



برآورد مقادیر نشت از سدهای خاکی با استفاده از روش‌های هوش مصنوعی

میثم نوری^{۱*} و فرزین سلماسی^۲

^۱ - نویسنده مسئول، فارغ التحصیل کارشناسی ارشد، دانشگاه تبریز، Meysamnouri71@gmail.com

^۲ - دانشیار گروه مهندسی آب، دانشگاه تبریز.

پذیرش: ۱۳۹۶/۴/۱۰

بازنگری: ۱۳۹۶/۴/۷

دریافت: ۱۳۹۵/۱۲/۲۴

چکیده

استفاده از پتوی رسی در مخازن سدها یکی از روش‌های اصلی کاهش نشت می‌باشد. در این مطالعه ابتدا با مدل‌سازی پتوی رسی در مخزن سد توسط روش المان محدود، با استفاده از تغییر پارامترهای موثر، ۳۲۰ داده نشت به دست آمد. اعتبارسنجی روش المان محدود نیز با مقایسه نتایج نشت حاصل از روش المان محدود و نتایج آزمایشگاهی صورت گرفت. برای بررسی مناسب‌ترین مدل برای پیش‌بینی مقادیر نشت (حاصل از مدل‌سازی‌ها) از پنج روش هوش مصنوعی شامل: پرسپترون چند لایه (MLP)، برنامه‌نویسی بیان ژن (GEP)، تابع شعاعی (RBF)، رگرسیون بردار پشتیبان (SVR) و یک روش ترکیبی هوشمند از الگوریتم کرم شب‌تاب (FFA) با پرسپترون چند لایه (MLP-FFA) استفاده شد. برای همه روش‌های هوشمند مصنوعی، ۷۵ درصد داده‌ها به عنوان آموزش و ۲۵ درصد به عنوان تست در نظر گرفته شد. ترکیب‌های مختلف از داده‌های ورودی شامل نسبت ضریب نفوذپذیری پی به ضریب نفوذپذیری پتوی رسی ($\log \frac{K_f}{K_b}$)، نسبت طول پتوی رسی به تراز آب بالا دست ($\frac{L_1}{H}$)، ضخامت پی آبرفتی به ضخامت پتوی رسی ($\frac{h_f}{t}$)، طول پتوی رسی به عرض هسته ($\frac{L_1}{L_2}$) و نسبت افقی به عمودی ضریب نفوذپذیری پی آبرفتی ($\frac{K_{fx}}{K_{fy}}$) برای مقایسه روش‌های ذکر شده مورد استفاده واقع شد. نتایج حاصل از روش‌های هوشمند با شاخص‌های زیر مورد بررسی قرار گرفتند: ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب تبیین (R^2)، نش ساتکلیف (NS)، شاخص ویلموت (WI) و دیگرام تیلور. نتایج حاصل از مطالعه نشان داد که استفاده از روش هوشمند کرم شب‌تاب (FFA)، نتایج بسیار شبیه به مقادیر موجود دارد و می‌توان در بهینه‌سازی پیش‌بینی مقادیر نشت از آن استفاده کرد.

کلیدواژه‌ها: الگوریتم کرم شب‌تاب، مدل ترکیبی، پیش‌بینی نشت، سد خاکی.

مقدمه

پوشش با نفوذپذیری خیلی کم در سطح بستر رودخانه و کف مخزن و اتصال آن به هسته میانی سد است که در واقع نقش این پوشش طولانی کردن مسیر جریان و در نتیجه افزایش افت پتانسیل و کاهش انرژی آب است، این نوع پوشش، پتوی رسی نامیده می‌شود. برای استفاده از پتوی رسی باید بر اساس معیارهای موجود، مناسب‌ترین طول و ضخامت که کمترین نشت ممکن را در بر خواهد داشت استفاده شود.

اخیراً روش‌های هوش مصنوعی به منظور برآورد نشت در سدهای خاکی استفاده شده است. این روش ساده اما قوی است و می‌تواند فرآیندهای غیر خطی پیچیده را به آسانی اداره کند، به طور مثال در محث جریان در خاک اشباع و غیر اشباع به جای حل معادله‌های دیفرانسیلی حاکم (معادله ریچاردز)، با داشتن سطح آب بالادست و پایین دست و همچنین دبی نشت می‌توان مدل را آموزش داد و بدون حل معادله ریچاردز، نشت را برآورد کرد. در مسائلی که به طور کامل غیر پارامتری هستند، روش‌های هوش مصنوعی یک مزیت بزرگ است که برای پیش‌بینی روابط به

سدها و سازه‌هایی که روی پی‌های آبرفتی احداث شده‌اند در معرض نشت قرار دارند. بر اساس مطالعاتی که انجام شده است حدود ۳۰ درصد عامل خرابی‌هایی که در سدهای خاکی رخ می‌دهد به علت وقوع نشت از بدنه و پی آن‌ها می‌باشد (Rahimi, 2004). ماهیت کنترل نشت در واقع کنترل انرژی پتانسیل ذرات آب است که موجب نشت و تلفات بعدی آن می‌گردد. ایجاد هسته با نفوذپذیری کم، نشت از بدنه را به خوبی کنترل کرده و مقدار آن را کاهش می‌دهد، بنابراین مقدار نشت صورت گرفته از پی سدها بسیار بیشتر از نشتی است که از بدنه اتفاق می‌افتد. کنترل نشت از پی به منظور جلوگیری از افزایش زیرفشار و جلوگیری از آبشستگی داخلی پی صورت می‌گیرد. ممکن است با توجه به هدف پروژه مثلاً ذخیره‌سازی دراز مدت، برق آبی بودن طرح و ... مقدار مجاز نشت در هر پروژه محدود شود (USACE, 1986). یکی از روش‌های کنترل نشت از زیر سدهای خاکی که روی پی‌های آبرفتی با نفوذپذیری زیاد احداث شده‌اند، استفاده از یک لایه

در مطالعه حاضر از روش‌های هوش مصنوعی پرسپترون چند لایه (MLP)، برنامه نویسی بیان ژن (GEP)، تابع شعاعی (RBF)، رگرسیون بردار پشتیبان (SVR) و یک روش ترکیبی هوشمند از الگوریتم کرم شب‌تاب (FFA) با استفاده از پرسپترون چند لایه (MLP-FFA) برای برآورد نشت از پی سدهای خاکی که در مخزن آن پتوی رسی برای کاهش نشت اجرا شده است، استفاده شده و مدلی که نتیجه مناسب ارائه می‌دهد با استفاده از شاخص‌های ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب تبیین (R^2)، نش ساتکلیف (NS) و شاخص ویلموت (WI) مشخص شده است. در واقع با توجه به این که روش الگوریتم کرم شب‌تاب یکی از روش‌های جدید هوش مصنوعی می‌باشد، برای اولین بار در زمینه نشت مورد مطالعه قرار گرفته است.

مواد و روش‌ها

در این مطالعه مدل‌سازی‌ها توسط نرم‌افزار SEEP/W 2012 صورت گرفت. این نرم‌افزار، مبتنی بر روش المان محدود می‌باشد که برای مدل‌سازی تراوش و توزیع فشار آب‌منفذی در محیط‌های متخلخل نظیر خاک و سنگ تهیه شده است و قادر است جریان را در دو حالت اشباع و غیراشباع مدل کند (SEEP/W, 2012). نمونه مورد مطالعه سدی به صورت شکل (۱) است که در این سد K_f ضریب نفوذپذیری پتوی رسی، L_1 طول پتوی رسی، t ضخامت پتوی رسی، h_f ضخامت پی آب‌رفتی، L_2 عرض هسته رسی در محل اتصال به پی می‌باشد و آخرین پارامتر K_f ضریب نفوذپذیری پی می‌باشد که در این مطالعه سعی شده است برای انطباق بیشتر نمونه مورد مطالعه با نمونه‌های واقعی موجود، ضریب نفوذپذیری عمودی پی K_{fy} و ضریب نفوذپذیری افقی پی K_{fx} که در مطالعات نسبت این دو ضریب ۱ فرض شده است، نسبت‌های مختلفی برای این ضریب مدل‌سازی شود، به عبارتی در این تحقیق خاک غیر ایزوتروپ در نظر گرفته شده است (مطابق با واقعیت). در جدول (۱) نحوه تغییرات پارامترهای موثر نشان داده شده است. در مدل‌های طرح شده، از المان‌های مثلثی و مستطیلی به اندازه ۰/۵ متر استفاده شده است و تراز آب بالادست و پایین‌دست به عنوان شرط مرزی مدل‌ها در نظر گرفته شده است.

مقادیر ورودی و خروجی داده‌ها نیاز ندارد (Gocic et al., 2015). یکی از ویژگی‌های کلاسیک هوش مصنوعی مدل‌هایی‌اند که قادر به تجزیه و تحلیل پویایی یا تصادفی بودن متغیرهای ورودی برای پیش‌بینی نشت‌اند، پس نتایج بهتری نسبت به سایر روش‌ها (تجربی و مدل‌های فیزیکی) دارند. بسیاری از محققان روش‌های هوش مصنوعی را در سدهای خاکی اعتبار سنجی کرده‌اند. Tayfu et al. (2005) جریان داخل سدی در لهستان را به روش المان محدود و شبکه عصبی بررسی کردند. آن‌ها سطح آب در بالادست و پایین‌دست سد را به عنوان ورودی و سطح آب در داخل پی‌زومتر را به عنوان خروجی مدل عصبی قرار دادند. این محققین نتایج حاصل از مدل‌سازی شبکه عصبی را بهتر از مدل‌سازی توسط المان محدود عنوان کردند و به این نتیجه رسیدند که مدل‌سازی توسط شبکه عصبی برای بررسی سطح آب در داخل خاک، نتایج مناسبی در بر دارد. Sattar و Ahmed (2014) از برنامه نویسی بیان ژن (GEP) برای پیش‌بینی شکست سد استفاده کردند و نتایج نشان داد مدل توسعه‌یافته بیان ژن بهتر از مدل‌های مبتنی بر اساس رگرسیون است. Mert و Derin (2008) پایداری شیب سدهای خاکی را در مواقع زلزله با روش شبکه عصبی مورد بررسی قرار دادند. در مطالعه آن‌ها نه ورودی و یک خروجی استفاده شده است که خروجی مطالعه آن‌ها ضریب پایداری شیب و ورودی مطالعه زاویه شیب، ارتفاع آب، چسبندگی خاک و ... بوده است. آن‌ها با بررسی اقسام مختلف شبکه عصبی، GRNN را بهترین روش برآورد پایداری شیب سدهای خاکی عنوان کردند. Nourani و Babakhani (2013) برای مدل‌سازی نشت از سدها، از ادغام شبکه مصنوعی با روش RBF استفاده نمودند. آن‌ها به این نتیجه رسیدند که شبکه عصبی به سبب انعطاف‌پذیری آن قادر به پیش‌بینی مناسبی از مقادیر نشت خواهد بود.

به تازگی یک روش هوش مصنوعی جدید، به نام الگوریتم کرم شب‌تاب (FFA) به طور گسترده‌ای برای حل مشکل بهینه‌سازی و آموزش شبکه‌های عصبی استفاده شده است. الگوریتم کرم شب‌تاب در برخی از زمینه‌ها برای مثال، در پیش‌بینی بار الکتریکی (Kavousi et al., 2014)، بهینه‌سازی مشخصات خاک‌ها (Fu et al., 2015) و بسیاری از مسائل طراحی و مهندسی (Yang, 2010; Kazemzadehparsi, 2014; Talatahari et al., 2014) نتایج قابل قبولی در بر داشته است.




Fig. 1- Embankment dam with upstream clay blanket

شکل ۱- سد خاکی با بتوی رسی بالادست

جدول ۱- بازه تغییر پارامترهای موثر در مدل سازی ها
Table 1- Range of modeling effective parameters

Clay Blanket	Clay core	Foundation	Parameters
$10^{-6} - 10^{-9}$	-	$10^{-3} - 10^{-5}$	Permeability coefficient (m/s)
0.5 - 1.5	-	25 - 70	Thickness (m)
25 - 400	23 - 83	-	Length (m)
-	-	1 - 15	K_{fx} / K_{fy}

متوسط به ترتیب 0.0001202 متر بر ثانیه و 0.000143 متر بر ثانیه لحاظ شده است. شکل (۲) نمونه فیزیکی مورد مطالعه را نشان می‌دهد. همچنین شکل (۳) مقایسه دبی نشست حاصل از المان محدود و نتایج آزمایشگاهی را نشان می‌دهد. همان طور که شکل (۳) نشان می‌دهد نتایج نشست حاصل از مطالعه آزمایشگاهی با نتایج حاصل از نرم افزار المان محدود کاملاً با هم مطابقت دارند به طوری که ضریب تبیین $R^2=0.999$ و میانگین مربعات خطا $MSE=0.0000007$ به دست آمده است. در نتیجه استفاده از آن در طرح ها می‌تواند نتایج قابل قبولی در بر داشته باشد. همچنین USBR (2014) به عنوان معتبرترین سازمان در اصول طراحی سازه‌های آبی در نشریات خود که برای راهنمایی طراحان ارائه می‌کند در سال ۲۰۱۴ در نشریه و دفترچه راهنمای خود مدل سازی‌ها را توسط نرم افزار SEEP/W انجام داده است.

اعتبارسنجی روش المان محدود

Khalili Shayan و Amiri Tokaldani (2012) در مطالعه‌ای مقدار نشست از پی سدهای خاکی را با وجود پرده آب‌بند در پی سد به روش آزمایشگاهی مورد مطالعه قرار داده‌اند. محققان به منظور مقایسه روش‌های برآورد زیر فشار، دبی نشست و گرادیان خروجی بر مبنای داده‌های تجربی، اقدام به تکمیل مدل آزمایشگاهی موجود در آزمایشگاه هیدرولیک گروه مهندسی آبیاری و آبادانی دانشگاه تهران نموده‌اند. عرض داخلی مورد استفاده در این مطالعه ۱۸ سانتی‌متر بوده و دیواره‌های سپری به عمق ۳۰ و ۲۵ و ۲۰ و ۱۵ و ۱۰ و ۵ و ۲/۵ سانتی‌متر به طور منفرد در موقعیت‌های انتهایی بالادست، انتهای پایین دست و در فاصله‌های $0.55/0$ و $0.7/0$ و $0.85/0$ و $1.0/0$ و $1.15/0$ متر از ابتدای فلوم جابه جا گردیده است. آزمایش‌ها در بارهای آبی بالادست و برابر $2/5$ و $5/0$ و $7/5$ و $10/0$ و $12/5$ و $15/0$ و $17/5$ و $20/0$ سانتی‌متر انجام شده و هدایت هیدرولیکی خاک در جهات قائم و افقی به طور




Fig. 2- Dimensions of experimental model (Khalili Shayan and Amiri Tokaldani, 2015)

شکل ۲- ابعاد مدل آزمایشگاهی (Khalili Shayan and Amiri Tokaldani, 2015)




Fig. 3- Comparison of experimental and finite element methods for estimating seepage (Khalili Shayan and Amiri Tokaldani, 2015)

شکل ۳- مقایسه روش المان محدود و نتایج آزمایشگاهی در برآورد نشت (Khalili Shayan and Amiri Tokaldani, 2015)

در رابطه (۱)، W بردار وزن و X فضای ورودی هیلبرت است. هدف روند یادگیری، یافتن تابع f با کمترین خطا بر اساس داده‌های مستقل و با توزیع یکنواخت است که الگوریتم ϵ -SVR نامیده می‌شود. بسیاری از مطالعه‌های انجام شده توسط SVR در هیدرولیک، نشان از عملکرد بهتر این روش نسبت به سایر روش‌ها را دارد (Khan and Coulibaly, 2006).

برنامه نویسی بیان ژن (GEP)

برنامه‌نویسی بیان ژن بر اساس یک اصل ژنتیکی، که در روند تکامل در طبیعت رخ می‌دهد، یعنی بقای اصلح کار می‌کند (Khatibi et al, 2015). تناسب GEP با برآورد خطای بین مقادیر مشاهده شده و پیش‌بینی شده ارزیابی می‌شود. برنامه‌ریزی بیان ژن ویرایش جدیدی از برنامه‌ریزی ژنتیک می‌باشد که به استنتاج برنامه‌های رایانه‌ای با اندازه‌ها و شکل‌های مختلف

در مطالعه حاضر نتایج نشت حاصل از روش المان محدود توسط روش‌های هوشمند مورد مطالعه قرار گرفتند که این روش‌ها عبارت اند از:

روش رگرسیون بردار پشتیبان (SVR)

Vapnik (1999) برای ساختن شکل رگرسیونی ماشین بردار پشتیبان از تابع خطای جدیدی استفاده نمود که به نام تابع خطای ϵ -insensitive خوانده می‌شود. به این مفهوم که خطاهایی با مقادیر کمتر از ϵ متحمل جریمه نمی‌شوند. از این محدوده به نام لوله یاد می‌شود و در مسائل چند بعدی ϵ -insensitive شکلی نظیر یک دال خواهد داشت و یا این محدوده بین دو ابر صفحه موازی قرار گرفته است. توابع خطی به شکل رابطه (۱) می‌باشند (Khan and Coulibaly, 2006).

$$f(x) = (w, x) + b, \quad w, x \in X, \quad b \in R \quad (1)$$

این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نرون‌های پایه) می‌باشند که متشکل از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشند. سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود. این نوع شبکه‌ها معمولاً با عنوان پرسپترون چند لایه نامیده می‌شوند (Haykin, 1999). قاعده فراگیری پرسپترون چند لایه را "قاعده کلی دیتا" یا قاعده پس از انتشار می‌گویند. نحوه‌ی عمل پرسپترون چند لایه‌ای مشابه پرسپترون تک لایه‌ای است. به این صورت که الگویی به شبکه عرضه می‌شود و خروجی آن محاسبه می‌گردد، مقایسه خروجی واقعی و خروجی مطلوب باعث می‌گردد که ضرایب وزنی شبکه تغییر یابد به طوری که در مراحل بعد خروجی صحیح‌تری حاصل شود. وقتی به شبکه آموزش ندیده‌ای الگویی عرضه شود خروجی‌های تصادفی تولید می‌کند. ابتدا باید تابع خطایی تعریف شود که تفاوت خروجی واقعی و خروجی مطلوب را نشان دهد (Dehghani et al., 2013).

الگوریتم کرم شب‌تاب (MLP-FFA)

پیش‌بینی نشت در این مطالعه بر اساس یک مدل هیبریدی پرسپترون (MLP) یکپارچه شده با یک الگوریتم کرم شب‌تاب (FFA) است. روش FFA الهام گرفته از طبیعت، در اصل توسط Yang (2010) به عنوان یک نوع از روش‌های هوش مصنوعی مبتنی بر جنبش کرم شب‌تاب توسعه داده شد. کرم‌های شب‌تاب نورهایی تولید می‌کنند که الگوی نوری هر کدام با دیگری متفاوت است. آن‌ها به منظور جذب جفت و شکار از این نور استفاده می‌کنند، میزان این نور رابطه مستقیم با جذابیت کرم شب‌تاب دارد. با در نظر گرفتن میزان نور هر کرم به عنوان مقدار تابع هدف، می‌توان رفتار کرم‌های شب‌تاب را به صورت یک الگوریتم بهینه‌ساز مدل نمود. همان‌طور که گفته شد میزان جذابیت کرم‌های شب‌تاب (β) نسبی بوده و به فاصله بین دو کرم شب‌تاب (r) و ضریب جذب نور (γ) بستگی دارد که از رابطه (3) قابل محاسبه است:

$$\beta(r) = \beta_0 \exp(-\gamma r^2) \quad (3)$$

در این رابطه، β_0 ، میزان جذابیت کرم درخشان‌تر در $r = 0$ است. موقعیت کرم i ام پس از حرکت به سمت کرم j ام که درخشان‌تر است از رابطه (4) محاسبه می‌گردد:

$$x_i^n = x_i^{n-1} + \beta_0 e^{-\gamma r_{ij}^2} (x_j^{n-1} - x_i^{n-1}) + \alpha e_i^{n-1} \quad (4)$$

$$r_{ij} = \|x_i - x_j\| \quad (5)$$

که x_i ، موقعیت کرم شب‌تاب کم نورتر، x_j ، موقعیت کرم شب‌تاب درخشان‌تر، n شماره تکرار، α عددی تصادفی و e_i^{n-1} ،

می‌پردازد. یکی از نقاط قوت GEP آن است که معیار تنوع ژنتیکی بسیار ساده بوده و بنابراین عملگرهای ژنتیک در سطح کروموزوم عمل می‌نمایند. هم‌چنین یکی دیگر از نقاط قوت این روش، عبارت است از طبیعت منحصر به فرد چند ژنی بودن آن که زمینه ارزیابی مدل‌های پیچیده‌ای را که شامل چندین زیرمدل می‌باشند فراهم می‌آورد (Ferreira, 2001). در فرایند این روش، گام اول انتخاب تابع برازش مناسب، گام دوم انتخاب مجموعه متغیرهای ورودی و مجموعه توابع به منظور تولید کروموزوم‌ها و گام سوم انتخاب ساختار و معماری کروموزوم‌ها می‌باشد.

شبکه توابع پایه شعاعی (RBF)

شبکه RBF یک شبکه سه لایه است؛ که لایه ورودی یک بافر است. لایه دوم یا، لایه مخفی، نگاشتی غیرخطی از فضای ورودی به فضایی با ابعاد بزرگتر است که امکان جداسازی خطی الگوها را میسر می‌سازد. لایه خروجی، مجموع وزنی ساده با خروجی خطی است. اگر هدف از RBF تقریب تابع باشد، این خروجی مناسب است. اما اگر هدف دسته‌بندی الگوها باشد، باید از تابع سیگموئید استفاده نمود. ویژگی منحصر به فرد شبکه RBF فرایند انجام شده در لایه مخفی است. اگر الگوها در فضای ورودی، خوشه‌ها را تشکیل دهند و اگر مرکز این خوشه‌ها شناخته شده باشد، فاصله تا مرکز خوشه قابل محاسبه است. سنجش مسافت به صورت غیرخطی انجام می‌شود. بنابراین، اگر الگو در ناحیه نزدیک مرکز خوشه باشد، مقدار آن نزدیک به یک خواهد بود. اطراف این ناحیه، مقدار مذکور به شدت کاهش می‌یابد. این ناحیه اطراف مرکز خوشه، متقارن است، به گونه‌ای که تابع غیرخطی شناخته شده که معمول‌ترین تابع آن، تابع گوسین است. مسافت از مرکز خوشه‌ها به صورت مسافت اقلیدسی محاسبه می‌گردد. وزن‌های ورودی به هر نرون در لایه مخفی، مختصات مرکز خوشه است. بنابراین، زمانی که یک نرون، الگوی ورودی نظیر X را دریافت می‌کند، مسافت از مرکز خوشه از رابطه (2) به دست می‌آید:

$$r_j = \sqrt{\sum (X_i - w_{ij})^2} \quad (2)$$

این شبکه در مقایسه با شبکه MLP به نرون بیشتری نیاز دارد؛ اما طراحی آن سریع‌تر از شبکه MLP بوده و این شبکه در مقایسه با شبکه عصبی سریع‌تر آموزش می‌بیند. با تعداد نرون کافی می‌توان هر تابع منطقی را به طور تقریبی نشان داد.

شبکه عصبی (MLP)

شبکه‌های چند لایه پیشخور (Multi-layer perceptron) یکی از مهم‌ترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشد

$$NS = \left| 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2} \right|, 0 \leq NS \leq 1 \quad (6)$$

۲- جذر میانگین مجموع مربع خطاها:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (7)$$

۳- میانگین قدر مطلق خطاها:

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i| \quad (8)$$

۴- شاخص ویلموت:

$$WI = \left| 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \right| \quad (9)$$

شاخص ویلموت یک شاخص توصیفی است که مقدار آن از یک تا ∞ می‌باشد و هرچه به یک نزدیکتر باشد می‌توان مدل را مناسب ارزیابی نمود و در این صورت سازگاری مدل مناسب می‌باشد. روش دیگری که برای ارزیابی مدل‌ها استفاده شده است استفاده از دیاگرام تیلور می‌باشد (Taylor, 2001). Taylor دیاگرامی را با استفاده از شاخص‌های مختلف از جمله $RMSE$ و ضریب همبستگی برای ارزیابی عملکرد مدل‌ها ارائه کرد. دیاگرام تیلور به صورت یک سری از نقاط در یک طرح قطبی ارائه می‌شود که نقاط مدل‌های مختلف در آن وجود دارد و هر روشی که نقطه مربوط به آن به نقطه مرجع (دبی) مشاهده شده در این مسئله) نزدیکتر باشد دقیق‌ترین نتایج را در بر دارد.

نتایج و بحث

بر اساس شبکه‌بندی مستطیلی و مثلثی صورت گرفته به تعداد ۱۵۰/۰۰۰ المان در نرم‌افزار SEEP/W پارامترهای بی‌بعد ذکر شده، مقادیر نشت به دست آمدند. مقادیر نشت به دو دسته تقسیم شدند: داده‌ها برای آموزش شبکه (۲۳۹ مقدار نشت یا ۷۵ درصد کل مقادیر) و داده‌هایی برای آزمون شبکه (۸۰ مقدار نشت یا ۲۵ درصد از کل مقادیر). جدول (۲) مشخصات آماری پارامترهای ورودی را که شامل آزمون و آموزش است نشان می‌دهد. جدول (۳) نتایج حاصل از مقایسه مدل‌ها با روش‌های آماری را نشان می‌دهد. همان‌طور که از جدول (۳) مشخص است از بین مدل‌های مورد ارزیابی، الگوریتم کرم شبتاب (FFA) با داشتن بیشترین مقادیر R^2 (در بخش تست: ۰/۹۱۹، در بخش آموزش: ۰/۹۵۹) و شاخص ویلموت WI (در بخش تست: ۰/۹۵۹، در بخش

یک بردار از اعداد تصادفی است که می‌تواند دارای توزیع یکنواخت یا گوسی باشد. قسمت سوم رابطه (۴)، ترم تصادفی رابطه محسوب می‌شود که باعث جستجوی جامع‌تر فضای تصمیم مسئله توسط الگوریتم می‌شود. جذب کرم‌های شبتاب تا جایی ادامه پیدا می‌کند که آن‌ها به سمت درخشان‌ترین کرم موجود جذب شوند، در واقع این کرم بهترین مقدار را برای تابع هدف ما ایجاد می‌کند.

در مطالعه ارائه شده ابتدا یک پتوی رسی در مخزن سد خاکی طراحی شد. پارامترهای متغیر مورد مطالعه، K_b ضریب نفوذپذیری پتوی رسی، L_1 طول پتوی رسی، t ضخامت پتوی رسی، h_f ضخامت پی آبرفتی، L_2 عرض هسته رسی در محل اتصال به پی می‌باشد و K_f ضریب نفوذپذیری پی آبرفتی می‌باشد که با لحاظ کردن مقادیر واقعی برای آن‌ها طرح‌های مختلف پتوی رسی با طول‌ها، ضخامت‌ها و ضریب نفوذپذیری مختلف، مدل‌سازی صورت گرفت. نتایج حاصل از مدل‌سازی‌ها ۳۲۰ داده نشت با طرح پتوی رسی در مخزن سد بود. برای پی بردن به این نکته که کدام مدل هوشمند می‌تواند برآورد بهتری از نشت داشته باشد، مقادیر نشت توسط این مدل‌ها مورد بررسی قرار گرفت. در واقع مدلی که بتواند نتایج قابل قبولی ارائه دهد می‌تواند با توجه به اعتبارسنجی صورت گرفته آلمان محدود با مقادیر آزمایشگاهی، در طراحی‌های پتوی رسی مورد استفاده قرار بگیرد و طراح می‌تواند با تکیه بر آن، طرحی از پتوی رسی را ارائه کند که کم‌ترین مقدار نشت را در بر داشته باشد. برای سهولت در استفاده پارامترهای ورودی به مدل‌های هوشمند به صورت بی‌بعد وارد مدل‌ها گردیدند. پارامترهای ورودی برای همه مدل‌ها یکسان بوده و شامل: نسبت ضریب نفوذپذیری پی به ضریب نفوذپذیری پتوی رسی $(\frac{K_f}{K_b})$ ، نسبت طول پتوی رسی به هد آب بالادست $(\frac{L_1}{H})$ ، ضخامت پی به ضخامت پتوی رسی $(\frac{h_f}{L_2})$ ، طول پتوی رسی به عرض هسته $(\frac{L_1}{L_2})$ و نسبت افقی به عمودی ضریب نفوذپذیری پی آبرفتی $(\frac{K_{fx}}{K_{fy}})$ می‌باشد. هم‌چنین مقدار نشت نهایی به دست آمده نیز به صورت بی‌بعد $\frac{q}{K_f \cdot h_f}$ به مدل‌ها معرفی شد.

معیارهای ارزیابی مدل‌ها

معیارهایی که مقایسه مدل‌ها توسط آن‌ها صورت می‌گیرد، در زیر ارائه شده‌اند. در روابط ارائه شده، P_i ، O_i مقادیر مشاهده شده و برآورد شده نشت، N تعداد برآوردها و \bar{O} میانگین مقادیر مشاهده شده می‌باشد.

۱- شاخص نش ساتکلیف: شاخص نش ساتکلیف نشان دهنده کارایی مدل می‌باشد و هر چه نزدیک تر به یک باشد نشان دهنده کارایی مناسب مدل و تطابق داده‌های ورودی و خروجی از مدل‌ها می‌باشد.

RBF و GEP دارای ضعیف‌ترین نتیجه در بین مدل‌های مورد مطالعه می‌باشند. نمودار پراکنندگی برای هر کدام از روش‌ها و همچنین دیگرام تیلور برای روش‌ها تهیه شده است که در اشکال (۴) تا (۹) نشان داده شده‌اند.

آموزش (۰/۹۵۴) و کمترین مقدار خطاها شامل MAE (در بخش تست: ۰/۰۰۳، در بخش آموزش: ۰/۰۰۵) و RMSE (در بخش آموزش و تست: ۰/۰۰۶) دقیق‌ترین نتایج را دارا می‌باشد به طوری که مشخص است مقادیری نزدیک به مقادیر واقعی می‌تواند داشته باشد. نکته دیگری که از جدول مشخص است این است که مدل

جدول ۲- مشخصات آماری پارامترها و مقادیر نشت

Table 2- Statistical properties of parameters and seepage values

Data set	Statistics	$\frac{h_f}{t}$	$\frac{K_{fx}}{K_{fy}}$	$\frac{L_1}{L_2}$	$\frac{L_1}{H}$	$\log \frac{K_f}{K_b}$	$\frac{q}{K_f h_f}$
All data	Average	83.63	3.19	7.59	4.14	3.12	0.08
	Standard deviation	23.23	4.27	2.85	1.51	0.8	0.01
	Maximum value	140	15	17.39	8	7	0.13
	Minimum value	16.66	1	0.6	1	0.6	0.03
	Correlation with $\frac{q}{K_f h_f}$	-0.232	-0.404	-0.026	-0.143	-0.404	1
Train data	Average	36.87	3.02	7.52	4.14	3.1	0.08
	Standard deviation	21.25	4.17	2.89	1.55	0.82	0.01
	Maximum value	140	15	17.39	8	7	0.1
	Minimum value	16.66	1	0.6	1	0.6	0.05
	Correlation with $\frac{q}{K_f h_f}$	-0.21	-0.397	-0.007	-0.111	-0.399	1
Test data	Average	43.89	3.71	7.81	4.13	3.17	0.08
	Standard deviation	27.82	4.54	2.72	1.39	0.74	0.01
	Maximum value	140	15	17.369	8	6	0.13
	Minimum value	16.66	1	1.16	1	1.69	0.03
	Correlation with $\frac{q}{K_f h_f}$	-0.24	-0.407	-0.056	-0.243	-0.426	1

جدول ۳- نتایج حاصل از مقایسه مدل‌های مورد استفاده

Table 3- Results of used models comparison

Models	Parameters	Training					Testing				
		RMSE	MAE	NS	WI	R ²	RMSE	MAE	NS	WI	R ²
MLP	neuron=5	0.007	0.005	0.796	0.939	0.796	0.009	0.006	0.755	0.913	0.794
RBF	neuron=5, spread=20	0.015	0.012	0.069	0.3	0.069	0.018	0.013	0.083	0.417	0.133
SVR	$\gamma=31.58$, $\sigma=8.95$	0.006	0.004	0.821	0.947	0.822	0.013	0.007	0.502	0.804	0.536
GEP	GN=3000	0.014	0.011	0.147	0.45	0.149	0.017	0.012	0.144	0.513	0.175
MLP-FFA	neuron=5	0.006	0.005	0.836	0.954	0.959	0.006	0.003	0.875	0.959	0.919




Fig 4- Performance of the RBF model

شکل ۴- عملکرد مدل RBF

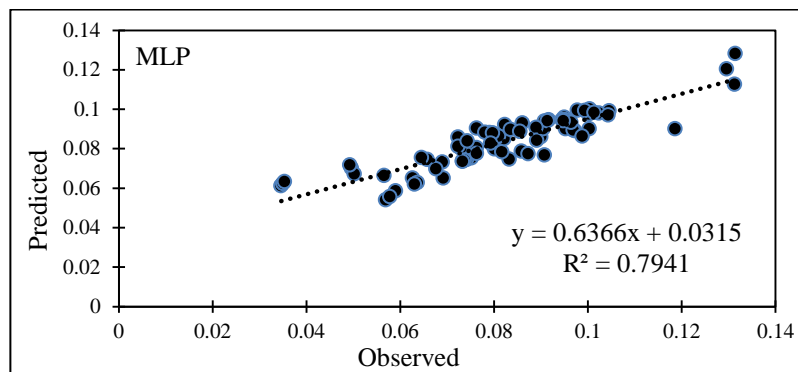


Fig 5- Performance of the MLP model

شکل ۵- عملکرد مدل MLP




Fig 6- Performance of the GEP model

شکل ۶- عملکرد مدل GEP




Fig 7- Performance of the SVR model

شکل ۷- عملکرد مدل SVR




Fig 8- Performance of the FFA model

شکل ۸- عملکرد مدل FFA




Fig 9- Taylor diagram for models evaluating

شکل ۹- دیاگرام تیلور برای ارزیابی مدل‌ها

مورد بحث محاسبه گردیده و نتیجه کار به صورت نقاط دایره‌ای رنگی روی شکل (۹) ارائه گردیده‌اند. در این دیاگرام نقطه مرجع نقطه دبی‌های مشاهده شده است و هر نقطه‌ای که به نقطه مرجع نزدیکتر باشد مقادیر دقیق‌تری را دربر دارد. با توجه به شکل (۹) نزدیکترین نقطه به نقطه مرجع نقطه مربوط به FFA است که شامل بهترین نتایج است.

همان‌طور که شکل (۸) و جدول (۳) نشان می‌دهد دقت دبی‌های برآورد شده توسط الگوریتم شب‌تاب از سایر روش‌ها بیش‌تر است. سپس با استفاده از انحراف معیار و ضریب تبیین R^2 مقادیر نشت مشاهده شده و مقادیر برآورد شده در غالب دیاگرام تیلور مورد تجزیه و تحلیل قرار گرفتند. شکل (۹) روش‌های مورد مطالعه را با دیاگرام تیلور مورد مقایسه قرار داده است. در دیاگرام تیلور محورهای افقی و عمودی هر دو انحراف از معیار، قطاع‌های سیاه رنگ ضریب همبستگی و قطاع‌های قهوه‌ای ریشه میانگین مربعات خطا را نشان می‌دهند. این عوامل برای روش‌های پنجگانه

نتیجه گیری

ترکیبی هوشمند از الگوریتم کرم شب تاب (FFA) مورد استفاده قرار گرفت. مدل‌ها با شاخص‌های آماری رایج و دیاگرام تیلور مقایسه شدند. نتایج نشان داد که مدل ترکیبی هوشمند الگوریتم کرم شب تاب (MLP-FFA) مقادیر نشت را با کمترین خطا و بالاترین دقت پیش‌بینی می‌کند به طوری که ضریب تبیین (R^2) ۰/۹۵ و کمترین مقدار خطاها شامل MAE (در بخش تست: ۰/۰۰۳، در بخش آموزش ۰/۰۰۵) و RMSE (در بخش آموزش و آزمون: ۰/۰۰۶) حاصل شد. همچنین مدل‌های شبکه عصبی توابع شعاعی RBF و برنامه‌ریزی بیان ژن GEP دارای ضعیف‌ترین نتایج در برآورد مقادیر نشت بودند. نکته‌ای که باید به آن اشاره شود این است که روش‌های هوش مصنوعی بسته به معادله‌های حاکم بر مسئله و ارتباط بین پارامترها و ... می‌تواند نتایج متفاوتی را در بر داشته باشد و نتایج قابل قبول یک روش در بررسی یک مسئله خاص، نمی‌تواند در بررسی سایر مسائل قابل اتکا باشد.

سپاسگزاری

نویسندگان مقاله از زحمات و همکاری صمیمانه جناب آقای دکتر محمدعلی قربانی (دانشیار گروه مهندسی آب دانشگاه تبریز) سپاسگزاری می‌نمایند.

با بررسی تأثیر پتوی رسی بر مقادیر نشت از پی مخزن سد مورد مطالعه، پارامترهای مهم و تأثیرگذار مورد تجزیه و تحلیل قرار گرفتند (جدول ۲). مشاهدات حاصل از نتایج این بررسی‌ها نشان‌دهنده همبستگی بالای ضریب نفوذپذیری پتوی رسی و پی آبرفتی با مقادیر نشت می‌باشد. به نحوی که از بین پارامترهای ذکر شده، بیشترین تأثیر بر مقادیر نشت را نسبت افقی به عمودی ضریب نفوذپذیری پی آبرفتی ($\frac{K_{fx}}{K_{fy}}$) دارا می‌باشد. این در حالی است که در مطالعه‌های اخیر و معمول، این ضریب یک در نظر گرفته شده است و معمولاً خاک ایزوتروپ فرض شده است که این با واقعیت مطابقت ندارد و می‌تواند نتایج غیر قابل قبولی در بر داشته باشد. همچنین به‌عنوان یک نکته مهم که حاصل بررسی مدل‌ها است می‌توان به این موضوع اشاره کرد که افزایش ضریب نفوذپذیری در پتوهای ضخیم‌تر، تأثیر بیشتری دارد و چنانچه در یک پتوی رسی با ضخامت کم، نفوذپذیری کم شود تأثیر قابل ملاحظه‌ای بر مقدار نشت نخواهد داشت. در مطالعه ارائه شده برای برآورد مقادیر نشت از مدل‌های هوشمند که شامل: پرسپترون چند لایه (MLP)، برنامه نویسی بیان ژن (GEP)، تابع شعاعی (RBF)، رگرسیون بردار پشتیبان (SVR) و یک روش

References

- 1- Ahmed, M. and Sattar, A., 2014. Gene expression models for prediction of dam breach Parameter. *Journal of Hydroinformatics*, 16(3), pp. 550-571.
- 2- Dehghani, N., Pirmoradian, N., Azimi, V. and Khanmohammady, S., 2013. Evaluation of MLP and RBF for estimating of monthly evaporation, case study: Rasht meteorological station. In *2th National Conference on Sustainable Agriculture and Sustainable Environment*, (In Persian).
- 3- Derin, U. and Mert tolon, S. M., 2008. Slope Stability during Earthquakes: A Neural Network Application. *Geo Congr. Characerization, Monitoring and Modeling of Geosystems*, pp. 878-2008.
- 4- Ferreira, C., 2001. Gene expression programming: A new adaptive algorithm for solving problems. *Complex Systems*, 13(2), pp. 87-129.
- 5- Fu, Q., Jiang, R., Wang, Z. and Li, T., 2015. Optimization of soil water characteristic curves parameters by modified firefly algorithm. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 31(11), pp. 117-122.
- 6- Gocic, M., Petkovic, M., Trajkovic, S., Shamshirband, S. H., Moetamedi, S. H. and Roslan, H., 2015. Determination of the most influential weather parameters on reference evapotranspiration by adaptive neuro-fuzzy methodology. *Computers and Electronics in Agriculture*, 114(1), pp. 277-284.
- 7- Haykin, S., 1999. *Neural Networks: A Comprehensive Foundation*. Prentice-Hall Inc.NJ.
- 8- Kavousi, A., Samet, H. and Marzbani, F., 2014. A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting. *Expert Systems with Applications*. 41(2), pp. 6047-6056.

- 9- KazemzadehParsi, M., 2014. A modified firefly algorithm for engineering design optimization problems. *Iranian Journal of Science and Technology*, 38(1), pp. 403-421.
- 10- Khalili Shayan, H. and Amiri Tokaldany, E., 2015. Effects of blanket, drains, and cutoff wall on reducing uplift pressure. Seepage, and exit gradient under hydraulic structures. *International Journal of Civil Engineering*, 13(4), pp. 486-500.
- 11- Khalili Shayan, H. and Amiri Tokaldani, E., 2012. Experimentally and numerically investigation of Bligh and Lane theory for estimating uplift under diversion dams. In *10th Hydraulic conference, Gilan University, Gilan, Iran*, (In Persian).
- 12- Khan, M. S. and Coulibaly, P., 2006. Bayesian neural network for rainfall-runoff modeling. *Water Resources Research*, 42, doi: 10.1029/2005WR003971. issn: 0043-1397, pp. 1-18.
- 13- Khatibi, A., Pourebrahim, S. H. and Danehkar, A., 2015. Application of Genetic Algorithm for Simulation of Land Use and Land Cover Changes; Case of Karaj City, Iran. *Journal of Tethys*, 3(4), pp. 286-296.
- 14- Nourani, V. and Babakhani, A., 2013. Integration of Artificial Neural Networks with Radial Basis Function Interpolation in Earthfill Dam Seepage Modeling. *Journal of Computing in Civil Engineering*. 27(1), pp.183-195.
- 15- Rahimi, H., 2004. *Embankment Dams*, Tehran University Press, (In Persian).
- 16- SEEP/W., 2012. *Seepage Modeling with SEEP/W*. Geo-Slope International Ltd, Calgary.
- 17- Talatahari, S., Hosseini, A., Mirghaderi, S. R. and Rezazadeh, F., 2014. Optimum Performance-Based Seismic Design Using a Hybrid Optimization Algorithm. *Hindawi Publishing Corporation Mathematical Problems in Engineering*. Volume 2014, Article ID 693128, 8 pages.
- 18- Tayfu, G., Swiate, D., Wita, A. and Singh, V., 2005. Case Study: Finite Element Method and Artificial Neural Network Models for Flow through Jeziorsko Earth fill Dam in Poland. *Journal of Hydraulic Engineering*, 131(3), pp. 431-440.
- 19- Taylor, KE., 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research*, 106 (7), pp.7183-7192.
- 20- USACE., 1986. *Seepage analysis and control for dams*. Department of the US army corps of Engineers, Washington, D.C. 20314-1000.
- 21- USBR., 2014. *Embankment dams, chapter 8, seepage, phase 4*. U. S. Department of Interior Bureau of Reclamation.
- 22- Vapnik, VK., 1999. An Overview of Statistical Learning Theory. *IEEE Transactions on Neural Network*, 10(1), pp. 988-998.
- 23- Yang, X. S. 2010. Firefly Algorithm, Stochastic Test Functions and Design Optimisation. *International Journal of Bio-Inspired Computation*, 2(2), pp. 78-84.