



تعیین قابلیت تکنیک‌های هوش مصنوعی در تخمین استهلاک انرژی سرریزهای پلکانی با رژیم جریان رویه‌ای

آرش جاعل^{۱*}، محمد راشکی قلعه‌نو^۲، مسیح ذوالقدر^۳

۱- گروه کشاورزی، دانشگاه پیام نور، تهران، ایران

۲- گروه مهندسی عمران، دانشگاه سیستان و بلوچستان، سیستان و بلوچستان، ایران

۳- گروه علوم و مهندسی آب، دانشگاه چهرم، فارس، ایران.

تاریخچه داوری:

دریافت: ۱۳۹۹/۰۱/۰۴

بازنگری: ۱۳۹۹/۰۵/۳۲

پذیرش: ۱۳۹۹/۰۶/۰۲

ارائه آنلاین: ۱۳۹۹/۰۶/۲۰

کلمات کلیدی:

استهلاک انرژی

برنامه‌نویسی بیان ژن

سرریز پلکانی

شبکه عصبی - فازی تطبیقی

الگوریتم کرم شب‌تاب

خلاصه: استهلاک انرژی در سرریزهای پلکانی از اهداف اولیه این گونه سازه‌ها محسوب می‌شود. در این پژوهش دقت روش شبکه عصبی مصنوعی (ANN)، روش مدل استنتاج عصبی فازی تطبیقی که بر اساس الگوریتم بهینه‌سازی کرم شب‌تاب آموزش دیده است (ANFIS-FA) و روش برنامه‌نویسی بیان ژن (GEP) در تخمین افت انرژی سرریزهای پلکانی با رژیم جریان رویه‌ای مورد بررسی قرار گرفته است. همچنین با انجام آنالیز حساسیت به بررسی اهمیت پارامترهای ورودی در پیش‌بینی افت انرژی برای هر یک از سه روش ذکر شده پرداخته شده است. بدین منظور از تعداد ۱۵۴ سری داده آزمایشگاهی استفاده شده است. پارامترهای ورودی برای هر روش شامل عدد فرود اولیه پرش، عدد آبشار، تعداد پلکان، شیب سرریز پلکانی و نسبت عمق بحرانی به ارتفاع پله هست. نتایج نشان می‌دهد که هر سه روش توانایی بالاتری در پیش‌بینی افت انرژی نسبت به روش‌های کلاسیک برای تخمین افت انرژی که بر پایه روش‌های متداول رگرسیون گیری بنا شده است داشته‌اند. نتایج روش ANFIS-FA (با $MAE = 2/385$ و $R = 0.2/979$) تا حدودی بیشتر از روش GEP (با $MAE = 2/672$ و $R = 0.2/978$) است. دقت بیشتر ساختارهای شبکه عصبی مورد استفاده در این تحقیق پایین‌تر از دو روش فوق است. با این وجود بیشترین دقت به دست آمده مربوط به شبکه عصبی پرسپترون چند لایه با ۳ لایه مخفی با تعداد به ترتیب ۱۲ و ۸ و ۷ نرون در هر لایه (با $MAE = 0/848$ و $R = 0.2/994$) است. در هر سه روش مؤثرترین پارامتر، عدد آبشار و کم اثرگذارترین پارامتر، شیب سرریز پلکانی است.

۱- مقدمه

را دارند که در اینجا توضیحاتی مختصر در مورد رژیم جریان رویه‌ای که تحقیق حاضر بر افت انرژی آن تمرکز دارد ارائه می‌شود. علاقه‌مندان برای توضیحات بیشتر می‌توانند به منبع [۳] مراجعه نمایند. در رژیم رویه‌ای، حرکت آب بر روی سازه، یک جریان پیوسته و منسجم است که در آن جریان فقط با لبه پله‌ها در تماس بوده و با سطح قائم و افقی پله در تماس نیست. افت اصطکاک توسط برخورد جریان با لبه پله‌ها و وجود جریان چرخشی در مثلث کنج دیواره و همچنین تبدلات مومنتم بین این ناحیه و جریان وجود خواهد داشت. در حقیقت در رژیم جریان رویه‌ای، پله‌ها نوعی کف کاذب^۴ به وجود می‌آورند که آب از روی آن عبور مینماید. پله‌ها به عنوان المانهای زبر، امکان افزایش تلفات انرژی جریان عبوری از روی آن را ایجاد میکند، به طوری که ضریب زبری دارسی ویسباخ در این نوع سرریزها حدود ۵ برابر بیشتر از سرریزهای با سطح هموار، تخمین زده شده است [۴]. در نتیجه انرژی جریان در پایین‌دست دچار افت شدیدی شده و سازه انرژی‌گیر متمرکز پایین‌دست، در ابعاد کوچک‌تر و با هزینه کمتر ساخته میشود. مطالعه هیدرولیک رژیم

سرریزهای پلکانی به دلیل سادگی در طراحی و ساخت آن‌ها، دارای قدمتی بیش از ۳۵۰۰ سال هستند [۱]. در جریان عبوری از سرریز پلکانی سه نوع جریان تیغه‌ای^۱، انتقالی^۲ و رویه‌ای^۳ مشاهده می‌شود. هر چند که روابط تجربی مختلفی برای تخمین خصوصیات جریان در سرریزهای پلکانی ارائه شده است؛ به دلیل ورود هوا و تشکیل گردابه‌های جریان، تخمین افت انرژی در جریان بر روی سرریز پلکانی پیچیده است [۲]. با توجه به قابلیت هوش مصنوعی، می‌توان از آن در تخمین افت انرژی استفاده نمود. در این تحقیق سعی شده است سه روش مختلف هوش مصنوعی برای تخمین افت انرژی جریان رویه‌ای در سرریز پلکانی مورد بررسی قرار گیرد.

هر یک از سه رژیم تیغه‌ای، انتقالی و رویه‌ای هیدرولیک خاص خود

- 1 Nappe Flow Regime
- 2 Transition Flow Regime
- 3 Skimming Flow Regime



معرفی شده‌اند. بوئس و هگر [۷]، آزمایش‌هایی را در یک کانال مستطیلی با عرض ۰/۵ متر و طول ۵/۷ متر با شیب ۳۰ و ۴۰ و ۵۰ درجه نسبت به افق با ارتفاع پله‌های مختلف انجام دادند. آن‌ها از دو حسگر نوری برای اندازه‌گیری سرعت جریان و غلظت هوا استفاده و رابطه‌های (۳) و (۴) را برای تخمین انرژی باقی‌مانده در انتهای سرریز پلکانی ارائه نمودند.

$$\text{چنانچه } \frac{H_{dam}}{y_c} < 15 - 20 \text{ داریم:}$$

$$\frac{H_{res}}{H_0} = \exp\left[\left(0.045\left(\frac{K}{D_{h,w}}\right)^{0.1}(\sin\phi)^{-0.8}\right)\frac{H_{dam}}{y_c}\right] \quad (3)$$

که $D_{h,w}$ قطر هیدرولیکی، k ارتفاع زبری و H_{res} انرژی باقی‌مانده در انتهای سرریز پلکانی است و در هنگامی که $\frac{H_{dam}}{y_c} \geq 15 - 20$ داریم:

$$\frac{H_{res}}{H_0} = \frac{\left(\frac{f_b}{8\sin\phi}\right)^{1/3} \cos\phi + \frac{\alpha}{2} \left(\frac{f_b}{8\sin\phi}\right)^{-2/3}}{\frac{H_{dam}}{y_c} + \left(\frac{f_b}{8\sin\phi}\right)^{1/3} \cos\phi + \frac{\alpha}{2} \left(\frac{f_b}{8\sin\phi}\right)^{-2/3}} \quad (4)$$

که \hat{a} ضریب تصحیح انرژی و f_b فاکتور اصطکاک زبری کف است. یاسودا [۸]، بر اساس آزمایش‌های خود در مدل فیزیکی رابطه (۵) را ارائه داد:

$$\frac{\Delta H}{H_0} = 1 - \frac{\left(\frac{y_w}{y_c}\right)^{-2} + 2\left(\frac{y_w}{y_c}\right) \cos\phi}{3 + 2\frac{H_{dam}}{y_c}} \quad (5)$$

که y_w عمق آب شفاف است. در آزمایش‌های ایشان چنانچه شیب کانال بیش از ۱۹ درجه بود یک تاج صاف^۲ با پروفیل نوع WES برای جلوگیری از پاشش آب در هنگام عبور از اولین پله نصب می‌شد. ایشان برای اندازه‌گیری میزان غلظت هوای آب از حسگر تخلخل سنج نوری^۳ با قطر ۰/۱ میلی‌متر استفاده کرد. پرش هیدرولیکی در مدل ایشان بلافاصله پس از پایان پله‌ها تشکیل می‌شد.

چنانسون بر روی سرریزهای پلکانی مطالعات زیادی نموده است و کاربرد رابطه (۲) را برای سرریزهای پلکانی بدون دریچه در بالادست، توصیه

رویه‌های و اندازه‌گیری خصوصیات جریان در این رژیم تا حدی پیچیده است. در این رژیم در ابتدای سرریز پلکانی، سطح جریان عبوری از پله‌ها، صاف و هموار است. اما با رشد لایه مرزی متلاطم از کف در طول سرریز و رسیدن آن به سطح آب، هوا وارد آب شده و جریان به صورت کف‌آلود و سفید رنگ تبدیل شده و ضخامت آن دائماً و به تدریج افزایش می‌یابد، تا در نهایت به یک محیط دو فاز متعادل آب و هوا تبدیل گردد. از این رو اندازه‌گیری خصوصیات جریان در این سرریزها مشکل است. مطالعات گسترده‌ای بر روی پلکانهای با کف پله‌ای صاف طی سال‌های ۱۹۸۵ تاکنون انجام گرفته است و محققین تلاش کرده‌اند خصوصیات جریان در سرریزهای پلکانی را توسط روشهای آزمایشگاهی، استفاده از مدل‌های هیدرولیک محاسباتی و یا استفاده از روش‌های هوش مصنوعی مورد مطالعه قرار دهند. روابطی نیز برای تخمین افت انرژی توسعه‌یافته که در ادامه به طور مختصر به مروری بر تحقیقات انجام شده پرداخته می‌شود.

کریستودولو [۵]، از ۱۵ پله قائم بر روی سرریزی به شکل سرریز استاندارد WES^۱ با شیب ۵۵ درجه نسبت به افق به منظور تعیین افت انرژی سرریز پلکانی استفاده کرد. دبی جریان بین ۱۰ تا ۴۵ لیتر در ثانیه و فلوام مورد استفاده دارای طول ۱۰ متر و عرض ۰/۵ متر بود. در تمام آزمایش‌ها جریان خروجی به صورت فوق بحرانی بوده و پرش هیدرولیکی رخ نداد. ایشان رابطه (۱) را برای تخمین افت انرژی ارائه داد:

$$\frac{\Delta H}{H_0} = \exp\left[-30\left(\frac{y_c}{N.h}\right)^2\right] \quad (1)$$

که در رابطه بالا، ΔH افت انرژی، H_0 انرژی جریان قبل از شروع سرریز پلکانی، y_c عمق بحرانی، N تعداد پله و h ارتفاع هر پله است. چانسون [۶]، بر اساس داده‌های محققان مختلف در هنگامی که در ابتدای سرریز پلکانی دریچه‌ای جهت کنترل آب نصب نشده باشد رابطه (۲) را ارائه داد.

$$\frac{\Delta H}{H_0} = 1 - \frac{\left(\frac{f_b'}{8\sin\phi}\right)^{1/3} \cos\phi + 0.5\left(\frac{f_b'}{8\sin\phi}\right)^{-2/3}}{1.5 + \frac{H_{dam}}{y_c}} \quad (2)$$

که در رابطه بالا H_{dam} ارتفاع سد، f_b' ضریب اصطکاک در جریان آب و هوا و θ زاویه شیب سرریز پلکانی با افق است. سایر پارامترها نیز قبلاً

2 Smooth Crest
3 Optical Void Probe

1 Waterways Experiment Station (WES)

سرریزهای پلکانی با استفاده از ماشین بردار پشتیبان^۱ (SVM) پرداختند. آن‌ها به منظور تعیین پارامترهای همبستگی بردار پشتیبان از الگوریتم ژنتیک (GA) استفاده کردند. نتایج حاصل از روش ترکیبی فوق با یک شبکه عصبی مصنوعی پس انتشار^۲ (BP) نیز مورد مقایسه قرار گرفت. نتایج مقایسه نشان دهنده عملکرد بهتر روش ترکیبی پیشنهادی بوده و در نهایت این الگوریتم ترکیبی به عنوان یک روش مناسب برای پیش‌بینی تلفات انرژی در سرریزهای پلکانی معرفی گردید. پارسایی و حقی آبی [۱۵]، به بررسی ویژگی‌های هیدرولیکی سرریزهای پلکانی با تاج دایره‌ای شکل پرداختند. آن‌ها نتیجه گرفتند که مهم‌ترین عامل مؤثر در تعیین ضریب تخلیه این نوع سرریزها، هد جریان نسبی (نسبت انرژی کل در بالادست سرریز به شعاع دایره تاج) است. همچنین افزایش ابعاد پلکان‌ها به عنوان عامل مهمی در افزایش استهلاک انرژی معرفی گردید.

مروری بر تحقیقات گذشته نشان می‌دهد که برای تخمین میزان استهلاک انرژی جریان عبوری از روی سرریزهای پلکانی تاکنون از مدل‌های رگرسیون گیری کلاسیک و یا انواع مختلفی از مدل‌های محاسبات نرم مانند شبکه‌های عصبی چند لایه، ماشین بردار پشتیبان و شبکه عصبی فازی تطبیقی استفاده شده است. مزیت روش‌های محاسبات نرم قابلیت بهتر انجام شبیه‌سازی در شرایط پیچیده و با وجود پراکندگی داده در متغیرهای اندازه گیری شده می‌باشد. هر یک از مدل‌های محاسبات نرم گفته شده ویژگی‌های مخصوص به خود را دارد. به عنوان مثال مدل‌های مبتنی بر الگوریتم درختی فضاهای متغیرهای ورودی را به چندین زیر فضا تقسیم کرده و به هر زیر فضا تابعی را برازش می‌دهد. هر چند که الگوریتم‌های مبتنی بر این روش دارای دقت مناسبی هستند ولی به دلیل کنکاش بیش از حد فضای متغیرهای ورودی ممکن است به پدیده بیش برازش دچار شوند. بیشتر الگوریتم‌های ارائه شده برای تعیین ساختار شبکه عصبی الگوریتم‌های تقریبی هستند و مشکل گرفتاری در حداقل محلی را دارند [۱۶]. مزیت روش ماشین بردار پشتیبان این است که حاشیه جداسازی برای دسته‌های مختلف کاملاً واضح هست. با این وجود هنگامی که مجموعه داده نویز زیادی داشته باشد، عملکرد خوبی ندارد و کلاس‌های هدف دچار همپوشانی می‌شوند. همچنین با افزایش تعداد داده، تعداد توابع کرنل افزایش می‌یابد که منجر به افزایش زمان محاسبات خواهد شد [۱۷]. یکی از مهم‌ترین مدل‌های محاسبات نرم که عدم قطعیت‌های پارامترهای ورودی را به طور قابل توجهی پوشش می‌دهد مدل شبکه عصبی فازی تطبیقی است. ترکیب توانایی‌های

می‌نماید [۳]. برازش این رابطه بر داده‌های محققان مختلف حاوی پراکندگی زیاد داده‌ها حول خط برازش شده هست که نشان از پیچیده بودن ماهیت این پدیده است و لزوم استفاده از روش‌های جدید برای تخمین دقیق‌تر افت انرژی محسوس می‌شود.


سلماسی و ازگر [۹]، دقت مدل عصبی فازی تطبیقی را با مدل رگرسیون گیری کلاسیک مورد مقایسه قرار دادند و نتیجه گرفتند که دقت مدل عصبی فازی تطبیقی (ANFIS) بیشتر از مدل به دست آمده توسط رگرسیون است. آن‌ها با استفاده از رگرسیون گیری چندین رابطه پیشنهاد دادند که دقیق‌ترین آن دارای رابطه‌ای به صورت زیر (با $R^2=0/928$) است.

$$\frac{\Delta H}{H_0} = -1.063Fr_1^{-2.119} + 350.365(vc/h)^{-0.02} + 473.031\left(\frac{q^2}{gh^3}\right)^{-0.014} + 61.544N^{0.052} - 858.114S^{0.007} \quad (6)$$

هم‌زمان با گسترش کاربرد رایانه در علوم مهندسی محققان به کاربرد روش‌های هوش مصنوعی در علوم آب علاقه‌مند شده‌اند. یکی از مزایای روش‌های مبتنی بر هوش مصنوعی نسبت به روش کلاسیک رگرسیون گیری، قابلیت مدل‌سازی بهتر تحت شرایط پراکنش و عدم قطعیت در اندازه‌گیری‌ها است. از این‌رو کاربرد آن‌ها گسترش روز افزون یافته است. روشنگر و همکاران [۱۰]، کاربرد شبکه عصبی (ANN) و سیستم عصبی فازی تطبیقی (ANFIS) را برای افت انرژی در جریان تیغه‌ای مورد بررسی قرار دادند. آن‌ها نتیجه گرفتند که سیستم عصبی فازی تطبیقی قابلیت برآورد بهتری نسبت به شبکه عصبی دارد. همچنین پارامترهای تأثیرگذار عمق بحرانی، ارتفاع و تعداد پله است. سلماسی و ازگر [۹]، با استفاده از نرم‌افزار SPSS به ارائه رابطه برای تخمین افت انرژی در سرریز پلکانی پرداختند. همچنین به کمک روش عصبی فازی تطبیقی اقدام به پیش‌بینی استهلاک انرژی در سرریزهای پلکانی نمودند. نتایج آن‌ها حاکی از برتری روش عصبی فازی تطبیقی در مقابل معادلات رگرسیونی دارد. پارسایی و حقی آبی [۱۱]، کارایی روش‌های شبکه عصبی چند لایه و الگوریتم یادگیری ماشین بر اساس ساختار درختی، موسوم به M5، در پیش‌بینی استهلاک انرژی سرریزهای پلکانی را مورد ارزیابی قرار دادند. الگوریتم M5 اولین بار توسط کوینلان [۱۲]، ارائه و توسط وانگ [۱۳]، بهبود داده شد. نتایج حاکی از آن است که با وجود دقت بالای هر دو روش، الگوریتم M5 عملکرد بهتری از خود نشان می‌دهد. جیانگ و همکاران [۱۴]، به بررسی افت انرژی در

1 Support Vector Machine

2 Back propagation



شکل ۱. پارامترهای هندسی و هیدرولیکی مؤثر بر اتلاف انرژی جریان

Fig. 1. Effective geometric and hydraulic parameters on the dissipation of flow energy

$$E_0 = H_w + y_0 + \frac{V_0^2}{2g} = H_w + y_0 + \frac{q^2}{2g(H_w + y_0)} \quad (7)$$

$$E_1 = y_1 + \frac{V_1^2}{2g} = y_1 + \frac{q^2}{2gy_1^2} \quad (8)$$

در این رابطه‌ها V_1 و V_0 به ترتیب سرعت جریان در بالادست و پایین‌دست سرریز، q دبی در واحد سرریز، g شتاب ثقل زمین است. نرخ اتلاف انرژی جریان با کم کردن انرژی جریان پایین‌دست و بالادست سرریز پلکانی به صورت رابطه (۹) به دست می‌آید.

$$\frac{\Delta E}{E_0} = \frac{E_0 - E_1}{E_0} = 1 - \frac{E_1}{E_0} \quad (9)$$

برای مشخص کردن تأثیر پارامترهای هیدرولیکی جریان و هندسی سرریز پلکانی بر مقدار اتلاف انرژی، می‌توان اتلاف انرژی را به صورت تابعی از پارامترهای هیدرولیکی و هندسی دانست. پارامترهای هندسی و هیدرولیکی مؤثر در استهلاک انرژی در رابطه (۱۰) آورده شده است.

$$\frac{\Delta E}{E_0} = f(q, l, h, H_w, g, N) \quad (10)$$

که در آن N تعداد پله‌های سرریز است. با به کارگیری آنالیز ابعادی

شبکه‌های عصبی و سیستم استنتاج فازی ممکن است سبب افزایش قدرت شبیه‌سازی مدل نسبت به شبکه‌های عصبی گردد. با این وجود در آموزش مدل عصبی فازی تطبیقی به طور متداول از الگوریتم‌های کلاسیک استفاده می‌شود. جایگزینی الگوریتم آموزشی متداول با روش‌های بهینه‌یابی قدرتمند منجر به بهبود کارایی مدل می‌شود. در این تحقیق با توجه به توانمندی‌های الگوریتم بهینه‌یابی کرم شبتاب، از این الگوریتم برای آموزش ساختار عصبی فازی تطبیقی استفاده شده است؛ و توانمندی این مدل ترکیبی برای تخمین عملکرد سرریزهای پلکانی در میزان استهلاک انرژی با مدل شبکه عصبی چند لایه و مدل برنامه‌نویسی بیان ژن مقایسه خواهد شد.

۲- مواد و روش‌ها

در تحقیق حاضر توانایی هوش مصنوعی در پیش‌بینی افت انرژی در رژیم جریان روبه‌ای مورد بررسی قرار گرفته است. برای محاسبه مقدار اتلاف انرژی جریان عبوری بر روی سرریز پلکانی به کارگیری رابطه برنولی برای بالادست و پایین‌دست سرریز همان‌طور که در شکل ۱ نشان داده شده است ضروری است.

در این شکل E_0 کل انرژی جریان در بالادست سرریز، y_0 عمق جریان قبل از سرریز، H_w ارتفاع سرریز، l و h به ترتیب ارتفاع و طول پله‌ها، y_1 عمق جریان در پایین‌دست سرریز و y_2 عمق جریان بعد از پرش هیدرولیکی است. رابطه انرژی جریان در بالادست و پایین‌دست سرریز در روابط (۷) و (۸) ارائه شده است.

جدول ۱. خصوصیات آماری داده‌های مورد استفاده در تحقیق حاضر

Table 1. Statistical characteristics of used data in the present research

پارامتر	افت بی‌بعد انرژی	عدد فرود اولیه پرش	عمق بحرانی به ارتفاع پله	عدد آبخار	تعداد پله	شیب سرریز پلکانی (شیب کف کاذب)
نماد	$\Delta H/H_0$	Fr_1	Y_c/h	q^2/gh^3	N	S
کمترین	۱۳/۱۴۵	۰/۲۳۴	۰/۰۹۴	$۴/۰۰ \times ۱۰^{-۶}$	۳	۱۵/۰۰
بیشترین	۹۶/۵۸۰	۹/۳۳۹	۱۳/۷۸۱	۰/۱۰۹	۵۰	۴۵/۰۰
میانه	۶۰/۷۴۶	۴/۰۵۹	۱/۸۱۳	۰/۰۰۱	۱۵	۴۵/۰۰
میانگین	۵۹/۱۷۲	۴/۲۱۴	۲/۵۲۹	۰/۰۱۲	۱۸/۵۱۹	۳۴/۱۵۶
انحراف معیار	۲۳/۱۷۹	۱/۴۲۱	۲/۴۲۸	۰/۰۲۳	۱۴/۳۸۷	۱۳/۵۷۴

نیکویی برازش (R^2)، مجذور میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) استفاده شده است. این روابط به صورت زیر تعریف شده‌اند:

$$R^2 = \frac{\left[\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right]^2}{\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (13)$$

$$RSME = \sqrt{\frac{\sum_{i=1}^n (Y_i - X_i)^2}{n}} \quad (14)$$

$$MAE = \frac{\sum_{i=1}^n |Y_i - X_i|}{n} \quad (15)$$

در این روابط، X_i و Y_i به ترتیب i امین داده واقعی (اندازه‌گیری شده) و برآورد شده، \bar{X} و \bar{Y} میانگین کل داده‌های X_i و Y_i در کل جامعه آماری و n تعداد کل نمونه‌های ارزیابی شده می‌باشند.

۲-۱- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی در واقع یک سیستم غیرخطی پیوسته و یک

پارامترهای بی‌بعد استخراج می‌شود. پارامترهای بی‌بعد در رابطه (۱۱) آورده شده است.

$$\frac{\Delta E}{E_0} = f \left(\frac{q^2}{gH_w^3}, \frac{h}{l}, N, \frac{y_c}{h}, Fr_1 \right) \quad (11)$$

در این رابطه Fr_1 عدد فرود جریان در پایین‌دست سرریز و y_c عمق بحرانی جریان بر روی سرریز است. اگر در این رابطه نسبت $q^2 / (gH_w^3)$ عدد دراپ نامیده شود و با نماد DN نشان داده شود، انرژی مخصوص (E) با انرژی کل (H) جایگزین و h/l را به عنوان شیب سرریز با S نشان داده شود، رابطه (۱۱) را می‌توان به صورت رابطه (۱۲) بازنویسی نمود.

$$\frac{\Delta H}{H_0} = f \left(DN, S, N, \frac{y_c}{h}, Fr_1 \right) \quad (12)$$

برای استفاده از مدل‌های رایانش نرم به جهت برآورد عملکرد سرریزهای پلکانی در استهلاک انرژی، پارامترهای سمت راست رابطه (۱۲) به عنوان ورودی و نرخ بی‌بعد استهلاک انرژی ($\Delta H/H_0$) به عنوان خروجی مدل مدنظر گرفته شد. بدین منظور از ۱۵۴ داده آزمایشگاهی ارائه شده توسط سلماسی و ازگر [۹] استفاده گردید. محدوده داده‌های مورد استفاده در تحقیق حاضر در جدول ۱ ارائه شده است:

در این تحقیق، برای ارزیابی دقت روابط از سه معیار آماری ضریب

انتخاب آن در تحقیق حاضر پرداخته شده است.

۲-۳- الگوریتم کرم شب‌تاب (Firefly Algorithm)

الگوریتم کرم شب‌تاب یکی از الگوریتم‌های بهینه‌یابی است که بر پایه محاسبات تکاملی بنا شده است. این الگوریتم توسط یانگ [۱۸]، معرفی گردید. ایده اصلی این الگوریتم از ارتباط نوری بین کرم‌های شب‌تاب الهام گرفته است. کرم‌های شب‌تاب نورهایی تولید می‌کنند که الگوی نوری هر کدام با یکدیگر متفاوت است. کرم‌های شب‌تاب به سمت نور بیشتر جذب می‌شوند و میزان جذب بین دو کرم شب‌تاب با درخشندگی آن‌ها نسبت مستقیم و با فاصله بین آن‌ها نسبت عکس دارد [۱۹].

بر طبق تحقیقات نویسندگان این مقاله، تاکنون این الگوریتم برای تخمین افت انرژی در سرریزهای پلکانی استفاده نشده است. همچنین دارای مزایای زیر است:

۱- جامع‌تر از الگوریتم‌های متداول مانند PSO است. به گونه‌ای که با تغییر و حذف قسمتی از کد آن می‌توان به الگوریتم PSO استاندارد دست یافت [۲۰].

۲- این الگوریتم قابلیت دارد که به روش جستجوی تصادفی گرایش پیدا نماید؛ بنابراین می‌توان چندین بهینگی را در طول یک تکرار یافت [۲۰]. همچنین این جمله به معنی آن است که میزان دقت در تخمین حدس اولیه در شروع محاسبات تأثیر چندانی برای رسیدن به جواب نهایی نخواهد داشت. ۳- این الگوریتم نسبت به بسیاری از الگوریتم‌های تکاملی ساختار ساده‌تری دارد؛ بنابراین کد نویسی آن راحت‌تر است.

۴- نسبت به بسیاری از الگوریتم‌های متداول مانند PSO سرعت اجرای بالاتری دارد که منجر به کاهش زمان همگرایی مدل و در نتیجه کاهش هزینه محاسباتی خواهد شد.

۵- در این الگوریتم تعداد پارامترهایی که برای رسیدن به جواب باید تنظیم شود، کم است [۲۱].

۶- برای مسائل تک مدی^۵ با تعداد بسیار کمی جمعیت کرم شب‌تاب به جواب بهینه دست می‌یابد [۲۲]. همچنین عملکرد مناسبی در جست و جوی جواب‌های بهینه در مسائل غیرخطی و چند مدی^۶ دارد [۱۸].

سیستم استنتاج عصبی-فازی تطبیقی^۷ از انواع شبکه عصبی مصنوعی می‌باشند که بر اساس سیستم فازی تاکاگی-سوگنو آموزش داده شده است.


ساختار اتصالی هستند که قادر به تقلید از رفتار مغز در برخورد با اطلاعات ورودی می‌باشند. اتصالات شامل وزن‌های اتصالی بین هر دو نرون می‌باشند. در تحقیق حاضر از شبکه عصبی پرسپترون چند لایه^۱ (MLP) با الگوریتم آموزشی لوبنرگ مارکوات^۲ استفاده شده است. از حداکثر ۳ لایه پنهان با تعداد بین ۱ تا ۲۰ نرون در هر لایه استفاده شده است. برای انتقال اطلاعات بین هر لایه از تابع فعال‌سازی منطقی^۳ استفاده شده است. شکل این تابع به صورت سیگموئید و خروجی آن بین صفر تا یک می‌باشد.

۲-۲- تئوری فازی و شبکه عصبی فازی تطبیقی


تئوری فازی بر مبنای محاسبات عددی بر روی مقادیر تولید شده توسط تابع عضویت برای هر یک از متغیرهای ورودی عمل می‌نماید و با استفاده از انتخاب قواعد اگر-آنگاه، سیستم استنتاج فازی را تشکیل می‌دهد. در تحقیق حاضر برای ایجاد شبکه عصبی فازی از دستور "genfis3" استفاده شده است. سیستم استنتاج فازی از نوع تاکاگی-سوگنو^۴ است؛ و در ساختار این سیستم برای عملگر and از روش "Prod" و برای عملگر or از روش "Probor" استفاده شده است. برای غیر فازی سازی از روش "wtav-er" استفاده شده است. از تابع عضویت فازی گوسی با حداکثر ۸ تابع عضویت استفاده شد که در نهایت تعداد ۳ دسته طبقه بندی به عنوان تعداد دسته بهینه به دست آمد. قوت شبکه‌های عصبی قابلیت یادگیری و انطباق می‌باشد. در حالی که مجموعه‌های فازی امکان ارائه اطلاعات در قالب قواعد فازی اگر-آنگاه را دارند. عموماً ترکیب این دو روش نسبت به استفاده انحصاری از تک‌تک آن‌ها دارای عملکرد بهتری است. این نگرش منجر به ایجاد سیستم‌هایی در قالب محاسبات عصبی-فازی شده است. در محیط عصبی-فازی تطبیقی به طور معمول از یکی از دو روش پس انتشار و یا ترکیب حداقل مربعات و کاهش شیب پس انتشار برای آموزش مدل استفاده می‌شود. این دو روش به نسبت قدیمی می‌باشند. چنانچه بتوان از قابلیت‌های محاسبات تکاملی در بهینه‌یابی آموزش مدل استفاده نمود ممکن است بتوان قابلیت فراگیری و سازگاری با محیط‌های ناشناخته را در مدل‌های هوش محاسباتی افزون نمود. در تحقیق حاضر با استفاده از کد نویسی در محیط MATLAB از ترکیب شبکه عصبی فازی تطبیقی و الگوریتم کرم شب‌تاب به منظور آزمون قابلیت مدل ترکیبی مذکور در تخمین افت انرژی استفاده شده است. در ادامه به معرفی اجمالی الگوریتم کرم شب‌تاب و دلایل

- 1 Multi-Layer Perceptron
- 2 Levenberg-Marquardt
- 3 Logistic
- 4 Takagi-Sugeno Fuzzy Model

- 5 Uni-Modal
- 6 Multi-Modal
- 7 Adaptive Neuro-Fuzzy Inference System (ANFIS)



ب-نتایج شبیه‌سازی به ازای تمام پارامترها در مرحله آزمایش



الف-نتایج شبیه‌سازی به ازای تمام پارامترها در مرحله آموزش

شکل ۲. نتایج حاصل از شبیه‌سازی افت انرژی در بهترین ساختار ANFIS-FA

Fig. 2. Results arising of energy dissipation simulation in the best ANFIS-FA structure

به یک مدل درختی تبدیل می‌شود؛ بنابراین، GEP یک سیستم ژنوتیپ فنوتیپ است و از یک ژنوم ساده برای نگهداری و انتقال اطلاعات وراثتی و یک فنوتیپ پیچیده برای کشف محیط و سازگاری با آن بهره می‌برد [۲۵].

۳- بحث و نتایج

۳-۱- نتایج حاصل از ترکیب عصبی فازی تطبیقی و کرم شبتاب (ANFIS-FA)

در شکل ۲ نتایج حاصل از اجرای مدل ترکیبی در حالی که تمام پارامترها به عنوان ورودی به مدل معرفی شده‌اند نشان داده شده است. شبیه‌سازی به ازای تمام متغیرها دارای $RMSE=2/155$ و $R^2=0/991$ در مرحله آموزش و $RMSE=3/796$ و $R^2=0/976$ در مرحله آزمایش مدل می‌باشد.

در جدول ۲ نتایج حاصل از تغییر پارامتر ورودی بر دقت مدل ترکیبی برای کل داده‌ها نشان داده شده است. همچنین در شکل ۳ تا شکل ۵ نتایج حاصل از شبیه‌سازی در مراحل آموزش و آزمایش به تفکیک برای مدل‌های با یک، دو و سه پارامتر ورودی، نشان داده شده است. به جهت سهولت کار از علائم اختصاری استفاده شده است. بدین ترتیب که A معرف عدد فرود اولیه پرش (Fr_1) ، B معرف $\frac{y_c}{h}$ ، C معرف عدد آبشار (یعنی $\frac{q}{gH^3}$)، D معرف تعداد پله (N) و E معرف شیب کف کاذب (S) است.

این شیوه در سال ۱۹۹۰ ابداع شد [۲۳]. سیستم استنتاج آن مطابق قوانین فازی اگر-آنگاه می‌باشد. ترکیب شبکه عصبی و مفاهیم منطق فازی در این نوع شبکه آن را برای تقریب زدن توابع غیرخطی قادر می‌سازد [۲۴]. در الگوریتم ترکیبی سیستم استنتاج عصبی فازی تطبیقی-کرم شبتاب آموزش مدل، توسط تابع بهینه کننده کرم شبتاب صورت می‌گیرد. به منظور بهینه‌سازی مقادیر توابع عضویت در شبکه ANFIS مقدار پارامترهای مورد استفاده در الگوریتم کرم شبتاب برای جمعیت اولیه برابر ۲۵، تعداد تکرار برابر ۱۰۰۰، ضریب γ برابر ۱، ضریب α برابر ۰/۱۲ و ضریب β_0 برابر ۲ در نظر گرفته شد.

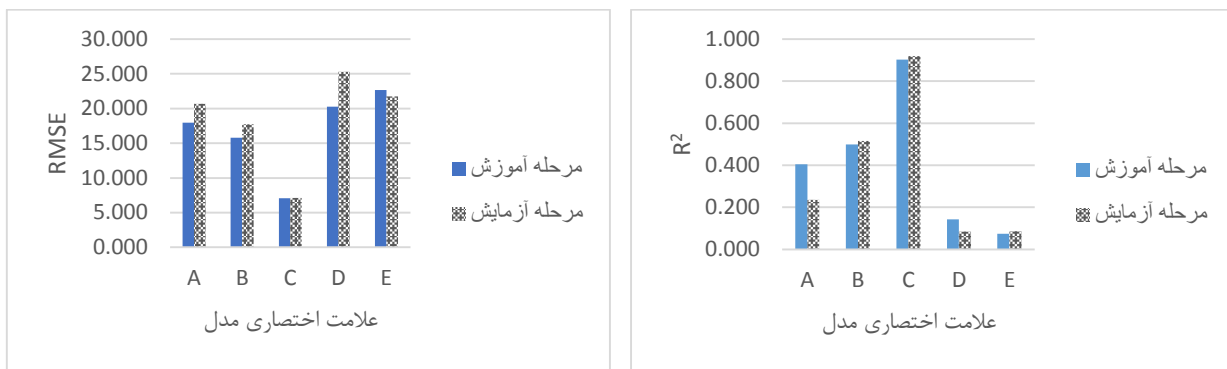
۲-۴- برنامه‌نویسی بیان ژن (GEP)

برنامه‌نویسی بیان ژن یک الگوریتم تکاملی است که با استفاده از اصول بنیادی الگوریتم ژنتیک و برنامه‌نویسی وراثتی گسترش یافته است. برنامه‌نویسی بیان ژن برای تولید برنامه‌هایی رایانه‌ای که دارای ساختارهایی شبیه درخت هستند و با تغییر اندازه‌ها، شکل و ترکیب آن‌ها، قادر به شبیه‌سازی پارامتر مورد نظر می‌باشند. در این روش موضوع مورد نظر با یک کروموزوم خطی با طول ثابت به عنوان برنامه کامپیوتری کدگذاری می‌شود. الگوریتم برنامه‌نویسی بیان ژن، به صورت تصادفی یک کروموزوم ایجاد می‌نماید که به صورت یک تابع ریاضی نمایش داده می‌شود و سپس

جدول ۲. آنالیز حساسیت برای پارامترهای ورودی در الگوریتم ترکیبی عصبی فازی تطبیقی - کرم شب تاب

Table 2. Sensitivity analysis for input parameters in adaptive neural fuzzy hybrid Firefly algorithm

پارامتر ورودی مدل	MAE	RMSE	R ²	پارامتر ورودی مدل	MAE	RMSE	R ²
$\left\{Fr, \frac{y_c}{h}, \frac{q^2}{gH_c^3}, N\right\}$	۱/۵۸۵	۲/۲۵۷	۰/۹۹۰	$\left\{\frac{y_c}{h}, \frac{q^2}{gH_c^3}, N\right\}$	۴/۲۱۰	۵/۷۹۶	۰/۹۳۸
$\left\{Fr, \frac{y_c}{h}, \frac{q^2}{gH_c^3}, S\right\}$	۴/۵۶۷	۵/۹۰۷	۰/۹۳۵	$\left\{\frac{y_c}{h}, \frac{q^2}{gH_c^3}\right\}$	۴/۴۷۹	۶/۱۱۴	۰/۹۳۰
$\left\{Fr, \frac{y_c}{h}, \frac{q^2}{gH_c^3}\right\}$	۲/۱۱۹	۲/۷۸۱	۰/۹۸۶	$\left\{\frac{y_c}{h}\right\}$	۱۲/۸۲۹	۱۶/۱۷۷	۰/۵۱۰
$\left\{Fr, \frac{q^2}{gH_c^3}\right\}$	۱/۴۶۱	۱/۷۵۶	۰/۹۹۴	$\left\{\frac{q^2}{gH_c^3}\right\}$	۵/۱۲۷	۶/۹۹۸	۰/۹۰۸
$\{Fr\}$	۱۳/۶۲۳	۱۸/۶۴۲	۰/۳۵۱	$\{N\}$	۱۹/۶۳۹	۲۳/۴۵۳	۰/۰۲۰
$\left\{\frac{y_c}{h}, \frac{q^2}{gH_c^3}, N, S\right\}$	۳/۹۴۱	۵/۴۶۴	۰/۹۴۴	$\{S\}$	۱۷/۹۶۸	۲۲/۱۷۹	۰/۰۸۰



شکل ۳. ارزیابی میزان حساسیت مدل به هر یک از متغیرها الف) بر اساس معیار R² ب) بر اساس معیار RMSE

Fig. 3. Assessing the sensitivity of the model to each of the variables. A) according to R²criterion. B) according to RMSE criterion



شکل ۴. ارزیابی میزان حساسیت مدل به دو متغیر ورودی الف) بر اساس معیار R² ب) بر اساس معیار RMSE

Fig. 4. Assessing the sensitivity of the model to two input parameters. A) according to R²criterion. B) according to RMSE criterion



شکل ۵. ارزیابی میزان حساسیت مدل به سه متغیر ورودی (الف) بر اساس معیار R² (ب) بر اساس معیار RMSE

Fig. 5. Assessing the sensitivity of the model to three input parameters. A) according to R²criterion. B) according to RMSE criterion

جدول ۳. ویژگی‌های مورد استفاده در تحقیق حاضر برای برنامه‌نویسی بیان ژن

Table 3. Used characteristics in the present research for Programming of Gene Expression

تنظیمات پارامتر	پارامتر ژنتیکی	تنظیمات پارامتر	پارامتر ژنتیکی	تنظیمات پارامتر	پارامتر ژنتیکی
۰/۳	نرخ ترکیب یک نقطه‌ای ^۲	+	توابع اتصال ^۱	تنظیمات پارامتر: $+, -, \times, \sqrt{\quad}, \text{Exp}, \text{Ln}, x^2$	توابع ژنتیکی
۰/۳	نرخ ترکیب دونقطه‌ای ^۵	RMSE	نوع خطای تابع تناسب ^۴	۵۰-۱۰	تعداد کروموزوم ^۳
۰/۱	نرخ ترکیب ژن ^۸	۰/۱ - ۰/۰۲	نرخ جهش ^۷	۸	اندازه سر ^۶
۰/۱	نرخ انتقال ژن ^{۱۱}	۰/۱	نرخ وارونگی ^{۱۰}	۳	تعداد ژن ^۹

همان‌طور که مشاهده می‌شود از بین مدل‌هایی که فقط با یک پارامتر ورودی اقدام به شبیه‌سازی اتلاف انرژی در سرریز پلکانی می‌کنند مدل با علامت اختصاری C یعنی مدلی که از پارامتر $\frac{q}{gh^3}$ به عنوان ورودی استفاده می‌کند دارای دقت بیشتری نسبت به سایر پارامترها است. این پارامتر که به عنوان عدد آبشار موسوم است در طراحی ابعاد سازه هیدرولیکی مستهلک کننده انرژی چه در کانال‌های کوچک و چه در سرریزهای پلکانی بزرگ نقش اساسی ایفا می‌کند. پیش‌بینی انجام شده توسط تلفیق شبکه عصبی فازی و الگوریتم کرم شب‌تاب نیز این نکته را تأیید می‌نماید.

شکل ۴ به بررسی دقت مدل به ازای دو ورودی می‌پردازد. در ترکیب با پارامتر عدد آبشار، تأثیر دو پارامتر عدد فرود و نسبت عمق بحرانی به ارتفاع پله $(\frac{y_c}{h})$ مورد بررسی قرار گرفته است. همان‌طور که مشاهده می‌شود در


حالت ترکیبی، تلفیق عدد فرود جریان در ابتدای پرش و عدد آبشار دقت بیشتری نسبت به حالت ترکیب آبشار با $\frac{y_c}{h}$ دارد. که دلیل آن احتمالاً تشکیل پرش هیدرولیکی در حوضچه آرامش سرریزهای پلکانی است. به ویژه در دبی‌های بالا که احتمال جریان رویه‌ای وجود دارد؛ زیرا در حالت تشکیل پرش قسمت عمده‌ای از انرژی به دلیل تلاطم، مستهلک خواهد شد. همچنین اثر ارتفاع پله در نسبت $\frac{y_c}{h}$ با افزایش دبی جریان کاهش می‌یابد؛ زیرا با افزایش عمق جریان به سبب افزایش دبی، پله به المان زبری تبدیل شده و جریان از حالت برخورد به بستر به حالت سر خوردن از پله همراه با جریان‌های چرخشی تبدیل خواهد شد.

شکل ۵ از ۳ پارامتر ورودی به منظور تخمین دقت مدل استفاده می‌کند. در این حالت نیز ترکیب عدد آبشار و عدد فرود قبل از پرش، نسبت به سایر


جدول ۴. خصوصیات (تعداد کروموزوم و نرخ جهش) در ساختارهای مختلف

Table 4. Characteristics (Chromosome number and Mutation rate) in different structures

شماره ساختار	تعداد کروموزوم	جهش	شماره ساختار	تعداد کروموزوم	جهش	شماره ساختار	تعداد کروموزوم	جهش
۱	۳۰	۰/۰۴۴	۷	۳۰	۰/۰۶	۱۳	۵۰	۰/۱
۲	۴۰	۰/۰۴۴	۸	۳۰	۰/۰۸	۱۴	۱۰	۰/۰۲
۳	۲۰	۰/۰۴۴	۹	۳۰	۰/۱	۱۵	۱۰	۰/۰۶
۴	۱۰	۰/۰۴۴	۱۰	۵۰	۰/۰۲	۱۶	۱۰	۰/۰۸
۵	۵۰	۰/۰۴۴	۱۱	۵۰	۰/۰۶	۱۷	۱۰	۰/۱
۶	۳۰	۰/۰۲	۱۲	۵۰	۰/۰۸			



ارزیابی بهترین ساختارها بر اساس معیار آماری RMSE



ارزیابی بهترین ساختارها بر اساس معیار R²

شکل ۶. ارزیابی بهترین ساختارها در برنامه‌نویسی بیان ژن بر اساس معیار آماری R² و RMSE


Fig. 6. Evaluation of the best structures in Gene Expression Programming based on statistical criteria R² and RMSE

۳-۲- نتایج مدل برنامه‌نویسی بیان ژن


در تحقیق حاضر برای مدل‌سازی از طریق برنامه‌نویسی بیان ژن از ویژگی‌های مورد استفاده در جدول ۳ استفاده شده است و ساختارهای مختلف با تغییر تعداد کروموزوم و نرخ جهش مورد بررسی قرار گرفته است. در جدول ۴ خصوصیات هر ساختار نشان داده شده است.

در شکل ۶ نتایج مدل برنامه‌ریزی وراثتی به ازای بهترین ساختارها نشان داده شده است. همان‌طور که مشاهده می‌شود برنامه‌ریزی وراثتی به ازای ساختارهای مختلف جواب مناسبی را ارائه می‌دهد. همان‌طور که مشاهده می‌شود ساختارهای شماره ۲ و ۱۰ بهترین نتایج را پیش‌بینی

ترکیب‌ها بهترین جواب را ارائه می‌دهد. همان‌طور که مشاهده می‌شود به نظر می‌رسد ترکیب پارامتر آبشار و عدد فرود به عنوان وزنه‌ای اثرگذار در رسیدن به جواب صحیح مؤثر واقع می‌شود. از مقایسه نتایج به دست آمده حاصل از شبیه‌سازی با دو پارامتر $\frac{q}{gh^3}$ و Fr_1 نسبت به شبیه‌سازی با ۳ پارامتر $\frac{q}{gh^3}$ و Fr_1 و $\frac{y_c}{h}$ این نکته برداشت می‌شود که افزودن پارامتر سوم توفیق‌چندانی در بهبود دقت مدل‌سازی نداشته است. با توجه به نتایج به دست آمده، می‌توان نتیجه گرفت که افزودن پارامترهای بیشتر (تعداد پله و ابعاد پله) کمکی به افزایش دقت رابطه ننموده و تنها هزینه انجام محاسبات را افزایش می‌دهد.



نتایج بهترین ساختارها در مرحله آزمایش



نتایج بهترین ساختارها در مرحله آموزش

شکل ۷. نتایج بهترین ساختارها در روش برنامه‌نویسی بیان ژن در مرحله آموزش و آزمایش

Fig. 7. Results of the best structures of Gene Expression Programming at training and testing data stage

$R^2=0/094$ کمترین تأثیر را بر افت انرژی دارد.

همان‌طور که مشاهده می‌شود برای برنامه‌نویسی بیان ژن (GEP) نیز همچون نتایج روش ترکیب شبکه‌های عصبی فازی تطبیقی - الگوریتم کرم شبتاب (ANFIS-FA)، در بین مدل‌هایی که از ۲ پارامتر برای شبیه‌سازی استفاده می‌کنند، ترکیب عدد آبشار و عدد فرود قبل از پرش بیشترین دقت را از بین دیگر ساختارها دارا هست. در ترکیب ۳ پارامتر ورودی لحاظ کردن پارامترهای عدد آبشار، عدد فرود قبل از پرش و $\frac{y_c}{h}$ نسبت به عدد آبشار، عدد فرود قبل از پرش و تعداد پله (N) نتایج به نسبت بهتری ارائه می‌دهد؛ اما همچنان دقت مدل‌سازی کمتر از حالتی است که از ۲ پارامتر عدد آبشار و عدد فرود قبل از پرش به عنوان پارامتر ورودی در شبیه‌سازی استفاده شده باشد.

۳-۳ نتایج حاصل از شبکه عصبی

در جدول ۶ خصوصیات آماری در مورد نتایج حاصل از اجرای شبکه عصبی برای کل ساختارهای تشکیل شده با لایه‌های پنهان از ۱ تا ۳ لایه نشان داده شده است. با توجه به نزدیک بودن نتایج به یکدیگر و با توجه به اینکه شبکه با ۱ لایه پنهان قادر است به خوبی شبیه‌سازی دقیقی از افت انرژی ارائه دهد، پیشنهاد می‌شود برای مدل‌سازی از شبکه با یک لایه پنهان به سبب کاهش هزینه محاسباتی استفاده شود. به هر حال بهترین ساختار

می‌کنند. در شکل ۷ نتایج بهترین ساختارها در مرحله آموزش و آزمایش نشان داده شده است.

رابطه به دست آمده در ساختار شماره ۱۰ به صورت زیر است:

$$\frac{\Delta H}{H_0} = \left(\frac{1.76062}{\sin\left(\frac{-S}{0.114959}\right)} - Fr_1^{1.5} \right) + (9.494659 \times \cos(\ln\left(\frac{(0.267029 + Fr_1) \times (y_c / h)}{0.267029 \times N}\right))) + (8.213409 - 8.213409 \times \ln\left(\frac{q^2}{gh^3}\right) - \sin(\ln N)) \quad (16)$$

این ساختار در مرحله آموزش دارای معیارهای $RMSE=3/146$ ، $MAE=2/462$ و $R^2=0/981$ و در مرحله آزمایش دارای معیارهای $RMSE=3/983$ ، $MAE=3/135$ و $R^2=0/975$ است.

به منظور بررسی تأثیرگذاری هرکدام از پارامترها بر دقت مدل، با تغییر پارامترهای ورودی میزان صحت نتایج خروجی مدل با استفاده از معیارهای آماری مورد بررسی قرار گرفته است. از این رو جدول ۵ به آنالیز حساسیت پارامترهای ورودی می‌پردازد. همان‌طور که ملاحظه می‌شود، برای مدل‌های با یک پارامتر ورودی عدد آبشار $\left(\frac{q^2}{gh^3}\right)$ با $RMSE=7/262$ و بیشترین تأثیر و شیب کف کاذب (S) با $RMSE=21/191$ و

جدول ۵. آنالیز حساسیت برای پارامترهای ورودی در برنامه‌نویسی بیان ژن


Table 5. Sensitivity analysis results of input parameters in Gene Expression Programming

پارامتر ورودی مدل	MAE	RMSE	R ²	پارامتر ورودی مدل	MAE	RMSE	R ²
$\left\{Fr, \frac{y_c}{h}, \frac{q^2}{gH_c^3}, N\right\}$	۴/۶۷۶	۶/۲۸۳	۰/۹۲۱	$\left\{\frac{y_c}{h}, \frac{q^2}{gH_c^3}, N\right\}$	۴/۱۵۴	۵/۸۷۱	۰/۹۳۱
$\left\{Fr, \frac{y_c}{h}, \frac{q^2}{gH_c^3}, S\right\}$	۲/۱۱۱	۲/۸۰۸	۰/۹۸۵	$\left\{\frac{y_c}{h}, \frac{q^2}{gH_c^3}\right\}$	۴/۵۴۵	۶/۴۱۰	۰/۹۱۷
$\left\{Fr, \frac{y_c}{h}, \frac{q^2}{gH_c^3}\right\}$	۳/۵۸۹	۵/۱۰۲	۰/۹۵۴	$\left\{\frac{y_c}{h}\right\}$	۱۲/۰۱۵	۱۵/۰۳۶	۰/۵۴۴
$\left\{Fr, \frac{q^2}{gH_c^3}\right\}$	۱/۴۸۵	۱/۸۷۴	۰/۹۹۳	$\left\{\frac{q^2}{gH_c^3}\right\}$	۵/۰۹۴	۷/۲۶۲	۰/۸۹۴
$\{Fr\}$	۱۴/۲۸۱	۱۸/۶۱۰	۰/۳۳۴	$\{N\}$	۱۷/۵۱۱	۲۰/۷۳۰	۰/۱۳۳
$\left\{\frac{y_c}{h}, \frac{q^2}{gH_c^3}, N, S\right\}$	۴/۲۰۱	۵/۸۱۵	۰/۹۳۲	$\{S\}$	۱۷/۳۰۳	۲۱/۱۹۱	۰/۰۹۴

جدول ۶. خصوصیات آماری ساختارهای شبکه عصبی ارزیابی شده در تخمین افت انرژی سرریز پلکانی

Table 6. Statistical characteristics of evaluated Neural Network structures to estimate stepped spillway energy dissipation

تعداد ساختارهای ارزیابی شده	خصوصیت آماری	میانگین قدر مطلق خطا در مرحله آموزش (MAE)	میانگین قدر مطلق خطا در مرحله آزمایش (MAE)	R ²
شبکه با ۱ لایه پنهان	میانگین	۲/۶۶۰	۳/۷۳۶	۰/۹۶۷
	کمترین مقدار	۱/۷۴۰	۲/۵۹۵	۰/۹۳۱
	بیشترین مقدار	۴/۳۵۸	۴/۸۷۲	۰/۹۸۶
	میانه	۲/۶۷۶	۳/۹۳۳	۰/۹۶۹
شبکه با ۲ لایه پنهان	میانگین	۲/۲۰۸	۳/۰۳۸	۰/۹۷۷
	کمترین مقدار	۰/۷۱۶	۱/۷۲۱	۰/۳۶۸
	بیشترین مقدار	۱۲/۷۷۹	۱۳/۱۲۸	۰/۹۹۸
	میانه	۲/۰۷۶	۲/۹۳۱	۰/۹۸۲
شبکه با ۳ لایه پنهان	میانگین	۲/۵۷۰	۳/۳۰۴	۰/۹۷۱
	کمترین مقدار	۰/۶۴۹	۱/۶۵۹	۰/۳۷۶
	بیشترین مقدار	۱۲/۴۲۲	۱۳/۲۹۴	۰/۹۹۸
	میانه	۲/۵۸۵	۳/۲۰۲	۰/۹۷۳



شکل ۸. نتایج بهترین ساختار شبکه عصبی در مرحله آموزش و آزمایش

Fig. 8. Results of the best structures of Artificial Neural Network in training and testing data stage

جدول ۷. نتایج آزمون‌های آماری برای بهترین ساختار شبکه عصبی برای تمام داده‌ها و مراحل آموزش و آزمایش

Table 7. Statistical results for the best structure of Artificial Neural Network for all data in training and testing data stages

پارامتر آماری	مقدار در مرحله آموزش	مقدار در مرحله آزمایش	مقدار برای کل داده‌ها
R^2	۰/۹۹۹۷	۰/۹۸۵	۰/۹۹۴
RMSE	۰/۴۰۵	۳/۱۴۰	۱/۷۲۷
MAE	۰/۳۲۶	۲/۱۲۳	۰/۸۴۸



می‌پردازد. از بین روابط محققین مختلف، رابطه ارائه شده توسط سلماسی و ازگر (۲۰۱۴) بیشترین دقت را دارا هست. در جدول ۹ نیز دقت سه روش مورد استفاده در تحقیق حاضر که بر پایه هوش مصنوعی قرار دارند در مقابل سایر روابط ارائه شده در پیشینه تحقیق به صورت آماری مورد بررسی قرار گرفته است. همان‌طور که مشاهده می‌شود، دقت روش ANFIS-FA و GEP بسیار نزدیک به یکدیگر است و با توجه به معیارهای آماری MAE و RMSE دقت روش ANFIS-FA بهتر است. همچنین شبکه عصبی (البته با بهترین ساختار) با دارا بودن ضریب همبستگی برابر ۰/۹۹، میانگین قدر مطلق خطا برابر با ۰/۸۴۸ و میانگین مجذور مربعات خطا برابر ۱/۷۲۷ بیشترین دقت را در تخمین افت انرژی سرریز پلکانی از آن خود نموده است.

دارای ۳ لایه پنهان با تعداد به ترتیب ۱۲، ۸ و ۷ نرون در هر یک از لایه‌ها است. نتایج حاصل از اجرای بهترین مدل در شکل ۸ و در جدول ۷ برای داده‌های آموزش و آزمایش نشان داده شده است. همچنین در جدول ۸ آنالیز حساسیت برای متغیرهای ورودی در بهترین ساختار شبکه عصبی انجام گرفته است. همان‌طور که مشاهده می‌شود، عدد آبشار را با درصد اهمیت ۵۹ درصد و پس از آن تعداد پلکان با درصد اهمیت ۱۵/۴ دارای بیشترین تأثیر و میزان شیب سرریز پلکانی با میزان اهمیت ۱/۸ درصد، کمترین تأثیر را بر میزان افت انرژی بی‌بعد ($\frac{\Delta H}{H_0}$) دارد. شکل ۹ به مقایسه بصری دقت روابط کلاسیک ارائه شده توسط محققین مختلف برای تخمین افت انرژی سرریز پلکانی در رژیم جریان رویه‌ای

جدول ۸. آنالیز حساسیت برای بهترین ساختار شبکه عصبی

Table 8. Sensitivity analysis for the best structure of Artificial Neural Network

پارامتر	Fr_1	y_c / h	q^2 / gh^3	N	S
درصد اهمیت	۹/۵۷	۱۴/۱۵	۵۹/۰۲	۱۵/۴۲	۱/۸۴



شکل ۹. مقایسه تصویری دقت روابط محققین در تخمین افت انرژی

Fig. 9. Visual comparison of different formulas to estimate energy dissipation

جدول ۹. مقایسه آماری روابط و روش‌های مختلف در تخمین افت انرژی

Table 9. Statistical comparison of different relations and methods for estimation of the energy dissipation

	R^2	MAE	RMSE
Christodoulou(1993)	۰/۳۰۳	۱۳/۳۶۲	۲۱/۶۵۱
Chanson(1994)	۰/۲۶۷	۱۰/۱۹۴	۱۹/۲۶۳
Yasuda et al(2001)	۰/۲۶۱	۲۳/۸۴۴	۳۰/۱۷۱
Boes et al(2003)	۰/۲۱۷	۱۲/۹۱۹	۲۰/۲۶۰
Salmasi and Ozger(2014)	۰/۹۲۸	۴/۶۹۰	۶/۲۰۵
ANN (The present study)	۰/۹۹۴	۰/۸۴۸	۱/۷۲۷
GEP(The present study)	۰/۹۷۸	۲/۶۷۲	۳/۴۲۹
ANFIS-FA(The present study)	۰/۹۷۹	۲/۳۸۶	۳/۳۶۳

۴- نتیجه گیری

سرریزهای پلکانی به جهت راندمان بالا در استهلاک انرژی در چهل سال اخیر به طور جدی مورد توجه و مطالعه قرار گرفته‌اند. از عوامل مؤثر بر افت انرژی در این سازه‌ها، حالت جریان است که در دبی‌های زیاد حالت گذر جریان از روی سرریز پلکانی به صورت رویه‌ای هست. در تحقیق حاضر برای جریان رویه‌ای، تأثیر عوامل هندسی و خصوصیات هیدرولیکی جریان (پارامترهای عدد فرود اولیه پرش، عدد آبشار، نسبت عمق بحرانی به ارتفاع پله، تعداد پله و شیب کف کاذب سرریز پلکانی) بر افت انرژی مورد مطالعه قرار گرفت. برای این کار از روش شبکه عصبی (ANN) و همچنین ترکیب روش عصبی فازی تطبیقی با تابع بهینه یاب بر اساس الگوریتم کرم شب‌تاب (ANFIS-FA) و روش برنامه نویسی بیان ژن (GEP) استفاده گردید. نتایج نشان می‌دهد که:

۱- در هر سه روش استفاده شده در تحقیق حاضر، متغیرهای عدد آبشار و شیب کاذب کف به ترتیب بیشترین تأثیر و کمترین تأثیر را بر میزان افت انرژی سازه دارند.

۲- در مدل‌سازی با روش ANFIS-FA تنها با دو پارامتر ورودی عدد آبشار و عدد فرود قبل از پرش می‌توان به جواب مناسب با $R^2=0/994$ و $MAE=1/461$ دست یافت و افزودن سایر پارامترها توفیق چندانی در بهبود دقت مدل‌سازی ایجاد نمی‌نماید. مدل‌سازی به ازای تمام پارامترهای ورودی منجر به $R^2=0/979$ و $MAE=2/386$ می‌شود.

۳- روش‌های ANFIS-FA و ANN قادر به ارائه رابطه به صورت مستقیم نمی‌باشند. روش GEP برخلاف آن‌ها توانایی ایجاد رابطه با دقت مناسب را دارد؛ اما به دلیل پیچیدگی ساختار به دست آمده از روش GEP پیشنهاد می‌گردد که در مدل‌های با قابلیت برنامه‌ریزی از آن استفاده گردد. میزان دقت بهترین ساختار روش GEP برابر $R^2=0/987$ و $MAE=2/672$ هست.

۴- شبکه عصبی مورد استفاده در تحقیق حاضر دارای دقت مناسبی برای مدل‌سازی افت انرژی است که در آن از ۱ تا ۳ لایه پنهان در ساختار شبکه عصبی استفاده شد. میانگین R^2 برای ساختارهای مختلف شبکه عصبی برای یک تا سه لایه پنهان به ترتیب $0/967$ و $0/977$ و $0/971$ است که نشان از دقت بالای شبکه عصبی در تخمین افت انرژی هست. بهترین شبکه دارای ۳ لایه پنهان با تعداد به ترتیب ۱۲ و ۸ و ۷ نرون در هر لایه با $R^2=0/994$ و $MAE=0/848$ هست، ولی با توجه به نتایج به نسبت یکسان ساختارهای مختلف و دقت بالای شبکه عصبی، می‌توان با استفاده از

تنها یک لایه پنهان به دقت مناسب شبیه‌سازی دست یافت.

۵- هر سه روش ANFIS-FA و GEP و ANN مورد استفاده در تحقیق حاضر دارای دقت بالاتری نسبت به روابط کلاسیک ارائه شده توسط محققین مختلف برای تخمین افت انرژی دارند. همچنین هر سه روش دارای دقتی تقریباً مساوی می‌باشند. با این وجود بهترین ساختار شبکه عصبی دقت بالاتری نسبت به سایر روش‌ها دارد.

منابع

- [1] H. Chanson, L. Toombes, Experimental investigations of air entrainment in transition and skimming flows down a stepped chute, Canadian Journal of Civil Engineering, 29(1) (2002) 145-156. [1]
- [2] N. Rajaratnam, Skimming flow in stepped spillways, Journal of Hydraulic Engineering, 116(4) (1990) 587-591
- [3] H. Chanson, Hydraulics of stepped chutes and spillways, CRC Press, 2002.
- [4] A.L.A. Simões, H.E. Schulz, R. De Melo Porto, Stepped and smooth spillways: resistance effects on stilling basin lengths, Journal of Hydraulic Research, 48(3) (2010) 329-337.
- [5] G.C. Christodoulou, Energy dissipation on stepped spillways, Journal of Hydraulic Engineering, 119(5) (1993) 644-650.
- [6] H. Chanson, Comparison of energy dissipation between nappe and skimming flow regimes on stepped chutes, Journal of Hydraulic Research, 32(2) (1994) 213-218.
- [7] R.M. Boes, W.H. Hager, Hydraulic design of stepped spillways, Journal of Hydraulic Engineering, 129(9) (2003) 671-679.
- [8] Y. Yasuda, Energy dissipation of skimming flows on stepped-channel chutes, in: Fluvial, Environmental and Coastal Developments in Hydraulic Engineering, CRC Press, (2004) 77-90.
- [9] F. Salmasi, M. Özger, Neuro-fuzzy approach for estimating energy dissipation in skimming flow over stepped spillways, Arabian Journal for Science and Engineering, 39(8) (2014) 6099-6108.

- (2000) 652-658.
- [18] X.-S. Yang, Firefly algorithms for multimodal optimization, in: International symposium on stochastic algorithms, Springer, (2009) 169-178.
- [19] X.-S. Yang, X. He, Firefly algorithm: recent advances and applications, arXiv preprint arXiv:1308.3898, (2013) 1-14.
- [20] M. Saniee-Abadeh, Z. Jabal-Amelian, Evolutionary algorithms and biological calculations, Niaze-Danesh Publication, 2013.
- [21] Q. Fu, Z. Liu, N. Tong, M. Wang, Y. Zhao, A novel firefly algorithm based on improved learning mechanism, in: International conference on logistics engineering, management and computer science (LEMCS 2015), Atlantis Press, (2015) 1-9.
- [22] I. Fister, I. Fister Jr, X.-S. Yang, J. Brest, A comprehensive review of firefly algorithms, Swarm and Evolutionary Computation, 13 (2013) 34-46.
- [23] J.-S. Jang, ANFIS: adaptive-network-based fuzzy inference system, IEEE transactions on systems, man, and cybernetics, 23(3) (1993) 665-685.
- [24] A. Abraham, Adaptation of fuzzy inference system using neural learning, in: Fuzzy systems engineering, Springer, (2005) 53-83.
- [25] C. Ferreira, Gene expression programming: mathematical modeling by an artificial intelligence, Springer, 2006.
- [10] K. Roushangar, S. Akhgar, F. Salmasi, J. Shiri, Neural networks-and neuro-fuzzy-based determination of influential parameters on energy dissipation over stepped spillways under nappe flow regime, ISH Journal of Hydraulic Engineering, 23(1) (2017) 57-62.
- [11] A. Parsaie, A.H. Haghiabi, Evaluation of energy dissipation on stepped spillway using evolutionary computing, Applied Water Science, 9(6) (2019) 144.1-7.
- [12] J.R. Quinlan, Learning with continuous classes, in: 5th Australian joint conference on artificial intelligence, World Scientific, (1992) 343-348.
- [13] Y. Wang, I.H. Witten, Induction of model trees for predicting continuous classes, (1996).
- [14] L. Jiang, M. Diao, H. Xue, H. Sun, Energy dissipation prediction for stepped spillway based on genetic algorithm-support vector regression, Journal of Irrigation and Drainage Engineering, 144(4) (2018) 04018003.1-9.
- [15] A. Parsaie, A.H. Haghiabi, The hydraulic investigation of circular crested stepped spillway, Flow Measurement and Instrumentation, 70 (2019) 101624.1-5.
- [16] M.R. Meybodi, H. Beygy, Neural Network Engineering Using Learning Automata: Determination of Desired Size for Three Layers Feed Forward Neural Networks, Journal of Faculty of Engineering (University of Tehran), 34(4 (70)) (2001) 1-26. (in Persian).
- [17] M.E. Tipping, The relevance vector machine, in: Advances in neural information processing systems,

چگونه به این مقاله ارجاع دهیم

A. Jael, M. Rashki Ghle Nou, M. Zolghadr, Determining the capability of artificial intelligence in estimating energy dissipation of skimming flow regime at stepped spillways, Amirkabir J. Civil Eng., 53(9) (2021) 3897-3912.

DOI: 10.22060/ceej.2020.18156.6783

