



بهینه سازی موقعیت و زاویه آبگیرهای جانبی در آبراهه‌های U شکل

حسین منتصری^{۱*}، زهرا جمال آبادی^۲

^۱ دانشیار گروه مهندسی عمران، دانشکده مهندسی، دانشگاه یاسوج

^۲ دانش آموخته کارشناسی ارشد، گروه مهندسی عمران، دانشکده مهندسی، دانشگاه یاسوج

Email: hmontaseri@yu.ac.ir*

تاریخ دریافت: [۱۴۰۱/۱۲/۲۲]

تاریخ پذیرش: [۱۴۰۲/۰۷/۲۷]

چکیده

انتخاب دقیق محل آگیری از قوس رودخانه‌ها و زاویه مناسب انحراف آبگیر، از عوامل اساسی در کاهش رسوبات وارد شده به سیستم انحراف و آگیری است. در این تحقیق با استفاده از مدل عددی FLUENT، مدل بهینه‌سازی الگوریتم ژنتیک چند هدفه (NSGAI) و مدل شبکه عصبی مصنوعی (ANN)، موقعیت و زاویه بهینه آبگیر جانبی در یک کانال U شکل به گونه‌ای تعیین شد که مقدار رسوب ورودی به آبگیر جانبی، کمینه و میزان دبی آگیری بیشینه شود. بدین منظور، ابتدا میدان جریان و رسوب در کانال U شکل با آبگیر جانبی در تعداد محدودی از موقعیت‌های مختلف قوس، زوایای آگیری مختلف و با دبی‌های آگیری متفاوت به وسیله مدل دو فازی فازگسسته در نرم افزار FLUENT شبیه سازی شد. سپس بر مبنای نتایج حاصل از مدل عددی FLUENT، یک فرامدل برای پیش‌بینی میزان رسوب انحرافی به آبگیر جانبی در کانال قوسی به ازای موقعیت، زاویه آگیری و دبی آگیری مورد نظر در مدل ANN ارائه شد. با اتصال مدل بدست آمده از ANN به مدل بهینه‌سازی الگوریتم ژنتیک چند هدفه (NSGA-II)، جبهه پارتو شامل فهرستی از موقعیت‌ها و زاویه‌های بهینه آبگیر جانبی متناظر با مقادیر بهینه توابع هدف (بیشترین دبی آگیری و کمترین رسوب انحرافی به آبگیر جانبی) و محدودیت‌های آن در کانال U شکل بدست آمد. در نهایت با استفاده از روش تصمیم گیری چند معیاره TOPSIS، بهترین گزینه از بین گزینه‌های موجود در جبهه پارتو تعیین گردید. نتایج نشان داد زاویه آگیری بهینه برابر با ۳۸ درجه و موقعیت بهینه آبگیر در کانال U شکل زاویه ۱۲۷ درجه می‌باشد.

واژگان کلیدی: آبگیر جانبی، آبراهه U شکل، الگوریتم ژنتیک، نرم افزار FLUENT، شبکه عصبی مصنوعی

۱-مقدمه

انتخاب دقیق محل آبگیری از رودخانه‌ها، از عوامل اساسی در کاهش رسوبات وارد شده به سیستم انحراف و آبگیری است. بطور کلی قوس خارجی رودخانه‌ها یا فاصله کمی پس از آن به عنوان مکان مناسب برای آبگیری انتخاب می‌شود. این عمل از بار رسوبات وارد شده به سیستم آبگیری می‌کاهد و رسوبات را بطرف قوس داخلی هدایت می‌نماید. همچنین انتخاب زاویه مناسب آبگیری باعث می‌شود که جریان با کمترین اغتشاش و بدون پدیده جدائی وارد آبگیر شود. هرچه نسبت دبی انحرافی بیشتر شود، اغتشاشات ناشی از جریان باعث اتلاف بیشتر انرژی جریان ورودی و نیز انتقال رسوبات کف به آبگیر خواهد شد. با بروز پدیده جدائی، از عرض مفید جریان کاسته شده که باعث کاهش راندمان آبگیری در اثر وقوع این پدیده خواهد شد. علاوه بر آن در ناحیه گردابی استعداد رسوبگذاری وجود خواهد داشت که در اثر مرور زمان در آبگیرهای عریض، امکان تثبیت رسوبات و رشد گیاهان که عامل تشدید کننده کاهش ظرفیت آبگذری آبگیر می‌باشد، پدید خواهد آمد. انتقال رسوبات به دو صورت بار بستر و بار معلق انجام می‌گیرد که بار بستر عامل مهمی در چگونگی تشکیل فرم‌های بستر دارد و بر شرایط جریان نیز تاثیر می‌گذارد.

از مطالعات انجام شده در زمینه تعیین موقعیت و زاویه مناسب آبگیری از قوس رودخانه‌ها می‌توان به موارد زیر اشاره نمود. مطالعه میدانی جاگلکار و همکاران (۱۹۷۱) نشان داد که قوس خارجی رودخانه بهترین محل جهت انحراف آب است [1]. بلانچت (۱۹۷۵) انتخاب محل انحراف را به طرف انتهای پایین دست خم که جریان مارپیچی توسعه یافته است توصیه نموده است [2]. رضوان (۱۹۸۹) محل قرارگرفتن آبگیر را در بخش خارجی قوس، به منظور حداقل نمودن ورود رسوبات درشت به آبگیر توصیه نموده است به شکلی که محل دهانه آبگیر در مقطعی قرار گیرد که جریان مارپیچی کاملاً توسعه یافته باشد. موقعیت مناسب استقرار آبگیر در سه چهارم زاویه مرکزی قوس مثلاً در نزدیکی ایشان پیشنهاد شده است [3]. نواک (۱۹۹۰) نیز بهترین محل آبگیر برای جلوگیری از ورود بار بستر را ساحل خارجی قوس معرفی نموده، ولی تصمیم‌گیری در مورد محل و

راستای انحراف را به ساختن مدل واگذار می‌نماید [4]. نواک بیان نمود که در مسیر مستقیم آبگیری با زاویه ۹۰ درجه نسبت به مسیر کانال اصلی نامطلوبترین حالت می‌باشد و آبگیر باید به شکلی قرار گیرد که خطوط جریان را با انحنا مناسب به داخل آبگیر هدایت نماید. ایشان زاویه آبگیری مناسب را بین ۳۰ تا ۴۵ درجه پیشنهاد می‌کند و استفاده از مدل هیدرولیکی برای انتخاب زاویه آبگیر را توصیه می‌کند. تحقیقات انجام شده توسط پیرستانی (۱۳۸۳) در کانال قوسی U شکل نشان داد در موقعیت آبگیری ۱۱۵ درجه، برای کلیه اعداد فرود، بیشترین دبی نسبی انحرافی مربوط به زاویه آبگیری ۶۰ درجه بوده و در صورتی که کاهش ورود رسوبات به داخل آبگیر مورد نظر باشد، محل آبگیری ۱۱۵ درجه و زاویه آبگیری ۶۰ درجه نسبت به محل‌های دیگر، توصیه شده است [5]. دهقانی (۱۳۸۵) بر اساس مطالعه روی میزان رسوب ورودی به آبگیر در موقعیت‌های ۹۰، ۱۰۲/۵، ۱۱۵، ۱۳۵ و ۱۵۰ درجه و با زوایای آبگیری ۳۰، ۴۵، ۶۰ و ۷۵، دبی‌های آبگیری مختلف دریافت که در نسبت‌های آبگیری غیر از حداکثر آبگیری، نسبت رسوب انحرافی در زاویه آبگیری ۴۵ درجه از زوایای ۷۵ و ۶۰ درجه کمتر می‌باشد. ایشان زاویه بین ۱۱۵ تا ۱۳۵ درجه را برای محل قرارگیری آبگیر توصیه نمود و به عنوان یک توصیه کاربردی در قوس‌ها عنوان نمود که بهتر است آبگیرها در نیمه دوم ربع سوم قوس واقع شوند [6]. توکلی و همکاران (۲۰۱۹) به بررسی سازوکار انتقال رسوب در یک کانال U شکل با آبگیر جانبی به همراه فرایندهای ورود رسوب به خود آبگیر و تشکیل توپوگرافی بستر با استفاده از مدل‌های عددی فازگسسته و اویلری در نرم افزار فلوئنت پرداختند [7].

به منظور بررسی دقیق رفتار سازه‌های هیدرولیکی، اغلب مدل فیزیکی آن ساخته می‌شود که این روش هزینه‌بر و وقت‌گیر است. امروزه با پیشرفت رایانه‌ها، مدل‌های عددی جایگاه خاصی برای حل مسائل پیچیده پیدا کرده‌اند. از مزایای اصلی مدل‌های عددی نسبت به مدل‌های فیزیکی این است که به کمک مدل‌های عددی به سادگی می‌توان شرایط فیزیکی مختلف را در شرایط مسأله اعمال و نتایج را مشاهده نمود.

همچنین مدل‌های هوش مصنوعی، به دلیل تخمین و پیش‌بینی نتایج با ضریب همبستگی بالا و خطای کمتر در مقایسه با مدل‌های پیش‌بینی معمولی، می‌توانند در تعامل با مدل‌های عددی برای پیش‌بینی رفتار سازه‌های هیدرولیکی و کاهش تعداد مدل‌سازی در مدل عددی و در نتیجه کاهش زمان محاسبات به عنوان گزینه‌ای کارا مورد استفاده قرار گرفته‌اند [8].

از پرکاربردترین مدل‌های شبیه‌سازی هوشمند، می‌توان به شبکه‌های عصبی مصنوعی اشاره نمود. شبکه‌های عصبی، سیستم‌های هوشمندی هستند که با پردازش داده‌های مشاهداتی، دانش و یا قانون نهفته بین داده‌های ورودی و خروجی را به ساختار شبکه منتقل می‌کنند. به عبارت ساده‌تر، این سیستم‌های مبتنی بر هوش محاسباتی سعی می‌کنند، ساختار عصبی مغز بشر را مدل‌سازی کنند. با پیشرفت شبکه‌های عصبی مصنوعی و کشف قابلیت‌های آنها در حل مسائل فنی پیچیده، استفاده از آنها در شاخه‌های مختلف علوم مهندسی رواج بسیاری یافته است.

امروزه الگوریتم‌های بهینه‌سازی فراکاوشی و تکاملی نیز رو به توسعه و گسترش هستند و در صورت اتصال یک الگوریتم تکاملی بهینه‌سازی به مدل‌های هوش مصنوعی، می‌توان از قابلیت بهینه‌سازی اینگونه الگوریتم‌ها در فضای پیوسته و گسسته نیز سود جست.

از شبکه‌های عصبی در مطالعات مختلف استفاده شده است. لین و همکاران (۲۰۱۹)، برای تعیین کمیت تأثیر هیدرولوژیکی تغییرات آب و هوا و درک بهتر رابطه جنگل و آب، یک شبکه عصبی مصنوعی (ANN) مدل مبتنی بر بارندگی-رواناب به حوضه زاگوانو، یکی از حوضه‌های معمولی در حوضه UMR، توسط یک سناریوی اقلیمی استفاده شد [9]. غلامی و همکاران (۲۰۲۱) از شبکه عصبی مصنوعی (ANN) برای شبیه‌سازی میزان فرسایش خاک استفاده کردند [10]. کرمی و همکاران (۲۰۱۲)، با تحلیل داده‌های مربوط به عمق آبستگي اطراف اولین آبشکن از آبشکن‌های سری و ارائه یک مدل رگرسیونی و یک مدل شبکه‌های عصبی مصنوعی (ANNs) و مقایسه آنها

در بدست آوردن بیشترین عمق آبستگي به این نتیجه رسیدند که مدل رگرسیون توسعه یافته بسیار دقیق و علمی است اما مدل‌های شبکه عصبی مصنوعی (ANNs) با دستیابی به الگوی داده‌های آزمایشگاهی و با دو شبکه عصبی پرسپترون چندلایه و عملکرد پایه شعاعی^۱، پیش‌بینی بهتری از مشاهدات را فراهم کرد [11]. قومان و همکاران (۲۰۱۱) یک مدل بارش-رواناب بر اساس شبکه عصبی مصنوعی (ANN) در یک حوزه آبخیز کشور پاکستان توسعه دادند [12]. این مدل برای هماهنگی با شرایطی که مجموعه داده‌های جمع‌آوری شده کم است و کیفیت داده‌ها مورد سوال قرار می‌گیرد، توسعه یافت. ایمبروفلو و همکاران (۲۰۱۱) به پیش‌بینی ضریب تخلیه سرریزهای کنجره‌ای مثلثی واقع در کانال مستقیم با استفاده از شبکه عصبی مصنوعی (ANN) پرداخت. برای تعیین ضریب تخلیه لبه‌های کنجره‌ای مثلثی ۲۵۰۰ آزمایش در نظر گرفته شد [13]. ایمری و همکاران (۲۰۰۰) نشان دادند شبکه‌های عصبی مصنوعی (ANNs) یک ابزار سریع و انعطاف پذیر برای ایجاد مدلی برای پیش‌بینی جریان رودخانه هستند که در مقابله با روش‌های معمول به خوبی عمل می‌کنند [14].

از تحقیقات صورت گرفته در زمینه کاربرد اتصال الگوریتم ژنتیک و مدل‌های هوش مصنوعی می‌توان به موارد زیر اشاره نمود. سیفی و همکاران (۲۰۱۸)، برای شبیه‌سازی و پیش‌بینی انتقال آلودگی برای توصیف کیفیت آب رودخانه از مدل ترکیبی توسعه یافته از یک مازول هوش مبتنی بر سیستم استنتاج فازی عصبی تطبیقی بهینه شده (ANFIS) و شبکه‌های عصبی مصنوعی (ANN) برای برآورد پراکندگی طولی استفاده کردند که ساختارهای آنها توسط الگوریتم ژنتیک (GA) بهینه شد [15]. همچنین عرب و همکاران (۲۰۱۶) در بهینه‌سازی شکل سرریز [16]، ابوطالبی و حداد (۲۰۱۵) در روندیابی سیل در رودخانه [17]، بهزادپور و ارشیری (۲۰۰۸) در مدل‌سازی شبکه توزیع آب [18]، باتاچارجیا و داتا (۲۰۰۹)، در مدیریت آبخوان‌های ساحلی [19] و ژانگ و همکاران (۲۰۱۱) در

بهینه‌سازی پمپ‌های محوری چندفازی از ترکیب مدل‌های هوش مصنوعی و الگوریتم ژنتیک استفاده نمودند [20].

در این تحقیق سعی شده است با استفاده از اتصال مدل شبکه عصبی مصنوعی و الگوریتم ژنتیک چند هدفه، بر اساس داده‌های حاصل از شبیه‌سازی توسط مدل عددی فلوئنت، موقعیت و زاویه آبگیر جانبی در کانال‌های قوسی بگونه‌ای تعیین شود که مقدار رسوب ورودی به آبگیر جانبی کمینه و میزان دبی آبگیری بیشینه شود. مراحل کار این تحقیق شامل مراحل زیر است که در روندنمای شکل (۱) نیز نشان داده شده است:




Fig. 1 flowchart of this study

۱- تدوین یک فرامدل بر مبنای مدل ANN و نتایج مدل عددی برای پیش‌بینی مقدار رسوب ورودی به آبگیر جانبی در کانال U شکل

۲- تعیین بهترین ساختار از مدل شبکه عصبی به منظور پیش‌بینی میزان رسوب با استفاده از معیارهای R^2 , SSE, MARE

۱- اتصال بهترین ساختار از مدل شبکه عصبی به الگوریتم بهینه‌سازی ژنتیک چند هدفه (NSGA-II) به منظور تعیین جبهه پارتو شامل لیستی از موقعیت‌های بهینه و زاویه‌های بهینه آبگیر جانبی در کانال U شکل

۲- تعیین بهینه‌ترین موقعیت و بهینه‌ترین زاویه آبگیر جانبی در کانال U شکل با اتصال جبهه پارتو بدست آمده از الگوریتم ژنتیک چند هدفه (NSGA-II) در مرحله قبل با استفاده از روش چندمعیاره $TOPSIS^1$ ، برای تعیین بهینه‌ترین گزینه از بین گزینه‌های موجود در جبهه پارتو

۲- مواد و روش ها

۲-۱- آنالیز ابعادی

تعداد پارامترهای مؤثر بر میزان رسوب ورودی به آبگیر قابل توجه می‌باشد، ولی با توجه به اینکه هدف از این تحقیق مطالعه بار بستر وارد شده به آبگیر و بررسی آثار پارامترهای موقعیت آبگیر، زاویه انحراف آبگیر و دبی آبگیری بر میزان رسوب وارد شده به آبگیر می‌باشد، با در نظر گرفتن پارامترهای مؤثر، پس از انجام تحلیل ابعادی با استفاده از روش π باکینگهام، پارامترهای بدون بعد به صورت زیر بدست می‌آید:

$$G_r = f(Q_r, \phi, \theta) \quad (1)$$

در این رابطه، $G_r = G_m / G_d$ نسبت رسوب انحرافی به درون آبگیر، G_m وزن رسوبات حمل شده در کانال اصلی تا لبه بالادست آبگیر، G_d وزن رسوبات منحرف شده به درون آبگیر، $Q_r = Q_m / Q_d$ نسبت دبی انحرافی به درون آبگیر، Q_m دبی جریان در کانال اصلی، Q_d دبی جریان در کانال آبگیر، ϕ زاویه مرکزی محل استقرار آبگیر و θ زاویه انحراف آبگیر می‌باشد.

۲-۲- مدل آزمایشگاهی

مدل آزمایشگاهی یک کانال U شکل در آزمایشگاه دانشگاه تربیت مدرس با شعاع متوسط $2/6$ متر و عرض $0/6$ متر می‌باشد. در قسمت بالادست قوس یک کانال مستقیم به طول




Fig. 2. Experimental model

شکل ۳- ردیابی حرکت رسوبات در مدل عددی و آزمایشگاهی برای دبی آگیری ۴۰ درصد (توکلی و منتصری، ۱۳۹۶)




Fig. 3. Sediment tracing in numerical and experimental models

۴-۲- شبکه عصبی مصنوعی چند لایه^۱ (MLP)

۷/۲ متر و در پایین دست قوس کانال مستقیمی به طول ۵/۲ متر وجود دارد. در موقعیت $\phi = 115^\circ$ درجه از قوس، کانال آگیری با زاویه انحراف $\theta = 45^\circ$ درجه قرار دارد. زاویه انحراف آگیری نسبت به خط عمود بر شعاع قوس گذرنده از موقعیت آگیری اندازه گیری شده است. شکل (۲) مدل آزمایشگاهی مربوط به مطالعات منتصری (۲۰۰۸) را نشان می دهد [21]. لازم به ذکر است موقعیت و زاویه آگیری در مدل آزمایشگاهی بر اساس توصیه ارائه شده در مطالعه دهقانی (۱۳۸۵) انتخاب شده است.

۳-۲- مدل عددی فاز گسسته

به منظور تولید داده‌های لازم برای آموزش و آزمایش مدل شبکه عصبی مصنوعی، از مدل عددی کالیبره شده در مطالعه توکلی و منتصری (۲۰۱۷) استفاده شد که ایشان با استفاده از مدل دوفازی فاز گسسته در Fluent، به شبیه سازی پدیده انتقال رسوب در یک کانال قوسی 180° درجه با آگیری جانبی پرداخته اند [21]. این مدل عددی با داده های آزمایشگاهی تحقیق منتصری (۲۰۰۸) کالیبره شده است. در شکل (۳) ردیابی حرکت رسوبات در مدل عددی و آزمایشگاهی برای دبی آگیری ۴۰ درصد نشان داده شده است [22].

با استفاده از مدل عددی کالیبره شده، در ۳۱ موقعیت از قوس خارجی از مقطع ۱۰ تا 140° درجه از قوس با فواصل 5° درجه و با ۵ زاویه آگیری $10^\circ, 30^\circ, 50^\circ, 70^\circ$ و 90° درجه و سه دبی آگیری (Q_r) $20\%, 30\%$ و 40% مدل عددی کالیبره شده، اجرا شد و درصد رسوب انحرافی به آگیری جانبی (G_r) در هر حالت تعیین شد. داده‌های حاصل شامل ۴۶۵ نمونه مربوط به مقدار رسوب انحرافی به آگیری جانبی در موقعیت‌های مختلف قوس (ϕ)، زوایای آگیری مختلف (θ) و به ازای دبی‌های آگیری مختلف (Q_r) به عنوان داده‌های لازم برای آموزش و درستی آزمایی مدل شبکه عصبی به کار برده شد.

شکل ۲. مدل آزمایشگاهی (منتصری ۱۳۸۷)

¹ Multi-layer perceptron

الگوریتم ژنتیک با رتبه‌بندی شکست‌نخورده NSGA به خاطر عدم استفاده از نخبه‌گرایی و نیاز به تعیین پارامتر اشتراکی، مورد انتقاد قرار گرفت. در روش NSGA-II که در سال ۲۰۰۲ توسط دب و همکارانش پایه‌گذاری شد، هر دو نقص فوق برطرف شده است [24]. در روش NSGA-II، اعضای جمعیت براساس مفهوم غلبه نداشتن مرتب می‌شوند. در روش مرتب‌سازی نامغلوب، به اعضای از جمعیت که نسبت به سایر اعضای آن نسل غلبه نشده هستند، رتبه یک نسبت داده شده و در دسته جبهه اول قرار می‌گیرند و از جمعیت نیز کنار گذاشته می‌شوند. سپس در بین اعضای باقیمانده مجدد اعضای که غلبه نشده باشند، انتخاب شده و رتبه دو به آن‌ها تعلق می‌گیرد. این اعضا در جبهه دوم قرار گرفته و به طور موقت از جمعیت کنار گذاشته می‌شوند. این روند تا قرار گرفتن تمامی اعضای جمعیت در جبهه‌های مختلف، ادامه می‌یابد.

۴-۲- روش تصمیم‌گیری چندمعیاره شباهت به گزینه ایده‌آل (TOPSIS) [25]

در این روش تحلیل چندمعیاره گسسته، گزینه‌ها بر اساس شباهت به حل ایده‌آل رتبه‌بندی می‌شوند، به این صورت که هر مقدار یک گزینه به جواب ایده‌آل شبیه‌تر باشد، رتبه بیشتری خواهد داشت. در این روش، جواب ایده‌آل به آن جوابی اطلاق می‌شود که از هر لحاظ بهترین باشد. در مسائل عملی، عموماً این جواب امکان‌پذیر نیست، ولی سعی شده است تا به آن نزدیک شود. به عنوان مثال اگر n معیار و m گزینه وجود داشته باشد، حل ایده‌آل آن گزینه‌ای است که برای هر معیار بهترین مقدار ممکن را حاصل کند.

در این روش ماتریس تصمیم^۴ به صورت زیر تعریف می‌شود:

$$D = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1n} \\ X_{21} & X_{22} & \dots & X_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ X_{m1} & X_{m2} & \dots & X_{mn} \end{bmatrix} \quad (3)$$

که در آن X_{ij} عملکرد گزینه i ام در رابطه با معیار j ام می‌باشد. مراحل یافتن بهترین گزینه به صورت زیر است:

مرحله ۱: بی واحد کردن ماتریس تصمیم توسط رابطه زیر:

شبکه‌های عصبی مصنوعی به‌عنوان تعمیم مدل‌های ریاضی می‌باشد و پردازش اطلاعات در عناصری به نام سلول‌های عصبی (نرون) رخ می‌دهد. هر نرون، یک تابع فعال‌سازی (معمولاً غیرخطی) را به ورودی خالص آن، (مجموع سیگنال‌های ورودی وزن‌دار)، برای تعیین سیگنال خروجی، اعمال می‌کند. در این شبکه‌های عصبی، سه لایه وجود دارد: لایه ورودی، لایه‌های میانی (پنهان) و لایه خروجی. لایه میانی و تعداد نرون‌های آن نقش بسیار موثری در شبکه‌های عصبی ایفا می‌کنند. در واقع این گره‌های لایه میانی هستند که به شبکه اجازه می‌دهند ویژگی‌های الگوی نهفته در ورای داده‌ها را کشف نماید (جانگ و همکاران، ۱۹۹۷) [23]. با این حال انتخاب تعداد لایه‌های میانی و تعداد گره‌های این لایه، از قانونمندی خاصی پیروی نمی‌کند. به ویژه آنکه افزایش تعداد لایه‌های پنهان از یک سو باعث افزایش زمان محاسبات و آموزش شبکه شده و از سوی دیگر سبب ایجاد مشکل فرا انطباق^۱ مدل‌های پیش‌بینی می‌شود.

در این تحقیق رای پیش‌بینی مقدار رسوب انحرافی به آبیگر جانبی، در نقاطی که مدل آزمایشگاهی و مدل فلوئنت اندازه‌گیری و بررسی نشده‌اند، از مدل شبکه عصبی مصنوعی چند لایه (MLP) استفاده شده است. ورودی‌های مدل مذکور عبارتند از موقعیت آبیگر، زاویه انحراف آبیگر و دبی آبیگری.

۲-۳- بهینه‌سازی چند هدفه

بهینه‌سازی چند هدفه^۲، یکی از زمینه‌های بسیار فعال و پرکاربرد تحقیقاتی در میان مباحث بهینه‌سازی است. تا کنون، روش‌های متعددی برای حل مسائل بهینه‌سازی چند هدفه معرفی شده‌اند که از میان آنها، الگوریتم‌های تکاملی از قبیل NSGA^۳ جایگاه ویژه‌ای دارند، زیرا اغلب، برخلاف روش‌های کلاسیک در ریاضیات کاربردی، مسائل بهینه‌سازی چندهدفه را به همان شکل که هستند، مورد حل قرار می‌دهند و از تبدیلات هندسی و مشابه آن استفاده نمی‌کنند.

3 Non-Dominated Sorting Genetic Algorithm
4 Decision matrices

1 Over fitting
2 Multi-objective Optimization

برای ایجاد مدل شبکه عصبی مصنوعی مراحل کلی زیر طی می‌شود:

مرحله اول - تعیین ساختار شبکه: منظور از تعیین ساختار یا معماری شبکه عصبی، تعیین نوع شبکه، تعیین تعداد بهینه لایه‌ها و گره‌های شبکه و تعیین توابع انتقالی به روش سعی و خطا برای دست یابی به یک جواب مناسب است.

مرحله دوم - آموزش شبکه: منظور از آموزش شبکه عصبی، اصلاح وزن‌های ارتباطی بین لایه‌ها و نیز وزن‌های بایاس شبکه برای نمونه‌های متعدد است. آموزش شبکه زمانی کامل می‌شود که خطای مدل یا اختلاف بین مقادیر خروجی شبکه و مقادیر هدف کمترین شود. برای رسیدن به این هدف، داده‌های آموزشی مربوط به الگوی مورد نظر چند بار به شبکه داده می‌شوند تا شبکه در هر بار با استفاده از آن‌ها وزن‌های خود را اصلاح کند. با تکرار زیاد این کار، وزن‌ها به گونه‌ای اصلاح می‌شوند که شبکه قادر است در برابر داده‌های ورودی غیر آموزشی، خروجی قابل قبول ارائه دهد.

مرحله سوم - آزمون شبکه: پس از تکمیل فرآیند آموزش شبکه و تصحیح وزن‌های آن، شبکه با استفاده از یک دسته داده‌های با خروجی معلوم مورد ارزیابی قرار می‌گیرد. در صورتی که آزمون شبکه موفقیت آمیز باشد، می‌توان از آن در تعیین مقادیر نامعلوم استفاده نمود.

آماده‌سازی داده‌ها

تقسیم بندی داده‌ها برای مراحل آموزش (Train) و آزمایش (Test) در حالات مختلفی انجام گرفت و نهایتاً از ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد مابقی برای آزمایش مدل‌ها به صورت تصادفی، استفاده شد.

در این مطالعه براساس نتایج به دست آمده از اجرای مدل‌های مختلف واسنجی‌شده فلونت به ازای تغییر موقعیت و زاویه انحراف آبگیر جانبی، یک مدل هوشمند به منظور پیش‌بینی رفتار هیدرولیکی آبگیر جانبی در میزان انحراف رسوبات بار بستر تدوین شده است. تعداد کل داده‌های بدست آمده از مدل عددی فلونت، ۴۶۵ داده به ازای موقعیت‌ها، زوایای مختلف و دبی‌های متفاوت آبگیری است که از این تعداد ۳۴۸ داده برای

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}}, i=1,2,\dots, m \quad j=1,2,\dots, n \quad (4)$$

مرحله ۲: به دست آوردن ماتریس وزن‌دار توسط رابطه زیر:

$$V_{ij} = W_j \times r_{ij} \quad (5)$$

مرحله ۳: پیدا کردن حل ایده‌آل و حل ضد ایده‌آل (عکس ایده‌آل): اگر حل ایده‌آل را با A^+ و حل ضد ایده‌آل را با A^- و نیز مجموعه معیارهای مثبت را با J^+ و مجموعه معیارهای منفی را با J^- نشان دهیم آن‌گاه داریم:

$$A^+ = \left\{ \left(\max_{j \in J^+} V_{ij} \right), \left(\min_{j \in J^-} V_{ij} \right) \right\}, \quad i=1,2,\dots,m \quad (6)$$

$$A^- = \left\{ \left(\min_{j \in J^+} V_{ij} \right), \left(\max_{j \in J^-} V_{ij} \right) \right\}, \quad i=1,2,\dots,m \quad (7)$$

مرحله ۴: محاسبه فاصله از حل ایده‌آل و حل ضد ایده‌آل برای هر گزینه i :

فاصله از حالت ایده‌آل (S_i^+) :

$$S_i^+ = \sqrt{\sum_{j=1}^n (V_{ij} - V_j^+)^2}, \quad i=1,2,\dots,m \quad (9)$$

فاصله از حالت ضد ایده‌آل (S_i^-) :

$$S_i^- = \sqrt{\sum_{j=1}^n (V_{ij} - V_j^-)^2}, \quad i=1,2,\dots,m \quad (10)$$

مرحله ۵: معیار نهایی رتبه‌بندی گزینه‌ها توسط رابطه زیر محاسبه می‌گردد:

$$C_i^* = \frac{S_i^-}{S_i^- + S_i^+} \quad (11)$$

مرحله ۶: در این مرحله رتبه‌بندی گزینه‌ها انجام می‌گیرد. گزینه‌ای که دارای بیشترین C_i^* است، رتبه اول و گزینه‌ای که دارای کمترین C_i^* است، حائز رتبه آخر خواهد بود.

۳- نتایج و بحث

۳-۱- ایجاد مدل شبکه عصبی مصنوعی

آموزش به مدل‌ها و ۱۱۷ داده برای آزمایش درستی‌آزمایی و مدل‌ها مورد استفاده قرار می‌گیرد.

معیارهای توقف شبکه عصبی

الگوریتم آموزش شبکه عصبی دارای معیارهای توقف مختلفی است و هر کدام از معیارها که زودتر برآورده شود، الگوریتم متوقف می‌شود. در مدل‌سازی این معیارها بر اساس پیش فرض های نرم افزار متلب، به صورت زیر در نظر گرفته شد:

○ تعداد تکرارها: ۱۰۰۰ تکرار

○ زمان: نامحدود

○ کارایی (خطا): ۰

○ گرادیان خطا: 10^{-7}

○ $\mu: 10^{-10}$

○ تعداد دفعات مردود شدن در اعتبار سنجی: ۶

یکی از معیارهای مهم در فرآیند آموزش شبکه‌های پرسپترون چند لایه، تعیین تعداد تکرار فرآیند آموزش به منظور دست‌یابی به وزن‌های بهینه است. در حالت کلی هر چه تعداد تکرار بیشتر شود، خطای مدل‌سازی کاهش می‌یابد. اما هنگامی که این تعداد از یک مقدار بیشتر شود، خطای آزمایش افزایش می‌یابد و سبب ایجاد پدیده وراآموزی^۱ می‌شود که در این حالت نتیجه آموزش مطلوب ولی نتیجه آزمایش نامطلوب خواهد بود. تعداد تکرارها در مدل‌سازی، بر اساس پیش فرض نرم‌افزار متلب، ۱۰۰۰ تکرار در نظر گرفته شده است.

تعیین بهترین ساختار مدل‌های شبکه عصبی مصنوعی چند لایه (MLP)

انتخاب تعداد نورون‌های لایه‌های پنهان قانون و قاعده خاص و مشخصی ندارد. معمولاً از یک لایه با تعداد زیاد نورون استفاده نمی‌شود و بهتر است از لایه‌های بیشتر با تعداد نورون‌های کمتر استفاده کرد. قانون کلی برای ساخت مدل وجود ندارد و توصیه می‌شود که مدل‌های مختلف، با

معماری‌های متفاوت آزمایش شود و با توجه به نتایج به دست آمده، بهترین آن‌ها انتخاب شود.

در این تحقیق، برای مشخص کردن بهترین ساختار و معماری شبکه عصبی، از دو شبکه عصبی پرسپترون سه لایه و چهار لایه استفاده شد. تعداد نورون‌های لایه‌های میانی از ۲ تا ۵ عدد در هر لایه استفاده شد و نتایج در هر حالت بدست آمد و بهترین ساختار برای مدل شبکه عصبی با استفاده از معیارهای R^2 و MARE تعیین شد. طبق جدول (۱) بهترین معماری شبکه عصبی به صورت یک شبکه عصبی چهار لایه با معماری $1 \times 5 \times 5 \times 3$ بدست آمد. به عبارت دیگر ۵ نورون در لایه پنهان اول و ۵ نورون در لایه پنهان دوم. لازم به ذکر است که تمام شبکه‌های عصبی در جدول زیر ۳ نورون در لایه ورودی و ۱ نورون در لایه خروجی دارند.

نوع تابع انتقال استفاده شده در مدل‌سازی‌ها، برای لایه میانی تانژانت سیگموئید و برای لایه خروجی خطی می‌باشد. الگوریتم آموزش شبکه عصبی، لونیبرگ-مارکوات^۲ انتخاب شده است.

۳-۲- اتصال بهترین ساختار مدل شبکه عصبی مصنوعی (MLP) به الگوریتم ژنتیک چند هدفه (NSGA-II)

در این مرحله، بهترین ساختار حاصل از مدل شبکه عصبی مصنوعی چند لایه (MLP)، که در مرحله قبل بدست آمده است به الگوریتم بهینه‌سازی ژنتیک چند هدفه (NSGA-II) متصل می‌شود تا با استفاده از این شبکه عصبی و الگوریتم ژنتیک چند هدفه، بتوان به جبهه پارتو دست یافت. جبهه پارتو در واقع شامل لیستی از موقعیت‌های بهینه و زاویه‌های بهینه آبنگير جانبی در کانال U شکل به شکلی است که مقدار رسوب ورودی به آبنگير جانبی، کمینه و میزان دبی آبنگيري بیشینه شود. ساختار مدل بهینه سازی دو هدفه به شکل زیر است:

$$\text{Minimize: } G_f = f(\phi, \theta, Q_f)$$

$$\text{Maximize: } Q_f$$

بطوری که G_f تابع هدف اول و Q_f تابع هدف دوم است.

جدول ۱- معماری های مختلف شبکه عصبی و خطای آموزش و آزمایش آنها

ANN Architecture	MARE train	MARE test	R ² train	R ² test
3×2×1	0.174	0.152	0.895	0.929
3×3×1	0.076	0.079	0.974	0.972
3×4×1	0.072	0.091	0.976	0.966
3×5×1	0.073	0.087	0.978	0.971
3×2×2×1	0.172	0.151	0.895	0.929
3×2×3×1	0.128	0.116	0.938	0.943
3×2×4×1	0.169	0.147	0.894	0.931
3×2×5×1	0.132	0.119	0.938	0.943
3×3×2×1	0.126	0.129	0.943	0.934
3×3×3×1	0.073	0.075	0.975	0.973
3×3×4×1	0.073	0.076	0.974	0.972
3×3×5×1	0.073	0.076	0.097	0.972
3×4×2×1	0.072	0.078	0.977	0.976
3×4×3×1	0.068	0.085	0.978	0.974
3×4×4×1	0.072	0.087	0.976	0.969
3×4×5×1	0.071	0.087	0.977	0.969
3×5×2×1	0.069	0.075	0.979	0.977
3×5×3×1	0.063	0.071	0.098	0.975
3×5×4×1	0.067	0.074	0.978	0.976
3×5×5×1	0.068	0.088	0.979	0.972

Table 1. Different neural network architectures and their training and testing errors

همچنین برای عمل تزویج با توجه به اینکه مساله بهینه سازی موجود یک مساله مقید است، از روش مقید وابسته^۱ استفاده شده است.

معیارهای توقف الگوریتم ژنتیک

روند همگرایی الگوریتم ژنتیک با معیارهای توقف الگوریتم ژنتیک تعریف می شود. معیارهای توقف تعیین می کند که چه چیزی باعث خاتمه الگوریتم می شود. این معیارها شامل موارد زیر است که مقدار آن بر اساس پیش فرض های نرم افزار متلب انتخاب شده است:

- تعداد نسل ها یا حداکثر تعداد تکرارها^۲
- پیش فرض: ۱۰۰ برابر تعداد متغیرهای ورودی
- محدودیت زمانی^۳
- بیشترین زمانی را برحسب ثانیه مشخص می کند که الگوریتم ژنتیک قبل از توقف اجرا می شود. پیش فرض: بی نهایت
- حد تناسب^۴

با توجه به اینکه پیش فرض الگوریتم ژنتیک بر کمینه سازی توابع هدف می باشد و از آنجا که تابع هدف دوم یعنی Q_f باید ماکزیمم شود، پس از تابع $-Q_f$ برای مینیمم سازی استفاده شده است. در این الگوریتم ژنتیک دو هدف، تعداد متغیرهای تصمیم ۳ می باشد. تعداد تکرارها برابر ۱۰۰۰ نسل در نظر گرفته شد. یکی دیگر از شرایط توقف الگوریتم عدم ایجاد تغییر در جواب ها بعد از ۵۰ نسل تکرار خواهد بود.

بر اساس پیش فرض نرم افزار متلب، درصد تزویج ۸۰٪ جمعیت اولیه و درصد نخبه گرایی برابر با ۵٪ جمعیت اولیه انتخاب شد. بنابراین درصد مربوط به عمل جهش بطور خودکار ۱۵٪ انتخاب می شود. لازم به ذکر است جمعیت اولیه برای هر یک از متغیرهای تصمیم برابر با ۶۰ انتخاب شده است. جمعیت اولیه ۲۰ برابر تعداد متغیرهای تصمیم در نظر گرفته می شود که برابر ۶۰ خواهد بود. برای انتخاب والدین در الگوریتم ژنتیک روش های مختلفی از قبیل انتخاب رقابتی، چرخ رولت، انتخاب تصادفی و ... وجود دارد که برای این مهم بر اساس پیش فرض نرم افزار متلب از روش انتخاب تصادفی استفاده شده است.

³ Time limit
⁴ Fitness limit

¹ Constraint dependent
² Generations

ژنتیک چند هدفه NSGA-II در شکل (۳) نشان داده شده است. جبهه پارتو شامل لیستی از مقدار درصد رسوب ورودی به آبنگیر و دبی انحرافی در موقعیت‌های و زاویه‌های بهینه آبنگیر جانبی در کانال U شکل حاصل از اجرای الگوریتم ژنتیک چند هدفه می‌باشد. در این شکل تابع هدف اول عبارتست از مینیمم سازی میزان رسوب ورودی به آبنگیر جانبی (G_r) و تابع هدف دوم عبارتست از ماکزیمم سازی میزان دبی آبنگیری (Q_r).

۳-۳- تعیین موقعیت و زاویه انحراف بهینه آبنگیر جانبی با استفاده از روش‌های TOPSIS

در این مرحله باید از بین تعداد زیاد جواب‌های بدست آمده در جبهه پارتو در مرحله قبل، بهینه ترین جواب شامل بهینه ترین موقعیت و بهینه ترین زاویه آبنگیر جانبی در کانال U شکل را بدست آورد. انتخاب یک جواب از بین جواب‌های موجود در جبهه پارتو کار آسانی نمی‌باشد و معیار خاصی نیز برای آن وجود ندارد. بدین منظور از اتصال جبهه پارتو بدست آمده از الگوریتم ژنتیک چند هدفه (NSGA-II) در مرحله قبل به روش‌های چندمعیاره مانند TOPSIS، برای تعیین بهینه‌ترین گزینه از بین گزینه‌های موجود در جبهه پارتو استفاده می‌شود. در جدول جواب‌های بهینه بدست آمده از جبهه پارتو در مرحله قبل به همراه رتبه TOPSIS نمایش داده شده است.

۴- نتیجه‌گیری

در این تحقیق با تدوین یک متدولوژی جدید شبیه سازی بهینه‌سازی بر مبنای مدل بهینه‌سازی الگوریتم ژنتیک چند هدفه، مدل عددی FLUENT و مدل شبکه عصبی مصنوعی، موقعیت و زاویه بهینه آبنگیر جانبی در کانال U شکل تعیین شد به گونه‌ای که مقدار رسوب ورودی به آبنگیر جانبی، کمینه و میزان دبی آبنگیری بیشینه شود.

اگر بهترین مقدار تابع برازش کمتر یا مساوی با مقدار حد تناسب باشد، الگوریتم متوقف می‌شود. پیش فرض: منهای بی نهایت

- نسل‌های بدون تغییر^۱

اگر میانگین وزنی تغییر نسبی در جواب‌های جبهه پارتو کمتر این تعداد نسل باشد، الگوریتم متوقف می‌شود. پیش فرض: ۱۰۰ نسل

- محدودیت زمانی بدون تغییر^۲

اگر بهبودی در بهترین مقدار تابع برازش برای بازه زمانی بر حسب ثانیه مشخص شده توسط "محدودیت زمانی بدون تغییر" وجود نداشته باشد، الگوریتم متوقف می‌شود.

- نوسان تابع^۳

اگر میانگین وزنی تغییر نسبی در گسترش جواب‌های جبهه پارتو در نسل‌های بدون تغییر کمتر از نوسان تابع باشد، الگوریتم متوقف می‌شود. پیش فرض: 1×10^{-4}

- نوسان قید^۴

بیشترین نوسان برای نقض محدودیت‌های خطی است. پیش فرض: 1×10^{-3}

شکل ۳- جبهه پارتو حاصل از الگوریتم ژنتیک چند هدفه




Fig 3. Pareto front of NSGA-II algorithm

پس از پایان بهینه سازی، یک سری جواب برای متغیرهای ورودی (X_i ها) و توابع هدف بدست می‌آید. جبهه پارتو بدست آمده از اتصال شبکه عصبی مصنوعی MLP به الگوریتم

جدول ۲-جواب‌های بهینه‌ی بدست آمده از جبهه پارتو به همراه رتبه TOPSIS

θ	ϕ	Q_r	G_r	TOPSIS Rank
37.38	125.88	0.3	0.07	18
37.82	124.68	0.2	0.07	19
38.64	126.87	0.4	0.1	15
37.86	124.67	0.21	0.07	21
38.64	126.87	0.4	0.1	16
38.37	126.53	0.39	0.1	13
37.9	125.71	0.32	0.07	10
38.16	125.83	0.33	0.08	7
37.95	126.22	0.31	0.07	17
38.4	126.58	0.36	0.09	5
38.2	126.81	0.36	0.08	1
38.6	126.79	0.38	0.09	11
38.42	126.64	0.4	0.1	14
37.87	125.88	0.32	0.08	9
38.15	125.16	0.36	0.09	4
37.82	124.68	0.2	0.07	20
38.14	126.29	0.34	0.08	3
38.22	125.94	0.38	0.09	8
38.62	126.87	0.39	0.1	12
38.11	125.91	0.35	0.08	2
38.37	126.53	0.33	0.08	6

Table 2. Optimum alternatives of Pareto front and TOPSIS ranks

۴۵ درجه برای زاویه آبیگری جانبی توصیه شده است. همچنین به لحاظ آبشستگی موضعی در حالت آب زلال نیز استقرار آبیگر در موقعیت ۱۱۵ درجه توسط ایشان توصیه شده است. در مطالعه رضوان (۱۹۸۹) محل قرارگرفتن آبیگر در بخش خارجی کانال قوسی، به منظور حداقل نمودن ورود رسوبات درشت به آبیگر، در سه چهارم زاویه مرکزی قوس متاندر (زاویه بین ۹۰ تا ۱۳۵ درجه) پیشنهاد شده است.

جدول ۳- موقعیت و زاویه بهینه آبیگر جانبی در کانال U شکل

Model	θ_{optimum}	ϕ_{optimum}	Q_r (%)	G_r (%)
ANN (MLP)	38.2	126.81	36	8

Table 3. Optimum position and diversion angle of lateral intake in the U shape channel

۴- منابع

[1] Joglekar, D.V., (1971), Manual on river behavior control and training (No. 60). Central Board of Irrigation and Power.

در جدول (۳) نتایج بدست آمده به همراه میزان زاویه آبیگری بهینه و موقعیت بهینه و دبی و رسوب بدست آمده نمایش داده شده است. مقدار زاویه آبیگری بهینه بدست آمده توسط این روش برابر با ۳۸ درجه و موقعیت بهینه بدست آمده توسط این روش برابر با ۱۲۷ درجه می‌باشد.

جواب‌های حاصل از این تحقیق برای موقعیت و زاویه بهینه آبیگر جانبی در محدوده‌های ذکر شده توسط پژوهشگران قبلی از جمله پیرستانی (۱۳۸۳)، دهقانی (۱۳۸۵) و رضوان (۱۹۸۹) می‌باشد. پیرستانی (۱۳۸۳) در مطالعه خود در کانال قوسی ۱۸۰ درجه روی الگوی جریان در اطراف آبیگرهای جانبی موجود در قوس موقعیت آبیگری ۱۱۵ درجه و زاویه آبیگری ۶۰ درجه را نسبت به محل‌های دیگر توصیه نمود. در مطالعه آزمایشگاهی دهقانی (۱۳۸۵) روی کنترل رسوب در آبیگری جانبی از قوس ۱۸۰ درجه در ۵ موقعیت ۹۰°، ۱۰۲°، ۱۱۵°، ۱۳۵° و ۱۵۰° با زوایای آبیگری ۴۵°، ۶۰° و ۷۵°، در شرایط وجود بار بستر در قوس ۱۸۰ درجه، زاویه مرکزی قوس بین ۱۱۵ تا ۱۳۵ درجه برای محل قرارگیری آبیگر در قوس خارجی و زاویه انحراف

- [15] Seifi. A., Riahi-madvar. H., (2018). "Improving one-dimensional pollution dispersion modeling in rivers using ANFIS and ANN-based GA optimized models", Springer, Volume 26, Issue 1, pp 867-885.
- [16] Arab, M., Nikoo, M., Afzali, S., S., (1395), Determination of optimum dimension of roller bucket of dams, Omran Modares Journal (In pension).
- [17] Aboutalebi, M., Haddad, OB. (2015) "Application of the SVR-NSGAII to hydrograph routing in open channels", Journal of Irrigation and Drainage Engineering Volume 142 ,Issue 3.
- [18] Behzadian, K., Ardeshir, A., (2008), "Multi-objective Sampling Design for Calibration of Water Distribution Network Model Using Genetic Algorithm and Neural Network", AIP Conference Proceedings, Volume 1298.
- [19] Bhattacharjya, RK., Datta, B. (2009), "ANN-GA-based model for multiple objective management of coastal aquifers", Journal of Water Resources Planning.
- [20] Zhang, j., Zhu,H.,Yang, C. et al. (2011), "Multi-objective shape optimization of helico-axial multiphase pump impeller based on NSGA-II and ANN" Volume 52, Issue 1, January 2011, Pages 538-546.
- [21] Tavakolli, K., Montaseri, H., (2017) Evaluating of two-phase models for numerical Simulation of sediment transport in a 180-degree Bend with lateral intake. MCEJ; 17 (2) :81-92 (In pension).
- [22] Montaseri, H., (2008). Sediment control at lateral intakes by submerged vanes in a 180-degree channel bend, Doctoral dissertation, Ph. D. thesis, Faculty of Civil and Environmental Engineering, Tarbiat Modares University, Tehran, Iran, (In pension).
- [23] Jang, J.S.R., Sun, C.T. and Mizutani, E., (1997). Neuro-fuzzy and soft computing-a computational approach to learning and machine intelligence. IEEE Transactions on automatic control, 42(10), pp.1482-1484.
- [24] Deb, K., Pratap, A., Agarwal, S. and Meyarivan, T.A.M.T., (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. IEEE transactions on evolutionary computation, 6(2), pp.182-197.
- [25] Karamouz, M. and Kerachian, R., (2003). Water quality planning and management. Amirkabir University of Technology (AUT), 173(1304-1308), p.58.
- [2] Blanchet, C., (1975), Canal Intakes Problems and Method Used to Reduce the Sediment Inflow. ICID, 9th Congress Moscow, 22: 293-302.
- [3] Razvan, E., (1989), "River Intake and Diversion Dams", Elsevier Science Publishing Company Inc. New York, NY. 10010, USA.
- [4] Novak, P., Moffat, A. and Nalluri, C., (1990). "Hydraulic Structures", Pitman, London.
- [5] Pirestani, M., (1383) "Investigating of flow and sedimentation pattern at lateral intake in channel bends", PhD thesis, Azad university (In pension).
- [6] Dehghani, A., A., (1385), Experimental study of sediment control at lateral intake in 180-degree bend, PhD THESIS, TMU (In pension).
- [7] Tavakolli, K., Montaseri, H., (2017) Evaluating of two-phase models for numerical Simulation of sediment transport in a 180-degree Bend with lateral intake. MCEJ; 17 (2) :81-92 (In pension).
- [8] Arab, M., Nikoo, M., Afzali, S., S., (2016), Determination of optimal dimensions of flip buckets by the simulation-optimization approach Case Study: The Jareh Dam. MCEJ; 16 (4) :175-186 (In pension).
- [9] Lin, Y., Wen., H., liu., SH, (2019), "Surface runoff response to climate change based on artificial neural network (ANN) models: a case study with Zagunao catchment in Upper Minjiang River, Southwest China", Journal of Water and Climate Change 10 (1): 158-166.
- [10] Gholami V, Borna F, Hadian B. (2021), Estimation of Soil Erosion using Artificial Neural Network (ANN) and Geographic Information System (GIS) on the Rangeland Hillslopes. jwmr; 12 (24) :147-158.
- [11] Karami, H., Ardeshir, A., Saneie M., Salamation A, (2012), "Prediction of time variation of scour depth around spur dikes using neural networks", J. Hydroinformatics 14(1), 180-191.
- [12] Ghumman, AR., Ghazaw, YM., Sohail, AR. et al., (2011), "Runoff forecasting by artificial neural network and conventional model", Alexandria Engineering Journal, Volume 50, Issue 4, Pages 345-350.
- [13] Emiroglu, ME., O Bilhan, O Kisi (2011), Expert Systems with Applications, "Neural networks for estimation of discharge capacity of triangular labyrinth side-weir located on a straight channel", Volume 38, Issue 1, Pages 867-874.
- [14] Imrie, CE., Durucan, S., Korre, A., (2000) "River flow prediction using artificial neural networks: generalisation beyond the calibration range", Journal of Hydrology, Volume 233, Issues 1-4, Pages 138-153.

Optimization of location and diversion angle of lateral intakes in U shaped channels

Hossein Montaseri^{*1}, Zahra Jamalabadi¹

1- Department of civil engineering, Faculty of engineering, Yasouj University, Yasouj, Iran

Email: hmontaseri@yu.ac.ir^{*}

Abstract:

Lateral intake and stream diversion facilities, which are widely used in irrigation, land drainage and municipal sewage systems, deal with sediment transport. In this research, using the FLUENT numerical model, Genetic Algorithm and neural network model, the optimal position and diversion angle of the lateral intake in the U-shaped channel is determined to minimize the amount of sediment inflow into the lateral basin and maximize the rate of dewatering discharge.

At first, simulation of the sediment transport phenomenon is carried out using FLUENT software in a 180-degree channel bend with a lateral intake that is located at a position of 115 degrees outside the arc and with a 45-degree diversion angle. The numerical model was calibrated with laboratory data.

Then, in 31 positions of the channel bend from the 10 to 140 degrees with 5 degrees' intervals and with 5 diversion angles of 10, 30, 50, 70 and 90 degrees, and for three diversion discharge ratios of 20%, 30% and 40%, the calibrated numerical model has been implemented and the percentage of sediment entered to the lateral intake were determined for each model. The results were used as the data necessary for training and validation of Artificial neural network (ANN) model.

By connecting the best model obtained from the ANN model, to NSGA-II model, the Pareto Front contains a list of optimal positions and optimal diversion angle of lateral intake are obtained with respect to the objective function and its limitations in the U-shaped channel.

Finally, to determine the optimal position and angle of the lateral basin in the U-shaped channel by connecting the Pareto front obtained from the Multi objective Genetic Algorithm (NSGA-II) to the TOPSIS multi-criteria decision-making method, the best option is found among the Pareto front options. The results include the optimum position and optimum angle of lateral intake dewatering along with diversion discharge and sediment rates corresponding to these values. The results show that the optimum diversion angle obtained is 38-degree and the optimum position obtained is 127-degree.

Keywords: Lateral intake, U shape channel, genetic algorithm, Fluent software, ANN.