های زیر است: لایه اول (لایه ورودی) وظیفه ورود اطلاعات به شبکه را بر عهده دارد و به طور کامل به لایه دوم متصل است. در لایه دوم (لایه الگو)، هر یک از پارامترهای ورودی با استفاده از بردار وزن به نرون‌های این لایه متصل می‌شوند. آموزش بردارهای وزن بین لایه اول و دوم مشابه آموزشی است که در مدل RBFNN بین لایه‌های اول و مخفی صورت

توسعه یافته است. هدف اصلی این روش رتبه‌بندی گزینه‌ها با توجه به بیشترین نزدیکی به جواب ایده‌آل هر معیار می‌باشد. جهت شروع عملیات تصمیم‌گیری با روش ویکور مراحل زیر مورد توجه قرار می‌گیرد (Opricovic and Tzeng, 2004):

- تشکیل ماتریس تصمیم (f_{ij} , $i = 1, 2, 3, \dots, n$, $j = 1, 2, 3, \dots, m$): این ماتریس، ماتریس امتیازدهی گزینه‌ها بر اساس معیارها است. در این مطالعه گزینه‌ها، پنج مدل نرم مورد استفاده در مدل غیرهیبریدی و پنج مدل هیبریدی توسعه یافته بوده و معیارها همان شاخص‌های خطا در نظر گرفته شده برای هر مدل می‌باشند. مقادیر n و m به ترتیب بیانگر تعداد کل معیارها و گزینه‌ها می‌باشد.

- تعیین وزن هر یک از معیارها: با استفاده از روش آنتروپی شانون، وزن هر یک از معیارها (w_i) تعیین می‌شود (Hanting et al., 2013).

- تعیین نقاط ایده‌آل مثبت و منفی برای هر معیار در میان تمامی گزینه‌ها است که به ترتیب f_i^+ و f_i^- نامیده می‌شوند. این مقادیر به صورت زیر تعیین می‌شوند. در این مطالعه معیارهای R، EIOA، JOA، EFF و NS به عنوان معیارهای مثبت و معیارهای MSE، MAE و MAPE به عنوان معیارهای منفی در نظر گرفته شده‌اند.

$f_i^+ = \max_j(f_{ij})$ and $f_i^- = \min_j(f_{ij})$ (برای معیارهای مثبت: معیارهایی که مقدار بیشتر آن‌ها مطلوب‌تر است).
 $f_i^+ = \min_j(f_{ij})$ and $f_i^- = \max_j(f_{ij})$ (برای معیارهای منفی: معیارهایی که مقدار کمتر آن‌ها مطلوب‌تر است).

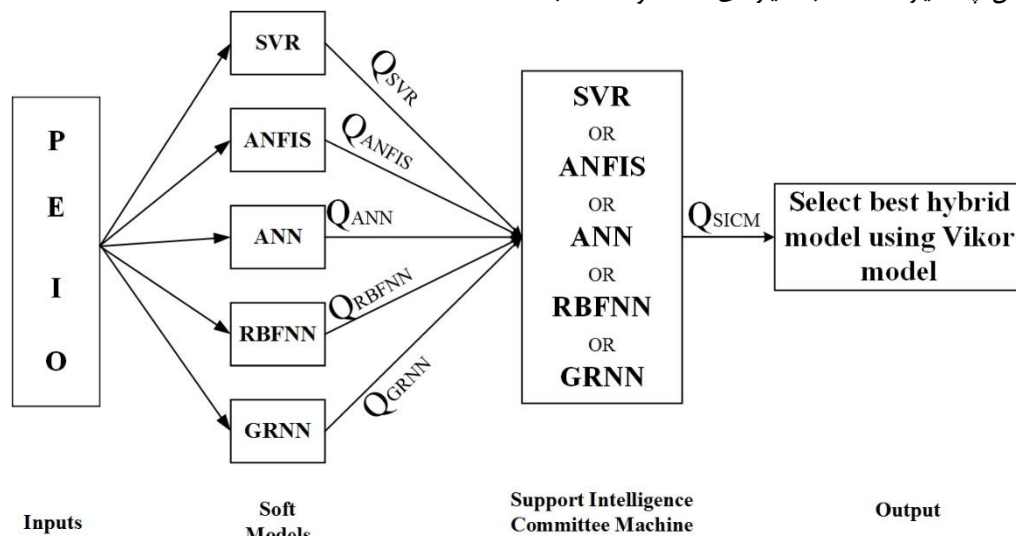


Fig. 2- The proposed SICM model structure for prediction of reservoir's monthly water level
 شکل ۲- ساختار مدل پیشنهادی جهت برآورد تراز ماهانه سطح آب مخزن

ساختار مدل SICM پیشنهادی از خروجی پنج مدل شبیه‌سازی نرم تحت عناوین ANN، ANFIS، RBFNN، GRNN و SVR استفاده و نتایج حاصل از این مدل‌ها توسط هر پنج مدل شبیه‌سازی تجمیع شده و در نهایت تراز ماهانه سطح آب مخزن با استفاده از روابط ۱۷ و ۱۸ مورد تخمین قرار می‌گیرد.

$$Q_i = SM_i(P, E, I, O) \quad (17)$$

$$Q_{SICM} = Q_i(SM_i) \quad (18)$$

در این روابط، P، E، I، O، به ترتیب پارامترهای ورودی مرتبط با بارش، تبخیر، جریان ورودی و جریان خروجی از مخزن می‌باشند. همچنین SM_i نوع مدل نرم مورد استفاده است که در این مطالعه از پنج مدل ANN، RBFNN، GRNN، ANFIS و SVR به دلیل قابلیت شبیه‌سازی پارامتر تراز سطح آب از آن‌ها استفاده شده است. بر مبنای خروجی هر یک از این مدل‌های نرم (Q_i) و ترکیب آن‌ها با استفاده از پنج مدل شبیه‌سازی، خروجی نهایی (Q_{SICM}) که تخمین بهتری از تراز سطح آب را ارائه می‌دهد، بدست می‌آید.

۲-۸- نحوه انتخاب مدل برتر SICM

ارزیابی و انتخاب یک روش از میان روش‌های گوناگون همواره از دغدغه‌های تصمیم‌گیرندگان در رشته‌های مختلف بوده است. برای مقایسه نتایج بدست آمده و انتخاب بهترین مدل، روش‌های تصمیم‌گیری مختلفی وجود دارد. در این مطالعه از روش تصمیم‌گیری چندمعیاره ویکور (VMCDM)^{۱۹}، که یکی از پرکاربردترین ابزارها در تصمیم‌گیری و انتخاب گزینه برتر است، استفاده گردید. این روش جهت حل مسائل چندمعیاره گسسته با معیارهای متضاد و نامتناسب

• محاسبه میزان سودمندی (S_j) و تأسف (R_j) هر گزینه: مطابق روابط ۱۹ و ۲۰ مقدار سودمندی بیانگر فاصله نسبی گزینه J از نقطه ایده‌آل و مقدار تأسف بیانگر حداکثر فاصله گزینه J از نقطه ایده‌آل می‌باشد.

$$S_j = \sum_{i=1}^n w_i \left(\frac{f_i^+ - f_{ij}}{f_i^+ - f_i^-} \right) \quad (19)$$

$$R_j = \max \left[w_i \left(\frac{f_i^+ - f_{ij}}{f_i^+ - f_i^-} \right) \right] \quad (20)$$

• محاسبه شاخص ویکور برای هر گزینه:

$$Q_j = v \left(\frac{S_j - S^*}{S^- - S^*} \right) + (1-v) \left(\frac{R_j - R^*}{R^- - R^*} \right), S^* \\ = \min_j (S_j), S^- \\ = \max_j (S_j), R^* \\ = \min_j (R_j), R^- \\ = \max_j (R_j) \quad (21)$$

در این رابطه v ، وزن مرتبط با حداکثر مطلوبیت گروهی است و در صورت توافق بالا بین گروه تصمیم‌گیرندگان، مقدار بیش از 0.5 ، توافق با اکثریت آراء، مقدار تقریباً برابر با 0.5 و در رد شدن توافق و یا توافق پایین، مقدار کمتر از 0.5 را به خود می‌گیرد (Opricovic and Tzeng, 2007).

• رتبه‌بندی گزینه‌ها با استفاده از مرتب نمودن صعودی مقادیر S_j ، R_j و Q_j . در واقع در این مرحله سه نوع رتبه برای هر یک از گزینه‌ها مشخص می‌شود.

• پیشنهاد بهترین رتبه از نظر Q_j (که کمترین مقدار Q_j را دارد) به عنوان راه‌حل سازشی برتر در صورتی که دو شرط زیر را ارضاء نماید:

شرط اول (ویژگی پذیرش^{۲۰}): اگر گزینه A^2 و A^1 در میان m گزینه رتبه اول و دوم را بر اساس رتبه‌بندی Q_j داشته باشند، رابطه زیر برقرار باشد:

$$Q(A^2) - Q(A^1) \geq \frac{1}{m-1} \quad (22)$$

شرط دوم (ثبات پذیرش در تصمیم‌گیری^{۲۱}): گزینه A^1 باید در رتبه‌بندی پارامترهای S_j و R_j نیز به عنوان رتبه برتر شناخته شود.

در صورتی که یکی از شروط اول و دوم برقرار نباشند، در این صورت یک مجموعه جواب سازشی به صورت زیر پیشنهاد می‌گردد:

(الف) در صورتی که تنها شرط دوم برقرار نباشد، گزینه‌های A^1 و A^2 به عنوان گزینه‌های برتر شناخته می‌شوند.

(ب) در صورت عدم برقرار شرط اول، گزینه‌های A^1 ، A^2 ، ... و A^m که رابطه $A^m - A^1 < \frac{1}{m-1}$ برای آن‌ها صادق باشد به عنوان گزینه برتر در نظر گرفته می‌شوند.

۲-۹- شاخص‌های ارزیابی عملکرد مدل‌ها

جهت ارزیابی مدل‌های مورد استفاده در این مطالعه، تمامی داده‌ها به صورت تصادفی به سه دسته تقسیم شده‌اند. ۸۵ درصد داده‌ها جهت آموزش مدل‌های نرم، ۱۰ درصد از داده‌ها برای کالیبراسیون آزمون و ۵ درصد جهت آزمون ساختارهای آموزش داده شده بکار گرفته می‌شود. سپس با استفاده از شاخص‌های ضریب همبستگی (R)^{۲۲}، متوسط مربعات خطا (MSE)^{۲۳}، متوسط قدرمطلق خطا (MAE)^{۲۴}، متوسط قدرمطلق درصد خطاها (MAPE)^{۲۵}، شاخص توافق (IOA)^{۲۶}، شاخص کارایی سیستم (EFF)^{۲۷}، شاخص راندمان نش (NS)^{۲۸} استفاده گردید. جزئیات شاخص‌های خطای R ، MSE و MAE را می‌توان در مطالعه (Rezapor Tabari (2016) ملاحظه نمود. لازم به ذکر است در این مطالعه واحد شاخص‌های MAE و MSE به ترتیب متر و متر مربع بوده و سایر شاخص‌ها دارای واحد نبوده و بی‌بعد می‌باشند.

$$MAPE = 100 \times \frac{1}{n} \times \left(\sum_{i=1}^n \frac{|x_{mi} - x_{ci}|}{x_{mi}} \right) \quad (23)$$

$$IOA = 1 - \frac{\sum_{i=1}^n (x_{mi} - x_{ci})^2}{\sum_{i=1}^n (|x_{mi} - \bar{x}_m| + |x_{ci} - \bar{x}_m|)^2} \quad (24)$$

$$EFF = \frac{\sqrt{\sum_{i=1}^n (x_{ci} - \bar{x}_m)^2}}{\sqrt{\sum_{i=1}^n (x_{mi} - \bar{x}_m)^2}} \quad (25)$$

$$NS = 1 - \frac{\sum_{i=1}^n (x_{mi} - x_{ci})^2}{\sum_{i=1}^n (x_{mi} - \bar{x}_m)^2} \quad (26)$$

در معادلات فوق x_{mi} و x_{ci} به ترتیب مقدار اندازه‌گیری و پیش‌بینی شده، \bar{x}_m متوسط مقادیر اندازه‌گیری شده می‌باشد.

۳- ارائه نتایج

با توجه به ساختار مدل‌های نرم و هیبریدی توسعه داده شده در محیط نرم‌افزاری MATLAB2017b و اجرای آن، بهترین مدل‌ها با تنظیم پارامترهای هر یک از این مدل‌ها استخراج گردید. لازم به ذکر است جهت بررسی اثر تأخیر پارامترهای ورودی بر نتایج پیش‌بینی تراز سطح آب مخزن، تأخیر زمانی هر یک از پارامترهای ورودی بر مدل‌ها اعمال گردید. نتایج حاکی از کاهش عملکرد مدل‌های پیش‌بینی می‌باشد. بر این اساس در تمامی مدل‌ها، چهار پارامتر بدون تأخیر زمانی مشتمل بر ورودی به مخزن، خروجی از مخزن، بارش و تبخیر به عنوان ورودی مدل‌های نرم و تراز سطح آب مخزن در انتهای ماه به عنوان خروجی مورد توجه قرار گرفته است. با اجرای مدل SVR برای توابع کرنل مختلف (SVR-RBF، SVR-LIN، SVR-POL، SVR-GAU، SVR-MLP و SVR-EXP)، مدل SVR-GAU به دلیل داشتن

و ۳ ارائه گردید. جهت تلفیق معیارهای ارزیابی مورد استفاده و دستیابی به مدل برتر، مقادیر شاخص ویکور برای هر مدل بر پایه مقادیر جدول ۳ محاسبه گردید (جدول ۵). مطابق این جدول می‌توان دریافت که مدل ANN با دارا بودن کمترین میزان عدد ویکور در رتبه اول قرار گرفته و دارای عملکرد بالاتری در پیش‌بینی پارامتر تراز سطح آب مخزن سد می‌باشد. پس از آن مدل RBFNN با شاخص ویکور ۰/۱۴ در رتبه دوم از نظر معیارهای هشت گانه خطا جهت پیش‌بینی پارامتر خروجی ارزیابی شده است. از آن‌جا که تمامی این پنج مدل نرم توانسته‌اند تا حدودی موجبات افزایش دقت نتایج پیش‌بینی را فراهم نمایند لذا استفاده هیبریدی از توانایی سایر مدل‌های نرم می‌تواند در بهبود نتایج پیش‌بینی نقش بسزایی داشته باشد. لذا در این مطالعه بر مبنای رویکرد هیبریدی پیشنهادی، نتایج این پنج مدل نرم به عنوان ورودی به هر یک از این مدل‌ها در نظر گرفته شد. در واقع مدل‌های هیبریدی ارائه شده به نوعی قبلاً توسط ساختارهای نرم مورد نظارت قرار گرفته شده‌اند. با اجرای رویکردهای هیبریدی تدوین شده و محاسبه شاخص‌های خطا برای هر یک از آن‌ها، امکان مقایسه و انتخاب مدل برتر مطابق جداول ۲ و ۴ فراهم گردید. مطابق این جدول ملاحظه می‌شود که عملکرد مدل‌های منفرد ابتدایی بسیار افزایش یافته و منجر به کاهش چشمگیر معیارهای خطا شده است. به عنوان نمونه می‌توان به مدل SVR اشاره نمود که با استفاده از مدل SICM-SVR، میزان خطای MSE آن با کاهش ۱۱۱ درصدی روبرو شده است (شکل ۳). با توجه به نزدیک بودن مقادیر شاخص‌های هشت‌گانه خطا در مدل‌های هیبریدی، استفاده از روش ویکور می‌تواند در معرفی مدل هیبریدی برتر بسیار کارا باشد. بنابراین مقادیر شاخص ویکور برای پنج مدل هیبریدی پیشنهادی محاسبه گردید (جدول ۵). در این جدول نیز مطابق نتایج حاصله از مدل‌های منفرد، مدل SICM-ANN با کسب کمترین میزان این شاخص رکورددار در پیش‌بینی تراز سطح آب مخزن می‌باشد. لذا در میان مدل‌های نرم منفرد، مدل ANN و در بین مدل‌های نظارت‌شده (هیبریدی)، مدل SICM-ANN از عملکرد بالاتری در تخمین مقدار تراز سطح آب مخزن سد کرج برخوردار می‌باشند.

کمترین میزان خطا در مرحله آزمون و بر اساس شاخص‌های خطای تعریف شده به عنوان بهترین مدل پیشنهاد گردید. این مسأله برای تعیین بهترین پارامتر و مدل مرتبط با سایر مدل‌های نرم نیز مورد توجه قرار گرفته است. به عنوان نمونه، شاخص راندمان نش و شاخص MSE در این مدل به ترتیب برابر با ۰/۵۸ و ۱۱۷/۸ تعیین گردید که نسبت به سایر مدل‌ها به ترتیب دارای بیشترین مقدار شاخص NS و کمترین میزان خطای MSE می‌باشد. در این مدل، پارامترهای تنظیم‌کننده C و E به ترتیب ۲۰۰ و ۰/۰۱ در نظر گرفته شده‌اند. لازم به ذکر است بازه تغییرات پارامترهای C و E به ترتیب برابر با ۳۰۰-۵۰ و ۱-۰/۰۰۱ در نظر گرفته شد. در مدل ANFIS، روشی که برای شبیه‌سازی در نظر گرفته شده است از نوع استلزام سوگنو می‌باشد. جهت آموزش ساختار FIS در این مدل از دستور genfis2 استفاده شده که نیازمند مرکز خوشه‌بندی داده‌های ورودی و خروجی است. با انجام فرآیند سعی و خطا در جهت دستیابی به بهترین مدل ANFIS و با در نظر گرفتن بازه ۱-۰ برای پارامتر مرکز خوشه، اعمال مرکز خوشه برابر با ۱ منجر به کمترین میزان خطای MSE برابر با ۹۶/۵۳ متر مربع گردید. با توسعه ساختار مدل ANN با یک لایه مخفی و ۹ نرون در آن، بهترین مدل شبکه عصبی مصنوعی با شاخص راندمان نش برابر با ۰/۸۹ در مرحله آزمون حاصل گردید. لازم به ذکر است بازه تغییرات تعداد نرون‌های لایه مخفی برابر با ۱۵-۲ نرون در نظر گرفته شد. در مدل RBFNN نیز با استفاده از عامل هموارساز و تعداد نرون به ترتیب برابر ۳ و ۲۵، بهترین پیش‌بینی با شاخص خطای MSE برابر با ۳۷ متر مربع بدست آمد. بازه تغییرات دو پارامتر هموارساز و تعداد نرون به ترتیب برابر با ۴-۰ و ۵۰-۵ در نظر گرفته شد. همچنین در مدل GRNN جهت ارائه مدل مناسب برای پیش‌بینی تراز سطح آب مخزن سد کرج با استفاده از روش سعی و خطا، مقدار ۰/۰۵ برای عامل هموارساز تعیین گردید. بازه تغییرات این پارامتر برابر با ۴-۰ در نظر گرفته شد. بر اساس این پارامتر، مدل GRNN همبستگی ۷۳ درصدی بین مقادیر مشاهداتی و پیش‌بینی شده را نشان می‌دهد. جهت ارزیابی وضعیت عملکرد مدل‌های نرم توسعه داده شده، مقادیر ۸ شاخص خطا معرفی شده برای هر مدل محاسبه و در قالب جداول ۱

Table 1- Error index values for soft models evaluation (Training stage)

جدول ۱- مقادیر شاخص‌های خطا جهت ارزیابی مدل‌های نرم (مرحله آموزش)

Models	R (Dimensionless)	MSE (m ²)	IOA (Dimensionless)	MAE (m)	EFF (Dimensionless)	MAPE (Dimensionless)	NS (Dimensionless)
SVR	0.96	24.7	0.97	1.73	0.91	0.11	0.93
ANFIS	0.82	101.85	0.89	7.35	0.65	0.42	0.65
ANN	0.86	80.85	0.92	6.15	0.74	0.35	0.74
RBFNN	0.83	100.54	0.9	7.29	0.68	0.42	0.68
GRNN	0.9	62.74	0.94	4.74	0.67	0.27	0.8

Table 2- Error index values for supervised (hybrid) models evaluation (Training stage)

جدول ۲- مقادیر شاخص‌های خطا جهت ارزیابی مدل‌های هیبریدی (مرحله آموزش)

Models	R (Dimensionless)	MSE (m^2)	IOA (Dimensionless)	MAE (m)	EFF (Dimensionless)	MAPE (Dimensionless)	NS (Dimensionless)
SICM-SVR	0.97	14.78	0.98	1.3	0.93	0.07	0.95
SICM-ANFIS	0.9	59.38	0.94	4.81	0.81	0.28	0.81
SICM-ANN	0.89	63.05	0.94	5.08	0.77	0.29	0.8
SICM-RBFNN	0.89	62.75	0.94	5.12	0.8	0.29	0.8
SICM-GRNN	0.94	38.5	0.96	3.44	0.83	0.2	0.88

Table 3- Error index values for soft models evaluation (Testing stage)

جدول ۳- مقادیر شاخص‌های خطا جهت ارزیابی مدل‌های نرم (مرحله آزمون)

Models	R (Dimensionless)	MSE (m^2)	IOA (Dimensionless)	MAE (m)	EFF (Dimensionless)	MAPE (Dimensionless)	NS (Dimensionless)
SVR	0.77	117.80	0.84	7.79	0.53	0.46	0.58
ANFIS	0.84	96.53	0.91	7.62	0.71	0.44	0.70
ANN	0.94	23.37	0.97	3.66	0.93	0.21	0.89
RBFNN	0.91	37	0.95	4.91	0.95	0.28	0.82
GRNN	0.73	134.57	0.83	7.16	0.60	0.41	0.52

Table 4- Error index values for supervised (hybrid) models evaluation (Testing stage)

جدول ۴- مقادیر شاخص‌های خطا جهت ارزیابی مدل‌های هیبریدی (مرحله آزمون)

Models	R (Dimensionless)	MSE (m^2)	IOA (Dimensionless)	MAE (m)	EFF (Dimensionless)	MAPE (Dimensionless)	NS (Dimensionless)
SICM-SVR	0.90	55.78	0.95	4.41	0.87	0.25	0.81
SICM-ANFIS	0.94	29.48	0.97	3.62	0.87	0.21	0.89
SICM-ANN	0.97	12.85	0.98	2.58	0.94	0.15	0.94
SICM-RBFNN	0.96	17.17	0.98	2.61	0.81	0.15	0.92
SICM-GRNN	0.90	46.88	0.94	4.61	0.83	0.26	0.80

Table 5- Results of Vikor method for soft and supervised (hybrid) models

جدول ۵- نتایج روش ویکور برای مدل‌های نرم و نظارت شده (هیبریدی)

Models	VIKOR Parameter	SVR	ANFIS	ANN	RBFNN	GRNN
Unsupervised Model	S	0.88	0.716	0.004	0.163	0.95
	R	0.43	0.347	0.004	0.064	0.52
	Q	0.88	0.71	0	0.14	1
Supervised Model (hybrid)	S	0.98	0.53	0.01	0.25	0.87
	R	0.81	0.43	0.01	0.25	0.68
	Q	1	0.53	0	0.27	0.86




Fig. 3- Comparison of MSE error index of soft and supervised (hybrid) models
 شکل ۳- مقایسه شاخص خطای MSE مدل‌های نرم و مدل‌های نظارت شده (هیبریدی)

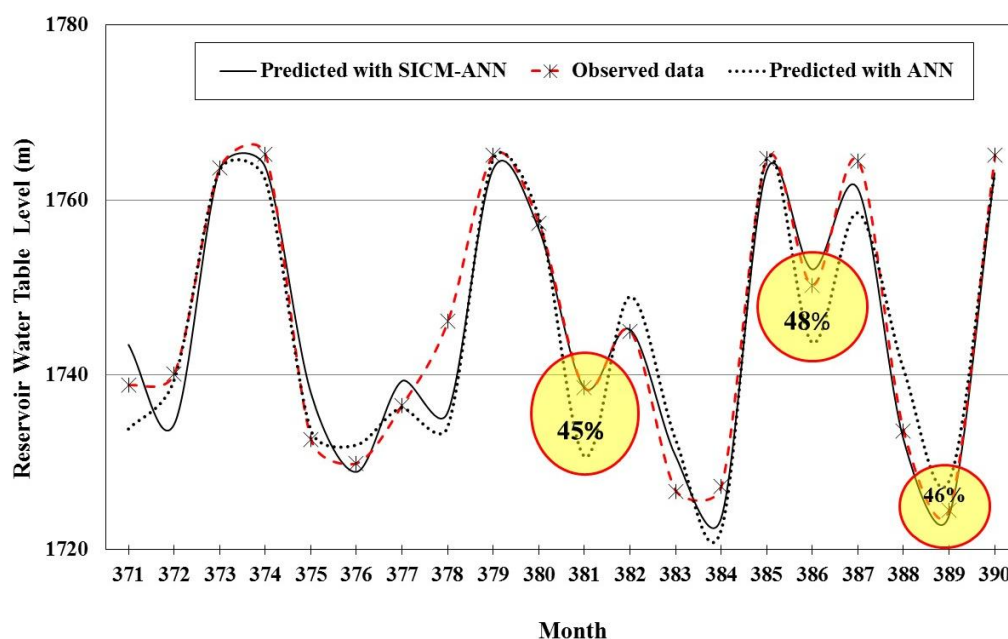


Fig. 4- Comparison of predicted water level time series using ANN and SICM-ANN models
 شکل ۴- مقایسه سری زمانی تراز سطح آب پیش‌بینی شده توسط مدل‌های ANN و SICM-ANN

دارای ۴۵، ۴۸ و ۴۶ درصد خطا نسبت به مقادیر مشاهداتی می‌باشند. این میزان خطا به طور نسبی برای سایر داده‌های دوره آزمون مشاهده می‌شود. از آنجا که استفاده از تراز سطح آب پیش‌بینی شده جهت تعیین حجم آب پشت مخزن سد و در نهایت تعیین‌کننده نحوه بهره‌برداری از آن می‌باشد، لذا بررسی میزان دقت حجم آب برآورد شده معادل تراز سطح آب مورد پیش‌بینی می‌تواند ابعاد دیگری از عملکرد و دقت رویکرد پیشنهادی را نشان دهد. برای این منظور بر پایه مقادیر تراز پیش‌بینی شده بر اساس دو مدل برتر ANN و

جهت بررسی میزان دقت مدل SICM-ANN در مقایسه با مدل ANN، سری زمانی تراز سطح آب مخزن در دوره آزمون مطابق شکل ۴ ترسیم شده است. مطابق این شکل ملاحظه می‌شود که در بسیاری از نقاط مدل ANN نتوانسته شرایط واقعی تراز سطح آب مخزن سد را مورد شبیه‌سازی قرار دهد.

به عنوان نمونه تراز پیش‌بینی شده توسط ANN برای مجموعه داده واقع در ردیف ۳۸۱، ۳۸۶ و ۳۸۸ از داده‌های دوره آزمون به ترتیب

SICM-ANN می‌توان دریافت که در صورت استفاده از مدل ANN، سالانه به میزان ۲۸ میلیون متر مکعب حجم آب پشت مخزن سد نسبت به مدل SICM-ANN بیشتر برآورد می‌شود. این مسأله در مقایسه با میزان ۳۲ میلیون متر مکعب آبی که به طور متوسط، ماهانه جهت تأمین نیازهای پایین‌دست سد رهاسازی می‌شود می‌تواند بسیار حائز اهمیت باشد. در واقع پیش‌بینی بیش از مقدار واقعی حجم مخزن منجر به افزایش ریسک در تأمین نیازهای آبی شده و راندمان بهره‌برداری از مخزن را کاهش می‌دهد. لذا توسعه رویکردهای هیبریدی علاوه بر کاهش قابل توجه میزان خطای پیش‌بینی، می‌تواند اثرات فاحشی بر روی مدیریت بهره‌برداری در شرایط واقعی از مخزن ایفا نموده و از اتخاذ تصمیمات ناصحیح توسط بهره‌برداران جلوگیری به عمل آورد.

۴- جمع‌بندی

نظر به اهمیت پیش‌بینی تراز سطح آب مخازن در مدیریت بهره‌برداری از آن‌ها، این مطالعه با توسعه رویکرد هیبریدی از مدل‌های نرم معروف اقدام به پیش‌بینی تراز سطح آب مخزن سد امیرکبیر کرج نموده است. برای این منظور با استفاده از آمار ۳۲ ساله پارامترهای بارندگی، تبخیر، تراز سطح آب، جریان ورودی و خروجی از مخزن ابتدا مدل‌های نرم منفرد همانند SVR، ANFIS، ANN، RBFNN و GRNN مورد آموزش و صحت‌سنجی قرار گرفت و پارامترهای این مدل تنظیم گردید. سپس بر مبنای هشت شاخص خطای ضریب همبستگی، متوسط مربعات خطا، متوسط قدرمطلق خطا، متوسط قدرمطلق درصد خطاها، شاخص توافق، شاخص توافق خطای بین مقادیر مشاهداتی و محاسباتی، شاخص کارایی سیستم و شاخص راندمان نش، که در مطالعات قبلی بیشترین کاربرد را در ارزیابی عملکرد مدل‌های شبیه‌ساز داشته‌اند، اقدام به مقایسه میزان دقت مدل‌های نرم گردید. از آنجا که ترکیب این شاخص در جهت تعیین مدل برتر نسبت به مقایسه جداگانه آن‌ها می‌تواند دید مناسب‌تری را در ارزیابی مدل‌ها ارائه نماید لذا با استفاده از روش تصمیم‌گیری ویکور و شاخص مرتبط با آن، مدل‌ها رتبه‌بندی شده و بر این اساس مدل ANN با توجه به دارا بودن کمترین میزان شاخص‌های خطا از بین پنج مدل نرم توسعه داده شده، به عنوان مدل منفرد برتر انتخاب گردید. با توجه به وجود خطا در مقادیر شبیه‌سازی شده توسط مدل ANN و در جهت بهبود نتایج پیش‌بینی تراز سطح آب، توسعه مدل هیبریدی در این مطالعه مورد توجه قرار گرفت. در این مدل، خروجی‌های تولید شده توسط پنج مدل نرم مورد اشاره به عنوان ورودی به هر یک از این پنج مدل در نظر گرفته شد. با اجرای این مدل‌های هیبریدی و محاسبه شاخص‌های خطا، مدل SICM-ANN بر مبنای شاخص ویکور به عنوان مدل برتر

انتخاب شد. بررسی دو مدل برتر ANN و SICM-ANN حاکی از بهبود قابل توجه نتایج پیش‌بینی تراز با کاهش ۴۵ درصدی خطای MSE و افزایش ضریب همبستگی از ۰/۹۴ به ۰/۹۷ می‌باشد. همچنین در صورت استفاده از مدل ANN، سالانه به میزان ۲۸ میلیون متر مکعب حجم آب پشت مخزن سد نسبت به مدل SICM-ANN بیشتر برآورد می‌شود که این مسأله در مقایسه با میزان ۳۲ میلیون متر مکعب آبی که به طور متوسط، ماهانه جهت تأمین نیازهای پایین‌دست سد رهاسازی می‌شود می‌تواند بسیار حائز اهمیت باشد. در واقع پیش‌بینی بیش از مقدار واقعی حجم مخزن منجر به افزایش ریسک در تأمین نیازهای آبی شده و راندمان بهره‌برداری از مخزن را کاهش می‌دهد. لذا توسعه رویکردهای هیبریدی علاوه بر کاهش قابل توجه میزان خطای پیش‌بینی، می‌تواند اثرات فاحشی بر روی مدیریت بهره‌برداری در شرایط واقعی از مخزن ایفا نموده و از اتخاذ تصمیمات ناصحیح توسط بهره‌برداران جلوگیری به عمل آورد.

پی‌نوشت‌ها

- 1- Artificial Intelligence
- 2- Soft Model
- 3- Artificial Neural Network
- 4- Fuzzy Inference System
- 5- Adaptive Neuro-Fuzzy Inference System
- 6- Support Vector Regression
- 7- Decision Trees
- 8- Gene Expression Programming
- 9- General Regression Neural Network
- 10- Radial Basis Function Neural Network
- 11- Artificial Neural Network Based on Particle Swarm Optimization
- 12- Multi- Layer Perceptron
- 13- Autoregressive Integrated Moving Average
- 14- Radial Basis Function-Firefly Algorithm
- 15- Supervised Intelligent Committee Machine
- 16- Insensitive Loss Function
- 17- Back-Propagation Algorithm
- 18- Smoothing Factor
- 19- Vikor Multi Criteria Decision Making
- 20- Acceptable Advantage
- 21- Acceptable Stability in Decision Making
- 22- Correlation Coefficient
- 23- Mean Square Error
- 24- Mean Absolute Error
- 25- Mean Absolute Percentage Error
- 26- Index of Agreement
- 27- Efficiency Coefficient
- 28- Nash-Sutcliffe Efficiency

۵- مراجع

Shamim MA, Hassan M, Ahmad S, Zeeshan M (2016) A comparison of artificial neural networks (ANN) and

- Ghorbani MA, Azani A, Mahmoudi Vanolya S (2015) Rainfall-runoff modeling using hybrid intelligent models. *Iran-Water Resources Research* 11(2):146-150 (In Persian)
- Hanting Z, Hao W, Yufei C (2013) Application of osculating value method based on entropy weight in the groundwater quality evaluation. *International Journal of Environmental Engineering Research* 2(2):45-49
- Hipni A, El-shafie A, Najah A, Abdul Karim O, Hussain A, Mukhlisin M (2013) Daily forecasting of dam water levels: Comparing a Support Vector Machine (SVM) model with Adaptive Neuro Fuzzy Inference System (ANFIS). *Water Resources Management* 27:3803-3823
- Kisi O, Shiri J, Karimi S, Shamsirband S, Motamedi S, Petkovic D, Hashim R (2015) A survey of water level fluctuation predicting in Urmia Lake using support vector machine with firefly algorithm. *Applied Mathematics and Computation* 270:731-743
- Kisi O, Shiri J, Nikoofar B (2012) Forecasting daily lake levels using artificial intelligence approaches. *Computers and Geosciences* 41:169-180
- Labani MM, Kadkhodaie-Ilkhchi A, Salahshoor K (2010) Estimation of NMR log parameters from conventional well log data using a committee machine with intelligent systems: A case study from the Iranian part of the south pars gas field, Persian Gulf Basin. *J Pet Science Engineering* 72:175-185
- Reazpor Tabari MM (2016) Prediction of river runoff using fuzzy theory and direct search optimization algorithm coupled model. *Arab J Science Engineering Springer* 41(10):4039-4051
- Rezapour Tabari MM, Mazak Mari M (2015) A simulation-optimization approach for reducing seepage rate in water conveyance canals. *Iran-Water Resources Research* 11(2):17-30 (In Persian)
- Mwale FD, Adeloye AJ, Rustum R (2014) Application of self-organising maps and multi-layer perceptron-artificial neural networks for stream flow and water level forecasting in data-poor catchments: The case of the lower shire floodplain, Malawi. *Hydrology Research* 45(6):838-854
- Nadiri A, Gharekhani M, Khatibi R, Sadeghfam S, Asghari Moghaddam A (2017a) Groundwater vulnerability indices conditioned by supervised intelligence committee machine (SICM). *Science of the Total Environment* 574:691-706
- Nadiri AA, Taherkhani Z, Sadeghi Aghdam F (2017b) Prediction of groundwater level of Bostan Abad using combining artificial intelligence models. *Iran-Water Resources Research* 13(3):43-55 (In Persian)
- local linear regression (LLR) techniques for predicting monthly reservoir levels. *KSCE Journal of Civil Engineering* 20(2):971-977
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000) Artificial neural networks in hydrology I: Preliminary concepts. *Journal of Hydrology Engineering* 5:115-123
- Barzegar R, Fijani E, Asghari Moghaddam A, Tziritis E (2017) Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *Science of the Total Environment* 599-600:20-31
- Broomhead D, Lowe D (1988) Multivariable functional interpolation and adaptive networks. *Complex System* 2:321-355
- Buyukyildiz M, Tezel G, Yilmaz V (2014) Estimation of the change in lake water level by artificial intelligence methods. *Water Resources Management* 28(13):4747-4763
- Chen CH, Lin ZS (2006) A committee machine with empirical formulas for permeability prediction. *Computer Geo-Science* 32:485-496
- Csabragi A, Molnar S, Tanos P, Kovacs J (2017) Application of artificial neural networks to the forecasting of dissolved oxygen content in the Hungarian section of the river Danube. *Ecological Engineering* 100:63-72
- Das M, Ghosh SK, Chowdary VM, Saikrishnaveni A, Sharma RK (2016) A probabilistic nonlinear model for forecasting daily water level in reservoir. *Water Resources Management* 30(9):3107-3122
- Elbisy MS (2015) Support vector machine and regression analysis to predict the field hydraulic conductivity of sandy soil. *KSCE Journal of Civil Engineering* 19(7):2307-2316
- El-Diasty M, Al-Harbi S, Pagiatakis S (2018) Hybrid harmonic analysis and wavelet network model for sea water level prediction. *Applied Ocean Research* 70:14-21
- Fijani E, Nadiri A, Moghaddam AA, Tsai FTC, Dixon B (2013) Optimization of DRASTIC method by supervised committee machine artificial intelligence to assess groundwater vulnerability for Maragheh-Bonab plain aquifer, Iran. *Journal of Hydrology* 503:89-100
- Gavili S, Javadi S, Banihabib ME, Sanikhani H (2018) Comparison of intelligent models to predict water level fluctuations of Zarival lake using groundwater level. *Iran-Water Resources Research* 14(3):268-277 (In Persian)

- Soleymani SA, Goudarzi S, Anisi MH, Hassan WH, Idris MYI, Shamshirband S, Mohamednoor N, Ahmedy I (2016) A novel method to water level prediction using RBF and FFA. *Water Resources Management* 30(9):3265-3283
- Specht DF (1991) A general regression neural network. *IEEE Trans. Neural Network* 2:568-576
- Tayfur G, Nadiri AA, Moghadam AA (2014) Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water Resources Management* 28(4):1173-1184
- Valizadeh N, El-Shafie A (2013) Forecasting the level of reservoirs using multiple input fuzzification in ANFIS. *Water Resources Management* 27(9):3319-3331
- Vapnik VN (1998) *Statistical Learning Theory*. John Wiley, New York
- Yadav B, Eliza Kh (2017) A hybrid wavelet-support vector machine model for prediction of lake water level fluctuations using hydro-meteorological data. *Measurement* 103:294-301
- Opricovic S, Tzeng GH (2004) The compromise solution by MCDM methods: A comparative analysis of VIKOR and TOPSIS. *European Journal of Operational Research* 156(2):445-455
- Opricovic S, Tzeng GH (2007) Extended VIKOR method in comparison with outranking methods. *European Journal of Operational Research* 178:514-529
- Rumelhart DE, McClelland JL and the PDP Research Group (1986) *Parallel distributed processing: Explorations in the microstructure of cognition*. MIT Press, Cambridge, Massachusetts, USA, 516p
- Sammen SS, Mohamed TA, Ghazali AH, El-Shafie A, Sidek LM (2017) Generalized regression neural network for prediction of peak outflow from dam breach. *Water Resources Management* 31(1):549-562
- Shirzad A, Tabesh M, Farmani R (2014) A comparison between performance of support vector regression and artificial neural network in prediction of pipe burst rate in water distribution networks. *KSCE Journal of Civil Engineering* 18(4):941-948