



Research Article

Determining the Discharge Coefficient of Lateral Overflows Using Neural Network

Hossein Montaseri*¹, Reza Khalili², Mehdi Malek Mahmmoudi³

1- Assistant Professor, Department of Civil Engineering, Water Resources Engineering and Management, Yasouj University

2- Master's degree in Civil Engineering, Water Resources Engineering and Management, Yasouj University

3- Master's degree in Civil Engineering, Water Resources Engineering and Management, Yasouj University

Received: 01 August 2022; Revised: 05 September 2022; Accepted: 28 September 2022; Published: 28 September 2022

Abstract

Side weirs are flow diverting structures that are widely used in irrigation and drainage industry, flood control, sanitary engineering and urban sewage systems. So far, the discharge coefficient in this type of overflows has been determined experimentally using regression techniques, and for this reason, in this research, linear regression models and artificial neural network were used to predict the discharge coefficient of the lateral overflow, and their results are in agreement with each other and with Computational values were compared and the best model in this field was selected for prediction. The discharge coefficient of lateral spillways is based on several combinations of dimensionless independent variables including the ratio of length to width of the spillway (L/B), the ratio of the flow depth downstream of the spillway to the height of the spillway (Hd/P), the ratio of the length of the spillway to the height of the spillway (L/P), the ratio of weir discharge flow to upstream flow (Qw/Qu) and the ratio of flow depth upstream of weir to weir width (Hu/B) were predicted. ANN7 model with inputs L/P , Qw/Qu , hu/B has the highest value of regression coefficient equal to 0.92 and RMSE and MAE error values equal to 0.23 and 0.15 performed the best prediction. Reg1 model with the values of regression coefficient, RMSE and MAE equal to 0.72, 0.17 and 0.11, respectively, it created the best results in prediction and was selected as the best linear regression model. The general results showed that ANN models compared to linear regression produces better results.

Keywords:

Side overflows, Neural network, Discharge coefficient, ANN model

Cite this article as: Montaseri, H., Khalili, R., Malek mahmudi, M. (2022). Determining the Discharge Coefficient of Lateral Overflows Using Neural Network. Civil and Project Journal, 4(4), 72–84.
<https://doi.org/10.22034/cpj.2022.354288.1147>

ISSN: 2676-511X / **Copyright:** © 2022 by the author.

Open Access: This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. If material is not included in the article's Creative Commons licence and your intended use is not permitted by statutory regulation or exceeds the permitted use, you will need to obtain permission directly from the copyright holder. To view a copy of this licence, visit <https://creativecommons.org/licenses/by/4.0/>

Journal's Note: CPJ remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.



نشریه عمران و پروژه

<http://www.cpjournals.com/>

تعیین ضریب تخلیه سرریزهای جانبی با استفاده از شبکه عصبی

حسین منتصری^{۱*}، رضا خلیلی^۲، مهدی ملک محمودی^۳

- ۱- استادیار گروه مهندسی عمران، مهندسی و مدیریت منابع آب، دانشگاه یاسوج
- ۲- کارشناس ارشد، مهندسی عمران گرایش مهندسی و مدیریت منابع آب، دانشگاه یاسوج
- ۳- کارشناس ارشد، مهندسی عمران گرایش مهندسی و مدیریت منابع آب، دانشگاه یاسوج

تاریخ دریافت: ۱۰ مرداد ۱۴۰۱؛ تاریخ بازنگری: ۱۴ شهریور ۱۴۰۱؛ تاریخ پذیرش: ۰۶ مهر ۱۴۰۱؛ تاریخ انتشار آنلاین: ۰۶ مهر ۱۴۰۱

چکیده

سرریزهای جانبی (Side weirs)، سازه‌های منحرف‌کننده جریان هستند که در صنعت آبیاری و زهکشی، کنترل سیلاب، مهندسی بهداشت و سیستم‌های فاضلاب شهری کاربرد فراوانی دارند. تاکنون ضریب دبی در این نوع سرریزها با استفاده از تکنیک‌های رگرسیون و به صورت تجربی تعیین شده است و به همین دلیل در تحقیق حاضر از مدل‌های رگرسیون خطی و شبکه عصبی مصنوعی برای پیش‌بینی ضریب تخلیه سرریز جانبی استفاده شد و نتایج آن‌ها با یکدیگر و با مقادیر محاسباتی مقایسه و بهترین مدل در این زمینه برای پیش‌بینی انتخاب شد. ضریب تخلیه سرریزهای جانبی بر اساس ترکیبات متعددی از متغیرهای مستقل بی‌بعد شامل نسبت طول به عرض سرریز (L/B)، نسبت عمق جریان در پایین دست سرریز به ارتفاع سرریز (Hd/P)، نسبت طول سرریز به ارتفاع سرریز (L/P)، نسبت دبی تخلیه سرریز به دبی بالادست (Qw/Qu) و نسبت عمق جریان در بالادست سرریز به عرض سرریز (Hu/B) پیش‌بینی شد. مدل ANN7 با ورودی‌های L/P ، Qw/Qu ، hu/B دارای بیشترین مقدار ضریب رگرسیون برابر با ۰/۹۲ و مقادیر خطای RMSE و MAE برابر با ۰/۲۳ و ۰/۱۵ و بهترین پیش‌بینی را انجام داد. مدل Reg1 با مقادیر ضریب رگرسیونی، RMSE و MAE به ترتیب برابر با ۰/۷۲، ۰/۱۷ و ۰/۱۱ بهترین نتایج را در پیش‌بینی ایجاد کرد و به عنوان بهترین مدل رگرسیون خطی انتخاب گردید. نتایج کلی نشان داد که مدل‌های ANN نسبت به مدل‌های رگرسیون خطی نتایج بهتری را ایجاد می‌کنند.

کلمات کلیدی:

سرریزهای جانبی، شبکه عصبی، ضریب تخلیه، مدل‌های ANN

۱. مقدمه

سرریزهای جانبی^۱، سازه‌هایی هستند که در کنار یک آبراهه یا کانال نصب می‌شوند و هنگامی که ارتفاع جریان از تاج آن فراتر رود، جریان از روی آن عبور کرده و وارد کانال فرعی می‌شود (Watanabe *et al.*, 2020). در معمول‌ترین نوع سرریزهای جانبی، سرریز به صورت موازی جهت جریان در کانال اصلی قرار می‌گیرد، که در این حالت کانال انتقال دارای زاویه قائمه نسبت به کانال اصلی می‌باشد (Akbar *et al.*, 2022). علم مهندسی آب، در قرن اخیر پیشرفت سریع در امر محاسبات دقیق داشته است (Khalili *et al.*, 2021). با پیشرفت در این امور هزینه‌ها به سمت حداقل و دقت پروژه‌ها به سمت حداکثر میل می‌نماید. تخمین میزان دبی عبوری در علوم آب مهم‌ترین و شاید پیچیده‌ترین مبحث است (Chuengsatiansup *et al.*, 2022). چراکه میزان دبی عبوری با عوامل مختلفی از قبیل: شیب، زبری، سطح مقطع، رسوب و غیره ارتباط دارد. بنابراین در تأسیسات مختلف انتقال و توزیع آب باید تخمین دقیق‌تری از دبی عبوری انجام پذیرد. چنانچه سرریز جانبی در دیواره یک کانال نصب شود که ارتفاع آن کمتر از ارتفاع کانال باشد، در هنگام بالا آمدن سطح آب، قسمتی از جریان از روی سرریز به صورت جانبی منحرف و به خارج از کانال اصلی تخلیه می‌گردد (Mouritsen, Pedraza-Acosta and Thrane, 2022). جریان حاکم بر این نوع سرریزها از نوع جریان (زیربحرانی و یا فوق بحرانی) و ابعاد سرریز ممکن است به صورت افزایشی و یا کاهش‌ی باشد (Gamero *et al.*, 2022). در سال‌های اخیر تحقیقات زیادی در زمینه ضریب تخلیه سرریزها با استفاده از شبکه‌های عصبی مصنوعی صورت گرفته است.

قبادیان و شفاهی در سال ۲۰۱۹ به بهینه‌سازی ضریب تخلیه سرریزهای جانبی در کانال‌های آبیاری با استفاده از شبکه‌های عصبی مصنوعی پرداختند آن‌ها از شبکه عصبی مصنوعی پرسپترون چندلایه با قانون یادگیری پس انتشار و تکنیک حداقل مربعات خطا استفاده کردند که این ضریب هم طراحی سرریزهای جانبی را با ایجاد سبک غیرخطی بین پارامترهای و تاثیر بر آن، از قبیل عدد فرود جریان در بالادست سرریز، ارتفاع سرریز به عمق جریان، طول سرریز به عمق جریان، ارتفاع جریان روی تاج سرریز به ارتفاع سرریز و پهنای کانال به عمق جریان را تعیین می‌نماید. مقایسه‌های آماری نتایج حاصل از شبکه عصبی مصنوعی با دوازده روش تجربی موجود نشان داد که شبکه عصبی مصنوعی قادر است با دقت بالاتری ضریب تخلیه سرریزهای جانبی را تعیین نماید (Qabadian and Shafa'i Bejestan, 2019).

یاسر مهری و نادر عباسی در سال ۱۳۹۹ به برآورد ضریب تخلیه سرریز جانبی کلید پیانویی تیپ B در انحنای ۱۲۰ درجه با استفاده از مدل‌های RBF و ANFIS و مقایسه با شبکه عصبی ANN پرداختند. در این پژوهش آن‌ها در ابتدا به بررسی آزمایشگاهی بر روی سرریز جانبی کلید پیانویی تیپ B در قطاع ۱۲۰ درجه پرداختند و ضریب تخلیه این سرریزها برای هر آزمایش استخراج شد، سپس توانایی مدل ANFIS و RBF و شبکه عصبی ANN در پیش‌بینی ضریب تخلیه سرریز مورد ارزیابی قرار دادند. برای این منظور دو مدل RBF و ANFIS در محیط نرم‌افزار MATLAB کد نویسی شد. تحلیل نتایج به دست آمده نشان داد، هر دو مدل RBF و ANFIS دارای دقت بالاتری نسبت به شبکه عصبی ANN هستند. همچنین مشخص شد که مدل RBF با $RMSE=0.044$ و $R^2=0.974$ دارای دقت بالاتری نسبت به مدل هوشمند ANFIS با $RMSE=0.0529$ و $R^2=0.891$ است (mehri and Abbasi, 2020).

بیلهان و همکاران در سال ۲۰۱۱ به بررسی استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی ضریب دبی سرریز جانبی لایبرنت مثلثی در کانال‌های منحنی پرداختند، آن‌ها عملکرد مدل ANN با چندین مدل رگرسیون غیرخطی و خطی مورد مقایسه قرار دادند و همچنین از آمار ریشه میانگین مربعات خطا (RMSE)، میانگین خطاهای مطلق (MAE) و ضریب همبستگی (R) به عنوان معیارهای مقایسه برای ارزیابی عملکرد مدل‌ها استفاده کردند. بر اساس مقایسه‌ها، مشخص شد که تکنیک محاسبات عصبی می‌تواند با موفقیت در مدل‌سازی ضریب تخلیه از داده‌های تجربی موجود استفاده شود و توافق خوبی بین مقادیر

¹ Side weirs

اندازه‌گیری شده و مقادیر به دست آمده با استفاده از مدل ANN وجود داشت. مشخص شد که مدل ANN با $RMSE=0.1658$ در مرحله اعتبارسنجی در برآورد ضریب دبی نسبت به مدل‌های رگرسیون غیرخطی و خطی چندگانه با $RMSE$ به ترتیب 0.2054 و 0.2926 برتری دارد (Bilhan, Emiroglu and Kisi, 2011).

هوا و همکاران در سال ۲۰۲۱ استفاده از محاسبات نرم و الگوریتم‌های یادگیری ماشین برای پیش‌بینی ضریب تخلیه سرریزهای هزارتوی منحنی مورد بررسی قرار دادند و هدف تحقیق آن‌ها برآورد ظرفیت سرریز یک هزارتوی منحنی با استفاده از مدل‌های پیش‌بینی هوشمند مختلف، یعنی سیستم استنتاج فازی-عصبی تطبیقی، ماشین بردار پشتیبان، درخت مدل M5، ماشین بردار پشتیبان حداقل مربعات و پشتیبانی حداقل مربعات بود. نتایج نشان داد که می‌توان به پارامترهای ورودی برای پیش‌بینی ضریب دبی تکیه کرد. به‌طور کلی، مدل LSSVM-BA بهترین دقت پیش‌بینی را در طول مراحل آموزش و آزمون نشان داد. چنین مدل پیش‌بینی کم‌هزینه‌ای ممکن است کاربرد عملی قابل توجهی داشته باشد، زیرا می‌تواند یک جایگزین اقتصادی برای راه‌حل آزمایشگاهی گران‌قیمت باشد که پرهزینه و زمان‌بر است (Hu et al., 2021).

صفر و همکاران در سال ۲۰۲۱ به پیش‌بینی دبی سرریز جانبی در کانال‌های همگرا با استفاده از شبکه‌های عصبی مصنوعی پرداختند و پارامترهای هندسی: طول سرریز، ارتفاع سرریز، زاویه همگرایی و عرض کانال پایین دست مورد بررسی قرار دادند و سه مدل شبکه عصبی برای تخمین دبی از سرریز جانبی استفاده شد. مدل‌ها با استفاده از MATLAB ساخته شد و متغیرهای بدون بعد که نسبت‌های هندسی و هیدرولیکی مدل بودند به‌عنوان پارامترهای ورودی انتخاب شدند. چهار نسبت به‌عنوان ورودی مدل برای تخمین ضریب دبی و دبی از سرریز انتخاب شد. با در نظر گرفتن خروجی‌های مدل، شبکه‌های عصبی-فازی کمترین خطا را نسبت به مدل‌های دیگر دارند و این مدل دبی سرریز شدن سرریز جانبی را با دقت ۹۹.۸ درصد برآورد می‌کند (Saffar et al., 2021).

نادر پور و همکاران در سال ۲۰۲۰

در این پژوهش جهت پیش‌بینی ضریب تخلیه سرریز جانبی از مدل‌های رگرسیون خطی و شبکه عصبی مصنوعی استفاده شد و نتایج آن‌ها با یکدیگر و با مقادیر محاسباتی مقایسه شد و در نهایت بهترین مدل در این زمینه برای پیش‌بینی انتخاب شد.

۲. مواد و روش‌ها

۱.۲. تحلیل ابعادی در سرریزهای جانبی

به‌منظور بررسی و شناخت رفتار هیدرولیکی جریان در سرریزهای جانبی و نیز ضریب تخلیه سرریزهای جانبی، استفاده از تحلیل ابعادی و ساخت گروه‌های بی‌بعد ضروری به نظر می‌رسد. با بی‌بعد کردن پارامترها به‌جای متغیرهای اصلی با بعد، از تعداد کمتری متغیر بدون بعد استفاده می‌شود (Khalili et al., 2020). روش‌های مختلفی برای بی‌بعد کردن پارامترها وجود دارد در اینجا از روش π باکینگهام استفاده شده است. معادله ابعادی پارامترهای مشخصه سرریزهای جانبی با تابع زیر بیان می‌شود:

$$f(B, S_0, L, P, y_1, U_1, \rho, \mu, \sigma, g, X, D_{50}, \rho_s, \xi) = 0 \quad (1)$$

B عرض کانال، S_0 شیب کانال اصلی، L طول سرریز جانبی، P ارتفاع سرریز جانبی، y_1 عمق جریان در ابتدای سرریز، U_1 سرعت جریان در مقطع ابتدای سرریز جانبی (کانال بالادست)، ρ جرم مخصوص سیال، μ لزجت دینامیکی سیال، σ کشش سطحی، و g شتاب ثقل X، به‌عنوان شاخص غلظت مواد معلق، D_{50} مشخصه اندازه متوسط ذرات، ρ_s جرم مخصوص رسوبات سیال و ξ انحراف معیار هندسی اندازه ذرات می‌باشد. با استفاده از تئوری باکینگهام کمیت‌های بدون بعد را از پارامترهای فوق تشکیل می‌دهیم.

$$\begin{aligned} \Pi_1 &= \frac{B}{y_1} & \Pi_2 &= \frac{P}{y_1} & \Pi_3 &= \frac{L}{y_1} & \Pi_4 &= \frac{U_1}{\sqrt{gy_1}} & \Pi_4 &= \frac{U_1}{\sqrt{gy_1}} \\ \Pi_5 &= S_o & \Pi_6 &= \frac{\sigma}{gy_1^2 \rho} & \Pi_7 &= \frac{\mu}{g^{1/2} y_1^{3/2} \rho} & \Pi_8 &= X & \Pi_9 &= \frac{\rho_s}{\rho} \\ \Pi_{10} &= \frac{D_{50}}{y_1} & \Pi_{11} &= \xi \end{aligned}$$

با استفاده از پارامترهای بدون بعد مشخصه سیستم، معادله کلی حاکم بر سرریزهای جانبی در جریان‌های رسوبی به صورت زیر بیان می‌شود:

$$f_2 \left(\frac{B}{y_1}, \frac{P}{y_1}, \frac{L}{y_1}, \frac{U_1}{\sqrt{gy_1}}, S_o, \frac{\sigma}{gy_1^2 \rho}, \frac{\mu}{g^{1/2} y_1^{3/2} \rho}, X, \frac{\rho_s}{\rho}, \frac{D_{50}}{y_1}, \xi \right) = 0 \quad (2)$$

هر رفتاری که تابعی از پارامترهای مشخصه سیستم باشد به صورت کلی زیر بیان می‌شود:

$$A^* = f_A(\Pi_1, \Pi_2, \Pi_3, \dots, \Pi_{11}) \quad (3)$$

که A^* به صورت زیر تعریف می‌شود:

$$A^* = \frac{A}{g^{X_A} y_1^{Y_A} \rho^{Z_A}} \quad (4)$$

از آنجاکه دبی جریان عبوری از سرریز جانبی به عنوان رفتار مؤثر بکار می‌رود، رابطه (۴-۳) و (۴-۴) به صورت زیر بیان می‌شوند:

$$Q_d^* = f_{Q_d}(\Pi_1, \Pi_2, \Pi_3, \dots, \Pi_{11}) \quad (5)$$

$$Q_d^* = \frac{Q_d}{g^{X_{Q_d}} y_1^{Y_{Q_d}} \rho^{Z_{Q_d}}} \quad (6)$$

۲.۲. استاندارد کردن داده‌های ورودی و خروجی

در این پژوهش از نرم افزار متلب نسخه ۲۰۱۷ استفاده شده است. وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه‌ها می‌شود. برای احراز از چنین شرایطی و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل استانداردسازی صورت می‌گیرد. این کار مانع از کوچک شدن بیش از حد وزن‌ها می‌گردد و درعین حال با تنظیم داده‌های ورودی در یک محدوده خاص می‌توان ورودی خالص نرون‌ها را در محدوده مطلوب قرار داده و از اشباع زود هنگام نرون‌ها جلوگیری به عمل آورد. به دلیل اینکه خروجی اکثر توابع انتقال در شبکه‌های عصبی بین ۱ و -۱ است، پس بهتر است داده‌ها بین این دو عدد استاندارد شوند. با توجه به اینکه در این تحقیق از تابع سیگموئید استفاده شده و خروجی این تابع بین ۰ و ۱ می‌باشد، لذا داده‌ها با استفاده از رابطه زیر بین دو عدد ۰/۱ و ۰/۹ استاندارد شدند.

$$x_i = 0.8 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) + 0.1 \quad (7)$$

در این رابطه: x_i مقدار استاندارد شده، x : مقدار واقعی و x_{\min} و x_{\max} به ترتیب مقادیر حداقل و حداکثر داده‌ها می‌باشند.

۳.۲. نوع شبکه، الگوریتم آموزش و تابع فعالیت

شبکه‌های عصبی پرسپترون، در زمره کاربردی‌ترین شبکه‌های عصبی است. این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها همراه با یک آموزش با نظارت، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. شبکه‌های عصبی پرسپترون چندلایه از نوع شبکه‌های پیش‌خور هستند. شبکه‌های عصبی پیش‌خور دولایه با توابع سیگموئید در لایه اول قادرند هر تابعی را با دقت دلخواه تقریب بزنند.

۴.۲. انتخاب مجموعه‌های آموزشی و آزمایشی

مجموعه آموزشی برای یادگیری و آموزش شبکه و مجموعه آزمایشی برای ارزیابی شبکه پس از آموزش مورداستفاده قرار می‌گیرند. در طراحی یک شبکه، عموماً بهتر است ابتدا یک مجموعه آموزشی انتخاب شود که در آن تمامی حالات ممکن از مسئله گنجانده شده است. انتخاب مجموعه آموزشی مناسب در عملکرد بعدی شبکه اهمیت زیادی دارد. در واقع چنانچه این مجموعه دربرگیرنده تمامی حالات ممکن نباشد، نمی‌تواند در زمان آموزش، یادگیری گسترده‌ای از کل سیستم داشته باشد و در زمان آزمون، این ضعف آموزشی شبکه که ناشی از انتخاب نادرست مجموعه آموزشی است مشخص می‌گردد که در این تحقیق از روش سعی و خطای مرسوم استفاده می‌شود.

۵.۲. ترکیب بردارهای ورودی به شبکه

انتخاب عناصر بردار ورودی به شبکه یکی از مراحل مهم در طراحی شبکه‌های عصبی مصنوعی است. با توجه به اینکه این تحقیق قصد دارد تا ضریب دبی سرریز جانبی را مدل‌سازی کند، لذا عناصر بردار ورودی به شبکه نیز بایستی از میان پارامترهای مؤثر بر این پدیده انتخاب شوند که در حقیقت همان متغیرهای بدون بعد حاصله از آنالیز ابعادی می‌باشند.

۶.۲. تحلیل داده‌ها

معیار سنجش خطای بین مقادیر پیش‌بینی و مشاهده‌شده در این مدل ضریب همبستگی، میانگین قدر مطلق خطای نسبی (MRE)، میانگین خطا (MBE)، ریشه میانگین مربعات خطاها یا تفاضل مقادیر پیش‌بینی و مشاهده‌ای (RMSE) می‌باشد. فرمول‌های ارائه‌شده برای این پارامترها به صورت زیر می‌باشد:

$$R^2 = \frac{\left[\sum_{i=1}^N (P_i - \bar{P})(O_i - \bar{O}) \right]^2}{\sum_{i=1}^N (P_i - \bar{P})^2 \sum_{i=1}^N (O_i - \bar{O})^2} \quad (8)$$

$$RMSE = \left(\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \right)^{0.5} \quad (9)$$

O_i : مقادیر مشاهده‌شده، P_i : مقادیر پیش‌بینی شده از مدل، \bar{P} : میانگین مقادیر پیش‌بینی شده از مدل، \bar{O} : میانگین مقادیر مشاهده‌شده، N : تعداد نمونه‌ها

۷.۲. رگرسیون

در مدل‌های آماری، تحلیل رگرسیون، یک فرایند آماری برای تخمین روابط بین متغیرها می‌باشد. این روش شامل تکنیک‌های زیادی برای مدل‌سازی و تحلیل متغیرهای خاص و منحصر بفرد، با تمرکز بر رابطه بین متغیر وابسته و یک یا چند متغیر مستقل، می‌باشد. تحلیل رگرسیون خصوصاً کمک می‌کند در فهم اینکه چگونه مقدار متغیر وابسته با تغییر هر کدام از متغیرهای مستقل

و با ثابت بودن دیگر متغیرهای مستقل تغییر می‌کند. بیشترین کاربرد تحلیل رگرسیون تخمین امید ریاضی شرطی متغیر وابسته از متغیرهای مستقل معین است که معادل مقدار متوسط متغیر وابسته است وقتی که متغیرهای مستقل ثابت هستند. کمترین کاربرد آن تمرکز روی چندک یا پارامتر مکانی توزیع شرطی متغیر وابسته از متغیر مستقل معین است. در همه موارد هدف تخمین یک تابع از متغیرهای مستقل است که تابع رگرسیون نامیده شده‌است. در تحلیل رگرسیون تعیین پراکندگی متغیر وابسته اطراف تابع رگرسیون مورد توجه است که می‌تواند توسط یک توزیع احتمال توضیح داده شود. در تحقیقاتی که از تحلیل رگرسیون استفاده می‌شود، هدف معمولاً پیش‌بینی یک یا چند متغیر وابسته از یک یا چند متغیر مستقل است. یک مدل رگرسیونی که یک متغیر مستقل داشته باشد را یک مدل رگرسیونی ساده می‌گویند. چنانچه هدف پیش‌بینی یک متغیر وابسته از چند متغیر مستقل باشد از مدل رگرسیون چندگانه استفاده می‌شود اما در صورتی که هدف پیش‌بینی هم‌زمان چند متغیر وابسته از متغیرهای مستقل یا زیرمجموعه آن‌ها باشد از مدل رگرسیون چند متغیری استفاده می‌شود. در تحقیقات رگرسیون هدف پیدا کردن متغیرهای مستقلی است که تغییرات متغیر وابسته را پیش‌بینی می‌کند. از آنجایی که در این مقاله هدف پیش‌بینی تغییرات متغیر وابسته بر اساس متغیر مستقل تحقیق می‌باشد از رگرسیون خطی ساده استفاده می‌شود. که معادله کلی آن به شرح زیر است:

$$y = \beta_0 + \beta_1 x_1 + \varepsilon \quad (10)$$

در این رابطه x : متغیر مستقل، Y : متغیر وابسته، β_0 : عرض از مبدأ معادله و ε : خطای پیش‌بینی است.

۳. نتایج و بحث

در این مقاله برای تخمین ضریب تخلیه سرریزهای جانبی از شبکه عصبی مصنوعی پرسپترون که در زمره کاربردی‌ترین شبکه‌های عصبی پیش‌خوراست، استفاده شد. ضریب تخلیه سرریزهای جانبی تابعی از نسبت طول به عرض سرریز (L/B)، نسبت عمق جریان در پایین‌دست سرریز به ارتفاع سرریز (H_d/P)، نسبت طول سرریز به ارتفاع سرریز (L/P)، نسبت دبی تخلیه سرریز به دبی بالادست (Q_w/Q_u) و نسبت عمق جریان در بالادست سرریز به عرض سرریز (H_u/B) است. برای به دست آوردن رابطه بین پارامترهای ورودی و خروجی از ۵۰ درصد داده‌ها به‌عنوان داده‌های آموزشی، ۲۵ درصد به‌عنوان داده‌های آزمایشی و ۲۵ باقیمانده عنوان داده‌های کنترلی استفاده گردید. تعداد نرون‌های لایه ورودی برابر با تعداد متغیرهای مستقل در نظر گرفته شد. تعداد نرون‌های لایه مخفی نیز در تمامی شبیه‌سازی‌ها برابر با ۱۰ در نظر گرفته شد، زیرا این تعداد نرون در لایه مخفی نتایج بهتری نسبت به تعداد بیشتر یا کمتر ایجاد می‌کرد. در نهایت با بهره‌گیری از الگوریتم پس انتشار خطا، هر شبکه ۲۵ بار آموزش داده شد. در جدول (۱) ترکیبات مختلف ورودی بر اساس متغیرهای مستقل بیان شده، آورده شده است.

جدول (۱): ترکیبات ورودی مدل‌های مورد ارزیابی

ترکیب ورودی	مدل	ترکیب ورودی	مدل
$L/B, h_d/P, h_u/B$	ANN ₁₄ , Reg ₁₄	$L/B, h_d/P, L/P, Q_w/Q_u, h_u/B$	ANN ₁ , Reg ₁
$L/B, h_d/P, Q_w/Q_u$	ANN ₁₅ , Reg ₁₅	$h_d/P, L/P, Q_w/Q_u, h_u/B$	ANN ₂ , Reg ₂
$L/B, h_d/P, L/P$	ANN ₁₆ , Reg ₁₆	$L/B, L/P, Q_w/Q_u, h_u/B$	ANN ₃ , Reg ₃
$Q_w/Q_u, h_u/B$	ANN ₁₇ , Reg ₁₇	$L/B, h_d/P, Q_w/Q_u, h_u/B$	ANN ₄ , Reg ₄
$L/P, h_u/B$	ANN ₁₈ , Reg ₁₈	$L/B, h_d/P, L/P, h_u/B$	ANN ₅ , Reg ₅
$L/P, Q_w/Q_u$	ANN ₁₉ , Reg ₁₉	$L/B, h_d/P, L/P, Q_w/Q_u$	ANN ₆ , Reg ₆
$h_d/P, h_u/B$	ANN ₂₀ , Reg ₂₀	$L/P, Q_w/Q_u, h_u/B$	ANN ₇ , Reg ₇
$h_d/P, Q_w/Q_u$	ANN ₂₁ , Reg ₂₁	$h_d/P, Q_w/Q_u, h_u/B$	ANN ₈ , Reg ₈
$h_d/P, L/P$	ANN ₂₂ , Reg ₂₂	$h_d/P, L/P, h_u/B$	ANN ₉ , Reg ₉
$L/B, h_u/B$	ANN ₂₃ , Reg ₂₃	$h_d/P, L/P, Q_w/Q_u$	ANN ₁₀ , Reg ₁₀
$L/B, Q_w/Q_u$	ANN ₂₄ , Reg ₂₄	$L/B, Q_w/Q_u, h_u/B$	ANN ₁₁ , Reg ₁₁
$L/B, L/P$	ANN ₂₅ , Reg ₂₅	$L/B, L/P, h_u/B$	ANN ₁₂ , Reg ₁₂
$L/B, h_d/P$	ANN ₂₆ , Reg ₂₆	$L/B, L/P, Q_w/Q_u$	ANN ₁₃ , Reg ₁₃


۱.۳. نتایج ارزیابی شبکه‌های عصبی مصنوعی در پیش‌بینی ضریب تخلیه سرریز جانبی

در این قسمت نتایج مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی مقادیر ضریب تخلیه سرریز جانبی آورده شده است. بدین منظور از مقایسه مقادیر ضریب تخلیه محاسباتی با مقادیر پیش‌بینی شده ضریب تخلیه بر اساس مدل‌های ANN استفاده گردید. نتایج آماری ارزیابی مدل ANN با ورودی‌های متفاوت در مراحل آموزشی و آزمایشی در جدول (۲) آورده شده است. همان‌طور که در این جدول ملاحظه می‌شود، مدل ANN₇ دارای بیشترین مقدار R² برابر با ۰/۹۲ در مرحله آزمایشی است. ملاحظه می‌شود که مدل‌های ANN₇ با ضریب رگرسیون برابر با ۰/۹۲ و مقادیر خطای RMSE و MAE برابر با ۰/۲۳ و ۰/۱۵ بهترین پیش‌بینی را انجام داده است. همچنین مدل‌های ANN₂، ANN₃، ANN₁ و ANN₄ نیز بعد از مدل ANN₇ بهترین نتایج را ایجاد کردند.


جدول (۲): مقایسه آماری ورودی‌های متفاوت به شبکه عصبی مصنوعی

شبکه	آموزشی			آزمایشی		
	R ²	RMSE	MAE	R ²	RMSE	MAE
ANN ₁	۰/۹۹	۰/۰۳	۰/۰۲	۰/۸۶	۰/۱۸	۰/۱۱
ANN ₂	۰/۹۷	۰/۰۵	۰/۰۴	۰/۹۱	۰/۱۳	۰/۱۵
ANN ₃	۰/۸۷	۰/۱	۰/۰۸	۰/۸۱	۰/۱۲	۰/۱۵
ANN ₄	۰/۹۸	۰/۰۵	۰/۰۴	۰/۸۷	۰/۱۴	۰/۱۸
ANN ₅	۰/۲۶	۰/۲۵	۰/۲	۰/۰۳	۰/۲۲	۰/۲۷
ANN ₆	۰/۹۸	۰/۰۵	۰/۰۴	۰/۶۱	۰/۲۳	۰/۳۶
ANN ₇	۰/۹۵	۰/۰۸	۰/۰۶	۰/۹۲	۰/۱۳	۰/۱۵
ANN ₈	۰/۵۶	۰/۱۹	۰/۱۵	۰/۵۷	۰/۱۶	۰/۲۳
ANN ₉	۰/۱۹	۰/۲۶	۰/۲۲	۰/۰۳	۰/۲۵	۰/۴
ANN ₁₀	۰/۹۱	۰/۱	۰/۰۷	۰/۹۱	۰/۲۲	۰/۳۶
ANN ₁₁	۰/۸۴	۰/۱۲	۰/۰۹	۰/۷۷	۰/۱۶	۰/۲۵
ANN ₁₂	۰/۱۵	۰/۲۸	۰/۲۳	.	۰/۲۶	۰/۳۸
ANN ₁₃	۰/۸	۰/۱۳	۰/۰۹	۰/۶۸	۰/۲۵	۰/۴۳
ANN ₁₄	۰/۳۳	۰/۲۴	۰/۱۹	۰/۰۵	۰/۳۳	۰/۴۵
ANN ₁₅	۰/۹۵	۰/۰۷	۰/۰۵	۰/۵۸	۰/۲۳	۰/۳۴
ANN ₁₆	۰/۲۷	۰/۲۵	۰/۲	۰/۰۷	۰/۲۸	۰/۳۹
ANN ₁₇	۰/۵۳	۰/۲	۰/۱۶	۰/۶۲	۰/۲۳	۰/۳۸
ANN ₁₈	۰/۱۸	۰/۲۶	۰/۲۱	۰/۱۲	۰/۲۵	۰/۴۱
ANN ₁₉	۰/۵۹	۰/۲۳	۰/۱۵	۰/۷۵	۰/۲۳	۰/۳۷
ANN ₂₀	۰/۲۹	۰/۲۴	۰/۱۹	۰/۱۳	۰/۲۲	۰/۳۴
ANN ₂₁	۰/۶۳	۰/۱۸	۰/۱۴	۰/۶۶	۰/۲۲	۰/۳۴
ANN ₂₂	۰/۱۲	۰/۴	۰/۳	.	۰/۲۵	۰/۳۷
ANN ₂₃	۰/۰۱	۰/۳۳	۰/۲۷	۰/۰۲	۰/۳۲	۰/۵۴
ANN ₂₄	۰/۷۱	۰/۱۶	۰/۱۲	۰/۵۰	۰/۲۸	۰/۴۶
ANN ₂₅	۰/۱۶	۰/۲۷	۰/۲۲	۰/۰۵	۰/۲۵	۰/۴۱
ANN ₂₆	۰/۱۳	۰/۲۹	۰/۲۳	۰/۰۵	۰/۲۹	۰/۵

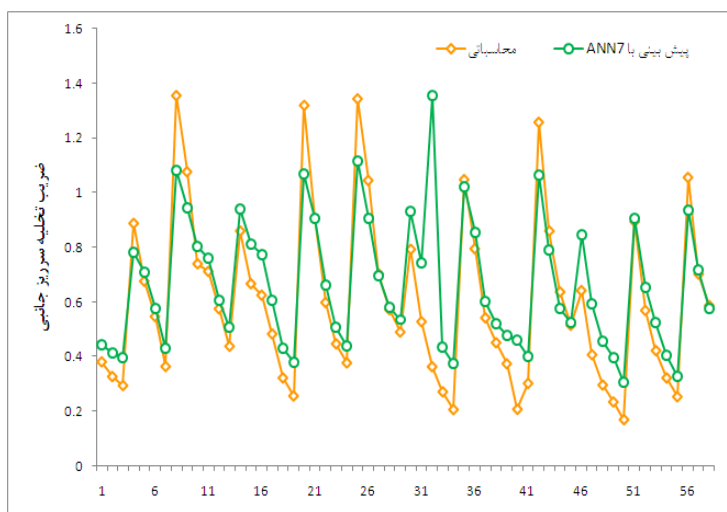
در شکل‌های (۱) و (۲) به ترتیب مقایسه مقادیر ضریب تخلیه سرریز جانبی پیش‌بینی شده با شبکه ANN₇ به‌عنوان بهترین مدل شبکه عصبی با مقادیر محاسباتی در مرحله آموزشی و آزمایشی آورده شده است. در شکل (۵) نتایج پیش‌بینی مدل ANN₇ ارائه شده است. بر اساس این شکل، مقادیر پیش‌بینی شده با مقادیر محاسباتی ضریب تخلیه سرریز جانبی روند یکسانی دارند و مدل ANN₇ مقادیر تقریباً یکسانی با مقادیر محاسباتی ایجاد کرده است.



شکل (۱): مقایسه مقادیر ضریب تخلیه سرریز جانبی پیش‌بینی‌شده با شبکه ANN7 با مقادیر محاسباتی در مرحله آموزشی




شکل (۲): مقایسه مقادیر ضریب تخلیه سرریز جانبی پیش‌بینی‌شده با شبکه ANN7 با مقادیر محاسباتی در مرحله آزمایشی



شکل (۵): نتایج پیش‌بینی مدل ANN7

در شکل (۳) نمودار ستونی مقایسه آماره‌های ارزیابی ۶ مدل برتر شبکه عصبی مصنوعی در پیش‌بینی ضریب تخلیه سرریز جانبی آمده است.



شکل (۴): مقایسه آماری بهترین مدل‌های ANN


۲.۳. نتایج ارزیابی رگرسیون خطی در پیش‌بینی ضریب تخلیه سرریز جانبی

در این مقاله از نرم‌افزار SPSS به منظور تحلیل مدل رگرسیون خطی استفاده گردید. در جدول (۳) نتایج آماری ورودی‌های متعدد به مدل رگرسیون خطی آورده شده است. همان‌طور که ملاحظه می‌شود، مدل Reg₁ با مقادیر ضریب رگرسیونی، RMSE و MAE به ترتیب برابر با ۰/۷۲، ۰/۱۷ و ۰/۱۱ بهترین نتایج را در پیش‌بینی ایجاد کرده است و به‌عنوان بهترین مدل رگرسیون خطی انتخاب می‌گردد.

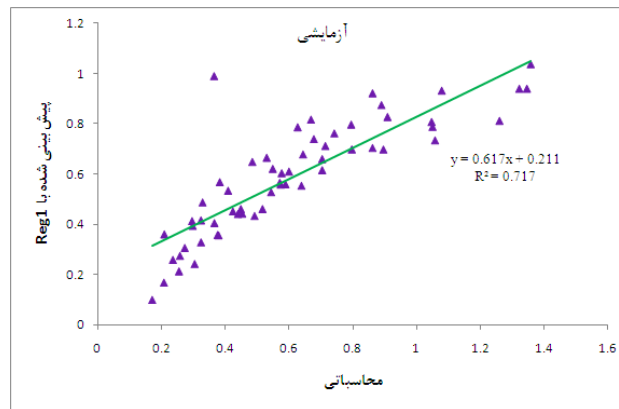
جدول (۳): مقایسه آماری ورودی‌های متفاوت به مدل‌های رگرسیون خطی

شبکه	آموزشی			آزمایشی		
	R ²	RMSE	MAE	R ²	RMSE	MAE
Reg ₁	۰/۷	۰/۱۶	۰/۱۱	۰/۷۲	۰/۱۷	۰/۱۱
Reg ₂	۰/۶۸	۰/۱۶	۰/۱۲	۰/۷۲	۰/۱۷	۰/۲۴
Reg ₃	۰/۶۹	۰/۱۶	۰/۱۲	۰/۷۱	۰/۱۷	۰/۲۴
Reg ₄	۰/۶۸	۰/۱۶	۰/۱۲	۰/۷	۰/۱۶	۰/۲۴
Reg ₅	۰/۱۵	۰/۲۷	۰/۲۱	۰/۱۱	۰/۲۳	۰/۳۵
Reg ₆	۰/۷	۰/۱۶	۰/۱۱	۰/۷۱	۰/۲۲	۰/۳۳
Reg ₇	۰/۶۸	۰/۱۶	۰/۱۲	۰/۷۱	۰/۱۷	۰/۲۴
Reg ₈	۰/۵۱	۰/۲۰	۰/۱۶	۰/۵۵	۰/۱۹	۰/۲۹
Reg ₉	۰/۱۴	۰/۲۷	۰/۲۱	۰/۱۲	۰/۲۵	۰/۳۹
Reg ₁₀	۰/۶۸	۰/۱۷	۰/۱۲	۰/۷۱	۰/۲۳	۰/۳۶
Reg ₁₁	۰/۶۷	۰/۱۶	۰/۱۲	۰/۶۹	۰/۱۷	۰/۲۵
Reg ₁₂	۰/۱۳	۰/۲۷	۰/۲۱	۰/۱۱	۰/۲۳	۰/۳۵
Reg ₁₃	۰/۶۸	۰/۱۶	۰/۱۲	۰/۶۸	۰/۲۲	۰/۳۴
Reg ₁₄	۰/۱۵	۰/۲۷	۰/۲۱	۰/۱۱	۰/۲۳	۰/۳۶
Reg ₁₅	۰/۶۸	۰/۱۶	۰/۱۲	۰/۷	۰/۲۲	۰/۳۴
Reg ₁₆	۰/۱۵	۰/۲۶	۰/۲۱	۰/۰۹	۰/۲۳	۰/۳۵
Reg ₁₇	۰/۵	۰/۲۰	۰/۱۶	۰/۵۶	۰/۲۴	۰/۳۸
Reg ₁₈	۰/۱۲	۰/۲۷	۰/۲۲	۰/۱۲	۰/۲۵	۰/۳۹
Reg ₁₉	۰/۶۶	۰/۱۷	۰/۱۳	۰/۶۸	۰/۲۳	۰/۳۶
Reg ₂₀	۰/۱۱	۰/۲۷	۰/۲۱	۰/۱۵	۰/۲۴	۰/۳۶
Reg ₂₁	۰/۵۱	۰/۲	۰/۱۶	۰/۵۵	۰/۲۴	۰/۳۹
Reg ₂₂	۰/۱۴	۰/۲۷	۰/۲۱	۰/۱۱	۰/۲۵	۰/۳۹
Reg ₂₃	۰/۱۳	۰/۲۷	۰/۲۱	۰/۱۱	۰/۲۸	۰/۴۵
Reg ₂₄	۰/۶۷	۰/۱۷	۰/۱۳	۰/۶۸	۰/۲۲	۰/۳۵
Reg ₂₅	۰/۱۲	۰/۲۷	۰/۲۲	۰/۰۴	۰/۲۴	۰/۳۷
Reg ₂₆	۰/۱۵	۰/۲۷	۰/۲۱	۰/۰۹	۰/۲۷	۰/۴۶

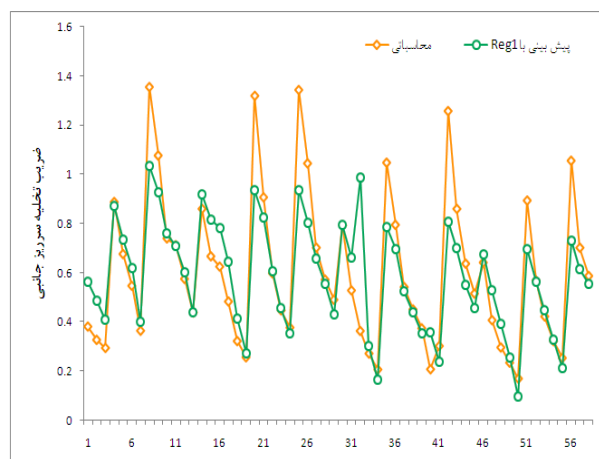
در شکل‌های (۵) و (۶) به ترتیب مقایسه مقادیر ضریب تخلیه سرریز جانبی پیش‌بینی شده با شبکه Reg_1 به‌عنوان بهترین مدل شبکه عصبی با مقادیر محاسباتی در مرحله آموزشی و آزمایشی آورده شده است. در شکل (۹) نتایج پیش‌بینی مدل ANN_7 ارائه شده است. بر اساس این شکل، مقادیر پیش‌بینی شده با مقادیر محاسباتی ضریب تخلیه سرریز جانبی روند یکسانی دارند و مدل Reg_1 مقادیر تقریباً یکسانی با مقادیر محاسباتی ایجاد کرده است.



شکل (۵): مقایسه مقادیر ضریب تخلیه سرریز جانبی پیش‌بینی شده با شبکه Reg_1 با مقادیر محاسباتی در مرحله آموزشی




شکل (۶): مقایسه مقادیر ضریب تخلیه سرریز جانبی پیش‌بینی شده با شبکه Reg_1 با مقادیر محاسباتی در مرحله آزمایشی



شکل (۷): نتایج پیش‌بینی مدل Reg_1

در شکل (۸) نمودار ستونی مقایسه آماره‌های ارزیابی ۶ مدل برتر رگرسیون خطی در پیش‌بینی ضریب تخلیه سرریز جانبی آمده است.



شکل (۸): مقایسه آماری بهترین مدل‌های رگرسیون خطی

۴. نتیجه‌گیری

در این مقاله از مدل‌های رگرسیون خطی و شبکه عصبی مصنوعی برای پیش‌بینی ضریب تخلیه سرریز جانبی استفاده شد و نتایج آن‌ها با یکدیگر و با مقادیر محاسباتی مقایسه و بهترین مدل در این زمینه برای پیش‌بینی انتخاب شد. این نتایج به همراه معیارهای آماری آن‌ها در جدول (۴) آورده شده است. در ستون آخر این جدول، رتبه‌بندی این مدل‌ها ارائه شده است. در بین این دو مدل پیش‌بینی، مدل ANN₇ با چهار پارامتر بی‌بعد L/P , Q_w/Q_u , h_u/B حائز رتبه اول گردید و به‌عنوان بهترین مدل شناخته شد.

جدول (۴): رتبه‌بندی بهترین مدل پیش‌بینی ضریب تخلیه سرریز جانبی

رتبه کل	رتبه‌بندی معیارهای آزمایشی			معیارهای آزمایشی			ورودی‌ها	مدل
	MAE	RMSE	R ²	MAE	RMSE	R ²		
۱	۲	۱	۱	۰/۱۵	۰/۱۳	۰/۹۲	L/P , Q_w/Q_u , h_u/B	ANN ₇
۲	۱	۲	۲	۰/۱۱	۰/۱۷	۰/۷۲	L/B , h_d/P , L/P , Q_w/Q_u , h_u/B	Reg ₁

در مقایسه خطای بین مقادیر پیش‌بینی ضریب تخلیه سرریز جانبی از ورودی‌های انتخاب شده، مشخص شد که مدل ANN با چهار پارامتر خطای کمتری را ایجاد کرده است.

منابع

- Akbar, M. F., Alkatiri, R. and Tuli, Z. (2022) 'Socio-Economic Aspects of Community in Limboto Lake Management in Telaga Biru District, Gorontalo Regency', *Journal La Bisecoman*, 3(2), pp. 59–64.
- Bilhan, O., Emiroglu, M. E. and Kisi, O. (2011) 'Use of artificial neural networks for prediction of discharge coefficient of triangular labyrinth side weir in curved channels', *Advances in Engineering Software*, 42(4), pp. 208–214.
- Chuengsatiansup, C. et al. (2022) 'Side-Channelling the Kalyna Key Expansion', in *Cryptographers' Track at the RSA Conference*. Springer, pp. 272–296.
- Gamero, P. et al. (2022) 'Shallow-water lee-side waves at obstacles: Experimental characterization and turbulent non-hydrostatic modeling using weighted-averaged residual equations', *Environmental Modelling & Software*, p. 105422.
- Hu, Z. et al. (2021) 'Using soft computing and machine learning algorithms to predict the discharge coefficient of curved labyrinth overflows', *Engineering Applications of Computational Fluid Mechanics*, 15(1), pp. 1002–1015.
- Khalili, R., Parvinnia, M. and Zali, A. (2020) 'Water Quality Assessment of Garmarood River Using

the National Sanitation Foundation Water Quality Index (NSFWQI), River Pollution Index (RPI) and Weighted Arithmetic Water Quality Index (WAWQI)', *Environment and Water Engineering*, 6(3), pp. 274–284. doi: 10.22034/jewe.2020.238090.1381.

Khalili, R., Zali, A. and Motaghi, H. (2021) 'Evaluating the Heavy Metals in the Water and Sediments of Haraz River, Using Pollution Load Index (PLI) and Geo accumulation Index (Igeo)', *Iranian Journal of Soil and Water Research*. doi: 10.22059/ijswr.2021.316080.668850.

mehri, yaser and Abbasi, N. (2020) 'Estimating the Discharge Coefficient of the Type B Piano-Key Side Weir at a 120° Curve using RBF and ANFIS Models in Comparison with Artificial Neural Networks', *Irrigation Sciences and Engineering*, 43(1), pp. 89–100. doi: 10.22055/jise.2018.24375.1723.

Mouritsen, J., Pedraza-Acosta, I. and Thrane, S. (2022) 'Performance, risk, and overflows: When are multiple management control practices related?', *Management Accounting Research*, 55, p. 100796.

Qabadian, R. and Shafa'i Bejestan, M. (2019) 'Optimizing the discharge coefficient of lateral overflows in irrigation canals using artificial neural networks', *National Conference on Management of Irrigation and Drainage Networks*.: undefined. Available at: <https://civilica.com/doc/5500>.

Saffar, S. *et al.* (2021) 'Prediction of the discharge of side weir in the converge channels using artificial neural networks', *Flow Measurement and Instrumentation*, 78, p. 101889.

Watanabe, K. *et al.* (2020) 'Development of geosynthetic-reinforced soil embankment resistant to severe earthquakes and prolonged overflows due to tsunamis', *Soils and Foundations*, 60(6), pp. 1371–1386.