



## ارزیابی کارایی دو مدل نروفازی و هیبرید موجکی - عصبی در پیش‌بینی جریان رودخانه (مطالعه موردی: حوضه محمدآباد)

فریبا نیرومند فرد<sup>۱</sup>، عباس خاشعی سیوکی<sup>۲</sup> و علی شهیدی<sup>۳</sup>

۱ و ۳- دانشجوی دکتری منابع آب و دانشیار، دانشکده کشاورزی گروه مهندسی آب، دانشگاه بیرجند  
۲- دانشیار، دانشکده کشاورزی گروه مهندسی آب، دانشگاه بیرجند (نویسنده مسؤول: abbaskhashei@birjand.ac.ir)  
تاریخ دریافت: ۹۶/۱۲/۱۲ تاریخ پذیرش: ۹۷/۱۰/۰۱  
صفحه: ۲۱۱ تا ۲۲۱

### چکیده

از مهم‌ترین مسائل در مدیریت حوزه‌های آبخیز، پیش‌بینی فرآیندهای هیدرولوژیکی بارش- رواناب می‌باشد. استفاده از مدل‌های جدید در این زمینه می‌تواند به مدیریت و برنامه‌ریزی صحیح کمک کند. علاوه بر آن پیش‌بینی جریان رودخانه، مخصوصاً در شرایط سیلابی، به مسئولان این امکان را خواهد داد که با آمادگی خسارت ناشی از سیل را کاهش دهند. با توجه به اهمیت پیش‌بینی جریان رودخانه در مدیریت منابع آب روش‌های مختلفی برای مدل کردن جریان رودخانه‌ها به کار برده می‌شوند، تا بتوان با به کارگیری این مدل در مدیریت خشکسالی و سیلاب خسارات ناشی از آن‌ها را به حداقل ممکن رساند. در این مطالعه برای پیش‌بینی سری زمانی جریان روزانه ایستگاه آبسنجی سرمو واقع بر رودخانه محمدآباد، مدل نروفازی و هیبرید موجکی- عصبی مورد استفاده قرار گرفت. برای این هدف سری زمانی اصلی به مدت ۲۸ سال به وسیله تبدیل موجکی به سه زیر سری و با موجک مادر دابچیز نوع چهارم انجام شد. مقدار ضریب همبستگی در مدل نروفازی ۰/۸۸+ و در مدل هیبرید موجکی-عصبی ۰/۹۵+ به دست آمده است و نیز پارامترهای ارزیابی RMSE، MSE، NS در مدل موجکی-عصبی به ترتیب ۰/۰۰۴+، ۰/۰۴۳+ و ۰/۹۱+ و در مدل نروفازی به ترتیب ۰/۳۲+، ۰/۱۰+ و ۰/۷۷+ بدست آمد. در نهایت نتایج حاصل از تبدیل موجکی-عصبی با نتایج حاصل از نروفازی، مقایسه و ملاحظه شد که روش موجکی-عصبی نسبت به روش نروفازی دقت پیش‌بینی بالاتری دارد.

واژه‌های کلیدی: پیش‌بینی جریان، سری زمانی جریان روزانه، مدل نروفازی، مدل هیبرید عصبی- موجکی

### مقدمه

بدون شک مهم‌ترین اقدام برای برنامه‌ریزی و مدیریت منابع آب تشخیص روند و دوره سیگنال است تا با استفاده از این مشخصه‌ها بتوان روند و دوره‌های آینده را تشخیص داده و به این وسیله از خسارات احتمالی که ممکن است بصورت خشکسالی یا سیل اتفاق بیافتد جلوگیری نمود. بیشتر سیگنال‌های هیدرولوژیکی مخصوصاً فصلی و روزانه دارای مشخصات غیرایستا، پرش، روند و تغییرات ناگهانی در بسامد هستند که برای مدل‌سازی آن‌ها استفاده از الگوریتم‌ها، معادلات غیرخطی و نظریه‌های جدید ریاضی ضروری به نظر می‌رسد (۲۴). استفاده از شبیه‌سازی‌ها، مدل‌های فیزیکی، مدل‌های ریاضی، توزیع‌های آماری و برنامه‌های رایانه‌ای مربوطه از مواردی است که برای پیش‌بینی پدیده‌ها استفاده می‌شود. اکنون مدل‌های هیدرولوژیکی مختلفی جهت مدل‌سازی رواناب پیشنهاد شده‌اند، اما به توجه به ماهیت غیرخطی، عدم قطعیت و عدم صراحت زیاد و ویژگی‌های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ یک از مدل‌های آماری و مفهومی پیشنهاد شده به منظور الگوسازی دقیق رواناب نتوانسته‌اند به عنوان یک مدل برتر و توانا شناخته شوند و این مسأله همواره از پیچیدگی‌های ویژه‌ای برخوردار است (۲۰). تبدیل موجکی تابعی است که نسخه بهبود یافته تبدیل فوریه را تداعی می‌نماید. تبدیل فوریه در آنالیز سیگنال‌های ناپایستا به شکست منجر می‌شود. در حالیکه تبدیل موجکی اجازه می‌دهد که سیگنال‌های ناپایستا نیز به خوبی آنالیز شوند (۲۵). شبکه عصبی مصنوعی یکی از

دستاوردهایی می‌باشد که با الگوبرداری از مغز انسان، می‌تواند پدیده‌های پیچیده و ناشناخته را به خوبی بررسی نماید (۱۴). از یاد تعداد متغیرها در شبکه عصبی مصنوعی می‌تواند سبب پیچیدگی ساختار شبکه عصبی و ناپایداری آن گردد که یکی از دلایل آن افزایش تعداد وزن‌ها نسبت به ورودی‌ها می‌باشد (۵). کاربرد موجک در شبکه عصبی موجکی به عنوان تابع آموزش، اخیراً به عنوان یک روش جایگزین، در شبکه‌های عصبی، به کار برده می‌شود. ترکیب تئوری موجکی و شبکه‌های عصبی منجر به گسترش شبکه‌های عصبی- موجکی شده است. در شبکه عصبی- موجکی، موقعیت و مقیاس موجک‌ها علاوه بر وزن‌ها بهینه‌سازی می‌شوند. در اصل شبکه عصبی موجکی به شبکه عصبی با استفاده از موجک اشاره دارد (۲۶). پارتال و کیسی (۲۱) یک روش ترکیبی را مبنی بر ترکیب wavelet-neuro-fuzzy برای پیش‌بینی بارندگی پیشنهاد دادند و بارندگی روزانه را توسط تبدیل موجک گسسته تجزیه کرده و نتایج حاصل را به عنوان ورودی به مدل neuro-fuzzy وارد نمودند و مشاهده کردند که مدل هیبریدی حاصل، همپوشانی و تطابق خوبی با داده‌های مشاهده شده فراهم می‌آورد.

کیسی (۹) مدل ترکیبی wavelet-neuro-fuzzy را با مدل کلاسیک neuro-fuzzy مقایسه نمود و نتایج تحقیق نشان داد که مدل ترکیبی بهتر عمل می‌کند و تکنیک ANN-Wavelet را برای مدل کردن جریان ماهانه پیشنهاد نمود. نبی‌زاده و همکاران (۱۸) با استفاده از مدل‌های مبتنی بر منطق فازی شامل سیستم استنتاج فازی (FIS) و سیستم


حوضه‌ها می‌باشند. پورآزاد و ستاری (۱) در تحقیق خود به پیش‌بینی جریان رودخانه اهرچای با استفاده از دو روش شبکه عصبی مصنوعی و نروفازی پرداختند. نتایج حاکی از آن بود که مدل نروفازی دقت بیشتری نسبت به شبکه‌های عصبی مصنوعی داشت. معروفی و همکاران (۱۱) در تحقیق خود به پیش‌بینی جریان رودخانه با استفاده از شبکه‌های عصبی مصنوعی و موجکی در رودخانه باراندوزچای پرداختند. نتایج تحقیق نشان داد که مدل موجکی-عصبی توانایی بیشتری در پیش‌بینی جریان رودخانه نسبت به شبکه عصبی مصنوعی دارد. در این مطالعه به بررسی و مقایسه کارایی دو مدل نروفازی و هیبرید موجکی-عصبی در پیش‌بینی جریان رودخانه پرداخته شده است.

### مواد و روش‌ها

#### معرفی منطقه مورد مطالعه

حوضه مورد مطالعه در این پژوهش، حوضه آبریز محمدآباد از زیر حوضه‌های گرگانرود استان گلستان می‌باشد. این حوضه دارای مساحتی برابر  $387/5$  کیلومترمربع و محیطی برابر با  $89$  کیلومتر می‌باشد و در طول جغرافیایی  $55^{\circ} 49'$  و عرض جغرافیایی  $36^{\circ} 42' 34''$  قرار دارد. حداکثر ارتفاع حوضه  $3500$  متر، حداقل ارتفاع  $500$  متر و ارتفاع متوسط حوضه  $1906$  متر از سطح دریا و شیب متوسط حوضه  $10/3$  درصد می‌باشد. طول شاخه اصلی رودخانه  $16/75$  کیلومتر و شیب خالص شاخه اصلی  $9/95$  درصد می‌باشد. این حوضه دارای یک ایستگاه باران‌سنجی معمولی و یک ایستگاه آبسنجی به نام سرمو است. ایستگاه باران‌سنجی سرمو در ارتفاع  $500$  متری و در طول جغرافیایی  $67^{\circ} 40'$  و عرض جغرافیایی  $52^{\circ} 30'$  قرار دارد. ایستگاه آبسنجی در ارتفاع  $500$  متری و در طول جغرافیایی  $78^{\circ} 40'$  و عرض جغرافیایی  $32^{\circ} 30'$  قرار دارد که در سال  $1354-55$  تأسیس گردیده است. شکل ۱ موقعیت این حوضه را در ایران و در استان گلستان نشان می‌دهد.

استنتاج فازی-عصبی تطبیقی (ANFIS) اقدام به پیش‌بینی جریان روزانه رودخانه ليقوان نمودند. نتایج پژوهش آن‌ها نشان داد که روش ANFIS از دقت بالاتری نسبت به روش FIS برخوردار است. کاتاتپ و همکاران (۷)، در پژوهشی تبدیل موجک گسسته را با سیستم‌های فازی تاکاگی-سوگنو ترکیب کرده، این مدل متشکل از یک مجموعه قوانین فازی است که این قوانین، بسط سری‌های توابع موجک هستند و از این بخش مدل برای مدل‌سازی سیستم استفاده گردید. نورانی و همکارانش (۱۶)، مدل ترکیبی موجکی-عصبی را برای شبیه‌سازی بارش-رواناب روزانه گیگل آبی واقع در اتیوپی به کار بردند. در تحقیق یاد شده برای زیاد کردن دقت تخمین مدل، از مقادیر ثبت شده بارش توسط ماهواره‌ها استفاده شد. نایاک و همکارانش (۱۷)، برای مدل‌سازی بارش-رواناب و استخراج هیدروگراف‌های سیلاب حوضه آبریز مالاپرابها واقع در هندوستان از آمار روزانه دبی، بارش و تبخیر استفاده کردند. در تحقیق آنها، مدل موجکی-عصبی نسبت به شبکه‌های عصبی مصنوعی عملکرد بهتری نشان داد. نورانی و کوماسی (۱۹)، از مدل تلفیقی شبکه موجکی-عصبی برای پیش‌بینی دبی رواناب یک روز بعد، استفاده نموده و به این نتیجه رسیدند که توانایی مدل شبکه موجکی-عصبی در پیش‌بینی نقاط بیشینه نمودار سری زمانی، نسبت به سایر روش‌ها بیشتر است. چنارد و همکاران (۴) در تحقیقی به مقایسه مدل تلفیقی موجکی-عصبی با دو مدل از شبکه عصبی مصنوعی ANN و اتورگرسیو AR برای مدل‌سازی جریان رودخانه مالاپرابها پرداختند و به این نتیجه رسیدند که مدل موجکی-عصبی نتایج بهتری را نسبت به دو مدل ANN و AR ارائه می‌دهد. آداموسکی و سون (۳)، از مدل ترکیبی تبدیلات موجکی گسسته و شبکه‌های عصبی، برای پیش‌بینی جریان یک روزه و سه روزه در رودخانه‌های غیر دائمی حوضه‌های نیمه‌خشک کارگوتیس استفاده کردند؛ نتایج تحقیق نشان داده که شبکه‌های موجکی-عصبی روش مؤثرتری برای پیش‌بینی جریان کوتاه‌مدت در این گونه



شکل ۱- موقعیت جغرافیایی حوضه محمدآباد  
Figure 1. Geographical location of the Mohammad Abad Watershed

## سیستم نروفازی

این سیستم اولین بار در سال ۱۹۹۳ توسط جانگ<sup>۱</sup> معرفی شد (۶). نکته اصلی در هنگام طراحی یک مدل نروفازی (ANFIS)، انتخاب سیستم استنتاج فازی (FIS)، است. برای مدل فازی مرتبه اول Sugeno، یک نمونه مجموعه با ۲ قانون IF-Then فازی به شکل زیر قابل ارائه است.


رابطه (۱)

$$X = A_1, y = B_1 \rightarrow f_1 = p_1 X + q_1 y + r_1$$

رابطه (۲)

$$X = A_2, y = B_2 \rightarrow f_2 = p_2 X + q_2 y + r_2$$

که در آن  $A_1, A_2, B_1, B_2$  به ترتیب توابع عضویت برای ورودی‌های  $x$  و  $y$  هستند.  $P_1, Q_1, R_1$  و  $P_2, Q_2, R_2$  پارامترهای تابع خروجی هستند (۲۳). معماری معمول ANFIS در شکل ۲ ارائه شده است. که در آن گروه‌هایی لایه مشابه، تابع مشابه دارد.



شکل ۲- معماری مدل ANFIS (۹)

Figure 2. Architecture of the ANFIS model (9)

لایه ۳: گروه نام این لایه که با  $N$  نام گذاری شده است قدرت تهبیج نرمال شده را محاسبه می‌کند:

رابطه (۷)

$$OP_i^2 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \leftarrow i = 1, 2$$

لایه ۴: گره  $i$  در این لایه مشارکت قانون نام را به سمت خروجی مدل با استفاده از تابع زیر محاسبه می‌کند.

رابطه (۸)

$$(OP_i^4 = \bar{w}_i f_i = \bar{w}_i (P_i x + q_i y + r_i))$$

که در آن،  $\bar{w}$ : خروجی لایه ۳ و  $\{P_i, Q_i, R_i\}$  مجموعه پارامترها می‌باشد.

لایه ۵: تنها گره این لایه، خروجی کلی ANFIS را مطابق زیر محاسبه می‌کند:

رابطه (۹)

$$OP_i^5 = overalloutput = \sum_i \bar{w}_i f_i = \frac{\sum_i \bar{w}_i f_i}{\sum_i \bar{w}_i}$$

اجرای نروفازی و پیش‌بینی میزان دبی روزانه حوزه آبخیز محمدآباد با استفاده از نرم‌افزار MATLAB صورت گرفت.

برای افزایش کارایی نروفازی در مدل‌سازی داده‌های ورودی و خروجی، داده‌ها معیارسازی (نرمال‌سازی) می‌شوند، یعنی بین دامنه عددی معمولاً صفر تا یک قرار می‌گیرند. از الگوهای آموزش برای آموزش نروفازی استفاده می‌شود. از آنجا که نروفازی فاقد برون‌یابی بالاست و توانایی تعمیم‌دهی آن فقط در چارچوب درون‌یابی مطرح است، بنابراین داده‌های آموزشی باید طوری انتخاب شوند که نماینده کل داده‌ها در تمام حالات ممکن از قبیل حدی (حداقل و حداکثر) باشند.

## کارکرد ANFIS بدین شرح می‌باشد:

لایه ۱: هر گره در این لایه درجات عضویت از یک متغیر ورودی را تولید می‌کند. گروه خروجی توسط روابط زیر تعریف می‌گردد:

$$OP_i^1 = \mu_{A_i}(x) \leftarrow i = 1, 2$$

رابطه (۳)

$$OP_i^1 = \mu_{B_{i-2}}(y) \leftarrow i = 3, 4$$

رابطه (۴)

که در آن  $x$  یا  $y$  ورودی به گره مورد نظر،  $A_i$  (یا  $B_{i-2}$ ) مجموعه فازی مرتبط با این گره است که توسط شکل توابع عضویت این گره مشخص می‌شود. با توجه به اینکه در این تحقیق تابع گوسی دارای بهترین برآوردها بود، به‌عنوان تابع عضویت انتخاب شد که خروجی آن به‌صورت زیر قابل محاسبه است.

رابطه (۵)

$$OP_i^1 = \mu_{B_{i-2}}(x) = \frac{1}{1 + \left( \frac{x - c_i}{a_i} \right)^{2b_i}}$$

که در آن:  $\{a_i, b_i, c_i\}$  مجموعه پارامترها هستند که شکل تابع عضویت را تغییر می‌دهند و حداکثر ۱ و حداقل صفر هستند (۸).

لایه ۲: هر گره در این لایه در سیگنال ورودی ضرب می‌گردد و خروجی که نشان‌دهنده قدرت تهبیج یک قانون است مطابق زیر محاسبه می‌گردد:

رابطه (۶)

$$OP_i^2 = w_i = \mu_{A_i}(x) \mu_{B_i}(y) \leftarrow i = 1, 2$$

انتخاب‌های مقیاس و موقعیت مبنی بر مزیت‌های هر دو مقیاس‌ها و موقعیت‌های دوتایی باشد، تحلیل‌ها دقیق خواهد بود. تبدیل موجک گسسته از بانک‌های فیلتر برای بازسازی سطح چند تفکیکی زمان-فرکانس بهره می‌برد (۱۲). این تبدیل، تبدیل موجک گسسته نامیده می‌شود. و به شکل زیر تعریف می‌شوند:

$$w_f(a, b) = |a|^{\frac{-1\Delta t}{2}} \sum_{k=1}^N f(k\Delta t) \psi^* \left( \frac{k\Delta t - b}{a} \right) \quad \text{رابطه (۱۵)}$$

$\Psi^*(t)$ : تابع مختلط و مرکب  $\Psi(t)$  است.  $W_f(a, b)$ : ضریب موجک است که تحت سطوح تجزیه و زمان‌های مختلف بدست آمده است.  $N$ : تعداد گام زمانی گسسته و  $\Delta t$ : فواصل زمانی نمونه است.  $W_f(a, b)$  می‌تواند ویژگی‌های سری زمانی اصلی را در زمان  $b$  و دامنه فرکانس  $a$  در زمان یکسان منعکس کند. انتخاب تابع موجکی و مقیاس موجکی دو موضوع مهم در تبدیل موجکی هستند (۲۸). در مرحله تجزیه تبدیل موجک گسسته سیگنال را به یک مجموعه از فرکانس‌های بالا و پایین تجزیه می‌کند. تجزیه موجک به یک سلسله فرکانس‌های بالا و پایین اولین بار توسط ملات پیشنهاد شده است، (۱۲). در سطح  $J$  که نشانگر زیر سری جزئی است بصورت زیر تعریف می‌شود.

$$D_j = \sum_{k \in Z} w_f(a, b) \psi(a, b) \quad \text{رابطه (۱۶)}$$

که  $W_f(a, b)$ : ضریب موجکی در مقیاس  $a$  و زمان  $b$  بوده و  $\Psi(a, b)(t)$  موجک مادر تبدیل یافته (موجک دختر) در مقیاس  $a$  و زمان  $b$  می‌باشد. که سیگنال اصلی از حاصل جمع همه  $D_j$  قابل حصول است.

$$S = \sum_{j \in Z} D_j$$

در تجزیه موجکی دو دسته  $D_j$  حاصل می‌شود که دسته اول دارای مقیاس  $a = 2^J$  که  $J \leq j$  می‌باشند و به  $D_j$ های ریز معروف‌اند و دسته دوم دارای  $a = 2^J$  که  $J \geq j$  هستند و  $D_j$  خشن نام دارند.  $J$  سطح تجزیه موجکی است.

$$A_J = \sum_{j > J} D_j \quad \text{رابطه (۱۷)}$$

$$S = A_J + \sum_{j < J} D_j$$

که  $A_J$  زیر سری تقریبی در سطح  $J$  است ۱۹۹۶. داده‌های استفاده شده در این تحقیق مربوط به دبی ایستگاه سرمو واقع در رودخانه محمدآباد از زیرحوضه‌های حوضه گرگانود است که شامل ۲۹ سال به تعداد ۱۰۵۸۵ داده دبی روزانه از تاریخ ۱۳۶۱ تا ۱۳۸۹ می‌باشد که به دو دسته آموزش (۸۰٪) و آزمون (۲۰٪) برای بررسی کارایی دو مدل، تقسیم‌بندی شد. در این مطالعه به تجزیه سری‌های زمانی ورودی داده‌های آموزش و آزمون به زیر سری‌ها با استفاده از

(۲۷). در ادامه برای ارزیابی، از معیارهای میانگین مربعات خطا (RMSE)، ضریب همبستگی ( $R^2$ ) و ضریب تبیین  $E$  استفاده شد.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i^o - Q_i^p)^2} \quad \text{رابطه (۱۰)}$$

$$R^2 = \frac{[\sum_{i=1}^n ((Q_i^p - \bar{Q}_i^p)(Q_i^o - \bar{Q}_i^o))]^2}{\sum_{i=1}^n (Q_i^p - \bar{Q}_i^p)^2 \sum_{i=1}^n (Q_i^o - \bar{Q}_i^o)^2} \quad \text{رابطه (۱۱)}$$

$$E = 1 - \frac{\sum_{i=1}^n ((Q_i^p - Q_i^o)^2)}{\sum_{i=1}^n ((Q_i^o - \bar{Q}_i^o)^2)} \quad \text{رابطه (۱۲)}$$

در اینجا  $n$ : تعداد داده‌ها،  $(Q_i^o)$ : دبی مشاهداتی و  $(Q_i^p)$ : دبی برآورد شده و  $(\bar{Q}^o)$ : میزان میانگین دبی‌های مشاهداتی می‌باشد.

تعداد کل داده‌ها ۱۰۵۸۵ داده دبی روزانه در طی ۲۹ سال (۱۳۶۱-۱۳۸۹) در ایستگاه سرمو بود که به دو دسته آموزش (۸۰٪) و آزمون (۲۰٪) برای بررسی کارایی نروفازی، تقسیم‌بندی شد. بهترین ساختار با ۴ تابع عضویت از نوع خطی و مدل‌سازی gbellmf (زنگوله‌ای) انتخاب گردید و ورودی مدل نروفازی، دبی ایستگاه سرمو به صورت (روز مورد نظر، روز قبل و روز بعد) به مدل داده شد.

### تبدیل موجکی

تبدیل موجکی تبدیلی است که سیگنال را به یک مجموعه از توابع اساسی سیگنال تجزیه می‌کند و در حقیقت یک مجموعه تابع اساسی از تأخیر و تغییر در مقیاس موجک مادر بدست می‌آید. تبدیل موجکی سیگنال به صورت همبستگی سیگنال و موجک تبدیل یافته توضیح داده شده است. که این تعریف را از بطن فرمول ضریب موجکی می‌توان دریافت کرد. مزیت مهم تبدیل موجکی این است که اطلاعات زمان و فرکانس را به طور مؤثری از سیگنال متغیر در زمان استخراج می‌کند، (۲۲). تابع موجک  $\Psi(t)$ ، موجک مادر نامیده می‌شود. که دارای ویژگی‌های شوک بوده و به سرعت می‌تواند به صفر کاهش پیدا کند. تابع موجک  $\Psi(t)$  به شکل ریاضی زیر تعریف می‌شود.

$$\int_{-\infty}^{+\infty} (t) \Psi dt = 0 \quad \text{رابطه (۱۳)}$$

توابع موجکی که برای آنالیز سیگنال استفاده می‌شوند، عبارتند از: موجک هار، مرلت، دابچیز، میر و غیره.

$\Psi_{(a,b)}(t)$  با استفاده از تأخیر و تغییر مقیاس موجک مادر از فرمول زیر حاصل می‌گردد.

$$\Psi_{(a,b)}(t) = |a|^{\frac{-1}{2}} \psi \left( \frac{t-b}{a} \right) \quad \text{رابطه (۱۴)}$$

$a \in \mathbb{R}, b \in \mathbb{R}, a \neq 0$

تبدیل‌های موجکی به دو دسته موجک پیوسته و گسسته تقسیم می‌شوند. برای کاربردهای علمی، هیدرولوژیست‌ها اغلب سیگنال‌های زمانی پیوسته در اختیار ندارند، بلکه بیشتر سیگنال‌های زمانی گسسته در اختیار آن‌هاست. اگر


می‌دهند. همچنین جدول شماره ۱ معیارهای ارزیابی شده برای مدل نروفازی را نشان می‌دهد. با توجه به مقادیر  $NS=0.77$  و  $MSE=0.1$ ،  $RMSE=0.32$ ،  $R=0.88$  است که می‌توان با توجه به مقادیر دبی در روز قبل، میزان دبی در روز بعد را با درصد اطمینان خوب و بالایی پیش‌بینی کرد. با توجه به اهمیت پیش‌بینی صحیح میزان دبی رودخانه، جهت مدیریت منابع آب و کاهش میزان خسارت ناشی از سیل استفاده از مدل‌سازی‌های هیدرولوژیکی اجتناب‌ناپذیر می‌باشد و مدل نروفازی با توجه به توانایی بالایی که در تجزیه و تحلیل داده‌ها و پیش‌بینی دارد، در این زمینه یکی از مدل‌های موفق بوده و می‌تواند در این زمینه به مسئولین و سازمان‌های مربوط یاری رساند. همان‌طور که در شکل ۴ مشاهده می‌شود همخوانی داده‌های محاسباتی جریان در مرحله آموزش نسبت به داده‌های مشاهداتی جریان کم بوده ولی در مرحله آزمون در شکل ۵ همخوانی بهتری بین مقادیر محاسباتی و مشاهداتی وجود دارد. همچنین در شکل ۶ اختلاف معنی‌داری بین مقادیر شبیه‌سازی شده و داده‌های مشاهداتی مشاهده نمی‌شود و مقادیر بیشتر حول محور یک‌به‌یک متمرکز هستند. از این رو مدل توانسته است مقادیر دبی را به طور قابل قبولی شبیه‌سازی کند و برآورد دبی روزانه در بسیاری از موارد با مقادیر مشاهداتی همخوانی دارد.

آنالیز موجکی توسط مدل موجکی-عصبی پرداخته شده است. همچنین بهترین ساختار با ۴ تابع عضویت از نوع خطی و مدل‌سازی gbellmf (زنگوله‌ای) برای مدل نروفازی انتخاب گردید و ورودی این مدل، دبی ایستگاه سرمو به صورت (روز مورد نظر، روز قبل و روز بعد) به مدل داده شد.

## نتایج و بحث


### نتایج مدل نروفازی

برای طراحی سیستم بهینه شبکه‌های عصبی فازی (نروفازی)، از طریق تغییر مداوم تعداد لایه‌ها و تعداد نرون‌های لایه پنهان، توپولوژی مناسب شبکه عصبی بررسی و از طریق تغییر مداوم توابع عضویت مختلف و تعداد توابع عضویت و تعداد تکرار، سیستم مناسب پایگاه استنتاج فازی طراحی شد. در طراحی مدل شبکه‌های عصبی این تحقیق، تعداد ۴ تابع عضویت، نوع تابع عضویت زنگوله‌ای (gbellmf) و تابع خروجی linear استفاده شد. در ضمن، ۸۰ درصد داده‌ها به‌عنوان داده‌های آموزش و ۲۰ درصد از داده‌ها به‌عنوان آزمون انتخاب شدند. شکل ۳ ساختار شبکه نروفازی، شکل ۴ مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی برای مدل‌سازی ۱ روز آینده در مرحله آموزش، شکل ۵ مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی برای مدل‌سازی ۱ روز آینده در مرحله آزمون و شکل ۶ پراکنش مقادیر شبیه‌سازی شده و مشاهده شده توسط این مدل را نشان




شکل ۳- ساختار مدل نروفازی در متلب


Figure 3. The structure of neuro-fuzzy model in MATLAB



شکل ۴- مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی بوسیله مدل نروفازی برای پیش‌بینی ۱ روز آینده در مرحله آموزش  
Figure 4. Comparison of observational runoff and computational runoff by a Neuro-Fuzzy model for modeling the next day at the training stage



شکل ۵- مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی بوسیله مدل نروفازی برای پیش‌بینی ۱ روز آینده در مرحله آزمون  
Figure 5. Comparison of observation runoff and computational runoff by Neuro-Fuzzy model for predicting the next day at the training stage



شکل ۶- پراکنش داده‌های دبی مشاهداتی و محاسباتی توسط مدل نروفازی  
Figure 6. Observational and computational discharge data distribution by Neuro-Fuzzy model

جدول ۱- معیارهای ارزیابی مدل نروفازی

| Table 1. Evaluation criteria of Neuro-Fuzzy model |      |            |      |         |
|---------------------------------------------------|------|------------|------|---------|
| NS                                                | MSE  | RMSE(m³/s) | R    | مدل     |
| ۰/۷۷                                              | ۰/۱۰ | ۰/۳۲       | ۰/۸۸ | نروفازی |


این الگوریتم بر اساس قانون آموزش سعی و خطا می‌باشد. و همچنین ساختار شبکه، که بیانگر نحوه اتصالات بین نرون شبکه و الگوریتم آموزش می‌باشد در اینجا به صورت پیش‌خور است. سپس پیش‌بینی سیگنال جریان روزانه بوسیله تبدیل موجکی گسسته محاسبه گردید. نرون‌های لایه مخفی بوسیله صحیح و خطا تعیین می‌گردد. در این مطالعه به منظور افزایش دقت مدل، داده‌های پیش پردازش شده توسط تبدیل موجکی گسسته و با بکارگیری موجک دابچیز نوع چهارم به عنوان ورودی‌های شبکه عصبی در نظر گرفته می‌شوند، و به این ترتیب تمامی ویژگی‌های ریز و درشت سیگنال نمایان می‌شوند که این خود باعث افزایش دقت مدل می‌گردد. هنگامیکه زیر سری‌ها به عنوان ورودی به شبکه عصبی وارد می‌شوند، شبکه عصبی به هر کدام از زیر سری‌های تجزیه‌ای وزن خاصی اختصاص می‌دهد به طوریکه وزن‌های بالا به

### نتایج مدل هیبرید موجکی-عصبی


اولین مرحله تجزیه سری‌ها، انتخاب موجک مادر بود که با توجه به کاربرد گسترده موجک دابچیز نوع چهارم، از این موجک به عنوان موجک مادر و همچنین برای آنالیز موجکی سری زمانی داده‌های آموزش در سه سطح به عنوان زیر سری انجام شد. در اینجا داده‌های ورودی مقادیر دبی روز مورد نظر و دبی روز قبل بوده است که برای هر کدام از سری داده‌ها سه زیر سری در نظر گرفته شده و همچنین از یک موجک مادر استفاده شده که زیر سری‌ها در شکل ۷ نشان داده شده است. سپس داده‌ها را وارد سیستم شبکه عصبی کرده که ۸ ورودی و ۱۰ لایه پنهان در نظر گرفته شد. ثابت شده است که پرسپترون چند لایه پس از آموزش با یکی از رایج‌ترین الگوریتم‌های یادگیری به نام الگوریتم پس انتشار خطا به طور رضایت بخشی در حل مسائل پیچیده به کار گرفته می‌شوند.

پیش‌بینی ۱ روز آینده در مرحله آزمون می‌باشد، همچنین در شکل ۱۰ پراکنش مقادیر شبیه‌سازی شده و مشاهده شده ترسیم شده است. جدول ۲ معیارهای ارزیابی شده برای مدل هیبرید موجک عصبی را که بدست آمده است نشان می‌دهد.

سطوح با ارزش سیگنال اختصاص می‌یابند. در ضمن، شکل ۸ مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی بوسیله مدل هیبرید موجک-عصبی برای پیش‌بینی ۱ روز آینده در مرحله آموزش و شکل ۹ مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی بوسیله مدل هیبرید موجک-عصبی برای




شکل ۷- (الف تا ج) زیر سری‌های جزئی حاصل از تجزیه موجک از سطح ۱ تا ۶  
Figure 7. Partial series derived from wavelet decomposition from level 1 to 6




شکل ۸- مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی بوسیله مدل هیبرید موجک-عصبی برای پیش‌بینی ۱ روز آینده در مرحله آموزش

Figure 8. Comparison of observation runoff and computational runoff by Wavelet-neural hybrid model for predicting the next day at the train stage



شکل ۹- مقایسه مقادیر رواناب مشاهداتی و رواناب محاسباتی بوسیله مدل هیبرید موجکی-عصبی برای پیش‌بینی ۱ روز آینده در مرحله آزمون  
Figure 9. Comparison of observation runoff and computational runoff by Wavelet-neural hybrid model for predicting the next day at the test stage



شکل ۱۰- پراکنش داده‌های دبی مشاهداتی و محاسباتی مشاهداتی توسط مدل هیبرید موجکی-عصبی  
Figure 10. Observational and computational discharge data distribution by the waveguide-neural hybrid model

جدول ۲- معیارهای ارزیابی مدل هیبرید موجکی-عصبی

Table 2. Evaluation criteria for wavelet-neural hybrid model

| NS   | MSE   | RMSE(m3/s) | R    | مدل               |
|------|-------|------------|------|-------------------|
| ۰/۹۱ | ۰/۰۴۳ | ۰/۰۰۴      | ۰/۹۵ | هیبرید موجکی-عصبی |

رضایت بخش این روش در پیش‌بینی می‌باشد. مقادیر معیارهای ارزیابی R و MSE در هر دو مدل توسط خود مدل محاسبه گردیده است.

جدول ۳ مقایسه معیارهای ارزیابی شده توسط دو مدل نروفازی و هیبرید موجکی-عصبی را نشان می‌دهد که با مقایسه مقادیر ضریب همبستگی و مقدارهای خطا می‌توان نتیجه گرفت که مدل هیبرید موجکی-عصبی پیش‌بینی بهتری را نسبت به مدل نروفازی داشته است.

شکل‌های ۸ و ۹ مقایسه مقادیر دبی محاسباتی و مشاهداتی در مرحله آموزش و آزمون توسط مدل هیبرید موجکی-عصبی را نشان می‌دهد که این مدل توانسته است به‌خوبی مقادیر دبی در روز بعد را در هر دو مرحله آموزش و آزمون شبیه‌سازی کند و همچنین تطابق رواناب پیش‌بینی شده و مشاهده شده را در شکل ۱۰ بصورت واضح‌تر می‌توان مشاهده نمود. که همپوشانی این نمودار بر روی نیمساز و تمرکز مقادیر حول محور یک به یک، مؤید دقت بسیار

جدول ۳- مقایسه توانایی دو مدل با بررسی مقادیر معیارهای ارزیابی شده توسط دو مدل

Table 3. Comparison of the ability of the two models by examining the values of the criteria assessed by the two models

| NS   | MSE   | RMSE  | R    | مدل               |
|------|-------|-------|------|-------------------|
| ۰/۷۷ | ۰/۱۰  | ۰/۳۲  | ۰/۸۸ | نروفازی           |
| ۰/۹۱ | ۰/۰۴۳ | ۰/۰۰۴ | ۰/۹۵ | هیبرید موجکی-عصبی |

گسسته و شبکه عصبی مصنوعی برای پیش‌بینی جریان رودخانه غیر دائمی در حوضه‌ای نیمه‌خشک ارائه دادند. کارایی نسبی هیبرید موجکی-عصبی با شبکه عصبی برای پیش‌بینی جریان ۱ تا ۳ روز بعد و برای دو رودخانه مختلف در قبرس (Kargotis در Evrychou و Xeros در Lazarides) مقایسه شد. در هر دو مورد، در هر دو رودخانه مدل هیبریدی دقت بیشتری را نسبت به مدل شبکه عصبی مصنوعی ارائه داد. نتایج نشان دادند که هیبرید موجک و شبکه عصبی یک روش بهبود برای پیش‌بینی کوتاه‌مدت در حوضه‌های نیمه‌خشک با رودخانه‌های غیر دائمی می‌باشد.

تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پایین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد و در مدل هیبریدی دقت پیش‌بینی دبی اوج که مهمترین قسمت مدل‌سازی سیل می‌باشد بالا می‌رود. همچنین دقت بالاتر مدل موجکی-عصبی نه تنها بخاطر پیش پردازش و پارتیشن‌بندی موجک به زیر سیگنال‌های مختلف است بلکه می‌تواند بخاطر توجه به تأثیر هر زیرسیگنال تجزیه‌ای به‌وسیله بزرگنمایی نسبی وزن آن زیرسیگنال باشد.

در این مطالعه از دو مدل نروفازی و هیبرید موجکی-عصبی برای پیش‌بینی جریان رودخانه در روز بعد استفاده گردید. در مدل نروفازی مقدار ضریب همبستگی ۰/۸۸ و در مدل موجکی-عصبی ۰/۹۵ و مقدار ضریب نش و کارایی مدل نروفازی ۰/۷۷ و مدل هیبرید موجکی-عصبی ۰/۹۱ نیز بدست آمده است، مقدار میانگین انحراف خطا (MBE) در مدل هیبرید موجکی-عصبی ۰/۰۴۳ و در مدل نروفازی برابر ۰/۱۰ می‌باشد که مقدار کم این معیار ارزیابی در مدل هیبرید موجکی-عصبی بیانگر وجود اختلاف کم‌تر بین مقادیر مشاهداتی و محاسباتی دبی جریان می‌باشد که نتایج حاکی از برتری کامل مدل موجکی-عصبی نسبت به مدل نروفازی در پیش‌بینی جریان روزانه می‌باشد. در شکل ۹ برازش مدل هیبرید موجکی-عصبی روی سری زمانی جریان در مرحله آزمون و برای پیش‌بینی ۱ روز بعد مشاهده می‌شود. تطابق این مدل بر روی داده‌های مشاهداتی از برازش نمودار شکل ۱۰ بر روی نیمساز نیز قابل مشاهده می‌باشد. همان‌طور که شکل نشان می‌دهد این مدل قادر به یافتن الگوی روزانه سری زمانی رواناب بوده و به خوبی توانایی شبیه‌سازی پیک‌های غیر معمول را دارا می‌باشد. نتایج این تحقیق مطابق با نتایج (۲) می‌باشد که روشی را مبنی بر تبدیل موجک

## منابع

1. Abdolahpor Azad, M.R. and M. Satari. 2015. The prediction of daily flow of the Ocherchay River using Artificial Neural Network (ANN) and its comparison with the Adaptive Fuzzy-Neural Inference System (ANFIS). Journal of Water and Soil Conservation, 22(1): 287-298 (In Persian).
2. Adamowski, J. and K. Sun. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. Journal of Hydrology, 390: 85-91.
3. Adamowski J. and K. Sun. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. Journal of Hydrology, 39(1-2): 85-91.
4. Chenard, J.F. and D. Caissie. 2008. Stream temperature modelling using artificial neural networks: application on Catamaran Brook, New Brunswick, Canada. Hydrological Processes, 22(17): 3361-3372.
5. Haykin, S. 1999. Neural Network: a comprehensive foundation, 2<sup>nd</sup> Ed., Prentice Hall., New Jersey, USA.
6. Jang, J.S. 1993. ANFIS: adaptive-network-based fuzzy inference system. IEEE Transactions on Systems Man and Cybernetics, 20(3): 665-685.
7. Katatepe, E. and M. Alci. 2005. A New Approach to Fuzzy Wavelet System Modeling, International Journal of Approximate Reasoning, 40: 302-322.
8. Kisim, O., T. Haktanir, M. Ardicoglu, O. Ozturk, E. Yalcin and S. Uludag. 2009. Adaptive neuro-fuzzy computing technique for suspended sediment estimation. Advances in Engineering Software, 40(6): 438-444.
9. Kisi, O. 2008. Stream flow forecasting using neuro-wavelet technique. Hydrological Process, 22: 4142-4152.
10. Kurtulus, B. and M. Razack. 2010. Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neurofuzzy. Journal of Hydrology, 381(1-2): 101-111.
11. Marofi, S., J. Amirmoradi and N. Parsafar. 2013. Daily Flow Prediction Using Artificial Neural Network and Neural Network (Case Study: BarandozChay River), Journal of Water and Soil Science, 23(3): 93-103 (In Persian).
12. Mallat, S. 1989. Theories for multiresolution signal decomposition: the wavelet representation, IEEE Pattern Anal and Machine Intell, 11(7): 93-674.
13. Merry, R.J.E. 2005. Wavelet theory and applications: a literature study. (DCT rapporten; Vol. 2005.053). Eindhoven: Technische Universiteit Eindhoven.
14. Menhaj, M. 2002. Basics of Neural Networks (Computational Intelligence). Amir Kabir University of Technology, 715 pp (In Persian).

15. Misiti, M., Y. Misiti, G. Oppenheim and J.M. Poggi. 1996. Wavelet Toolbox™ 4User's Guide.
16. Nourani, V., A.H. Baghanam, J. Adamowski and M. Gebremichael. 2013. Using self-organizing maps and wavelet transforms for space-time pre-processing of satellite precipitation and runoff data in neural network based rainfall-runoff modeling. *Journal of Hydrology*, 476: 228-243.
17. Nayak, P.C., B. Venkatesh, B. Krishna and KJ. Sharad. 2013. Rainfall-runoff modeling using conceptual, data driven, and wavelet based computing approach. *Journal of Hydrology*, 493: 57-67.
18. Nabizadeh, M., A. Mosaedi, M. Hesam and A.A. Dehghani. 2012. Comparison of Fuzzy logic based models in predicting daily discharge of Lighvan River, *Journal of Soil and Water Conservation Research*, 19(1): 117-134 (In Persian).
19. Nourani V., M. Komasi and A. Mano. 2009. A multivariate ANN-Wavelet approach for rainfall runoff modeling. *Water Resources Management*, 23: 2877-2894.
20. Nori, M. and H. Ghanbari. 2007. Rainfall-runoff simulation with radial-function radial neural network (RBF) basedon probabilistic neural network classification (PNN). *Compact Discs Proceedings of the 3<sup>rd</sup> Conference on Watershed Management and Water Resources Management*, Kerman University (In Persian).
21. Partal, T. and O. Kisi. 2007. Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology*, 342: 199-212.
22. Rioul, O. and M. Vetterli. 1991. Wavelets and signal processing. *IEEE SP Magazine*, 14-38.
23. Sanikhani, H. and Ö. Kisi. 2012. River flow estimation and forecasting by using two different adaptive neuro-fuzzy approaches. *Water Resource Management*, 26(6): 1715-1729 (In Persian).
24. Shefaei, M., A. Fakherifard, S. Darbandi and M. Ghorbani. 2013. River flow daily forecast using wavelet hybrid model and neural network; A case study of hydrometric station in the Aji Chai catchment area. *Journal of Irrigation and Water Engineering*, 14: 113-127 (In Persian).
25. Sifuzzaman, M., M.R. Islam and M.Z. Ali. 2009. Application of Wavelet Transform and its Advantages Compared to Fourier Transform. *Journal of Physical Sciences*, 13: 121-134.
26. Thuillard M. 2000. A Review of Wavelet Networks, Wavelets, Fuzzy wavenets and their Applications, ESIT 2000, Aachen, Germany, 14-15 Sept.
27. Vafakhah, M. 2012. Application of artificial neuro networks and adaptive neuro-fuzzy inference system of Civil Engineering, *Canadian Journal of Civil Engineering*, 39(4): 402-414.
28. Zhang, B.L. and ZY. Dong. 2001. An adaptive neural wavelet model for short term load forecasting. *Electric Power System Research*, 59: 121-129.

## Evaluation of the Neuro-Fuzzy and Hybrid Wavelet-Neural Models Efficiency in River Flow Forecasting (Case Study: Mohammad Abad Watershed)

Fariba Niromandfard<sup>1</sup>, Abbas Khasheisiuki<sup>2\*</sup> and Ali Shahidi<sup>3</sup>

1 and 3- Ph.D. Student of water resource and Associate Professor, Faculty of Agriculture, Department of Water Engineering, University of Birjand

2- Associate Professor, Faculty of Agriculture, Department of Water Engineering, University of Birjand  
(Corresponding author: abbaskhashei@birjand.ac.ir)

Received: March 3, 2018

Accepted: December 22, 2018

### Abstract

One of the most important issues in watersheds management is rainfall-runoff hydrological process forecasting. Using new models in this field can contribute to proper management and planning. In addition, river flow forecasting, especially in flood conditions, will allow authorities to reduce the risk of flood damage. Considering the importance of river flow forecasting in water resources management, various methods are used to model rivers flow in order to minimize their potential damage by using the model in drought and flood management. In this study, the neuro-fuzzy and hybrid neural-wavelet models were used to forecast the daily flow time series of the Sarmou water meter station located on the Mohammad Abad River. For this purpose, the original time series has been translated to three sub-series for 28 years using wavelet transformation and type IV Daubechies mother wavelet. The correlation coefficient value was obtained 0.88 for neuro-fuzzy model and 0.95 for hybrid wavelet -neural model, and the RMSE, MSE, and NS evaluation parameters in neural-wavelet model were 0.004, 0.043, and 0.91, respectively; these parameters in neuro-fuzzy model were 0.32, 0.10, and 0.77, respectively. Finally, the results of wavelet-neural transformation were compared with the results of neuro-fuzzy model, and it was observed that the wavelet- neural method has a higher predictive accuracy than the neuro-fuzzy method.

**Keywords:** Daily flow time series, Flow forecasting, Neuro-fuzzy model, Wavelet -neural model