

بازسازی دبی روزانه با استفاده از روش‌های شبکه عصبی و فازی - عصبی (مطالعه موردی: سرشاخه‌های حوزه آبخیز کارون)

❖ **مجتبی نساجی زواره***: استادیار موسسه آموزش عالی علمی کاربردی جهاد کشاورزی، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران.

❖ **باقر قرمز چشمه***: استادیار پژوهشکده تحقیقات حفاظت خاک و آبخیزداری، سازمان تحقیقات، آموزش و ترویج کشاورزی، تهران، ایران.

❖ **فاطمه رحیم زاده***: عضو هیئت علمی پژوهشکده هواشناسی، تهران، ایران.

چکیده

برای برآورد دبی روزانه در مدل‌های هیدرولوژی نیاز به دبی‌های پیوسته در بازه زمانی روزانه هست. تعداد سال‌های آماری متفاوت، نواقص آماری و خطای اندازه‌گیری باعث ایجاد سری‌های زمانی با پایه زمانی غیرمشترک می‌گردد. بنابراین بازسازی داده‌های دبی روزانه از اهمیت ویژه‌ای برخوردار است. این تحقیق به منظور بازسازی دبی روزانه در یکی از سرشاخه‌های رودخانه کارون و در دو مرحله انجام گرفت. در هر دو مرحله تحقیق با استفاده از داده‌های دبی روزانه دو ایستگاه بالادست و روش‌های شبکه عصبی، فازی-عصبی و رگرسیون دومتغیره دبی روزانه ایستگاه پائین‌دست بازسازی گردید. در مرحله دوم با گروه‌بندی مقادیر دبی به سال‌های خشک، نرمال و مرطوب دبی روزانه بازسازی شد. نتایج نشان داد روش‌های شبکه عصبی و فازی دارای دقت بالاتری نسبت به روش رگرسیون دومتغیره برای بازسازی دبی روزانه بود. بین مدل‌های مختلف شبکه عصبی و فازی مدل شبکه عصبی پرسپترون (MLP) دارای قابلیت مناسب‌تری نسبت به بقیه مدل‌ها است. همچنین گروه‌بندی دبی به سال‌های خشک، نرمال و مرطوب باعث کاهش خطا در بازسازی دبی روزانه گردید. بر اساس شاخص میانگین خطای نسبی (MRE) به ترتیب سال‌های نرمال، مرطوب و خشک کمترین خطا در بازسازی دبی روزانه را دارند.

واژگان کلیدی: بازسازی، دبی روزانه، شبکه عصبی، فازی-عصبی، کارون.

۱. مقدمه

پیش‌بینی دقیق دبی موضوع بحث‌برانگیز برای مدیران و مهندسين منابع آب است. این برآوردها در ابعاد مختلف زمانی کاربردهای متفاوتی دارد. روش‌های برآورد دبی شامل فرمول‌ها، مدل‌های ریاضی و مفهومی توسط محققین برای مناطق مختلف ارائه گردیده است. یکی از روش‌هایی که در سال‌های اخیر به‌طور گسترده در علوم هواشناسی و هیدرولوژی به کار گرفته شده روش شبکه‌های عصبی مصنوعی است محققین جهت برآورد دبی از این روش در مناطق مورد مطالعه مدل‌های مختلفی را پیشنهاد و از پارامترهایی همچون بارش، دما، تبخیر و تعرق، آب معادل برف، دبی ماه‌های قبل، دبی روزانه و دبی ماهانه را شبیه‌سازی نمودند [۴، ۷، ۱۱، ۱۳، ۲۰، ۲۱، ۲۳، ۲۴، ۲۵].

در ایستگاه‌های هیدرومتری اندازه‌گیری دبی در بازه زمانی روزانه صورت می‌پذیرد. مجموعه داده‌های ثبت شده در این ایستگاه‌ها را سری‌های زمانی هیدرولوژیکی می‌نامند. این سری‌ها با استفاده از روش‌های آماری تحلیل و در برنامه‌ریزی، مدیریت و کنترل سیستم‌های منابع آب به کار گرفته می‌شود. یکی از مزایای سری‌های زمانی این است که نواقص آماری، عدم پیوستگی و دوره‌های آماری کوتاه‌مدت را نشان می‌دهد. نواقص آماری در سری‌های زمانی هیدرولوژیکی مربوط به نواقص دستگاه‌های اندازه‌گیری (الکتریکی، مکانیکی)، اثرات پدیده‌های طبیعی (زلزله، سیل، لغزش و غیره)، انتقال داده‌ها، ذخیره و فرآیند بازیابی است. بنابراین لازم است قبل از استفاده از آن‌ها نسبت به تکمیل، تصحیح و تهیه پایه زمانی مشترک آماری اقدام نمود [۱ و ۱۸].

روش‌های مختلفی برای بازسازی داده‌های هواشناسی و هیدرولوژی مورد استفاده قرار می‌گیرد. هر روش برای داده‌های خاصی کاربرد دارد، به‌عنوان مثال استفاده از نزدیک‌ترین ایستگاه، نسبت نرمال و یا همبستگی برای برآورد داده‌های دما و بارش ماهانه و سالانه کاربرد زیادی

دارد [۱۰ و ۲۲].

بازسازی داده‌های سالانه و ماهانه در هواشناسی و هیدرولوژی امری متداول بوده ولی بازسازی داده‌های روزانه با استفاده از روش‌های معمول و سنتی مرسوم نمی‌باشد. بازسازی سری‌های زمانی دبی در غرب آفریقا با استفاده از ۱۰ روش مورد بررسی قرار داده شد روش رگرسیون و درون‌یابی روش‌های مناسب‌تری برای بازسازی دبی روزانه در این منطقه بوده‌اند [۵].

بازسازی سری‌های زمانی هواشناسی و هیدرولوژی با استفاده از روش شبکه عصبی در ابعاد زمانی مختلف توسط محققین مورد بررسی قرار گرفته است. برای مثال با استفاده از روش فازی عصبی دبی ده روزه را بازسازی نمودند [۲]. نتایج نشان‌دهنده توانایی این روش در بازسازی دبی است. همچنین در تحقیقی، با استفاده از روش شبکه عصبی و گروه‌بندی داده‌ها به فصل‌های خشک و مرطوب، دبی ماهانه را بازسازی نمودند [۱۶]. از طرفی در تحقیق دیگر، نواقص آماری داده‌های دبی ماهانه را با استفاده از مقادیر ایستگاه‌های مجاور و روش‌های نسبت نرمال، همبستگی بین ایستگاه‌ها و شبکه‌های عصبی مصنوعی مورد بررسی قرار دادند. نتایج نشان داد مدل شبکه‌های عصبی مصنوعی دارای کارایی مناسبی جهت پیش‌بینی داده‌های مفقود شده هیدرولوژی است [۱۰].

اما برای بررسی کارایی این روش در بازسازی داده‌های روزانه هواشناسی و هیدرولوژی نیاز به تحقیقات بیشتری است. که در تحقیقی با استفاده از ۶ مدل شبکه عصبی مصنوعی مقادیر بارش، دمای حداکثر و حداقل روزانه را بازسازی نمودند [۹]، با استفاده از روش‌های شبکه عصبی و استفاده از دو ایستگاه بالادست و داده‌های دبی با تأخیر زمان، دبی روزانه را بازسازی کردند [۸] و به‌منظور بازسازی بارش از روش‌های شبکه عصبی، رگرسیون درختی و ترکیب شبکه عصبی و رگرسیون درختی برای مدل‌سازی بارش-رواناب در مدل SWAT استفاده نمودند [۱۷]. هرچند که مدل‌های شبکه عصبی

۲.۲. روش‌های مورد مطالعه

شبکه عصبی مصنوعی مدل ریاضی است که توانایی مدل‌سازی و ایجاد روابط غیرخطی برای درونیابی را دارا است. به باور بیشتر پژوهشگران، شبکه عصبی مصنوعی در تحلیل مسائل ناشناخته و پیچیده، عملکرد خوبی از خود نشان می‌دهد و با برخورداری از قابلیت تشخیص الگو، رابطه خوبی بین ورودی و خروجی داده‌ها برقرار می‌کند [۱۹]. همچنین در قیاس با دیگر الگوها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی از خود نشان می‌دهد. علت این امر پردازش توزیعی^۴ اطلاعات در آن است. به‌طوری‌که عمل پردازش کاملاً موازی صورت می‌گیرد و به‌جای اینکه تمام بار محاسبه به یک واحد پردازشگر تحمیل شود، تعداد زیادی از واحدهای پردازشگر هم‌زمان وارد عمل شده و در نتیجه با کم شدن سهم هر یک از آن‌ها، تأثیر منفی بسیاری در عملکرد شبکه و خروجی آن نمی‌گذارد. یکی از متداول‌ترین مدل‌های شبکه عصبی مصنوعی، مدل شبکه چندلایه پرسپترون^۵ (MLP) است که از یک لایه ورودی، لایه پنهان و یک لایه خروجی تشکیل شده است. یک لایه گروهی از نرون‌ها (واحد پردازشگر) است که ارتباط بین ورودی و خروجی می‌باشد. شبکه‌های MLP اغلب شبکه‌های چندلایه‌ای پیش‌خور^۶ نیز نامیده می‌شود. در این شبکه‌ها تعداد نرون‌های لایه ورودی برابر با تعداد عناصر بردار ورودی و تعداد نرون‌های لایه خروجی برابر با تعداد عناصر بردار خروجی است. تعیین تعداد نرون‌های لایه پنهان بسیار پیچیده بوده و عمدتاً به‌طور تجربی به دست می‌آید.

و رگرسیون درختی بازسازی را بهتر از روش‌های قبلی برآورد کردند اما ترکیب مدل رگرسیون درختی و شبکه عصبی دقت بازسازی را نسبت به دو مدل قبلی افزایش داد.

اگرچه روش‌های مختلفی برای بازسازی آماری پارامترهای هواشناسی و هیدرولوژی در مقیاس زمانی ماهانه وجود دارد. اما تحقیقاتی در زمینه بازسازی پارامترهای هواشناسی و هیدرولوژی در مقیاس زمانی روزانه در کشورمان صورت نگرفته است. علاوه بر این حجم زیاد داده‌های دبی روزانه و تأثیرپذیری سریع دبی روزانه نسبت به تغییرات عوامل مختلف در حوزه آبخیز، بازسازی دبی روزانه را مشکل می‌سازد.

این مقاله در نظر دارد تا با استفاده از روش‌های شبکه عصبی مصنوعی، عصبی-فازی و رگرسیون دومتغیره ضمن مقایسه روش‌های مختلف، مناسب‌ترین روش را برای بازسازی سری‌های زمانی دبی روزانه ارائه نماید.

۲. روش‌شناسی تحقیق

۱.۲. معرفی منطقه مورد مطالعه

منطقه مورد مطالعه در استان کهگیلویه و بویر احمد واقع شده و جزء سرشاخه‌های حوزه آبخیز کارون محسوب می‌شود. برای بررسی روش‌های بازسازی دبی روزانه سه ایستگاه شاه‌مختار (۲۰۵-۲۱)، کبکیان (۲۱۱-۲۱) و پاپاوه (۲۱۵-۲۱) انتخاب شدند. داده‌های دبی روزانه برای سه ایستگاه در دوره زمانی ۱۳۵۱ الی ۱۳۸۰ انتخاب گردید. حوزه‌های بالادست ایستگاه‌های فوق مناطق کوهستانی کارون را شامل شده و در بالادست آن‌ها سازه‌های تأثیرگذار بر دبی روزانه تأسیس نشده است. جداول (۱) و (۲) ویژگی‌های مرفومتری و شاخص‌های آماری میانگین^۱ و انحراف استاندارد^۲ و ضریب چولگی^۳ برای ایستگاه‌های بالادست و خروجی را نشان می‌دهد. شکل (۱) موقعیت حوزه و ایستگاه‌های هیدرومتری را نشان می‌دهد.

¹ Mean

² Standard deviation

³ Skewness

⁴ Distributed processing

⁵ Multilayer perceptron network

⁶ Multilayer feedforward network


جدول ۱. مشخصات آماری دبی روزانه ایستگاه‌های مورد مطالعه*

مدل	کد ایستگاه	۲۱-۲۰۵			۲۱-۲۱۱			۲۱-۲۱۵		
		میانگین	انحراف معیار	چولگی	میانگین	انحراف معیار	چولگی	میانگین	انحراف معیار	چولگی
عمومی	۲۲/۳۹	۳۹/۱۳	۵/۵۳	۱۷/۴۴	۲۶/۸۶	۶/۲	۵۰/۲۱	۶۴/۸۸	۴/۳۴	
خشک	۱۱/۲۷	۱۴/۷	۴/۳۴	۹/۹۶	۱۱/۵۷	۴/۷۶	۲۸/۲۹	۲۶/۷۸	۳/۷۷	
نرمال	۲۰/۹۱	۲۹/۷۳	۳/۸۸	۱۵/۸۷	۲۰/۱۱	۴/۶۸	۴۷/۲۸	۴۸/۲۵	۳/۴۶	
تر	۳۷/۲۴	۵۸/۶۸	۴/۰۸	۲۷/۹۹	۳۹/۶۶	۴/۸۱	۷۹/۷۸	۹۴/۶۱	۳/۱۱	

*واحدها برحسب مترمکعب بر ثانیه است.

جدول ۲. ویژگی‌های مرفومتری حوزه‌های مورد مطالعه

مساحت حوزه (کیلومتر مربع)	حداقل ارتفاع (متر)	حداکثر ارتفاع (متر)	طول حوزه (کیلومتر)	متوسط شیب آبراهه اصلی (در صد)	محیط حوزه (کیلومتر)	کد ایستگاه
۱۰۶۳/۳۷	۱۷۲۴	۲۹۳۳	۵۵/۸۹	۱۳	۱۸۷/۹۵	۲۱-۲۰۵
۸۷۵/۴۶	۱۵۵۹	۲۶۳۹	۴۹/۷۷	۱/۵۲	۱۷۵/۶۷	۲۱-۲۱۱
۲۶۹۰/۹۸	۱۵۰۰	۲۹۳۳	۹۵/۱۴	۱/۱۶	۲۹۴/۳۵	۲۱-۲۱۵



شکل ۱. موقعیت منطقه مورد مطالعه

در تحقیق کاملاً به‌طور تصادفی انتخاب شد. در روش MLP و FF از تابع انتقال^۷ سیگموئیدی و الگوریتم آموزش لونیبرگ مارکوات^۸ به دلیل دارا بودن همگرایی سریع انتخاب گردید [۱۵]. تعداد متغیر ورودی در شبکه در کلیه مراحل تحقیق ۲ ورودی دبی روزانه ایستگاه‌های بالادست بوده و تعداد نرون‌های لایه پنهان با روش سعی و خطا تعیین گردید، تعداد نرون‌های مورد استفاده از ۱ تا ۱۱ نرون مورد بررسی قرار گرفته است. در روش CANFIS از تابع عضویت^۹ بل^{۱۰} و گوسین^{۱۱} و دو الگوریتم آموزش لونیبرگ مارکوات و مومنت^{۱۲} استفاده گردید. بدین منظور ابتدا داده‌های دبی روزانه کلیه ایستگاه‌های مورد مطالعه جمع‌آوری و پس از بررسی اولیه مدل‌سازی شبکه، با استفاده از نرم‌افزار نروسولوشن^{۱۳} نسخه ۵ انجام گرفت.

به‌منظور بررسی توانمندی‌های شبکه‌های طراحی شده برای پیش‌بینی دبی روزانه و مقایسه آن با داده‌های مشاهداتی (واقعی)، محققین مختلف از شاخص‌های آماری متفاوتی استفاده می‌نمایند. متوسط خطای مطلق^{۱۴} (MAE)، ضریب همبستگی^{۱۵} (R)، متوسط خطای نسبی^{۱۶} (MRE) و میانگین مربع خطا^{۱۷} (MSE) شاخص‌های آماری به کار گرفته شده در این بررسی بوده‌اند. معادلات (۲)، (۳)، (۴) و (۵) رابطه معیارهای آماری فوق را ارائه می‌دهند.

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_{obsi} - x_{anni}| \quad (2)$$

ساختار شبکه به توابع غیرخطی نیاز دارد که به‌طور پیوسته مشتق‌پذیر باشند. اغلب اوقات این توابع به شکل‌های تابع سیگموئیدی، تانژانت هیپربولیک، خطی، باینری و گوسی در نظر گرفته می‌شوند. از میان تابع‌های ذکر شده تابع سیگموئیدی بیشترین کاربرد را در حل مسائل مهندسی دارد که یکی از دلایل استفاده از آن سادگی مشتق آن است که استفاده از روش پس انتشار خطا^۱ را بسیار ساده می‌کند [۱۲]، این تابع به شکل زیر تعریف می‌شود.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (1)$$

X ورودی به یک نرون در شبکه عصبی و f(x) خروجی متناظر آن نرون می‌باشد.

این تحقیق با استفاده از ۴ روش و در دو مرحله صورت پذیرفت. روش‌های مورد استفاده در این مقاله عبارت از روش‌های شبکه عصبی چندلایه پرسپترون (MLP)، شبکه عصبی پیش‌خور (FF)، شبکه عصبی-فازی^۲ (CANFIS) و رگرسیون خطی^۳ (LR) می‌باشد. در اولین مرحله برای کل دوره آماری ۲۸ سال، ۴ مدل مورد بررسی قرار گرفتند. در مرحله دوم سال‌های خشک، تر و نرمال مبنای تقسیم‌بندی داده‌ها برای ارزیابی مدل‌ها در نظر گرفته شدند. به‌منظور تهیه مدل‌های مناسب شبکه عصبی و بررسی قابلیت این روش ابتدا لازم است معماری شبکه صورت گیرد. برای هر مدل شبکه عصبی متغیرهای ورودی از ایستگاه‌های هیدرومتری بالادست گرفته شد. در کلیه مراحل تحقیق ۶۰ درصد داده‌ها برای آموزش^۴، ۱۵ درصد ارزیابی^۵ و ۲۵ درصد برای تست^۶ استفاده گردید. داده‌های مورد استفاده

⁷ Transfer function

⁸ Levenberg-Marquardt

⁹ Membership function

¹⁰ Bell

¹¹ Gaussian

¹² Momentum

¹³ Neurosolutions

¹⁴ Mean absolute error

¹⁵ Correlation coefficient

¹⁶ Mean relative error

¹⁷ Mean square error

¹ Back propagation

² Co-active neuro-fuzzy inference system

³ Linear regression

⁴ Training

⁵ Cross validation

⁶ Testing

داده توسط شبکه و Π تعداد داده‌ها می‌باشند. با توجه به دسته‌بندی داده‌ها برای مقایسه درون گروه‌ها از تمامی معیارها می‌توان استفاده نمود. اما برای مقایسه بین گروه‌ها از معیار شاخص آماری MRE استفاده گردید.

$$R = \frac{\sum_{i=1}^n (x_{obsi} - x_{anni})(x_{anni} - \bar{x}_{ann})}{\sqrt{\sum_{i=1}^n (x_{obsi} - \bar{x}_{obs})^2 (x_{anni} - \bar{x}_{ann})}} \quad (3)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_{obsi} - x_{anni})^2 \quad (4)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(x_{obsi} - x_{anni})}{x_{obsi}} \right| \quad (5)$$

۳. نتایج

پس از آموزش و تست داده‌های دبی روزانه با استفاده از روش‌های MLP، FF، CANFIS و LR جمعاً ۱۰۸ مدل آموزش و سپس تست گردید. جدول (۳) نتایج تست مناسب‌ترین مدل‌ها برای ایستگاه ۲۱۵-۲۱ را نشان می‌دهد.

x_{obs} و x_{ann} به ترتیب مقدار مشاهده‌ای و برآورد شده

جدول ۳. نتایج تست مناسب‌ترین مدل‌ها بر اساس سری کامل دبی روزانه برای بازسازی دبی روزانه ایستگاه ۲۱۵-۲۱ (مترمکعب بر ثانیه)

گروه	مدل	MSE	R	MRE	MAE
۱	CANFIS	۴۲۰/۸۶	۰/۹۴۸	۰/۱۶۷	۸/۱۱
	MLP	۳۹۰/۲۸	۰/۹۵۱	۰/۱۶۷	۸
	FF	۳۸۹/۹۹	۰/۹۵۱	۰/۱۶۵	۷/۹۵
	LR	۳۷۴/۳۷	۰/۹۵	۰/۲۴۷	۸/۸۹

جدول ۴. نتایج تست مناسب‌ترین مدل‌ها بر اساس گروه‌بندی سری‌های دبی روزانه برای بازسازی دبی روزانه ایستگاه ۲۱۵-۲۱ (مترمکعب بر ثانیه)


گروه	مدل	MSE	R	MRE	MAE
۱	CANFIS	۲۰۵/۲۸	۰/۹۵۳	۰/۱۳	۶/۲۶
	MLP	۲۰۳/۶۸	۰/۹۵۵	۰/۱۱۶	۵/۷۹
	FF	۲۲۹/۰۲	۰/۹۴۹	۰/۱۲۸	۶/۲۴
	LR	۲۱۸/۴۳	۰/۹۵۴	۰/۱۸۱	۷/۹۶
۲	CANFIS	۷۳/۹	۰/۹۴۶	۰/۱۷۵	۴/۲۹
	MLP	۶۹/۵۳	۰/۹۵	۰/۱۶۹	۴/۲۴
	FF	۷۳/۴۳	۰/۹۴۷	۰/۱۷۵	۴/۳۵
	LR	۸۲/۸۹	۰/۹۴۴	۰/۲۰۳	۴/۷۷
۳	CANFIS	۱۴۳۴/۵۶	۰/۹۳۹	۰/۱۴۶	۱۴/۷
	MLP	۱۰۳۴/۵۱	۰/۹۵۳	۰/۱۳۳	۱۲/۹
	FF	۱۰۸۴/۲۷	۰/۹۵۲	۰/۱۴۷	۱۳/۱۷
	LR	۱۱۵۸/۸۹	۰/۹۴۲	۰/۲۶۶	۱۵/۶۸

بر اساس نتایج جداول (۳) و (۴) در هر دو مرحله مدل‌سازی روش‌های شبکه عصبی و فازی-عصبی دقت بالاتری را در بازسازی دبی روزانه نسبت به روش رگرسیون دومتغیره دارند. کمترین مقادیر MRE در گروه مقادیر عمومی، نرمال، خشک و مرطوب به ترتیب ۰/۱۶۵، ۰/۱۱۶، ۰/۱۶۹ و ۰/۱۳۳ مربوط به مدل‌های شبکه عصبی می‌باشد. در مدل عمومی و مدل‌های حاصل از گروه‌بندی، روش‌های شبکه عصبی و فازی دارای توانایی نزدیک به همدیگر در بازسازی دبی روزانه نسبت به روش رگرسیون دومتغیره می‌باشند. بین روش‌های MLP، FF و CANFIS در مدل عمومی، شبکه‌های FF و MLP دارای قابلیت مناسب‌تری نسبت به روش CANFIS می‌باشد. مطابق نتایج جدول (۳) مقایسه مدل‌های MLP، FF و CANFIS، کمترین مقادیر MAE، MRE و MSE را مدل FF دارد هر چند مدل‌های MLP و CANFIS نیز دارای نتایج مشابهی می‌باشند.


در مرحله دوم تحقیق داده‌ها به سه گروه سال‌های خشک، نرمال و مرطوب دسته‌بندی گردیدند. نتایج جدول (۴) بر اساس گروه‌بندی داده‌ها به سال‌های خشک، نرمال و مرطوب حاکی از افزایش توانایی مدل‌های شبکه عصبی و فازی در بازسازی دبی روزانه به صورت گروه‌بندی می‌باشد. در گروه مقادیر عمومی کمترین مقادیر شاخص‌های آماری مربوط به مدل FF می‌باشد هر چند که مدل MLP و CANFIS نیز دارای مقادیر مناسبی هستند. در تمامی گروه داده‌ها اعم از خشک، نرمال و مرطوب کمترین مقادیر MRE، MSE و MAE و بیشترین مقدار R متعلق به مدل MLP می‌باشد بنابراین این مدل دارای بیشترین دقت در بازسازی دبی روزانه است. در این مرحله نتایج نشان می‌دهد که گروه‌های مقادیر نرمال، مرطوب و خشک به ترتیب قابلیت بیشتری برای بازسازی دبی روزانه را دارند.

برای مقایسه بین گروه‌های مختلف با یکدیگر و با مدل عمومی از شاخص آماری متوسط خطای نسبی (MRE) استفاده گردید. شکل (۲) مقایسه بین مقادیر MRE را از روش‌های مختلف به منظور بازسازی دبی روزانه را نشان می‌دهد. در این نمودار تفاوت مقادیر MRE از روش LR با روش‌های MLP، FF و CANFIS در گروه‌های مختلف مشخص می‌باشد. در روش LR بیشترین مقدار MRE به ترتیب مربوط به گروه مقادیر تر، عمومی، خشک و نرمال می‌باشد. کمترین مقدار MRE در بین گروه‌های مختلف مربوط به گروه مقادیر نرمال می‌باشد. مقدار MRE در مدل MLP در گروه نرمال، تر و خشک به ترتیب برابر ۰/۱۱۶، ۰/۱۳۳ و ۰/۱۶۹ هستند. بنابراین بر اساس شاخص آماری MRE در مدل MLP دقت بازسازی دبی روزانه به ترتیب در گروه‌های نرمال، تر و خشک کاهش می‌یابد. مدل FF در گروه عمومی دارای مقدار MRE کمتری نسبت به مدل MLP و CANFIS می‌باشد. هر چند که مدل MLP نیز دقت مشابهی با مدل FF دارد.


مقایسه بین مقادیر واقعی و برآورد شده از روش MLP در شکل‌های (۳) الی (۶) نشان داده شده است. مقایسه شکل‌های (۳) الی (۶) نشان می‌دهد دسته‌بندی داده‌ها بر اساس سال‌های خشک، نرمال و مرطوب مدل‌های مناسب‌تری را نسبت به مدل عمومی ارائه می‌نماید. تجمع بیشتر نقاط پیرامون خط حاصل نشان می‌دهد مطابق شکل (۶) گروه مقادیر نرمال نسبت به بقیه گروه‌ها توانایی بیشتری را در بازسازی دبی روزانه دارد. علاوه بر این رابطه بین مقادیر مشاهداتی و برآورد شده توسط روش MLP و ضریب همبستگی نشان می‌دهد گروه‌بندی مقادیر دبی می‌تواند به عنوان یک روش برای بهبود بازسازی سری‌های زمانی دبی روزانه مورد استفاده قرار گیرد.




شکل ۲. مقایسه مقدار MRE در مدل‌های مختلف شبکه عصبی و فازی




شکل ۳. مقایسه مقادیر دبی روزانه برآورد شده در ایستگاه ۲۱۵-۲۱ از روش MLP و مقادیر مشاهداتی در مدل عمومی



شکل ۴. مقایسه مقادیر دبی روزانه برآورد شده در ایستگاه ۲۱۵-۲۱ از روش MLP و مقادیر مشاهداتی در مدل سال‌های خشک



شکل ۵. مقایسه مقادیر دبی روزانه برآورد شده در ایستگاه ۲۱۵-۲۱ از روش MLP و مقادیر مشاهداتی در مدل سال‌های مرطوب



شکل ۶. مقایسه مقادیر دبی روزانه برآورد شده در ایستگاه ۲۱۵-۲۱ از روش MLP و مقادیر مشاهداتی در مدل سال‌های نرمال

۴. بحث و نتیجه‌گیری

شبکه عصبی پیش‌خور (FF)، شبکه عصبی پرسپترون (MLP)، شبکه فازی-عصبی (CANFIS) و رگرسیون دومتغیره (LR) در دو مرحله بر روی این داده‌ها بکار گرفته شد.

در مرحله اول برای کل دوره آماری با استفاده از ۴ روش دبی روزانه بازسازی گردید. نتایج نشان داد که روش‌های شبکه عصبی و فازی-عصبی دارای دقت بالاتری نسبت به روش رگرسیون دومتغیره می‌باشد. در بین روش‌های مختلف شبکه‌های عصبی و فازی روش‌های FF، MLP و CANFIS دارای بیشترین دقت می‌باشد. در مرحله دوم کل سری‌های زمانی دبی روزانه به سه گروه

سری‌های زمانی طولانی‌مدت در تحلیل تغییرپذیری زمانی، روند وقایع حد، تخمین ریسک و احتمال وقوع موردنیاز است. در بین سری‌های زمانی دبی روزانه دارای نواقص آماری زیادی می‌باشد. بنابراین به‌منظور تهیه پایه زمانی مشترک آماری، بازسازی این داده‌ها موردنیاز می‌باشد. به‌منظور ارائه یک روش مناسب بازسازی به‌طور موردی از داده‌های دبی روزانه سه ایستگاه در سرشاخه‌های رودخانه کارون استفاده گردید. دبی روزانه ایستگاه پائین‌دست رودخانه با استفاده از دبی روزانه دو ایستگاه بالادست بازسازی شد. در این تحقیق از ۴ مدل

سال‌های خشک، نرمال و مرطوب تقسیم گردید و از ۴ روش مورد استفاده در مرحله اول تحقیق بازسازی دبی روزانه صورت پذیرفت. نتایج نشان داد روش‌های شبکه عصبی و عصبی-فازی دارای دقت بالاتری نسبت به روش رگرسیون دومتغیره می‌باشد. در بین داده‌های گروه‌بندی شده دقیق‌ترین مدل شبکه عصبی MLP است. این نتیجه با تحقیقات [۹] در بازسازی بارش، دمای حداکثر و حداقل روزانه مطابقت دارد. کمترین مقادیر MRE متعلق به مدل‌های شبکه عصبی و فازی-عصبی در گروه‌های مختلف نسبت به مدل‌های رگرسیونی می‌باشد. نتایج

تحقیق [۱۰] نیز نشان می‌دهد که روش شبکه عصبی و فازی دارای قابلیت مناسب‌تری نسبت به روش‌های سنتی است. شبکه عصبی MLP به ترتیب برای گروه‌های مقادیر نرمال، مرطوب و خشک دارای کمترین مقدار می‌باشد. مقایسه مقادیر MRE در دو مرحله تحقیق نشان می‌دهد که گروه‌بندی داده‌ها می‌تواند به‌عنوان یک روش مناسب برای افزایش دقت در بازسازی دبی روزانه مورد استفاده قرار گیرد.

References

- [1] Alizadeh, A. (2004). *Principals of applied hydrology*, 18^{ed} Edition, University of Imam Reza press.
- [2] ASCE Task Committee, (2000a). Artificial neural networks in Hydrology I. *Journal of Hydrologic Engineering*, 5 (2), 115–123.
- [3] ASCE Task Committee, (2000b). Artificial neural networks in Hydrology II. *Journal of Hydrologic Engineering*, 5 (2), 124–132.
- [4] Birikundavyi, S., Labib, R., Trung, H.T. and Rousselle, J. (2002). Performance of neural networks in daily streamflow forecasting. *Journal of Hydrologic Engineering*, 7(5), 392-398.
- [5] Boakye, P.G. and Schultz, G. A. (1994). Filling gaps in runoff time series in West Africa. *Hydrological Sciences - Journal- des Sciences Hydrologiques*, 39(6), 621-636.
- [6] Chang, F.J, Hu, H. and Chen, Y. (2001). Counter propagation fuzzy-neural network for streamflow reconstruction. *Hydrological Processes*, 15, 219–232.
- [7] Chau, K.W., Wu, C.L. and Li, Y.S. (2005). Comparison of several flood forecasting models in Yangtze River. *Journal of Hydrologic Engineering*, 10(6), 485-491.
- [8] Cigizoglu, H.K. (2005). Application of generalization regression neural networks to intermittent flow forecasting and estimation. *Journal of Hydrologic Engineering*, 10(4), 336-341.
- [9] Coulibaly, P. and Evora, N.D. (2007). Comparison of neural network methods for infilling missing daily weather records. *Journal of hydrology*, 341, 27-41.
- [10] Dastorani, M.T., Mogadamnia, A.R. and Talebi, A. (2009). Evaluation and comparison of the efficiency of different methods for hydrological data reconstruction. The 5th National Conference on Watershed Management, University of Gorgan, Iran.
- [11] Elshorbagy, A. and Simonovic, S.P. (2000). Performance evaluation of artificial neural networks. *Journal of Hydrologic Engineering*, 5(4), 424-427.
- [12] Emamgholizadeh, S., Kashef Por, S.M. and Torabi Podeh, H. (2005). Using artificial neural networks to predict discharge in Balarod River of Khuzestan province, The 5th Iranian Hydraulic Conference, Shahid Bahaonar University of Kerman, Iran.
- [13] Garbrecht, J.D. (2006). Comparison of three alternative ANN designs for monthly rainfall-runoff simulation. *Journal of Hydrologic Engineering*, 1(5), 502-505.
- [14] Govindaraju, R.S. and Ramachandra, R.A. (2000). *Artificial Neural Networks in Hydrology*. Kluwer Academic Publisher.
- [15] Hagan, M.T. and Menhaj, M.B. (1994). Training feedforward techniques with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5(6), 989-993.
- [16] Khalil, M., Panu, U.S. and Lennox, W.C. (2001). Groups and neural networks based streamflow data infilling procedures. *Journal of Hydrology*, 241, 153-176.
- [17] Kim J.W., Pachepsky, Y.A. (2010). Reconstructing missing daily precipitation data using regression trees and artificial neural networks for SWAT streamflow simulation. *Journal of Hydrology*, 394(3-4), 305-314.
- [18] Mahdavi, M. (2002). *Applied hydrology*, 2^{ed} Edition, University of Tehran press.
- [19] Menhaj, M.B. (2002). *Fundamentals of neural networks*, Amirkabir University of Technology press.
- [20] Nassaji Zavareh, M. and Safie, A. (2007). Forecasting of monthly discharge using artificial neural network. 3th National Congress on Civil Engineering, University of Tabriz, Iran.
- [21] Raghuwanshi, N.S., Singh, R. and Reddy, L.S. (2006). Runoff and sediment yield modeling using artificial neural networks: upper Siwane River, India. *Journal of Hydrologic Engineering*, 11(1), 71-79.

- [22] Sadatinejad, S.J. (1997). Statistical compression of the reconstruction methods of precipitation data in Isfahan province. MSc Thesis, Tarbiat Modares University.
- [23] Sudheer, K.P. (2005). Knowledge extraction from trained neural network river flow models. *Journal of Hydrologic Engineering*, 10(4), 264-269.
- [24] Tokar, A.S. and Johnson, P.A. (1999). Rainfall-runoff modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 4(3), 232-239.
- [25] Tokar, A.S. and Markus, M. (2000). Precipitation-runoff modeling using artificial neural networks and conceptual models. *Journal of Hydrologic Engineering*, 5(2), 156-161.