

پیش‌بینی جریان روزانه رودخانه با استفاده از مدل هیبرید موجک و شبکه عصبی؛ مطالعه موردی ایستگاه هیدرومتری ونیار در حوضه آبریز آجی چای

مریم شفائی^۱، احمد فاخری فرد^۲، صابره دربندی^۳، محمدعلی قربانی^۴

تاریخ دریافت ۱۳۹۲/۰۳/۳۰

تاریخ پذیرش: ۱۳۹۲/۰۹/۲۶

مقاله برگرفته از پایان نامه کارشناسی ارشد

چکیده

با توجه به اهمیت پیش‌بینی جریان رودخانه در مدیریت منابع آب روش‌های مختلفی برای مدل کردن جریان رودخانه‌ها بکار برده می‌شوند. تا بتوان با بکارگیری این مدل در مدیریت خشکسالی و سیلاب خسارات ناشی از آن‌ها را به حداقل ممکن رساند. در این مطالعه نیز برای پیش‌بینی سری زمانی جریان روزانه ایستگاه ونیار، با توجه به ویژگی‌های غیرخطی مقیاس‌های زمانی چندگانه، مدل هیبرید شبکه عصبی و موجک پیشنهاد شده است. برای این هدف سری زمانی اصلی به مدت ۳۵ سال بوسیله تبدیل موجکی به ۱۱ زیرسری زمانی چند فرکانسی تجزیه شده، و سپس برای پیش‌بینی جریان یک و دو و سه و چهار روز آینده، این سری‌ها بعنوان داده‌های ورودی به مدل شبکه عصبی مصنوعی وارد شد. نتایج بدست آمده از تبدیل موجک-شبکه عصبی با نتایج حاصل از کاربرد شبکه عصبی، مقایسه شده و ملاحظه گردید که روش موجک-شبکه عصبی نسبت به روش شبکه عصبی دقت پیش‌بینی بالاتری دارد و همچنین دقت پیش‌بینی در هر دو مدل با افزایش تعداد تأخیرها در نرون خروجی کاهش می‌یابد. لازم بذکر است که در پیش‌بینی توسط شبکه عصبی-موجکی از دو موجک هار و میر استفاده شد که نتایج شبیه‌سازی توسط موجک میر به مراتب بالاتر از موجک هار بود.

واژه‌های کلیدی: سری زمانی چند فرکانسی، سری‌های زمانی، مدیریت منابع آب، موجک میر، موجک هار.

۱. کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب، دانشگاه

تبریز، تبریز، ایران، تلفن (۰۹۱۸۱۵۰۱۶۸۵) (MARYAMSHAFAEI65@YAHOO.COM) (نویسنده مسؤل)

۲. استاد گروه مهندسی آب، گروه مهندسی آب، دانشگاه تبریز، تبریز، ایران، تلفن (۰۹۱۴۳۱۳۵۴۹۶) (AFFARD312@YAHOO.COM)

۳. استادیار گروه مهندسی آب، گروه مهندسی آب، دانشگاه تبریز، تبریز، ایران، تلفن (۰۹۱۴۳۱۰۳۲۴۹) (SABEREHDARANDI@YAHOO.COM)

۴. دانشیار گروه مهندسی آب، گروه مهندسی آب، دانشگاه تبریز، تبریز، ایران، تلفن (۰۹۱۴۴۱۴۰۳۸۱) (CUSP2004@YAHOO.COM)

مقدمه

بدون شک مهمترین اقدام برای برنامه‌ریزی و مدیریت منابع آب تشخیص روند^۱ و پربود سیگنال است تا با استفاده از این مشخصه‌ها بتوان روند و پربوده‌های 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 ماهانه و روزانه دارای مشخصات غیرایستا^۲، پرش^۳، روند و تغییرات ناگهانی در بسامد هستند که برای مدل‌سازی آن‌ها استفاده از الگوریتم‌ها، معادلات غیرخطی و نظریه‌های جدید ریاضی ضروری به نظر می‌رسد. استفاده از شبیه‌سازها، مدل‌های فیزیکی، مدل‌های ریاضی، توزیع‌های آماری و برنامه‌های رایانه‌ای مربوطه از مواردی است که برای پیش‌بینی پدیده‌ها استفاده می‌گردد. اکنون مدل‌های هیدرولوژیکی مختلفی جهت مدل‌سازی رواناب پیشنهاد شده‌اند، اما با 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 (نوری و عبقری، ۱۳۸۶).

در حالت کلی برای تشخیص اطلاعاتی که در سیگنال مخفی می‌باشد باید از تبدیل‌کننده‌های ریاضی استفاده نمود که تبدیل فوریه یکی از این تبدیل‌کننده‌ها می‌باشد (پولیکار، ۱۹۹۶).

تبدیل موجکی تابعی است که نسخه بهبود یافته تبدیل فوریه را تداعی می‌نماید. تبدیل فوریه در آنالیز سیگنال‌های نایستا به شکست منجر می‌شود. در حالیکه تبدیل موجکی اجازه می‌دهد که سیگنال‌های نایستا نیز بخوبی آنالیز شوند (سیفوزامان و همکاران، ۲۰۰۹). شبکه‌های عصبی مصنوعی یکی از دستاوردهایی می‌باشد که با الگو برداری از مغز انسان، می‌تواند پدیده‌های پیچیده و ناشناخته را بخوبی بررسی نماید (منهاج، ۱۳۸۱). ازدیاد 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 (هیکن، ۱۹۹۹). از طرفی در مواردی متغیرها از همبستگی بالائی برخوردار هستند که استفاده از همه‌ی آنها نوعی ورود اطلاعات تکراری را به همراه دارد (ژانگ، ۲۰۰۷). که این موارد می‌توانند از یافتن مدل‌های بهینه جلوگیری کنند (برودهارست و همکاران، ۱۹۹۷).

روش‌های متفاوتی برای رفع این مشکل پیشنهاد شده‌اند. مثلاً الگوریتم ژنتیک و دیگر روش‌های بهینه‌سازی (بودن و همکاران، ۲۰۰۵). ولی در این روش‌ها نیز برخی متغیرها بطور مستقیم حذف می‌گردند و اثر آنها در نظر گرفته نمی‌شود. روش‌های دیگری نیز بعنوان پیش پردازش روی داده‌های ورودی شبکه‌های عصبی در نظر گرفته شده‌اند که از این دسته می‌توان تبدیل موجکی را نامبرد. با وجود قابلیت انعطاف مناسب ANN در مدل‌سازی سری‌های زمانی هیدرولوژی مثل رواناب (هیکن، ۱۹۹۹)، گهگاه هنگامیکه نوسانات سیگنال تا حد زیادی نا ایستا باشند و فرآیندهای هیدرولوژیکی فیزیکی در دامنه بزرگی از مقیاس‌های ۱ روزه تا چند روزه عمل می‌کنند کمبودی در ANN احساس می‌شود. و در صورتیکه پیش پردازش روی داده‌های ANN انجام نشود، شبکه‌های عصبی مصنوعی در مقابل داده‌های نا ایستا توانائی نخواهد داشت (کاناس و همکاران، ۲۰۰۶).

کاربرد موجک در شبکه عصبی موجکی بعنوان تابع آموزش، اخیراً بعنوان 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 شبکه‌های 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 (تویلارد، ۲۰۰۰). برای بهینه‌سازی بهره‌برداری از ذخیره مخزن از مدل ترکیبی الگوریتم ژنتیک و Wavelet(Coif5, Haar, Db10, Sym4) استفاده شده و با استفاده از این مدل ترکیبی بهره‌برداری سد مخزنی چند منظوره سد و نیار در تبریز را بهینه‌سازی شد و نتایج با استفاده از انحراف مربعات ماهانه کل (TSD) رها سازی و تقاضا مقایسه شد. بهترین نتایج از ترکیب GA و WT(SYM4) با انحراف مربعات ماهانه کل برابر با ۷/۴۵۳ و قابلیت اطمینان ۸۴ در صد بدست آمد

¹ -Trend² -Non stationary³ -Drift

آب‌های منطقه‌ای نسبتاً وسیع از این استان (شهرستان‌های تبریز، سراب، بستان آباد) را جمع‌آوری و به دریاچه ارومیه می‌رساند. این رودخانه، در جهت عمومی شرقی-غربی جریان دارد. آماربرداری از شاخه اصلی آبی‌چای توسط چهار ایستگاه هیدرومتری صورت می‌گیرد که یکی از این ایستگاه‌ها ونیار می‌باشد. موقعیت جغرافیایی ایستگاه ونیار در طول شرقی ۴۶ درجه و ۲۴ دقیقه و عرض شمالی ۳۸ درجه و ۷ دقیقه قرار گرفته است، و یکی از زیر حوضه‌های آبی‌چای بوده که محیط آن تا محل ایستگاه هیدرومتری ونیار ۵۲۸/۵ کیلومتر است. در این مطالعه از جریانات روزانه ونیار به مدت ۳۵ سال، (۱۱ دی سال ۱۳۵۳ تا ۲۹ اسفند ۱۳۸۷) استفاده شده است که دارای جریان روزانه میانگین ۱۰/۳۷ متر مکعب بر ثانیه و جریان روزانه ماکزیمم ۳۴۲ و مینیمم ۰ متر مکعب بر ثانیه می‌باشد.

شبکه عصبی مصنوعی

ساختار کلی ANN از سه لایه متفاوت تشکیل شده است. لایه ورودی که پخش داده در شبکه و لایه میانی که فرآیند پردازش داده را بعهده دارد. لایه خروجی نیز افزون بر پردازش داده‌ها، به ازای بردار ورودی شبکه، خروجی و عملکرد آن را نشان می‌دهد (سلطانی، ۱۳۸۱). نرون، کوچکترین یکان پردازشگر شبکه است. در شبکه عصبی مصنوعی هر نرون زمانی فعال می‌شود که مجموع سیگنال‌های رسیده به بدنه آن از حد آستانه مشخصی تجاوز نماید. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مسئله مورد بررسی مشخص می‌شود، حال آنکه تعداد نرون‌های موجود در لایه‌های پنهانی و همچنین تعداد این لایه‌ها با سعی و خطا در جهت کاهش مقدار خطا توسط طراح ارائه می‌شود (قبایی سوق و همکاران، ۱۳۸۹). اتصالاتی که بین نرون‌ها وجود دارد، دارای وزن هستند. این وزن‌ها در هنگام عبور داده‌ها از آن اتصال، در داده عبوری تأثیر می‌گذارند (سیلورمن و دراکوب، ۲۰۰۰). با وجود بسیاری از قوانین به نظر می‌رسد که شبکه عصبی از یک مجموعه از مثال‌ها می‌تواند یاد بگیرد. این یکی از مزیت‌های شبکه عصبی نسبت به روش‌های سنتی می‌باشد. به منظور فهمیدن یا طراحی فرآیند یادگیری، ابتدا باید مدل محیطی را که شبکه عصبی در آن اجرا می‌شود را در اختیار داشت، یعنی

(ابراهیمی و بارانی، ۱۳۸۴). پارتال و کیشی (۲۰۰۷) 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 بعنوان ورودی به مدل neuro-fuzzy وارد نمودند و مشاهده کردند که مدل هیبریدی حاصل، همپوشانی و تطابق خوبی را با داده‌های مشاهده شده فراهم می‌آورد. کیشی (۲۰۰۸) مدل ترکیبی با مدل کلاسیک neuro-fuzzy را 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.

نورانی و همکاران (۲۰۰۹) در مقاله‌ای ترکیب دو قابلیت شبکه‌های عصبی مصنوعی و آنالیز موجک را با کارایی بهتر در پیش‌بینی فرآیندهای هیدرولوژیکی به نام شبکه‌های عصبی-موجکی، ارائه دادند و از مدل ارائه شده برای پیش‌بینی بارش یک ماه بعد حوضه آبریز لیقوانچای واقع در آذربایجان شرقی استفاده نمودند و نتایج نشان داد که مدل شبکه عصبی-موجکی می‌تواند پیش‌بینی بارندگی را در هر دو دوره کوتاه مدت (پیش‌بینی ۱ ماه بعد) و بلندمدت (پیش‌بینی بیش از یک ماه) به علت استفاده سری‌های زمانی چند مقیاسی از لایه ورودی شبکه عصبی مصنوعی به خوبی به انجام برساند. با توجه به اهمیت پیش‌بینی‌های کوتاه مدت در مهندسی منابع آب، و ویژگی غیرخطی و ناایستای سری زمانی جریان روزانه، هدف این مطالعه اجرای یک مدل هیبریدی Wavelet-ANN به منظور پیش‌بینی جریانات روزانه ایستگاه ونیار است. و در اینجا از دو نوع مدل برای پیش‌بینی جریان روزانه استفاده شده است. اولین روش استفاده از ANN بطور مستقیم جهت پیش‌بینی جریان روزانه است و دومین روش استفاده از مدل شبکه عصبی مصنوعی-موجکی است که در آخر توانایی این دو مدل در پیش‌بینی جریان مقایسه خواهد شد. و همچنین در مدل هیبریدی موجک-شبکه عصبی دقت پیش‌بینی دو موجک هار و میر نیز ارزیابی شده و مقایسه می‌شوند.

مواد و روش‌ها

منطقه مورد مطالعه

رودخانه آبی‌چای از مهمترین رودهای حوضه ارومیه، و از رودخانه‌های مهم استان آذربایجان شرقی است. که

می‌کند. تابع محرک سیگموئیدی تانژانت هیپربولیک^۲ در زیر نشان داده شده است:

$$a(t+1)=F(\text{net}(t))=\tanh(\text{net}(t)) \quad (3)$$

پارامترهای داخلی (وزن‌ها و بایاس‌ها) بهینه را بوسیله مقایسه تخمین‌های پردازشی شبکه عصبی و مقدارهای مشاهداتی بدست آورده و در نتیجه مقدارهای تخمین زده شده را می‌تواند به مقدار حقیقی نزدیک‌تر کند. مقایسه فوق‌الذکر مبتنی بر یک ارزیابی با استفاده از تابع اجرایی می‌باشد. در اینجا از این تابع بعنوان تابع خطا نام برده شده است. یک الگوریتم را بایستی برای بهینه‌سازی پارامترهای داخلی و به منظور تولید بردار Y (بردار تخمینی) تعیین نمود بطوریکه این بردار تا حد امکان به بردار t (بردار مشاهداتی) نزدیک باشد. و تعیین این الگو سبب تولید تابع خطای مینیمم می‌باشد. این تابع به شکل زیر تعریف خواهد شد (گویندراجو و رایو، ۲۰۰۰).

$$E = \sum_{h=1}^n (t_h - y_h)^2 \quad (4)$$

تعداد داده‌ها n میباشد

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^۳ 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 بطور موثری از سیگنال متغیر در زمان استخراج می‌کند (ریول و وترلی، ۱۹۹۱). 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.

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (5)$$

اینکه چه اطلاعاتی برای فرآیند یادگیری در دسترس است. به این مدل بعنوان مدل یادگیری اشاره شده است. دوم اینکه، باید چگونگی بروز شدن وزن‌ها را درک نمود یعنی قوانین یادگیری که فرآیند بروز شدن را کنترل می‌کنند را باید فهمید. الگوریتم یادگیری به روشی که قوانین یادگیری برای تعدیل وزن‌ها در شبکه استفاده می‌شوند اشاره می‌کنند (هیکن، ۱۹۹۴). حالت سیستم در یک نقطه و در زمان معین بوسیله اصطلاح فعالسازی نرون‌های شبکه بیان می‌شود. اگر N تعداد نرون‌ها باشد، حالت سیستم می‌تواند با بردار $a(t)$ معین شود که حالت فعالسازی نرون‌ها در شبکه را معین می‌کند (دیووس، ۲۰۰۳). هر نرون دارای یک تابع خروجی می‌باشد بطوریکه حالت جاری فعالسازی را به سیگنال خروجی نگاشت میکند. خروجی با $oi(t)$ نمایش داده می‌شوند.

$$oi(t)=f(ai(t)) \quad (1)$$

تابع خروجی اغلب وابسته به مقداری به نام بایاس^۱ می‌باشد. در موقعیتی که تابع خروجی برابر با تابع همانی می‌باشد، هیچ بایاسی برای نرون استفاده نشده است. برای مثال یک بایاس ۰/۵ به این معنی است که یک تابع آستانه‌ای که بعنوان تابع خروجی استفاده می‌شود فقط در صورتیکه مقدار ورودی از ۰/۵ تجاوز کند از سیگنال عبور داده می‌شود (دیووس، ۲۰۰۳).

قانون انتشار یک شبکه، روش محاسبه‌ی شبکه ورودی $Net(t)$ یک نرون از چندین خروجی نرون همسایه را توصیف می‌کند. بطور نمونه این شبکه ورودی جمع وزنی شده ورودی‌های یک نرون می‌باشد، یعنی خروجی گره‌های قبلی که در وزن‌های ماتریسی (W) ضرب شده است (دیووس، ۲۰۰۳).

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

قانون فعالسازی اغلب تابع محرک نامیده می‌شود. و مقدار فعالسازی یک نرون بر مبنای شبکه ورودی تعیین می‌گردد. تابع F با گرفتن $a(t)$ و بردارهای $Net(t)$ برای هر نوع اتصال مختلف، یک حالت جدید فعالسازی را تولید

2-Hyperbolic tangent sigmoid activation function
3 - WaveletTransform

1 -Bias

یک سلسله فرکانس های بالا و پائین اولین بار توسط ملات پیشنهاد شده است (ملات، ۱۹۸۹). در سطح تجزیه J ، D_j که نشانگر زیر سری جزئی است بصورت زیر تعریف می شود.

$$D_j(t) = \sum_{k \in \mathbb{Z}} W_f(a, b) \psi_{(a, b)}(t) \quad (۸)$$

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 می باشد. که سیگنال اصلی از حاصل جمع همه D_j قابل حصول است.

$$S = \sum_{j \in \mathbb{Z}} D_j \quad (۹)$$

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

$$A_J = \sum_{j > J} D_j \quad (۱۰)$$

$$S = A_J + \sum_{j < J} D_j \quad (۱۱)$$

که A_J زیر سری تقریبی در سطح J است (میسیتی و همکاران، ۱۹۹۶).

در این مطالعه در مرحله اول از شبکه عصبی - موجکی برای پیش بینی جریان روزانه استفاده شده است، به این منظور ابتدا سری های زمانی اصلی جریان روزانه ایستگاه ونیار با استفاده از کد برنامه ای که در نرم افزار متلب^۵ نوشته شد، و با بکارگیری موجک میر (موجک پیچیده) و هار (موجک ساده) و توسط تبدیل موجک گسسته به ۱۱ زیر سری معین $d(t)_1, d(t)_2, d(t)_3, \dots, d(t)_{10}, a(t)_{10}$ تجزیه می شوند. هر چه تعداد مراحل منتخب برای تجزیه بیشتر باشد، سیگنال به همان تعداد به بسامدهای بالا گذر و پایین گذر تجزیه میشود و دقت کار افزایش می یابد، اما

توابع موجکی که برای آنالیز سیگنال استفاده می شوند، عبارتند از: موجک هار^۱، مرلت^۲، دابچیز^۳، میر^۴ و غیره... $\psi_{(a, b)}(t)$ با استفاده از تأخیر و تغییر مقیاس موجک مادر از فرمول زیر حاصل می گردد.

$$\psi_{(a, b)}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (۶)$$

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

تبدیل های موجکی به دو دسته موجک پیوسته و گسسته تقسیم می شوند. برای کاربردهای عملی، هیدرولوژیست ها اغلب سیگنال های زمانی پیوسته در اختیار ندارند، بلکه بیشتر سیگنال های زمانی گسسته در اختیار آنهاست. اگر انتخاب های مقیاس و موقعیت مبنی بر مزیت های هر دو (مقیاس ها و موقعیت های دوتایی) باشد، تحلیل ها دقیق خواهد بود. تبدیل موجک گسسته از بانک های فیلتر برای بازسازی سطح چند تفکیکی زمان-فرکانس بهره می برد (میری، ۲۰۰۵). این تبدیل، تبدیل موجک گسسته نامیده می شود. و به شکل زیر تعریف می شود:

$$W_f(a, b) = |a|^{-\frac{1}{2}} \sum_{k=1}^N f(k\Delta t) \psi^*\left(\frac{k\Delta t - b}{a}\right) \quad (۷)$$

$\psi^*(t)$ تابع مختلط و مرکب $\psi(t)$ است. $W_f(a, b)$ ضریب موجک است که تحت سطوح تجزیه و زمان های مختلف بدست آمده است. N تعداد گام زمانی گسسته و Δt فواصل زمانی نمونه است. $W_f(a, b)$ می تواند ویژگی های 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 (ژانگ و دانگ، ۲۰۰۱). در مرحله تجزیه تبدیل موجک گسسته سیگنال را به یک مجموعه از فرکانس های بالا و پائین تجزیه می کند. تجزیه موجک به

1 Haar
2 Morlet
3 Daubechies
4 Meyer

صحيح و خطا تعيين می‌گردد. که در اینجا بین ۳ تا ۱۰ نرون در نظر گرفته شد و در نهایت نرونی که باعث حداقل خطا گردید بعنوان تعداد نرون‌های مخفی برای ساختمان برای شبکه عصبی انتخاب شد. انتخاب نرون‌های مخفی و تعداد تکرارهای آموزش دو موضوع مهم در مدل‌سازی توسط ANN می‌باشند که باید مورد توجه قرار گیرد. بطوریکه انتخاب مناسب این دو پارامتر سبب پیشرفت مدل‌سازی در مرحله آموزش و تأیید می‌شود. در این مطالعه تعداد نرون مخفی با صحیح و خطا محاسبه گردید و تعداد تکرارها نیز ۲۰۰ انتخاب شد که آموزش شبکه را با هدف کارایی 4-10 برآورده می‌سازد و از تابع محرک تانژانت هیپربولیک و قانون یادگیری مومنتم استفاده شد. همانطور که گفته شد طول سری زمانی ۱۲۴۹۷ روز است که ۶۰ درصد داده‌ها برای آموزش (Training) و ۲۵ درصد برای تست (Test) و ۱۵ درصد برای اعتبارسنجی (Cross Validation) در نظر گرفته شد. برای ارزیابی مقدار کارایی و دقت این مدل از ضریب همبستگی و ریشه مربعات خطاها^۴ و میانگین قدر مطلق خطاها^۵ بین رواناب مشاهداتی و محاسباتی استفاده شده است.

در مرحله دوم در این بررسی، از شبکه عصبی پرسپترون چند لایه که ساختمان آن پیشخور می‌باشد، بدون پیش پردازش و تجزیه کردن داده‌ها برای پیش‌بینی جریان یک روز بعد استفاده شده است به اینصورت که سیگنال نرمال شده دبی روزانه بعنوان ورودی و سیگنال نرمال شده دبی روزانه با یک تأخیر نسبت به داده‌های ورودی، بعنوان خروجی بکار برده شد. همچنین تعداد تکرارها ۲۰۰ بوده و نرون‌های لایه مخفی از ۳ تا ۲۰ تغییر می‌کنند. سپس این پیش‌بینی‌ها برای ۲ و ۳ و ۴ روز بعد نیز انجام گرفت.

نتایج و بحث

ابتدا بدون هیچ گونه پیش پردازشی شبکه پیش‌خور پرسپترون چند لایه مدل ANN برای مدلسازی جریان روزانه استفاده می‌شود. در تحقیق حاضر مدلسازی جریان ۱ و ۲ و ۳ و ۴ روز بعد مد نظر قرار گرفته است. نتایج حاصل از آزمایش تعداد نرون‌های بالاتر از ۱۰ در لایه پنهان نشان داد که این افزایش نرون سبب کارایی بهتر نمی‌شود و دقت آن همچنان ثابت می‌ماند، که این نتیجه

از مرحله ای به بعد مقادیر بسامدها تقریباً ثابت باقی می‌ماند (طوفانی و همکاران، ۱۳۹۰)

از آنجا که هدف از تجزیه موجکی، ساده‌سازی سیگنال تا حد امکان است با استفاده از کد برنامه نوشته شده در Matlab مشاهده شد که در سطح تجزیه ۱۰ زیر سری تقریبی به مرحله‌ای می‌رسند که در آنها بسامدی مشاهده نمی‌گردد. و در زیر سری $a_{10}(t)$ ترند را می‌توان مشاهده نمود. در نتیجه موج‌های تجزیه شده در این سطح به ساده ترین شکل ممکن هستند. $d(t)_1, d(t)_2, d(t)_3, \dots, d(t)_{10}$ زیر سری‌های جزئی بوده و $a(t)_{10}$ ها زیر سری تقریبی هستند. و بعد از نرمالایز شدن توسط فرمول زیر بعنوان ورودی‌های شبکه عصبی در زمان t در نظر گرفته می‌شوند.

$$I_i = \frac{(X_i - X_{\min})}{(X_{\max} - X_{\min})} \quad (12)$$

X_i سری زمانی جریان روزانه و X_{\max} , X_{\min} به ترتیب مینیمم و ماکزیمم جریان روزانه می‌باشند.

به منظور آموزش شبکه سری زمانی نرمال جریان روزانه در زمان $T+t$ بعنوان خروجی ANN در نظر گرفته می‌شود که T طول زمان پیش‌بینی می‌باشد. بطوریکه در اینجا جمعاً ۱۱ نرون ورودی وارد شبکه عصبی شده و لازم بذکر است که دلیل استفاده از موجک میر شباهت بسیار زیاد این موجک به سیگنال جریان روزانه و نیار می‌باشد. مقایسه پیش‌بینی موجک میر با موجک هار که موجکی ساده می‌باشد، در ادامه بحث ارزیابی خواهد شد.

ثابت شده است که پرسپترون‌های چند لایه^۱ پس از آموزش با یکی از رایج‌ترین الگوریتم‌های یادگیری به نام الگوریتم پس انتشار خطا^۲ بطور رضایت بخشی در حل برخی مسائل پیچیده بکار رفته اند. این الگوریتم بر اساس قانون آموزش سعی و خطا می‌باشد. و همچنین ساختار شبکه، که بیانگر نحوه اتصالات بین نرون‌های شبکه و الگوریتم آموزش می‌باشد در اینجا بصورت پیش‌خور^۳ است. سپس سیگنال جریان روزانه را بوسیله تبدیل موجکی گسسته دو موجک میر و هار تجزیه و نتایج پیش‌بینی با هم مقایسه شدند. نرون‌های لایه مخفی بوسیله

4 -RMSE
5 -MAE

1 Multilayer perceptron
2 -Back Propagation(BP)
3 -Feed Forward

ضرایب همبستگی ($R=0.883$) در پیش بینی ۱ روز بعد نشاندهنده اجرای نسبتاً پائین شبکه عصبی در مدلسازی می باشد. که علت آن احتمالاً بخاطر معنی دار بودن نوسانات داده ها حول میانگین می باشد، بطوریکه رگرسیون کوتاه مدت بین داده ها کاهش می یابد. البته این کارایی در پیش بینی روزهای بعدی کمتر نیز می شود. نتایج پیش بینی روزهای بعدی در شبکه عصبی، کاهش دقت مدلسازی این روزها را نشان می دهد. که کاهش ضریب همبستگی و افزایش خطاها این را تأیید می نمایند. که این پدیده بخاطر کاهش حافظه جریان رودخانه در اثر افزایش تأخیرها در سیگنال خروجی می باشند. جدول ۱ دقت پیش بینی ها را در ۱ و ۲ و ۳ و ۴ روز بعد نشان می دهد.

توسط محققان دیگر نیز در هیدرولوژی اثبات شد (آبراهارت و سی، ۲۰۰۰ و نورانی و همکاران، ۲۰۰۹). هنگامیکه خطا در مرحله اعتبار سنجی بالا می رود آموزش متوقف می شود، که این امر برآزش نیافتن بیش از اندازه ی^۱ داده های مجموعه آموزش را در شبکه عصبی تأیید می کند. و پس از آن آموزش در شبکه عصبی متوقف شده و شروع به پیش بینی و تعمیم مجموعه داده های تست می کند.



جدول ۱- نتایج ضریب همبستگی و خطاهای حاصل از پیش بینی مدل شبکه عصبی






تعداد تأخیر	شبکه عصبی	ساختار	تعداد	آموزش			اعتبارسنجی			تست		
				R	RMSE	MAE	R	RMSE	MAE	R	RMSE	MAE
۱	۱-n-۱	۱-۱۰-۱	۳	۰.۸۸۳	۰.۰۰۱۱	۰.۰۱۲	۰.۷۵	۰.۰۰۰۳	۰.۰۰۷	۰.۸۹	۰.۰۰۰	۰.۰۰۶۹
۲	۱-n-۱	۱-۴-۱	۳	۰.۸۸۷	۰.۰۰۱۱	۰.۰۱۳۱	۰.۷۵	۰.۰۰۰۳	۰.۰۰۷۱	۰.۸۹	۰.۰۰۰	۰.۰۰۷۳
۳	۱-n-۱	۱-۴-۱	۴	۰.۸۵۳	۰.۰۰۱۲	۰.۰۱۳۶	۰.۷۱	۰.۰۰۰۴	۰.۰۰۷۱	۰.۸۴	۰.۰۰۰	۰.۰۰۷۵
۴	۱-n-۱	۱-۹-۱	۴	۰.۸۴۶	۰.۰۰۱۴	۰.۰۱۴۷۷	۰.۷۰	۰.۰۰۰۴	۰.۰۰۷۲	۰.۸۳	۰.۰۰۰	۰.۰۰۷۸






دیگر بیشترین وابستگی را به سیگنال اصلی جریان دارد و پریود کوتاه بوده و در ضمن نقش معنی داری در پیش بینی جریان بعهده دارد. نتایج این پیش‌بینی در جدول ۲ نمایش داده شده است. همانطور که در جدول ۲ مشاهده می‌شود کارایی و دقت مدل‌های حاصل از تجزیه با موجک هار پایین‌تر از نتایج موجک میر می‌باشد که پله ای بودن و ساده بودن شکل این موجک علت آن می‌باشد. در صورتیکه موجک میر به علت شباهت به سیگنال جریان روزانه و پیچیدگی اش، موجب بالا رفتن کارایی مدل شبکه عصبی-موجک گردیده است. با مقایسه نتایج جدول ۱ و ۲، یا بعبارت دیگر مقایسه شبیه‌سازی مدل شبکه عصبی با مدل موجک-شبکه عصبی کارایی و دقت بالاتر مدل‌سازی شبکه عصبی-موجکی نسبت به شبکه عصبی مشاهده می‌گردد. دقت بالاتر مدل شبکه عصبی-موجکی نه تنها بخاطر پیش پردازش و پارتیشن‌بندی موجک به زیر سیگنال‌های مختلف است بلکه علت آن می‌تواند بخاطر توجه به تأثیر هر زیر سیگنال تجزیه‌ای بوسیله بزرگنمایی نسبی وزن آن زیر سیگنال باشد.

در مرحله بعد به منظور افزایش دقت مدل، داده‌های پیش پردازش شده توسط تبدیل موجکی گسسته و با بکارگیری موجک هار و میر بعنوان 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. یکی از اهداف این تحقیق مطالعه روی تأثیر نوع موجک مادر، روی مدل‌سازی می‌باشد. که در اینجا دو نوع موجک مادر هار و میر بمنظور مقایسه استفاده شده‌اند. و ۱۱ زیر سری $d(t)_1, d(t)_2, d(t)_3, \dots, d(t)_{10}, a(t)_{10}$ توسط موجک هار و میر محاسبه شده و وارد شبکه شدند. این ۱۱ زیر سری در شکل (۱) نمایش داده شده‌اند. دلیل استفاده از سطح ۱۰ در تجزیه موجکی رسیدن به ترند کامل در این سطح می‌باشد. بطوریکه همه جزئیات سیگنال در زیر سری‌های جزئی آن و هویتش در زیرسری تقریبی نشان داده شده. در بررسی دیگری نیز از همین تعداد تکرار (۲۰۰) برای پیش‌بینی بارش-رواناب بهره گرفته شد و نتایج مطلوبی حاصل شد (نورانی و همکاران، ۲۰۰۹).

هنگامیکه زیر سری‌ها بعنوان ورودی به شبکه عصبی وارد می‌شوند، شبکه عصبی به هر کدام از زیر سری‌های تجزیه‌ای وزن خاصی اختصاص می‌دهد بطوریکه وزن‌های بالا به سطوح با ارزش سیگنال اختصاص می‌یابند. مثلاً در سطح تجزیه ۱۰ شبکه عصبی وزن بالاتر را به d_{10} نسبت خواهد داد، چرا که d_{10} نسبت به زیر سیگنال‌های







شکل (۱) - زیر سری جزئی و تقریبی d_1 تا d_{10} حاصل از تجزیه موجکی


جدول ۲- نتایج ضریب همبستگی و خطاهای حاصل از پیش بینی مدل شبکه عصبی-موجکی با بکاربردن موجک هار و میر

تعداد تأخیر	موجک	سازمان شبکه	آموزش			اعتبارسنجی			تست		
			R	RMSE	MAE	R	RMSE	MAE	R	RMSE	MAE
۱	میر	۱۱-۱۰-۱	۰٫۹۶۸	۰٫۰۰۰۳	۰٫۰۰۶	۰٫۹۴	۰٫۰۰۰۱	۰٫۰۰۳	۰٫۹۷	۰٫۰۰۰۱	۰٫۰۰۳۲
۱	هار	۱۱-۸-۱	۰٫۹۵	۰٫۰۰۰۳	۰٫۰۰۶	۰٫۹۱	۰٫۰۰۰۱	۰٫۰۰۳	۰٫۹۶	۰٫۰۰۰۱	۰٫۰۰۳۳
۲	میر	۱۱-۴-۱	۰٫۹۴	۰٫۰۰۰۵	۰٫۰۰	۰٫۸۸	۰٫۰۰۰۲	۰٫۰۰۵	۰٫۹۴	۰٫۰۰۰۲	۰٫۰۰۵
۲	هار	۱۱-۹-۱	۰٫۸۶۲	۰٫۰۰۱۲	۰٫۱۰	۰٫۷۴	۰٫۰۰۰۵	۰٫۰۱۴	۰٫۸۴	۰٫۰۰۰۶	۰٫۰۱۶۹
۳	میر	۱۱-۴-۱	۰٫۹۴	۰٫۰۰۰۵	۰٫۰۱	۰٫۸۸	۰٫۰۰۰۲	۰٫۰۰۵	۰٫۹۳	۰٫۰۰۰۲	۰٫۰۰۵۷
۳	هار	۱۱-۸-۱	۰٫۷۶	۰٫۰۰۲۱	۰٫۰۲۶	۰٫۲۷	۰٫۰۰۰۸	۰٫۰۱۹	۰٫۷۰	۰٫۰۰۰۹	۰٫۰۱۶
۴	میر	۱۱-۹-۱	۰٫۹۲	۰٫۰۰۰۷	۰٫۰۱	۰٫۸۴	۰٫۰۰۰۲	۰٫۰۰۶۲	۰٫۹۰	۰٫۰۰۰۳	۰٫۰۰۶۷
۴	هار	۱۱-۴-۱	۰٫۸۰	۰٫۰۰۱۶	۰٫۰۲	۰٫۷۱	۰٫۰۰۰۵	۰٫۰۱۱	۰٫۷۸	۰٫۰۰۰۶	۰٫۰۱۲۵


پیش‌بینی جریان روزانه و سطح آب زیرزمینی دقت پیش‌بینی را نسبت به روش‌های آماری و ANN بالا می‌برد. در شکل (۲) برازش مدل شبکه عصبی-موجکی روی سری زمانی جریان در مرحله آموزش و برای پیش‌بینی ۱ روز بعد مشاهده می‌شود. تطابق این مدل بر روی داده‌های مشاهده‌ای از برازش نمودار شکل (۳) 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 توانائی شبیه‌سازی پیک‌های غیر معمول را دارا می‌باشد.

این نتایج مطابق با نتایج آداموسکی و کارن (۲۰۱۰) می‌باشد که روشی را مبنی بر تبدیل موجک گسسته و شبکه عصبی مصنوعی برای پیش‌بینی جریان رودخانه غیر دائمی در حوضه‌ای نیمه خشک ارائه دادند. کارائی نسبی هیبرید موجک و شبکه عصبی با شبکه عصبی برای پیش‌بینی جریان ۱ تا ۳ روز بعد و برای دو رودخانه مختلف مقایسه شد. در هر دو مورد، در هر دو رودخانه مدل هیبریدی دقت بیشتری را نسبت به شبکه عصبی مصنوعی ارائه داد. نتایج نشان دادند که هیبرید موجک و شبکه عصبی یک روش بهبود بخش برای پیش‌بینی کوتاه مدت در حوضه‌های نیمه خشک با رودخانه غیر دائمی می‌باشد. و همچنین در یک بررسی مدل شبکه موجکی را برای پیش‌بینی جریان روزانه رودخانه گات^۱ غربی هند و سطح آب زیرزمینی ماهانه در دلتای گوداواری^۲ هند بکار برده شد. نتایج نشان دادند که شبکه موجکی در


1-Ghat
2-Godavari




شکل (۲) - تطابق مقادیر رواناب روزانه و رواناب محاسباتی بوسیله مدل هیبریدی برای مدلسازی ۱ روز آینده در مرحله آموزش




شکل ۳- تطابق رواناب پیش بینی شده در مقابل رواناب مشاهده شده برای پیش بینی دبی یک روز بعد در روش موجک-شبکه عصبی با موجک میر در مرحله آموزش



شکل (۴) - تطابق مقادیر رواناب روزانه و رواناب محاسباتی بوسیله مدل هیبریدی و موجک میر در مرحله تست برای پیش بینی ۱ روز بعد



شکل ۵- تطابق دبی پیش بینی شده در مقابل دبی مشاهده شده برای پیش بینی دبی یک روز بعد در روش موجک-شبکه عصبی با موجک میر در مرحله تست



شکل ۶- تطابق مقادیر رواناب روزانه و رواناب محاسباتی دبی پیک (شکل ۳) بوسیله مدل هیبریدی و موجک میر در مرحله تست

نتیجه گیری

در این مطالعه شبیه سازی مدل شبکه عصبی مصنوعی با شبکه عصبی موجکی برای پیش بینی ۱ و ۲ و ۳ و ۴ روز بعد در جریان روزانه ایستگاه ونیار مقایسه گردید و اولین نتیجه ای که از این مقایسه گرفته شد حاکی از برتری کامل مدل پیش بینی شبکه عصبی-موجکی نسبت به مدل شبکه عصبی در پیش بینی جریان روزانه می باشد. با اینکه مدل ANN بخاطر در اختیار داشتن کرنل غیرخطی توانایی مدلسازی رفتارهای غیرخطی را داراست، ولی با توجه به ویژگی های نا ایستائی و غیر خطی بودن سری زمانی جریان روزانه ونیار، به منظور پیش بینی و

مرحله بعد مدل سازی (روز ۹۳۷۴-۱۲۴۹۷) با استفاده از مدل آموزش برای پیش بینی ۱ روز بعد می باشد. شکل (۴) مقادیر محاسباتی و مشاهداتی را در مرحله تست نشان می دهد. همچنین تطابق رواناب پیش بینی شده و مشاهده شده را در شکل (۵) بصورت واضح تر می توان مشاهده نمود. که همپوشانی این نمودار بر روی نیمساز مؤید دقت بسیار رضایت بخش این روش در پیش بینی می باشد. نکته قابل توجه در این نمودار تطابق مقادیر مشاهداتی و محاسباتی در دبی های پیک می باشد. که شکل (۶) این برازش را به خوبی نمایش می دهد.

و سومین نتیجه‌ای که از این تحقیق گرفته می‌شود، این است که با افزایش تأخیر در سیگنال خروجی دقت پیش‌بینی در هر دو مدل (شبکه عصبی و شبکه عصبی-موجکی) کاهش می‌یابد. که بدلیل کم شدن حافظه جریان رودخانه همزمان با افزایش تأخیر می‌باشد. نتیجه چهارم اینکه استفاده از موجک میر دقت پیش‌بینی مدل هیبریدی را افزایش می‌دهد. ولی نتایج استفاده از موجک هار به مراتب پائین‌تر از موجک میر می‌باشد. که این نیز به دلیل ساده بود موجک مادر هار نسبت به شکل موجک میر می‌باشد.

شبیه‌سازی دقیق ملزم به استفاده از شبکه عصبی-موجکی می‌باشیم. چرا که شبکه عصبی به تنهایی قادر به غلبه بر ناپیوستگی سیگنال نمی‌باشد. در حالیکه تبدیل موجکی با جدا نمودن سیگنال به فرکانس های بالا و پائین ویژگی های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. و همچنین در مدل هیبریدی دقت پیش‌بینی دبی پیک که مهمترین قسمت مدل‌سازی سیل می‌باشد بالا می‌رود.

منابع

۱. ابراهیمی، ل. و غ. بارانی. ۱۳۸۴. معرفی مدل تلفیقی تبدیل موجکی و شبکه های عصبی برای پیش بینی خشکسالی حوزه های آبخیز سدها. مجموعه مقالات دومین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک، ۳ و ۴ اسفند ۱۳۸۴، دانشگاه کرمان، ص ۲۳۵۴-۲۳۵۹
۲. سلطانی، س. ۱۳۸۱. مقایسه مدل های تفهیمی در مقایسه با شبکه های عصبی مصنوعی در شبیه سازی بارش- رواناب. پایان نامه کارشناسی ارشد، دانشگاه تربیت مدرس، ص ۹۸.
۳. طوفانی، پ.، ا. مساعدی، و ا. فاخری فرد. ۱۳۹۰. پیش بینی بارندگی با استفاده مستقیم از نظریه موجک. نشریه آب و خاک. ۲۵، ص ۱۲۱۷-۱۲۲۶.
۴. قبائی سوق، م.، ا. مساعدی و ح. موسی هزار جریبی. ۱۳۸۹. ارزیابی تأثیر پیش پردازش پارامترهای ورودی به شبکه عصبی مصنوعی با استفاده از روشهای رگرسیون گام به گام و گاما تست به منظور تخمین سریعتر تبخیر و تعرق روزانه. نشریه آب و خاک، دانشگاه فردوسی مشهد. جلد ۲۴ شماره ۳، ص ۶۱۰-۶۲۴.
۵. منهاج، م. ۱۳۸۱. مبانی شبکه های عصبی (هوش محاسباتی). جلد اول، مرکز نشر دانشگاهی صنعتی امیرکبیر، صفحه ۷۱۵.
۶. نوری، م.، ه. عبقری. ۱۳۸۶. شبیه سازی بارش- رواناب با شبکه های عصبی تابع بنیادی شعاعی (RBF) مبتنی بر طبقه بندی شبکه عصبی احتمالاتی (PNN). لوح فشرده مجموعه مقالات سومین کنفرانس آبخیزداری و مدیریت منابع آب و خاک، ۲۰ و ۲۱ آذر ۱۳۸۶، دانشگاه کرمان.
7. Abrahart, R.J.; L. See. 2000. comparing neural network (NN) and Auto Regressive Moving Average (ARMA) techniques for the provision of continuous river flow forecasts in two contrasting catchment. *Hydrological Process*, 14:2157-2172.
8. Adamowski, Jan.; Karen. 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* vol, 390:85-91.
9. Bowden, G.J.; G.C. Dandy; H.R. Maier. 2005. Input determination for neural network models in water resources applications. Part I. background and methodology. *J. of Hydrologic*. 301:75-92.
10. Broadhurst, D.; R. Goodacre; A. Jones; J.J. Rowland and D.B. Kell. 1997. Genetic algorithms as a method for variable selection in multiple linear regression and partial least squares regression, with applications to pyrolysis mass spectrometry. *Anal. Chim. Acta*. 348 (1-3): 71-86.
11. Cannas, B.; A. Fanni; L. See and G. Sias. 2006. Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning. *Phys Chem Earth*. 31(18):1164-1171.
12. de Vos, N.J. 2003. Rainfall-Runoff Modelling Using Artificial Neural Networks. M. Sc. Thesis Report., Civil Engineering Informatics Group and Section of Hydrology & Ecology.
13. Govindaraju, Rao S. 2000. Artificial neural networks in hydrology II: hydrologic applications. *Journal of Hydrologic Engineering*. 5(2):124-137, ASCE.
14. Haykin, S. 1994. *Neural Networks: a comprehensive foundation*. Mac Millan College. Publishing Company New York.

15. Haykin, S.1999. Neural networks: a comprehensive foundation, 2nd Ed., Prentice Hall., New Jersey, USA.
16. Kisi, O .2008. Stream flow forecasting using neuro-wavelet technique. Hydrol. Process. Vol, 22:4142–4152.
17. Mallat, S. 1989. Thories for multiresolution signal decomposition: the wavelet representation ,IEEE Pattern Anal. and Machine Intell.11(7): 93-674.
18. Merry, R.J.E. 2005. Wavelet Theory and Applications. A literature study. Eindhoven University of Technology Department of Mechanical Engineering Control Systems Technology Group.
19. Misiti, M.; Y. Misiti; G. Oppenheim and J.M. Poggi. 1996. “Wavelet Toolbox”..
20. Nourani ,V.; M. Komasi and A. Mano .2009. A Multivariate ANN-Wavelet Approachfor Rainfall–Runoff Modeling. Water Resour Manage 23: 2877–2894.
21. Partal, T.; O. Kisi. 2007. Wavelet and neruro-fuzzy conjunction model for precipitation forecasting. Journal of Hydrology 342: 199-212.
22. Polikar, R. 1996. Fundamental Concept and An Oveview Of The Wavelet Theory Wavelet Tutorial. SECOND EDITION. ROWAN UNIVERSITY. COOLLEGE OF ENGINEERING WEB SERVERS. GLASSBORO .NJ.08028.
23. Rioul, O.; M. Vetterli. 1991. Wavelets and signal processing. IEEE SP Magazine. p-p, 14–38.
24. Sifuzzaman, M.; M.R. Islam; M.Z. Ali .2009. Application of Wavelet Transform and its Advantages Compared to Fourier Transform. Journal of Physical Sciences, 13:121-134.
25. Silverman, D.; J. A. Dracup.2000. Artificial neural network and long range precipitation prediction in California. Journal of Applied Meteorology 39(1):57-66.
26. Thuillard, M .2000. A review of wavelet networks ,wavelets, fuzzy wavelets and their application. ESIT.in:Presented in Conference 14-15 September.
27. Zhang, BL .; ZY. Dong .2001. An adaptive neural wavelet model for short term load forecasting. Electr Power Syst Res. 59:121–129.
28. Zhang, Y.X. 2007. Artificial neural networks based on principal component analysis input selection for clinical pattern recognition analysis. Talanta. 73 (1):68-75.

Archive of SID

Predicrion Daily Flow of Vanyar Station Using ANN and Wavelet Hybrid Procedure

Maryam shafaei¹,ahmad fakhei fard²,sabereh darbandi³,mohammadali ghorbani⁴

Abstract

According to the importance of river flow forecasting in water resources management, various methods are considered to model the flow in rivers. For the propose of minimizing the flood or drought hazard from the view point of management. Having nonlinear features and multiple time scales, the time series of daily flow were considered to be analised using artificial neural network (ANN) and wavelet hybrid procedures. For this purpose the original time series for 35 years was decomposed to 11 multi-frequency subseries by wavelet transform and then in order to predict the flow of future 1, 2, 3, and 4 days, this sub series was entered as input data to ANN model. The results of the Application modeling of wavelet- ANN with the results of modeling of ANN is compared, and it was observed that method of wavelet-neural networks has a higher forecast accuracy than method of ANN and also forecast accuracy in both models with increasing number of delays in the output neurons is reduced, and it was observed that in predicte by wavelet-neural networks were used from Haar wavelet and Meyer wavelet that results the simulation of Meyer wavelet were more accurate than Haar wavelet.

Keyword: Haar wavelet ,Meyer wavelet, Multi-frequency time series, Time series, Water resources management

¹.MSc in water resource engineering,Tabriz University,Tabriz,Iran,maryamshafaei65@yahoo.com.

².Professor ,department of water engineering, Tabriz University,Tabriz,Iran,affard312@yahoo.com.

³.Assistant Professor, department on water engineering, Tabriz University,Tabriz,Iran,saberehdarbandi@yahoo.com.

⁴.Associate Professor, department on water engineering, Tabriz University, Tabriz,Iran,culp2004@yahoo.com.