

Evaluation and Application of Ensemble AI-based Models for Estimating Piezometric Heads in Earth Fill Dams

E. Sharghi^{1*}, V. Nourani² and N. Behfar³

Abstract

Failure of earth fill dams is a great challenge in Civil Engineering, for which one of the main causes is uncontrolled seepage through the core and foundation of the dam. Thus seepage analysis is one of the most important complications in design, construction and operation of this type of dams. The first step for seepage analysis is inspecting the piezometric heads. In the following paper, Sattarkhan earth fill dam piezometric heads have been analyzed via Artificial Intelligence (AI) models and a classic black box model, based on two scenarios. Each scenario had different input combinations for modeling of various conditions. Later the ensemble models have been formed via outputs of the single black box models to improve modeling performance. Three methods of model ensemble were considered, including simple linear averaging model, weighted linear averaging model and non-linear neural ensemble model. Results showed that employing model ensemble and in particular non-linear ensemble by neural network, improved the modeling accuracy up to 10%. Moreover, comparing both scenarios, it is concluded that in case of a failure of a piezometer, employing scenario 2 can be an effective way.

Keywords: Estimating Piezometric Heads, Artificial Intelligence Models, Model Ensemble, Sattarkhan Earth Fill Dam.

Received: November 30, 2017

Accepted: June 7, 2018

ارزیابی و کاربرد مدل‌های ترکیبی هوش مصنوعی برای تخمین هد پیزومتریک سد خاکی

الناز شرقی^{۱*}، وحید نورانی^۲ و نازنین بهفر^۳

چکیده

شکست سدهای خاکی از چالش‌های بزرگ مهندسی عمران به شمار می‌رود که یکی از عمده‌ترین علل وقوع آن، تراوش کنترل نشده از هسته و پی سد می‌باشد. از این رو تحلیل تراوش، از مسائل بسیار مهم در طی مراحل طراحی، ساخت و بهره‌برداری از این نوع سدها است. در این راستا بررسی هد پیزومتریک یکی از اولین مراحل بررسی تراوش می‌باشد؛ در تحقیق حاضر هد پیزومتریک سد خاکی ستارخان با استفاده از مدل‌های جعبه سیاه هوش مصنوعی و جعبه سیاه کلاسیک بر اساس ۲ سناریو مورد بررسی قرار گرفته است. در هر سناریو ترکیب ورودی‌های مختلفی برای شرایط متفاوت در نظر گرفته شده است. در ادامه برای بهبود عملکرد مدل‌سازی، روش ترکیب مدل با استفاده از خروجی مدل‌های منفرد جعبه سیاه انجام گرفته است. روش ترکیب مدل با استفاده از ۳ روش میانگین‌گیری خطی ساده، میانگین‌گیری خطی وزندار و ترکیب غیر خطی با استفاده از شبکه عصبی مصنوعی انجام گرفته است. نتایج حاکی از آن است که به کارگیری مدل‌های ترکیبی و به ویژه مدل ترکیبی غیرخطی با شبکه عصبی مصنوعی باعث افزایش دقت مدل‌سازی تا ۱۰٪ شده است. علاوه بر این، با مقایسه نتایج دو سناریو، نتیجه‌گیری می‌شود که به کارگیری سناریو ۲ می‌تواند روشی مؤثر برای شرایطی همچون خرابی یا از کارافتادگی برخی از پیزومترها باشد.

کلمات کلیدی: تخمین هد پیزومتریک، مدل‌های هوش مصنوعی، ترکیب مدل، سد خاکی ستارخان.

تاریخ دریافت مقاله: ۹۶/۱۰/۹

تاریخ پذیرش مقاله: ۹۷/۳/۱۷

1- Assistant Professor, Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran. E-mail: sharghi@tabrizu.ac.ir

2- Professor, Department of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran.

3- M.Sc. Graduate in Hydraulic Structures Engineering, Department of Water Resources Engineering, Faculty of Civil Eng., University of Tabriz, Tabriz, Iran.

*- Corresponding Author

۱- استادیار گروه عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز.

۲- استاد گروه عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز.

۳- دانش‌آموخته کارشناسی ارشد مهندسی آب و سازه‌های هیدرولیکی، گروه عمران آب، دانشکده مهندسی عمران، دانشگاه تبریز.

*- نویسنده مسئول

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

محاسبات نرم^۱ از جمله هوش مصنوعی^۲ روش‌های محاسباتی جدیدی هستند که در دهه‌های اخیر برای بسیاری از مسائل هیدرولیک، هیدرولوژی و منابع آب به کار گرفته شده‌اند (Tayfure et al., 2005; Nourani, 2015). محاسبات نرم را می‌شود حاصل تلاش‌های جدید علمی دانست که مدل‌سازی، تحلیل و در نهایت کنترل سیستم‌های پیچیده را با سهولت و موفقیت زیادتری امکان‌پذیر می‌سازند (Nourani, 2015). محاسبات نرم با پذیرش اینکه نتایج حاصل می‌توانند تا حدی غیر دقیق باشند و با محور قرار دادن ذهن انسان و طبیعت سعی در پایین آوردن هزینه محاسبات دارند (Nourani, 2015). از جمله ابزار محاسبات نرم می‌توان به شبکه‌های عصبی مصنوعی (ANN)^۳، سیستم استنتاج فازی (ANFIS)^۴ و ماشین‌های بردار پشتیبان (SVM)^۵ اشاره کرد.

مروری بر تاریخچه کاربرد محاسبات نرم، بیان می‌کند که محاسبات نرم در تعدادی از مسائل تراوش سد خاکی به کار گرفته شده و نتایج مطلوبی حاصل شده است. از جمله: Tayfure et al. (2005) یک مدل عددی با استفاده از روش المان محدود (FEM)^۶ برای شبیه‌سازی جریان سد خاکی Jeziorsko واقع در لهستان به کار بردند. آن‌ها به علت کمبودها و محدودیت‌های مدل FEM، یک مدل ANN نیز برای پیش‌بینی تراوش تنها با استفاده از داده‌های تراز آب بالادست-پایین دست سد ارائه کردند و به این نتیجه رسیدند که مدل ANN به خوبی مدل FEM و حتی در برخی موارد بهتر از مدل FEM عمل می‌کند. (Nourani et al., 2012) برای بررسی هد پیزومتریک یک سد خاکی در ایران، مدل‌های ANN با استفاده از داده‌های تراز آب بالادست-پایین دست سد ایجاد کردند و نتایج به دست آمده را با نتایج مدل FEM مقایسه کردند و به این نتیجه رسیدند که مدل ANN می‌تواند جایگزین نسبتاً مناسبی برای مدل عددی FEM باشد. (Rankovic et al., 2014) رفتار یک سد بتنی را با استفاده از رگرسیون بردار پشتیبان (SVR)^۷ مدل‌سازی کردند که نتایج بیانگر این بود که مدل‌های محاسبات نرم نتایج دقیقی را ارائه می‌کند. (Novakovic et al., 2014) از یک مدل فازی-عصبی برای تخمین هد پیزومتریک سد Iron Gate 2 استفاده کردند که مقایسه مقادیر پیش‌بینی شده توسط مدل شناسایی بر اساس SVR با داده‌های تجربی خاکی از آن بود که مدل شناسایی SVR نتایج دقیقی ارائه می‌کند.

پیش‌بینی دقیق فرآیندهایی که دارای سیستم غیر خطی و پیچیده می‌باشند از طریق یک مدل منفرد غیر ممکن خواهد بود، از طرفی در شرایط مختلف و برای داده‌هایی با الگوهای متفاوت هر مدل قابلیت پوشش بخشی از پیچیدگی‌های موجود در مسأله را خواهد داشت، لذا

صنعت سدسازی یکی از مهمترین فعالیتهای زیربنایی و اساسی تمدن امروز است. نقش سدها در توسعه کشاورزی و صنعت، تأمین آب آشامیدنی، تولید انرژی هیدروالکتریک، کنترل سیلاب و دیگر مسائل جنبی قابل توجه است. با توجه به اینکه امروزه جوامع بشری با مشکل کم آبی مواجه هستند، نقش سدها در مدیریت صحیح منابع آب بیش از پیش مشخص می‌شود (Nourani et al., 2012). در این میان سدهای خاکی در بین انواع سدها به دلیل صرفه‌های اقتصادی، سهولت اجرا، در دسترس بودن مصالح مصرفی و عملکرد سازه‌ای از اهمیت بسزایی برخوردار هستند. با توجه به این که خرابی و شکست سد، نه تنها سرمایه مالی ساخت آن را از بین می‌برد، بلکه تلفات جانی نیز در بر دارد که قابل جبران نخواهد بود، لذا چندین دهه است که اطمینان از ایمنی این نوع سدها ذهن طراحان و محققین را به خود مشغول ساخته است (Vafaeian, 2015).

به طور کلی خرابی سدهای خاکی را می‌توان به سه گروه خرابی هیدرولیکی، خرابی حاصل از تراوش و خرابی سازه‌ای تقسیم‌بندی کرد، هر چند ممکن است بسیاری از خرابی‌ها در اثر چند علت همزمان به وقوع بپیوندند (Vafaeian, 2015).

بر اساس آمار ۵۸٪ از خرابی‌های سدهای خاکی، بر اثر تراوش در شالوده و بدنه این نوع سدها اتفاق افتاده است (Zhang et al., 2009). اگرچه وجود تراوش در تمام سدهای خاکی غیرقابل اجتناب است، اما در صورت مناسب بودن شرایط برای فرسوده شدن خاک، تراوش سبب شسته شدن خاک در آن ناحیه مستعد گردیده و چنانچه در ابتدای بروز فرسایش جلوگیری نگردد، به خرابی سد منجر می‌گردد.

تاکنون تراوش با استفاده از مدل‌های ریاضی و فیزیکی مختلفی بررسی و پیش‌بینی شده است (Tayfure et al., 2005). در برخی از این مدل‌ها از فرضیهایی برای ساده‌سازی معادلات استفاده شده که ممکن است به خطاهای بزرگی منجر شود (Nourani et al., 2012; Nourani, 2015). علاوه بر این تراوش آب به خصوصیات مصالح بستگی دارد که توزیع آن در هر پروژه تصادفی بوده و شرایط ساخت متفاوت از آماده‌سازی نمونه‌ها در آزمایشگاه است. از این رو با توجه به پیچیدگی و وجود عدم قطعیت‌های بارز در پدیده تراوش، به کارگیری مدل‌های جعبه سیاه، که با دریافت ورودی و خروجی مشاهداتی، فرایند مورد نظر را تخمین می‌زنند، می‌تواند در بهبود مدل‌سازی این پدیده مؤثر باشد.

۲- مواد و روش‌ها

۲-۱- سد مورد مطالعه

سد خاکی ستارخان، سدی مخزنی است که در استان آذربایجان شرقی بر روی رودخانه اهرچای احداث شده است. ارتفاع این سد از روی پی سنگی ۷۸ متر و از روی بستر آبرفتی ۵۹ متر می‌باشد. حجم مخزن در صورتی که سطح آب در تراز نرمال باشد، معادل ۱۳۱/۵ میلیون متر مکعب می‌باشد. در طول محور سد، ۴ مقطع ابزار بندی، ۲ مقطع در بخش میانی دره و در محل حداکثر مقطع و ۲ مقطع بر روی تکیه‌گاه‌ها و در ارتفاع میانگین سد در نظر گرفته شده است (Bandab Consulting Engineers, 2003). ارتفاع آب در پی‌زومترها از سال ۷۸ تا ۸۸ هر ماه یک بار و قرائت تراز آب دریاچه به صورت روزانه برای این سد، از سازمان آب منطقه‌ای استان آذربایجان شرقی دریافت شده است.

در این مقاله داده‌های پی‌زومترهای ۲۰۷، ۲۱۲، ۲۱۶ و ۲۱۷ از مقطع ۲ مورد استفاده قرار گرفته اند. شکل ۱، مقطع شماره ۲ سد را همراه با موقعیت پی‌زومترها نشان می‌دهد. مشخصه‌های آماری داده‌های پی‌زومترهای مذکور در جدول ۱ ذکر شده است.

۲-۲- روش تحقیق

در این تحقیق در ابتدا مدل‌های ANN، ANFIS، SVR و ARIMA بر اساس ۲ سناریو، که در ادامه توضیح داده شده، ایجاد و سپس با استفاده از نتایج مدل‌های منفرد مذکور مدل‌های ترکیبی برای بالا بردن عملکرد مدل‌سازی تشکیل شدند.




Fig. 1- Positions of the piezometers in cross section No. 2

شکل ۱- موقعیت پی‌زومترها در مقطع شماره ۲

تحقیقات منابع آب ایران، سال چهاردهم، شماره ۴، زمستان ۱۳۹۷
Volume 14, No. 4, Winter 2019 (IR-WRR)

در سالهای اخیر برای در نظر گرفتن عدم قطعیت‌ها در مدل‌ها و ارائه‌ی مدلی جامع که تا حد امکان تمامی پیچیدگی‌های موجود در مسأله را پوشش دهد، از روشهای ترکیب مدل که یک استراتژی برای پوشش عدم قطعیت و پیچیدگی‌های موجود در ساختار مدل و ناپایداری در شبیه‌سازی اطلاعات می‌باشد، استفاده شده است. از جمله مطالعاتی که در زمینه ترکیب مدل در علوم مختلف انجام گرفته می‌توان به مطالعه Shamseldin et al. (1997) اشاره کرد که ۳ روش مختلف ترکیب مدل را برای تخمین رواناب به کار بردند و نشان دادند که ترکیب خروجی مدل‌های مختلف تخمین بهتری از رواناب در مقایسه با مدل‌های منفرد اولیه به دست می‌دهد. (Zhang et al. (2003) از یک مدل ترکیبی حاصل از مدل شبکه عصبی و مدل کلاسیک خودهمبسته تفاضلی با میانگین متحرک آریمای^۸ برای پیش‌بینی سری‌های زمانی استفاده کرد که نتایج حاکی از آن بود که ترکیب مدل یک روش مؤثر برای افزایش دقت پیش‌بینی می‌باشد. (Nadiri et al. (2017) از روش ترکیب مدل‌های هوش مصنوعی با استفاده از یک شبکه عصبی مصنوعی به عنوان ترکیب کننده غیرخطی برای پیش‌بینی سطح آب زیرزمینی استفاده کردند، که نتایج حاصل نشانگر کاهش خطای مدل هوش مصنوعی ترکیبی نسبت به مدل‌های منفرد بود.

با وجود این که در زمینه تراوش سد خاکی کارهایی با استفاده از مدل‌های هوش مصنوعی انجام گرفته، اما ترکیب آن‌ها مورد بررسی قرار نگرفته است. لذا در این پژوهش ابتدا با استفاده از مدل‌های شبکه عصبی مصنوعی، استنتاج تطبیقی عصبی-فازی، ماشین بردار پشتیبان و مدل آریمای تراوش سد خاکی بر اساس دو سناریو مدل سازی شده و نتایج به دست آمده صحت‌سنجی می‌گردد. سپس مدل‌های بدست آمده با استفاده از ۳ روش متفاوت با یکدیگر ترکیب شده و کارایی مدل‌های ترکیبی نسبت به مدل‌های منفرد مورد بررسی قرار می‌گیرد.

Table 1- Statistics of observed heads in piezometers in section No. 2

| Piezometer | 207 | 212 | 216 | 217 |
|------------------------|----------|----------|----------|----------|
| Average (m) | 1431.237 | 1431.515 | 1434.799 | 1432.404 |
| Minimum (m) | 1424.830 | 1424.890 | 1429.630 | 1430 |
| Maximum (m) | 1439.570 | 1439.350 | 1442.730 | 1438.250 |
| Standard Deviation (m) | 3.424 | 3.390 | 3.536 | 2.249 |

۲-۳- شبکه‌های عصبی مصنوعی

در کاربردهای مهندسی شبکه‌های عصبی مصنوعی، شبکه‌های چندلایه پیشرو^۹ با الگوریتم یادگیری پس انتشار^{۱۰} بسیار رایج است (Nourani et al., 2011). ثابت شده است که مدل شبکه BP با سه لایه برای پیش‌بینی و شبیه‌سازی در هر گونه مسائل مهندسی رضایت بخش است (Nourani et al., 2011; Hornik, 1988).

مقدار خروجی یک شبکه سه لایه پیشرو با الگوریتم پس انتشار به صورت رابطه (۳) بیان می‌شود (Nourani et al., 2012):

$$\hat{y}_k = f_0 \left[\sum_{j=1}^{M_N} W_{kj} \cdot f_h \left(\sum_{i=1}^{N_N} W_{ji} x_i + W_{j0} \right) + W_{k0} \right] \quad (3)$$

که در آن W_{ji} وزن در لایه میانی متصل کننده نرون i ام در لایه ورودی و نرون j ام در لایه میانی، W_{j0} بایاس نرون j ام در لایه میانی، تابع محرک نرون میانی، W_{kj} وزن در لایه خروجی متصل کننده نرون j ام در لایه میانی و نرون k ام در لایه خروجی، W_{k0} بایاس نرون k ام در لایه خروجی، f_0 تابع محرک برای نرون خروجی، x_i متغیر ورودی i ام برای لایه ورودی، \hat{y}_k ، y به ترتیب متغیرهای خروجی محاسبه و مشاهده شده و N_N و M_N به ترتیب تعداد نرون در لایه ورودی و پنهان هستند. وزن‌ها در لایه‌های میانی و خروجی متفاوت هستند، و مقادیر آنها می‌تواند در طول فرآیند آموزش شبکه تغییر کند.

۲-۴- سیستم استنتاج تطبیقی عصبی-فازی

سیستم استنتاج تطبیقی عصبی-فازی نخستین بار در سال ۱۹۹۳ توسط جانگ ارائه شد (Jang, 1993). ساختار شبکه عصبی-فازی، از ترکیب دو ساختار شبکه‌های عصبی و سیستم‌های فازی تشکیل شده که در این ساختار، از مزایای شبکه‌های عصبی و همچنین از ویژگی توانایی مدل‌سازی استنتاج سیستم‌های فازی که باعث افزایش قدرت تصمیم‌گیری در شرایط عدم قطعیت می‌شود، استفاده شده است.

هر یک از سیستم‌های فازی شامل سه بخش اصلی، فازی‌سازی، پایگاه داده فازی و غیر فازی کردن می‌باشد. پایگاه داده شامل دو بخش

۲-۲-۱- سناریو ۱

در سناریو اول سعی شده است که ارتفاع پیزومتریک هر پیزومتر با استفاده از داده‌های خود پیزومتر و داده‌های تراز آب مخزن مدل شود. تخمین ارتفاع هر پیزومتر مطابق با رابطه (۱) انجام می‌گیرد:

$$P_t^i = f_n(P_{t-1}^i \cdots P_{t-n}^i \cdot h_t \cdot h_{t-1} \cdots h_{t-m}) \quad (1)$$

که در آن هد پیزومتر i در زمان t تابعی است از هد پیزومتر i در ماه‌های قبل تا تأخیر زمانی n و تراز آب بالادست در زمان t و ماه‌های قبل تا تأخیر زمانی m ، که تأخیرهای زمانی مؤثر با استفاده از پروسه سعی و خطا به دست آمدند. بدین ترتیب که مدل‌های مختلفی با تأخیرهای زمانی متفاوت ایجاد و ورودی‌های مدل بهینه با کمترین تعداد ورودی، به عنوان ورودی‌های مؤثر در نظر گرفته شدند. در نتیجه مشخص شد که ارتفاع پیزومتر i در زمان t با ارتفاع پیزومتر i در زمان $t-1$ و تراز آب بالا دست در زمان t وابستگی بیشتری دارد.

۲-۲-۲- سناریو ۲

در سناریو دوم به عنوان یک روش مدل‌سازی دیگر، از داده‌های ۲ پیزومتر دیگر نیز در فرآیند مدل‌سازی استفاده شده است. در این سناریو ارتفاع پیزومتر i تابعی است از زیر سری‌های تراز آب بالادست و ۲ پیزومتر دیگر، به عبارتی:

$$P_t^i = f_n(P_{t-1}^j \cdots P_{t-o}^j \cdot P_{t-1}^k \cdots P_{t-r}^k \cdot h_t \cdots h_{t-m}) \quad (2)$$

که در آن P_k^{t+r} و P_j^{t-o} به ترتیب، زیر سری‌های پیزومترهای j ام و k ام هستند تا تأخیر زمانی o و r . در این سناریو برای تعیین ۲ پیزومتر مؤثر در مدل‌سازی از ضریب همبستگی استفاده شد، و مانند سناریو ۱ برای تعیین تأخیرهای زمانی مؤثر از پروسه سعی و خطا استفاده شد. که در نهایت از داده‌های تراز آب بالادست در زمان t و داده‌های ۲ پیزومتر دیگر در زمان t به عنوان ورودی مدل‌های هوش مصنوعی استفاده شد. با توجه به این که در طول بهره‌برداری از سد امکان خرابی و از کار افتادن برخی از پیزومترها وجود دارد، به همین علت به کار گرفتن سناریو ۲ در این گونه موارد بسیار مفید خواهد بود.

$$y_t = \sum_{i=1}^p \alpha_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (6)$$

که در آن y_t از تفاضلی مرتبه d داده اصلی z_t از طریق عمل پیش پردازش حاصل می‌شود. در مدل $ARIMA(p,d,q)$ ، p ، d ، q به ترتیب عبارت‌اند از تعداد جملات خود همبسته، مرتبه تفاضلی و تعداد جملات میانگین متحرک.

۲-۷- ترکیب مدل

یکی از پیشرفتهای مهم در شبکه‌های عصبی مصنوعی طی دهه اخیر، ترکیب مدل است. ایده اصلی این روش چند مدله، استفاده از قابلیت منحصر به فرد هر یک از مدل‌ها، برای تخمین بهتر الگوی سری داده‌ها است. با ترکیب مدل‌های مختلف، عملکرد پیش‌بینی نسبت به عملکرد مدل‌های منفرد می‌تواند افزایش یابد (Zhang, 2007). اغلب در ترکیب مدل، شبکه‌های منفرد با استفاده از روشهای مختلف مانند الگوریتم‌های آموزش متفاوت آموزش داده می‌شوند و سپس خروجیهای مدل‌های منفرد با استفاده از روشهای ترکیب مدل از جمله میانگین‌گیری با هم ترکیب می‌شوند (Wolpert, 1992; Krogh and Vedelsby, 1995).

در این پژوهش روش ترکیب مدل به ۳ صورت، ترکیب خطی ساده، ترکیب خطی وزن‌دار و ترکیب غیر خطی با شبکه عصبی مصنوعی انجام شده است. در مدل ترکیبی خطی ساده، عمل ترکیب کردن به صورت میانگین‌گیری ساده و در مدل ترکیبی خطی وزن‌دار، عمل ترکیب کردن مطابق رابطه (۷) انجام شده است (Krogh and Vedelsby, 1995):

$$\bar{f}(x) = \sum_i w_i f_i(x) \quad (7)$$

که در آن $\bar{f}(x)$ خروجی مدل ترکیبی، $f_i(x)$ خروجی مدل‌های منفرد (مدل‌های ANN، ANFIS، SVR و ARIMA) و w_i وزن مدل‌های منفرد می‌باشد که بر اساس عملکرد هر یک از مدل‌های منفرد (مانند ضریب تبیین مدل‌ها) تعیین می‌شود، به طوری که وزن‌ها باید مثبت و مجموعشان باید ۱ باشد. در روش ترکیبی خطی ساده وزن هر کدام از مدل‌ها برابر ۰/۲۵ است. در این مطالعه برای ایجاد مدل ترکیبی غیر خطی از شبکه عصبی مصنوعی استفاده شد. شکل شماتیک ترکیب مدل در شکل ۲ نشان داده شده است.

اصولی، قانون پایه فازی و عملگر استنتاج است (Jang et al., 1997; Nourani and Komasi, 2013). در ساختار انفیس هر ورودی دو یا چند تابع عضویت دارد، که پارامترهای توابع عضویت این سیستم از طریق الگوریتم پس انتشار یا ترکیب آن با روش حداقل مربعات تنظیم می‌شوند. این عملیات تنظیم به سیستم‌های فازی اجازه می‌دهد تا ساختار خود را از مجموعه داده‌ها فرا بگیرد (Kia, 2012).

۲-۵- ماشین بردار پشتیبان

ماشین بردار پشتیبان در سال ۱۹۹۵ توسط کورتز و واپنیک معرفی شد (Kia, 2012). این شبکه‌های عصبی یکی از روشهای یادگیری با ناظر هستند که برای طبقه‌بندی مورد استفاده قرار می‌گیرند. ماشین بردار پشتیبان بر خلاف سایر شبکه‌های عصبی به جای اینکه خطای مدل‌سازی یا طبقه‌بندی را کمینه کند، ریسک عملیاتی را به عنوان تابع هدف در نظر می‌گیرد و مقدار بهینه آن را حساب می‌کند (Nourani, 2015).

ایده ماشین‌های بردار پشتیبان تعمیم یافته و نوع دیگری از ماشین بردار پشتیبان به نام رگرسیون بردار پشتیبان مطرح شدند، که برای تخمین مقادیر تابع، تقریب تابع، مدل‌سازی، برازش منحنی، پیش‌بینی سری‌های زمانی و غیره مورد استفاده قرار می‌گیرند. در رگرسیون بردار پشتیبان هدف این است که یک رگرسیون خطی انجام داده و سپس این رگرسیون خطی با یک کرنل ترکیب کرده و یک رگرسیون غیر خطی به دست آید، مطابق با رابطه (۴) (Cortes and Vapnik, 1995):

$$y = \sum_i (\alpha_i^+ - \alpha_i^-) K(x_i, x_j) + b \quad (4)$$

کرنل تابع پایه شعاعی، یک کرنل بسیار رایج است که به شکل رابطه (۵) بیان می‌شود:

$$k(x_1, x_2) = \exp(-\lambda \|x - y\|^2) \quad (5)$$

که در آن پارامتر آزاد λ ، پارامتر کرنل است (Schölkopf et al., 2000; Liu and Pender, 2015).

۲-۶- مدل خودهمبسته تفاضلی با میانگین متحرک

مدل آرما گسترش یافته‌ی مدل آرما^{۱۱} است که برای سری‌های زمانی که ایستا نبوده و یا دارای میانگین ثابت نمی‌باشند و با تفاضل‌گیری ایستا می‌شوند، مورد استفاده قرار می‌گیرد. معادله مدل $ARIMA(p,d,q)$ بصورت رابطه (۶) نوشته می‌شود (Nourani, 2015):




Fig. 2- Schematic diagram of ensemble model

شکل ۲- شماتیک مدل ترکیبی

گرفت. در مدل سازی شبکه عصبی، برای به دست آوردن ساختار بهینه، تعداد نرون ها در لایه میانی و تعداد تکرار مرحله آموزش متغیر در نظر گرفته شده و در نهایت ساختار بهینه انتخاب شد. شایان ذکر است که مدل بهینه برای پیژومتر ۲۰۷ با ۴ نرون میانی و تعداد تکرار ۱۰ و مدل بهینه برای پیژومتر ۲۱۷ با ۸ نرون میانی و تعداد تکرار ۵۰ به دست آمد.

سپس مدل سازی ANFIS با سیستم استنتاج فازی سوگنو و الگوریتم بهینه سازی هیبرید انجام گرفت و در ادامه مدل SVR با استفاده از کرنل تابع پایه شعاعی (RBF)^{۱۶} ایجاد و آموزش داده شد. در مدل های ANFIS و SVR همانند مدل ANN با استفاده از داده های صحت سنجی کارایی مدل های ایجاد شده مورد بررسی قرار گرفت. در این مدل سازی ها نیز مدل بهینه به دست آمده و به عبارت دیگر با تغییر پارامترهای مربوطه، مدلی با عملکرد بهینه به دست آمد. قابل ذکر است که در مدل سازی با ANFIS برای پیژومتر ۲۰۷ تابع عضویت gauss2mf و برای پیژومتر ۲۱۷ تابع عضویت trimf به کار گرفته شد و در مدل سازی با SVR مدل بهینه برای پیژومتر ۲۰۷ با پارامتر کرنل $\gamma = 0/5$ و مدل بهینه برای پیژومتر ۲۱۷ با پارامتر کرنل $\gamma = 0/33$ به دست آمد.

در مدل سازی با ARIMA طی روند سعی و خطا پارامترهای مدل بهینه به دست آمدند. در نهایت برای پیژومتر ۲۰۷ مدل بهینه ARIMA (11,2,4) و برای پیژومتر ۲۱۷ مدل بهینه ARIMA (10,2,11) ایجاد شد.

در سناریو دوم برای مدل سازی پیژومتر ۲۰۷ از دو پیژومتر ۲۱۲ و ۲۱۶ برای مدل سازی پیژومتر ۲۱۷ از دو پیژومتر ۲۰۷ و ۲۱۶ استفاده شد. در این سناریو نیز مدل های ANN، ANFIS و SVR همانند سناریو اول ایجاد شدند. در سناریو ۲ مدل بهینه ANN برای پیژومتر ۲۰۷ با ۱۰ نرون میانی و تعداد تکرار ۲۰۰ و برای پیژومتر ۲۱۷ با ۳ نرون میانی و تعداد تکرار ۱۰ و مدل های ANFIS با همان پارامترهای سناریو ۱ و در مدل سازی با SVR مدل بهینه برای پیژومتر ۲۰۷ با

۸-۲- معیار ارزیابی دقت مدل

صحت سنجی مدل ها به منظور سنجش دقت مدل ها انجام می گیرد. برای این منظور آماره های مختلفی تدوین شده و مورد استفاده قرار می گیرند. در این پژوهش از ضریب تبیین^{۱۲}، جذر میانگین مربعات خطا^{۱۳} و ضریب همبستگی^{۱۴} استفاده شده است، که مقدار آن در هر دو مرحله آموزش و صحت سنجی باید در محدوده مطلوب قرار گیرد (RMSE ≈ 0 ، DC ≈ 1) توسط روابط ۸ و ۹ محاسبه می شود (Nourani, 2015).

$$DC = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (8)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (9)$$

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^N (x_i - \bar{x})^2 (y_i - \bar{y})^2} \quad (10)$$

که در روابط فوق، y_i داده های مربوط به نتایج مدل و x_i داده های مشاهده ای، \bar{x} و \bar{y} میانگین داده های ذکر شده و N تعداد داده ها می باشد.

۳- نتایج و بحث

در این مقاله هد پیژومتریک سد خاکی ستارخان با استفاده از مدل های ANN، ANFIS، SVR و ARIMA بر اساس دو سناریو با ترکیب ورودی های مختلف بررسی شده است.

در ابتدا داده های پیژومترهای ۲۱۷ و ۲۰۷ به دو قسمت داده های واسنجی، شامل ۷۰٪ داده ها از ابتدا و داده های صحت سنجی شامل ۳۰٪ داده های انتهایی تقسیم شدند و با استفاده از داده های واسنجی مدل شبکه عصبی مصنوعی پیشرو با الگوریتم آموزشی پس انتشار ایجاد شد و با الگوریتم گرادیان توأم مقیاس شده^{۱۵} آموزش داده شد. قابل ذکر است که تابع تانژانت سیگموئید به عنوان تابع محرک در لایه های میانی و خروجی به کار گرفته شد. سپس با استفاده از داده های صحت سنجی، کارایی مدل به دست آمده مورد بررسی قرار

Table 2- Results of single models for piezometer 207
جدول ۲- نتایج مدل‌های منفرد برای پیزومتر ۲۰۷

| | | ANN | ANFIS | SVR | ARIMA |
|------------|------|--------|--------|--------|--------|
| Scenario 1 | DC | 0.9535 | 0.9566 | 0.9502 | 0.9172 |
| | RMSE | 0.7252 | 0.7068 | 0.7577 | 0.9404 |
| | CC | 0.9769 | 0.9780 | 0.9756 | 0.9617 |
| Scenario 2 | DC | 0.9671 | 0.9637 | 0.9507 | 0.9172 |
| | RMSE | 0.6140 | 0.6464 | 0.7464 | 0.9404 |
| | CC | 0.9837 | 0.9821 | 0.9752 | 0.9616 |

Table 3- Results of single models for piezometer 217
جدول ۳- نتایج مدل‌های منفرد برای پیزومتر ۲۱۷

| | | ANN | ANFIS | SVR | ARIMA |
|------------|------|--------|--------|--------|--------|
| Scenario 1 | DC | 0.9121 | 0.9082 | 0.9170 | 0.8892 |
| | RMSE | 0.6660 | 0.6776 | 0.6444 | 0.7645 |
| | CC | 0.9546 | 0.9531 | 0.9582 | 0.9440 |
| Scenario 2 | DC | 0.9495 | 0.9449 | 0.9468 | 0.8892 |
| | RMSE | 0.5028 | 0.5276 | 0.5184 | 0.7645 |
| | CC | 0.9748 | 0.9724 | 0.9729 | 0.9440 |

پارامتر کرنل $\gamma = 0.33$ و برای پیزومتر ۲۱۷ با پارامتر کرنل $\gamma = 0.5$ به دست آمد.

مقادیر DC و RMSE مدل‌های مذکور برای هر دو سناریو برای کل داده‌های پیزومتر ۲۰۷ در جدول ۲ و برای کل داده‌های پیزومتر ۲۱۷ در جدول ۳ نشان داده شده است. نمودار مقادیر مشاهده و محاسبه شده در هر دو مرحله آموزش و صحت‌سنجی توسط مدل‌ها براساس سناریو ۱ برای پیزومتر ۲۰۷ در شکل ۳ و برای پیزومتر ۲۱۷ در شکل ۴ نشان داده شده است.

همانگونه که از نتایج جداول ۲ و ۳ مشخص است برای پیزومتر ۲۰۷ نتایج دقیق تری نسبت به پیزومتر ۲۱۷ به دست آمده است.




Fig. 3- Observed and computed results of single models for piezometer 207
شکل ۳- مقادیر مشاهده و محاسبه شده توسط مدل‌های منفرد برای پیزومتر ۲۰۷




Fig. 4- Observed and computed results of single models for piezometer 217
شکل ۴- مقادیر مشاهده و محاسبه شده توسط مدل‌های منفرد برای پیزومتر ۲۱۷

- I. ANN+ANFIS
- II. ANN+SVR
- III. ANN+ARIMA
- IV. ANFIS+SVR
- V. ANFIS+ARIMA
- VI. SVR+ARIMA
- VII. ANN+ANFIS+SVR
- VIII. ANN+ANFIS+ARIMA
- IX. ANN+SVR+ARIMA
- X. ANFIS+SVR+ARIMA
- XI. ANN+ANFIS+SVR+ARIMA

در این مرحله از کار ابتدا روش ترکیب مدل با همه ترکیب‌ها برای سناریو اول انجام گرفت، سپس بر اساس نتایج سناریو ۱، ترکیباتی که بهترین نتایج را به دست داده بودند، برای سناریو ۲ نیز تشکیل شدند. در ترکیب مدل غیرخطی توسط شبکه عصبی با متغیر در نظر گرفتن نرون میانی و تعداد تکرار مرحله آموزش مدل بهینه به دست آمد که در نتیجه برای پیرومتر ۲۰۷ در سناریو ۱ برای بهترین ترکیب (ANN+SVR+ARIMA) تعداد ۱۰ نرون میانی و تعداد تکرار ۱۳۰ و برای سناریو ۲ تعداد ۸ نرون میانی و تعداد ۱۸۰ تکرار به دست آمد. همین طور برای پیرومتر ۲۱۷ در سناریو ۱ برای بهترین ترکیب (ANFIS+ARIMA) تعداد ۶ نرون میانی و تعداد تکرار ۱۶۰ و برای سناریو ۲ تعداد ۲ نرون میانی و تعداد تکرار ۴۰ به دست آمد.

مقادیر DC و RMSE بهترین ترکیبات مدل‌های ترکیبی هر دو سناریو، برای پیرومتر ۲۰۷ در جدول ۴ و برای پیرومتر ۲۱۷ در جدول ۵ نشان داده شده است.

بر اساس نتایج جداول ۴ و ۵ همان طور که در قسمت قبل ذکر شد مقادیر تخمینی برخی از مدل‌ها بیشتر از مقادیر مشاهده شده و مقادیر تخمینی برخی از مدل‌ها کمتر از مقادیر مشاهده شده می‌باشد و هر کدام از مدل‌ها در مدل سازی بخشی از سری زمانی عملکرد مناسبی دارند و در برآورد بعضی قسمتهای دیگر ضعفهایی دارند که در ترکیب با هم باعث بهبود نتایج نسبت به مدل‌های اولیه شدند.

چون پیرومتر ۲۰۷ نزدیک‌ترین پیرومتر به بالادست سد می‌باشد در نتیجه همبستگی بیشتری با سری زمانی ارتفاع آب بالادست دارد. در مقابل پیرومتر ۲۱۷ فاصله بیشتری با بالادست سد دارد و به علت اینکه حرکت آب در خاک آهسته است و عبور آب از خاک باعث کاهش نوسانات موجود در بالادست سد می‌شود، از این رو سری زمانی پیرومتر ۲۱۷ همبستگی کمتری با سری زمانی بالادست سد دارد. به علت استفاده از سری‌های زمانی بالادست سد و خود پیرومتر در مدل‌سازی‌ها در نهایت نتایج بهتری برای پیرومتر ۲۰۷ به دست آمده است. همین طور نتایج حاصل از سناریو ۲ دارای دقت بیشتری نسبت به سناریو ۱ می‌باشد. این امر به این دلیل می‌باشد که در سناریو ۲ از داده‌های همزمان با داده‌های هدف و همین طور از ۲ پیرومتر برای مدل‌سازی استفاده شده است.

با مقایسه نتایج مدل‌های هوش مصنوعی و مدل ARIMA مشاهده می‌شود که در مدل ARIMA به علت خطی بودن، از تأخیر زمانی زیادی برای به دست آوردن مدل بهینه استفاده شده، اما مدل‌های هوش مصنوعی به علت داشتن ماهیت غیر خطی به تأخیر زمانی بسیار کمتری برای به دست آوردن مدل بهینه نیاز دارند و با این وجود نتایج بهتر و دقیق‌تری را ارائه می‌کنند.

با توجه به جداول ۲ و ۳ و شکل‌های ۳ و ۴ مدل ANN به علت اینکه یک مدل درون‌یاب کننده است، در تخمین اکثر نقاط پیک عملکرد مناسبی ندارد و از سویی دیگر مشاهده می‌شود که مقادیر تخمینی توسط مدل آریمای بیشتر از مقادیر مشاهده شده سری زمانی است و در مقابل در اکثر نقاط مقادیر تخمینی مدل‌های ANFIS و SVR کمتر از مقادیر مشاهده شده است. بر این اساس که هر کدام از مدل‌ها محدودیت‌هایی دارند و مدلی که از همه جوانب بهتر باشد، وجود ندارد، از این رو در ادامه برای بهبود عملکرد مدل‌سازی، خروجی مدل‌های منفرد به ۳ روش میانگین‌گیری ساده، میانگین‌گیری وزن دار و ترکیب غیر خطی با شبکه عصبی بر اساس ۱۱ نوع ترکیب مدل مختلف باهم ترکیب شدند:

Table 4- Results of ensemble models for piezometer 207

جدول ۴- نتایج مدل‌های ترکیبی برای پیرومتر ۲۰۷

| | | Simple ensemble | Weighted ensemble | Nonlinear ensemble |
|------------|------|-----------------|-------------------|--------------------|
| Best comb. | | XI | XI | IX |
| Scenario 1 | DC | 0.9645 | 0.9644 | 0.9724 |
| | RMSE | 0.9337 | 0.6340 | 0.5586 |
| | CC | 0.9824 | 0.9824 | 0.9861 |
| Scenario 2 | DC | 0.9772 | 0.9771 | 0.9806 |
| | RMSE | 0.5083 | 0.5091 | 0.4678 |
| | CC | 0.9891 | 0.9890 | 0.9904 |

Table 5- Results of ensemble models for piezometer 217

جدول ۵- نتایج مدل‌های ترکیبی برای پیزومتر ۲۱۷

| | | Simple ensemble | Weighted ensemble | Nonlinear ensemble |
|------------|------|-----------------|-------------------|--------------------|
| Best comb. | | IX | IX | V |
| Scenario 1 | DC | 0.9322 | 0.9321 | 0.9399 |
| | RMSE | 0.5827 | 0.5828 | 0.5482 |
| | CC | 0.9663 | 0.9662 | 0.9696 |
| Scenario 2 | DC | 0.9647 | 0.9648 | 0.9656 |
| | RMSE | 0.4203 | 0.4198 | 0.4152 |
| | CC | 0.9838 | 0.9838 | 0.9827 |

- استفاده از داده‌های همزمان با داده‌های هدف در مدل‌سازی باعث افزایش دقت مدل‌سازی شد.

- در صورت خرابی یک پیزومتر می‌توان از داده‌های پیزومترهایی که همبستگی بالایی با پیزومتر مورد نظر دارند، در مدل‌سازی استفاده کرد.

- روش ترکیب مدل، کارایی مدل‌سازی را افزایش داد.

- کارایی مدل ترکیبی غیر خطی بالاتر از مدل‌های ترکیبی خطی بود.
- به کار بردن مدل ترکیبی غیرخطی با شبکه عصبی می‌تواند روش مناسبی برای مدل‌سازی پدیده‌های غیر خطی همچون تخمین هد پیزومتریک باشد.

پیشنهاد می‌شود:

- از مدل‌های جعبه سفید (مبتنی بر فیزیک) در روش ترکیب مدل استفاده شود.

- اقدام به مدل‌سازی مشابه برای سایر کمیت‌های سد خاکی مثل نشست و تراوش از پی شود.

با توجه به نزدیکی نتایج مدل‌های منفرد هوش مصنوعی، نتایج مدل‌های ترکیبی میانگین‌گیری ساده و میانگین‌گیری وزن‌دار بسیار نزدیک به هم به دست آمده است.

در مجموع نتایج حاکی از آن است که روش ترکیب مدل باعث افزایش دقت مدل‌سازی شده، زیرا هر مدل مزایا و معایبی دارد، و ترکیب مدل از اجزا هر کدام از مدل‌های منفرد استفاده می‌کند، بنابراین توانایی بیشتری در مدل‌سازی پدیده دارد. برای هر کدام از ترکیب‌ها عملکرد مدل ترکیبی غیر خطی با شبکه عصبی بهتر از دو مدل ترکیبی خطی برای همان ترکیب می‌باشد. چون در مدل ترکیبی غیر خطی از شبکه عصبی استفاده شده و به علت ماهیت غیر خطی پدیده، مدل غیر خطی پدیده مورد بررسی را با دقت بیشتری مدل می‌کند. در بین مدل‌های ترکیبی خطی نیز مدل ترکیبی وزن‌دار، به علت تاثیر دادن بیشتر مدل با کارایی بالاتر، در برخی از ترکیب‌ها عملکرد بهتری نسبت به مدل ترکیبی ساده نشان داده است.

پی‌نوشت‌ها

1. Soft Computing
2. Artificial Intelligence (AI)
3. Artificial Neural Network (ANN)
4. Adaptive Neuro-Fuzzy Inference System (ANFIS)
5. Support Vector Machine (SVM)
6. Finite Element Method (FEM)
7. Support Vector Regression (SVR)
8. Auto Regressive Integrated Moving Average (ARIMA)
9. Feed Forward
10. Back Propagation (BP)
11. Auto Regressive Moving Average (ARMA)
12. Determination Coefficient (DC)
13. Root Mean Square Errors (RMSE)
14. Correlation Coefficient (CC)
15. Scaled Conjugate Gradient
16. Radial Basis Function (RBF)

۴- نتیجه‌گیری و پیشنهادات

در این تحقیق از مدل‌های جعبه سیاه برای مدل‌سازی هد پیزومتریک سد خاکی ستارخان استفاده شد. برای این منظور با استفاده از دو سناریو با ترکیب ورودی‌های متفاوت، پیزومترهای ۲۰۷ و ۲۱۷ واقع در مقطع شماره ۲ مدل‌سازی شدند. در ابتدا پیزومترهای مذکور با مدل‌های ANN، ANFIS، SVR و ARIMA مدل‌سازی شد و در ادامه برای افزایش کارایی مدل‌سازی روش ترکیب مدل به سه روش میانگین‌گیری خطی ساده، میانگین‌گیری خطی وزن‌دار و ترکیب غیر خطی با شبکه عصبی مصنوعی انجام شد و در نهایت نتایج مورد مقایسه قرار گرفت، که به طور کلی می‌توان نتایج زیر را استنتاج کرد:
- برای پیزومتر نزدیک‌تر به بالادست به علت همبستگی بیشتر با سری زمانی بالادست سد، نسبت به پیزومتر دورتر از بالادست، نتایج دقیق‌تری به دست آمد.

- rainfall-runoff process. *Journal of Hydrology* 402:41-59
- Nourani V, Sharghi E, Aminfar MH (2012) Integrated ANN model for earthfill dams seepage analysis: Sattarkhan dam in Iran. *Artificial Intelligence Research* 1(2):22-37
- Novakovic A, Rankovic V, Grujovic N, Divac D, Milivojevic N (2014) Development of neuro-fuzzy model for dam seepage analysis. *Annals of the Faculty of Engineering Hunedoara* 12(2):133-136
- Rankovic V, Grujovic N, Divac D, Milivojevic N (2014) Development of support vector regression identification model for prediction of dam structural behavior. *Structural Safety* 48:33-39
- Schölkopf B, Smola AJ, Williamson RC, Bartlett PL (2000) New support vector algorithms. *Neural Computation* 12:1207-1245
- Shamseldin AY, O'Connor KM, Liang G.C (1997) Methods for combining the outputs of different rainfall-runoff models. *Journal of Hydrology* 197:203-229
- Tayfure G, Swiatek D, Wita A, Singh VP (2005) Case study: finite element method and artificial neural network models for flow through Jeziorsko earthfill dam in Poland. *Journal of Hydraulic Engineering* 131(6):431-440
- Vafaeian M (2015) Earth dams & rockfill dams. Arkan Danesh, Isfahan, 464p (In Persian)
- Wolpert DH (1992) Stacked generalization. *Neural Networks* 5(2):241-59
- Zhang GP (2003) Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing* 50:159-175
- Zhang GP (2007) A neural network ensemble method with jittered training data for time series forecasting. *Information Sciences* 177:5329-5346
- Zhang LM, Xu Y, Jia JS (2009) Analysis of earth dam failures: a database approach. *Georisk* 3(3):184-189
- Bandab Consulting Engineers (2003) Technical reports of instrumentation of Sattarkhan dam. East Azarbayjan Regional Water Authority, 250p (In Persian)
- Cortes C, Vapnik V (1995) Support-vector networks. *Machine Learning* 20:273-297
- Hornik K (1988) Multilayer feed-forward networks are universal approximators. *Neural Networks* 2(5):359-366
- Jang JSR (1993) ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems Man and Cybernetics* 23(3):665-685
- Jang JSR, Sun CT, Mizutani E (1997) *Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence*. Prentice Hall, NJ, 640p
- Kia M (2012) *Soft computing in Matlab*. Kian Publication, Tehran, 624p (In Persian)
- Krogh A, Vedelsby J (1995) Neural network ensembles, cross validation, and active learning. *Advances in Neural Information Processing* 7:231-238
- Liu Y, Pender G (2015) A flood inundation modeling using v-support vector machine regression model. *Engineering Applications of Artificial Intelligence* 46:223-231
- Nadiri AA, Taherkhani Z, Sadeghi Aghdam F (2017) Prediction of ground water level of Bostan Abad using combining artificial intelligence models. *Iran-Water Resources Research* 13(3):43-55 (In Persian)
- Nourani V (2015) *Basics of hydroinformatics*. Tabriz University Press, 636p (In Persian)
- Nourani V, Komasi M (2013) A geomorphology-based ANFIS model for multi-station modelling of rainfall-runoff process. *Journal of Hydrology* 490:41-55
- Nourani V, Kisi Ö, Komasi M (2011) Two hybrid artificial intelligence approaches for modeling