

استفاده از روش جی‌ترینگ داده‌ها در مدل‌سازی تراوش سد خاکی با استفاده از ترکیب مدل‌های هوش مصنوعی

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

تاریخ دریافت: ۹۶/۰۷/۰۱

تاریخ پذیرش: ۹۷/۰۹/۲۵

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

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

۳- دانش آموخته کارشناسی ارشد مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه تبریز

*مسئول مکاتبات، پست الکترونیکی: elnaz_sharghi@yahoo.com

چکیده

اخیراً مدل‌های هوش مصنوعی مثل شبکه عصبی مصنوعی پیشرو و رگرسیون بردار پشتیبان قابلیت بالایی در مدل‌سازی سری‌های زمانی غیرخطی هیدرولیکی نشان داده‌اند. مدل‌های هوش مصنوعی روش‌هایی موثر برای بررسی و مدل‌سازی مقادیر زیادی از داده‌های دینامیک، غیرخطی و دارای خطا ارائه می‌دهند. از اینرو در این مقاله مسئله تراوش سد خاکی ستارخان با استفاده از دو مدل جعبه سیاه هوش مصنوعی شبکه عصبی مصنوعی پیشرو و رگرسیون بردار پشتیبان، بر اساس دو سناریو با ترکیب ورودی‌های مختلف مورد بررسی قرار گرفته و سپس به عنوان یک روش پیش‌پردازش برای بهبود عملکرد مدل، سری‌های نوفه با توزیع نرمال، میانگین صفر و انحراف معیارهای مختلف تولید شده و با افزودن آنها به داده‌های اصلی و تشکیل مجموعه‌های آموزشی مختلف، شبیه‌سازی تراوش با استفاده از مدل‌های هوش مصنوعی انجام شد. در ادامه به عنوان روشی دیگر برای بهبود عملکرد مدل، روش پس‌پردازش ترکیب مدل با استفاده از خروجی مدل‌های منفرد به کار گرفته شد. روش ترکیب مدل با استفاده از روش میانگین‌گیری غیرخطی با استفاده از شبکه عصبی مصنوعی انجام گرفت. نتایج حاکی از آن است که به کارگیری هم‌زمان هر دو روش جی‌ترینگ داده‌ها و ترکیب مدل، باعث بهبود دقت مدل تا ۳۲٪ در مرحله صحت‌سنجی می‌شود.

واژه‌های کلیدی: تراوش سد خاکی، ترکیب مدل، جی‌ترینگ داده‌ها، سد خاکی ستارخان، مدل‌های هوش مصنوعی

Implementation of Data Jittering Technique for Seepage Analysis of Earth fill Dam Using Ensemble of AI Models

Elnaz Sharghi^{1*}, Vahid Nourani², Nazanin Behfar³

Received: 06/05/2018

Accepted: 26/04/2020

¹Assist. Prof., Dept. of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Iran

²Prof., Dept. of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Iran

³M.Sc., Dept. of Water Resources Engineering, Faculty of Civil Engineering, University of Tabriz, Iran

*Corresponding Author, Email: elnaz_sharghi@yahoo.com

Abstract

Recently, it has been shown that Artificial Intelligence (AI) methods such as Feed forward neural network and Support vector regression have great capability in modeling of non-linear hydraulic time series. AI methods offer effective approaches for handling large amounts of dynamic, non-linear and noisy data. Hence in this paper, seepage of Sattarkhan earth fill dam using two AI models of Feed forward neural network and Support vector regression was simulated, based on 2 scenarios with different combination of inputs. Afterwards, as a pre-processing method for improving the model performance, normally distributed noises with the mean of zero and various standard deviations were generated and added to the time series to form different jittered training data sets, for AI modeling of seepage. Further, as another method for improving the model performance, an ensemble post-processing model was developed using outputs of sole models. Non-linear neural averaging method was considered for model ensembling. The obtained results indicated that simultaneous application of the both jittering and model ensembling methods improved the model accuracy up to 32% in the verification step.

Keywords: Artificial intelligence, Earth fill dam seepage, Ensemble, Jittering, Sattarkhan earth fill dam

مقدمه

مدل‌های هوش مصنوعی^۱ از جمله روش‌های نسبتاً جدید جعبه سیاه هستند که در دهه‌های اخیر در بسیاری از مسائل هیدرولیک، هیدرولوژی و منابع آب به کار گرفته شده‌اند. از جمله مدل‌های AI می‌توان به شبکه‌های عصبی پیشرو^۲ و رگرسیون بردار پشتیبان^۳ اشاره کرد. مروری بر تاریخچه کاربرد مدل‌های AI، بیان می‌کند که هوش مصنوعی در تعدادی از مسائل تراوش به کار گرفته شده و نتایج مطلوبی حاصل شده است. به عنوان مثال، در زمینه شبیه‌سازی تراوش از سد خاکی تایفور و همکاران (۲۰۰۵) یک مدل عددی با استفاده از روش المان محدود^۴ برای شبیه‌سازی جریان سد خاکی Jeziorsko واقع در لهستان به کار بردند. آنها به علت کمبودها و محدودیت‌های مدل FEM، یک مدل

سدهای خاکی از جمله مهم‌ترین و پیچیده‌ترین سازه‌های مهندسی می‌باشند که هزینه‌های هنگفتی صرف مطالعه و اجرای این نوع پروژه‌ها می‌شود، لذا پرداختن به مسائل مربوط به ایمنی آنها ضمن ساخت و نیز در دوران بهره‌برداری از اهمیت خاصی برخوردار است. بر اساس آمار خرابی سدهای خاکی، ۵۸٪ از خرابی‌ها بر اثر تراوش در شالوده و بدنه این نوع سدها اتفاق افتاده است (ژانگ و همکاران ۲۰۰۹). البته وجود تراوش در تمام سدهای خاکی غیرقابل اجتناب است، اما اگر شرایط مناسبی برای فرسودن خاک داشته باشد، موجب شسته شدن خاک در آن ناحیه مستعد گردیده و چنانچه در ابتدای بروز فرسایش جلوگیری نگردد، به خرابی سد منجر می‌گردد (وفائیان ۱۳۹۴).

¹ Artificial Intelligence-AI

² Feed Forward Neural Network-FFNN

³ Support Vector Regression-SVR

⁴ Finite Element Method-FEM

در فرآیند آموزش مدل‌های هوش مصنوعی، هر مجموعه داده آموزشی یک نمونه محدود از کل داده‌های موجود بوده لذا یک مجموعه داده انتخاب شده به تنهایی نمی‌تواند بیانگر تمام الگوهای موجود باشد. در واقع به دلیل محدودیت امکانات و عدم دسترسی، امکان نمونه‌برداری داده‌های فراوان که بتواند الگوهای مختلف از پدیده را شامل گردد، وجود ندارد. بنابراین افزایش تعداد داده‌ها با استفاده از داده‌های مصنوعی که دارای ماهیتی شبیه به داده‌های اصلی هستند، می‌تواند به عنوان یک پیش‌پردازش جهت آمادگی بهتر داده‌ها برای آموزش مدل‌های AI در نظر گرفته شود. در سال‌های اخیر محققان اثر تولید داده‌های آموزشی اضافی به وسیله افزودن نوفه به داده‌های ورودی را روی مدل‌سازی و قابلیت تعمیم و انطباق ANN مطالعه و بررسی کرده‌اند (نورانی و پرتویان ۲۰۱۷، یگانه فرد و ذهبیون ۱۳۹۳، ژانگ ۲۰۰۷). اتفاق آرا بر آن است که افزودن نوفه خوب به نمونه‌های آموزشی می‌تواند منجر به توسعه عمومی ANN شود. با وجود این که تاثیر افزودن نوفه خوب بر افزایش دقت مدل‌سازی در علوم مختلف بررسی شده است اما در زمینه تراوش مورد بحث و بررسی قرار نگرفته است که در این پژوهش با تولید سری‌های آموزشی متنوع هم‌الگو با سری اصلی از طریق افزودن نوفه خوب به سری‌های اصلی، داده‌هایی که هم از لحاظ کیفی و هم از لحاظ کمی مناسب بوده، ایجاد و در ادامه از این داده‌ها جهت آموزش مدل‌های AI استفاده می‌شود.

از سوی دیگر فرآیندهایی که دارای سیستم غیرخطی و پیچیده می‌باشند پیش‌بینی دقیق آنها غیرممکن خواهد بود، از طرفی در شرایط مختلف و برای داده‌هایی با الگوهای متفاوت هر مدل قابلیت پوشش بخشی از پیچیدگی‌های موجود در مسئله را خواهد داشت، لذا در سال‌های اخیر برای در نظر گرفتن عدم قطعیت‌ها در مدل‌ها و ارائه‌ی مدلی جامع که تا حد امکان تمامی پیچیدگی‌های موجود در مسئله را پوشش دهد، از روش ترکیب مدل‌ها به عنوان روش پس‌پردازش

شبکه عصبی مصنوعی^۵ 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. نورانی و همکاران (۲۰۱۲) برای بررسی تراوش از یک سد خاکی در ایران، یک مدل ANN با استفاده از داده‌های تراز آب بالادست- پایین دست سد ایجاد کردند و در ادامه با افزودن یک نرون دیگر به لایه ورودی تحت عنوان نرون موقعیت، یک مدل که توانایی مدل کردن ۳ بعدی را داشت ایجاد کردند و به این نتیجه رسیدند که مدل ANN می‌تواند جایگزین نسبتاً مناسبی برای مدل عددی FEM باشد. امامی و همکاران (۱۳۹۵) با استفاده از مدل ANN به پیش‌بینی تراوش از بدنه سد خاکی شهید کاظمی بوکان پرداختند که نتایج مدل پیشنهادی تحقیق مذکور نشان داد که مدل به کار برده شده در یافتن هدف مسئله کاملاً موفق و با سرعت بالا عمل می‌کند و قابلیت بالایی در پیش‌بینی پدیده تراوش دارد. همین طور از مدل SVR مبتنی بر مفاهیم ماشین بردار پشتیبان^۶ نیز مثل مدل FFNN در

زمینه آنالیز تراوش سدهای خاکی بهره گرفته شده است. یونگ بی (۲۰۱۲) پدیده رگاب در سدها را توسط روش‌های هوشمند مورد بررسی قرار داد. در این مطالعه نشان داده شده که مدل SVR مبتنی بر تابع هسته پایه شعاعی دقت پیش‌بینی بسیار بالایی دارد و روش SVR عملکرد مناسبی دارد و یک روش موثر برای حل مسئله رگاب در سدها است که می‌تواند در پروژه‌های واقعی مورد استفاده قرار گیرد. اسکندری و همکاران (۱۳۹۷) از مدل ماشین بردار پشتیبان- مویک برای پیش‌بینی ماهانه سطح آب زیرزمینی دشت برازجان استفاده کردند که نتایج حاکی از مناسب بودن عملکرد مدل مذکور برای پیش‌بینی سطح آب زیرزمینی بود.

⁵ Artificial Neural Network-ANN

⁶ Support Vector Machine-SVM

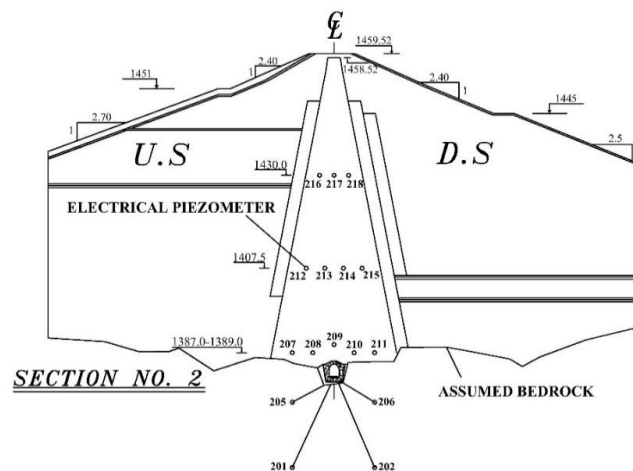
این زمینه مورد بررسی قرار نگرفته و استفاده نشده که در مطالعه حاضر ترکیب دو مدل AI انجام می‌گیرد.

است. ارتفاع آب در پیزومترها از ابتدای سال ۷۸ تا پایان سال ۹۲ 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 گرفته‌اند. شکل ۱، مقطع شماره ۲ سد را همراه با موقعیت پیزومترها نشان می‌دهد. مشخصه‌های آماری داده‌های پیزومترهای مذکور در جدول ۱ ذکر شده است.

در علوم مختلف استفاده شده است (بیتس و گرنجر ۱۹۶۹، شمس‌الدین و همکاران ۱۹۹۷، ژانگ ۲۰۰۳). هرچند تعداد اندکی مطالعه با استفاده از AI در زمینه آنالیز تراوش سد خاکی انجام شده ولی ترکیب آنها در مواد و روش‌ها

سد خاکی ستارخان

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 مترمکعب می‌باشد. در طول محور سد، ۴ مقطع ابزاربندی، 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



شکل ۱- موقعیت پیزومترها در مقطع شماره ۲.

جدول ۱- مشخصه‌های آماری پیزومترهای مورد استفاده.

پیزومتر				مخزن	
۲۰۷	۲۱۲	۲۱۶	۲۱۷		
۱۴۳۹/۵۷۰	۱۴۳۹/۳۵۰	۱۴۴۲/۷۳۰	۱۴۴۲/۸۶۰	۱۴۴۷/۲۱۰	بیشینه (m)
۱۴۲۴/۸۳۰	۱۴۲۴/۸۹۰	۱۴۲۹/۶۳۰	۱۴۲۵/۵۸۰	۱۴۳۸/۲۵۰	کمینه (m)
۱۴۳۱/۲۷۳	۱۴۳۱/۵۱۵	۱۴۳۴/۷۹۹	۱۴۳۴/۳۳۲	۱۴۳۲/۴۰۴	میانگین (m)
۳/۴۲۴	۳/۳۹۰	۳/۵۳۶	۴/۱۴۳	۲/۲۴۹	انحراف معیار (m)

مصنوعی به داده‌های اصلی مدل‌سازی با استفاده از مدل‌های FFNN و SVR انجام شد و در ادامه خروجی مدل‌های مذکور باهم ترکیب شدند. یک طرح کلی از

روش تحقیق

در این تحقیق در ابتدا مدل‌های FFNN و SVR ایجاد شدند. در ادامه داده‌های مصنوعی براساس یک توزیع دلخواه ایجاد شده و سپس با افزودن داده‌های

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

$$P_t^i = f_n(P_t^j, P_{t-1}^j, P_{t-2}^j, \dots, P_{t-r}^j, P_t^k, P_{t-1}^k, P_{t-2}^k, \dots, P_{t-r}^k, h_t, h_{t-1}, \dots, h_{t-m}) \quad [2]$$

که در آن P_{t-r}^j و P_{t-r}^k به ترتیب، زیر سری‌های پیژومترهای j ام و k ام هستند تا تاخیر زمانی r و o با توجه به این که در طول بهره‌برداری از سد امکان خرابی و از کار افتادن برخی از پیژومترها وجود دارد، به همین علت به کار گرفتن سناریو ۲ در این گونه موارد بسیار مفید خواهد بود.

روش پیشنهادی در شکل ۲ نشان داده شده است.


سناریو ۱

در سناریو اول سعی شده است که ارتفاع پیژومتریک هر پیژومتر با استفاده از داده‌های همان پیژومتر و داده‌های تراز آب مخزن مدل شود. برای این سناریو تخمین ارتفاع هر پیژومتر مطابق با رابطه ۱ انجام می‌گیرد:

$$P_t^i = f_n(P_{t-1}^i, P_{t-2}^i, \dots, P_{t-n}^i, h_t, h_{t-1}, \dots, h_{t-m}) \quad [1]$$

که در آن i در آن هد پیژومتر i در زمان t تابعی است از هد پیژومتر i در ماه‌های قبل تا تاخیر زمانی n و تراز آب بالادست در زمان t و ماه‌های قبل تا تاخیر زمانی m .

سناریو ۲



شکل ۲- دیاگرام شماتیک روش پیشنهادی.

شبکه BP وزن‌های شبکه در خلاف جهت شیب تابع کارایی حرکت می‌کنند. مقدار خروجی یک شبکه سه لایه پیشرو با الگوریتم BP به صورت رابطه ۳ بیان می‌شود (نورانی و همکاران ۲۰۱۲):

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

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 لایه میانی، f_h 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 لایه خروجی، f_0 تابع محرک برای

شبکه عصبی مصنوعی پیشرو

FFNN اولین و ساده‌ترین نوع شبکه‌های عصبی مصنوعی بودند که اختراع شدند. در این شبکه اطلاعات فقط در یک جهت رو به جلو (پیشرو) منتقل می‌شوند. از گره‌های ورودی به گره‌های پنهان و از گره‌های پنهان به گره‌های خروجی. هیچ چرخه و حلقه‌ای در این شبکه‌ها وجود ندارد (معیری و همکاران ۱۳۸۹). ثابت شده است که مدل شبکه‌های پیشرو سه لایه با الگوریتم یادگیری پس انتشار^۷ برای پیش‌بینی و شبیه‌سازی در هر گونه مسائل مهندسی رضایت بخش است (هورنیک و همکاران ۱۹۸۹). در

⁷ Back Propagation (BP)

تعداد نمونه‌های سری زمانی در عرض (نه در طول زمان سری زمانی) افزایش می‌یابد. سپس این سری زمانی می‌تواند برای آموزش مدل‌های AI استفاده شود. آموزش با این داده‌ها باعث ایجاد قیده‌های بیشتر در فرآیند آموزش شده، که خود به نوعی از مشکل ازبر کردن شبکه در طی فرآیند یادگیری جلوگیری خواهد کرد (نورانی و پرتویان ۲۰۱۷).

ترکیب مدل

یکی از پیشرفت‌های مهم در ANN 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 تنها می‌تواند افزایش یابد. یافته‌های نظری و تجربی نشان می‌دهند که ترکیب روش‌های مختلف می‌تواند یک راه موثر برای بهبود عملکرد مدل‌سازی باشد (برزگر و همکاران ۱۳۹۸، ژانگ ۲۰۰۳).

در این پژوهش ترکیب مدل با استفاده از روش میانگین‌گیری غیرخطی توسط مدل FFNN انجام شده است، که ورودی نرون‌های لایه اول مدل ترکیبی عصبی، خروجی‌های به دست آمده از دو مدل منفرد می‌باشد.

معیار های ارزیابی دقت مدل

در این پژوهش در راستای ارزیابی مدل‌ها از ضریب تبیین^۸ و جذر میانگین مربعات خطا^۹ و میانگین قدر مطلق خطا^{۱۰} استفاده شده است، که مقدار آن در هر دو مرحله آموزش و صحت‌سنجی باید در محدوده مطلوب قرار گیرد ($DC \approx 1$, MAE , $RMSE \approx 0$) مقدار آماره مذکور توسط روابط ۶ و ۷ و ۸ محاسبه می‌شود (نورانی ۱۳۹۴).

$$DC = 1 - \frac{\sum_{i=1}^n (o_{obs_i} - o_{com_i})^2}{\sum_{i=1}^n (o_{obs_i} - \bar{o}_{obs})^2} \quad [6]$$

نرون خروجی، x_i متغیر ورودی i ام برای لایه ورودی، y ، \hat{y}_k به ترتیب متغیرهای خروجی محاسبه و مشاهده شده و M_M و N_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.

رگرسیون بردار پشتیبان

SVR رایج‌ترین فرم SVM است. بر خلاف شبکه‌های عصبی دیگر که خطای مدل‌سازی را کمینه می‌کنند، SVR ریسک عملیاتی را به عنوان تابع هدف در نظر می‌گیرد و مقدار آن را کمینه می‌کند. در SVR هدف این است که یک رگرسیون خطی انجام داده و سپس این رگرسیون خطی با یک کرنل ترکیب کرده و یک رگرسیون غیرخطی به دست آید، مطابق با رابطه ۴ (کورتس و وپنیک ۱۹۹۵):

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

کرنل تابع پایه شعاعی، یک کرنل بسیار رایج

است که به شکل رابطه ۵ بیان می‌شود:

$$K(x_1, x_2) = \exp(-\gamma \|x_1 - x_2\|^2) \quad [5]$$

که در آن پارامتر آزاد γ ، پارامتر کرنل است (برزگر و همکاران ۱۳۹۸، لیو و پندر ۲۰۱۵).

تولید نوفه و داده مصنوعی (جی‌ترینگ)

تقریباً در تمامی مسائل عملی با سری زمانی، ثبت بیش از یک مشاهده در هر زمان خاص صورت نمی‌گیرد. به عنوان مثال برای سری زمانی دبی روزانه در یک روز که یک نمونه برداشت می‌شود و یا میانگین چند نمونه برداشت شده گزارش می‌شود، در این حالت مقدار دبی برداشت شده در یک زمان مشخص در یک روز می‌تواند با مقادیر دبی در زمان‌های دیگر همان روز تا حدی متفاوت باشد.

روش پیشنهادی در این مقاله مبتنی بر این ایده است که اگر برای هر سری زمانی، مجموعه‌ای از نوفه‌ها ایجاد و به سری زمانی اصلی اضافه شوند که هم الگو با سری زمانی اصلی باشند، در این صورت

⁸ Determination Coefficient - DC

⁹ Root Mean Square Errors - RMSE

¹⁰ Mean Absolute Error - MAE

ساختار شبکه مثل تعداد نرون‌های لایه میانی و تعداد تکرار مرحله آموزش از نکات بسیار مهم است که انتخاب مناسب آنها می‌تواند از مشکلاتی چون ازبر کردن شبکه جلوگیری کند. از این رو در مدل‌سازی شبکه عصبی، برای به دست آوردن ساختار بهینه، تعداد نرون‌ها در لایه میانی و تعداد تکرار مرحله آموزش متغیر در نظر گرفته شد و در نهایت ساختار بهینه انتخاب شد. نتایج به دست آمده برای ساختار بهینه هر دو پیرومتر ۲۰۷ و ۲۱۷ در جدول ۲ ارائه شده است. در ادامه مدل SVR با استفاده از کرنل تابع پایه شعاعی ایجاد و آموزش داده شد. کرنل تابع پایه شعاعی دارای عملکرد بهتر و پارامترهای تنظیم کمتری در مقایسه با کرنل‌های چند جمله‌ای و سیگموید است (نوری و همکاران ۲۰۱۱). در SVR همانند مدل FFNN مدل بهینه به دست آمد، به عبارت دیگر با تغییر پارامترهای مربوطه مدلی با عملکرد بهینه به دست آمد. نتایج به دست آمده برای بهترین ساختار برای پیرومترهای ۲۰۷ و ۲۱۷ در جدول ۲ ارائه شده است. شایان ذکر است که در جدول ۲، $a-b-c$ در ساختار مدل FFNN به ترتیب نشان دهنده نرون‌های لایه ورودی، لایه میانی و لایه خروجی هستند و همچنین $a-b-c$ در ساختار SVR به ترتیب به $c-e-\gamma$ اشاره دارد.

جدول ۲- نتایج مدل‌های منفرد برای سناریو ۱.

شماره پیرومتر	مدل	ساختار مدل	DC		RMSE*		MAE*	
			آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
پیرومتر ۲۰۷	FFNN	۳-۸-۱	۰/۸۵۸۸	۰/۷۱۶۶	۰/۰۶۱۲	۰/۰۲۵۷	۰/۰۴۴۹	۰/۰۲۷۱
	SVR	۱۵-۰/۰۱-۰/۳۳۳	۰/۸۴۵۳	۰/۶۹۳۵	۰/۰۶۶۹	۰/۰۲۸۲	۰/۰۴۶۶	۰/۰۲۸۵
پیرومتر ۲۱۷	FFNN	۳-۵-۱	۰/۷۵۶۶	۰/۶۸۶۵	۰/۱۰۹۸	۰/۱۰۴۵	۰/۰۷۹۹	۰/۰۸۶۰
	SVR	۳۰-۰/۱-۰/۳۳۳	۰/۷۲۲۹	۰/۶۴۶۷	۰/۰۹۴۴	۰/۱۲۱۲	۰/۰۶۸۲	۰/۰۹۸۵

* مقادیر RMSE و MAE برای مقادیر نرمال شده محاسبه گشته‌اند.

بالادست تأثیر بیشتری می‌پذیرد، در حالی‌که پیرومتر ۲۱۷ در بالاترین تراز و وسط سطح مقطع قرار گرفته

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (o_{obs_i} - o_{com_i})^2}{n}} \quad [7]$$

$$MAE = \frac{\sum_{i=1}^n |o_{obs_i} - o_{com_i}|}{n} \quad [8]$$

که در روابط فوق، o_{com} ، داده‌های مربوط به نتایج مدل و o_{obs} ، داده‌های مشاهداتی، \bar{o}_{obs} ، میانگین داده‌های ذکر شده و N تعداد داده‌ها می‌باشد.

نتایج و بحث

در مرحله اول پیرومترهای ۲۰۷ و ۲۱۷ با استفاده از مدل‌های FFNN و SVR بر اساس سناریو ۱ به صورت جداگانه مدل‌سازی شدند. در سناریو ۱ برای تعیین ورودی‌های موثر ضریب همبستگی به کار گرفته شد و مشخص شد که ارتفاع پیرومتر i در زمان t با ارتفاع پیرومتر $i-1$ در زمان $t-1$ و تراز آب بالادست در زمان t و $t-1$ وابستگی بیشتری دارد. از این رو مدل‌های AI در سناریو ۱ با ۳ ورودی آموزش داده شدند. در این مرحله ابتدا مدل FFNN با الگوریتم آموزشی BP و الگوریتم بهینه سازی گرادیان توأم مقیاس شده توسط ۷۵٪ ابتدایی داده‌ها بر اساس سناریو ۱ برای پیرومترهای ۲۰۷ و ۲۱۷ ایجاد و آموزش داده شد. قابل ذکر است که تابع تانژانت سیگموید به عنوان تابع محرک در لایه‌های میانی و خروجی به کار گرفته شد. در آموزش هر FFNN

پیرومتر ۲۰۷ نزدیک‌ترین پیرومتر به بالادست سد می‌باشد و از این رو از تغییرات سطح آب

است و بنابراین از نوسانات سطح آب بالادست کمتر از پیژومتر ۲۰۷ تأثیر می‌پذیرد. از طرف دیگر، با توجه به اصطکاک داخلی خاک، این نوسانات با عبور از سد کاهش می‌یابد و نوسانات سطح آب بالادست تأثیر قابل توجهی بر پیژومتر ۲۱۷ ندارد. با توجه به استفاده از سری زمانی تراز آب بالادست در آموزش مدل‌های AI و به دلایل ذکر شده، همانگونه که از نتایج جدول ۲ مشخص است برای پیژومتر ۲۰۷ نتایج دقیق‌تری نسبت به پیژومتر ۲۱۷ به دست آمده است.

در سناریو ۲ برای تعیین پیژومتر موثر در مدل‌سازی از ضریب همبستگی مابین پیژومترهای مقطع ۲ و پیژومترهای ۲۰۷ و ۲۱۷ استفاده شد، که در نتیجه برای مدل‌سازی پیژومتر ۲۰۷ از دو پیژومتر

جدول ۳- نتایج مدل‌های منفرد برای سناریو ۲.

شماره پیژومتر	مدل	ساختار مدل	DC		RMSE*		MAE*	
			آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
پیژومتر ۲۰۷	FFNN	۱-۵-۴	۰/۸۷۰۹	۰/۷۸۰۰	۰/۰۲۹۱	۰/۰۲۸۶	۰/۰۲۸۸	۰/۰۲۲۷
	SVR	۳۳-۰/۰۱-۱۵	۰/۸۵۷۱	۰/۷۷۰۰	۰/۰۴۷۶	۰/۰۳۸۰	۰/۰۳۶۲	۰/۰۲۷۵
پیژومتر ۲۱۷	FFNN	۱-۲-۴	۰/۷۹۰۹	۰/۷۱۰۰	۰/۰۶۵۸	۰/۰۹۶۷	۰/۰۶۱۳	۰/۰۷۷۲
	SVR	۲۵-۰/۲-۵	۰/۸۰۸۰	۰/۶۹۰۱	۰/۰۶۴۷	۰/۱۰۷۷	۰/۰۵۲۲	۰/۰۸۶۴

* مقادیر RMSE و MAE برای مقادیر نرمال شده محاسبه گشته‌اند.

با مقایسه نتایج مدل‌های منفرد (نمودارهای مربوطه ارائه نشده‌اند)، مشاهده شد که برخی از مدل‌ها تخمین‌های بالاتری از مقادیر مشاهده شده سری زمانی ارائه داده و در مقابل برخی دیگر از مدل‌ها مقادیر پایین‌تری از مقادیر مشاهده شده ارائه داده‌اند. بنابراین می‌توان نتیجه گرفت که هر مدل دارای محدودیت‌هایی است و هر مدل توانایی بهتری در مدل‌سازی سناریوهای مختلف و پیژومترهای مختلف دارد و مدلی که از همه جوانب بهتر باشد، وجود ندارد. بنابراین، با ترکیب مدل‌های مختلف، عملکرد مدل‌سازی می‌تواند بهبود یابد.

با توجه به نتایج دو سناریو هرچند که در سناریو ۲ داده‌های خود پیژومتر در لایه ورودی مورد استفاده قرار نگرفته اما به دلیل استفاده از داده‌های هم‌زمان با داده‌های هدف و همین‌طور به کار گرفتن ۲ پیژومتر برای مدل‌سازی، نتایج حاصل از سناریو ۲ دارای دقت بیشتری نسبت به سناریو ۱ می‌باشد. از این رو در موارد عمومی مدل‌سازی تراوش، سناریو ۱ می‌تواند مورد استفاده قرار گیرد و در شرایط خرابی و از کار افتادگی برخی از پیژومترها، به کارگیری سناریو ۲ می‌تواند موثر واقع شود.

ذکر است که در تولید سری‌های نوفه، سری‌های متعددی با میانگین صفر و انحراف معیارهای نرمال شده $0/005$ ، $0/01$ ، $0/05$ و $0/1$ تولید شدند، و برای هر سری زمانی با هر کدام از انحراف معیارها ۳ سری داده تولید شد.

در این مرحله، ابتدا با استفاده از سری داده‌های اصلی و مصنوعی مدل‌سازی با FFNN و SVR بر اساس سناریو ۱ انجام گرفت. در مدل‌سازی FFNN همانند مدل منفرد، با به کارگیری تابع تانژانت سیگموید به عنوان تابع محرک در لایه‌های میانی و خروجی، و با استفاده از الگوریتم آموزشی BP و الگوریتم بهینه سازی گرادیان توأم مقیاس شده آموزش داده شد و بهترین ساختار شبکه توسط روش آزمون و خطا به دست آمد. در مدل SVR نیز کرنل تابع پایه شعاعی مورد استفاده قرار گرفت و با تغییر پارامترهای مربوطه، مدلی با عملکرد بهینه به دست آمد که نتایج به دست آمده برای بهترین انحراف معیار در جدول ۴ ارائه شده است.

در مرحله بعد برای تولید سری‌های زمانی متعدد که دارای الگوهای مشابه با سری زمانی اصلی باشند ابتدا سری‌های زمانی نوفه متعدد تولید شدند، که برای این منظور ابتدا توابع چگالی احتمال پیرومترهای مورد استفاده در این تحقیق مورد بررسی قرار گرفت. تراز آب بالادست و پیرومترهای ۲۰۷ و ۲۱۲ از توزیع نرمال ولی پیرومترهای ۲۱۶ و ۲۱۷ به علت این که در بالاترین تراز سطح مقطع سد قرار گرفته‌اند و از ترازهای پایین سطح آب بالادست چندان متاثر نمی‌شوند، بنابراین از توزیع نیم نرمال پیروی می‌کنند. از این رو در ادامه اقدام به تولید سری‌های زمانی نوفه متعدد با میانگین صفر و انحراف معیارهای مشخص با توزیع نرمال برای تراز آب بالادست و پیرومترهای ۲۰۷ و ۲۱۲ و با توزیع نیم نرمال برای پیرومترهای ۲۱۶ و ۲۱۷ شد و در ادامه این سری‌های نوفه تولید شده به مقادیر متناظرشان در سری زمانی اصلی اضافه شدند تا از این طریق سری‌های زمانی بیشتری که دارای خواص و الگوی سری زمانی اصلی هستند تولید گردد. قابل

جدول ۴- نتایج مدل‌های منفرد با سری‌های نوفه‌دار برای سناریو ۱.

شماره پیرومتر	مدل	انحراف معیار نوفه	ساختار مدل	DC		RMSE*		MAE*	
				آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
پیرومتر ۲۰۷	FFNN	۰/۰۵	۱۲-۴-۱	۰/۹۱۴۴	۰/۸۱۶۹	۰/۰۵۸۸	۰/۰۳۲۷	۰/۰۴۴۱	۰/۰۲۷۲
	SVR	۰/۰۵	۶-۰/۰۵-۰/۳۳۳	۰/۹۲۶۴	۰/۷۹۶۰	۰/۰۶۲۹	۰/۰۳۵۶	۰/۰۴۴۰	۰/۰۲۶۴
پیرومتر ۲۱۷	FFNN	۰/۰۵	۱۲-۹-۱	۰/۸۳۷۱	۰/۸۲۳۵	۰/۱۰۶۴	۰/۱۰۵۸	۰/۰۸۳۶	۰/۰۸۶۱
	SVR	۰/۰۵	۱۵-۰/۱-۰/۳۳۳	۰/۸۳۳۲	۰/۷۰۱۵	۰/۰۸۲۴	۰/۱۱۴۷	۰/۰۶۰۲	۰/۰۹۶۱

* مقادیر RMSE و MAE برای مقادیر نرمال شده محاسبه گشته‌اند.

سری‌های نوفه با انحراف معیارهای خیلی کوچک تاثیر چندانی در مدل‌ها نداشته‌اند. افزایش سطح نوفه‌ها تا $0/01$ و $0/05$ باعث پیشرفت مدل‌ها شد و در انحراف معیار $0/05$ مدل بهینه به دست آمد. ولی افزایش سطح نوفه به $0/1$ باعث کاهش راندمان مدل‌ها

با مقایسه نتایج مدل‌سازی FFNN و SVR توسط داده‌های اصلی و پردازش شده با نوفه خوب با نتایج مرحله اول مشاهده شد که سری‌های نوفه ایجاد شده با انحراف معیار $0/005$ باعث افزایش کارایی مدل‌ها نشده‌اند. این نتیجه بیانگر آن است که

شد که این مسئله بیانگر آنست که هرگاه انحراف معیار نوفه‌ها بزرگ انتخاب شود می‌تواند باعث بر هم زدن الگوهای بین داده‌ها شود.

در ادامه با توجه به نتایج به دست آمده از سناریو ۱، با انحراف معیاری که بهترین نتیجه را به دست داده بود، مدل‌سازی برای سناریو ۲ نیز انجام

گرفت. نتایج به دست آمده از مدل‌های FFNN و SVR برای بهترین انحراف معیار برای سناریو ۲ در جدول ۵ ارائه شده است.

جدول ۵- نتایج مدل‌های منفرد با سری‌های نوفه‌دار برای سناریو ۲.

شماره پیزومتر	مدل	انحراف معیار نوفه	ساختار مدل	DC		RMSE*		MAE*	
				آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
پیزومتر ۲۰۷	FFNN	۰/۰۵	۱۶-۹-۱	۰/۹۲۰۵	۰/۸۴۰۰	۰/۰۳۲۰	۰/۰۳۹۲	۰/۰۲۵۷	۰/۰۳۰۶
	SVR	۰/۰۵	۵-۰/۰۱-۰/۳۳۳	۰/۹۰۰۴	۰/۸۳۰۷	۰/۰۴۲۷	۰/۰۴۲۳	۰/۰۲۶۳	۰/۰۳۴۳
پیزومتر ۲۱۷	FFNN	۰/۰۵	۱۶-۲-۱	۰/۹۰۸۰	۰/۷۴۰۰	۰/۰۵۱۰	۰/۱۱۲۱	۰/۰۳۹۲	۰/۰۸۸۹
	SVR	۰/۰۵	۱۵-۰/۰۱-۰/۳۳۳	۰/۹۰۵۰	۰/۶۹۲۲	۰/۰۵۸۵	۰/۱۱۷۵	۰/۰۴۷۵	۰/۰۹۵۶

* مقادیر RMSE و MAE برای مقادیر نرمال شده محاسبه گشته‌اند.

همچنان که از جدول ۵ مشخص است برای سناریو ۲ نیز نتایجی مشابه با سناریو ۱ به دست آمده است. به عبارتی در سناریو ۲ نیز سری‌های زمانی تولید شده توسط نوفه‌های با انحراف معیار ۰/۰۵ به دلایل ذکر شده باعث افزایش دقت و کارایی مدل شده‌اند.

در مجموع افزودن نوفه با انحراف معیار ۰/۰۵ برای پیزومتر ۲۰۷ و ۲۱۷ به ترتیب باعث افزایش تا ۱۰٪ و ۱۵٪ در مرحله آموزش و تا ۱۵٪ و ۲۰٪ در مرحله صحت‌سنجی شده است. با مقایسه نتایج به دست آمده برای دو پیزومتر مشاهده می‌شود که روش پیش‌پردازش تولید جی‌ترینگ تاثیر بیشتری را در پیزومتر ۲۱۷ داشته و به میزان بیشتری کارایی مدل‌ها را بالا برده و به عبارتی باعث بهبود بیشتر پیزومتر با عملکرد پایین‌تر شده است. به عبارت دیگر، کارایی روش پیشنهادی در مواردی که کیفیت داده‌های جمع آوری شده به علت محدودیت‌های فنی پایین‌تر است؛ قابل توجه است.

در مرحله بعد خروجی‌های به دست آمده از

مدل‌سازی‌ها برای بهترین انحراف معیار ($\sigma=0/05$) با استفاده از روش میانگین‌گیری عصبی ترکیب شدند. پارامترهای مدل ترکیبی عصبی، تنها با استفاده از داده‌های کالیبره برآورد شدند. در مدل ترکیبی عصبی همانند مدل منفرد FFNN، با به کارگیری تابع تانژانت سیگموید به عنوان تابع محرک در لایه‌های میانی و خروجی، و با استفاده از الگوریتم آموزشی BP و الگوریتم بهینه سازی گرادیان توأم مقیاس شده آموزش داده شد و بهترین ساختار شبکه توسط روش آزمون و خطا به دست آمد. نتایج به دست آمده برای پیزومتر ۲۰۷ و ۲۱۷ برای سناریوهای ۱ و ۲ به ترتیب در جداول ۶ و ۷ ارائه شده است. سری‌های زمانی مشاهده و محاسبه شده توسط مدل‌های ترکیبی عصبی برای پیزومتر ۲۰۷ و ۲۱۷ به ترتیب در شکل‌های ۳ و ۴ و همین‌طور دیاگرام متقابل مدل‌های ترکیبی عصبی برای پیزومتر ۲۰۷ و ۲۱۷ به ترتیب در شکل‌های ۵ و ۶ ارائه شده است.

جدول ۶- نتایج مدل‌های ترکیبی برای سناریو ۱.

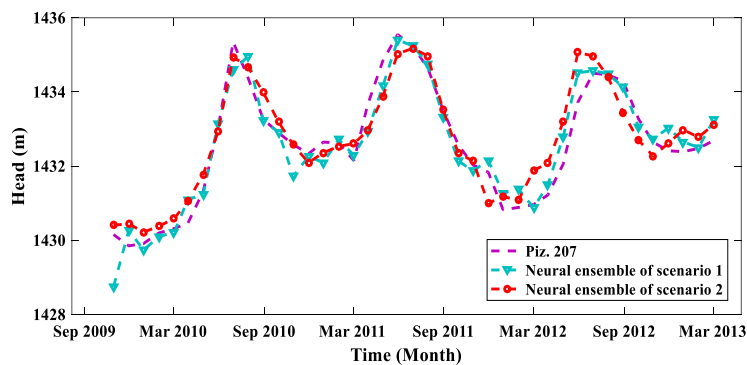
شماره پیزومتر	ساختار مدل	DC		RMSE*		MAE*	
		آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
پیزومتر ۲۰۷	۲-۷-۱	۰/۹۳۹۷	۰/۹۱۵۳	۰/۰۵۶۴	۰/۰۳۰۸	۰/۰۴۲۴	۰/۰۲۲۸
پیزومتر ۲۱۷	۲-۶-۱	۰/۸۵۵۳	۰/۸۰۰۰	۰/۱۰۰۳	۰/۰۹۹۷	۰/۰۷۹۶	۰/۰۸۴۲

* مقادیر RMSE و MAE برای مقادیر نرمال شده محاسبه گشته‌اند.


جدول ۷- نتایج مدل‌های ترکیبی برای سناریو ۲.

شماره پیزومتر	ساختار مدل	DC		RMSE*		MAE*	
		آموزش	صحت‌سنجی	آموزش	صحت‌سنجی	آموزش	صحت‌سنجی
پیزومتر ۲۰۷	۲-۹-۱	۰/۹۳۹	۰/۸۱۱۱	۰/۰۲۹۰	۰/۰۳۶۵	۰/۰۲۳۱	۰/۰۲۹۷
پیزومتر ۲۱۷	۲-۱۰-۱	۰/۹۱۱۷	۰/۸۱۰۰	۰/۰۸۶۷	۰/۰۸۵۴	۰/۰۶۸۷	۰/۰۷۱۰

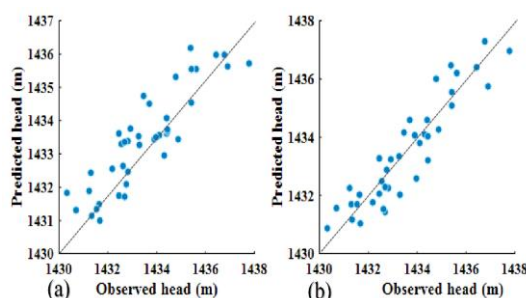
* مقادیر RMSE و MAE برای مقادیر نرمال شده محاسبه گشته‌اند.



شکل ۳- نتایج مرحله صحت‌سنجی مدل‌های ترکیبی عصبی برای پیزومتر ۲۰۷.



شکل ۴- نتایج مرحله صحت‌سنجی مدل‌های ترکیبی عصبی برای پیزومتر ۲۱۷.

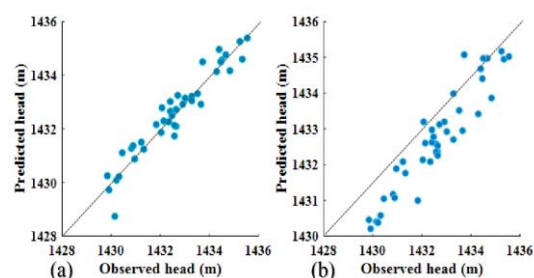


شکل ۶- دیاگرام متقابل مرحله صحت‌سنجی مدل‌های ترکیبی عصبی برای پیزومتر ۲۱۷. (a) سناریو ۱، (b) سناریو ۲.

در این تحقیق از مدل‌های جعبه سیاه برای مدل‌سازی تراوش سد خاکی ستارخان واقع در شمال غرب ایران استفاده شد. برای این منظور بر اساس دو سناریو، ارتفاعات پیزومتریک این سد مدل‌سازی شدند. در ابتدا پیزومترهای مورد نظر با مدل‌های FFNN و SVR مدل‌سازی شد و در ادامه برای افزایش کارایی مدل اقدام به ساخت داده‌های مصنوعی با استفاده از تولید نوفه براساس خواص سری‌های زمانی اصلی گردید و در ادامه با استفاده از داده‌های مصنوعی و اصلی مدل‌سازی با مدل‌های FFNN و SVR انجام شد و نتایج به دست آمده با استفاده از روش پس‌پردازش میانگین‌گیری عصبی ترکیب شد. در نهایت نتایج مورد مقایسه قرار گرفت که مقایسه نتایج به دست آمده از مدل‌های منفرد نشان داد که مدل FFNN در مرحله صحت‌سنجی نسبت به مدل SVR منفرد نتایج بهتری دارد.

مقایسه نتایج سناریوها نشان داد که استفاده از داده‌های هم‌زمان با داده‌های هدف در مدل‌سازی باعث افزایش دقت مدل می‌شود. به علاوه بررسی شد که در صورت خرابی یک پیزومتر می‌توان از داده‌های دیگر پیزومترها بر اساس سناریو ۲، در مدل‌سازی استفاده کرد.

بهره‌گیری از روش پیش‌پردازش جی‌ترینگ و روش پس‌پردازش ترکیب مدل همراه با هم باعث



شکل ۵- دیاگرام متقابل مرحله صحت‌سنجی مدل‌های ترکیبی عصبی برای پیزومتر ۲۰۷. (a) سناریو ۱، (b) سناریو ۲.

بر اساس جداول ۶ و ۷ مشاهده می‌شود که تقریباً در تمامی موارد ترکیب مدل باعث افزایش دقت و کارایی مدل‌سازی شده است. همان طور که در قسمت قبل ذکر شد برخی از مدل‌ها تخمین بالاتر و برخی تخمین پایین‌تری از مقادیر مشاهده شده ارائه داده‌اند و هر کدام از مدل‌های منفرد در مدل‌سازی 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 شده‌اند. چون در مدل ترکیبی غیرخطی از مدل FFNN استفاده شده و به علت ماهیت غیرخطی پدیده، در نتیجه مدل غیرخطی پدیده مورد بررسی را با دقت بیشتری مدل می‌کند.

در مجموع بهره‌گیری از روش پیش‌پردازش جی‌ترینگ و روش پس‌پردازش میانگین‌گیری غیرخطی عصبی باعث افزایش عملکرد مدل‌سازی AI برای پیزومترهای ۲۰۷ و ۲۱۷ تا ۱۸٪ برای مرحله آموزش و ۳۲٪ برای مرحله صحت‌سنجی شده‌اند.

به کارگیری روش پیش‌پردازش جی‌ترینگ باعث بهبود بیشتر کارایی مدل‌ها در مرحله صحت‌سنجی شد. زیرا مدل‌ها در مرحله آموزش الگوهای مختلفی را فرا می‌گیرند، در نتیجه در مرحله صحت‌سنجی دقت مدل بیشتر افزایش پیدا کرد.

نتیجه‌گیری کلی

افزایش عملکرد مدل‌سازی AI برای پیژومترهای ۲۰۷ و ۲۱۷ تا ۳۲٪ در مرحله صحت‌سنجی شد.

بهبود نتایج مدل‌سازی AI شد. به صورتی‌که در مجموع روش پیش‌پردازش جی‌ترینگ و روش پس‌پردازش میانگین‌گیری غیرخطی عصبی باعث

منابع مورد استفاده

- Barzegar R, Asghari Moghaddam A and Fijani E, 2019. Forecasting monthly water level fluctuations of Lake Urmia using supervised committee machine artificial intelligence model. *Water and Soil Science-University of Tabriz* 29(1): 165-177. (In Persian)
- Bates JM and Granger CWJ, 1969. The combination of forecasts. *Operational Research Quarterly* 20: 451-468.
- Cortes C and Vapnik V, 1995. Support-vector networks. *Machine Learning* 20: 273-297.
- Emami S, Arvanaghi H and Parsa J, 2017. Forecasting of seepage from body of earthfill dam using artificial neural network (Case study: Shahid Kazemi Boukan dam). *Journal of Dam and Hydroelectric PowerPlant* 14: 24-34. (In Persian)
- Eskandari A, Solgi A and Zarei H, 2018. Simulating fluctuations of groundwater level using combination of support vector machine and wavelet transform. *Irrigation Sciences and Engineering* 41(1): 165-180. (In Persian)
- Hornik K, Stinchcombe M and White H, 1989. Multilayer feedforward networks are universal approximators. *Neural Networks* 2(5): 359-66.
- Liu Y and Pender G, 2015. A flood inundation modeling using v-support vector machine regression model. *Engineering Applications of Artificial Intelligence* 46: 223-231.
- Moayeri MM, Nikpoor R, Hoseinzadeh Dalir A and Farsadizadeh D, 2009. Comparison of artificial neural networks, adaptive neuro-fuzzy and sediment rating curve models for estimating suspended sediment load of Ajichay River. *Water and Soil Science-University of Tabriz* 20(2): 71-82. (In Persian)
- Noori R, Karbassi AR and Moghaddamnia A, 2011. Assessment of input variables determination on the SVM model performance using PCA, gamma test and forward selection techniques for monthly stream flow prediction. *Journal of Hydrology* 401: 177-189.
- Nourani V, 2015. *Basics of Hydroinformatics*. Tabriz University Press. (In Persian)
- Nourani V and Partoviyan A, 2017. Hybrid denoising-jittering data pre-processing approach to enhance multi-step-ahead rainfall-runoff modeling. *Stochastic Environmental Research and Risk Assessment* 1-18.
- Nourani V, Sharghi E and Aminfar MH, 2012. Integrated ANN model for earthfill dams seepage analysis: Sattarkhan Dam in Iran. *Artificial Intelligence Research* 1(2): 22-37.
- Shamseldin AY, O'Connor KM and Liang GC, 1997. Methods for combining the outputs of different rainfall-runoff models. *Journal of Hydrology* 197: 203-229.
- Tayfure G, Swiatek D, Wita A and 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. (In Persian)
- Yongbiao L, 2012. Prediction methods to determine stability of dam if there is piping. *IERI Procedia* 1: 131-137.
- Yeganeh Fard M and Zahabiyoun B, 2014. Artificial flow production using artificial neural networks. *Amirkabir Journal of Science & Research* 46(1): 1-10. (In Persian)
- 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 and Jia JS, 2009. Analysis of earth dam failures: A database approach. *Georisk* 3(3): 184-189.