

## بررسی عملکرد ماشین‌های یادگیری در تخمین ضریب دبی آبگذری آبگیرهای کفی با روزنه دایره‌ای

علی میرنوراللهی<sup>۱</sup>، حجت کریمی<sup>۲\*</sup>، سعید فرزین<sup>۳</sup>، مجتبی عامری<sup>۴</sup>

تاریخ ارسال: ۱۳۹۹/۰۹/۲۸

تاریخ پذیرش: ۱۴۰۰/۰۲/۲۴

مقاله پژوهشی برگرفته از پایان نامه نویسنده اول

### چکیده

با توسعه فناوری و پیشرفت تکنولوژی، روش‌های هوشمند بسیاری برای تخمین ضریب آبگذری سازه‌های هیدرولیکی مختلف پدید آمده است. یکی از سازه‌هایی که در نیروگاه‌های برقابی کاربرد دارد، سازه آبگیر کفی است. وظیفه این سازه، انتقال جریان به کانال جمع‌آوری است. از مزیت‌های این سازه می‌توان به پایداری آن‌ها در برابر بارهای دینامیکی و استاتیکی به دلیل قرارگیری این سازه‌ها در پایین‌ترین تراز اشاره کرد. در پژوهش حاضر، چهار الگوریتم هوشمند توانمند ماشین یادگیری مضاعف (ELM)، شبکه‌های عصبی رگرسیون عمومی (GRNN)، مدل رگرسیون خود تطبیق شونده (MARS) و مدل درخت M5 در مدل‌سازی ضریب آبگذری آبگیر کفی مورد ارزیابی قرار گرفته است. نتایج مدل‌سازی نشان داد که الگوریتم ELM در هر دو دوره آموزش (۷۰ درصد داده‌ها) و آزمون (۳۰ درصد داده‌ها) از دقت بیشتری نسبت به سایر الگوریتم‌های بررسی شده برخوردار است. به طوری که ضریب  $R^2$  برای الگوریتم مذکور تا ۳/۷۴ درصد بیشتر از دیگر الگوریتم‌های استفاده شده بود. همچنین معیار DDR و هیستوگرام خطای مدل‌سازی بیانگر برتری الگوریتم ELM بود. در نهایت نیز سرعت محاسبه الگوریتم‌های به کار برده شده مورد مقایسه قرار گرفت که الگوریتم ELM تا ۲/۵۵۷ برابر سریع‌تر از سایر الگوریتم‌ها بود. بنابراین، الگوریتم ELM به دلیل دقت خوب و در عین حال سرعت زیاد، دارای پتانسیل بالا جهت مدل‌سازی ضریب آبگذری سرریزها است.

واژه‌های کلیدی: الگوریتم‌های هوشمند، ماشین یادگیری مضاعف، آبگیر کفی روزنه‌ای، ضریب آبگذری، روزنه دایره‌ای

<sup>۱</sup> - دانشجوی کارشناس ارشد، مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، ایران، ۰۹۱۲۰۱۸۲۷۲۳. [alimimurollahi@semnan.ac.ir](mailto:alimimurollahi@semnan.ac.ir)

<sup>۲\*</sup> - دانشیار، گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، ایران، ۰۹۱۲۴۸۰۳۳۵۰. [hkarami@semnan.ac.ir](mailto:hkarami@semnan.ac.ir) (نویسنده مسئول)

<sup>۳</sup> - دانشیار، گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، ایران، ۰۹۱۷۴۱۱۲۸۹۱. [saeed.farzin@semnan.ac.ir](mailto:saeed.farzin@semnan.ac.ir)

<sup>۴</sup> - استادیار، گروه مهندسی عمران، واحد شاهرود، دانشگاه آزاد اسلامی، شاهرود، ایران، ۰۹۱۲۳۷۳۰۱۰۸. [m\\_ameri@iau-shahrood.ac.ir](mailto:m_ameri@iau-shahrood.ac.ir)



## مقدمه

با پیشرفت تکنولوژی و توسعه نرم افزارها، روش های مختلفی برای حل مسایل هیدرولیکی پدید آمده است. یکی از آن روش ها، الگوریتم های هوشمند است که با استفاده از آن ها می توان پارامترهای هیدرولیکی سازه های هیدرولیکی را مورد ارزیابی قرار داد. یکی از سازه های هیدرولیکی مهم در نیروگاه های برقابی که از اهمیت بسیاری برخوردار است، سازه آبگیر کفی است. به دلیل عمق کم جریان و محدودیت شرایط برای احداث انواع آبگیر جانبی، در رودخانه های کوهستانی با شیب تند و با رسوبات درشت دانه، مناسب ترین آبگیر، آبگیر کفی می باشد (Bouvard, 1992). از آنجایی که نیروگاه های برقابی در کنار رودخانه های کوهستانی با شیب زیاد ساخته می شوند، امروزه آبگیرهای کفی به عنوان یکی از اجزای مهم پروژه های برق آبی شناخته می شوند (Kamanbedast & Bejestan, 2008). کف های مشبک در ساخت جریان شکن های کوچک نیز به کار می روند (Mizuyama & Mizuno, 1994). در برخی حالات که ارتفاع آب پایین دست کانال ها منشوری افزایش یافته است، می توان از کف مشبک به عنوان مستهلک کننده انرژی استفاده کرد. از دیگر مزایا این نوع آبگیر نسبت به آبگیرهای دیگر مقاومت در برابر بارهای استاتیکی و دینامیکی به دلیل قرارگیری در پایین تراز کانال می باشد (Viparelli, 1963) و (Orth et al., 1954). در آبگیرهای کفی روزنه ای، با قرار گرفتن روزنه با قطر مشخص در فواصل معین از هم در صفحه، امکان آبیگری را فراهم می سازند. عمده ترین مشکل در این نوع آبگیرها نیز، گرفتگی بر اثر تجمع رسوبات، ایجاد گردابه، محبوس شدن هوا و یخ زدگی ورودی ها می باشد (Lund, 2005).

در چند دهه اخیر، مطالعاتی در زمینه آبگیر کفی انجام گردیده است و کارهایی نظیر (Brunella, 2003)، (Shafai bajestan & Kamanbedast, 2008) و (Bina, 2018) به صورت آزمایشگاهی انجام شده است. همچنین در بررسی آبگیرهای کفی به صورت عددی، افرادی همچون (Aghamajidi & Heydari, 2014) و (Castillo et al., 2017)، بررسی هایی انجام داده اند. در زمینه هوش مصنوعی نیز در پژوهش های انجام شده در

زمینه سرریز و آبگیرها می توان به (Kocabaş et al., 2008)، (Emiroglu et al., 2009)، (Kocabaş et al., 2009)، (Emiroglu et al., 2011) و (Azamathulla et al., 2016) اشاره کرد. در ادامه به بررسی دقیق مطالعات مهم دو دهه اخیر پرداخته شده است.

فرودی خور و همکاران در سال ۱۳۹۶ با استفاده از روش استنتاج فازی-عصبی تطبیقی و ماشین بردار پشتیبان به تخمین ضریب آبگذری سرریز لبه تیز پرداختند. آن ها دریافتند که هر دو روش به خوبی ضریب آبگذری این سازه را تخمین می زند (فرودی خور و همکاران، ۱۳۹۶). ظهیری با استفاده از روش برنامه ریزی ژنتیک روابطی برای ضریب آبگذری سرریز قوسی بدست آورد (ظهیری، ۱۳۹۳).

کیسی و همکاران در سال ۲۰۱۲ به بررسی عملکرد سرریز جانبی نوک مرغابی و مثلثی در شرایط زیربحرانی پرداختند. آن ها دریافتند که روش ANN و GEP عملکرد بهتری نسبت به روش رگرسیونی دارد (Kisi et al., 2012). (Salmasi et al., 2013) به پیش بینی ضریب آبگذری سرریز مرکب با روش های GP و ANN پرداختند. نتایج ایشان نشان داد که روش GP دقت بیشتری نسبت به ANN دارد.

(Zaji et al., 2016) با استفاده از روش ماشین بردار پشتیبان ضریب آبگذری برای سرریز جانبی را پیش بینی کردند و نتیجه گرفتند که اگر داده های ورودی بیشتر باشد، نتایج بهتری حاصل می شود. در پژوهش ایشان از دو روش SVR-rbf و SVR-poly استفاده شده است که دقت روش اول بهتر از روش دوم می باشد. مهری و همکاران در سال ۲۰۱۹ سعی در پیش بینی ضریب آبگذری سرریز کلید پیانویی با روش GMDH و DGMDH داشته اند. آن ها پس از بررسی ها دریافتند که روش DGMDH از روش دیگر از دقت بیشتری برخوردار است (Mehri et al., 2019).

(Righetti & Lanzoni, 2008) مطالعه آزمایشگاهی خود را بر روی کف مشبک با میله در امتداد جریان در شرایط فوق بحرانی انجام دادند. آن ها در نهایت رابطه ای برای ضریب آبگذری این نوع آبگیرها ارائه کردند. (Hosseini et al., 2014) با بررسی اثر شکل مقطع عرضی میله ها در آبگیرهای کفی با میله هایی در امتداد جریان دریافتند که بهترین شکل مقطع عرضی میله برای انحراف جریان، مقطع

شده است، لیکن به جایگاه الگوریتم‌های هوشمند در این زمینه توجه چندانی نشده است و همچنین ارزیابی مقایسه عملکرد این الگوریتم‌ها مغفول مانده است. این پژوهش با هدف بررسی امکان استفاده از روش‌های ماشین یادگیری مضاعف، شبکه‌های عصبی رگرسیون عمومی، رگرسیون اس پی لاین خود تطبیق شونده و درخت M5 در ایجاد رابطه‌ای بین پارامترهای ورودی (شیب طولی کف مشبک، عدد فرود بالادست کف مشبک، تعداد روزنه و نسبت مساحت بازشدگی) و پارامتر پیش‌بینی شونده (ضریب آبگذری) انجام شده است. همچنین در ادامه با مقایسه نتایج حاصل از این پیش‌بینی با داده‌های آزمایشگاهی معتبر، و همچنین سرعت مدل‌سازی بهترین مدل معرفی شده است.


## مواد و روش

### مشخصات آزمایشگاهی

آزمایش‌های مورد نظر در یک کانال مستطیلی به عرض ۰/۶ متر، عمق ۰/۶ متر و طول ۱۰ متر با ضریب زبری ۰/۰۸۵ انجام پذیرفت. محل قرارگیری کانال فرعی در فاصله ۳/۶ متری تا ۴/۲ متری از کانال اصلی با عرض ۰/۶ متر، عمق ۰/۴ متر و طول ۴/۵ متر قرار گرفته است. در انتهای کانال فرعی به منظور اندازه‌گیری دبی عبوری از کف مشبک، سرریز مثلثی کالیبره شده قرار گرفته است. در ابتدای کانال فرعی یک شبکه فلزی به منظور آرام و منظم نمودن خطوط جریان تعبیه گردید تا در طول سرریز همواره جریانی آرامی عبور نماید. برای اندازه‌گیری ارتفاع آب بر روی کف مشبک، از دستگاه عمق سنج دیجیتال با دقت ۰/۰۱ میلی‌متر استفاده شده است. دبی ورودی نیز توسط یک دبی سنج آلتراسونیک با دقت ۰/۰۱ لیتر بر ثانیه اندازه‌گیری گردید. مشخصات کانال و متعلقات آن در شکل ۱ آورده شده است. لازم به ذکر است که تمامی آزمایش‌ها در دانشگاه آزاد اسلامی شاهرود انجام شده است

عرضی لوزوی است و در این نوع آبگیرها با میله‌های لوزوی شکل، توزیع فشار یکنواخت‌تر از اشکال دیگر است. بینا و ساقی به بررسی آزمایشگاهی آبگیر از کف توسط محیط متخلخل پرداخته‌اند. آن‌ها رابطه‌ای برای این نوع آبگیر بر اساس  $\frac{L}{y_0}$  و  $S_0$  و  $\varepsilon$  ارائه کردند (L طول صفحه مشبک،  $y_0$  عمق جریان نزدیک شونده،  $S_0$  شیب طولی صفحه مشبک و  $\varepsilon$  درصد بازشدگی کف ریز می‌باشد). همچنین دریافتند که وجود رسوبات به صورت بار بستر در آزمایش‌های این تحقیق باعث کاهش ضریب تخلیه به میزان ۲/۷۵ درصد نسبت به حالت جریان بدون رسوب گشته است (Bina & Saghi, 2017).

(Castillo et al., 2013) مطالعه عددی خود را با استفاده از نرم‌افزار Flow-3D در زمینه آبگیر کفی با میله انجام دادند. آن‌ها در مطالعات خود بر روی آبگیر کفی، اثر رسوب را نیز در نظر گرفتند و دریافتند که جریان حاوی رسوب، طول مرطوب آبگیر کفی را بیشتر می‌کند. علت این امر گرفتگی فضای بین میله‌ها توسط رسوبات است. از دیگر دستاورد پژوهش آن‌ها می‌توان به دقت بالای پیش‌بینی پروفیل سطح آب اشاره کرد. (Chang et al., 2018) با مدل‌سازی عددی جریان فوق بحرانی در آبگیرهای کفی توسط میله در امتداد جریان، به بررسی اختلاط آب و هوا در این نوع آبگیرها پرداختند. آن‌ها با دبی و شکل میله‌های مختلف با نرم‌افزار Ansys 2013 موفق به انجام این امر شدند. آن‌ها دریافتند که پس از عبور جریان از ناحیه بازشدگی بین میله‌ها جت آبی تشکیل می‌شود که باعث تداخل هوا با جریان می‌شود. در ادامه با ورود این جت آب، جریان چرخشی پدید می‌آید که باعث جذب هوا و آشفتگی می‌شود. آن‌ها همچنین دریافتند که غلظت هوا در جریان عبوری از میله‌ها با دبی ورودی رابطه معکوسی دارد. با بررسی مطالعات فوق مشخص می‌شود که اگرچه مطالعات چندی در زمینه تخمین ضریب آبگذری آبگیر کفی انجام



شکل (۱): مشخصات آزمایشگاه و متعلقات آن

فرود بالادست کف مشبک (Fr1) بررسی شد. لازم به ذکر است که نسبت مساحت بازشدگی از تقسیم مساحت روزنه‌ها به مساحت کل کف مشبک بدست می‌آید. در جدول ۱ محدوده پارامترهای هندسی و هیدرولیکی استفاده شده در آزمایش‌ها و ورودی و خروجی الگوریتم را نشان می‌دهد.

**محدوده پارامترهای هندسی و هیدرولیکی**  
در آزمایشات انجام شده برای بدست آوردن ضریب آبگذری، ۵۴ آزمایش انجام شد. به منظور بررسی عوامل موثر بر این پارامتر، شیب طولی کف مشبک (S)، نسبت مساحت بازشدگی کف مشبک (A)، تعداد روزنه (N) و عدد

جدول (۱): محدوده پارامترهای هندسی و هیدرولیکی آزمایش‌ها و ورودی و خروجی‌های الگوریتم

ورودی						خروجی					
Num	A	N	Fr <sub>1</sub>	S	C <sub>d</sub>	Num	A	N	Fr <sub>1</sub>	S	C <sub>d</sub>
۲۸	۰/۰۷	۹	۰/۵	۱۰	۰/۸۱	۱	۰/۰۷	۹	۰/۵	۰	۱/۰۹
۲۹	۰/۰۷	۹	۰/۷	۱۰	۰/۹۱	۲	۰/۰۷	۹	۰/۷	۰	۱/۲۵
۳۰	۰/۰۷	۹	۰/۹	۱۰	۱/۰۲	۳	۰/۰۷	۹	۰/۹	۰	۱/۴۳
۳۱	۰/۰۳	۹	۰/۵	۱۰	۰/۷۳	۴	۰/۰۳	۹	۰/۵	۰	۱/۱۲
۳۲	۰/۰۳	۹	۰/۷	۱۰	۰/۸۶	۵	۰/۰۳	۹	۰/۷	۰	۱/۲۶
۳۳	۰/۰۳	۹	۰/۹	۱۰	۰/۹۲	۶	۰/۰۳	۹	۰/۹	۰	۱/۳۸
۳۴	۰/۰۱	۹	۰/۵	۱۰	۰/۹۹	۷	۰/۰۱	۹	۰/۵	۰	۱/۷۹
۳۵	۰/۰۱	۹	۰/۷	۱۰	۱/۰۷	۸	۰/۰۱	۹	۰/۷	۰	۱/۸۴
۳۶	۰/۰۱	۹	۰/۹	۱۰	۱/۱۰	۹	۰/۰۱	۹	۰/۹	۰	۱/۸۹
۳۷	۰/۰۷	۶	۰/۵	۱۰	۰/۸۴	۱۰	۰/۰۷	۶	۰/۵	۰	۱/۳۱
۳۸	۰/۰۷	۶	۰/۷	۱۰	۰/۹۲	۱۱	۰/۰۷	۶	۰/۷	۰	۱/۳۲
۳۹	۰/۰۷	۶	۰/۹	۱۰	۱/۰۳	۱۲	۰/۰۷	۶	۰/۹	۰	۱/۳۹
۴۰	۰/۰۳	۶	۰/۵	۱۰	۰/۹۰	۱۳	۰/۰۳	۶	۰/۵	۰	۱/۳۴
۴۱	۰/۰۳	۶	۰/۷	۱۰	۱/۰۲	۱۴	۰/۰۳	۶	۰/۷	۰	۱/۵۰
۴۲	۰/۰۳	۶	۰/۹	۱۰	۱/۰۹	۱۵	۰/۰۳	۶	۰/۹	۰	۱/۶۳
۴۳	۰/۰۱	۶	۰/۵	۱۰	۱/۱۵	۱۶	۰/۰۱	۶	۰/۵	۰	۱/۸۳
۴۴	۰/۰۱	۶	۰/۷	۱۰	۱/۲۶	۱۷	۰/۰۱	۶	۰/۷	۰	۱/۹۸
۴۵	۰/۰۱	۶	۰/۹	۱۰	۱/۳۶	۱۸	۰/۰۱	۶	۰/۹	۰	۲/۰۲
۴۶	۰/۰۷	۳	۰/۵	۱۰	۰/۹۹	۱۹	۰/۰۷	۳	۰/۵	۰	۱/۳۵
۴۷	۰/۰۷	۳	۰/۷	۱۰	۱/۰۵	۲۰	۰/۰۷	۳	۰/۷	۰	۱/۴۵
۴۸	۰/۰۷	۳	۰/۹	۱۰	۱/۱۵	۲۱	۰/۰۷	۳	۰/۹	۰	۱/۵۵
۴۹	۰/۰۳	۳	۰/۵	۱۰	۱/۰۸	۲۲	۰/۰۳	۳	۰/۵	۰	۱/۵۶
۵۰	۰/۰۳	۳	۰/۷	۱۰	۱/۱۷	۲۳	۰/۰۳	۳	۰/۷	۰	۱/۶۳
۵۱	۰/۰۳	۳	۰/۹	۱۰	۱/۱۸	۲۴	۰/۰۳	۳	۰/۹	۰	۱/۷۶
۵۲	۰/۰۱	۳	۰/۵	۱۰	۱/۲۷	۲۵	۰/۰۱	۳	۰/۵	۰	۱/۹۵
۵۳	۰/۰۱	۳	۰/۷	۱۰	۱/۳۶	۲۶	۰/۰۱	۳	۰/۷	۰	۲/۲۱
۵۴	۰/۰۱	۳	۰/۹	۱۰	۱/۴۸	۲۷	۰/۰۱	۳	۰/۹	۰	۲/۲۳




الگوریتم یادگیری قدرتمند و ساده تنها از یک لایه پنهان تشکیل شده است. ساختار این الگوریتم مانند یک شبکه عصبی پیش رو تک لایه می‌باشد (Feng et al., 2016). ELM نیازی به تعیین پارامترهای پیچیده ندارد و دارای عملکرد بهتر و سرعت بیشتر از الگوریتم های سنتی می‌باشد. به طور کلی، مدل های ELM از سه لایه تشکیل شده است: لایه ورودی، لایه پنهان و لایه خروجی، که توسط نوروں ها به هم متصل می شوند. مزایای استفاده از ELM عبارتند از: (۱) لایه پنهان نیازی به تنظیم ندارد و (۲) سرعت یادگیری بسیار سریعتر از شبکه های عصبی سنتی تغذیه ای است (Abdullah et al., 2015). شکل ۲ ساختار روش ماشین یادگیری مضاعف را نشان می‌دهد.

طبق جدول ۱، پارامترهای  $A$ ،  $S$ ،  $N$  و  $Fr_1$  به عنوان ورودی، و  $C_d$  به عنوان خروجی در نظر گرفته شده است. همچنین در پژوهش حاضر ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد داده‌ها برای آزمون انتخاب شده است. همچنین، انتخاب داده به صورت تصادفی بوده است. در ادامه به منظور نرمال کردن داده‌ها از رابطه ۱ استفاده شده است.

$$X_{Normal} = \frac{X - X_{Min}}{X_{Max} - X_{Min}} \quad (1)$$

ماشین یادگیری مضاعف (ELM)

روش ماشین یادگیری مضاعف برای اولین بار توسط (Huang et al., 2006) معرفی شد، که به عنوان یک



شکل (۲): ساختار روش ماشین یادگیری مضاعف


### رگرسیون اس پی لاین خود تطبیق شونده (MARS)

رگرسیون اس پی لاین خود تطبیق شونده یک مدل غیر خطی است که برای پیش‌بینی نتایج عددی استفاده می‌شود. یکی از مزیت‌های این روش ایجاد رابطه غیر خطی بین متغیرهای پیش‌بینی کننده و پیش‌بینی شونده است. همچنین، این مدل دارای دو گام پیش‌رو و پس‌رو است. با استفاده از روش پیش‌رو، فضای ورودی‌ها به زیرمجموعه‌های تقسیم می‌شود و برای هر زیرمجموعه یک رابطه رگرسیونی اس پی لاین ایجاد می‌شود (De Andrés et al., 2011). شکل ۳ ساختار روش رگرسیون اس پی لاین خود تطبیق شونده را نشان می‌دهد.

رابطه ۱ یک شبکه عصبی پیش‌رو تک لایه را مدل می‌کند:

$$\sum_{i=1}^N B_i g_i(\alpha_i x_j + \beta_i) = y_j \quad (1)$$

که  $B_i$ ،  $g_i$ ،  $\alpha_i$ ،  $\beta_i$ ،  $x_j$  به ترتیب معرف وزن نهایی لایه خروجی، تابع تحریک، وزن مربوط به نرون لایه پنهان  $i$  ام، بایس مربوط به لایه پنهان  $i$  ام و ورودی  $j$  ام می‌باشند.  $y_j$  نیز بیانگر خروجی  $j$  ام مدل می‌باشد. در پژوهش حاضر مشابه با پژوهش (Yaseen et al., 2016) از تابع تحریک سیگموئید لگاریتمی استفاده شده است.



شکل (۳): ساختار روش رگرسیون اس پی لاین خود تطبیق شونده


داده های آموزش است. از نظر ریاضی، مدل GRNN را می توان به صورت رابطه ۲ ارائه کرد:

$$E[Y|X] = \frac{\int_{-\infty}^{\infty} Yf(Y, X)dX}{\int_{-\infty}^{\infty} f(Y, X)dX} \quad (2)$$

در رابطه ۲  $X = [x_1, x_2, x_3, \dots, x_n]^T$  متغیر غیروابسته است.  $Y = [y_1, y_2, y_3, \dots, y_m]^T$  متغیر وابسته است.  $E[Y|X]$  مقدار مورد انتظار خروجی  $Y$  با توجه به بردار ورودی  $X$  است.  $f(Y, X)$  تابع چگالی احتمال مشترک  $X$  و  $Y$  است. در شکل ۴ مشخصات ساختار شبکه عصبی رگرسیون عمومی را نشان می دهد.

#### شبکه های عصبی رگرسیون عمومی (GRNN)

شبکه عصبی رگرسیون عمومی توسط (Watson, 1964) و (Nadaraya, 1964) به منظور ایجاد یک مدل رگرسیون کلی (خطی یا غیر خطی) معرفی شد. این روش همانند ANN روند آموزش تکرار شونده نیاز ندارد و قادر به محاسبه ی رابطه بین ورودی ها و خروجی ها بر اساس الگوی داده ها هستند. در حقیقت GRNN نوعی شبکه RBF است که دارای یک لایه خطی و یک لایه پایه شعاعی است که از فضای بهینه سازی بهره می برد. از مزیت های این روش به همگرایی سریع آن می توان اشاره کرد، همچنین این الگوریتم پیچیدگی ساختاری ANN را ندارد. هدف مدل GRNN اندازه گیری الگوهای موجود در یک نمونه هدف مشخص از الگوهای موجود در مجموعه



شکل (۴): ساختار شبکه های عصبی رگرسیون عمومی

گردد. انتظار می رود که میزان خطای حاصل از آزمون کاهش یابد که این انحراف معیار به صورت معادله ۳ نوشته می شود.

$$SDR = sd(T) - \sum_i \frac{|T_i|}{|T|} sd(T_i) \quad (3)$$

که  $T$  نشان دهنده یک دسته نمونه ها است که به برگ می رسد،  $T_i$  نشان دهنده زیرمجموعه ای از نمونه ها است که دارای تأمین خروجی از مجموعه بالقوه است و  $sd$  نشان دهنده انحراف معیار است.

$$(S) = \frac{n_i \times (S_i) + K \times M(S)}{n_i + K} \quad (4)$$

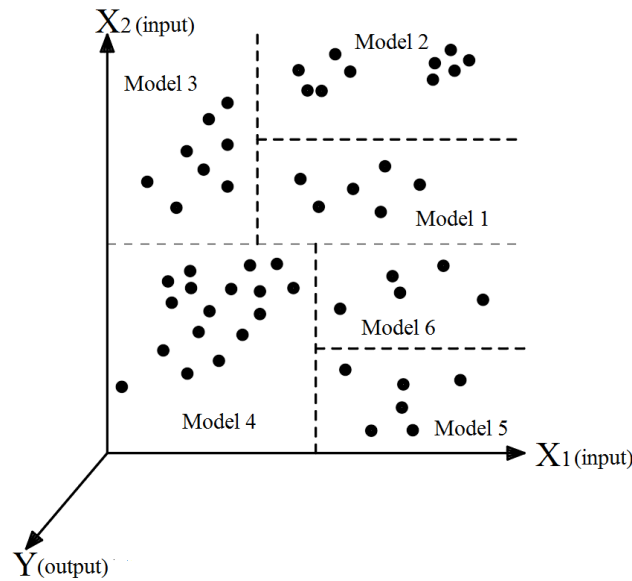

در اینجا  $K$  ثابت هموارسازی است که مقدار آن ۱۵ فرض می شود (Quinlan, 1992).

### مدل تصمیم درخت M5

مدل M5 یکی از زیرشاخه های ماشین های آموزش مرتبط با ساخت یا بازبینی مدل ها در تعداد زیاد نمونه های آزمایشی است که به تخمین مسائل رایج مثل داده های گم شده و نویزها می پردازد (Quinlan, 1992). این مدل اولین بار توسط کواینلا ارائه گردید. در شکل ۵ اجزای تشکیل دهنده مدل درختی M5 ارائه شده است.

مجموعه داده های آموزشی  $T$  دارای همبستگی در یک برگ (زیر مجموعه) هستند یا توسط بعضی از آزمون ها مجموعه  $T$  به یکسری زیرمجموعه متناظر با خروجی های آزمون تقسیم می گردند و همان مرحله بر روی زیر مجموعه ها به صورت بازگشتی اعمال می گردد. اولین قدم در ساخت یک مدل درختی، محاسبه انحراف معیار مقادیر هدف در مجموعه داده های  $T$  است. برآیند آزمون، تقسیم شدن مجموعه  $T$  است. اگر از انحراف معیار داده ها هدف  $sd(T_i)$  در مجموعه  $T_1$  به عنوان شاخص خطا استفاده





شکل (۵): نمونه الگوریتم مدل درختی M5 با شش مدل رگرسیون خطی

$$NSE = 1 - \frac{\sum_{t=1}^T (Q_N^t - Q_E^t)^2}{\sum_{t=1}^T (Q_E^t - \bar{Q}_E)^2} \quad (۸)$$

در رابطه های فوق E و N به ترتیب داده های آزمایشگاهی و داده های عددی هستند. همچنین n تعداد کل داده ها می باشد

### نتایج و بحث

پارامتر Cd از اهمیت بالای در طراحی آبیگرهای کفی برخوردار است. در این پژوهش به منظور بررسی دقیق این پارامتر ۵۴ آزمایش انجام شده است. نتایج طراحی این ضریب با استفاده از الگوریتم های GRNN، ELM، MARS و M5 بر اساس معیارهای ارزیابی در جدول ۲

### معیار ارزیابی و دقت

به منظور ارزیابی نتایج در این پژوهش از چهار معیار (RMSE)، (R2)، (MAE) و (NSE) طبق روابط (۵)، (۶)، (۷) و (۸) استفاده گردیده است.

$$MAE = \frac{1}{n} \sum_{i=1}^n |E - N| \quad (۵)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E - N)^2}{n}} \quad (۶)$$

$$R^2 = 1 - \left[ \frac{\sum_{i=1}^n (E - N)^2}{\sum_{i=1}^n E^2 - \left(\frac{\sum_{i=1}^n N^2}{n}\right)} \right] \quad (۷)$$

نهایی الگوریتم‌ها بر اساس نتایج دوره آزمون تعیین می‌شود. زیرا، در دوره آزمون است که داده‌های جدید به الگوریتم داده می‌شود. بر اساس نتایج دوره آزمون در جدول ۲، الگوریتم ELM با مقادیر ۰/۰۶۰، ۰/۰۸۰ و ۰/۹۶۰ به ترتیب برای MAE، RMSE و NSE دارای بهترین نتایج است. الگوریتم‌های MARS، GRNN و M5 نیز از نظر بیشترین دقت پس از ELM در رتبه‌های بعدی قرار می‌گیرند.


ارائه شده است. مطابق با نتایج این جدول، در دوره آموزش کمترین مقدار معیار MAE با مقدار ۰/۰۴۶ مربوط به الگوریتم M5 می‌شود. اما الگوریتم ELM بر اساس معیارهای RMSE و NSE (۰/۰۵۸ و ۰/۹۷۴ به ترتیب برای RMSE و NSE) دارای بهترین نتایج است. بنابراین الگوریتم ELM در دوره آموزش دارای بهترین نتایج است. همچنین، با توجه به جدول ۲، سه الگوریتم دیگر نیز به خوبی آموزش داده شده‌اند. لازم به ذکر است که عملکرد

جدول (۲): معیارهای ارزیابی برای الگوریتم‌های بررسی شده

آزمون			آموزش			الگوریتم
NSE	RMSE	MAE	NSE	RMSE	MAE	
۰/۹۱۶	۰/۰۸۹	۰/۰۶۹	۰/۹۳۴	۰/۰۹۷	۰/۰۷۵	GRNN
۰/۹۶۰	۰/۰۸۰	۰/۰۶۰	۰/۹۷۴	۰/۰۵۸	۰/۰۵۴	ELM
۰/۹۳۸	۰/۰۸۵	۰/۰۶۸	۰/۹۵۷	۰/۰۷۷	۰/۰۶۳	MARS
۰/۹۳۴	۰/۱۱۸	۰/۰۹۴	۰/۹۶۴	۰/۰۶۴	۰/۰۴۶	M5

ELM نیز الگوریتم MARS بر اساس معیار DDR دارای دقیق‌ترین نتایج است. در حالی که، پراکندگی مقادیر DDR حول عدد یک، بیشتر از سایر الگوریتم‌های بررسی شده است. همچنین، در دوره آزمون پراکندگی DDR برای هر چهار الگوریتم اندکی بیشتر از دوره آموزش است. این موضوع، به این دلیل است الگوریتم‌ها بر اساس داده‌های دوره آموزش ایجاد شده‌اند.

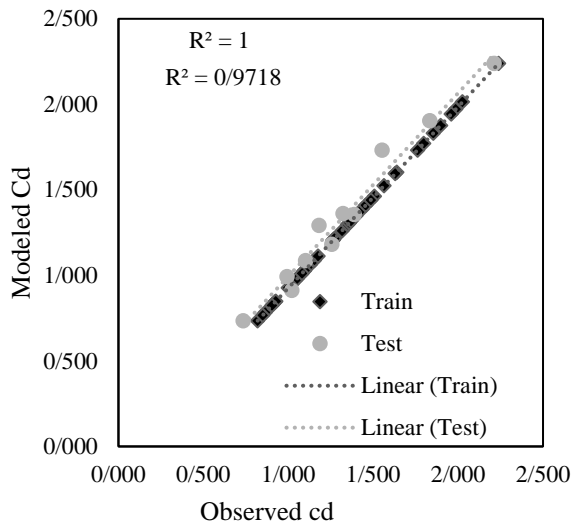
پارامتر DDR نشان دهنده نسبت مقادیر مدل شده و مشاهداتی است که هر چه نزدیک‌تر به یک باشد مطلوب‌تر است. شکل ۶ معیار DDR را برای داده‌های دوره آموزش و آزمون نشان می‌دهد. با توجه به این نمودار، در دوره آموزش، پراکندگی DDR برای الگوریتم ELM حول عدد یک، کمتر از دیگر الگوریتم‌ها است. الگوریتم M5 نیز پس از ELM در رتبه بعدی قرار دارد. در دوره آزمون نیز، مقادیر DDR برای الگوریتم ELM نزدیکتر به یک است. پس از



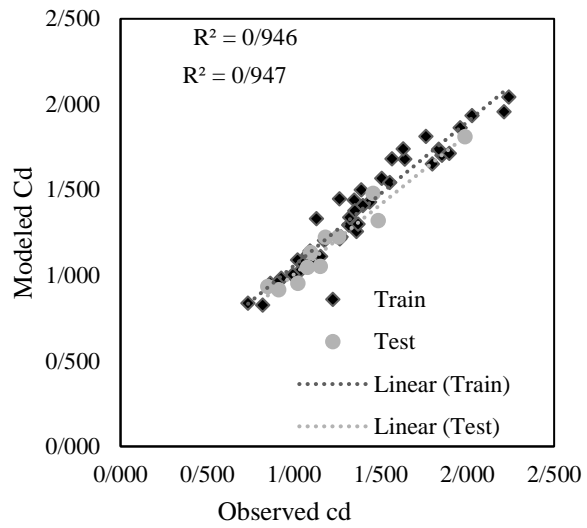
شکل (۶): نمودار معیار DDR برای داده‌های دوره آموزش و آزمون

با ۰/۹۷۲ است. پس از الگوریتم ELM الگوریتم‌های MARS، GRNN و M5 به ترتیب با مقادیر ۰/۹۵۵، ۰/۹۴۷ و ۰/۹۳۷ دارای بیشترین مقادیر ضریب  $R^2$  می‌باشند. بنابراین، استفاده از الگوریتم ELM نسبت به الگوریتم‌های MARS، GRNN و M5، سبب مدل‌سازی ضریب آگذری آگیر کفی به ترتیب با ۱/۷۸، ۲/۶۴ و ۳/۷۴ درصد  $R^2$  بیشتر شده است.

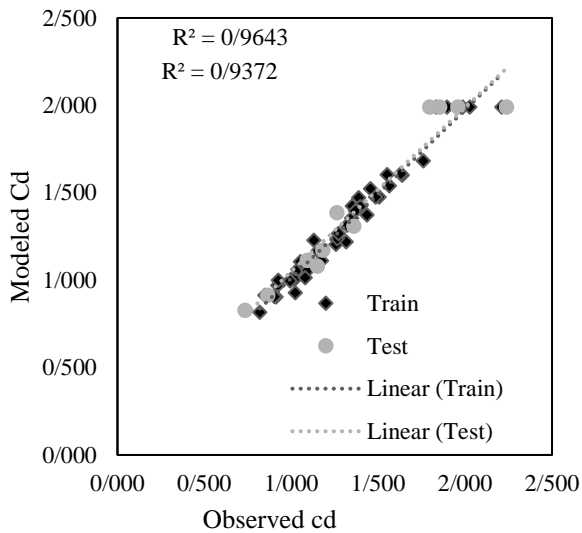
در ادامه، مقدار ضریب تعیین برای الگوریتم‌های بررسی شده در دوره آموزش و آزمون تخمین زده شده است. با توجه به شکل ۷، در دوره آموزش، الگوریتم ELM دارای بالاترین ضریب  $R^2$  برابر با ۱ می‌باشد. الگوریتم‌های M5، MARS و GRNN نیز به ترتیب با مقادیر ۰/۹۶۴، ۰/۹۵۷ و ۰/۹۴۶ پس از ELM دارای بیشترین مقادیر ضریب  $R^2$  می‌باشند. - در دوره آزمون نیز، بیشترین مقدار ضریب  $R^2$  برای ELM می‌باشد. مقدار  $R^2$  برای این الگوریتم برابر




(ب)



(الف)



(د)




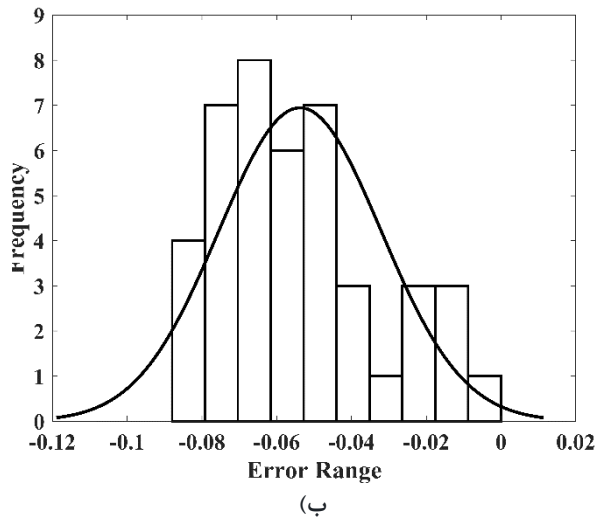


(ج)

شکل (۷): نمودار معیار  $R^2$  برای الگوریتم‌های بررسی شده، الف) GRNN، ب) ELM، ج) MARS، د) M5

می‌باشد. مقدار خطاها برای این الگوریتم بین ۰/۰۸۵- تا صفر تغییر می‌کند. بدترین نتایج نیز در دور آموزش مربوط به الگوریتم GRNN می‌باشد. با این حال، اختلاف نتایج دوره آموزش بسیار ناچیز است و هر چهار الگوریتم به خوبی آموزش دیده‌اند.

اصولاً هیستوگرام خطا برای یک الگوریتم موفق باید در اطراف عدد صفر باشد و از توزیع نرمال پیروی کند (Kocabaş et al., 2008). شکل ۸ هیستوگرام خطا را برای الگوریتم‌های بررسی شده در دوره آموزش نشان می‌دهد. با توجه به این شکل، هیستوگرام خطا برای الگوریتم ELM نسبت به دیگر الگوریتم‌های بررسی شده، نزدیک‌تر به صفر



شکل (۸): هیستوگرام الگوریتم‌های بررسی شده در دوره آموزش (الف) GRNN، (ب) ELM، (ج) MARS، (د) M5



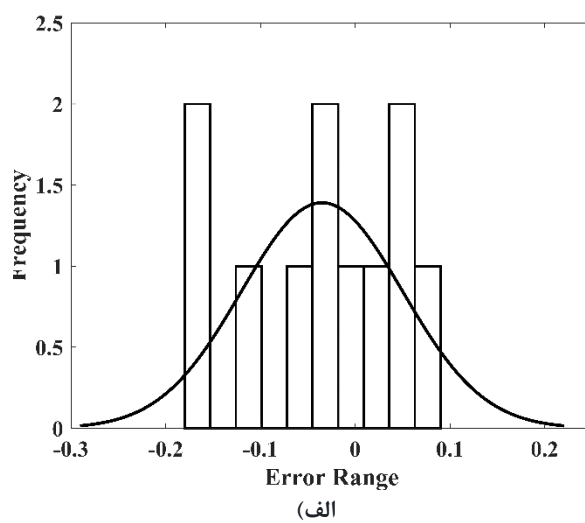

به MARS است. این موضوع به این دلیل است الگوریتم MARS در ساختار خود از روابط غیرخطی استفاده می‌کند که سبب شده است برای داده‌های جدید نسبت به الگوریتم M5 از دقت بیشتری برخوردار باشد. در حالی که الگوریتم M5 در ساختار خود تنها از روابط خطی استفاده می‌کند. در نهایت زمان مدل‌سازی ضریب آنگذری آنگیر کفی توسط الگوریتم‌های مختلف در جدول ۳ مورد بررسی قرار گرفته است. با توجه به این جدول الگوریتم ELM دارای کمترین زمان محاسبه است که نسبت به الگوریتم‌های GRNN، MARS و M5 به ترتیب ۲/۵۵۷، ۱/۵۵۹ و ۱/۸۱۵ بار کمتر است.

هیستوگرام خطا برای دوره آزمون در شکل ۹ نمایش داده شده است. با بررسی این شکل می‌توان دریافت که دقیق‌ترین نتایج مربوط به الگوریتم ELM است. مقدار خطاها برای این الگوریتم در محدوده  $-0.1$  تا  $0.2$  قرار دارد. همچنین، نمودار خطاها برای الگوریتم ELM به توزیع نرمال با میانگین صفر نزدیک‌تر است. پس از الگوریتم ELM نیز به ترتیب الگوریتم‌های MARS، GRNN و M5 قرار دارند.

نتایج جدول ۲ و شکل‌های ۶، ۷، ۸ و ۹ بیانگر دقت بیشتر ELM می‌باشد. همچنین، با وجود اینکه در دوره آموزش دقت الگوریتم M5 بیشتر از MARS و GRNN است، در دوره آزمون بیشترین دقت پس از ELM مربوط

الگوریتم‌های بررسی شده است. برتری MARS نسبت به GRNN نیز به دلیل استفاده از استراتژی تقسیم و حل و تقریب رابطه بین ورودی‌ها و خروجی‌ها با استفاده از چندین رگرسیون غیرخطی توسط الگوریتم MARS است. همچنین، مطابق با نتایج مدل‌سازی ضریب آنگذری، الگوریتم GRNN با استفاده از روابط غیرخطی موجب بهبود نتایج نسبت به M5 شده است.

برتری ELM نسبت به الگوریتم‌های MARS، GRNN و M5 به این دلیل است که الگوریتم ELM تنها از یک لایه تشکیل شده است. همچنین، این الگوریتم نیازی به محاسبات تکراری ندارد و تنها با یک بار تکرار مقدار وزن‌ها و خروجی‌ها را تعیین می‌کند. بنابراین، ELM از پیچیدگی محاسباتی کمتری نسبت به سایر الگوریتم‌های به‌کار برده شده برخوردار است که سبب هزینه محاسباتی کمتر و دقت بیشتر این الگوریتم نسبت به سایر



شکل (۹): هیستوگرام الگوریتم‌های بررسی شده در دوره آزمون الف) GRNN، ب) ELM، ج) MARS، د) M5

(2019)، برتری ELM نسبت به M5 نتایج پژوهش (Feng et al., 2018) را تأیید می‌کند.

در پژوهش حاضر، برتری ELM نسبت به GRNN نتایج پژوهش (Yaseen et al., 2016)، برتری ELM نسبت به MARS نتایج پژوهش (Kumar & Samui, )

جدول (۳): زمان مدل سازی برای الگوریتم های مختلف

M5	MARS	ELM	GRNN	الگوریتم زمان (ثانیه)
۱/۱۸۵	۱/۲۷۹	۰/۶۵۳	۱/۶۷۰	نسبت زمان مدل سازی به زمان مدل سازی توسط سریع ترین الگوریتم
۱/۸۱۵	۱/۵۵۹	۱	۲/۵۵۷	

## نتیجه گیری

که الگوریتم ELM دارای بیشترین سرعت در مدل سازی ضریب آبگذری آنگیر کفی بود. با توجه به سرعت و دقت بالای الگوریتم ELM در مدل سازی ضریب آبگذری کفی می توان این الگوریتم را علاوه بر مدل سازی پارامتر مذکور، در موارد دیگری همچون، پیش بینی سیلاب، پیش بینی جریان ورودی به مخازن، طراحی سیستم های منابع آب استفاده کرد. همچنین الگوریتم ELM با استفاده از روش آموزش منحصر به فرد خود که تنها در یک تکرار، مقدار رابطه غیرخطی بین داده های ورودی و خروجی را با دقت بالا بدست می آورد، با سرعت بیشتری نسبت به الگوریتم های دیگر قادر به انجام مدل سازی است.

در پژوهش حاضر، ضریب آبگذری آنگیر کفی با استفاده از چهار پارامتر شیب طولی کف مشبک، نسبت مساحت بازشدگی، تعداد روزنه ها و عدد فرود و با استفاده از چهار الگوریتم جدید ELM، GRNN، MARS و M5 مدل شد. نتایج مدل سازی بر اساس معیارهای MAE، RMSE، NSE و R2 حاکی از برتری ELM در هر دو دوره آموزش و آزمون بود. به طوری که در دوره آزمون، مقدار ضریب R2 برای این الگوریتم تا ۳/۷۴ درصد بیشتر از سایر الگوریتم های بررسی شده بود. همچنین، معیار DDR و نمودار هیستوگرام خطا حاکی از برتری الگوریتم ELM بود. در نهایت سرعت الگوریتم ها به کار برده شده ارزیابی شدند

## منابع

ظهیری، ع. ۱۳۹۴. استخراج رابطه ضریب دبی در سرریزهای قوسی به کمک روش برنامه ریزی ژنتیک. نشریه آبیاری و زهکشی ایران، شماره ۲، جلد ۹، ص ۳۲۳-۳۳۴.  
فرودی خور، ع.، م. صانعی، و م. اژدری مقدم. ۱۳۹۶. مقایسه سامانه استنتاج فازی-عصبی تطبیقی (ANFIS) و سامانه ماشین بردار پشتیبان (SVM) در تخمین میزان ضریب دبی سرریزهای لبه تیز. نشریه آبیاری و زهکشی ایران، شماره ۵، جلد ۱۱، ص ۷۷۲-۷۸۴.

Abdullah, S.S., Malek, M.A., Abdullah, N.S., Kisi, O. and Yap, K.S. 2015. Extreme learning machines: a new approach for prediction of reference evapotranspiration. *Journal of Hydrology*, 527: 184-195.

Aghamajidi, R. and Heydari, M.M. 2014. Simulation of Flow on Bottom Turn out Structures with Flow 3D. *Bull. Env. Pharmacol. Life Sci*, 3(3): 173-181.

Azamathulla, H.M., Haghiabi, A.H. and Parsaie, A. 2016. Prediction of side weir discharge coefficient by support vector machine technique. *Water Science and Technology: Water Supply*, 16(4):1002-1016.

Bina, K. 2018. Using dividing discharge streamline concept for estimating diverted discharge in mesh-panel bottom racks. *Flow Measurement and Instrumentation*, 61 38-48.



- Bina, K. and Saghi, H. 2017. Experimental study of discharge coefficient and trapping ratio in mesh-panel bottom rack for sediment and non-sediment flow and supercritical approaching conditions. *Experimental Thermal and Fluid Science*, 88: 171-186.
- Bouvard. M. 1992. *Mobile barrages and intakes on sediment transporting rivers*, IAHR Monograph, Balkema, Rotterdam, The Netherlands.
- Brunella, M. 2003. Subharmonic variation of the leafwise Poincaré metric. *Inventiones mathematicae*, 152(1): 119-148.
- Castillo, L., García, J. and Carrillo, J. 2017. Influence of rack slope and approaching conditions in bottom intake systems. *Water*, 9(1): 65.
- Castillo, L.G., Carrillo, J.M. and García, J.T. 2013, September. Flow and sediment transport through bottom racks. CFD application and verification with experimental measurements. In *Proceedings of the 35th IAHR Congress, Chengdu, China*: 8-13.
- Chang, L., Chan, S.N. and Lee, J.H. 2018. 3D Numerical Modeling of a Supercritical Intake with a Flow Diversion Barrier.
- De Andrés, J., Lorca, P., de Cos Juez, F.J. and Sánchez-Lasheras, F. 2011. Bankruptcy forecasting: A hybrid approach using Fuzzy c-means clustering and Multivariate Adaptive Regression Splines (MARS). *Expert Systems with Applications*, 38(3): 1866-1875.
- Emiroglu, M.E., Bilhan, O. and Kisi, O. 2011. Neural networks for estimation of discharge capacity of triangular labyrinth side-weir located on a straight channel. *Expert Systems with Applications*, 38(1): 867-874.
- Feng, Y., Cui, N., Zhao, L., Hu, X. and Gong, D. 2016. Comparison of ELM, GANN, WNN and empirical models for estimating reference evapotranspiration in humid region of Southwest China. *Journal of Hydrology*, 536: 376-383.
- Feng, Y., Jia, Y., Zhang, Q., Gong, D. and Cui, N., 2018. National-scale assessment of pan evaporation models across different climatic zones of China. *Journal of hydrology*, 564: 314-328.
- Hosseini, K., Rikhtegar, S., Karami, H. and Bina, K. 2015. Application of Numerical Modeling to Assess Geometry Effect of Racks on Performance of Bottom Intakes. *Arabian Journal for Science and Engineering*, 40(3): 677-684.
- Huang, G.B., Zhu, Q.Y. and Siew, C.K. 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70(1-3): 489-501.
- Kamanbedast, A.A and Bejestan, M.S. 2008. Effects of slope and area opening on the discharge ratio in bottom intake structures. *J. of Applied Sciences*, 8(14):2631-2635.
- Kisi, O., Emiroglu, M.E., Bilhan, O. and Guven, A. 2012. Prediction of lateral outflow over triangular labyrinth side weirs under subcritical conditions using soft computing approaches. *Expert systems with Applications*, 39(3): 3454-3460.
- Kocabaş, F., Kişi, Ö. and Ardiçlioğlu, M. 2009. An artificial neural network model for the prediction of critical submergence for intake in a stratified fluid medium. *Civil Engineering and Environmental Systems*, 26(4): 367-375.





- Kocabaş, F., Ünal, S. and Ünal, B. 2008. A neural network approach for prediction of critical submergence of an intake in still water and open channel flow for permeable and impermeable bottom. *Computers & Fluids*, 37(8):1040-1046.
- Kumar, M. and Samui, P., 2019. Reliability Analysis of Pile Foundation Using ELM and MARS. *Geotechnical and Geological Engineering*, 37(4): 3447-3457.
- Lund, S. 2005. in Department of Hydraulic and Environmental Engineering. Norwegian University of Science and Technology (N.T.N.U), Trondheim, Norway.
- Mehri, Y., Soltani, J. and Khashehchi, M. 2019. Predicting the coefficient of discharge for piano key side weirs using GMDH and DGMDH techniques. *Flow Measurement and Instrumentation*, 65: 1-6.
- Mizuyama, T and Mizuno, H. 1994. Behavior of debris flow at control structures. In Proc., IAHR Int. Workshop on Floods and Inundations Related to Large Earth Movement.
- Nadaraya, E.A., 1964. On estimating regression. *Theory of Probability & Its Applications*, 9(1): 141-142.
- Orth, J, Chardonnet, G and Meynardi, M. 1954, Etude de Grilles pour Prises d'eau du Type. en-dessous, *La Houille Blanche*, 9(6): 343–351 (in French).
- Quinlan, J.R., 1992, November. Learning with continuous classes. In 5th Australian joint conference on artificial intelligence, 92: 343-348.
- Righetti, M. and Lanzoni, S. 2008. Experimental study of the flow field over bottom intake racks. *Journal of Hydraulic Engineering*, 134(1):15-22.
- Salmasi, F., Yıldırım, G., Masoodi, A. and Parsamehr, P. 2013. Predicting discharge coefficient of compound broad-crested weir by using genetic programming (GP) and artificial neural network (ANN) techniques. *Arabian Journal of Geosciences*, 6(7): 2709-2717.
- Shafai Bejestan, M and A, Kammanbedast. 2008. Experimental investigation of the effects of sediment on discharge coefficient at bottom intake, 2nd Int. Junior Research on Hydraulic structures, university of Pisa, Pisa, Italy.
- Viparelli, C. 1963. Dissipatori a griglia di fondo. *Energ. Elettr*, 7: 509–519 (in Italian).
- Watson, G.S., 1964. Smooth regression analysis. *Sankhyā: The Indian Journal of Statistics, Series A*.359-372.
- Yaseen, Z.M., Jaafar, O., Deo, R.C., Kisi, O., Adamowski, J., Quilty, J. and El-Shafie, A., 2016. Stream-flow forecasting using extreme learning machines: A case study in a semi-arid region in Iraq. *Journal of Hydrology*, 542: 603-614.
- Zaji, A.H., Bonakdari, H. and Shamshirband, S. 2016. Support vector regression for modified oblique side weirs discharge coefficient prediction. *Flow Measurement and Instrumentation*, 51:1-7.



## Investigate of Learning Machines Performance in Estimation of Circular Bottom Intake Discharge Coefficient

Ali Miroorollahi<sup>1</sup>, \*Hojat Karami<sup>2</sup>, Saeed Farzin<sup>3</sup>, Mojtaba Ameri<sup>4</sup>

### ABSTRACT

By the development of technology and the advancement of technology, many intelligent methods have emerged for estimating the discharge coefficient of different hydraulic structures. One of the structures used in power plants is bottom intake structure. The task of this structure is to transfer the flow to the collecting channel. The advantages of these structures are their stability against dynamic and static loads due to their low level alignment. In the present study, four intelligent algorithms capable of extreme learning machine (ELM), general regression neural networks (GRNN), multivariate adaptive regression spline (MARS) and M5 tree model have been evaluated in modeling of discharge coefficient of bottom intake. The modeling results showed that the ELM algorithm is more accurate than the other algorithms in both training (70% of data) and test (30% of data) periods. In addition,  $R^2$  coefficient for the mentioned algorithm was up to 3.74% higher than the other algorithms used. Also the DDR criterion and modeling error histogram showed the superiority of the ELM algorithm. Finally, the computational speed of the algorithms used was compared, which ELM algorithm was 2.557 times faster than the other algorithms. Therefore, the ELM algorithm has high potential for modeling the discharge coefficient in overflows due to its good accuracy and high speed.

**KEY WORDS: Intelligent Algorithms, Extreme Learning Machine, Circular Bottom Intake, Discharge Coefficient, Circular Orifice**

---

<sup>1</sup> - M.Sc Student of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan, University, Semnan, Iran. [alimirnurollahi@semnan.ac.ir](mailto:alimirnurollahi@semnan.ac.ir)

<sup>2\*</sup> - Associate Professor, Department of Water engineering and Hydraulic Structure, Faculty of Civil Engineering, Semnan University, Semnan, Iran. Corresponding Author: Email: [hkarami@semnan.ac.ir](mailto:hkarami@semnan.ac.ir)

<sup>3</sup> - Associate Professor, Department of Water engineering and Hydraulic Structure, Faculty of Civil Engineering, Semnan University, Semnan, Iran, [saeed.farzin@semnan.ac.ir](mailto:saeed.farzin@semnan.ac.ir)

<sup>4</sup> - Assistant Professor, Department of Civil engineering, Shahrood Branch, Islamic Azad University, Shahrood, Iran, [m\\_ameri@iau-shahrood.ac.ir](mailto:m_ameri@iau-shahrood.ac.ir)

## Research Paper

**Investigate of Learning Machines Performance in Estimation of Circular Bottom Intake Discharge Coefficient**Ali Miroorollahi<sup>1</sup>, \*Hojat Karami<sup>2</sup>, Saeed Farzin<sup>3</sup>, Mojtaba Ameri<sup>4</sup>

<sup>1</sup> - M.Sc Student of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan, University, Semnan, Iran. [alimirnurollahi@semnan.ac.ir](mailto:alimirnurollahi@semnan.ac.ir)

<sup>2</sup> \* - Associate Professor, Department of Water engineering and Hydraulic Structure, Faculty of Civil Engineering, Semnan University, Semnan, Iran. Corresponding Author: Email: [hkarami@semnan.ac.ir](mailto:hkarami@semnan.ac.ir)

<sup>3</sup> - Associate Professor, Department of Water engineering and Hydraulic Structure, Faculty of Civil Engineering, Semnan University, Semnan, Iran, [saeed.farzin@semnan.ac.ir](mailto:saeed.farzin@semnan.ac.ir)

<sup>4</sup> - Assistant Professor, Department of Civil engineering, Shahrood Branch, Islamic Azad University, Shahrood, Iran, [m\\_ameri@iau-shahrood.ac.ir](mailto:m_ameri@iau-shahrood.ac.ir)

**Corresponding Author:** hojat karami

**Address:** Department of Water engineering and Hydraulic Structure, Faculty of Civil Engineering, Semnan University, Semnan, Iran

**Email:** [hkarami@semnan.ac.ir](mailto:hkarami@semnan.ac.ir)  
**Tel:** 09124803350



10.22125/IWE.2020.217438.1294

Received:  
**December 18, 2020**  
Accepted:  
**April 13, 2020**  
Available online:  
**June.01.2022**

**Keywords:**  
**Intelligent Algorithms, Extreme Learning Machine, Circular Bottom Intake, Discharge Coefficient, Circular Orifice**

**Abstract**

By the development of technology and advancement of technology, many intelligent methods for estimating the discharge coefficient of various hydraulic structures have emerged. One of the structures used in hydropower plants is the bottom intakes structure. The task of this structure is to transfer flow to the collection channel. In the present study, four powerful intelligent extreme learning machine (ELM) algorithms, general regression neural networks (GRNN), multivariate adaptive regression spline model (MARS) and M5 tree model have been evaluated in modeling the bottom intake discharge coefficient. The modeling results showed that the ELM algorithm in both training (70% of data) and test (30% of data) is more accurate than the other algorithms studied. So that the coefficient  $R^2$  for the mentioned algorithm was up to 3.74% higher than the other algorithms used. DDR and histogram of modeling error also showed the superiority of ELM algorithm.

## 1. Introduction

Due to the shallow flow and limited conditions for the construction of lateral intake, in Mountain Rivers with steep slopes and coarse-grained sediments, the most suitable intake is the bottom intake (Bouvard, 1992). In some cases where the water level downstream of the prismatic canals has increased, the bottom intake can be used as an energy dissipator. Another advantage of this type of intake compared to other intakes is resistance to static and dynamic loads due to its location at the bottom of the canal (Viparelli, 1963) and (Orth et al., 1954). Using genetic programming method, Zahiri obtained relation for arc overflow coefficient (Zahiri, 2014).

## 2. Materials and Methods

In the experiments performed to obtain the discharge coefficient, 54 experiments were performed. In order to investigate the factors affecting this parameter, the longitudinal slope of the perforated plate ( $S$ ), the ratio of the perforated plate opening area ( $A$ ), the number of orifice ( $N$ ) and the Froude number of perforated plate ( $Fr1$ ) were investigated. Parameters  $A$ ,  $S$ ,  $N$  and  $Fr1$  are considered as input, and  $Cd$  as output. Also in the present study, 70% of the data were selected for training and 30% of the data were selected for testing. Also, the data selection was random. For more detailed study, ELM, MARS, GRNN algorithms and M5 tree decision model have been used.

The extreme learning machine method was first introduced by (Huang et al., 2006), which as a powerful and simple learning algorithm consists of only one hidden layer (Feng et al., 2016). Multivariate adaptive regression splines is a nonlinear model used to predict numerical results. One of the advantages of this method is the non-linear relation between predictor and predictor variables. The general regression neural network was introduced by (Watson, 1964) and (Nadaraya, 1964) in order to create a general regression model (linear or nonlinear). This method, like ANN, does not require a repetitive training process. The M5 is a subset of training machines related to model construction or revision in a large number of test specimens that estimate common problems such as missing data and noise (Quinlan, 1992). This model was first introduced by Quinella.

## 3. Results

In the training period, the minimum value of MAE criterion with the value of 0.046 is related to M5 algorithm. But the ELM algorithm based on RMSE and NSE criteria (0.058 and 0.974 for RMSE and NSE, respectively) has the best results. Therefore, the ELM algorithm has the best results in the training period. Based on the results of the test period in the ELM algorithm with values of 0.060, 0.080 and 0.960, respectively, for MAE, RMSE and NSE have the best results. MARS, GRNN and M5 algorithms are also in the next ranks after ELM in terms of accuracy. In the training period, the DDR scatter for the ELM algorithm around number one is less than other algorithms. Also, the DDR scatter period test for all four algorithms is slightly higher than the training period. The training period error histogram for the ELM algorithm is closer to zero than the other algorithms examined. However, the difference in training results is negligible and all four algorithms are well trained. By examining the error histogram in the test period, it can be seen that the most accurate results are related to the ELM algorithm.

## 4. Discussion and Conclusion

In the present study, the bottom intake discharge coefficient was modeled using four parameters of perforated plate longitude slope, opening area ratio, number of orifice and Froude number and using four new algorithms ELM, GRNN, MARS and M5. The modeling results based on MAE, RMSE, NSE and  $R^2$  criteria showed the superiority of ELM in both training and testing period. Also, the DDR criterion and the error histogram showed the superiority of the ELM algorithm.

## 5. Six important references

1. Bouvard. M. 1992. Mobile barrages and intakes on sediment transporting rivers, IAHR Monograph, Balkema, Rotterdam, The Netherlands.
2. Hosseini, K., Rikhtegar, S., Karami, H. and Bina, K. 2015. Application of Numerical Modeling to Assess Geometry Effect of Racks on Performance of Bottom Intakes. Arabian Journal for Science and Engineering, 40(3): 677-684.

3. Kisi, O., Emiroglu, M.E., Bilhan, O. and Guven, A. 2012. Prediction of lateral outflow over triangular labyrinth side weirs under subcritical conditions using soft computing approaches. *Expert systems with Applications*, 39(3): 3454-3460.
4. Kumar, M. and Samui, P., 2019. Reliability Analysis of Pile Foundation Using ELM and MARS. *Geotechnical and Geological Engineering*, 37(4): 3447-3457.
5. Orth, J, Chardonnet, G and Meynardi, M. 1954, Etude de Grilles pour Prises d'eau du Type. en-dessous, *La Houille Blanche*, 9(6): 343–351 (in French).
6. Righetti, M. and Lanzoni, S. 2008. Experimental study of the flow field over bottom intake racks. *Journal of Hydraulic Engineering*, 134(1):15-22.

### **Conflict of Interest**

Authors declared no conflict of interest.

\*