

عملکرد شبکه عصبی مصنوعی در پیش‌بینی و تحلیل فرایندهای هیدرولوژیک (مطالعه موردی: کمبود آب حوضه آبخیز نازلوچای در استان آذربایجان غربی)

سعید فرزین^{۱*}، حجت کرمی^۲، مهسا دوست‌محمدی^۳، آنسه قنبری^۴ و الهام ضمیری^۵

۱ و ۲. استادیار، گروه مهندسی آب و سازه‌های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان
۳ و ۴. دانشجوی کارشناسی ارشد مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه سمنان

(تاریخ دریافت ۱۳۹۵/۰۸/۰۹؛ تاریخ تصویب ۱۳۹۵/۱۰/۱۰)

چکیده

بارش یکی از فرایندهای هیدرولوژیک است که تأثیر زیادی در کنترل مدیریت منابع آب دارد. کمبود بارش سبب به‌وجود آمدن مشکلات فراوانی از جمله کمبود آب شرب می‌شود. به‌علت اهمیت مسئله کمبود آب، استفاده از روش‌های نوین به‌منظور پیش‌بینی فرایندهای هیدرولوژیک تأثیر زیادی در برنامه‌ریزی و مدیریت منابع آب خواهد داشت. از این‌رو، در تحقیق حاضر کمبود آب ماهانه در حوضه نازلوچای طی یک دوره آماری ۳۹ ساله (۱۳۵۲-۱۳۹۱) با استفاده از مدل شبکه عصبی مصنوعی و مدل بهبود یافته موجک- شبکه عصبی، شبیه‌سازی، پیش‌بینی و تحلیل شده است. عملکرد این دو مدل توسط معیارهای خطای ضریب همبستگی، ضریب تبیین و جذر میانگین مربعات خطا ارزیابی شد. بنا بر نتایج به‌دست آمده، مدل موجک- شبکه عصبی با ضریب همبستگی ۰/۹۶ و ۰/۹۴۵ که به‌ترتیب مختص به حالت آموزش و آزمون است، نسبت به شبکه عصبی مصنوعی توانایی بیشتری برای پیش‌بینی کمبود آب داشت. در ادامه، مقادیر کمبود آب ماهانه در این حوضه طی سال‌های ۱۳۹۲ تا ۱۳۹۹ پیش‌بینی شده است. نتایج نشان می‌دهند روند کمبود آب همچنان مانند گذشته باقی است. البته، متوسط میزان کمبود در ۸ سال آینده تقریباً ۲/۹۵ میلیون مترمکعب تخمین زده شد. در حالی که همین پارامتر برای ۳۹ سال گذشته ۴/۰۴ میلیون مترمکعب بوده است. از این‌رو، نیاز است که برای سال‌های آینده اقدامات لازم انجام شود و با برنامه‌ریزی مدیریتی دقیق برای بهره‌برداری از منابع آب (کشاورزی، صنعت، شرب و...)، کاهش میزان کمبود آب در سال‌های آتی ممکن شود.

کلیدواژگان: الگوریتم موجک، شبکه بهینه، کمبود آب، نويزردایی، هوش مصنوعی.

مقدمه

مطالعه فرایندهای هیدرولوژیک در مدیریت منابع آب، از موارد اساسی در بهره‌برداری و مدیریت کمی و کیفی این منابع به‌شمار می‌آید. بارش از جمله فرایندهای هیدرولوژیک است که کمبود آن سبب به‌وجود آمدن خشکسالی و کمبود آب می‌شود. عرضه و تأمین آب برای نیازهای مستقیم انسان، از جمله شرب، یک هدف نهایی است [۱]. از سوی دیگر، آب عرضه‌شده به کشاورزی و صنعت به‌عنوان عاملی برای تولید، حیاتی است. دنیای امروز، همراه با افزایش جمعیت، با رشد روزافزون نیازهای مختلف غذایی، آب و انرژی مواجه است. افزایش نیازها، بروز خشکسالی‌های مکرر و محدودیت استفاده دوباره از حجم شایان توجهی از منابع آب به‌دلیل آلودگی‌ها و محدودیت‌های زیست‌محیطی، نیاز به نگرش سیستمی در مدیریت منابع آب را دوچندان کرده است. رشد روزافزون جمعیت و توسعه اراضی کشاورزی برای تولید، توزیع ناهمگن زمانی و مکانی آب شیرین به‌لحاظ کمی از یک طرف و محدودیت‌ها و مشکلات روزافزون کیفی از طرف دیگر به نبود تعادل در عرضه و تقاضای آب و ناپایداری در حوضه آبریز منجر شده و به یکی از چالش‌های مهم قرن حاضر در بسیاری از کشورها تبدیل شده است [۱].

پیشرفت تکنولوژی سبب شده است بشر در جست‌وجوی روش‌های نوین برای پیش‌بینی پارامترهای مختلف باشد. مدل‌های هوش مصنوعی از روش‌های مورد علاقه مهندسان هستند که سبب سهولت در انجام محاسبات می‌شوند. از روش‌های هوش مصنوعی در پیش‌بینی بسیاری از زمینه‌های منابع آب استفاده شده است. شبکه عصبی مصنوعی ترکیبی از بهره‌برداری از عناصر ساده است که این عناصر از سیستم عصبی الهام گرفته شده است.

شبکه عصبی با برخورداری از قابلیت تشخیص الگو، رابطه خوبی بین داده‌های ورودی و خروجی برقرار می‌کند. این روش در قیاس با دیگر روش‌ها، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی دارد. مدل‌های شبکه عصبی مصنوعی با آموزشی که دیده‌اند می‌توانند، بدون ایجاد رابطه صریح ریاضی، رفتار سیستم را پیش‌بینی کنند [۲].

هال و همکارانش با استفاده از شبکه‌های عصبی مصنوعی بارش تگزاس را پیش‌بینی کردند. نتایج تحقیق آنها نشان داد همبستگی خطی بین مقادیر پیش‌بینی‌شده بارش با مقادیر واقعی برابر ۰/۹۵ است [۳]. سحای و همکارانش (۲۰۰۰) با

استفاده از شبکه عصبی مصنوعی بارش فصل تابستان را در هند پیش‌بینی کردند. نتایج پژوهش نشان‌دهنده پیش‌بینی خوب بارش با میانگین مربعات خطا ۵۴/۲ میلی‌متر است [۴]. رامیرز و همکارانش از شبکه عصبی پرسپترون پیش‌خور با الگوریتم آموزش پس‌انتشار خطا و روش‌های رگرسیونی برای پیش‌بینی بارش ماهانه در منطقه سائوپائولوی برزیل استفاده کردند. نتایج برتری روش شبکه عصبی مصنوعی را نسبت به روش‌های رگرسیونی نشان می‌دهند [۵]. سو و ری جریان در آبراه‌های در هاوایی را با استفاده از شبکه‌های عصبی چندلایه و شبکه تابع پایه شعاعی پیش‌بینی کردند. پارامترهای آماری جذر متوسط مربع خطا و ضریب همبستگی به‌ترتیب برابر ۰/۰۶۷ و ۰/۹۹ برای مدل شبکه عصبی پرسپترون چندلایه، ۰/۰۶۹ و ۰/۹۸ برای منحنی دبی اشل نظیر آن به‌وجود آمد؛ با توجه به این نتایج شبکه عصبی دقت بیشتری نسبت به دبی اشل دارد [۶]. بسطامی و همکارانش برای پیش‌بینی بارش و تراز آب رودخانه بوداپ از شبکه عصبی مصنوعی استفاده کردند. براساس نتایج این پژوهش دقت پیش‌بینی مقادیر بارش برابر ۹۶/۴ درصد است. همچنین با استفاده از بارش پیش‌بینی‌شده تراز آب رودخانه را با دقت ۸۵/۳ درصد محاسبه کردند [۷].

یانگ و همکارانش در تحقیقی نشان دادند دقت پیش‌بینی شبکه عصبی مصنوعی نسبت به مدل سری زمانی تلفیقی در پیش‌بینی سطح آب زیرزمینی برتری دارد [۸]. ناستوز و همکارانش شدت بارش توسط شبکه عصبی مصنوعی را پیش‌بینی کردند. نتایج این تحقیق نشان‌دهنده پیش‌بینی قابل اطمینانی از شدت بارش برای چهار ماه آینده است [۹]. آنتونوپولس و همکارانش در پژوهشی از شبکه عصبی مصنوعی برای محاسبه تأخیر روزانه دریاچه‌ای در شمال یونان استفاده و نتیجه را با روش‌های تجربی کلاسیک مقایسه کردند. سپس به شبکه عصبی بهینه با ساختار ۱-۴-۴ دست یافتند که ضریب همبستگی برابر ۰/۹۲، نشان‌دهنده عملکرد مناسب شبکه است [۱۰].

فقیه کاربرد شبکه عصبی مصنوعی و بهینه‌سازی آن با روش الگوریتم ژنتیک در تخمین داده‌های بارش ماهانه را ارزیابی کرد. این تحقیق با هدف بررسی کارایی شبکه عصبی مصنوعی در برآورد مکانی بارش ماهانه انجام گرفت. بدین‌منظور شبکه عصبی با ساختار پرسپترون چندلایه برای تدوین مدل برآورد مکانی بارش در پنج ایستگاه سینوپتیک و

آنها نشان داد با افزایش ورودی‌ها و دخالت‌دادن بارندگی‌های یک و دو روز قبل، عملکرد هر سه مدل بهبود می‌یابد [۱۷]. محققان به‌منظور بهبود دقت نتایج مدل هوشمند به رفع نویز داده‌ها پرداختند. تمام داده‌های اندازه‌گیری شده مقدراری نویز دارند که قسمت ناخواسته داده‌ها هستند. این نویزها را می‌توان به دو دسته کلی تقسیم کرد؛ نویزهای اندازه‌گیری که مربوط به چگونگی اندازه‌گیری داده‌های مشاهداتی است و نویزهای دینامیکی که فرایندی مختص به ماهیت داده‌های مطالعه شده است و طی این فرایند در هر گام زمانی یک مقدار تصادفی کوچک به ایجاد نویز در سیستم منجر می‌شود. در واقع این نویزها در اندازه‌گیری مقادیر خروجی یک سیستم تأثیر می‌گذارند و سبب بروز خطا در سیستم و کاهش دقت پیش‌بینی داده‌ها می‌شوند. بنابراین، استفاده از روش‌های نویززدایی برای حذف نویز و پیش‌پردازش داده‌ها و یا روشی که بتواند این نویزها و نوسانات را حذف و یا درک آنها را برای مدل فراهم کند در بهبود کارایی این مدل‌ها تأثیرگذار است. به همین دلیل محققان همواره به دنبال راه‌حلی برای بهبود نتایج مدل‌های هوشمند بوده‌اند. مطالعات گذشته نشان می‌دهد ترکیب روش‌های هوشمند و تبدیل موجک‌دار بسیاری از پدیده‌های هیدرولوژیک به کسب نتایج بهتری منجر می‌شود [۱۸].

نظریه موجک به‌عنوان یک ایده تکمیلی برای رفع مشکل تبدیل‌های فوری و تبدیل فوری زمان کوتاه، مطرح شد [۱۹]. تبدیل موجکی تابعی است که نسخه بهبودیافته تبدیل فوری را تداعی می‌کند. تبدیل فوری در آنالیز سیگنال‌های نایستا به شکست منجر می‌شود. در حالی که تبدیل موجکی اجازه می‌دهد که سیگنال‌های نایستا نیز به خوبی آنالیز شوند [۲۰].

کیم و والدس برای پیش‌بینی خشکسالی حوضه‌ای در ایالت مکزیکوی امریکا از مدل ترکیبی شبکه عصبی-موجکی استفاده کردند. در نهایت، از مقایسه مدل ترکیبی یادشده با سایر روش‌های آماری و همچنین مدل شبکه عصبی، نتیجه گرفتند که مدل ترکیبی، توانایی خوبی در پیش‌بینی و تخمین خشکسالی دارد [۲۱]. کیسی برای پیش‌بینی جریان متناوب رودخانه طی یک روز آینده از مدل شبکه عصبی-موجکی استفاده کرد و نتیجه گرفت که ترکیب شبکه عصبی و تبدیل موجک سبب افزایش دقت شبکه عصبی می‌شود به طوری که جذر میانگین مربع خطاها حدود ۶۵ تا ۷۵ درصد

باران‌سنجی، واقع در استان کردستان، به کار گرفته شد [۱۱]. صف‌شکن و همکارانش به‌منظور شبیه‌سازی آن‌نمود بارش-رواناب در حوضه آبخیز معرف کسلیان از مدل شبکه عصبی پرسپترون چندلایه (MLP) استفاده کردند. در این پژوهش داده‌های بارندگی را با توجه به الگوی زمانی بارندگی به چهار گروه تقسیم کردند. نتایج نشان‌دهنده همبستگی قوی بین خروجی‌های مدل با مقادیر اندازه‌گیری شده است. ضریب همبستگی برای گروه اول و چهارم به ترتیب برابر ۰/۹۱ و ۰/۹۹ به دست آمد [۱۲].

فتاحی و همکارانش جریان رودخانه کارون شمالی را با استفاده از شبکه عصبی پیش‌بینی کردند. در این مطالعه به‌منظور طراحی بهینه معماری شبکه عصبی مصنوعی برای پیش‌بینی دبی رودخانه‌ها براساس سیگنال‌های اقلیمی از الگوریتم ژنتیک بهره گرفته شد [۱۳]. خزایی و میرزایی در پژوهشی بین مدل‌های مختلف شبکه عصبی مصنوعی و سری زمانی آرما در برآورد دبی ماهانه در حوضه آبخیز طالقان برای یک دوره ۳۰ ساله مقایسه کردند. نتایج بیانگر دقت بیشتر شبکه عصبی نسبت به مدل سری زمانی آرماست [۱۴]. رحمتی و همکارانش به پیش‌بینی تبخیر با استفاده از شبکه عصبی مصنوعی و سیگنال‌های اقلیمی در حوضه دز پرداختند. مقایسه داده‌های مشاهده‌ای تبخیر و خروجی شبکه عصبی مصنوعی همبستگی زیاد بین این داده‌ها را نشان می‌دهد، به طوری که میزان این همبستگی در ایستگاه خرم‌آباد ۷۹ درصد، دزفول ۹۴ درصد، کوهرنگ ۸۰ درصد و اراک ۷۲ درصد است [۱۵]. جهانگیر و همکارانش وضعیت خشکسالی با استفاده از شاخص بارندگی استاندارد (SPI) و شبکه عصبی پرسپترون چندلایه را پیش‌بینی کردند. در این مطالعه پایش و پیش‌بینی وضعیت خشکسالی با استفاده از داده‌های بارش ۳۸ ایستگاه باران‌سنجی در محدوده دو استان تهران و البرز به وسیله شاخص بارندگی استاندارد (SPI) در بازه زمانی ۳۱ ساله در میانگین‌های زمانی ۳، ۶، ۹، ۱۲ و ۲۴ ماهه انجام گرفت. نتایج نشان داد مقادیر پیش‌بینی شده با تقریب خوبی به مقادیر مشاهداتی نزدیک است [۱۶]. حقی‌زاده و همکارانش در تحقیقی با استفاده از شبکه عصبی مصنوعی پرسپترون چندلایه و مدل فازی عصبی تطبیقی و روش رگرسیون چندمتغیره، فرایند بارش-رواناب را به صورت روزانه در حوضه آبخیز خرم‌آباد شبیه‌سازی کردند. نتایج پژوهش

بنا بر مطالعات گذشته در مدیریت منابع آب، روش هوش مصنوعی توانایی خود را در پیش‌بینی بسیاری از فرایندهای هیدرولوژیک نشان داده است؛ ولی هنوز چالش‌هایی درباره دقت نتایج پیش‌بینی با شبکه عصبی مصنوعی وجود دارند که ضرورت بهبود این روش را ایجاب می‌کند. همچنین باید توجه کرد که استفاده از مدل‌های هوشمند در پیش‌بینی فرایندهای هیدرولوژیک می‌تواند تأثیر ارزنده‌ای در تصمیم‌گیری‌های مختص به منابع آب داشته باشد. از سوی دیگر، تا کنون درباره پیش‌بینی کمبود آب با استفاده از هوش مصنوعی مطالعه‌ای صورت نگرفته است. بنابراین، در این تحقیق به شبیه‌سازی کمبود آب ماهانه حوضه نالوچای با استفاده از روش‌های شبکه عصبی مصنوعی و شبکه عصبی مصنوعی بهبود یافته با الگوریتم موجک پرداخته می‌شود. سپس توانایی این دو مدل در تخمین کمبود آب ماهانه مقایسه و تحلیل می‌شود. در ادامه، با انتخاب شبکه بهینه، میزان کمبود آب برای سال‌های آینده با استفاده از مدل تلفیقی موجک- شبکه عصبی پیش‌بینی می‌شود. نتایج به دست آمده در برنامه‌ریزی‌های مدیریت منابع آب حوضه آبخیز کارکرد مؤثری دارد.

مواد و روش‌ها

شبکه عصبی مصنوعی^۱

پیشرفت سریع علم و تکنولوژی و پیچیدگی مسائل مهندسی موجب شده است بشر در جست‌وجوی روش‌های نوینی همچون روش‌های محاسبات نرم باشد که با دقت زیاد قادر به حل مسائل هستند. شبکه عصبی مصنوعی یکی از روش‌های پرترفدار هوش مصنوعی است که از سیستم عصبی انسان ایده گرفته است و در رشته‌های مختلف استفاده می‌شود [۲۷]. یافتن روابط پیچیده میان پارامترهای مختلف مسئله و بی‌نیازی به اطلاعات مقدماتی درباره موضوع مد نظر از مزایای این روش هستند. شبکه عصبی مصنوعی از لایه ورودی نورون‌ها، یک یا چند لایه پنهان و لایه خروجی تشکیل شده است که هر لایه با لایه بعدی کاملاً مرتبط است. هر لایه از تعداد زیادی گره تشکیل شده است و لایه‌ها توسط اتصالات وزن‌دار بین نورون‌ها با هم مرتبط هستند. در شکل ۱ نمای کلی لایه‌های شبکه عصبی را نمایش می‌دهد [۲۸-۳۰].

و میانگین مطلق خطاها حدود ۱۲ تا ۴۳ درصد کاهش می‌یابد [۲۲]. شفایی و کیسی جریان روزانه رودخانه آجی‌چایی را با استفاده از مدل شبکه عصبی- موجکی پیش‌بینی کردند و نتایج را با مقادیر به دست آمده توسط مدل شبکه عصبی مصنوعی و مدل ماشین بردار پشتیبانی مقایسه کردند که این نتایج نشان‌دهنده عملکرد بهتر مدل شبکه عصبی- موجکی نسبت به دو مدل دیگر است و ضریب همبستگی مدل عصبی - موجکی برابر ۰/۹۶ است [۲۳].

حسن‌زاده و همکارانش در تحقیقی برای پیش‌بینی خشکسالی‌های آبی، از تلفیق الگوریتم ژنتیک و مدل ترکیبی شبکه عصبی- موجکی در تحلیل شاخص بارندگی استاندارد شده، استفاده کردند و در نهایت نشان دادند به کارگیری روش تلفیقی یاد شده در مقایسه با تلفیق الگوریتم ژنتیک و شبکه عصبی، نتایج بهتر و دقیق‌تری را ارائه می‌دهد [۲۴]. شفایی و همکارانش به پیش‌بینی جریان روزانه رودخانه با استفاده از مدل هیبرید موجک و شبکه عصبی پرداختند. برای این هدف سری زمانی اصلی به مدت ۳۵ سال به وسیله تبدیل موجکی به ۱۱ زیرسری زمانی چندفرکانسی تجزیه شد. سپس برای پیش‌بینی جریان یک، دو، سه و چهار روز آینده، این سری‌ها به عنوان داده‌های ورودی به مدل شبکه عصبی مصنوعی وارد شد. نتایج به دست آمده از تبدیل موجک- شبکه عصبی با نتایج کاربرد شبکه عصبی، مقایسه و ملاحظه شد که روش موجک- شبکه عصبی نسبت به روش شبکه عصبی دقت پیش‌بینی بیشتری دارد و همچنین دقت پیش‌بینی در هر دو مدل با افزایش تعداد تأخیرها در نورون خروجی کاهش می‌یابد [۲۵]. روشنگر و همکارانش برای پیش‌بینی مصرف روزانه آب شهری از ترکیب الگوریتم‌های تکاملی و آنالیز تبدیل موجک استفاده کردند. براساس نتایج تحقیق حاضر، این ترکیب سبب بهبود ۱۰ درصدی نتایج پیش‌بینی می‌شود [۲۶]. حاجی‌آبادی و همکارانش با استفاده از دو مدل هوشمند برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی تخمین بار رسوب معلق را بررسی کردند. سپس میزان تأثیر دو رویکرد نوین‌زدایی توسط الگوریتم موجک و تبدیلات لگاریتمی به عنوان پیش‌پردازشگر، در بهبود نتایج ارزیابی و مقایسه شد. نتایج نشان می‌دهد پس از نوین‌زدایی، مقدار جذر میانگین مجذورات خطا در شبکه عصبی مصنوعی از ۱۹۹/۲۴ به ۱۴۴/۱۷ میلی‌گرم بر لیتر کاهش می‌یابد [۱۸].

الگوریتم لونیگ مارکوآرت از الگوریتم‌های بهینه‌سازی عددی است که از مزایای دو الگوریتم گاوس-نیوتون و الگوریتم کاهش شیب بهره می‌برد. این الگوریتم زمانی که آموزش شبکه که تا چند صد وزن دارد بسیار کارآمد به نظر می‌رسد؛ ولی به منظور افزایش بهره‌وری الگوریتم، نیازهای محاسباتی برای هر تکرار از الگوریتم آموزش LM بسیار بیشتر است که با افزایش دقت محاسبات، نیازهای محاسباتی برای هر تکرار از الگوریتم افزایش بیشتری خواهد داشت [۳۴].

نویززدایی با استفاده از تبدیل موجک^۴

موجک یکی از روش‌های مهم برای تجزیه سیگنال‌هاست. استفاده از تبدیل موجک توسط گراسمن^۵ در سال ۱۹۸۴ مطرح شد. به منظور حذف و کاهش نویز سیگنال‌ها می‌توان از تبدیل فوریه بهره برد؛ ولی استفاده از این تابع در طول انجام تبدیلات، موجب تغییر در خواص مکانی و زمانی سیگنال‌ها می‌شود. بنابراین، به منظور رفع این مشکل دابچیز^۶ استفاده از تبدیل موجک را در سال ۱۹۸۷ پیشنهاد کرد که ویژگی‌های اصلی سیگنال را تغییر نمی‌دهد [۱۸].

تبدیل موجک در شناسایی و تحلیل بسیاری از زوایای پنهان سیگنال‌ها نسبت به دیگر روش‌های تحلیل سیگنال توانایی قابل قبولی دارد. از کاربردهای اصلی تبدیل موجک در سری‌های زمانی می‌توان به نویززدایی اشاره کرد. حذف نویز باید به صورتی باشد که سیگنال نویززدایی شده تا حد زیادی به سیگنال اصلی شبیه باشد به طوری که خواص زمانی و مکانی اصلی سیگنال دچار تغییر نشود که این امر به کمک تبدیل موجک گسسته امکان پذیر شده است. با اینکه تبدیل موجک پیوسته برای تحلیل زمان-فرکانس ابزار خوبی است؛ ولی بار محاسباتی اضافی دارد، به همین علت تبدیل موجک گسسته معرفی شد.

$\Psi(t)$ ، تابع موجک است اگر و تنها اگر تبدیل فوریه آن $\Psi(\omega)$ ، شرط رابطه ۳ را داشته باشد که شرط پذیرش برای موجک $\Psi(t)$ نامیده می‌شود. اگر معادله ۴ برقرار باشد، موجک، شرط بالا را خواهد داشت.


حالت فعال‌سازی نورون‌ها بیانگر حالت سیستم است که با بردار $a(t)$ نمایش داده می‌شود و تابع خروجی هر نورون با $o_i(t)$ نمایش داده می‌شود که در رابطه ۱ نمایش داده شده است.

$$a_i(t) = f(a_i(t)) \quad (1)$$

شبکه ورودی یک نورون Net(t) از حاصل ضرب خروجی‌های گره‌های قبلی در وزن‌های ماتریسی مطابق رابطه ۲ به دست می‌آید [۳۱].

$$Net(t) = W \cdot O(t) \quad (2)$$

در تحقیق حاضر از شبکه عصبی چندلایه و توابع پس‌انتشار برگشتی^۱ و الگوریتم لونیگ مارکوآرت^۲ استفاده شده است.



شکل ۱. ساختار شبکه عصبی

در شبکه عصبی پیش‌خور امکان ایجاد رابطه خطی و غیرخطی بین ورودی‌ها و خروجی‌ها فراهم شده است. پرسپترون چندلایه^۳ یکی از الگوریتم‌های پرکاربرد شبکه‌های عصبی پیش‌خور است که شرایط تولید خروجی در محدوده خارج از $+1$ و -1 را میسر می‌سازد [۳۲ و ۳۳]. مهم‌ترین مزیت تابع آموزشی پس‌انتشار برگشتی، از بین بردن تأثیرات مضر روی اندازه مشتق جزئی است. از این الگوریتم به منظور به‌روزرسانی وزن‌ها با توجه به رفتار تابع خطا استفاده می‌شود ولی مقدار مشتق بر روند به‌روزرسانی وزن‌ها بی‌تأثیر خواهد بود. تابع آموزشی پس‌انتشار برگشتی در مقایسه با الگوریتم استاندارد کاهش شیب، سرعت بیشتری در محاسبات و به حافظه کمتری نیز نیاز دارد [۳۴].

4. Wavelet Transform
5. Grassman
6. Daubechies

1. Resilient Backpropagation (RP)
2. Levenberg-Marquardt (LM)
3. Multilayer perceptron (MLP)

تجزیه، سطح آستانه انتخاب شده و به ضرایب فرکانس بالا اعمال می‌شود. گام سوم نیز بازسازی سیگنال است.

سیگنال اصلی در هر مرحله به دو سیگنال تقریب و جزئی تجزیه می‌شود. سیگنال تقریب حاوی مؤلفه‌های مقیاس بالا (فرکانس پایین) و سیگنال جزئیات حاوی مؤلفه‌های مقیاس پایین و یا فرکانس بالای سیگنال است. به بیان دیگر، در هر بار تجزیه یک باند فرکانسی از سیگنال اصلی جدا و باقی‌مانده در سیگنال تقریب ذخیره می‌شود. بنابراین، در حالت کلی می‌توان سیگنال اصلی را از حاصل جمع سیگنال‌های حاصل شده، به‌دست آورد.



شکل ۲. نمایش مراحل رفع نویز

هر چه تعداد مراحل منتخب برای تجزیه بیشتر باشد، سیگنال به همان تعداد به بسامدهای بالاگذر و پایین‌گذر تجزیه می‌شود و دقت کار افزایش می‌یابد؛ اما از مرحله‌ای به بعد، مقادیر بسامدها تقریباً ثابت باقی می‌مانند. از آنجا که هدف از تجزیه موجکی، نویززدایی داده‌ها تا حد امکان است، مشاهده می‌شود که در سطح تجزیه ۸ زیرسری تقریبی به مرحله‌ای می‌رسد که در آنها بسامدی مشاهده نمی‌شود. سپس این داده‌ها پس از نرمالیزه‌شدن توسط فرمول ۷ به‌عنوان ورودی شبکه عصبی تحت الگوی بهینه در نظر گرفته می‌شوند.

$$X_N = \frac{(X - X_{\min})}{(X_{\max} - X_{\min})} + 0.1 \quad (7)$$

معیارهای ارزیابی دقت مدل‌سازی

برای مقایسه کمی عملکرد مدل استفاده‌شده می‌توان از

$$\int_{-\infty}^{+\infty} \frac{|\psi(\omega)|}{|\omega|^2} d\omega < +\infty \quad (3)$$

$$\psi(0) = \int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (4)$$

این خصوصیت تابع با میانگین صفر است. در رابطه ۵، $\Psi(t)$ تابع موجک مادر نام دارد که با اعمال ریاضی انتقال و مقیاس در طول سیگنال بررسی شده، تحت تغییر اندازه و محل قرار می‌گیرد.

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (5)$$

الگوریتم موجک سیگنال $f(t)$ با تابع موجک $\Psi(t)$ ربط پیدا خواهد کرد. رابطه ۶ نیز، الگوریتم موجک پیوسته سیگنال را به‌دست می‌آورد.

$$C(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-\tau}{s}\right) dt \quad (6)$$

$$= \int_{-\infty}^{+\infty} f(t) \psi_{s,\tau}(t) d(t)$$

در مرحله اول این تحقیق از شبکه عصبی پرسپترون چندلایه که ساختمان آن پیش‌خور است بدون پیش‌پردازش داده‌ها برای پیش‌بینی جریان یک ماه بعد استفاده شده است به این صورت که سیگنال نرمال‌شده داده‌های کمبود ماهانه با تأخیرهای یک‌ماهه به‌عنوان ورودی و داده‌های زمان (t) به‌عنوان خروجی به‌کار برده شده است. براساس اینکه تنها یک لایه پنهان برای شبکه عصبی کافی است تا تابع غیرخطی را با هر دقت دلخواهی تقریب کند از یک لایه پنهان در شبکه عصبی استفاده شد. تعداد نورون‌های لایه مخفی از ۲ تا ۸ نورون تغییر می‌کند. در مرحله دوم از شبکه عصبی موجکی برای پیش‌بینی کمبود ماهانه آب استفاده شده است. به این‌منظور ابتدا سری زمانی اصلی داده‌های کمبود آب ماهانه حوضه نازلوچای با استفاده از کد برنامه‌ای که در نرم‌افزار متلب نوشته شده و با به‌کارگیری موجک Coif و bior توسط تبدیل موجک گسسته به ۸ زیرسری معین تجزیه می‌شوند. مراحل رفع نویز در فلوجارت شکل ۲ نشان داده شده است. به‌طور کلی، روش مبتنی بر ویولت برای حذف نویز از سه مرحله تشکیل شده است؛ گام اول انتخاب تابع ویولت و تجزیه به چند سطح است. گام دوم حذف نویز در ضرایب فرکانس بالاست. به این‌صورت که برای هر سطح

$$R = 1 - \frac{(1 - R^2)(N - 1)}{N - P - 1} \quad (10)$$

در روابط ۸ و ۹، y_i مقادیر پیش‌بینی‌شده، x_i مقادیر مشاهده‌شده و \bar{y} و \bar{x} به ترتیب میانگین مقادیر پیش‌بینی‌شده و مشاهداتی هستند. در رابطه ۱۰ نیز، R^2 ضریب تعیین، p تعداد متغیرهای پیش‌بینی و N تعداد کل مشاهدات است.

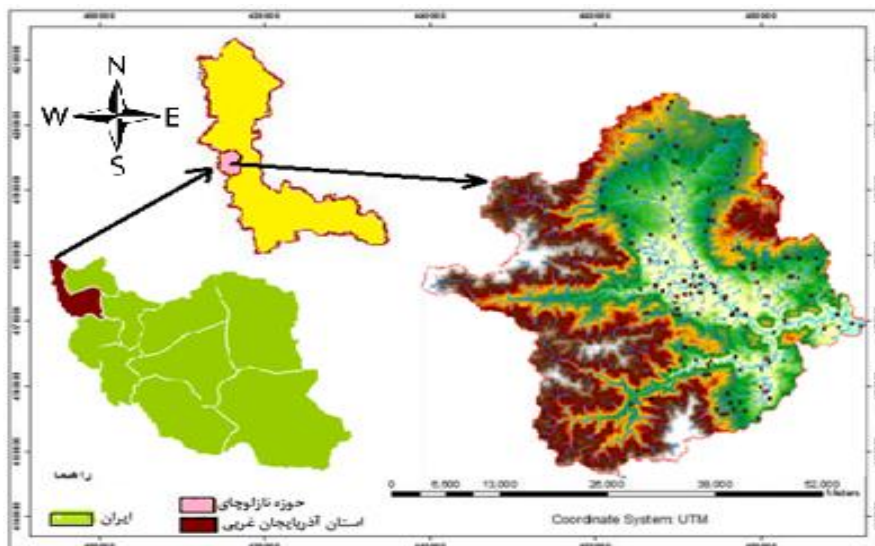
معرفی منطقه پژوهش شده

حوضه آبخیز نازلوچای با مساحت ۵۱۸۰۱ کیلومتر مربع از زیرحوضه‌های دریاچه ارومیه و واقع شده در استان آذربایجان غربی است. این حوضه در بین طول‌های جغرافیایی $24^{\circ} 44'$ تا $45^{\circ} 53'$ و عرض‌های جغرافیایی $30^{\circ} 37'$ تا $37^{\circ} 58'$ قرار گرفته است [۳۶]. این حوضه از شرق به دریاچه ارومیه، از غرب به کشور ترکیه محدود است. همچنین این حوضه از شمال با حوضه شیواسان‌چای و زولان‌چای و از سمت جنوب با حوضه روضه‌چای همسایه است. شیب حوضه نازلوچای در ارتفاعات غرب بیش از ۵۰ درصد است و در مناطق شرقی کاهش می‌یابد. ارتفاع متوسط حوضه $1944/2$ متر و متوسط بارش سالیانه آن $488/6$ میلی‌متر است. در شکل ۳ موقعیت جغرافیایی منطقه مطالعه‌شده بررسی شده است.

بررسی اختلاف بین مقادیر مشاهده‌شده و برآوردشده بهره برد. شاخص R^2 ، میزان همبستگی میان مقادیر مشاهداتی و خروجی‌های مدل هوشمند را تحت رابطه خطی بیان می‌کند و نزدیکی مقدار این شاخص به ۱، نشانگر دقت زیاد مدل شبکه عصبی و تطابق خوب داده‌های مشاهداتی و نتایج تخمین است؛ ولی به علت حساسیت این شاخص نسبت به انحراف نقاط، باید برای ارزیابی مدل از سایر شاخص‌ها نیز بهره برد. جذر میانگین مربعات خطا (RMSE) نشان‌دهنده وزن خطاهای بزرگ‌تر براساس تفاوت میان مقادیر مشاهداتی و پیش‌بینی‌شده است. نزدیکی این شاخص به عدد صفر، دستیابی به نتایج مطلوب را امکان‌پذیر می‌کند. همچنین ضریب همبستگی R ، برای تعیین نوع و درجه رابطه یک متغیر کمی با متغیر کمی دیگر استفاده می‌شود [۳۵]. در این تحقیق از جذر میانگین مربعات خطا (RMSE) ۱، ضریب تبیین R^2 و ضریب همبستگی R ۳ برای ارزیابی عملکرد مدل استفاده شد که در روابط ۸، ۹ و ۱۰ آورده شده است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (8)$$

$$R^2 = \left[\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \right]^2 \quad (9)$$



شکل ۳. محدوده جغرافیایی حوضه نازلوچای

1. Root Mean Square Error
2. Determination Coefficient
3. Correlation Coefficient

نتایج و بحث

در نهایت بهترین نتایج با استفاده از ۷۰ درصد داده‌ها به‌عنوان داده‌های آموزش به‌دست آمد و ۳۰ درصد باقی داده‌ها به‌عنوان داده‌های آزمون استفاده شده است. از دو تابع پس‌انتشار برگشتی (RP) و الگوریتم لئونبرگ مارکوآرت (LM) نیز، برای آموزش و آزمون داده‌ها بهره گرفته شد.

به‌منظور انتخاب تعداد وقفه بهینه در لایه ورودی، الگوهای مختلفی برای ورودی بررسی شدند که در جدول ۱ نمایش داده شده‌اند. برای انتخاب الگوی بهینه از روش آنالیز پیش‌رونده استفاده و مشاهده شد که برای پیش‌بینی کمبود آب هرماه در صورت استفاده از داده‌های ۱۲ ماه قبل (الگوی ۷) نتایج بهتری به‌دست خواهد آمد.

جدول ۱. حالات مختلف استفاده‌شده در انتخاب تعداد وقفه بهینه لایه ورودی

الگوها	تعریف
۱	$SH_t = f(SH_{t-1})$
۲	$SH_t = f(SH_{t-1} + SH_{t-2})$
۳	$SH_t = f(SH_{t-1} + SH_{t-2} + SH_{t-3})$
۴	$SH_t = f(SH_{t-1} + SH_{t-2} + SH_{t-3} + SH_{t-4})$
۵	$SH_t = f(SH_{t-1} + SH_{t-2} + SH_{t-3} + SH_{t-4} + SH_{t-5})$
۶	$SH_t = f(SH_{t-1} + SH_{t-2} + SH_{t-3} + SH_{t-4} + SH_{t-5} + \dots + SH_{t-12})$
۷	$SH_t = f(SH_{t-1} + SH_{t-11} + SH_{t-12})$

آزمون به‌ترتیب ۰/۶۶۲۸ و ۰/۶۶۴۶ به‌دست آمد، کمترین مقدار ضریب تعیین نیز در مراحل آموزش و آزمون با مقادیر ۰/۴۳۹۴ و ۰/۴۴۱۶، ضعیف‌ترین نتایج را به‌دست آورد که بیانگر نامناسب بودن الگوی ۱ است. الگوی ۷ بیشترین مقدار ضریب همبستگی در فاز آموزش، معادل ۰/۹۵۲۳ و همچنین بیشترین مقدار ضریب تعیین را برابر ۰/۹۰۴۹ در مرحله آزمون به‌دست آورد که با تابع LM آموزش دیده است که در نتیجه این الگو با ساختار ۱-۴-۴ به‌عنوان شبکه بهینه انتخاب شد.

در شکل‌های ۴ تا ۷ مقایسه بین کمبود واقعی و پیش‌بینی شده با شبکه عصبی بهینه حوضه نازلوچای به‌ترتیب برای داده‌های آموزش و آزمون نشان داده شده است. از این نمودارها مشاهده می‌شود که شبکه عصبی مصنوعی بهینه در مقایسه با سایر شبکه‌های عصبی، با دقت زیادی، ارتباط بین داده‌های ورودی و خروجی را شبیه‌سازی کرده است.


در تحقیق حاضر از داده‌های کمبود آب حوضه نازلوچای محاسبه‌شده با نرم‌افزارهای WEAP استفاده شده است [۳۷]. سری زمانی داده‌های ماهانه طی ۳۹ سال (۴۶۸ سری داده) از حوضه با بهره‌گیری از شبکه عصبی و نوپزدایی با موجک، شبیه‌سازی و پیش‌بینی شده‌اند. برای این منظور ابتدا داده‌های کمبود آب با استفاده از شبکه عصبی پیش‌بینی می‌شوند، سپس داده‌ها با کمک موجک، نوپزدایی می‌شوند و پس از نرمال‌سازی، دوباره تحت شبکه عصبی قرار می‌گیرند و عمل تخمین داده‌ها انجام می‌گیرد. برای تشکیل شبکه عصبی از درصدهای مختلفی از داده‌ها برای آموزش شبکه استفاده شده است که

برای آنکه تابع غیرخطی با دقت کافی به پیش‌بینی پارامترها بپردازد، از یک لایه پنهان برای شبکه عصبی استفاده می‌شود، تعداد نورون‌های هر لایه اهمیت زیادی دارد و در دقت نتایج به‌دست‌آمده مؤثر خواهد بود. بنابراین، شبکه استفاده‌شده از یک لایه پنهان با تعداد نورون‌های ۲ تا ۸ نورون تشکیل شده و بررسی و تحلیل شده است. لایه ورودی ۳ تا ۸ نورون و لایه خروجی تنها ۱ نورون دارد.


معیارهای خطا از جمله جذر میانگین مربعات خطا، ضریب تعیین و ضریب همبستگی مدل‌های مختلف استفاده‌شده در این تحقیق ارزیابی شده است. جدول ۲ به تجزیه و تحلیل نتایج و ارزیابی میزان دقت مدل‌های به‌کاررفته برای پیش‌بینی پارامتر کمبود آب پرداخته است. شبکه با الگوی ۱ و ساختار ۱-۲-۳ و تابع آموزش LM و شبکه با الگوی ۱ و ساختار ۱-۸-۸ و تابع آموزش RP نامناسب‌ترین نتایج پیش‌بینی را به‌دست آورده‌اند. کمترین ضریب همبستگی در مدل‌سازی در مراحل آموزش و

جدول ۲. معیارهای خطای مختص به ساختارهای استفاده‌شده در تحقیق

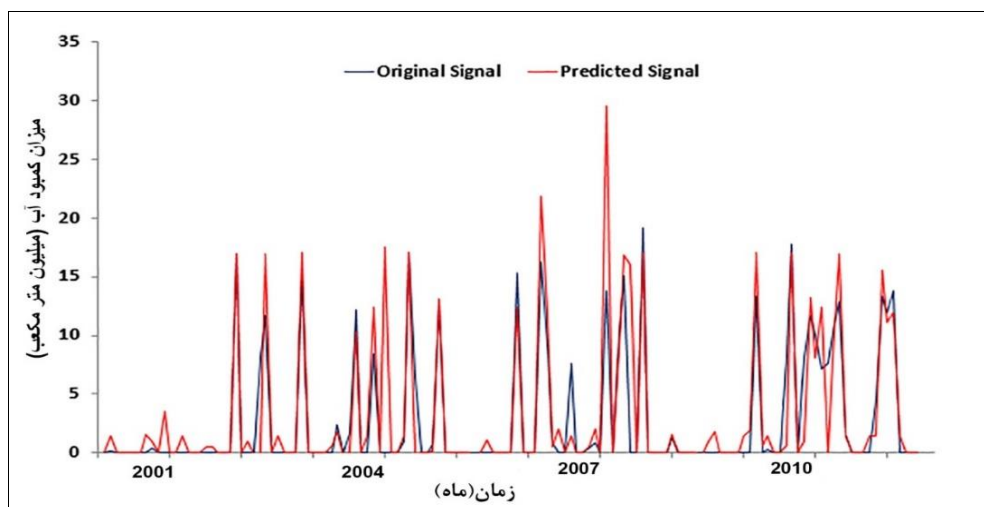
شماره	تایع	ساختار	ضریب همبستگی (tr)	ضریب همبستگی (ts)	ضریب تعیین (tr)	ضریب تعیین (ts)	جذر میانگین مربعات خطا (tr)	جذر میانگین مربعات خطا (ts)
۱	LM	۳_۲_۱	۰/۶۶۲۸	۰/۷۲۶۶	۰/۴۳۹۴	۰/۵۲۸	۰/۱۸۰۴	۰/۱۵۸۹
۱	RP	۸_۸_۱	۰/۷۰۸۵	۰/۶۶۴۶	۰/۵۰۲	۰/۴۴۱۶	۰/۱۷۰۱	۰/۱۷۲۵
۲	LM	۴_۴_۱	۰/۸۵۲۱	۰/۸۲۴۹	۰/۷۲۶	۰/۶۸۰۵	۰/۱۲۶۱	۰/۱۳۱۱
۲	RP	۶_۶_۱	۰/۸۴۳	۰/۸۰۰۶	۰/۷۱۰۷	۰/۶۴۱	۰/۱۲۹۶	۰/۱۳۸۱
۳	LM	۳_۳_۱	۰/۸۶۵۳	۰/۷۸۴۱	۰/۷۴۸۸	۰/۶۱۴۷	۰/۱۲۰۸	۰/۱۴۴۲
۳	RP	۸_۸_۱	۰/۸۶۱۱	۰/۸۰۳۴	۰/۷۴۱۴	۰/۶۴۵۵	۰/۱۲۲۵	۰/۱۳۷۶
۴	LM	۴_۴_۱	۰/۸۷۳۷	۰/۸۰۵۲	۰/۷۶۳۴	۰/۶۴۸۴	۰/۱۱۷۲	۰/۱۳۷۹
۴	RP	۶_۶_۱	۰/۸۵۰۹	۰/۸۳۵۱	۰/۷۲۴۱	۰/۶۹۷۳	۰/۱۲۶۶	۰/۱۲۷۷
۵	LM	۳_۳_۱	۰/۸۶۹۵	۰/۸۱۲۵	۰/۷۵۶۵	۰/۶۶۰۱	۰/۱۱۹	۰/۱۳۵۲
۵	RP	۴_۴_۱	۰/۸۶۲۱	۰/۸۳۶۳	۰/۷۴۳۱	۰/۶۹۹۴	۰/۱۲۲۱	۰/۱۲۷۳
۶	LM	۴_۴_۱	۰/۹۴۳۱	۰/۸۷۷۸	۰/۸۸۹۵	۰/۷۷۰۶	۰/۰۸۱۸	۰/۱۰۶۲
۶	RP	۸_۸_۱	۰/۹۴۳۱	۰/۸۵۱۷	۰/۸۸۹۴	۰/۷۲۵۳	۰/۰۸۱۹	۰/۱۱۷۸
۷	LM	۴_۴_۱	۰/۹۵۲۳	۰/۸۵۲۳	۰/۹۰۴۹	۰/۷۲۶۴	۰/۰۸۵۲	۰/۱۲۳۱
۷	RP	۸_۸_۱	۰/۹۴۶۴	۰/۸۸۴	۰/۸۹۵۷	۰/۷۸۱۵	۰/۰۷۷۸	۰/۱۱




شکل ۴. مقایسه کمبود آب واقعی و پیش‌بینی‌شده حوضه آبخیز نازلوجای برای داده‌های آموزش



شکل ۵. تطابق کمبود آب پیش‌بینی‌شده در مقابل مشاهده‌شده برای پیش‌بینی دبی یک ماه بعد برای داده‌های آموزش




شکل ۶. مقایسه کمبود آب واقعی و پیش‌بینی‌شده حوضه آبخیز نازلوچای برای داده‌های آزمون



شکل ۷. تطابق کمبود آب پیش‌بینی‌شده در مقابل مشاهده‌شده برای پیش‌بینی دبی یک ماه بعد برای داده‌های آزمون

جزئیات آنها حذف و تنها قسمت کلیات برای آموزش مدل‌های هوشمند استفاده می‌شود. در نهایت، تأثیر نویز دایمی سیگنال‌ها در نتایج روش‌های هوشمند به وسیله سه معیار ارزیابی معرفی شده بررسی شده است. بررسی‌های انجام‌شده نشان‌دهنده برتری تابع موجک Bior نسبت به Coif برای رفع نویز داده‌هاست. شکل ۸ سری زمانی داده‌های کمبود ماهانه آب را نشان می‌دهد که توسط تابع موجک Bior به دو بخش کلیات و جزئیات برای سطح تجزیه ۸ تقسیم شده است.

در این پژوهش به منظور تجزیه سیگنال‌ها از تبدیل موجک گسسته استفاده شده است به طوری که پس از عبور سیگنال‌ها از فیلترهای بالاگذر و پایین‌گذر، سیگنال به دو بخش تجزیه خواهد شد. بخش اول کلیات نامیده می‌شود که از عبور سیگنال از فیلتر پایین‌گذر به دست آمده و شامل اطلاعات فرکانس پایین و مشخصات اصلی سیگنال است. بخش دوم در نتیجه عبور سیگنال از فیلتر بالاگذر است که شامل اطلاعات فرکانس بالا است و جزئیات نام دارد. پس از تجزیه تمام سیگنال‌های ورودی، قسمت



شکل ۸. سری زمانی سیگنال تجزیه‌شده توسط موجک Bior در سطح ۸

ابراهیمی [۳۹]، نیک‌منش [۴۰] و رجایی و جعفری [۴۱] نشان‌دهنده ارجحیت مدل عصبی-موجک در پیش‌بینی است.

با توجه به نتایج جدول ۳، با حذف نویز در سری زمانی می‌توان به پیش‌بینی مقادیر کمبود آب با استفاده از شبکه عصبی با دقت مطلوب نائل شد. بنابراین، داده‌های نویزگیری‌شده برای پیش‌بینی کمبود آب برای ۸ سال آینده (۲۰۱۳-۲۰۲۰) حوضه آبخیز نازلوچای در استان آذربایجان غربی استفاده شده و نتایج در شکل ۹ نشان داده شده است.


نتایج پیش‌بینی نشان‌دهنده آن است که مشکل کمبود آب در این حوضه آبخیز همچنان باقی است و کاهش شایان توجهی مشاهده نشده است. مقدار بیشترین کمبود آب در ۳۹ سال گذشته، ۲۴/۸۲ میلیون مترمکعب تعیین شده است در حالی که این پارامتر برای ۸ سال آینده، ۱۸/۱۶ میلیون مترمکعب تخمین زده شده است. همچنین مقدار متوسط کمبود آب برای ۳۹ سال گذشته و ۸ سال آینده به ترتیب ۴/۰۴ و ۲/۹۵ میلیون مترمکعب تعیین شد. به‌منظور مدیریت و برنامه‌ریزی منابع آب حوضه آبخیز نازلوچای باید اقدامات مناسبی انجام شود تا میزان کمبود آب در سال‌های آینده کاهش یابد.

معیارهای خطای ساختار بهینه با استفاده از داده‌های رفع نویز شده، در جدول ۳ آمده است. با توجه به جدول ۳، میزان معیار خطای RMSE به‌دست‌آمده از این فاز از مدل‌سازی تقریباً ۰/۰۸۱۳ حاصل شد که بسیار به مقدار صفر نزدیک است و بیانگر دقت زیاد صحت‌سنجی کمبود آب است. ضریب همبستگی در هر دو فاز آموزش و آزمون این الگو، بیشتر از ۰/۹۴ به‌دست آمد. در این فاز از تابع آموزشی پس‌انتشار برگشتی (LM) بهره برده شده است که بیشترین دقت در مدل‌سازی و بهترین تطابق میان مقادیر تخمین زده‌شده و مشاهداتی را داراست.

با مقایسه نتایج جدول ۲ و ۳، یا به بیان دیگر مقایسه شبیه‌سازی مدل شبکه عصبی با مدل موجک-شبکه عصبی کارایی و دقت بیشتر مدل موجک-شبکه عصبی نسبت به شبکه عصبی مشاهده می‌شود. دقت بیشتر این مدل به دلیل پیش‌پردازش و پارتیشن‌بندی موجک به زیرسیگنال‌های مختلف است. به‌طور کلی، بررسی نتایج پژوهش‌های انجام‌شده با مدل شبکه عصبی مصنوعی و عصبی-موجک در زمینه فرایندهای هیدرولوژیک بیانگر دقت مناسب این دو مدل در شبیه‌سازی و پیش‌بینی داده‌هاست. مقایسه این دو مدل در پژوهش‌های شفافیتی و همکارانش [۲۵]، نوری و همکارانش [۳۸]، رجایی و

جدول ۳. معیارهای خطای مختص به ساختار بهینه با استفاده از داده‌های رفع نویز شده

شماره	تابع	ساختار	ضریب همبستگی (tr)	ضریب همبستگی (ts)	ضریب تعیین (tr)	ضریب تعیین (ts)	جذر میانگین مربعات خطا	جذر میانگین مربعات خطا
موجک	LM	۴_۴_۱	۰/۹۶۰۷	۰/۹۴۵۵	۰/۹۲۳	۰/۸۹۴	۰/۰۶۵۴	۰/۰۸۱۳



شکل ۹. نمودار پیش‌بینی کمبود آب حوضه نازلوچای از سال ۲۰۱۳ تا ۲۰۲۰

نتیجه‌گیری

عصبی با داده‌های رفع نویز شده نسبت به شبکه عصبی با سیگنال اصلی داده‌هاست. ضریب همبستگی داده‌ها در مرحله آموزش و آزمون در مدل موجک- شبکه عصبی به ترتیب ۰/۹۵۲۳ و ۰/۸۵۲۳ به دست آمد که بیانگر دقت زیاد این روش است. در ادامه، با به‌کارگیری از داده‌های رفع نویز شده میزان کمبود آب در سال‌های ۲۰۱۳ تا ۲۰۲۰ پیش‌بینی شد. نتایج پیش‌بینی نشانگر آن است که کمبود آب در سال‌های پیش‌بینی شده همانند روند سال‌های گذشته است و بیانگر کمبود آب در فصول کم‌بارش است. از این‌رو، برنامه‌ریزی مناسب و دقیق به‌منظور بهره‌برداری از منابع آب (کشاورزی، صنعت، شرب و...) نیاز است تا میزان کمبود آب در سال‌های آتی کاهش یابد.

منابع

- [1]. Water and Wastewater Department of Energy Office Planning. Report begin updating the master plan studies of water in watersheds grade 2 Tehran. 2008. [In Persian]
- [2]. Menhaj M. Computational Intelligence (first volume: Foundations of Neural Networks). Amirkabir University Publishers. 2014. Page 716. [In Persian]

پیش‌بینی فرایندهای هیدرولوژیک می‌تواند به‌عنوان ابزاری مناسب برای مدیریت منابع آب تلقی شود. در این مطالعه به‌منظور پیش‌بینی کمبود ماهانه آب ایستگاه نازلوچای، شبیه‌سازی با کمک مدل شبکه عصبی مصنوعی و سپس با مدل موجک- شبکه عصبی انجام شد و نتایج این دو روش با یکدیگر مقایسه شد. در آغاز، پس از بررسی الگو و ساختارهای مختلف در شبکه عصبی، ساختار بهینه برای شبکه انتخاب شد. ساختار بهینه از سه لایه تشکیل شده است که لایه پنهان شامل ۴ نورون است. برای انتخاب ورودی‌های شبکه، حالت‌های مختلف سری زمانی به‌صورت آنالیز پیش‌رونده استفاده شدند. نتایج نشان داد برای پیش‌بینی کمبود آب هر ماه بهتر است از داده‌های ۱۲ ماه قبل استفاده شود. پس از انتخاب ساختار و الگوی بهینه، داده‌ها با بهره‌گیری از الگوریتم موجک، نویززدایی و در شبکه بهینه قرار داده شدند. برای نویززدایی سیگنال داده‌ها از موجک‌های مادر Bior و Coif در سطح ۱ تا ۸ استفاده شده است که نتایج نشان‌دهنده برتری داده‌های به‌دست‌آمده از موجک Bior در سطح ۸ برای شبیه‌سازی است. نتایج به‌دست‌آمده بیانگر برتری مدل شبکه

- [3]. Hall T, Brooks HE, Doswell III CA. Precipitation forecasting using a neural network. *Weather and forecasting*. 1999 Jun;14(3):338-45.
- [4]. Sahai AK, Soman MK, Satyan V. All India summer monsoon rainfall prediction using an artificial neural network. *Climate dynamics*. 2000 1;16(4):291-302.
- [5]. Ramirez M.C.V, Velho H.F, Ferreira N.J. Artificial neural network technique for rainfall forecasting applied to the São Paulo region. *Journal of Hydrology*. 2005; 301,146-162.
- [6]. Sahoo GB, Ray C. Flow forecasting for a Hawaii stream using rating curves and neural networks. *Journal of hydrology*. 2006 5;317(1):63-80.
- [7]. Bustami R, Bessaih N, Bong C, Suhaili S. Artificial neural network for precipitation and water level predictions of Bedup River. *IAENG International Journal of computer science*. 2007 1; 34(2):228-33.
- [8]. Yang ZP, Lu WX, Long YQ, Li P. Application and comparison of two prediction models for groundwater levels: A case study in Western Jilin Province, China. *Journal of arid Environments*. 2009; 73(4):487-92.
- [9]. Nastos PT, Moustis KP, Larissi IK, Paliatsos AG. Rain intensity forecast using artificial neural networks in Athens, Greece. *Atmospheric Research*. 2013 31; 119:153-60.
- [10]. Antonopoulos VZ, Gianniou SK, Antonopoulos AV. Artificial neural networks and empirical equations to estimate daily evaporation: application to lake Vegoritis, Greece. *Hydrological Sciences Journal*. 2016 Jan 16(just-accepted).
- [11]. Faghieh H. Evaluating artificial neural network and its optimization using genetic algorithm in estimation of monthly precipitation data (Case Study: Kurdistan Region). *JWSS - Isfahan University of Technology*. 2010; 14 (51):27-44. [In Persian]
- [12]. Safshekan F, PirMoradian N, Afshin Sharifan R. Simulation of rainfall-runoff hydrograph according to the pattern of rainfall and the use of artificial neural network in kasilian basin. *Iran-Watershed Management Science & Engineering*. 2011; 5(15):1-10. [In Persian]
- [13]. Fatahi A, Delavar M, Noohi K. North Karun river flow forecasting using artificial neural network. *Geographical Research Publishers*. 2012; 51-78. [In Persian]
- [14]. Khazaei M, Mirzaei MR. Comparison prediction performance of monthly discharge using ANN and time series. *Watershed Engineering and Management*. 2013; 5(2): 74-84. [In Persian]
- [15]. Rahmati E, Montazeri M, Gandomkar A, Lashanizand M. Evaporation Predict Using Climate Signals and Artificial Neural Network in Dez Basin. *Geographical Research Journal*. 2015 30(2):261-274. [In Persian]
- [16]. Jahangir M, Khoshmashraban M, Yousefi H. Drought monitoring and forecasting network using standard precipitation index and multilayer perceptron Neural Network (Case Study: Tehran and Alborz provinces). *Iranian Journal of Ecohydrology*. 2016; 417-428. [In Persian]
- [17]. Haghizadeh A, Mohammadlou M, Noori F. Simulation of rainfall-runoff process using multilayer perceptron and adaptive neuro-fuzzy interface system and multiple regressions (Case study: Khorramabd watershed). *Iranian Journal of Ecohydrology*. 2015; 233-243. [In Persian]
- [18]. Hajiabadi R, Farzin S, Hassanzadeh Y. Intelligent Models Performance Improvement Based on Wavelet Algorithm and Logarithmic Transformations in Suspended Sediment Estimation. *Journal of Water and Soil*. 2016;30(1):112-124. [In Persian]
- [19]. Lotfollahi-Yaghin MA, Koozdaragh M. Examining the function of wavelet packet transform (WPT) and continues wavelet transform (CWT) in recognizing the crack specification. *KSCE Journal of Civil Engineering*. 2011; 497-506. [In Persian]
- [20]. Sifuzzaman M, Islam MR, Ali MZ. Application of wavelet transform and its advantages compared to Fourier transform. 2009; 121-134.
- [21]. Kim TW, Valdés JB. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering*. 2003 Nov; 8(6):319-28.
- [22]. Kişi Ö. Neural networks and wavelet conjunction model for intermittent streamflow forecasting. *Journal of Hydrologic Engineering*. 2009 19; 14(8):773-82.
- [23]. Shafaei M, Kisi O. Predicting river daily flow using wavelet-artificial neural networks based on regression analyses in comparison with artificial neural networks and support vector machine models. *Neural Computing and Applications*. 2016: 1-4.
- [24]. Hassanzadeh Y, Abdi Kordani A, Fakheri Fard A. Drought Forecasting Using Genetic Algorithm and Conjoined Model of Neural

- Network-Wavelet. *Journal of Water and Wastewater*. 2012; 23(3): 48-59. [In Persian]
- [25]. Shafaei M, Fakhei Fard A, Darbandi S, ghorbani M. Prediction Daily Flow of Vanyar Station Using ANN and Wavelet Hybrid Procedure. *Journal of Irrigation and Water*. 2014; 113-128. [In Persian]
- [26]. Roshangar K, Zarghaami M, Tarlaniazar M. Forecasting Daily Urban Water Consumption using Conjunctive Evolutionary Algorithm and Wavelet Transform Analysis, A Case Study of Hamedan City, Iran. *Journal of Water and Wastewater*. 2015; 26(4): 110-120. [In Persian]
- [27]. Zhang G, Patuwu BE, Hu MY. Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*. 1998; 14(1):35-62.
- [28]. French MN, Krajewski WF, Cuykendall RR. Rainfall forecasting in space and time using a neural network. *Journal of hydrology*. 1992 Aug 15;137(1-4):1-31.
- [29]. Silverman D, Dracup JA. Artificial neural networks and long-range precipitation prediction in California. *Journal of applied meteorology*. 2000 Jan;39(1):57-66.
- [30]. Choubin B, Khalighi-Sigaroodi S, Malekian A, Kişi Ö. Multiple linear regression, multi-layer perceptron network and adaptive neuro-fuzzy inference system for forecasting precipitation based on large-scale climate signals. *Hydrological Sciences Journal*. 2016 Apr 25; 61(6):1001-9.
- [31]. De Vos NJ. Rainfall-run off modelling using artificial neural networks. Doctoral dissertation, TU Delft, Delft University of Technology. 2003.
- [32]. Safshekan F, Pirmoradian N, Afshin Sharifan R. Simulation of rainfall-runoff according to the pattern of rainfall and the use of artificial neural network. *Iran-Watershed Management Science & Engineering*. 2011. [In Persian]
- [33]. Shahhossein Dastjerdi S, Shahnoushi N, Darijani A, Davari K. Application of artificial neural network models in simulation of drought severity (A Case of Torshakli Station in Golestan Province). *Third National Conference on Integrated Water Resource Management*. 2012. [In Persian]
- [34]. Gopalakrishnan K. Effect of training algorithms on neural networks aided pavement diagnosis. *International Journal of Engineering, Science and Technology*. 2010;2(2):83-92.
- [35]. Legates DR, McCabe GJ. Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water resources research*. 1999;35(1):233-41.
- [36]. Erfanian M, Bayazi M, Abghari H, Esmali Ouri A. Monthly simulation of streamflow and sediment using the SWAT in Nazlochai and prioritization of critical regions. *Journal of Watershed Engineering and Management*. 2016;552-562. [In Persian]
- [37]. Ahmadi L. Water allocation in Nazloo plain, Urima, using Weap and Vensim. Thesis for the degree of Master of Science in civil engineering. Semnan University. 2016. [In Persian]
- [38]. Noori R, Farokhnia A, Morid S, Riahi Madvar H. Effect of input variables preprocessing in artificial neural network on monthly flow prediction by PCA and wavelet transformation. *Journal of Water and Wastewater*. 2009 20(1): 13-22. [In Persian]
- [39]. Rajae T, Ebrahimi H. Application of wavelet-neural network model for forecasting groundwater level time series with non-stationary and nonlinear characteristics. *J. of Water and Soil Conservation*. 2016;22(5): 99-115. [In Persian]
- [40]. Nikmanesh MR. Prediction of monthly average discharge using the hybrid model of artificial neural network and wavelet transforms (Case study: KorRiver-Pol-e-Khan Station). *J. of Water and Soil Conservation*. 2015;22(3): 231-239. [In Persian]
- [41]. Rajae T, Jafari H. Prediction of water sodium absorption ratio (SAR) using ANN and wavelet conjunction model (case study: Rudbar Station of Sefidrud River). 2016;26(2-2):189-205. [In Persian]