

# پیش‌بینی دبی ورودی روزانه سد سفیدرود با الگوریتم‌های فراابتکاری ترکیبی با سیستم استنتاج عصبی فازی

حسین حکیمی خانسر<sup>۱</sup>، جواد پارسا<sup>۲\*</sup>، عمران مؤمنی کلشتیری<sup>۳</sup>، نوربخش کرمی<sup>۴</sup> معین خوشدل سنگده<sup>۵</sup>

<sup>۱</sup>دکتری علوم و مهندسی آب و کارشناس شرکت سهامی آب منطقه‌ای گیلان

<sup>۲</sup>گروه علوم و مهندسی آب، دانشگاه تبریز، تبریز، ایران، ایمیل jparsa@tabrizu.ac.ir

<sup>۳</sup>کارشناس ارشد مدیریت منابع آب و مدیر سدهای گیلان

<sup>۴</sup>کارشناس ارشد مدیریت ساخت و رییس اداره بهره‌برداری و نگهداری از سد و نیروگاه سفیدرود

<sup>۵</sup>کارشناس ارشد ژئوتکنیک و کارشناس شرکت سهامی آب منطقه‌ای گیلان

## چکیده

تخمین مقادیر دبی ورودی به سیستم منابع آبی یکی از اقدامات اساسی برای آگاهی از برنامه‌ریزی و تخصیص بهینه منابع آب به بخش‌های مختلف مصرف، در آینده است. در این مطالعه، از ترکیب الگوریتم‌های فراابتکاری شامل الگوریتم‌های چرخه‌ی آب (WCA)، گرگ خاکستری (GOW)، وال (WOA)، الگوریتم شبکه عصبی (GOA) و ملخ (NNA) برای آموزش سیستم عصبی- فازی و بهروزرسانی پارامترهای آن استفاده گردید و در نهایت بهترین مدل‌ها برای پیش‌بینی دبی ورودی روزانه سد مخزنی سفیدرود، توسعه داده شد. در مرحله آزمون، مدل ANFIS-WCA کمترین مقادیر MAE و SI NRMSE به ترتیب برابر  $R^2 = 0.736$ ،  $0.736/0.480$  و  $0.9840/0.9840$  بیشترین مقدار ANFIS-WCA مدل است. بر اساس شاخص عملکرد جهانی (GPI)، مدل ANFIS-GOA به عنوان بهترین مدل و پس از آن مدل‌های ANFIS-NNA، ANFIS-WOA و ANFIS-ANN بهترین دقت از طریق مدل ANFIS-GOA به دست آمد. نتایج نشان داد که مدل ANFIS-WCA با توجه به شاخص SI  $1/3\%$  در مقایسه با ANFIS-NNA و  $1/6\%$  در مقایسه با ANFIS-GOA کاهش را نشان می‌دهد. علاوه بر این، بر اساس GPI، مدل ANFIS-WCA تا ۱۱ درصد در مقایسه با مدل ANFIS-ANN و ۲۰ درصد در مقایسه با مدل ANFIS-GOA بهبود را نشان می‌دهد. دقت بالای مدل ANFIS-WCA در مقایسه با سایر مدل‌های هیبریدی نشان‌دهنده عملکرد الگوریتم چرخه‌ی آب برای فرار از بهینه محلی در ترکیب با مدل ANFIS-WCA پیچیدگی دبی ورودی است، که قادر کرده این الگوریتم به ابزاری قدرتمند برای تخمین دبی ورودی سد سفیدرود تبدیل شود.

کلمات کلیدی: الگوریتم فراابتکاری، الگوریتم چرخه‌ی آب، سد سفیدرود، دبی ورودی، سیستم استنتاج فازی- عصبی- تطبیقی،

## مقدمه

مخازن و سدهای ذخیره آب نقشی کلیدی در توسعه اقتصاد و برطرف نمودن نیازهای آبی در کشور دارند [۱]. در برنامه‌ریزی‌های مدیریتی منابع آبی، پیش‌بینی شرایط آینده به منظور تخصیص بهینه منابع آب به بخش‌های مختلف از قبیل شرب، کشاورزی و غیره ضروری است. معمولاً در سیستم منابع آب نیاز به خش‌های مختلف از قبیل کشاورزی، شرب و غیره تغییرات عمده‌ای ندارند و به آسانی قابل پیش‌بینی است ولی پیش‌بینی مقادیر جریان ورودی به سیستم منابع آب در روزهای آینده بسیار مهم است. جریان رودخانه به متغیرهای مختلف هواشناسی، هیدرولیکی، خاک‌شناسی و مؤلفه‌های توسعه جوامع انسانی بستگی دارد و در موارد گوناگون اساساً تعریف دقیق و کاملی از آورد و فیزیک جریان یک رودخانه وجود ندارد، بنابراین با وجود عدم قطعیت‌های فراوان و نیاز به اطلاعات وسیع، تخمین آورد یک رودخانه توسط مدل‌های هیدرولیکی و هیدرولوژیکی را سخت و غیرممکن می‌کند. مدل‌های مختلف هوشمند با توانایی بالا در مدل‌سازی پدیده‌های پیچیده و غیرخطی کاربرد فراوانی دارند و می‌توانند با ارائه الگوی مناسب به عنوان گزینه‌ی مناسب برای حل مشکل ذکر شده، به پیش‌بینی جریان رودخانه‌ها بپردازنند.

پیش‌بینی‌های جریان ورودی به مخازن سدها در بازه‌های زمانی کوتاه مدت و بلندمدت، برای بهینه‌سازی مصرف آب و برنامه‌ریزی در توسعه منابع آب انجام می‌شود [۲]. اکثر مدل‌های استفاده شده برای پیش‌بینی سری‌های زمانی در زمینه منابع آب، بر اساس وجود رابطه خطی بین متغیرها مانند مدل‌های خود همبسته و خود همبسته میانگین متحرک توسعه یافته است. به دلیل پیچیده و

غیرخطی بودن جریان ورودی از طریق رودخانه‌های منتهی به آن‌ها، مدل‌های خطی کارایی چندانی نداشته و به کارگیری مدل‌های غیرخطی در این زمینه بسیار مفیدتر خواهد بود. در سال‌های اخیر پیشرفت‌های فراوانی در زمینه مدل‌های هوشمند و محاسبات نرم انجام گرفته است. از میان روش‌های هوش مصنوعی به شبکه عصبی و سیستم‌های فازی توجه بیشتری شده است. با توجه به گسترش کاربرد الگوریتم‌های فرا ابتکاری و داده کاوی استفاده از این دو مدل به تنها‌یی مناسب نخواهد بود. همچنین در موارد متعدد ترکیب سیستم استنتاج عصبی-فازی با الگوریتم‌های داده کاوی جواب‌های دقیق‌تری نسبت به مدل آموزش کلاسیک آن داده است [۳]. الگوریتم‌های بهینه‌سازی فرا ابتکاری در کاربردهای مهندسی و بهینه‌سازی در حال فراگیر و عمومی شدن هستند زیرا مفاهیم نسبتاً ساده‌ای داشته و پیاده‌سازی آن‌ها راحت بوده و نیازی به اطلاعات مشتق تابع هدف ندارند و می‌توانند بهینه‌های محلی را پشت سر گذاشته و در طیف گسترده‌ای از مسائل گوناگون استفاده شوند. الگوریتم‌های تکاملی زیرمجموعه‌ای از محاسبات تکاملی بوده و در شاخه هوش مصنوعی قرار می‌گیرند. الگوریتم‌های شامل الگوریتم‌هایی برای جستجو هستند که در آن‌ها عمل جستجو از چندین نقطه در فضای جواب صورت می‌گیرد. الگوریتم‌های فرا ابتکاری الهام گرفته‌شده از طبیعت مسائل بهینه‌سازی را با تقلید از پدیده‌های زیستی یا فیزیکی حل می‌کنند.

در مورد پیش‌بینی دبی رودخانه‌ها مطالعاتی صورت گرفته است از جمله می‌توان موارد ذیل را نام برد. امری و همکاران [۴] به قابلیت توسعه مدل شبکه‌های عصبی مصنوعی در پیش‌بینی دبی جریان رودخانه پرداختند و به این نتیجه رسیدند که طول دوره آماری داده‌ها عامل موثری بر عملکرد مدل است. فاشی و همکاران [۵] برای مدل‌سازی هوشمند سری زمانی آورد ماهانه ورودی به سد وحدت سندج از مدل شبکه عصبی استاتیکی و دینامیکی، استفاده کردند. نتایج نشان داد که مدل شبکه عصبی دینامیکی سری زمانی با دقت بالاتری نسبت به مدل استاتیکی، مقدار آورد ماهانه را پیش‌بینی می‌کند. کیسی و سیکیزو-گلو [۶] عملکرد انواع مختلف از شبکه‌های عصبی مصنوعی شامل شبکه‌های پیش‌خور با الگوریتم پس انتشار خطا، شبکه‌های پایه شعاعی و شبکه‌های رگرسیونی تعیین‌یافته را در پیش‌بینی جریان دو رودخانه مختلف از ترکیه بررسی کردند. نتایج نشان از عملکرد بهتر مدل پایه شعاعی در مقایسه با سایر مدل‌ها بود.

سامانه استنتاج فازی عصبی تطبیقی نیز از جمله روش‌هایی است که در تحلیل پدیده‌های غیرخطی و بررسی رابطه بین ورودی و خروجی از جمله مباحث مشابه با این تحقیق به کاربرد شده است. چنگ و چن [۷] از مدل فازی عصبی و از داده‌های بارش و جریان به منظور پیش‌بینی جریان رودخانه داچا در مرکز تایلند استفاده کردند. نتایج از عملکرد بهتر روش فازی عصبی در مقایسه با مدل‌های سری زمانی همکاران [۸] از سیستم استنتاج فازی عصبی تطبیقی در مدل‌سازی سری زمانی هیدرولوژیکی برای پیش‌بینی جریان آب رودخانه‌ها در هندوستان استفاده کردند. مقایسه نتایج نشان داد که مدل فازی عصبی به لحاظ سرعت محاسباتی، خطای پیش‌بینی، عملکرد مناسب تری نسبت به شبکه‌های عصبی مصنوعی و مدل‌های مربوط به سری‌های زمانی دارد. همچنین نتایج نشان داد که مدل فازی - عصبی، نه تنها از کارایی مشابه و بلکه ساختار آسان تری نسبت به شبکه‌های عصبی مصنوعی برخوردار است. ثانی خانی و کیسی [۹] از دو روش مختلف فازی عصبی شامل افزار شبکه و دسته‌بندی تفریقی و از مقادیر جریان‌های پیشین جهت پیش‌بینی میزان جریان رودخانه در دو ایستگاه هیدرومتری واقع در کشور ترکیه استفاده کردند و نتایج نشان داد که هر دو روش در پیش‌بینی میزان جریان از دقت قابل قبولی برخوردارند. لوهانی و همکاران [۱۰] در پیش‌بینی جریان - ماهانه ورودی به مخزنی در هندوستان از دو مدل فازی عصبی و خود همبسته استفاده کردند. نتایج نشان داد که مدل فازی - عصبی در مقایسه با مدل‌های عصبی و خود همبسته به ازای کلیه الگوهای مورد استفاده به عنوان ورودی مدل، عملکرد بهتری دارد.

چند مورد از مطالعاتی که در ایران در مورد رودخانه انجام شده است در ادامه ذکر شده است. امامی و همکاران [۱۱] از سه الگوریتم فرا ابتکاری بهینه‌سازی شامل الگوریتم ژنتیک ، الگوریتم گرگ خاکستری و الگوریتم انتخابات جهت پیش‌بینی بار رسوبی معلق رودخانه‌ها استفاده شده است. نتایج به دست آمده نشان می‌دهد الگوریتم گرگ خاکستری در مقایسه با سایر الگوریتم‌های به کار گرفته شده، از کارایی بالاتری برخوردار است. امامی و پارسا [۱۲] به مقایسه عملکرد الگوریتم‌های فرا ابتکاری با منحنی سنجه رسوب به صورت مطالعه موردي در رودخانه‌ی زرینه‌رود پرداختند. نتایج به دست آمده نشان داد که الگوریتم گرگ در مقایسه با سایر الگوریتم‌های به کار گرفته شده، از کارایی بالاتری برخوردار بوده که این امر می‌تواند به برنامه‌ریزی صحیح و جامع برای طراحی و ساخت سازه‌های آبی منجر شود. وفایی نژاد و همکاران [۱۳] به بهینه‌سازی ضرایب معادله منحنی سنجه رسوب در برآورد دبی رسوب

با استفاده از الگوریتم ازدحام ذرات و الگوریتم تبرید به صورت مطالعه موردی ایستگاه شهر بیجار پرداختند. نتایج به دست آمده نشان‌دهنده این واقعیت است که مدل الگوریتم بهینه‌سازی ازدحام ذرات دارای جواب‌های بهتری نسبت به الگوریتم تبرید دارد. همان طور که مشاهده شد بیشتر مطالعات در مورد منحنی سنجه رسوب رودخانه‌ها است و مطالعه‌ای در مورد دبی رودخانه‌ها با ترکیب الگوریتم‌های فرا ابتکاری با ANFIS انجام نشده است.

از آن جا که ساختار سیستم استنتاج عصبی - فازی تطبیقی بر اساس یک شبکه پیشرو است، در بیشتر مواقع به مسائل ایستاده محدود می‌شود، برای غلبه بر این مشکل از ترکیب پنج الگوریتم فرا ابتکاری شامل چرخه‌ی آب (WCA)، گرگ خاکستری (GOW)، وال (WOA)، الگوریتم شبکه عصبی (GOA) و ملخ (NNA) برای آموزش سیستم عصبی - فازی و بهروزرسانی پارامترها و ساختار آن به منظور پیش‌بینی دبی ورودی روزانه سد مخزنی سفیدرود استفاده شده است. برخلاف تحقیقات قبلی که از داده‌های رودخانه برای پیش‌بینی استفاده شده است، در این تحقیق از داده‌های خود سد برای این منظور استفاده گردید و در نهایت بهترین مدل‌ها با توجه به شاخص‌های آماری برای پیش‌بینی دبی ورودی روزانه سد مخزنی سفیدرود، توسعه داده شده است.

#### سد مخزنی سفیدرود

سد مخزنی سفیدرود بر روی رودخانه سفیدرود و در پایین دست محل تلاقی دو رودخانه قزل اوزن و شاهرود (شکل ۱)، در ۷۵ کیلومتری جنوب شهر رشت و در مجاورت شهر منجیل احداث گردیده است. در این مطالعه از آورد یا دبی ورودی تجمیعی هر دو رودخانه مذکور (کل آورد رودخانه سفیدرود) استفاده شده است. این دو رودخانه تأمین کننده آب ورودی به سد سفیدرود می‌باشند. هدف اصلی سد سفیدرود تنظیم جریان‌های ورودی به رودخانه سفیدرود جهت آبیاری ۱۸۹۸۳۲ هکتار اراضی شالی‌کاری داشت گیلان و فومنات واقع در پایین دست و اهداف فرعی آن کنترل سیلاب، تولید انرژی برق آبی با ظرفیت اسمی ۸۷,۵ مگاوات ساعت، تأمین آب شرب و صنایع شهرهای مرکزی و شرق نزدیک گیلان، تأمین نیازهای شیلات و آبزی پروری و دامپروری سفیدرود و همچنین تأمین نیاز محیط‌زیست است [۱۴].



شکل ۱: موقعیت جغرافیایی و حوضه آبریز سد سفیدرود.

Figure 1: Geographical location and Sefidroud dam catchment area.

## الگوریتم بهینه‌سازی چرخه آب (WCA)

مانند همه الگوریتم‌های فرا ابتکاری، با جمعیت اولیه (اصطلاح قطرات باران)، الگوریتم چرخه آب شروع به کار می‌کند. نخست، فرض می‌شود که باران یا دیگر انواع بارش وجود دارند. بهترین قطره‌ی آب یا بهترین فرد به عنوان دریا انتخاب می‌شود. در ادامه، برخی از قطرات باران خوب به عنوان رود و مابقی قطرات باران به عنوان نهرهایی که به سمت رودخانه‌ها و دریا جریان دارند، در نظر گرفته می‌شوند (Eskandar et al., 2012).

چنین آرایه‌ای در الگوریتم GA و PSO اصطلاحاً به ترتیب کروموزوم و موقعیت ذرات را شامل می‌شوند. در مسائل بهینه‌سازی چند بعدی، یک قطره باران، آرایه‌ای به شکل  $N_{Var}^*$  را تشکیل و با رابطه ۱ تعیین می‌گردد:

$$Raindrop = [X_1, X_2, X_3, \dots, X_{N_{Var}}] \quad (1)$$

در رابطه بالا،  $X_1$  تا  $X_{N_{Var}}$  متغیرهای تصمیم هستند. نخست، یک نمونه از ماتریس قطرات باران به اندازه‌ی  $N_{Pop} * N_{Var}$  و به طور تصادفی ایجاد می‌گردد:

$$Population\ Raindrop = \begin{bmatrix} Raindrop1 \\ Raindrop2 \\ \vdots \\ \vdots \\ Raindrop_{N_{pop}} \end{bmatrix} = \begin{bmatrix} X_1^1 & X_2^1 & \dots & X_{N_{Var}}^1 \\ \vdots & \vdots & \dots & \vdots \\ X_1^{N_{pop}} & X_2^{N_{pop}} & \dots & X_{N_{Var}}^{N_{pop}} \end{bmatrix} \quad (2)$$

که  $N_{pop}$  و  $N_{Var}$  به ترتیب تعداد قطرات باران (جمعیت اولیه) و تعداد متغیرهای طراحی است. مقادیر تابع هدف (C) از رابطه‌ی زیر حاصل می‌شود:

$$C_i = Cost_i = f(X_1, X_2, X_3, \dots, X_{N_{Var}}), \quad i=1, 2, 3, \dots, N_{pop} \quad (3)$$

در رابطه بالا،  $C_i$  مقدار تابع هدف هر قطره است. در اولین گام، به تعداد  $N_{pop}$  قطره‌ی باران ایجاد می‌شود و سپس به تعداد  $N_{SR}$  از بهترین قطرات (حداقل ارزش) به عنوان دریا و رود برگزیده می‌شوند. در مسائل مربوط به کمینه‌سازی، قطره‌ی باران با حداقل مقدار به عنوان دریا در نظر گرفته می‌شوند.  $N_{SR}$  مجموع تعداد رودها و یک دریا از رابطه‌ی ۴ و مابقی جمعیت (نهرهایی که ممکن است به رودخانه‌ها و یا به طور مستقیم به دریا برسند) با استفاده از رابطه‌ی ۵ محاسبه می‌گردد.

$$N_{SR} = \text{Number of Rivers} + 1 \quad (4)$$

$$N_{Raindrop} = N_{pop} - N_{SR} \quad (5)$$

برای تعیین یا اختصاص قطرات باران به رودها و دریا، بسته به شدت جریان از رابطه‌ی ذیل استفاده می‌شود:

$$NS_n = round \left( \frac{Cost_n}{\sum_{i=1}^{N_{SR}} Cost_i} \right) \times N_{Var}, \quad n = 1, 2, 3, \dots, N_{SR} \quad (6)$$

که در آن،  $NS_n$  نهرهایی هستند که به رودهای خاص و یا دریا ریخته می‌شوند. یک نهر جریان تا رسیدن به رودخانه در امتداد خط اتصال بین آن‌ها با استفاده از یک فاصله که به طور تصادفی انتخاب شده، جریان می‌یابد که این فاصله با رابطه‌ی زیر مشخص می‌شود.

$$X \in (0, c \times d), \quad c > 1 \quad (7)$$

که در آن  $c$  مقادیری بین یک و دو (نزدیک به دو) دارد و بهترین مقدار برای  $C$  عدد ۲ است.  $d$  در رابطه بالا، فاصله‌ی فعلی بین نهر و رودخانه است. مقدار  $X$  در رابطه بالا متناظر با یک عدد تصادفی توزیع شده (یکنواخت و یا ممکن است هر توزیع مناسب دیگر) بین صفر و  $(c * d)$  است. موقعیت جدید نهرها و رودخانه‌ها را می‌توان از روابط زیر به دست آورد:

$$X_{Stream}^{i+1} = X_{Stream}^i + rand \times C \times (X_{River}^i - X_{Stream}^i) \quad (8)$$

$$X_{River}^{i+1} = X_{River}^i + \text{rand} \times C \times (X_{Sea}^i - X_{River}^i) \quad (9)$$

در این روابط،  $\text{rand}$  یک عدد تصادفی یکنواخت توزیع شده بین صفر و یک است. اگر راه حل ارائه شده به وسیله‌ی یک نهر، بهتر از رودخانه متصل به آن باشد، موقعیت رودخانه و نهر باهم عوض می‌شود. این جایه‌جایی می‌تواند برای رودخانه‌ها و دریا نیز اتفاق بیفتد. یکی از مهم‌ترین عواملی که از همگرایی سریع الگوریتم (همگرایی نابالغ)، و به دام افتادن در بهینه‌های محلی جلوگیری می‌کند، فرآیند تبخیر است. این فرآیند باعث خواهد شد که آب دریا با تبخیر به صورت جریان رودها و یا نهرها دوباره به دریا بریزد. رابطه ۱۰ نشان می‌دهد که آیا رود به دریا می‌ریزد یا نه.

$$\text{if } |X_{Sea}^i - X_{River}^i| < d_{\max}, i = 1, 2, 3, \dots, N_{SR} - 1 \\ \text{فرآیند بارش و تبخیر} \rightarrow \\ \text{پایان} \rightarrow \quad (10)$$

که در آن،  $d_{\max}$  عدد کوچکی (نزدیک به صفر) است، بنابراین، اگر فاصله‌ی بین رود و دریا از  $d_{\max}$  کمتر باشد، بیانگر آن است که رود به دریا رسیده است. در این وضعیت، فرآیند تبخیر اثر می‌کند، و همانند طبیعت، بعد از تبخیر کافی، باران (بارش) شروع خواهد شد  $d_{\max}$  شدت جستجو را در نزدیکی دریا (راه حل بهینه) تنظیم می‌کند. مقدار  $d_{\max}$  با توجه به رابطه‌ی زیر در هر مرحله کاهش می‌یابد:

$$d_{\max}^{i+1} = d_{\max}^i - \frac{d_{\max}^i}{\text{max iteration}} \quad (11)$$

پس از برآورده شدن فرآیند تبخیر، فرآیند بارندگی اعمال می‌شود. در فرآیند بارندگی، قطرات باران جدید نهرها را در مکان‌های مختلف تشکیل می‌دهند (مانند عملگر جهش در الگوریتم GA). برای تعیین مکان جدید نهرهای تازه شکل‌گرفته، از رابطه‌ی زیر استفاده خواهد شد.

$$X_{Stream}^{\text{new}} = LB \times \text{randn} \times (UB - LB) \quad (12)$$

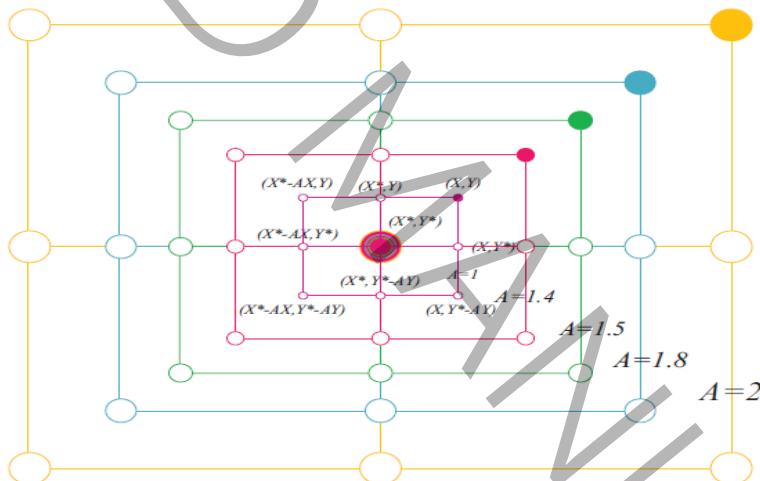
$LB$  و  $UB$  در رابطه بالا، به ترتیب، کران پایین و بالای مسئله هستند. بهترین قطرات باران جدید تشکیل شده به عنوان رود، و بقیه‌ی قطرات باران جدید به عنوان نهرهای جدید، که به سمت رودخانه‌ها در جریان‌اند و یا ممکن است به طور مستقیم به دریا بریزند، در نظر گرفته می‌شوند [۱۵]. در این مطالعه، معیار همگرایی در الگوریتم مذکور، رسیدن به تعداد تکرار برابر ۱۰۰۰ مد نظر قرار گرفته است. در مطالعه حاضر، مدل ANFIS با WCA (که از آن به عنوان ANFIS-WCA ذکر می‌شود) برای شبیه‌سازی دبی ورودی روزانه سد مخزنی سفیدرود ترکیب شده است.

### الگوریتم گرگ خاکستری (GOW)

الگوریتم بهینه‌سازی گرگ خاکستری در گروه الگوریتم‌های هوش جمعی قرار دارد و مانند خیلی از الگوریتم‌های فرا ابتکاری دیگر، الهام گرفته از طبیعت است و اساس آن ساختار سلسله مراتبی است که رفتار اجتماعی گرگ‌های خاکستری را در زمان شکار، مدل‌سازی می‌کند. در پیاده‌سازی این الگوریتم، چهار نوع از گرگ‌های خاکستری، مانند آلفا، بتا، دلتا و امگا برای مدل‌سازی سلسله مراتبی رهبری گرگ‌های خاکستری استفاده شده است که سه گام اصلی برای شکار، شامل: جستجو برای طعمه، محاصره طعمه و حمله به طعمه، اجرا می‌شوند. نتایج حاصل از توابع محک گوناگون، حاکی از عملکرد مطلوب این الگوریتم در مقایسه با الگوریتم‌های مشابه است [۱۶]. در مطالعه حاضر، مدل ANFIS با GOW (که از آن به عنوان ANFIS-GOW ذکر می‌شود) برای شبیه‌سازی دبی ورودی روزانه سد مخزنی سفیدرود ترکیب شده است.

الگوریتم بهینه‌سازی فرا ابتکاری نهنگ یا الگوریتم وال یکی از الگوریتم‌های فرا ابتکاری جدید است که توسط آقای میرجلیلی در سال ۲۰۱۶ [۱۷] ارائه شده است. این الگوریتم فرا ابتکاری الهام گرفته از طبیعت است. الگوریتم بهینه‌سازی نهنگ (WOA) که رفتار اجتماعی نهنگ‌های کوهان دار<sup>۱</sup> را تقلید می‌کند از راهبرد شبکه حبابی الهام گرفته شده است. نهنگ‌ها یا وال‌ها موجودات عظیم‌الجثه‌ای هستند. آن‌ها به عنوان بزرگترین پستانداران در جهان محسوب می‌شوند. مراحل عملکرد الگوریتم بهینه‌سازی نهنگ در ادامه آمده است. محاصره طعمه: نهنگ کوهان دار می‌تواند موقعیت طعمه و محدوده آن‌ها را شناسایی کند. از آنجا که موقعیت طراحی بهینه در فضای جستجو از قبل مشخص نیست، الگوریتم WOA فرض می‌کند که بهترین راه حل کاندید فعلی همان طعمه هدف یا نزدیک به بهینه است. روش حمله حبابی (مرحله بهره‌برداری): به منظور مدل کردن ریاضی رفتار حبابی نهنگ‌های کوهان دار دو روش به صورت زیر طراحی شده است:

کاهش مکانیزم محاصره: این رفتار با کاهش مقدار  $a$  به دست می‌آید (شکل ۲). توجه داشته باشید که محدوده نوسان  $A$  نیز با  $a$  کاهش می‌یابد؛ به عبارت دیگر  $A$  یک مقدار تصادفی در بازه  $[a-a, a]$  است که از ۲ تا صفر در حین تکرارهای الگوریتم کاهش می‌یابد. با قرار دادن مقدار تصادفی به بردار  $A$  در بازه  $[1, 2]$ ، موقعیت جدید هر عامل جستجو می‌تواند در هر نقطه‌ای بین موقعیت اصلی عامل جست و موقعیت بهترین عامل فعلی باشد. بروز رسانی مارپیچی موقعیت: این روش ابتدا فاصله بین نهنگ واقع در  $(X, Y)$  و موقعیت طعمه  $(X^*, Y^*)$  را محاسبه می‌کند. سپس یک معادله مارپیچی بین موقعیت نهنگ و طعمه برای تقلید از حرکت مارپیچ نهنگ کوهان دار ایجاد می‌کند.



شکل ۲: سلسله‌مراتب مرحله اکتشاف الگوریتم بهینه‌سازی نهنگ.

**Figure 2: Discovery steps of whale optimization algorithm.**

جستجو برای طعمه (مرحله اکتشاف): همین رویکرد بر اساس تنوع بردار  $A$  را می‌توان برای جستجوی طعمه استفاده کرد (اکتشاف). در حقیقت نهنگ‌های کوهان دار به صورت تصادفی با توجه به موقعیت هر یک از یکدیگر جستجو را انجام می‌دهند. بنابراین ما از  $A$  با یک مقدار تصادفی بزرگتر از ۱ یا کوچکتر از ۱- برای مجبور کردن عامل جستجو برای حرکت از یک نهنگ مرجع استفاده می‌کنیم. در مقابل با مرحله بهره‌برداری، ما موقعیت عامل جستجو را در مرحله اکتشاف بر حسب انتخاب تصادفی یک عامل جستجوی بهترین عامل جستجو تا کنون به روزرسانی می‌کنیم. این مکانیزم و فرض  $1 > |A| > 1$  باعث اکتشاف می‌شود و به الگوریتم WOA اجازه می‌دهد تا جستجوی عمومی و کلی را انجام دهد. در مطالعه حاضر، مدل ANFIS با WOA (که از آن به عنوان ANFIS-WOA ذکر می‌شود) برای شبیه‌سازی دبی ورودی روزانه سد مخزنی سفیدرود ترکیب شده است.

<sup>1</sup> humpback

## الگوریتم فرا ابتکاری شبکه عصبی (NNA)

الگوریتم فرا ابتکاری شبکه عصبی (NNA) توسعه و گسترش یافت. این الگوریتم بهینه‌سازی با الهام از سیستم‌های عصبی بیولوژیکی و شبکه‌های عصبی مصنوعی (ANNs) برای حل مشکلات پیچیده بهینه‌سازی پیشنهاد شده است. روش پیشنهادی که به عنوان الگوریتم شبکه عصبی (NNA) نامیده می‌شود، بر اساس ساختار منحصر به فرد مدل‌های شبکه عصبی مصنوعی (ANN) توسعه یافته است. این الگوریتم از ساختار پیچیده شبکه عصبی و عملگرهای آن به منظور ایجاد راه حل‌های جدید سود می‌برد. داشتن یک الگوریتم بدون هیچ گونه تلاشی برای تنظیم دقیق پارامترهای اولیه و آماری در مدل می‌تواند این الگوریتم را نسبت به سایر بهینه سازهای گزارش شده تمایز کند. این الگوریتم یک روش تطبیقی بدون نظرارت برای حل مشکلات بهینه‌سازی است. بدون نظرارت در آن به این معنی است که هیچ سرنخ و اطلاعاتی در مورد فرآیند بهینه وجود ندارد و راه حل‌ها با یادگیری از محیط بهروز شده است. این الگوریتم یک روش بهینه‌سازی پرسپترون تک لایه است که دارای بازخورد خود است. در مطالعه حاضر، مدل ANFIS با NNA (که از آن به عنوان ANFIS-NNA ذکر می‌شود) برای شبیه‌سازی دبی ورودی روزانه سد مخزنی سفیدرود ترکیب شده است.

## الگوریتم ملخ (GOA)

یکی از جدیدترین الگوریتم‌های فرا ابتکاری که در سال ۲۰۱۷ معرفی شده، الگوریتم بهینه‌سازی ملخ (GOA) است. ملخ یک الگوریتم فرا ابتکاری الهام گرفته شده از طبیعت است که رفتار ملخ‌ها در طبیعت و حرکت گروهی آن‌ها را به سمت منبع غذایی تقلید نموده و آن را شبیه‌سازی می‌کند. اگرچه ملخ‌ها معمولاً در طبیعت به صورت انفرادی دیده می‌شوند، آن‌ها در یکی از بزرگ‌ترین گروه‌های موجودات قرار دارند. مدل ریاضی این الگوریتم تقليدی از رفتار دسته ملخ‌ها در طبیعت برای حل مسائل بهینه‌سازی است. نتایج شبیه‌سازی‌ها در این الگوریتم نشان می‌دهد که الگوریتم ملخ نتایج بهتری در مقایسه با الگوریتم‌های شناخته شده اخیر داشته است. بررسی شبیه‌سازی این الگوریتم روی مسائل واقعی نیز نشان داده است که الگوریتم ملخ قادر به حل مسائل واقعی با فضای ناشناخته است. در الگوریتم ملخ تعدادی از ملخ‌ها در فضای جست و جو قرار دارند. مقدار برآزندگی هر ملخ با استفاده از تابع برآش به دست می‌آید. مکان بعدی هر ملخ بر مبنای مکان فعلی ملخ، مکان هدف و مکان همه ملخ‌های دیگر تعریف می‌شود. در حقیقت وضعیت همه ملخ‌ها برای تعریف مکان جدید هر ملخ مد نظر قرار می‌گیرد که این نکته باعث تفاوت الگوریتم ملخ و ازدحام ذرات شده است [۱۹]. در مطالعه حاضر، مدل ANFIS با GOA (که از آن به عنوان ANFIS-GOA ذکر می‌شود) برای شبیه‌سازی دبی ورودی روزانه سد مخزنی سفیدرود ترکیب شده است.

## سیستم استنتاج فازی عصبی تطبیقی (ANFIS)

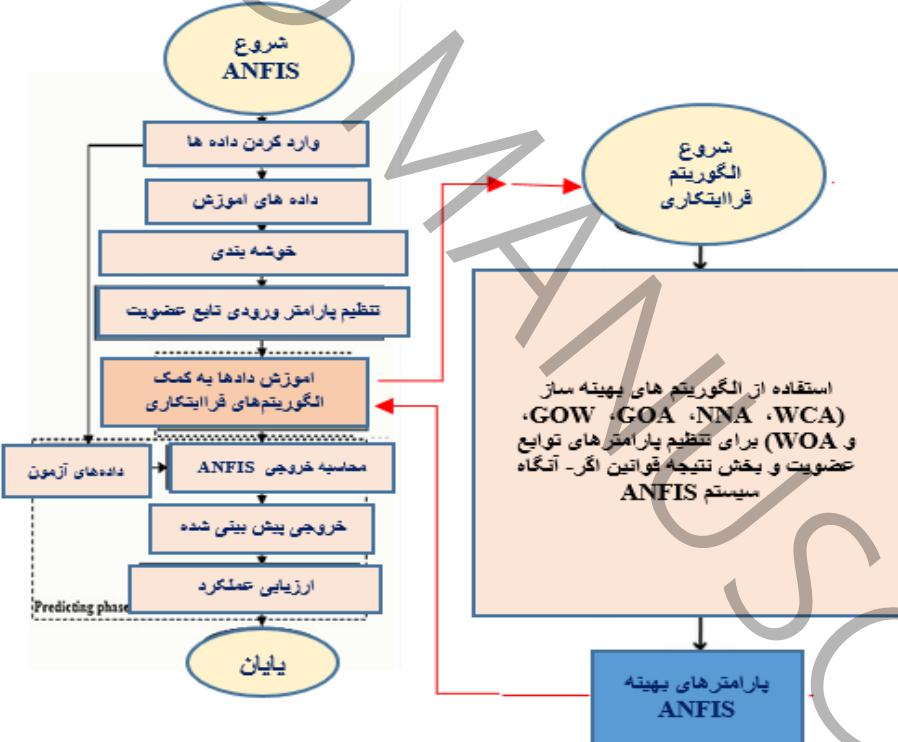
جانگ [۲۰] ANFIS را با در نظر گرفتن توانایی‌های نظریه فازی که مبتنی بر منطق فازی و رویکرد شبکه‌های الکترونیکی مصنوعی است، معرفی کرد. ساختار شبکه ANFIS از ترکیب شبکه‌های عصبی و سیستم فازی تشکیل شده است. ساختار مناسب با توجه به داده‌های ورودی، نوع توابع عضویت ورودی و خروجی، قوانین فازی و تعداد توابع عضویت انتخاب می‌شود [۲۱].

## ترکیب ANFIS با الگوریتم فرا ابتکاری

غالباً از رویکردهای کلاسیک، نظریه گرادیان نزولی و پس انتشار برای طراحی و آموزشی سیستم استنتاج عصبی فازی یا (ANFIS) استفاده می‌شود؛ اما در این مطالعه، از الگوریتم‌های فرا ابتکاری در طراحی بهینه سیستم‌های فازی نوع تاکاگی-سوگو-کانگ (TSK) استفاده شده است. ساختار سیستم استنتاج عصبی فازی بر پایه یک سیستم استنباط فازی است که پارامترهای بخش‌های فرض و نتیجه قوانین اگر-آنگاه فازی توسط یک مدل شبکه عصبی تنظیم می‌شود. از آنجا که الگوریتم یادگیری شبکه عصبی مبتنی بر استفاده از روش‌های بهینه‌سازی بر مبنای شیب توابع است که امکان دارد جواب نهایی الگوریتم یادگیری و پارامترهای تنظیم شده در نقاط بهینه موضعی محبوس شوند، بنابراین استفاده از روش‌های جستجو یا بهینه‌سازی فرا ابتکاری برای برطرف نمودن این مشکل،

قابل بررسی است. در واقع در این مطالعه، با ترکیب الگوریتم‌های تکاملی و فرا ابتکاری، با سیستم‌های عصبی فازی، سعی شده است تنظیم مقادیر بهینه برای پارامترهای این سیستم، به الگوریتم‌های بهینه‌سازی بهینه‌سازی هوشمند و آگذار شود. مراحل توسعه این مدل در شبیه‌سازی دی ورودی سد بر مبنای سیستم ترکیبی عصبی فازی تطبیقی و پنج الگوریتم بهینه‌سازی فرا ابتکاری به طور خلاصه به شرح زیر است:

۱. ورودی‌ها و خروجی سیستم‌های توسعه داده شده تعیین شد.
۲. نرمال سازی و ساخت مجموعه داده‌های مربوط به بخش آموزش و آزمون برای مدل ترکیبی (در توسعه تمامی مدل‌ها از ۷۰٪ داده‌ها به طور تصادفی برای آموزش و ۳۰٪ باقیمانده برای آزمون استفاده شده است).
۳. با استفاده از متغیرهای ورودی و یک متغیر خروجی یک سیستم فازی پایه ایجاد شد.
۴. کلیه پارامترهای توابع عضویت مربوط به ورودی‌ها و خروجی‌های سیستم فازی پایه تعیین شد.
۵. تنظیم پارامترهای توابع عضویت و بخش نتیجه قوانین اگر-آنگاه سیستم فازی استنتاجی سیستم فازی توسط الگوریتم بهینه‌سازی فرا ابتکاری.
۶. برگرداندن سیستم فازی دارای بهترین مقادیر پارامترهای تنظیم به عنوان نتیجه نهایی یک سیستم عصبی فازی تطبیقی بهینه
۷. مقایسه عملکرد مدل‌های ترکیبی مختلف توسعه داده شده با استفاده از شاخص‌های آماری و انتخاب بهترین مدل در این تحقیق کدهای مربوط به الگوریتم‌های بهینه‌ساز با کد مربوط به مدل ANFIS در محیط متلب ۲۰۱۴ باهم ترکیب شده و آموزش ANFIS با این الگوریتم‌ها انجام شده است. شکل ۳ نحوه ترکیب مدل ANFIS با الگوریتم‌های بهینه‌ساز مورد مطالعه را نشان می‌دهد.



شکل ۳: فلوچارت الگوریتم‌های فرا ابتکاری ترکیب شده با ANFIS

Figure 3: Flowchart of meta-heuristic algorithms combined with ANFIS.

شاخص‌های ارزیابی

در این مطالعه برای ارزیابی مدل‌ها از چندین شاخص آماری استفاده شده است که در ادامه در مورد آن‌ها توضیحاتی ارائه شده است.

خطای جذر میانگین مربعات (RMSE) و ریشه میانگین مربعات خطای نرمال شده (NRMSE) اطلاعاتی را در مورد عملکرد کوتاه مدت یک مدل با مقایسه نظیر به نظری، تفاوت واقعی بین مقادیر برآورده شده و مشاهده شده را ارائه می دهد [۲۲، ۲۳]. معیار نامناسبی برای خطای متوسط است زیرا تابعی از سه مشخصه از مجموعه خطاهای نسبت به دیگری است [۲۴]. با توجه به این که مقدار RMSE متناسب با واحد اندازه گیری متغیر است، مقایسه مقدار آن بین مدل های ساخته شده برای دو متغیر با واحدهای متفاوت درست نخواهد بود. لذا مقدار RMSE را به دامنه داده های متغیر وابسته تقسیم کرده و آن را RMSE نرمال شده (NRMSE) می نامند. این معیار برای مقایسه مدل های مختلف مناسب خواهد بود. لازم به ذکر است که NRMSE زیر ۱۰ درصد نشان دهنده دقیق بودن مدل، ۱۰-۲۰ درصد مناسب بودن مدل، ۲۰-۳۰ درصد دقت متوسط و بیش از ۳۰ درصد نشانه ضعیف بودن مدل است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{N}} \quad (13)$$

$$NRMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{\frac{N}{O_i}}} \quad (14)$$

#### میانگین خطای مطلق (MAE)

معمولأ برای مقایسه کارایی مدل های پیش بینی شده برای یک سری داده واحد یا چندین سری داده با واحدهای یکسان، MAE بسیار پر کاربرد است زیرا از نظر مفهومی و محاسباتی بسیار ساده است. روش شبیه سازی که MAE را به حداقل می رساند منجر به تخمین میانه خواهد شد، در حالی که به حداقل رساندن RMSE منجر به تخمین مقادیر میانگین می شود. در نتیجه RMSE به رغم دشوارتر بودن در تفسیر به طور گسترده ای مورد استفاده قرار می گیرد [۲۵].

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

#### ضریب تعیین ( $R^2$ )

این ضریب کسری از مقادیر برآورده شده را نشان می دهد که نزدیک ترین مقدار به خط اندازه گیری داده ها هستند. این شاخص خطی بودن را مورد بررسی قرار می دهد و برای افزایش عملکرد مدل ها بسیار مفید است [۲۶، ۲۷].

$$R^2 = \left( \frac{\sum_{i=1}^n (O_i - \bar{O}_i)(E_i - \bar{E}_i)}{\sqrt{\sum_{i=1}^n (O_i - \bar{O}_i)^2} \sum_{i=1}^n (E_i - \bar{E}_i)^2} \right)^2 \quad (16)$$

#### شاخص پراکندگی (SI)

این شاخص بر اساس شاخص RMSE ساخته شده و مانند آن نیز عمل می کند. مزیت این شاخص نسبت به RMSE این است که می توان آن را طبقه بندی کرد دقت کارایی مدل ها با این شاخص توسط [۲۸] بحث شده است. بر اساس این شاخص، مقایسه کیفی عملکرد مدل ها به ۴ قسمت بسیار عالی، خوب، متوسط و ضعیف طبقه بندی می شوند.

$$SI = \frac{RMSE}{\bar{E}} \quad (17)$$

با توجه به [۲۸] مقایسه کیفی عملکرد مدل بر اساس شاخص  $SI$  به شرح زیر است:  
 اگر  $SI < 0.1$ , عملکرد بسیار عالی، اگر  $0.1 \leq SI < 0.2$ , عملکرد خوب، اگر  $0.2 \leq SI < 0.3$ , عملکرد متوسط و اگر  $SI > 0.3$ , عملکرد ضعیف، توصیف می شود.

#### میانگین خطای اربی (MBE)

برای ارزیابی بیش برآش (MBE مثبت) و کم برآش (MBE منفی) مدل‌ها استفاده می‌شود [۲۲].

$$MBE = \frac{1}{n} \sum_{i=1}^n |E_i - O_i| \quad (18)$$

#### خطای ( $T_{stat}$ )

$T_{stat}$ <sup>۱</sup> تابعی از خطاهای اربی میانگین و مریع میانگین خطای است که به طور گسترده استفاده می‌شود. استفاده جدأگانه از این شاخص می‌تواند منجر به انتخاب نادرست بهترین مدل از مجموعه مدل‌های نامزد شود، بنابراین، این شاخص، می‌تواند ارزیابی سریع تر و قابل اعتماد عملکرد مدل‌ها را تکمیل نماید [۲۹].

$$T_{stat} = \sqrt{\frac{(n-1) MBE^2}{RMSE^2 - MBE^2}} \quad (19)$$

#### عدم قطعیت با سطح اطمینان ۹۵٪ ( $U_{95}$ )

فاصله اطمینان نشان‌دهنده عدم قطعیت اثر اندازه بر داده‌ها است. هنگام محاسبه فاصله اطمینان، عرض این فاصله با اندازه نمونه، میزان خطای اندازه‌گیری مطالعه و میزان اطمینان مورد نیاز تعیین می‌شود. بین فاصله اطمینان ۹۵٪ و سطح اهمیت ۵٪ دو طرفه یک رابطه منحصر به فرد وجود دارد [۳۰].

$$U_{95} = 1.96 \sqrt{(SD^2 + RMSE^2)} \quad (20)$$

که در این رابطه SD شاخص انحراف استاندارد، برای نشان دادن انحراف مقادیر برآورد شده از مقادیر مشاهده شده است.

#### شاخص عملکرد جهانی (GPI)

این شاخص از ضرب پنج شاخص آماری به دست می‌آید. GPI مزایای تمام شاخص‌ها یعنی ضریب تعیین ( $R^2$ ), میانگین خطای مطلق (MAE)، شاخص پراکندگی (SI)، عدم قطعیت با ۹۵٪ سطح اطمینان ( $U_{95}$ ) و  $T_{stat}$  را ترکیب می‌کند. این شاخص عملکرد کوتاه مدت و بلندمدت و نیز خطی بودن مدل‌ها را نشان می‌دهد، بنابراین می‌توان از آن برای رتبه‌بندی مدل‌ها استفاده کرد. یک مزیت مهم GPI طبقه‌بندی آسان‌تر و واقع‌بینانه‌تر مدل‌ها کاربردی است. [۲۶].

$$GPI = MBE \times RMSE \times U_{95} \times T_{stat} \times (1 - R^2) \quad (21)$$

در روابط بالا،  $E_i$ ،  $O_i$  و  $\bar{O}_i$  به ترتیب برابر مقادیر دبی ورودی برآورد شده سد، مشاهده شده، میانگین مقادیر دبی ورودی برآورد شده و مشاهده شده و  $n$  تعداد داده‌های مشاهده شده است. در مقایسه عملکرد مدل با شاخص‌های فوق، مدل برتر مدلی است که در آن مقادیر همه شاخص‌ها (به استثنای  $R^2$ ) به صفر و شاخص  $R^2$  به عدد یک میل نماید.

<sup>۱</sup> T-statistic test

چون روش مدل سازی به کمک شبکه عصبی، یک روش داده محور است و درک قبلی از روابط بین متغیرها وجود ندارد، یک تحلیل اولیه روی شرایط داده ها، نرمال سازی و به مقیاس در آوردن متغیرها برای عملکرد بهتر این نوع مدل ها بهتر است انجام گیرد.  
[۳۱] بنابراین با استفاده از رابطه زیر داده ها بین ۰/۹ تا ۰/۱ نرمال شدند.

$$x_n = \left( 0.8 \times \left( \frac{(x - x_{min})}{(x_{max} - x_{min})} \right) \right) + 0.1 \quad (22)$$

مقادیر  $X$ ،  $X_n$  و  $X_{max}$  به ترتیب داده های نرمال شده، داده های اصلی، کمینه داده ها، بیشینه داده ها هستند.

## نتایج و بحث

### آمار توصیفی و آنالیز همبستگی داده های ورودی

با بررسی داده های اندازه گیری شده در سد سفیدرود در طی دوره ۱۵ ساله، حجم مخزن بر حسب میلیون مترمکعب، بارندگی بر حسب میلی متر، تبخیر بر حسب میلیون مترمکعب، تراز متوسط مخزن بر حسب متر، حجم مخزن بر حسب میلیون مترمکعب، مساحت دریاچه بر حسب کیلومترمربع و دما بر حسب درجه سانتی گراد به عنوان ورودی های مدل هوشمند و دبی ورودی سد بر حسب میلیون مترمکعب، به عنوان خروجی مدل هوشمند انتخاب گردید. داده های تحقیق طی یک دوره ۱۵ ساله می باشند. جدول ۱ واحد ها و علامت اختصاری آن ها را در تحقیق نشان می دهد.

آنالیز همبستگی برای تصمیم گیری درباره ورودی های مدل هوشمند از بین متغیرهای بالا و تأخیر زمانی داده ها با استفاده از نرم افزار SPSS نسخه ۲۰ ۱۴ انجام گرفت [۳۲]. در این مطالعه، با استفاده ازتابع همبستگی متقطع انتخاب مقادیر پیشین ویژگی های ورودی که دارای بیشترین همبستگی با دبی ورودی سد در هر روز بود، صورت گرفت. همچنین از تابع خود همبستگی جزئی برای تعیین رابطه مقادیر دبی ورودی سد در هر روز با مقادیر پیشین آن استفاده گردید. به منظور برآورده تأخیرهای زمانی از تابع خود همبستگی، تأخیر (۷ تا ۷-) روز و محدوده اطمینان ۹۵ درصد استفاده شده است (مقادیر منفی، نشان دهنده زمان قبل و مقادیر مثبت، نشان دهنده زمان بعد است). در شکل های ۴ و ۵ زمان بر حسب روز و محور Y نشان دهنده مقادیر همبستگی بین ویژگی ها با دبی ورودی سد (تا ۷ روز) است. نتایج در شکل ۴ با توجه به تابع همبستگی متقطع نشان داد که داده های دبی ورودی سد در هر روز با داده های مساحت، حجم مخزن و تراز مخزن سد در ۷ روز قبل بیشترین همبستگی را دارد. همچنین داده های دبی ورودی سد سفیدرود در هر روز با توجه به تابع خود همبستگی در شکل ۵ با داده های دبی ورودی در یک روز قبل بیشترین همبستگی را دارد. از بقیه ویژگی های انتخاب شده به علت همبستگی پایین با دبی ورودی صرف نظر شده است.

جدول ۱: واحد ها و علامت اختصاری متغیرها.

Table 1: Units and abbreviations of the variables.

متغیر	بارندگی	تبخیر	دبی ورودی	تراز متوسط مخزن	حجم مخزن	مساحت دریاچه	متوسط دما	واحد
علامت اختصاری				MCM	MCM	km <sup>2</sup>	oC	
T	A	RV	RL	QI	E	P		

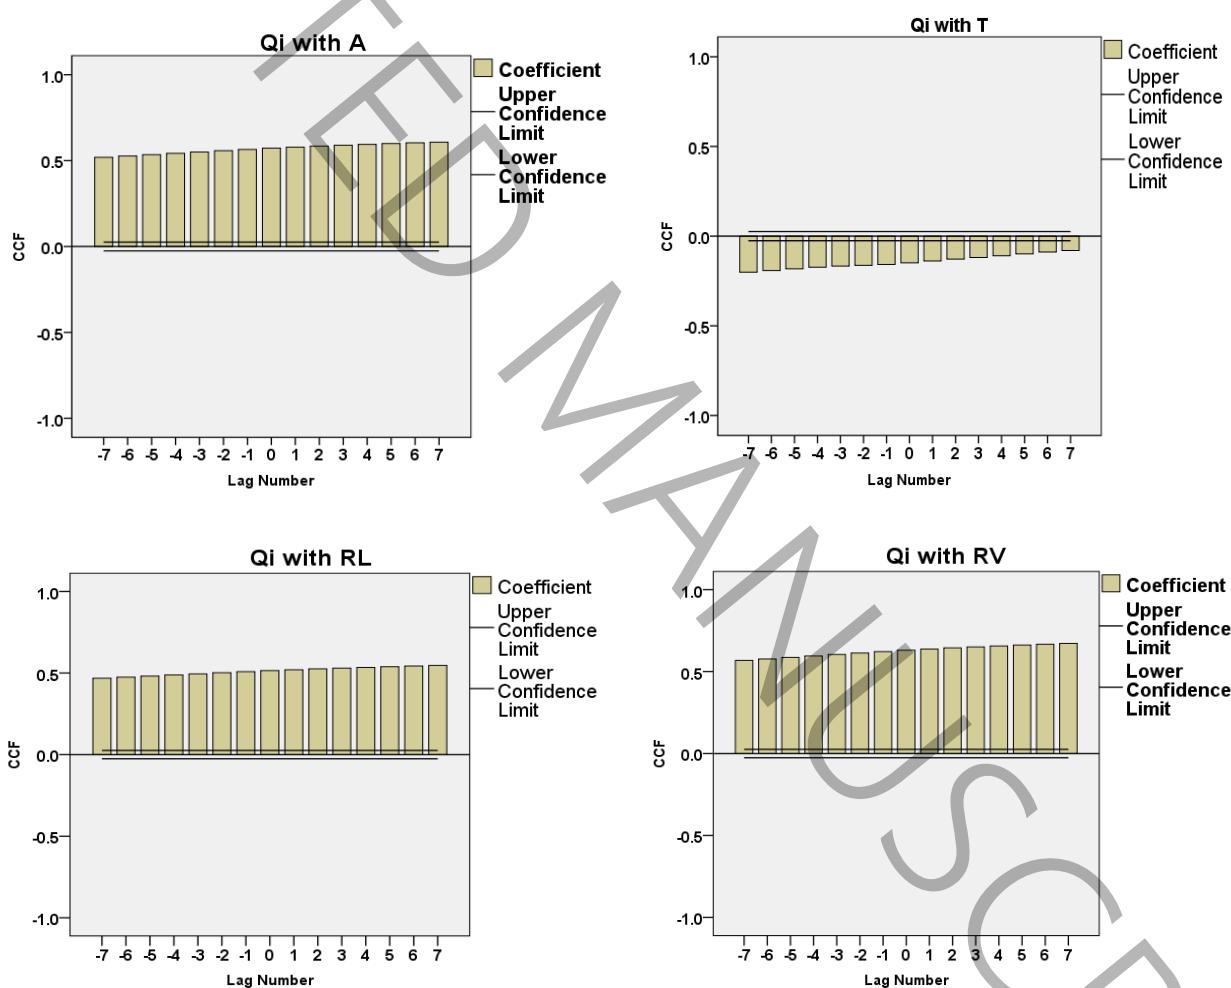
در نهایت چهار ویژگی شامل مساحت، حجم مخزن و تراز مخزن سد در ۷ روز قبل و دبی ورودی در یک روز قبل به عنوان ورودی مدل های ترکیبی انتخاب شدند و به طور تصادفی به دو دسته آموزشی (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم بندی شد. جدول ۲ آمار توصیفی متغیرهای اندازه گیری شده توسط ابزار دقیق سد سفیدرود برای هر یک از ویژگی های ورودی و متغیر خروجی را نشان می دهد. بیشترین ضریب تغییرات (CV)، میانگین در مورد متغیرهایی که به عنوان ورودی مدل هوش مصنوعی به کار رفته اند مربوط به حجم مخزن است. در مورد چولگی همه ویژگی ها دارای چولگی مثبت هستند. چولگی معیاری از تقارن یا عدم تقارن تابع توزیع است. برای یک توزیع کاملاً متقاضان چولگی صفر و برای یک توزیع نامتقارن با کشیدگی به سمت مقادیر بالاتر چولگی مثبت و برای توزیع نامتقارن با کشیدگی به سمت مقادیر کوچکتر مقدار چولگی منفی است. در مورد کشیدگی ویژگی های تراز آب و حجم مخزن دارای کشیدگی منفی و مابقی ویژگی ها دارای کشیدگی مثبت هستند. کشیدگی نشان دهنده ارتفاع

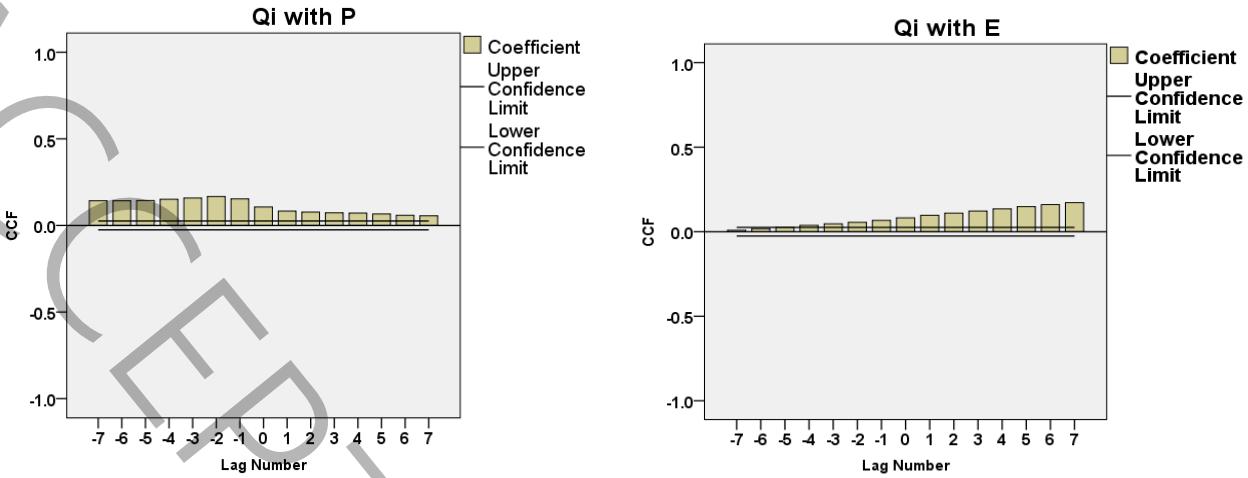
یک توزیع است. کشیدگی مثبت یعنی قله توزیع مورد نظر از توزیع نرمال بالاتر و کشیدگی منفی نشانه پایین تر بودن قله از توزیع نرمال است.

جدول ۲: آمار توصیفی متغیرهای اندازه‌گیری شده توسط ابزار دقیق سد.

Table 2: Descriptive statistics of variables measured by dam accurate instruments.

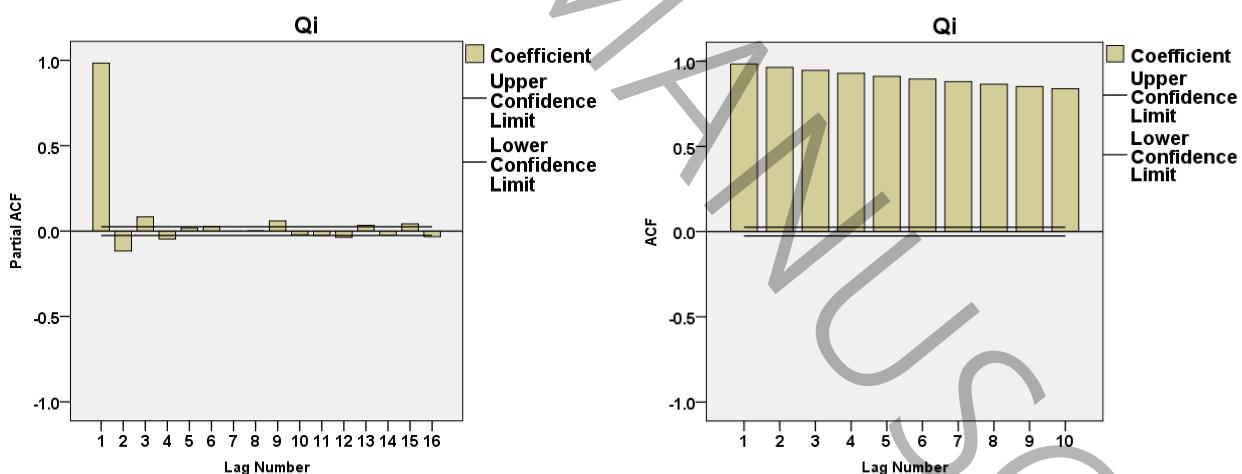
ویژگی‌های ورودی	میانگین	میانه	انحراف معیار	کمینه	بیشینه	ضریب تغییرات	چولگی	کشیدگی
-0/۸۰۷	-0/۰۱۵	۵۲/۱۵	۵۲/۱۵	۰	۱۳۵/۷۴	۲۸/۹	۲۵/۴۵۴۸	A
-۱/۲۱۵۰	۰/۴۱۲۰	۸۸۴/۲۰	۱۱۱۱/۸۷	۲۲۷/۶۷	۲۸۴/۴۹۶۸۱	۵۳۰/۱۹۰۰	۵۹۴/۸۰۰۱	RV
-۱/۳۲۸۰	-۰/۱۱۸۰	۲۶/۲۷	۲۷۷۳/۰۴	۲۴۶/۷۷	۸/۳۵۸۴۱	۲۵۸/۸۲۰۰	۲۵۹/۵۴۸۵	RL
۸/۱۹۱۰	۲/۷۲۰۰	۷۰۵	۷۰۷	۲	۱۰۲/۹۶۵۲۸	۳۳/۵۰۰۰	۷۲/۲۹۷۰	QI





شکل ۴: آنالیز همبستگی متقاطع داده‌های مورد استفاده: همبستگی متقابل بین دبی ورودی و دبی ورودی سد (Qi with P)، همبستگی متقابل بین بارندگی و دبی ورودی سد (Qi with A)، همبستگی متقابل بین تراز آب مخزن و دبی ورودی سد (Qi with RL)، همبستگی متقابل بین تبخیر و دبی ورودی سد (Qi with E). همبستگی متقابل بین دما و دبی ورودی سد (Qi with T). همبستگی متقابل بین حجم مخزن و دبی ورودی سد (Qi with RV).

**Figure 4: Cross-correlation analysis of the used data: cross-correlation between inflow rate and dam inflow rate (Qi with P), cross-correlation between rainfall and dam inflow rate (Qi with A), cross-correlation between reservoir water level and dam inflow rate (Qi with RL), cross-correlation between evaporation and dam inflow rate (Qi with E), cross-correlation between temperature and dam inflow rate (Qi with T), cross-correlation between reservoir volume and dam inflow rate (Qi with RV).**



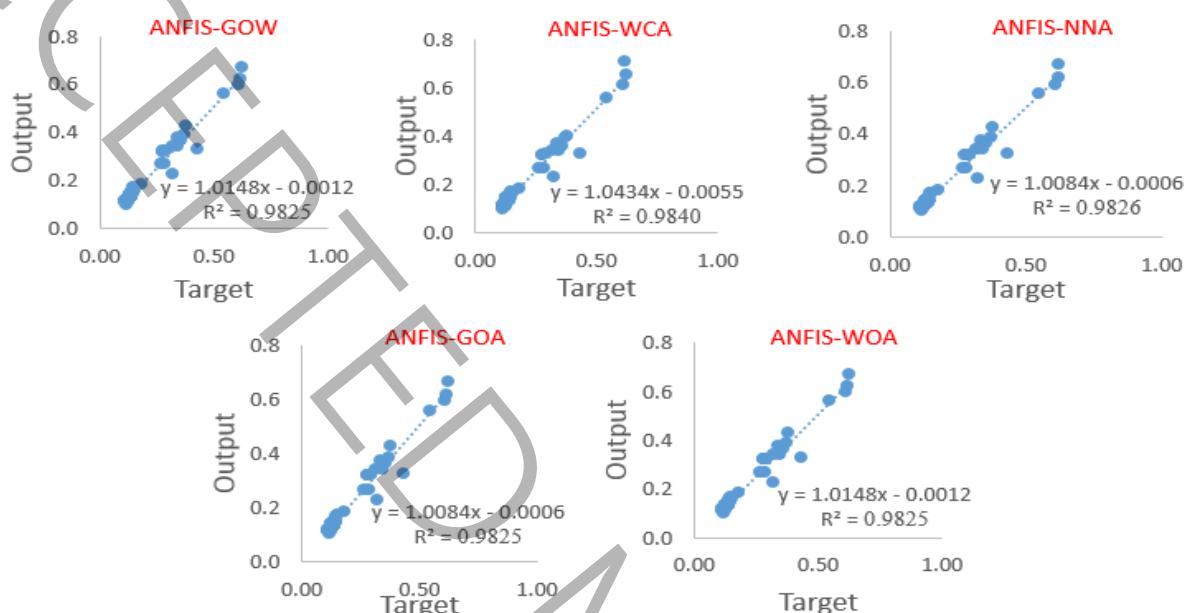
شکل ۵: نمودار خود همبستگی دبی ورودی سد.

**Figure 5: Autocorrelation diagram of dam inflow rate.**

ارزابی مدل‌ها

جدول ۳ نتایج شاخص‌های آماری مدل‌های مختلف هیبریدی را نشان می‌دهد. همه الگوریتم‌های ترکیبی با ANFIS با توجه به  $SI < 0.1$  عملکرد عالی را دارند. مدل GOW - ANFIS با مقادیر  $R^2$ ، MAE، NRMSE و SI به ترتیب برابر با  $0.9829$ ،  $0.0755$  و  $0.04151$  بوده که این عملکرد را ارائه کرده است. شکل ۶ نمودار پراکندگی نتایج الگوریتم‌های مختلف هیبریدی را نشان می‌دهد.

همان طور که در شکل ۶ مشاهده می‌شود، توانایی و دقت عملکرد تمامی الگوریتم‌های هیبریدی فوق در تخمین دبی ورودی بر اساس نمودارهای پراکنده‌گی قابل تأیید است. در تمام مدل‌های ترکیبی، اندازه جمعیت برابر ۱۰۰ و تعداد تکرار ۱۰۰۰ و کران بالا و پایین به ترتیب ۱۰ و ۱۰۰- انتخاب شد که با فرآیند آزمون و خطای شناسایی شدند. نتایج نشان داد که اگر جمعیت و تعداد تکرار کمتر از ۳۰ باشد، عملکرد کاهش می‌یابد.



شکل ۶: دبی ورودی مشاهده شده و پیش‌بینی شده توسط مدل‌های مختلف ترکیبی.

Figure 6: Observed and predicted inflow rate by different hybrid models.

جدول ۳: پارامترهای عملکرد مدل‌های هیبریدی برای تخمین دبی ورودی سد.

Table 3: Performance parameters of different hybrid models to estimate dam inflow rate.

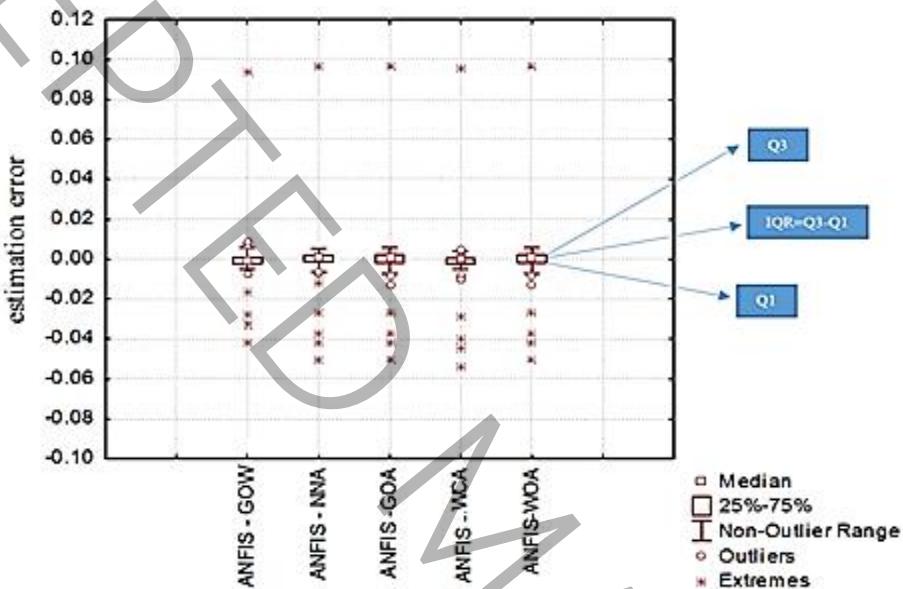
آزمون					آموزش					مدل
NRMSE	MAE	SI	$R^2$	NRMSE	MAE	SI	$R^2$	-		
۰/۰۷۳۶	۰/۴۵۰۰	۰/۰۷۳۶	۰/۹۸۴۰	۰/۰۷۳۹	۰/۵۰۵۰	۰/۰۷۳۹	۰/۹۸۴۲	ANFIS - WCA		
۰/۰۷۴۷	۰/۴۶۵۷	۰/۰۷۴۷	۰/۹۸۲۶	۰/۰۷۵۰	۰/۴۷۶۵	۰/۰۷۴۸	۰/۹۸۳۰	ANFIS - NNA		
۰/۰۷۴۸	۰/۴۷۶۳	۰/۰۷۴۸	۰/۹۸۲۵	۰/۰۷۵۳	۰/۴۷۶۷	۰/۰۷۵۰	۰/۹۸۲۹	ANFIS - GOA		
۰/۰۷۵۵	۰/۴۱۵۱	۰/۰۷۵۵	۰/۹۸۲۹	۰/۰۷۵۶	۰/۴۱۵۲	۰/۰۷۵۸	۰/۹۸۳۰	ANFIS - GOW		
۰/۰۷۴۸	۰/۴۷۶۳	۰/۰۷۴۸	۰/۹۸۲۵	۰/۰۷۵۱	۰/۴۷۶۵	۰/۰۷۴۹	۰/۹۸۲۶	ANFIS-WOA		

مقایسه مدل‌های هیبریدی

مطابق جدول ۲، مدل ANFIS-WCA کمترین مقادیر SI ، MAE و NRMSE به ترتیب برابر ۰/۰۷۳۶ و ۰/۴۵۰۰ و ۰/۰۷۳۶ می‌باشد. مقدار  $R^2$  برابر ۰/۹۸۴۰ را ارائه می‌کند، که نشان‌دهنده برتری آن نسب به سایر مدل‌ها است. بر اساس مقدار SI، مدل ANFIS- WCA عملکرد عالی دارد [۲۸]. نزدیک‌ترین مدل به آن مدل ANFIS - NNA با مقادیر SI ، MAE و NRMSE به ترتیب برابر ۰/۰۷۴۷ و ۰/۴۶۵۷ و ۰/۰۷۴۷ می‌باشد. شکل ۷ همه مدل‌های هیبریدی را در یک نمودار جعبه‌ای در مرحله آزمون، بر اساس توزیع خطای کلی نشان می‌دهد. اختلاف بین مقادیر دبی ورودی سد سفیدرود اندازه‌گیری شده و پیش‌بینی

شده در این جعبه به عنوان مقادیر خطای محاسبه شد. خطاهای مثبت، تخمین‌های کم و خطاهای منفی، تخمین‌های زیاد را نشان می‌دهند. نمودار جعبه‌ای روشی استاندارد برای نشان دادن توزیع خطای بر اساس چهار مقدار است: چارک اول (Q1)، چارک سوم (Q3)، محدوده بین چارک‌ها (IQR) و بخشی در داخل مستطیل که میانه را نشان می‌دهد و هرچه قدر مقدار IQR کمتر باشد دقت مدل بالاتر است [۳۳]. به طور کلی و مطابق شکل ۶، طول جعبه کم (IQR کوچک‌تر) در مدل‌های ANFIS-WCA تمرکز خطای در اطراف صفر را تأیید می‌کند که نشان‌دهنده عملکرد بهتر این مدل هیبریدی نسبت به سایر مدل‌ها است.

علاوه بر این، همان طور که قبل ذکر شد، از سه شاخص عدم قطعیت ( $U_{95}$ )،  $T_{\text{stat}}$  و GPI برای ارزیابی بهتر مدل‌های هیبریدی استفاده شد. توصیه می‌شود که از شاخص  $U_{95}$  برای ارزیابی عمیق نتایج و نشان دادن انحراف نتایج تخمینی از مشاهداتی و همچنین از شاخص GPI برای رتبه‌بندی کلی به عنوان یک تحلیل چندگانه استفاده شود.



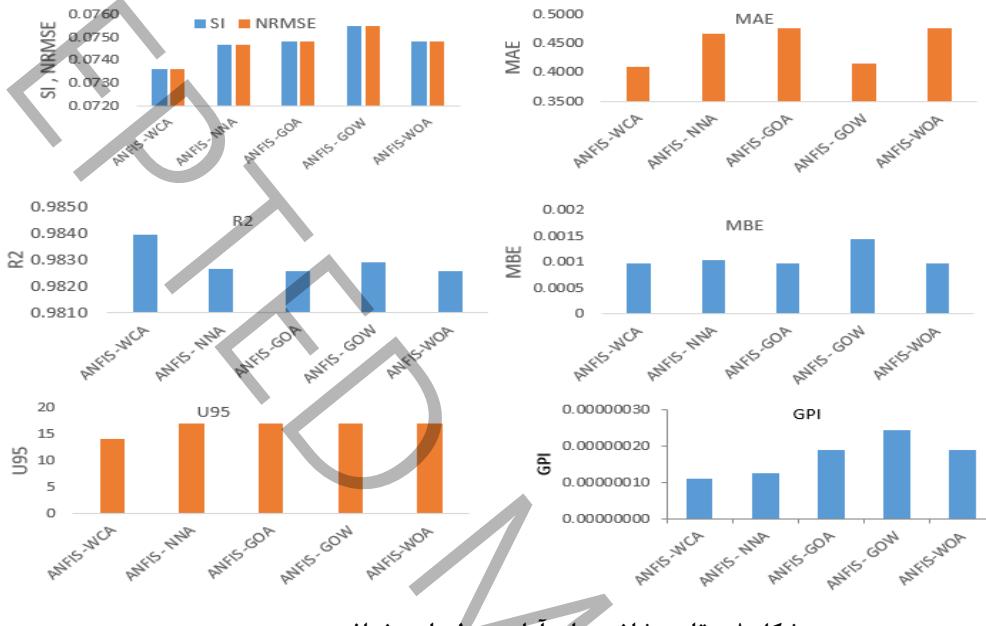
شکل ۷: نمودار جعبه‌ای توزیع خطای تخمین دبی ورودی سد در مرحله آزمون برای همه مدل‌ها، ۲۵٪: چارک پایین خطاهای، ۷۵٪: چارک بالای خطاهای.

**Figure 7: Box diagram of the distribution of the error of dam inflow rate estimation in the test stage for all models, 25%: lower quartile of errors, 75%: upper quartile of errors.**

شکل ۸ مقادیر شاخص عدم قطعیت ( $U_{95}$ ) را نشان می‌دهد. دامنه تغییرات شاخص عدم قطعیت ( $U_{95}$ ) بین ۱۴ تا ۱۷ بوده که کمترین و بیشترین مقدار آن به ترتیب مربوط به ANFIS-WCA و ANFIS-GOW است. از شکل بهوضوح می‌توان دریافت که مدل ANFIS-WCA دارای کمترین مقدار شاخص  $U_{95}$  است که عملکرد برتر آن را نسبت به سایر مدل‌های هیبریدی را تأیید می‌کند. در بقیه مدل هیبریدی عملکرد مدل‌ها در مورد شاخص  $U_{95}$  مشابه بوده و به عبارتی دقت برآورده در مدل‌های دیگر افزایش نداشته است. همان طور که در شکل ۸ مشاهده می‌شود، مدل‌های مختلف هیبریدی با شاخص‌های آماری مذکور ارائه شده است. با توجه به شاخص‌های آماری NRMSE و MBE به ترتیب الگوریتم‌های چرخه آب، گرگ خاکستری، شبکه عصبی، وال و ملخ در بهینه کردن سیستم استنتاج عصبی-فازی عملکرد بهتری دارند، ولی با توجه به شاخص‌های آماری  $R^2$  و MAE به ترتیب الگوریتم‌های چرخه آب، شبکه عصبی، وال و گرگ خاکستری عملکرد بهتری دارند.

در نهایت مشاهده می‌شود که شاخص‌های آماری مختلف ممکن است نتایج متفاوتی در تعیین مدل با بالاترین دقت رتبه‌بندی مدل‌ها داشته باشند، زیرا هر شاخص در مورد عملکرد مدل در سطح منحصر به فردی قضاوت می‌کند، از این رو انتخاب بهترین و مناسب‌ترین مدل بر اساس شاخص‌های مختلف نمی‌تواند راه حل قابل اعتمادی باشد، بنابراین، یک شاخص آماری استاندارد برای

ترکیب اثر کلی شاخص‌های آماری مورد نیاز است. برای مقایسه نهایی در این مطالعه، از GPI به عنوان یک شاخص ۵ عاملی استفاده شد [۲۶، ۲۹]. با توجه به معادله (۲۰)، در GPI از ترکیب پنج شاخص  $T_{sta}$ ، MBE، RMSE و  $R^2$  استفاده شده است، بنابراین می‌تواند مدل‌های مورد استفاده برای تخمین دبی ورودی سد را رتبه‌بندی کند. انتظار می‌رود مدل با رتبه اول (دارای مقدار GPI نزدیک به صفر) هم از نظر عملکرد و هم از نظر دقیق‌تر از مدل‌های دیگر باشد [۲۶، ۲۹]. شکل ۸ مقدار GPI را برای تمام مدل‌های ترکیبی بر اساس رتبه‌بندی نشان می‌دهد. بر اساس این شکل، برتری مدل ترکیبی ANFIS-WCA در تخمین دبی ورودی سد مشهود است زیرا کمترین مقدار GPI را دارد. جدول ۴ پارامترهای بهینه مربوط به الگوریتم‌های فراابتکاری را نشان می‌دهد.



شکل ۸: مقادیر شاخص‌های آماری مدل‌های مختلف هیبریدی.

Figure 8: Statistical index values of different hybrid models.

شکل ۹، روند همگرایی الگوریتم‌های مختلف ترکیبی به سمت جواب بهینه را نشان می‌دهد. همان طوری که در این شکل مشاهده می‌شود الگوریتم ANFIS-WCA روند همگرایی بهتری نسبت به سایر الگوریتم‌ها دارا می‌باشد و زودتر به جواب بهینه همگرا شده است.

جدول ۴: پارامترهای کنترلی بهینه الگوریتم‌های فراابتکاری در مدل‌های هیبریدی.

Table 4: Optimal control parameters of meta-heuristic algorithms in different hybrid models.

مدل	ANFIS-WCA	ANFIS-GOA	ANFIS-NNA	ANFIS-GOW	ANFIS-WOA
تعداد جمعیت (عامل جستجو)	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
حداکثر تعداد تکرارها	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰
حد پایین و بالای وزن‌ها و بایاس‌ها	[-10, +10]	[-10, +10]	[-10, +10]	[-10, +10]	[-10, +10]
پارامترهای دیگر	Nsr=4 dmax=1e-16	-	-	-	-

علت عملکرد بهتر این مدل ترکیبی را می‌توان به آموزش خوب سیستم شبکه عصبی مصنوعی و توانایی بالای آن در بهینه کردن وزن‌ها و ساختار شبکه عصبی مصنوعی دانست. دقیق‌تر برای مدل ANFIS-WCA در مقایسه با مدل‌های هیبریدی دیگر نشان دهنده عملکرد آن برای فرار از بیشینه و کمینه‌های محلی است که باعث می‌شود این مدل به عنوان ابزاری قدرتمند برای تخمین دبی ورودی سد سفیدرود به کار رود. این مسئله را می‌توان با پیچیدگی‌های موجود در مسئله بهینه‌سازی توجیه کرد. این مطلب نشان دهنده این است که این الگوریتم دارای راهبرد اکتشاف بهتری بوده و گام حرکت بهینه موثرتری را انتخاب نموده است.

## نتیجه‌گیری

هدف از پژوهش حاضر برآورد دبی ورودی سد مخزنی سفیدرود به منظور رفع دو محدودیت عدم وجود مدل جامع برای تمامی سدها و کمبود اطلاعات هیدرولیکی و هیدرولوژیکی در ایران است. از این‌رو، بر اساس کارایی مدل سیستم استنتاج فازی عصبی تطبیقی هیبرید شده با الگوریتم‌های فراابتکاری چرخه آب، گرگ خاکستری، ملخ و وال تفاوت معنی‌داری را از نظر کیفیت مدل‌سازی و دقت نتایج در شبیه‌سازی دبی ورودی به سد سفیدرود نشان ندادند. شاخص عملکرد جهانی (GPI) در مدل ANFIS-WCA تا ۱۱ درصد در مقایسه با مدل ANFIS-ANN و ۲۰ درصد در مقایسه با مدل ANFIS-GOA بهبود یافته است. نتایج شاخص‌های آماری مختلف نشان داد که ANFIS-WCA نسبت به سایر الگوریتم‌های هیبریدی کارآمدتر بوده و الگوریتم WCA ابزار قدرتمندی در بهینه‌سازی ساختار ANFIS است که نشان‌دهنده پیچیدگی فرآیند دبی ورودی است. همچنین با توجه به شاخص NRMSE مدل ANFIS-WCA دقت شبیه‌سازی را به ترتیب  $1/4$  و  $1/6$  درصد در مقایسه با مدل‌های ANFIS-GOA و ANFIS-NNA بهبود بخشید. همچنین نتایج با استفاده از تعدادی شاخص بصری و آماری مورد تجزیه و تحلیل قرار گرفت و پتانسیل الگوریتم چرخه آب به عنوان ابزاری کارآمد برای تولید و بهبود پارامترهای داخلی مدل ANFIS تأیید شد. مدل‌های هیبریدی پیشنهادی توانایی خوبی در تخمین دبی ورودی سد نشان دادند، با این وجود، لازم است این مدل‌ها در سدهای دیگر با ویژگی‌های متفاوت آزمایش کرد تا از کاربرد این مدل‌ها در شرایط مختلف اطمینان حاصل شود. با توجه به اینکه اندازه‌گیری دبی ورودی سد با روش‌های مستقیم مستلزم صرف هزینه و زمان است، توسعه روش‌های داده محور می‌تواند معرفی و استفاده شود. پیشنهاد می‌شود برای سایر کمیت‌های سد سفیدرود از جمله دبی خروجی و تراز مخزن نیز مدل‌سازی با مدل‌های ترکیبی مذکور انجام شود. همچنین در مطالعه‌های آتی از دیگر الگوریتم‌های فراابتکاری جهت آموزش ANFIS در پیش‌بینی دبی ورودی سد سفیدرود استفاده شده و نتایج حاصل با نتایج به دست آمده از این مطالعه مقایسه شود.

## منابع

- [1] A. Ebrahimzadeh, M. Zarghami, V. Nourani, Evaluation of earth dam overtopping risk by system dynamics, Monte-Carlo simulation and Latin Hypercube Sampling methods (case study: Hajilarchay Dam, Iran), Iran-Water Resources Research, 15(1) (2019) 14-31.

- [2] Ö. Kişi, River flow forecasting and estimation using different artificial neural network techniques, *Hydrology research*, 39(1) (2008) 27-40.
- [3] K.I. Hsu, H.V. Gupta, S. Sorooshian, Artificial neural network modeling of the rainfall-runoff process, *Water resources research*, 31(10) (1995) 2517-2530.
- [4] C. Imrie, S. Durucan, A. Korre, River flow prediction using artificial neural networks: generalisation beyond the calibration range, *Journal of hydrology*, 233(1-4) (2000) 138-153.
- [5] P. Fathi, Y. Mohammadi, M. Homaei, Intelligent modeling of monthly flow time series into vahdat dam in sanandaj city, *Water and Soil*, 23(1) (2009).
- [6] O. Kisi, H. Kerem Cigizoglu, Comparison of different ANN techniques in river flow prediction, *Civil Engineering and Environmental Systems*, 24(3) (2007) 211-231.
- [7] F. J. Chang, Y. C. Chen, A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction, *Journal of hydrology*, 245(1-4) (2001) 153-164.
- [8] P.C. Nayak, K. Sudheer, D. Rangan, K. Ramasastri, A neuro-fuzzy computing technique for modeling hydrological time series, *Journal of Hydrology*, 291(1-2) (2004) 52-66.
- [9] H. Sanikhani, O. Kisi, River flow estimation and forecasting by using two different adaptive neuro-fuzzy approaches, *Water resources management*, 26(6) (2012) 1715-1729.
- [10] A. Lohani, R. Kumar, R. Singh, Hydrological time series modeling: A comparison between adaptive neuro-fuzzy, neural network and autoregressive techniques, *Journal of Hydrology*, 442 (2012) 23-35.
- [11] H. Emami, S. Emami, S. Heydari, Prediction Suspended Sediment Load of River Using Meta-heuristic Algorithms, *Iranian Journal of Irrigation & Drainage*, 13(5) (2019) 1426-1438.
- [12] S. Emami, J. Parsa, Comparising performance of meta-heuristic algorithms with the sediment rate curve (case study: Zarrineh Rood River), *Watershed Engineering and Management*, 13(1) (2021) 43-54. (in Persian)
- [13] A. Vafaeinejad, Z. Chatsimab, S. Bloori, F Mirdar Harijani, Optimization equation sediment rating curves in sediment discharge rate using particle swarm algorithm (PSO) and annealing (SA) (Case Study Bijar station), *Natural Ecosystems of Iran*, 8(3) (2017) 69-82.
- [14] H. Hakimi Khansar, A. Shabani chafjiri, Determining Effective Features for Estimating the Volume of Water Delivered to the Irrigation and Drainage Network using Artificial Intelligence Methods (Case study: Irrigation and Drainage Network of Sefidrood Dam), *Water Management in Agriculture*, 8(2) (2022) 117-134. (in Persian)
- [15] H. Eskandar, A. Sadollah, A. Bahreininejad, M. Hamdi, Water cycle algorithm – A novel metaheuristic optimization method for solving constrained engineering optimization problems, *Computers & Structures*, 110-111 (2012) 151-166.
- [16] S. Mirjalili, S.M. Mirjalili, A. Lewis, Grey wolf optimizer, *Advances in engineering software*, 69 (2014) 46-61.
- [17] S. Mirjalili, A. Lewis, The whale optimization algorithm, *Advances in engineering software*, 95 (2016) 51-67.
- [18] A. Sadollah, H. Sayyaadi, A. Yadav, A dynamic metaheuristic optimization model inspired by biological nervous systems: Neural network algorithm, *Applied Soft Computing*, 71 (2018) 747-782.
- [19] S.Z. Mirjalili, S. Mirjalili, S. Saremi, H. Faris, I. Aljarah, Grasshopper optimization algorithm for multi-objective optimization problems, *Applied Intelligence*, 48(4) (2018) 805-820.
- [20] J. S. Jang, ANFIS: adaptive-network-based fuzzy inference system, *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3) (1993) 665-685.
- [21] K. Tanaka, An introduction to fuzzy logic for practical applications, 1996.
- [22] C. Ma, M. Iqbal, Statistical comparison of solar radiation correlations monthly average global and diffuse radiation on horizontal surfaces, *Sol. Energy*, 33 (1984) 143–148.
- [23] M. Dasineh, A. Ghaderi, M. Bagherzadeh, M. Ahmadi, A. Kuriqi, Prediction of hydraulic jumps on a triangular bed roughness using numerical modeling and soft computing methods, *Mathematics*, 9(23) (2021) 3135.
- [24] C.J. Willmott, K. Matsuura, On the use of dimensioned measures of error to evaluate the performance of spatial interpolators, *International Journal of Geographical Information Science*, 20(1) (2006) 89-102.
- [25] M.S. Lewis-Beck, Election forecasting: Principles and practice, *The British Journal of Politics and International Relations*, 7(2) (2005) 145-164.

- [26] O. Behar, A. Khellaf, K. Mohammedi, Comparison of solar radiation models and their validation under Algerian climate – The case of direct irradiance, *Energy Conversion and Management*, 98 (2015) 236-251.
- [27] R. Daneshfaraz, E. Aminvash, A. Ghaderi, J. Abraham, M. Bagherzadeh, SVM performance for predicting the effect of horizontal screen diameters on the hydraulic parameters of a vertical drop, *Applied sciences*, 11(9) (2021) 4238.
- [28] M. F. Li, X. P. Tang, W. Wu, H.B. Liu, General models for estimating daily global solar radiation for different solar radiation zones in mainland China, *Energy Conversion and Management*, 70 (2013) 139-148.
- [29] R. Stone, Improved statistical procedure for the evaluation of solar radiation estimation models, *Solar energy*, 51(4) (1993) 289-291.
- [30] C.M. Patino, J.C. Ferreira, Confidence intervals: a useful statistical tool to estimate effect sizes in the real world, *Jornal Brasileiro de Pneumologia*, 41 (2015) 565-566.
- [31] H. Hakimi Khansar, Simulation of behavior of the Kabudval Dam during construction with 3D numerical modeling, *Amirkabir Journal of Civil Engineering*, 53(9) (2021) 20-20.(in Persian)
- [32] J. Parsa, H. Hakimi Khansar, A. Hoseinzadeh dalir, J. Shiri, Simulation of soil stress in earth dams using artificial intelligence models and determination of effective features, *Amirkabir Journal of Civil Engineering*, (2021). (in Persian)
- [33] S. Maroufpoor, E. Maroufpoor, O. Bozorg-Haddad, J. Shiri, Z.M. Yaseen, Soil moisture simulation using hybrid artificial intelligent model: Hybridization of adaptive neuro fuzzy inference system with grey wolf optimizer algorithm, *Journal of Hydrology*, 575 (2019) 544-556.

# Extended Estimation of daily inflow of Sefidroud dam using meta-heuristic algorithms combined with fuzzy neural inference system

Hossein Hakimi Khansar<sup>1</sup>, Javad Parsa<sup>\*2</sup>, Omran Momeni Keleshteri<sup>3</sup>, Norbakhsh Karami<sup>4</sup>, Moein Khoshdel Sangdeh<sup>5</sup>

<sup>1</sup> Ph.D in Water Science and Engineering, and Expert of Guilan Regional Water Company

<sup>2</sup> Department of Water Engineering, University of Tabriz, Iran, E-mail: jparsa@tabrizu.ac.ir

<sup>3</sup> MSc in Water Resources Management, and Manager of Guilan Dams

<sup>4</sup> MSc in Construction Management, and Head of Operation and Maintenance Department of Dam and Powerhouse of Sefidroud

<sup>5</sup> MSc in Geotechnics, and Expert of Guilan Regional Water Company

## ABSTRACT

Estimating water inflows to water resource systems is crucial for effective planning and optimal allocation of water resources across various consumption sectors. This study proposes a novel approach that combines Meta Heuristic algorithms, namely Water Cycle Algorithms (WCA), Gray Wolf Optimizer (GWO), Whale Optimization Algorithm (WOA), Neural Network Algorithm (NNA), and Grasshopper Optimization Algorithm (GOA), with a Neural-Fuzzy System for training and updating parameters. The objective is to develop accurate models for predicting the daily inflow of Sefidroud reservoir dam. Unlike gradient-based algorithms, this method overcomes the challenges associated with training. The Autocorrelation Function and Correlation function were utilized to select four features: dam lake area, reservoir volume, reservoir level of the dam during the previous 7 days, and inflow in the previous day. Various statistical indicators were employed to evaluate the performance of the developed models. In the test stage, the ANFIS-WCA model demonstrated superior performance with the lowest values of SI (0.0736), MAE (0.05048), and NRMSE (0.0736), and the highest value of  $R^2$  (0.9840). Based on the GPI index, the ANFIS-WCA model was identified as the best model, followed by ANFIS-NNA, ANFIS-GOA, and ANFIS-WOA models. Conversely, the ANFIS-GOA model exhibited the least accuracy. The results indicated that the ANFIS-WCA model outperformed the ANFIS-NNA model by 31% in terms of SI, and the ANFIS-GOA model by 1.6% in terms of SI. Furthermore, the GPI index revealed an improvement of up to 11% compared to the ANFIS-ANN model, and 20% compared to the ANFIS-GOA model. The high accuracy of the ANFIS-WCA model, compared to other hybrid models, highlights the effectiveness of the water cycle algorithm in combination with the ANFIS model. This approach proves to be a powerful tool for estimating the input discharge of Sefidroud Dam, as it successfully avoids local optima.

## KEYWORDS

Fuzzy-neural-adaptive inference system, inflow, Meta-heuristic algorithm, Sefidroud dam, Water cycle algorithm.