

مرتع و آبخیزداری، مجله منابع طبیعی ایران
دوره ۶۸، شماره ۳، پاییز ۱۳۹۴

تاریخ دریافت: ۱۳۹۲/۲/۳

تاریخ پذیرش: ۱۳۹۲/۸/۲۳

ص ۵۷۱-۵۵۳

پیش‌بینی بارندگی ماهانه با استفاده مستقیم از موجک و

شبکه عصبی موجکی

- ❖ **پریوش طوفانی؛** کارشناس ارشد مهندسی منابع آب دانشگاه علوم کشاورزی و منابع طبیعی گرگان
- ❖ **احمد فاخری فرد؛** استاد، گروه مهندسی آب دانشگاه تبریز
- ❖ **ابوالفضل مساعدی*؛** استاد دانشکده منابع طبیعی و محیط زیست دانشگاه فردوسی مشهد
- ❖ **امیراحمد دهقانی؛** دانشیار گروه مهندسی آب دانشگاه علوم کشاورزی و منابع طبیعی گرگان

چکیده

برآورد و پیش‌بینی بارش اهمیت ویژه‌ای دارد. به دلیل نبود قطعیت، هیچ یک از مدل‌های آماری و مفهومی نتوانسته‌اند به منزله یک مدل برتر در الگوسازی دقیق بارش شناخته شوند. اخیراً، به کاربرد موجک در آنالیز سیگنال‌ها و سری‌های زمانی در هیدرولوژی توجه شده است. در این تحقیق، سیگنال بارندگی با استفاده از موجک مادر منتخب تجزیه شد و داده‌های به‌دست‌آمده با دو روش برازش معادلات مستقیم و هیبرید عصبی-موجکی برای پیش‌بینی استفاده شد. روش مذکور در پیش‌بینی بارندگی ماهانه ۳۳ سال ایستگاه زرین‌گل از سال آبی ۱۳۵۴ - ۱۳۵۵ تا ۱۳۸۶ - ۱۳۸۷ به‌کار گرفته شد و نتایج با یکدیگر مقایسه شد. نتایج نشان داد تجزیه سیگنال با موجک به طور قابل ملاحظه‌ای موجب افزایش همبستگی میان داده‌های مشاهداتی و محاسباتی می‌شود و سیگنال بارندگی با دقت بیشتری پیش‌بینی می‌شود؛ به طوری که در روش مستقیم میزان R^2 برابر با ۰٫۷۴ و در روش هیبرید عصبی-موجکی در بهترین حالت برای چهار سطح تجزیه برابر ۰٫۹۵ است. این نتیجه قدرت موجک در ساده‌سازی سیگنال و افزایش دقت پیش‌بینی داده‌های کاملاً تصادفی بارندگی را در منطقه مورد نظر تأیید می‌کند. ضمن آنکه، معنی‌دار نبودن تست F در سطح ۹۰ درصد و بالاتر تأیید دیگری بر این مطلب است.

واژگان کلیدی: بارش، پیش‌بینی، تئوری موجک، زرین‌گل، سیگنال، هیبرید عصبی-موجکی.

مقدمه

اطلاعات ثبت شده حداقل سی ساله از کل بارندگی ماهانه یک منطقه می تواند راهنمای کار مناسبی برای پیش بینی سیلاب های منطقه و محاسبه ضریب رواناب و همچنین استفاده از مدل های مناسب بارندگی - رواناب یک منطقه باشد. حال اگر اطلاعات به کمک روش های مناسب آماری به کار گرفته شود، می توان الگوریتم مناسبی برای محاسبه یا تخمین بارندگی در سال های آتی به صورت کل بارندگی ماهانه و سالانه به دست آورد. استفاده از آمار بارندگی می تواند الگوی کشت مناسبی برای برنامه ریزی سطح زیر کشت، با توجه به نیاز آبی گیاهان زراعی منطقه، فراهم آورد. بنابراین، علاوه بر موارد بیان شده، پیش بینی بارندگی می تواند به برنامه ریزی آبیاری، مدیریت زراعی و مدیریت مراتع و حوضه های آبخیز بسیار کمک کند.

پیش بینی بارش برای همه کشورهای، به ویژه کشورهای در حال توسعه، که اقتصاد آنها مبتنی بر کشاورزی و دام پروری است، بسیار مهم است. در سال های اخیر، تحقیقات وسیعی در زمینه پیش بینی های میان مدت و بلندمدت بارندگی (ماهانه و فصلی) در نقاط مختلف جهان انجام یافته است. امروزه، محققان، با ابداع و پیشرفت روش هایی چون روش های هوشمند - که ابزاری توانمند، انعطاف پذیر و مستقل از مدل های دینامیکی سیستم اند - در جستجوی راه هایی برای پیش بینی دقیق تر پارامترهای مهم هواشناسی اند. هوش محاسباتی یکی از موفق ترین و مستعدترین روش ها برای کنترل عدم قطعیت در سیستم ها و مدل های مهندسی است [۱]. در دهه اخیر، با توجه به پیشرفت و گسترش روزافزون زمینه های مختلف هوش مصنوعی، توجه

برآورد و پیش بینی بارش و تعیین رواناب ناشی از آن در مدیریت و بهره برداری صحیح از حوضه، مدیریت سدها و مخازن، و همچنین به حداقل رسانی خسارات ناشی از سیلاب، خشکسالی و مدیریت منابع آب نقش اساسی و مؤثری ایفا می کند. پیش بینی هر واقعه ای اساس مدیریت بحران آن را تشکیل می دهد و این امکان زمانی حاصل می شود که بتوان مدل های پیش بینی مناسب را در اختیار داشت [۱۲]. بیشتر سیگنال های هیدرولوژیکی، به ویژه فصلی و ماهانه، دارای مشخصات غیرایستا^۱، دریفت، تمایل^۲ (روند) و تغییرات ناگهانی در فرکانس اند [۹]؛ برای مدل سازی آنها کاربرد الگوریتم ها، معادلات غیرخطی و تئوری های جدید ریاضی ضروری به نظر می رسد. یک مدل هیدرولوژیکی ساختاری است که بتواند، با توجه به ویژگی های حوضه و عوامل مؤثر بر پدیده مورد نظر، تعامل و رفتار آن را با تقریب قابل قبولی نشان دهد. به منظور پیش بینی پدیده ها از شبیه سازها، مدل های فیزیکی، مدل های ریاضی، توزیع های آماری و نرم افزارهای موجود رایانه ای استفاده می شود.

تاکنون مدل های هیدرولوژیکی مختلفی برای مدل سازی بارندگی پیشنهاد شده است. اما، با توجه به ماهیت غیرخطی، عدم قطعیت، عدم صراحت زیاد و ویژگی های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ یک از مدل های آماری و مفهومی پیشنهاد شده به منظور الگوسازی دقیق بارش نتوانسته اند مدلی برتر و توانا شناخته شوند و این مسئله همواره دارای پیچیدگی های ویژه ای است.

1. nonstationary

2. trend

با مدل نروفازی نشان داد که مدل هیبریدی موجکی نروفازی به خوبی با داده‌های مشاهداتی - به خصوص برای سری‌های زمانی که در ماه‌های تابستان مقدار بارشی برابر صفر دارند و برای مقادیر حداکثر در زمان آزمون - منطبق می‌شود و پیش‌بینی این مدل از مدل عصبی - فازی دقیق‌تر است [۱۳].

با استفاده از شبکه‌های عصبی - موجکی می‌توان کارایی بهتر ترکیب شبکه‌های عصبی مصنوعی و آنالیز موجک را در پیش‌بینی فرایندهای هیدرولوژیکی نشان داد. در این راستا، به منظور مدل‌سازی برای پیش‌بینی بارش یک ماه بعد حوضه آبریز ليقوان‌چای، واقع در آذربایجان شرقی، سه موجک *db4 Haar* و *Meyer* به کار گرفته شد. به دلیل ساختار ساده و ابتدایی موجک *Haar*، نتایج به دست آمده حاکی از برتری موجک *Haar* نسبت به دو موجک *db4* و *Meyer* است و نیز نشان‌دهنده آن است که مدل شبکه عصبی - موجکی می‌تواند هر دو وقوع کوتاه‌مدت و بلندمدت بارندگی را، به علت استفاده سری‌های زمانی چندمقیاسی از لایه ورودی شبکه عصبی مصنوعی، پیش‌بینی کند [۱۱].

مدل رگرسیون موجکی (*WR*) با توسعه دو مدل موجک گسسته و رگرسیون خطی ایجاد شده است. این مدل برای شبیه‌سازی آبدهی فصل بهار رودخانه‌ها در مناطق کارستی و آنالیز سری مشاهداتی داده‌ها و نیز به عنوان ابزاری برای تفسیر داده‌های سری تولیدشده به وسیله مدل به کار گرفته شد [۱۵]. در مطالعه دیگری با استفاده از مدل رگرسیون موجکی (*WR*) به پیش‌بینی جریان روزانه کوتاه‌مدت دو ایستگاه از رودخانه فیلوس در منطقه غرب دریای سیاه ترکیه پرداخته شد. در مرحله اول مطالعه،

بسیاری از محافل علمی و مهندسی زمینه‌های مختلف به این مقوله معطوف شده است. به کارگیری و ترکیب روش‌های هوشمند - همچون شبکه عصبی مصنوعی^۱، منطق فازی^۲ و الگوریتم ژنتیک^۳ - برای کنترل سیستم‌ها بسیار مورد توجه قرار گرفته است [۱۰].

استفاده از شبکه عصبی در هیدرولوژی و منابع آب در سال‌های اخیر رشد چشمگیری داشته و چنین ویژگی‌ای آن را به ابزاری مناسب برای پیش‌بینی‌های هیدرولوژیکی تبدیل کرده است. از طرفی، پیش‌پردازش الگوهای آموزشی قبل از ورود به شبکه عصبی و تلفیق شبکه عصبی با دیگر روش‌های ریاضی و آماری می‌تواند نقش مؤثری در بالا بردن دقت پیش‌بینی‌ها و مدل‌سازی بارش - رواناب داشته باشد [۱۲]. از جمله روش‌هایی که می‌توان با آن‌ها داده‌ها را پیش‌پردازش کرد آنالیز موجکی گسسته^۴، سیستم‌های فازی^۵، تجزیه به مؤلفه اصلی^۶ و خوشه‌بندی^۷ است [۱۱].

آموزش شبکه عصبی مصنوعی با پیش‌پردازش داده‌ها و با استفاده از تبدیل موجکی پیوسته و گسسته اثر بهتری در آموزش شبکه تجزیه‌ناپذیر سیگنال‌های نارس آشفته^۸ دارد [۳]. تجزیه داده‌های بارش‌های روزانه سه ایستگاه ترکیه با استفاده از تبدیل موجکی به تعدادی زیرسری و سپس استفاده از این زیرسری‌ها به عنوان ورودی مدل نروفازی برای پیش‌بینی بارش روزانه و در نهایت مقایسه این مدل

1. artificial neural networks
2. fuzzy logic system
3. genetic algorithm
4. discrete wavelet transform
5. fuzzy system
6. principal component analysis
7. clustering
8. noisy

بسیار کمک کند. روش‌های کاربردی مختلف پیش‌بینی بارندگی همواره با خطاهایی همراه است. با توجه به اینکه داده‌های بارندگی ماهیتی تصادفی و پرریودیک دارند و می‌توانند همانند سیگنالی پیچیده عمل کنند، می‌توانند خصوصیات سیگنال‌ها را داشته باشند و با شناسایی خصوصیات سیگنالی، که به آن مشابهت بیشتری دارند، می‌توان آن‌ها را دقیق‌تر پیش‌بینی کرد. از این رو، در این تحقیق سعی شده است به مقایسه مقادیر واقعی بارندگی ماهانه در ایستگاه زرین‌گل استان گلستان با نتایج پیش‌بینی بارندگی ماهانه با به‌کارگیری تئوری موجک برای تجزیه سیگنال بارندگی و استفاده از آن به صورت تابع مستقیم سینوسی و نیز به صورت هیبرید عصبی پرداخته شود و دقت این روش در منطقه مورد مطالعه ارزیابی شود.

روش‌شناسی تحقیق

موقعیت منطقه مورد بررسی

ایستگاه زرین‌گل یکی از ایستگاه‌های باران‌سنجی استان گلستان است و در موقعیت ۵۴ درجه و ۵۷ دقیقه طول شرقی و ۳۶ درجه و ۵ دقیقه عرض شمالی در ارتفاع ۲۸۰ متری از سطح دریا، با میانگین سالانه ۸۰۸ میلی‌متر بارندگی، در کنار رود زرین‌گل واقع شده است (شکل ۱). در این تحقیق از سری زمانی مقادیر بارندگی ماهانه ایستگاه زرین‌گل استفاده شد. نحوه به‌کارگیری داده‌ها به طور خلاصه در ادامه معرفی می‌شود: نخست آمار بارندگی ماهانه ایستگاه زرین‌گل از سال آبی ۱۳۵۴ - ۱۳۵۵ تا ۱۳۸۶ - ۱۳۸۷ (شامل ۳۹۶ ماه) جمع‌آوری شد. این آمار کامل و فاقد داده مفقود بود. جدول ۱ مشخصات آماری آن را

مدل‌های WR ، شبکه عصبی و مدل $ARMA$ برای پیش‌بینی داده‌های جریان یکروزه به‌کار گرفته شد. نتایج نشان داد که روش WR از دو روش دیگر (شبکه عصبی و مدل $ARMA$) بهتر عمل می‌کند؛ ضمن آنکه روش $ARMA$ تا اندازه‌ای نتایج بهتری از روش شبکه عصبی به دست می‌دهد. در مرحله بعد، از دو روش WR و شبکه عصبی برای پیش‌بینی جریان دو و سه‌روزه استفاده شد. نتایج این بخش هم نشان داد که پیش‌بینی حاصل از مدل WR دقیق‌تر از شبکه عصبی است [۷]. از مدل تبدیلات موجکی گسسته و شبکه‌های عصبی برای پیش‌بینی جریان یک و سه‌روزه در رودخانه‌های دائمی حوضه‌های نیمه‌خشک کارگوتیس و گزروس در قبرس استفاده شد. نتایج نشان‌دهنده دقیق‌بودن روش شبکه‌های عصبی - موجکی برای پیش‌بینی جریان کوتاه‌مدت در این حوضه‌هاست [۲].

با استفاده از روش‌های هیبرید مدل برنامه‌ریزی ژنتیک موجکی و مدل نروفازی موجکی به پیش‌بینی بارندگی روزانه پرداخته شد. نتایج نشان داد که هیبرید برنامه‌ریزی ژنتیک موجکی و نروفازی موجکی پیش‌بینی بارش روزانه را به مقدار زیادی نسبت به مدل‌های برنامه‌ریزی ژنتیکی و نروفازی بهبود می‌بخشد؛ ضمن آنکه مدل برنامه‌ریزی ژنتیکی موجکی در مقایسه با مدل هیبرید فازی موجکی قدرت پیش‌بینی بیشتری دارد [۸].


با توجه به اینکه مقدار و زمان وقوع بارندگی نقش مهمی در نحوه مدیریت منابع آب یک منطقه دارد، پیش‌بینی این متغیر هواشناسی و هیدرولوژیکی می‌تواند به مدیران، برنامه‌ریزان، کشاورزان و سایر مردم در زمینه برنامه‌ریزی و استفاده بهینه از منابع آب

بارش ایستگاه زرین گل فاقد روند و بیانگر آن است که میانگین بارش در طول سالیان متمادی تغییر محسوسی نداشته است.

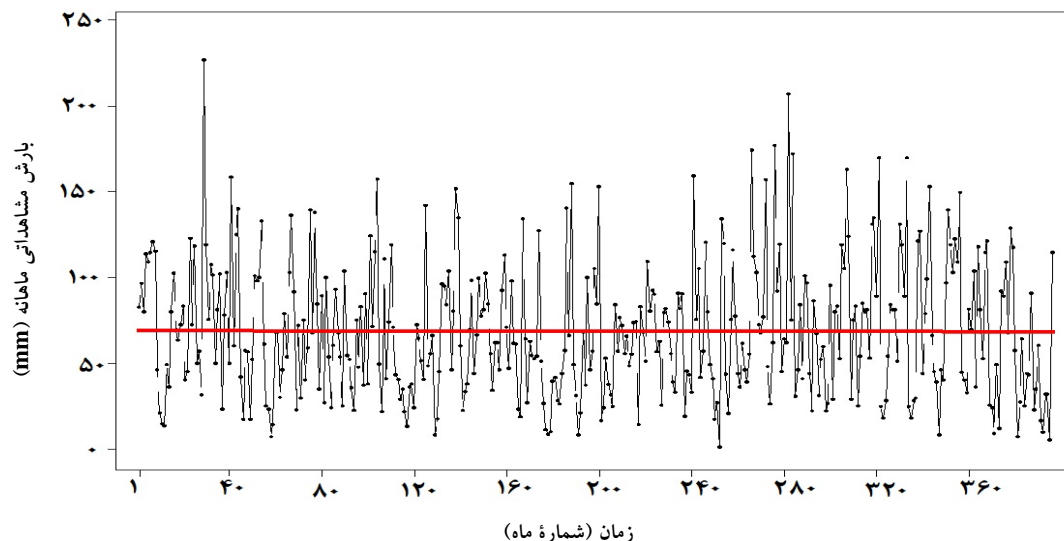
نشان می‌دهد. شکل ۲ نمودار سری زمانی این داده‌ها و روند آن‌ها را نشان می‌دهد. بررسی روند سری مشخص شده در شکل ۲ نشان می‌دهد که داده‌های

جدول ۱. مشخصات آماری مقادیر بارش ماهانه (mm) ایستگاه زرین گل در طول دوره آماری مورد استفاده

میانگین	حداکثر	حداقل	انحراف معیار	ضریب تغییرات
۶۸٫۶۹	۲۲۷	۱	۳۹٫۵۷	۰٫۵۷۶



شکل ۱. موقعیت جغرافیایی ایستگاه زرین گل در استان گلستان



شکل ۲. نمودار سری زمانی و روند بارش ماهانه ایستگاه زرین گل در طول دوره آماری مورد بررسی

موجک

پیوسته موجکی^۲ (CWT)؛^۲ تبدیل گسسته موجکی^۳ (DWT).

تبدیل پیوسته موجکی با یکی از روابط زیر (رابطه‌های ۲ یا ۳) بیان می‌شود:

(۲)

$$CWT(\text{Scale}, \text{Position}) = \int_{-\infty}^{\infty} f(t)\psi(\text{scale}, \text{position})dt$$

یا به صورت زیر:

$$CWT_s^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int s(t)\psi_{s,\tau}^*(t)dt \quad (۳)$$

رابطه فوق تابعی از دو متغیر s و τ است. τ نشان‌دهنده انتقال^۴، s بیانگر مقیاس^۵ (عکس فرکانس) و علامت * نشان‌دهنده مزدوج مختلط^۶ است. پارامترهای s و τ اعداد حقیقی‌اند و s همیشه مثبت است و ممکن است مقادیر پیوسته یا گسسته به خود بگیرد. s و τ در تبدیل موجکی پیوسته دارای مقادیر پیوسته و در تبدیل گسسته دارای مقادیر گسسته‌اند. $\psi(t)$ تابع موجک مادر^۷ نامیده می‌شود. عبارت مادر به این دلیل به کار رفته که توابع (موجک‌های) متفاوت به وجود آمده بر اساس پارامترهای مقیاس و انتقال همگی از تابع پایه (موجک مادر) ناشی می‌شوند. به عبارت دیگر، موجک مادر موجک اصلی برای تولید توابع پنجره دیگر است. از انواع موجک‌های مادر می‌توان به موجک میر^۸، سیملت^۹، مورلت^{۱۰}، هار^{۱۱} و

به هر کمیت متغیر در زمان یا مکان که قابل اندازه‌گیری باشد سیگنال می‌گویند. برای آنالیز سیگنال‌ها از مبدل‌های ریاضی استفاده می‌شود تا بتوان اطلاعاتی به دست آورد که از سیگنال‌های خام به راحتی قابل دسترس نیست. تبدیل موجک یکی از مبدل‌های ریاضی کارآمد در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی‌ای هستند که شکل مقیاس- زمان را از سری‌های زمانی و روابط آن‌ها برای آنالیز سری‌های زمانی، که شامل متغیرها و غیرثابت‌هاست، ارائه می‌دهند.

تحلیل موجکی^۱ استفاده از فاصله‌های زمانی طولانی مدت را برای اطلاعاتی با فرکانس پایین و تناوب‌های کوتاه‌تر را برای اطلاعاتی با فرکانس بالا ارائه می‌دهد. تحلیل موجکی قادر به نمایش جنبه‌های مختلف داده‌های متفاوت، نقاط شکست و ناپیوستگی‌هاست که ممکن است دیگر روش‌های آنالیز سیگنال آن‌ها را نشان ندهند [۱، ۴].

موجک به معنی موج کوچک است و دارای سه مشخصه است: تعداد نوسان محدود؛ بازگشت سریع به صفر در هر دو جهت مثبت و منفی در دامنه خود؛ و میانگین صفر. این سه ویژگی، که شرط مقبولیت نامیده می‌شود، شرایط لازم برای تابعی است که بتواند به عنوان تبدیل موجکی عمل کند و به شکل رابطه ۱ بیان می‌شود:

$$\int \psi(t)dt = 0 \quad (۱)$$

که در آن $\psi(t)$ تابع موجکی است.

دو نوع تبدیل موجکی وجود دارد: ۱. تبدیل

2. Continues Wavelet Transform
3. Discrete Wavelet Transform
4. translation
5. scale
6. complex conjugate
7. mother wavelet
8. meyer
9. symlet
10. morlet
11. haar

1. wavelet analysis

بارش روزانه، ماهیتی گسسته دارند. بنابراین، از تبدیل موجک گسسته برای تجزیه و بازسازی این سری‌های زمانی استفاده می‌شود [۱۶].

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی مدل‌های ریاضی و انعطاف‌پذیری هستند که در مدل‌سازی سیستم‌های پیچیده به کار می‌روند. همچنین، این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نورون‌ها یک نگاشت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه دهند. پردازش در شبکه‌های عصبی مصنوعی بر اساس بسیاری از واحدهای پردازش، که نورون نام دارد، انجام می‌شود. هر نورون در هر لایه به همه عناصر لایه قبل و بعد با یک سری وزن‌هایی متصل شده است. توانایی کلی شبکه عصبی مصنوعی یادگیری ارتباط غیرخطی بین داده‌ها و تعمیم نتایج برای داده‌های دیگر است [۶]. در مسائل سری‌های زمانی تعداد نورون‌های ورودی به تعداد مشاهدات تأخیر داده‌شده که برای یافتن ارتباط موجود در سری‌های زمانی و برای پیش‌بینی‌های مقادیر آینده استفاده می‌شود. بستگی دارد [۵]. لایه میانی و نورون‌ها در ارائه بهتر عملکرد شبکه نقش مهمی دارند.

اصولاً وارد نمودن داده‌ها به صورت خام به شبکه عصبی باعث کاهش سرعت و دقت شبکه می‌شود. برای دوری از چنین شرایطی و همچنین به منظور یکسان‌کردن ارزش داده‌ها برای شبکه عمل نرمال‌سازی صورت می‌گیرد؛ این کار مانع کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نورون‌ها می‌شود. بنابراین، قبل از

کلاه مکزیکی^۱ اشاره کرد. کلیه توابع پنجره $\psi_{s,\tau}^*(t)$ که از تابع مادر ساخته می‌شوند، موجک‌های دختر^۲ نامیده می‌شوند و از رابطه ۴ به دست می‌آیند. ضریب مقیاس با حروف a یا s نمایش داده می‌شود [۴].

$$\psi_{s,\tau}(t) = \psi\left(\frac{t-\tau}{s}\right) \quad (4)$$

مقیاس به طور ساده به معنای کشیده شدن یا فشرده شدن موجک است و میزان کشش یا مدت زمان موجک را بیان می‌کند. انتقال موجک به طور ساده به مفهوم به تأخیر انداختن یا جلو انداختن موجک و بیان‌کننده موقعیت موجک بر روی محور زمان است.

تبدیل گسسته موجکی برای پیش‌پردازش و آنالیز سری‌های زمانی مناسب‌تر از تبدیل موجکی پیوسته است، زیرا داده‌های تبدیل‌یافته با DWT اجزای اضافی ندارند. بنابراین، تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان-فرکانس به کار برد.

فرایند تجزیه سیگنال شامل یک یا چند مرحله است که در تجزیه چندمرحله‌ای موج پس از اولین مرحله تفکیک با تجزیه مجدد قسمت تقریبی تجزیه موج ادامه می‌یابد. از آنجا که در تجزیه سیگنال توسط موجک همه اطلاعات پنهان در سیگنال استخراج می‌شود، روش‌های ابتدایی پردازش داده‌ها، نظیر نرمال‌سازی داده‌های خام، تأثیری در تجزیه ندارد و نتایج تجزیه حاصل از هر دو حالت یکسان است. بنابراین، از داده‌های خام بارندگی بدون هیچ‌گونه پیش‌پرداز اولیه داده‌ها استفاده شد. سری زمانی داده‌های مشاهداتی، نظیر جریان‌های ماهانه و

1. mexican hat
2. daughter wavelet

اول معادله‌ای مستقیم برای پیش‌بینی استخراج شد و در روش دوم، بر اساس کارهایی که پیش از این انجام شده بود، داده‌های حاصل از تجزیه به عنوان ورودی شبکه عصبی تعریف شد. در ادامه هر یک از این دو روش و مزایا و معایب هر یک شرح داده می‌شود.

روش مستقیم

پس از استخراج داده‌های حاصل از تجزیه، نوبت استفاده از این داده‌ها برای ساختن معادله‌ای مناسب به منظور پیش‌بینی در ماه‌های آینده است. در این روش، بعد از تجزیه سیگنال توسط موجک، برای هر یک از جزئیات و تقریب یک معادله مناسب برازش داده شد. بدین منظور، از جعبه ابزار *Curve fitting* موجود در نرم‌افزار متلب ویرایش ۷٫۶ استفاده شد. هر یک از جزئیات ۲ تا ۱۰ و تقریب ۱۰ام به عنوان ورودی وارد برنامه شد. سپس، از میان معادلاتی نظیر فوریه، گوسین^۳، چندجمله‌ای^۴، توانی^۵، مجموع سینوسی^۶ و ویبل^۷، که برازش داده شده بودند، معادله‌ای انتخاب شد که داده‌های محاسباتی حاصل از آن بیشترین مقدار R^2 و کمترین مقدار *RMSE* را با داده‌های مشاهداتی داشته باشد. از بین همه معادلات، معادله مجموع سینوسی مرتبه هشتم (رابطه ۶) شامل این شرایط است:

(۶)

$$f(x) = a_1 \times \sin(b_1 x + c_1) + a_2 \times \sin(b_2 x + c_2) + a_3 \times \sin(b_3 x + c_3) + a_4 \times \sin(b_4 x + c_4) + a_5 \times \sin(b_5 x + c_5) + a_6 \times \sin(b_6 x + c_6) + a_7 \times \sin(b_7 x + c_7) + a_8 \times \sin(b_8 x + c_8)$$

آموزش، برای نرمال‌سازی داده‌های مورد استفاده، بر اساس رابطه ۵، داده نرمال شد.

$$x_{normal} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (5)$$

که در این رابطه x_i مقادیر بارندگی ماهانه، x_{min} کمترین مقدار بارندگی ماهانه، x_{max} بیشترین مقدار بارندگی ماهانه و x_{normal} داده‌های نرمال شده است.


برای اجرای این تحقیق، نخست سیگنال بارش توسط نظریه موجک تجزیه شد. برای تجزیه می‌توان از جعبه ابزار^۱ موجود در نرم‌افزار متلب^۲ استفاده کرد. اما، با توجه به محدودیت‌های موجود برای مراحل تجزیه و نوع موجک مادر منتخب، برنامه کامل تجزیه در *M.File* نرم‌افزار متلب ویرایش ۷٫۶ گدنویسی شد. سپس، تجزیه صورت پذیرفت. این گد امکان تجزیه تا مراحل مورد نظر و استخراج ضرایب و داده‌های بازسازی شده را برای موجک مادر منتخب فراهم می‌کند. نخست باید موجک مادر مناسب از بین موجک‌های گسسته موجود انتخاب شود. برای انتخاب موجک مادر شباهت کلی سیگنال با موجک‌های مختلف بررسی شد و در نهایت، موجکی انتخاب شد که با تغییر پارامترهای مقیاس و انتقال بیشترین قدرت تطبیق با داده‌های مشاهداتی را داشت. سپس، به کمک گد برنامه نوشته شده در نرم‌افزار متلب سیگنال بارندگی تجزیه شد.

پس از استخراج داده‌های حاصل از تجزیه، نوبت استفاده از این داده‌ها برای پیش‌بینی و ساختن معادله‌ای مناسب به منظور پیش‌بینی در ماه‌های آینده است. بدین منظور، از دو روش استفاده شد: در روش

3. gaussian
4. polynomial
5. power
6. sum of sin function
7. weibull

1. toolbox
2. matlab

۶۰ درصد داده‌ها برای آموزش^۱ شبکه، ۱۵ درصد داده‌ها برای تست صحت آموزش^۲ و ۲۵ درصد داده‌ها برای صحت‌سنجی^۳ انتخاب شد. سپس، داده‌های دسته اول برای آموزش شبکه وارد شبکه عصبی شد. پس از انتخاب شبکه برای هر سری از ورودی‌ها، شبکه مد نظر بر روی داده‌های صحت‌سنجی شده اجرا شد و مقادیر پیش‌بینی به دست آمد. سپس، این مقادیر با مقادیر واقعی مقایسه و نتایج به دست آمده بررسی شد.



شکل ۳. نمایش مدل هیبرید موجکی به صورت شماتیک

نتایج

همان‌گونه که ذکر شد، نخستین قدم برای تجزیه سیگنال با موجک، انتخاب موجک مادر است. برای انتخاب موجک مادر، شکل سری زمانی ترسیم شد. با دریافت کلی از شکل سری زمانی شباهت زیادی بین سری زمانی حاصل از داده‌ها و شکل موجک مادر میر وجود دارد؛ شکل ۴ آن را نشان می‌دهد. موجک میر نتیجه بهتری نسبت به سایر موجک‌های مادر بر روی سیگنال بارندگی دارد [۱۱]. بنابراین، این موجک به منزله موجک مادر انتخاب شد.

که در این رابطه a ، b و c ضرایب معادله سینوسی و x زمان وقوع بارش‌ها بر حسب شماره ماه است؛ که اولین ماه شماره ۱ و آخرین ماه شماره ۳۹۶ است.

در نهایت، داده‌های حاصل از تجزیه با رابطه ۷، که معادله بازسازی سیگنال حاصل از تجزیه موجک است، بازسازی شد.

$$S = \sum_{i=1}^n d_n + a_n \quad (7)$$

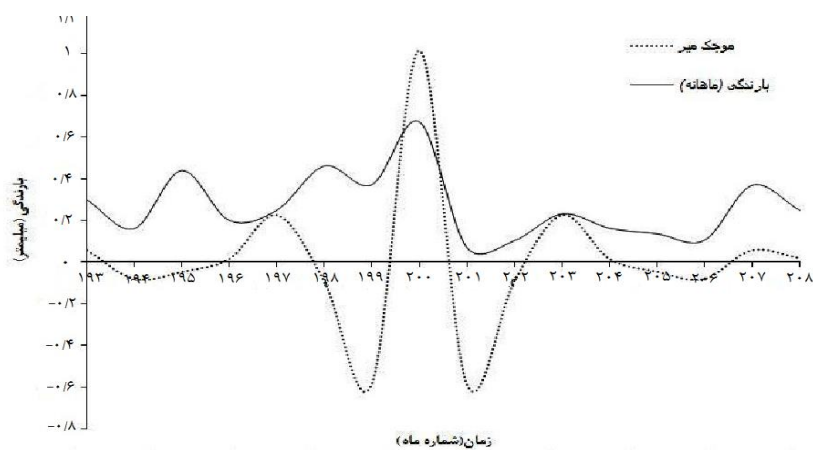
که در آن S سیگنال مد نظر، d جزئیات، a تقریب و n آخرین مرحله تجزیه است.

سپس، داده‌ها به دو دسته ۸۵ درصد (از ماه ۱ تا ماه ۳۳۶) و ۱۵ درصد (ماه ۳۳۷ تا ۳۹۶) تقسیم شد و برای ۸۵ درصد داده‌ها معادلات مناسب برازش یافت و پس از رسیدن به معادله مطلوب از آن برای پیش‌بینی بارندگی استفاده و نتایج حاصل از آن با ۱۵ درصد باقی مانده داده‌ها مقایسه شد.





هیبرید عصبی - موجکی

در این روش داده‌های حاصل از تجزیه توسط موجک به عنوان ورودی شبکه عصبی تعریف شد. شکل ۳ نمایش شماتیک مدل را نشان می‌دهد. بدین منظور، نخست داده‌های حاصل از تجزیه موجک با استفاده از رابطه ۵ برای ورود به شبکه عصبی نرمال‌سازی شد. سپس، داده‌های ۳ تا ۱۰ مرحله تجزیه هر یک به صورت جداگانه به عنوان ورودی‌های شبکه عصبی تعریف شد، مثلاً برای ۵ مرحله تجزیه ۶ ورودی (۵ ورودی جزئیات و ۱ ورودی تقریب) برای شبکه عصبی تعریف شد. بدین منظور، داده‌های هر ورودی به سه دسته تقسیم شد:

1. taining
2. checking
3. testing



شکل ۴. موجک میر و پنجره تصادفی سیگنال بارش ماهانه (ماه‌های شماره ۱۹۳ تا ۲۰۸)



شکل ۵. نمودار سری زمانی داده‌های مشاهداتی و $d2$ ، $d5$ ، $d8$ و $a10$

۱۲ مرحله استفاده شد. نتایج حاصل از هر یک از مراحل تفاوتی چندانی در بخش جزئیات (d) با یکدیگر نداشتند، اما از آنجا که مراحل بالا در تجزیه حاوی خصوصیات و تغییرات کلی داده‌ها در طول زمان است و همچنین در معادله نهایی آخرین تقریب


هر چه تعداد مراحل منتخب برای تجزیه بیشتر باشد، سیگنال به همان تعداد به فرکانس‌های بالاگذر و پایین‌گذر تجزیه می‌شود و دقت کار افزایش می‌یابد، اما از مرحله‌ای به بعد مقادیر فرکانس‌ها تقریباً ثابت باقی می‌ماند. در این تحقیق از ۸، ۱۰ و

به منظور پیش‌بینی در ماه‌های آینده است. از بین همه معادلات، معادله مجموع سینوسی مرتبه هشتم (معادله ۶) شامل این شرایط بود. برای dl نیز از معادلات سری زمانی استفاده شد. چون dl نویز محسوب می‌شد و در صورت ورود به عنوان تابع سینوسی در معادلات، مقدار R^2 را به شدت کاهش می‌داد. نتیجه نشان داد که نتایج حاصل از معادلات برازش داده‌شده همبستگی بسیار زیادی با داده‌های مشاهده‌ای دارد و مقدار ضریب تبیین در حدود 0.93 به دست آمد که در شکل ۶ مشاهده می‌شود.

(a) دخیل است و به نوعی بار اصلی داده‌ها را بر عهده دارد، مراحل بالاتر ارجحیت دارد. از طرفی، a_{10} با a_{12} تفاوت محسوسی نداشت، به همین علت برای جلوگیری از ورود معادلات اضافی در محاسبات، در نهایت، ۱۰ مرحله تجزیه انتخاب شد. شکل ۵ نمودار حاصل از تجزیه برای مراحل ۲، ۵ و ۸ جزئیات و مرحله ۱۰ تقریب و سری زمانی مشاهداتی را نشان می‌دهد.

روش مستقیم

پس از استخراج داده‌های حاصل از تجزیه، نوبت استفاده از این داده‌ها برای ساختن معادله‌ای مناسب



شکل ۶. نمودار همبستگی میان داده‌های مشاهده‌ای و محاسباتی بارندگی ماهانه

آن‌ها به عنوان داده محاسباتی با داده‌های مشاهده‌ای مقایسه شد. در مرحله بعد، به هر یک از تجزیه‌ها یا برای مجموع برخی از تجزیه‌ها معادلات برازش داده شد. در نهایت، برای هر یک از جزئیات مرحله ۱ تا ۵ یک معادله جداگانه انجام شد و برای جزئیات ۶ تا ۱۰ و تقریب ۱۰ مقادیر با هم جمع شد. سپس، معادله مناسب برازش داده شد (رابطه ۸).

بدین ترتیب، مشخص شد که این روش قدرت تطابق کافی با داده‌های مشاهده‌ای را دارد. سپس، داده‌ها به دو بخش ۸۵ درصد و ۱۵ درصد تقسیم شد. برای ۸۵ درصد داده‌ها معادلات مناسب برازش داده شد و از معادله نهایی برای پیش‌بینی و صحت‌سنجی ۱۵ درصد باقی‌مانده استفاده شد. برای رسیدن به نتیجه مطلوب، در مرحله اول به هر یک از تجزیه‌ها معادله مناسبی برازش داده شد. سپس، حاصل جمع

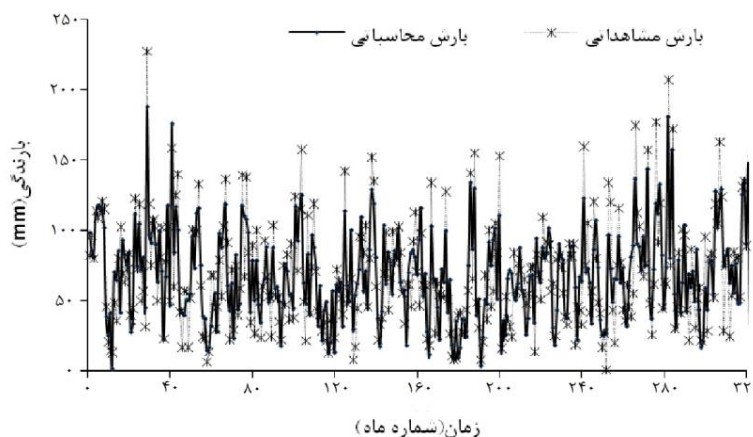
(۸)

$$\begin{aligned}
\text{Function} = & 9.675 \times \sin(1.049x - 0.09724) + 10.9 \times \sin(1.037x - 3.319) + 6.864 \times \sin(1.1x - 0.09202) + \\
& 5.756 \times \sin(1.318x + 1.122) + 5.413 \times \sin(0.9056x + 1.844) + 5.428 \times \sin(0.8733x - 0.04809) + \\
& 5.71 \times \sin(1.401x - 1.186) + 5.038 \times \sin(1.221x + 3.201) + 18.57 \times \sin(0.523x - 1.043) + \\
& 5.773 \times \sin(0.5707x + 0.815) + 15.9 \times \sin(0.552x - 3.761) + 6.931 \times \sin(0.4802x - 0.09095) + \\
& 46.09 \times \sin(0.736x + 1.365) + 3.285 \times \sin(0.589x + 1.905) + 17.6 \times \sin(0.556x - 1.31) + \\
& 43.7 \times \sin(0.737x + 4.298) + 6.783 \times \sin(0.222x + 2.942) + 61.16 \times \sin(0.262x + 1.623) + \\
& 42.3 \times \sin(0.2903x + 0.681) + 3.664 \times \sin(0.319x - 0.7308) + 3.767 \times \sin(0.367x + 1.374) + \\
& 59.34 \times \sin(0.261x - 1.374) + 40.09 \times \sin(0.291x + 3.658) + 2.084 \times \sin(0.335x + 0.652) + \\
& 6.305 \times \sin(0.152x + 2.734) + 100.3 \times \sin(0.202x + 2.008) + 21.73 \times \sin(0.2058x + 1.734) + \\
& 63.98 \times \sin(0.1175x - 4.04) + 6.633 \times \sin(0.188x + 0.686) + 4.458 \times \sin(0.145x - 0.00056) + \\
& 61.78 \times \sin(0.118x - 1.018) + 118.5 \times \sin(0.202x - 1.103) + 109.5 \times \sin(0.0067x + 0.438) + \\
& 50.22 \times \sin(0.013x + 2.541) + 6.892 \times \sin(0.0423x + 1.365) + 256.6 \times \sin(0.088x + 0.94) + \\
& 4.718 \times \sin(0.045x + 3.8) + 3.588 \times \sin(0.059x - 0.683) + 252.4 \times \sin(0.088x - 2.199) + \\
& 1.541 \times \sin(0.107x - 1.826)
\end{aligned}$$


است. با به دست آمدن معادله نهایی و جای گذاری زمان‌های مورد نظر در معادله پیش‌بینی صورت گرفت. نتایج به دست آمده از پیش‌بینی نشان داد که انتقال واریانس با استفاده از تجزیه سیگنال بهبود می‌یابد (شکل ۹). مقدار ضریب تبیین برای این سری داده‌ها در حدود ۰٫۷۴ به دست آمد؛ شکل ۱۰ آن را نشان می‌دهد.

نتایج به دست آمده نشان داد که معادله نهایی برازش یافته به خوبی فرکانس را منتقل می‌کند (شکل ۷) و با ضریب تبیین ۰٫۸۴ همبستگی بسیار زیادی میان داده‌های بارندگی ماهانه (که کاملاً تصادفی‌اند) و داده‌های محاسباتی دارد (شکل ۸).

همان‌گونه که مشاهده می‌شود، معادله پیش‌بینی شامل شش معادله مجموع سینوسی مرتبه هشتم




شکل ۷. نمودار تطابق داده‌های بارندگی ماهانه مشاهده‌ای - محاسباتی



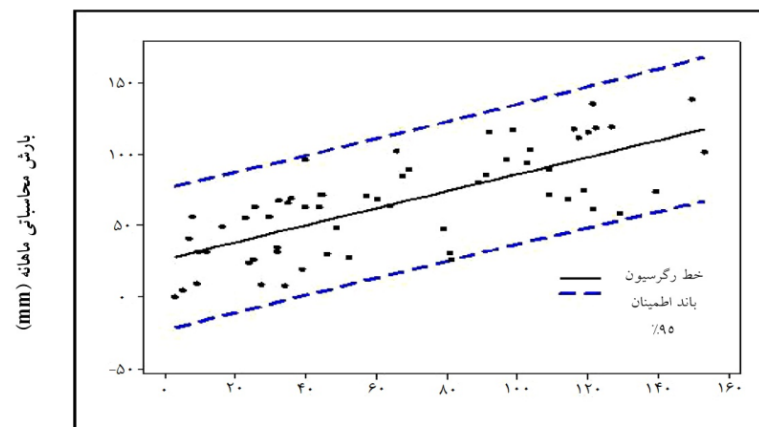
بارش مشاهده‌ای ماهانه (mm)

شکل ۸. نمودار همبستگی میان ۸۵ درصد از داده‌های بارندگی ماهانه مشاهده‌ای و محاسباتی



زمان (شماره ماه)

شکل ۹. نمودار تطابق داده‌های بارندگی ماهانه مشاهده‌ای و پیش‌بینی شده



بارش مشاهده‌ای ماهانه (mm)

شکل ۱۰. نمودار همبستگی میان ۱۵ درصد داده‌های بارندگی ماهانه مشاهده‌ای و پیش‌بینی شده

ورودی‌های شبکه عصبی تعریف شد. سپس، داده‌های دسته اول برای آموزش شبکه وارد شبکه عصبی شد. نتایج نشان داد که شبکه عصبی تأخیر زمانی (TDNN) و شبکه بازگرداننده تأخیر زمانی (TLRN) بیشترین همبستگی و کمترین $RMSE$ را با داده‌های بارش مشاهده‌ای دارند. پس از انتخاب شبکه برای هر سری از ورودی‌ها، شبکه مورد نظر بر روی داده‌های صحت‌سنجی اجرا شد. جدول ۲ نتایج آن را نشان می‌دهد. همچنین، این جدول (جدول ۲) مقدار ضریب تبیین به دست آمده از روش هیبرید موجکی برای هر مرحله از تجزیه توسط موجک را نشان می‌دهد.

از میان سطوح تجزیه، تجزیه در ۴ مرحله بیشترین میزان همبستگی را نشان داد. جدول ۳ نتایج به دست آمده برای این سطح تجزیه و شکل ۱۱ نمودار حاصل از مقادیر همبستگی و سطوح تجزیه را نشان می‌دهد.

اجرای تست F روی نسبت اختلاف واریانس مشاهدات و محاسبات به واریانس مشاهدات و همچنین روی نسبت واریانس محاسبات به مشاهدات نشان داد که داده‌های مشاهداتی و پیش‌بینی در سطوح اعتماد ۹۰ درصد، ۹۵ درصد و ۹۹ درصد اختلاف معنی‌دار ندارند و هر دو به یک جامعه آماری تعلق دارند. این بدان معنی است که پیش‌بینی مستقیم از طریق امواج تجزیه شده توسط موجک به خوبی واریانس را منتقل می‌کند.

هیبرید عصبی - موجکی


همان طور که مطرح شد، برای اجرای این تحقیق داده‌های ورودی به سه دسته تقسیم شد: ۶۰ درصد داده‌ها برای آموزش شبکه، ۱۵ درصد داده‌ها برای تست صحت آموزش و ۲۵ درصد داده‌ها برای صحت‌سنجی انتخاب شد و هر یک از تجزیه‌های مراحل ۳ تا ۱۰ به صورت جداگانه به عنوان

جدول ۲. نتایج حاصل از هیبرید موجکی


$RMSE$		R^2		Train epoch	تعداد ورودی	نوع شبکه	سطح تجزیه
صحت‌سنجی	آموزش	صحت‌سنجی	آموزش				
۰,۰۴۵	۰,۰۲۸	۰,۹۴۵۵	۰,۹۶۹۶	۱۰۰	۴	TDNN-B-L	۳
۰,۰۳۵	۰,۰۳۳	۰,۹۵۴۷	۰,۹۶۶۸	۱۰۰	۵	TDNN-B-L	۴
۰,۰۴۶	۰,۰۳۲	۰,۹۴۶۱	۰,۹۶۰۴	۱۰۰	۶	TDNN-B-L	۵
۰,۰۴۸	۰,۰۲۴	۰,۹۳۴۵	۰,۹۷۷۹	۱۰۰	۷	TDNN-B-L	۶
۰,۰۸۷	۰,۰۴	۰,۸۲۱۳	۰,۹۳۸۷	۱۰۰	۸	TLRN-O-M	۷
۰,۰۶۳	۰,۰۴۷	۰,۸۹۵۸	۰,۹۷۱۲	۱۰۰	۹	TLRN-O-M	۸
۰,۱۰۵	۰,۰۴۵	۰,۷۲۸۸	۰,۹۲۶۹	۱۰۰	۱۰	TDNN-O-M	۹
۰,۱۲۳	۰,۰۵۶	۰,۷۵۹۵	۰,۸۷۸۹	۱۰۰	۱۱	TDNN-O-M	۱۰

جدول ۳. نتایج تعدادی از معیارهای آماری به دست آمده از هیبرید موجکی برای سطح تجزیه ۴


صحت سنجی	تست صحت آموزش	آموزش	سطح تجزیه ۴
۹۹	۵۹	۲۳۶	تعداد داده‌ها
۰٫۰۳۴	۰٫۰۶۸	۰٫۰۳۳	RMSE
۰٫۹۵۴۵	۰٫۸۸۶۷	۰٫۹۶۶۶	R^2
۰٫۰۰۰۲	۰٫۰۰۳۳	۰٫۰۰۰۰۲۷۴	کمترین مقدار خطا
۰٫۰۸۷	۰٫۳۲۲۲	۰٫۱۹۵۲	بیشترین مقدار خطا
۰٫۰۲۹۲	۰٫۰۴۷۸	۰٫۰۲۵۲	خطا میانگین (MAE)
TDNN-1-B-L			نوع شبکه



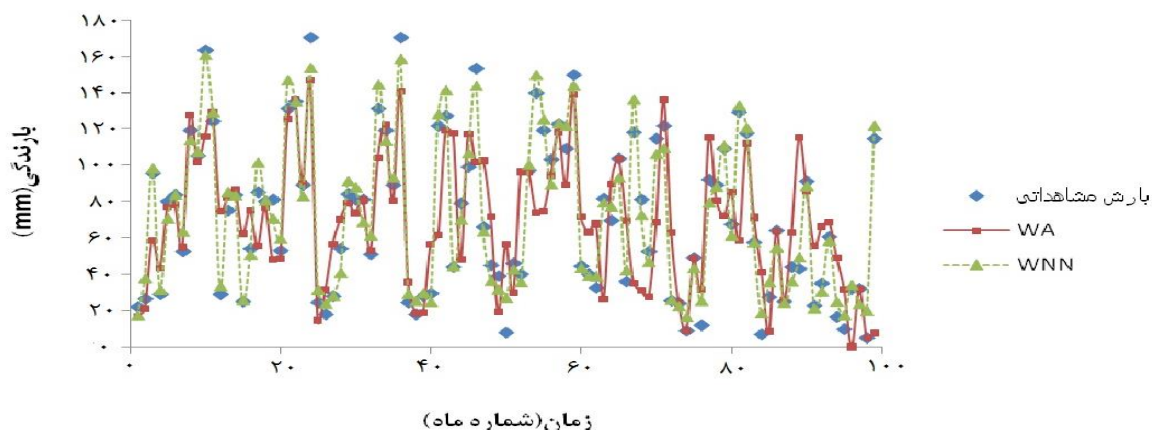
شکل ۱۱. تغییرات ضریب تبیین نسبت به مراحل تجزیه سیگنال



شکل ۱۲. نمودار فرکانسی d7 و d8



شکل ۱۳. نمودار فرکانسی a7 و a8



شکل ۱۴. نمودار مقایسه‌ای روش‌های به‌کار گرفته‌شده در پیش‌بینی بارش ماهانه ایستگاه زیرین گل

$a7$ و $a8$ مربوط می‌شود. شکل ۱۴ نمودار مقایسه‌ای دو روش به‌کار گرفته‌شده در این تحقیق با داده‌های مشاهداتی را نشان می‌دهد.

بحث و نتیجه‌گیری

نتایج این تحقیق نشان داد که تجزیه سیگنال به امواج ساده‌تر امکان مدل‌شدن داده‌هایی با حالت تصادفی را فراهم می‌کند و دقت پیش‌بینی نسبت به روش‌های مرسوم را افزایش می‌دهد. هر تجزیه (d) یک سری تغییرات واریانس در اشل‌های کوچک و بزرگ را نشان می‌دهد. فرکانس‌های کوتاه‌تر نشان‌دهنده

با افزایش تعداد سطوح تجزیه، از مرحله ششم به بعد مقدار R (یا R^2) کاهش می‌یابد و نشان می‌دهد که با افزایش تعداد ورودی‌ها به شبکه عصبی دقت کاهش می‌یابد و با افزایش تعداد فرکانس‌های پایین‌گذر (d) به عنوان ورودی‌های شبکه عصبی خطای بیشتری وارد محاسبات می‌شود. از طرفی، عدم تطابق فازها موجب سیر نزولی نمودار نشان‌داده‌شده در شکل‌های ۱۲ و ۱۳ شده است. تفاوت بسیار زیاد میان مقدار ضریب تبیین ۷ و ۸ مرحله به تفاوت و اختلاف فاز میان $d7$ و $d8$ و نیز

نتایج به دست آمده از این بخش تحقیق است؛ با این تفاوت که در این تحقیق از موجک میر و شبکه TDNN برای تجزیه سری زمانی بارش استفاده شده است.

تجزیه سیگنال‌های بارش حوضه آبریز ليقوان‌چای به کمک موجک‌های *db4*, *Haar* و *Meyer* نشان داد که مدل عصبی - موجکی می‌تواند بارندگی را، به علت کاربرد سری‌های زمانی چندمقیاسی از لایه ورودی شبکه عصبی مصنوعی، به خوبی پیش‌بینی کند [۱۱]؛ این نتیجه با نتایج به دست آمده از این بخش تحقیق به خوبی منطبق است.

استفاده از مدل تبدیلات موجکی گسسته و شبکه‌های عصبی نشان داد که شبکه‌های عصبی - موجکی روش مؤثری برای پیش‌بینی جریان به صورت کوتاه‌مدت‌اند [۲]؛ این نتیجه با نتایج به دست آمده در این تحقیق کاملاً همخوانی دارد. همچنین، استفاده از روش‌های هیبرید موجکی قدرت پیش‌بینی بارندگی را نسبت به روش‌های نروفازی و برنامه‌ریزی ژنتیک بهبود می‌بخشد [۸]؛ این نتیجه نیز با نتایج به دست آمده از روش هیبرید موجکی عصبی تطابق دارد.

مقایسه دو روش ذکر شده با یکدیگر نشان داد که تجزیه سیگنال بارندگی با استفاده از روش موجک موجب استخراج خواص مستتر در سیگنال و، در نتیجه، موجب افزایش قدرت و دقت پیش‌بینی می‌شود. در روش مستقیم قدرت تطبیق داده‌های تجزیه سطوح بالاتر بهتر از تجزیه سطوح پایین‌تر است. بنابراین، همبستگی زیادی میان داده‌های این سطوح با معادله برازش یافته وجود دارد. در روش

تغییرات ماهانه و فصلی است؛ این مشخصات به صورت مستتر در هر تجزیه موجود است، مثلاً، در تجزیه مرحله ۱۰، مقادیر جزئیات و تقریب تقریباً نشان‌دهنده میانگین متحرک سیگنال بارش ایستگاه زرین‌گل است. به عبارت دیگر، در مرحله ۱۰ فرکانس‌های بالاگذر و پایین‌گذر تا بیشترین حد ممکن از یکدیگر جدا شدند و سیگنال به صورت کاملاً ساده شده باقی ماند و همه خواص پنهان سیگنال خام آشکارسازی شد و در نهایت، تفاوت فرکانس بالاگذر و پایین‌گذر فقط در مقادیر عددی آن‌ها بود و از نظر خاصیت یکسان شد.

عیب عمده روش پیش‌بینی مستقیم از طریق امواج تجزیه شده توسط موجک طولانی بودن معادلات قابل برازش به دلیل پیرویدیک بودن آن‌ها و اختلاف فازهای ایجاد شده است. با مدل‌بندی مناسب تجزیه‌های یک موج می‌توان برای موجی که ساختار روشنی ندارد پیش‌بینی لازم را انجام داد، زیرا وقتی اطلاعات نهفته درون سیگنال با وضوح مناسبی در اختیار نیست، برای بازسازی سیگنال می‌توان از تبدیلات موجکی استفاده کرد [۱۴، ۱۶].

نتایج به دست آمده از روش هیبرید عصبی - موجکی نیز نشان داد که ترکیب موجک گسسته تک‌بعدی و شبکه عصبی موجب افزایش بسیار زیاد توانایی پیش‌بینی هوش مصنوعی می‌شود [۲، ۸، ۱۱، ۱۳، ۱۶].

نتایج تجزیه سری‌های زمانی سطح آب زیرزمینی و مدل‌سازی ضرایب موجکی به دست آمده از شبکه پرسپترون چندلایه نشان داد که پیش‌پردازش و تجزیه سری با موجک گسسته آتروس می‌تواند دقت پیش‌بینی شبکه را بهبود بخشد [۱۶]؛ این نتیجه مشابه

تأثیر خصوصیات اقلیمی بر دقت این گونه پیش‌بینی‌ها نیاز است. بنابراین، پیشنهاد می‌شود این تکنیک در اقلیم‌های مختلف کشور بررسی شده و نتایج آن با روش‌های متداول پیش‌بینی کوتاه‌مدت بارندگی از قبیل روش‌های متداول آماری (روش‌های مبتنی بر خودهمبستگی سری‌های زمانی و ...) یا روش‌های هوشمند مقایسه شود.

هیبرید عصبی- موجکی همبستگی میان داده‌های مشاهداتی و محاسباتی به مراتب بیشتر از روش مستقیم است. به طور خلاصه، با توجه به ماهیت تصادفی بارندگی و پیرودیگ بودن آن، با استفاده از شبکه‌های عصبی- موجکی یا روش‌های هیبرید موجکی می‌توان بارندگی ماهانه را با دقت قابل قبولی پیش‌بینی کرد، هر چند به تحقیقات بیشتری درباره

References

- [1] Abghari, H. (2008). Investigation of Wavelet Neural Networks and Auto-Regressive Models to Intelligent prediction of Monthly river flow, Ph.D. thesis, University of Tehran, 173PP.
- [2] Adamowski, J. and Sun, K. (2010). Development of coupled wavelet transform and neural network method for flow forecasting of Non-perennial River in semi-arid watersheds, *Journal of Hydrology*, 390, 85-91.
- [3] Cannas, B., Fanni, A., See, L. and Sias, G. (2006). Data preprocessing for river flow forecasting using neural network: wavelet transforms and data partitioning, *Physics and Chemistry of the Earth*, 31(18), 1164-1171.
- [4] Chan, A. and Y. Liu, S. (1998). *Wavelet Toolware: Software for Wavelet Training*, Academic Press, 81p.
- [5] Cybenko, G. (1989). Approximation by super positions of a sigmoid function, *Math Contr, Signals Syst*, 2, 303-314.
- [6] Karayiannis, N.B. and Venetsanopoulos, A.N. (1993). *Artificial Neural Network: Learning Algorithms, Performance Evaluation, and Application*, Kluwer Academic Publisher, Boston, 523p.
- [7] Kisi, O. (2010). Wavelet regression model for short-term stream flow forecasting, *Journal of Hydrology*, 389(3), 344-353.
- [8] Kisi, O. and Shiri, J. (2011). Precipitation Forecasting Using Wavelet-Genetic Programming and Wavelet-Neuro-Fuzzy conjunction Models, *Water Resources Management*, 25(13), 3135-3152.
- [9] Mahdavi, M. (2007). *Applied Hydrology*, 2ed Edition, Tehran University Press, 362PP.
- [10] Menhaj, M.B. (2008). *Fundamentals of neural networks (Computational Intelligence)*, vol1, Center published of Professor Hesabi, 715p.
- [11] Nourani, V., Alami, M. and Aminfar, M. (2009). A combined neural-wavelet model for prediction of Lighvanchai watershed precipitation, *Engineering Applications of Artificial Intelligenec*, 22, 466-472.
- [12] Noury, M. and Abghari, H. (2007). Simulated rainfall - runoff with radial basic function neural network (RBF) classification based on probabilistic neural network (PNN), *Proceedings of The third conference on watershed management and soil and water resources management (in CD)*, Kerman, Iran.
- [13] Partal, T. and Kisi, O. (2007). Wavelet and neruro-fuzzy conjunction model for precipitation forecasting, *Journal of Hydrology*, 342, 199-212.
- [14] Sabzivand, R. (2003). *Predictions of rainfall using a wavelet transform*, Water Resource Management Organization of Iran Press, 123p.
- [15] Salerno, F. and Tartari, G. (2009). A coupled approach of surface hydrological modelling and Wavelet Analysis for understanding the baseflow components of river discharge in karst environments, *Journal of Hydrology*, 376, 295-306.
- [16] Wang, W. and Ding, J. (2003). Wavelet Network Model and Its Application to the Prediction of Hydrology, *Nature and Science*, 1(1), 67-71.

