

پیش‌بینی بارش ماهانه با مدل ترکیبی شبکه عصبی مصنوعی-موجک و مقایسه با مدل شبکه عصبی مصنوعی

اباذر سلگی^۱، حیدر زارعی^۲، امیر پور حقی^۳، حمیدرضا خدا بخشی^۴

تاریخ دریافت: ۱۳۹۲/۱۰/۲۲

تاریخ پذیرش: ۱۳۹۵/۰۲/۲۲

چکیده

بدون شک اولین قدم در مدیریت رودخانه پیش‌بینی بارش سطح حوضه آبریز می‌باشد. با این حال، با توجه به بالا بودن خاصیت تصادفی فرآیندها، بسیاری از مدل‌ها هنوز هم به منظور تعریف چنین پدیده پیچیده‌ای در زمینه مهندسی هیدرولوژیک توسعه داده می‌شوند. اخیراً شبکه‌های عصبی مصنوعی به عنوان یک برون‌یابی و درون‌یابی غیرخطی گسترده توسط هیدرولوژیست‌ها مورد استفاده قرار می‌گیرد. در پژوهش حاضر، تجزیه و تحلیل موجک به صورت ترکیب با شبکه عصبی مصنوعی و مقایسه با شبکه عصبی مصنوعی برای پیش‌بینی بارش ایستگاه وراینه در شهرستان نهاوند انجام شد. برای این منظور، سری زمانی اصلی با استفاده از تئوری موجک به چندین زیرسیگنال زمانی تجزیه شد، پس از آن این زیرسیگنال‌ها به عنوان داده‌های ورودی به شبکه عصبی مصنوعی برای پیش‌بینی بارش ماهانه استفاده شد. نتایج به دست آمده نشان داد که با توجه به ضریب همبستگی $0/92$ و میانگین مربعات خطای $0/002$ مدل ترکیبی شبکه عصبی مصنوعی-موجک، عملکرد این مدل نسبت به مدل شبکه عصبی مصنوعی با ضریب همبستگی $0/75$ و میانگین مربعات خطای $0/003$ بهتر می‌باشد و می‌تواند برای پیش‌بینی بارش کوتاه مدت و بلند مدت استفاده شود.

واژه‌های کلیدی: پیش‌بینی بارش ماهانه، شبکه عصبی مصنوعی، شهرستان نهاوند، مدل ترکیبی شبکه عصبی-موجک.

^۱ کارشناسی ارشد، دانشجوی دکتری مهندسی منابع آب، دانشکده علوم آب، دانشگاه شهید چمران اهواز- همدان، شهرستان نهاوند، شهر فیروزان، بلوار انقلاب، ۰۹۱۸۹۴۹۹۵۷۹. A-Solgi@Phdstu.Scu.ac.ir

^۲ استادیار گروه هیدرولوژی و منابع آب، دانشکده علوم آب، دانشگاه شهید چمران اهواز ۰۹۱۶۹۷۵۵۵۳۶. Zareih@scu.ac.ir

^۳ کارشناسی ارشد، دانشجوی دکتری مهندسی منابع آب، دانشکده علوم آب، دانشگاه شهید چمران اهواز- لرستان، خرم‌آباد، شهرک پارسیلون، ۰۹۱۶۹۷۵۵۵۳۶. Pourhaghiamir@yahoo.com

^۴ کارشناس ارشد، معاون طرح و توسعه شبکه‌های آبیاری و زهکشی سازمان آب و برق خوزستان، khamid2000@yahoo.com

مقدمه

برآورد و پیش‌بینی بارش و دستیابی به مقدار رواناب ناشی از آن، نقش اساسی و مؤثری را در مدیریت و بهره‌برداری صحیح از حوضه، مدیریت سدها و مخازن، به حداقل رساندن خسارات ناشی از سیلاب، خشکسالی و مدیریت منابع آب ایفا می‌کند و به همین دلیل مورد توجه هیدرولوژیست‌ها می‌باشد. پیش‌بینی هر واقعه‌ای، اساس مدیریت بحران آن را تشکیل می‌دهد و این امکان، زمانی حاصل می‌شود که بتوان مدل‌های پیش‌بینی مناسب را در اختیار داشت. روش‌های مختلفی برای پیش‌بینی وقایع هیدرولوژیکی از جمله بارندگی به کار می‌رود. نتایج حاصل از بکارگیری هر یک از این روش‌ها همواره با مقداری خطا همراه می‌باشد. پیش‌بینی درست در سیگنال‌های هیدرولوژیکی نظیر بارندگی می‌تواند اطلاعات مفیدی را به منظور پیش‌بینی مقدار بارندگی و مدیریت منابع آب و خاک در یک حوضه ارائه دهد. علاوه بر این، پیش‌بینی درست در سیگنال‌های هیدرولوژیکی نقش مهمی را در کاهش اثرات خشکسالی بر سیستم‌های منابع آب ایفا می‌کند. سیستم‌های هیدرولوژی به وسیله فاکتورهای زیادی نظیر آب و هوا، پوشش گیاهی زمین، میزان نفوذپذیری، تبخیر و تعرق، و غیره که وابسته به اجزای استوکستیک، مقیاس‌های چند زمانه و ویژگی‌های غیرخطی بالا هستند، تحت تاثیر قرار می‌گیرند. با وجود روابط غیرخطی، عدم قطعیت و عدم صراحت زیاد، ویژگی‌های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ یک از مدل‌های آماری و مفهومی پیشنهاد شده به منظور الگوسازی دقیق بارش و رواناب نتوانسته‌اند به عنوان یک مدل برتر و توانا شناخته شوند. امروزه شبکه‌های غیرخطی به عنوان یکی از سیستم‌های هوشمند در پیش‌بینی یک چنین پدیده‌های پیچیده بسیار مورد استفاده قرار می‌گیرند. یکی از روش‌هایی که در سال‌های اخیر در زمینه هیدرولوژی مورد توجه قرار گرفته است، استفاده از تبدیل موجک به عنوان روشی نوین و بسیار مؤثر در

زمینه آنالیز سیگنال‌ها و سری‌های زمانی است. در زیر به برخی از مطالعات صورت گرفته اشاره می‌شود:

مدلسازی و پیش‌بینی جریان ماهانه رودخانه با استفاده از روش شبکه عصبی مصنوعی - موجک در ترکیه مورد بررسی قرار گرفته است. نتایج این بررسی نشان داد که این مدل می‌تواند دقت پیش‌بینی را افزایش دهد و از مدل‌های پرسپترون چند لایه^۱ (MLP)، رگرسیون خطی چندگانه^۲ (MLR) و خودهمبسته^۳ (AR) بهتر انجام شود (Kisi, 2008). بهبود عملکرد شبکه‌های عصبی مصنوعی^۴ (ANN) در پیش‌بینی سری زمانی فصلی مورد بررسی قرار گرفته است. مدل برای چهار سری زمانی کامل آزمایش شد. نتیجه شبکه عصبی پیشنهادی با نتایج حاصل از مدل‌های آماری مرسوم و ساختارهای دیگر شبکه - عصبی مورد مقایسه قرار گرفت که این مقایسه نشان داد که مدل پیشنهادی شبکه عصبی خطای پیش‌بینی کمتری نسبت به روش‌های دیگر دارد (Hamzaçebi, 2008). یک مدل ترکیبی عصبی - موجک برای پیش‌بینی بارش حوضه ليقوان چای تبریز ارائه شده است. برای این منظور سری زمانی اصلی توسط تبدیل موجک به چندین زیرسری تبدیل شده که این زیرسری‌های تبدیل شده به عنوان ورودی به شبکه عصبی مصنوعی برای پیش‌بینی بارش یک ماهه اعمال شد. نتایج این تحقیق نشان داد که مدل پیشنهادی می‌تواند بارش را در هر دو سطح کوتاه مدت و بلند مدت پیش‌بینی کند (Nourani et al., 2009). بهبود رویکرد مبتنی بر مدلسازی بارش - رواناب با استفاده از مدل ترکیبی شبکه عصبی مصنوعی - موجک انجام شده که حاکی از این بوده است که مدل با داده‌های ورودی بارش و آبدهی، عملکرد بهتری نسبت به مدل با داده‌های ورودی بارش دارد (Chua et al., 2010). یک روش براساس تبدیل جفت موجک گسسته و شبکه‌های عصبی مصنوعی برای پیش‌بینی جریان رودخانه‌های فصلی در کشور قبرس

¹ - Multi Layers Perceptron

² - Multi Linear Regression

³ - Auto Regressive

⁴ - Artificial Neural Network

است. نتایج نشان داد که مدل پیشنهادی منجر به نتیجه بهتر به خصوص در مورد ضریب تبیین برای تشخیص نقاط اوج شده است (Nourani and Parhizkar, 2013). مدل سازی بارش-رواناب با استفاده از مدل ترکیبی شبکه عصبی مصنوعی-موجک انجام شده است. نتایج این مطالعه نشان داده که مدل ترکیبی موجک شبکه عصبی مصنوعی-موجک نسبت به مدل شبکه عصبی مصنوعی و روش رگرسیونی کارایی بالاتری دارد (کماسی، ۱۳۸۶). با استفاده از تبدیل موجک پیش‌بینی بارندگی ماهانه در ایستگاه زرینگل استان گلستان انجام شده و نتایج حاصل از این مطالعه با مدل سری زمانی خطی فصلی^۱ (SARIMA) مقایسه شد. نتایج نشان داد که تجزیه سیگنال با موجک همبستگی میان داده‌های مشاهداتی و محاسباتی را نسبت به روش‌های سری زمانی به طور قابل ملاحظه‌ای افزایش می‌دهد و پیش‌بینی سیگنال بارش با دقت بیشتری صورت می‌گیرد (طوفانی و همکاران، ۱۳۹۰).

با توجه به کاربرد وسیع شبکه عصبی مصنوعی و تبدیلات موجک در علوم مختلف به خصوص علوم مربوط به آب و همچنین با توجه به اینکه از تبدیل موجک به ندرت در ایران برای پیش‌بینی بارش استفاده شده است در این تحقیق پیش‌بینی بارش با مدل ترکیبی شبکه عصبی مصنوعی-موجک و مدل شبکه عصبی مصنوعی مورد بررسی قرار گرفت. همچنین در تحقیقات محدود گذشته فقط از پارامتر بارش جهت پیش‌بینی بارش استفاده شده است در این تحقیق علاوه بر پارامتر بارش از پارامترهای دما و رطوبت نسبی نیز استفاده شده است تا اثر آن‌ها بر پیش‌بینی بارش مورد بررسی قرار گیرد.

مواد و روش‌ها

ایستگاه وراینه شامل ۳ ایستگاه باران‌سنجی، تبخیرسنجی و هواشناسی به نام وراینه می‌باشد. که در

ارائه شد. عملکرد مدل شبکه عصبی مصنوعی-موجک و مدل شبکه عصبی مصنوعی برای پیش‌بینی جریان در یک دوره زمانی کوتاه یک و سه روزه برای دو رودخانه متفاوت مورد مقایسه قرار گرفت. در هر دو حالت (یک و سه روزه)، مدل شبکه عصبی-موجک برای ارائه پیش‌بینی جریان، دقیق‌تر از مدل شبکه عصبی مصنوعی بود (Adamowski and sun, 2010). دو روش ترکیبی هوش مصنوعی برای مدل‌سازی فرایند بارش-رواناب دو حوضه در آذربایجان ایران ارائه شد. مدل اول SARIMAX^۱-ANN (مدل شبکه عصبی مصنوعی- آریمای فصلی ضریبی با ورودی برون‌زا) و مدل دوم، مدل سیستم استنتاج فازی عصبی تطبیقی-موجک^۲ (WANFIS) بود. نتایج نشان داد که اگر چه مدل‌های پیشنهادی می‌تواند هر دو شرایط کوتاه مدت و بلند مدت تخلیه رواناب را با توجه به اثرات فصلی پیش‌بینی کنند، ولی مدل دوم نسبتاً مناسب‌تر است (Nourani, 2010). یک ترکیب جدید شبکه عصبی برای مدل‌سازی بارش-رواناب در حوضه آق‌چای ایران ارائه شد. این مدل پیشنهادی ترکیبی از روش‌های پردازش داده‌ها، الگوریتم ژنتیک و الگوریتم لونبرگ مارکوارت برای آموزش ورودی‌های شبکه‌های عصبی بود. نتایج نشان داد که این روش قادر به پیش‌بینی دقیق‌تر رواناب نسبت به شبکه‌های عصبی مصنوعی و مدل سیستم استنتاج فازی عصبی تطبیقی است (Asadi et al., 2013). روش استخراجی مبتنی بر ویژگی نقشه خود سازماندهی شده^۳ (SOM) و روش ترکیبی شبکه عصبی مصنوعی-موجک برای مدل‌سازی بارش رواناب ارائه شده است. در این کار یک روش دو مرحله‌ای برای مدل‌سازی فرایند بارش-رواناب در دوحوضه دلانی کریک^۴ و پایین کریک^۵ فلوریدا، ایالات متحده آمریکا انجام شد. روش دو مرحله‌ای شامل اطلاعات قبل از پردازش و مراحل مدل‌سازی

^۱ - Seasonal Auto Regressive Integrated Moving Average with exogenous input

^۲ - Wavelet-Adaptive Neuro Fuzzy Inference System

^۳ - Self-Organizing Map

^۴ - Delaney Creek

^۵ - Payne Creek

^۶ - Seasonal Auto Regressive Integrated Moving Average

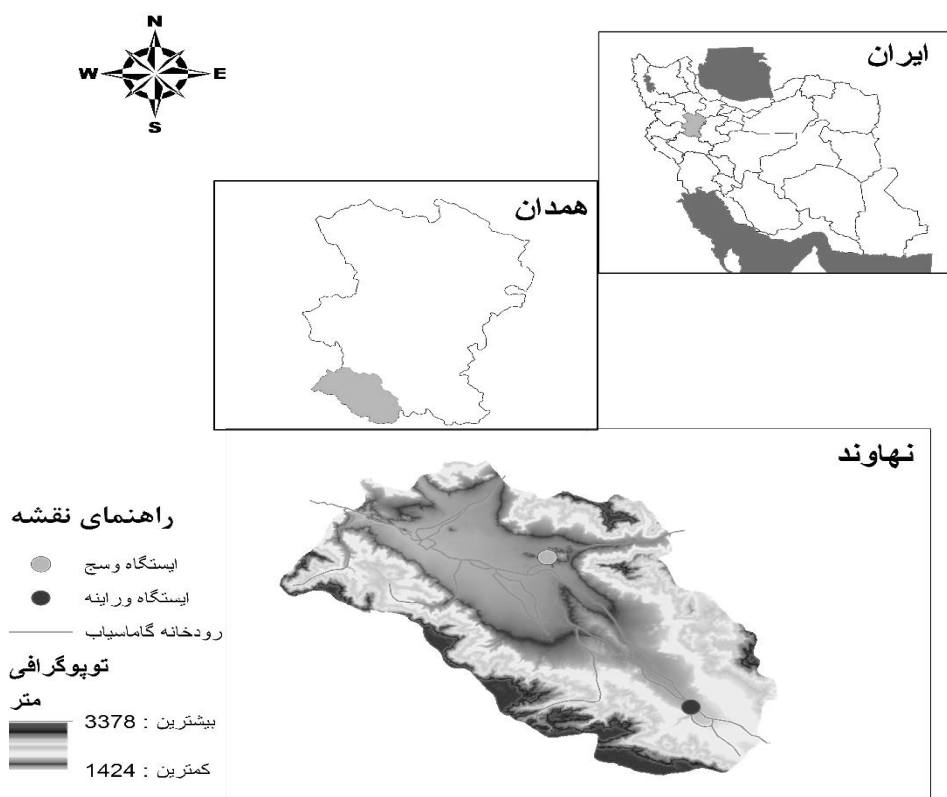
نمودار جرم مضاعف استفاده شد که حاکی از همگنی داده‌ها بود.

سپس با استفاده از تبدیل موجک داده‌ها تجزیه و تحلیل شد بدین ترتیب که با استفاده از برنامه متلب و در نظر گرفتن سطوح مختلف تجزیه، موجک‌های مادر^۱ مختلف و کدنویسی در متلب، تبدیل موجک روی پارامترهای ورودی پیاده شد.

شهرستان نهاوند در موقعیت جغرافیایی ۴۸ درجه و ۲۴ دقیقه و ۱۵ ثانیه طول شرقی و ۳۴ درجه و ۰۴ دقیقه و ۳۲ ثانیه عرض شمالی قرار دارند. این ایستگاه در سال ۱۳۴۸ تأسیس شده است و دارای ارتفاع ۱۷۹۵ متر از سطح دریا با میانگین بارش سالانه درازمدت ۵۲۱ میلی‌متر می‌باشد (جدول ۱). در این بررسی داده‌های ماهانه بارش، دما و رطوبت نسبی در یک دوره ۲۵ ساله (۱۳۶۶-۱۳۹۰) از ایستگاه وراینه در شهرستان نهاوند دریافت شد. برای بررسی همگنی داده‌ها از ایستگاه وسج به عنوان ایستگاه کمکی و از

جدول (۱): برخی از متغیرهای اقلیمی ایستگاه وراینه

متغیر اقلیمی	میانگین	حداکثر	حداقل	انحراف معیار	واریانس	ضریب تغییرات
بارش ماهانه (میلی‌متر)	۴۰/۳	۲۵۱	۰/۰	۴۹/۲	۲۴۱۹/۲	۱/۲
دمای ماهانه (سلسیوس)	۱۰	۲۶	-۹	۸/۹	۷۸/۹	۰/۹
رطوبت نسبی ماهانه (درصد)	۶۷	۸۷	۲۰	۱۱/۶	۱۳۳/۹	۰/۲



شکل (۱): موقعیت ایستگاه وراینه در شهرستان نهاوند، استان همدان و ایران.

(۱۳۶۶) به عنوان داده‌های آموزش، ۱۵ درصد به عنوان داده‌های صحت‌سنجی (۱۳۸۶-۱۳۸۲) و ۱۵ درصد به عنوان داده‌های تست (۱۳۹۰-۱۳۸۶) در نظر گرفته شد. با استفاده از شبکه عصبی مصنوعی و ساخت ساختارهای مختلف به طوری که در هر ساختار نوع ورودی‌ها (ورودی‌های جدول ۲) متفاوت باشد با مقایسه قانون‌های مختلف آموزش و روش‌های مختلف موجود مثل پرسپترون چند لایه، پیشخور تعمیم یافته (GFF) و غیره، بهترین قانون آموزش، تعداد نرون و لایه‌های مخفی و تعداد اجرای برنامه، تعداد تکرار هر مرحله مشخص شد. در نهایت بهترین مدل با استفاده از روش الگوریتم ژنتیک تعیین شد. برای شبکه عصبی مصنوعی ۶ ساختار مورد بررسی قرار گرفت که جزئیات آن‌ها در جدول (۲) آورده شده است.

به علت اینکه وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. از روش نرمال‌سازی (استانداردسازی) داده‌ها استفاده شده است که این کار مانع کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نرون‌ها می‌گردد. با روش نرمال‌سازی هر عدد تبدیل به عددی بین ۰ تا ۱ می‌شود. تا بتوان آن‌ها را در تابع شبکه عصبی به کار برد (Riad et al., 2004). برای این کار از رابطه زیر استفاده شد.

$$y = 0.5 + (0.5 \times \left(\frac{x - \bar{x}}{x_{\max} - x_{\min}} \right)) \quad (1)$$

که در این رابطه X داده مورد نظر، \bar{X} میانگین داده‌ها، x_{\max} حداکثر داده‌ها، x_{\min} حداقل داده‌ها، y داده استاندارد شده می‌باشد. ۷۰ درصد از داده‌ها (۱۳۸۲-۱۳۸۲)

جدول (۲): جزئیات ساختارهای مختلف مدل شبکه عصبی مصنوعی

خروجی	ورودی	ساختار
P_{t+1}	$P_{t-1}, P_t, N_{t-1}, N_t, T_{t-1}, T_t$	۱
P_{t+1}	$P_{t-1}, P_t, T_{t-1}, T_t$	۲
P_{t+1}	P_{t-1}, P_t	۳
P_{t+1}	P_{t-1}, P_t, N_t, T_t	۴
P_{t+1}	P_t, N_t, T_t	۵
P_{t+1}	$P_{t-1}, P_t, N_{t-1}, N_t$	۶

فرانسه ارائه شد. تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی هستند که شکل مقیاس-زمان از سری‌های زمانی و روابط آنها جهت آنالیز سری‌های زمانی که شامل متغیرها و غیر ثابت‌ها می‌باشد را ارائه می‌دهد. تحلیل موجکی^۱ استفاده از فاصله‌های زمانی طولانی مدت را برای اطلاعات دارای فرکانس پائین و تناوب‌های کوتاه‌تر را برای اطلاعات دارای فرکانس بالا ارائه می‌دهد. تحلیل موجکی قادر به نمایش جنبه‌های مختلف داده‌های متفاوت، نقاط شکست و ناپیوستگی‌ها می‌باشد که ممکن است دیگر روش‌های آنالیز سیگنال آن‌ها را نشان ندهند. تابع موجک، تابعی

P_t بارش ماهانه بر حسب میلی‌متر، N_t رطوبت نسبی بر حسب درصد و T_t دمای ماهانه بر حسب درجه سلسیوس می‌باشد. $P_{t-1}, N_{t-1}, T_{t-1}$ داده‌های مربوط به یک ماه قبل و P_{t+1} بارش ماه بعد می‌باشد.

تبدیل موجک

تئوری موجکی یکی از روش‌های علم ریاضی است که ایده اصلی آن برگرفته از تبدیل فوریه است که در قرن نوزدهم مطرح شده است ولی استفاده از آن قدمتی ۱۰ ساله دارد. مفهوم کلی موجک‌ها به صورت تئوری کنونی توسط مورلت و تیمی در مرکز تحقیقات فیزیک نظری مارسل زیر نظر آلکس گراسمن در

^۱ - Wavelet Analysis

صفر انطباقی وجود ندارد و به ازای T های منفی انطباق عکس یا بیشترین تفاوت وجود دارد. انتقال در تبدیل موجکی نشان‌دهنده موقعیت پنجره است. در این روش نیز یک تابع پنجره در نظر گرفته شده و در موج مورد نظر ضرب می‌شود. بر خلاف تبدیل قطعه‌ای، در تبدیل پیوسته موجکی پهنای تابع پنجره متغیر می‌باشد، به طوری که برای هر مؤلفه موج می‌توان عرض مناسبی را انتخاب نمود. این موضوع مهم‌ترین خصوصیت تبدیل موجکی است (Nourani et al., 2009). مقیاس به طور ساده به معنای کشیده شدن یا فشرده شدن موج می‌باشد. همان‌گونه که در نقشه‌ها مقیاس بزرگ متناظر با نشان ندادن جزئیات کلی است، در اینجا نیز مقیاس بزرگ متناظر با نشان ندادن جزئیات موج، و مقیاس کوچک متناظر با نشان دادن جزئیات موج است. به طور مشابه در جملات فرکانسی، فرکانس پائین (مقیاس بزرگ) متناظر با اطلاعات کلی موج می‌باشد که معمولاً اندازه موج داخلی است، در حالی که فرکانس‌های بزرگ متناظر با جزئیات اطلاعات پوشیده در موج است که معمولاً در یک زمان کوتاه به طول می‌انجامد. همچنین انتقال موجک به طور ساده به مفهوم به تأخیرانداختن یا جلوانداختن موجک و بیان‌کننده موقعیت موجک بر روی محور زمان است. توابع موجک مادر دارای انواع بسیاری هستند که در شکل ۲ موجک‌های مادر استفاده شده در این تحقیق نشان داده شده‌اند (Nourani et al., 2009).

است که دو ویژگی مهم نوسانی بودن و کوتاه مدت بودن را دارا می‌باشد. $\psi(x)$ تابع موجک است اگر و فقط اگر تبدیل فوریه آن $\psi(\omega)$ ، شرط زیر (رابطه ۲) را ارضا کند (Mallat, 1998).

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

این شرط با عنوان شرط پذیرفتگی^۱ برای موجک $\psi(x)$ شناخته می‌شود. رابطه فوق را می‌توان معادل با رابطه ۳ دانست:

$$\psi(0) = \int_{-\infty}^{+\infty} \psi(x) dx = 0 \quad (3)$$

این ویژگی تابع با میانگین صفر، چنان محدودکننده نبوده و توابع بسیاری را می‌توان براساس آن تابع موجک نامید. $\psi(x)$ تابع موجک مادر است که توابع مورد استفاده در تحلیل، با دو عمل ریاضی انتقال^۲ و مقیاس^۳ در طول سیگنال مورد تحلیل، تغییر اندازه و تغییر محل می‌یابند.

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (4)$$

در نهایت ضرایب موجک در هر نقطه از سیگنال (b) و برای هر مقدار از مقیاس (a) با رابطه ۵ قابل محاسبه می‌باشد (Mallat, 1998).


$$T(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \psi\left(\frac{t-b}{a}\right) f(t) dt \quad (5)$$

که در رابطه ۵، a کار مقیاس و b کار انتقال تابع را انجام می‌دهند. به ازای مقادیر مختلف a و b مقدار T بدست می‌آید هر موقع T بیشترین مقدار مثبت را داشته باشد بیشترین انطباق را دارد. به ازای T برابر

¹ - Admissibility

² - Translation

³ - Scale



شکل (۲): a موجک Haar، b موجک Db4، c موجک Sym3

زیرسری‌های $T_a(t)$ و $N_a(t)$ ، $P_a(t)$ مربوط به مقیاس کلی^۴ در سطح پایانی برای پارامترهای بارش، دما و رطوبت نسبی بوده، همچنین زیرسری‌های دیگر مربوط به مقیاس کوچک^۵ در سطح ۱ تا سطح پایانی می‌باشند.

در انتخاب موجک مادر می‌بایست شرط‌های زیر وجود داشته باشد (Fofola and Kumar, 1995).

- ۱- مساحت زیر منحنی آن صفر باشد.^۱ ۲- مقدار میانگین آن از هر دو سمت به صفر میل کند.^۲ ۳- ممان‌های آن هم صفر باشد. این شرط اگر وجود نداشته باشد اشکالی ندارد.^۳

مدل ترکیبی شبکه عصبی مصنوعی - موجک

اگر داده‌ها با استفاده از تبدیل موجک تجزیه و تحلیل شود و خروجی آن به عنوان ورودی در شبکه عصبی مصنوعی مورد استفاده قرار بگیرد مدل ترکیبی حاصل می‌شود. پارامترهای بارش، دما و رطوبت نسبی توسط تبدیل موجک تجزیه شده و بسته به سطح بررسی و موجک مادر آنها به چندین زیرسری زمانی تبدیل می‌شوند که این زیرسری‌ها به عنوان ورودی به شبکه عصبی مصنوعی وارد می‌شوند (شکل ۳). همچنین در این شکل که نمای شماتیکی از مدل شبکه عصبی مصنوعی-موجک است.

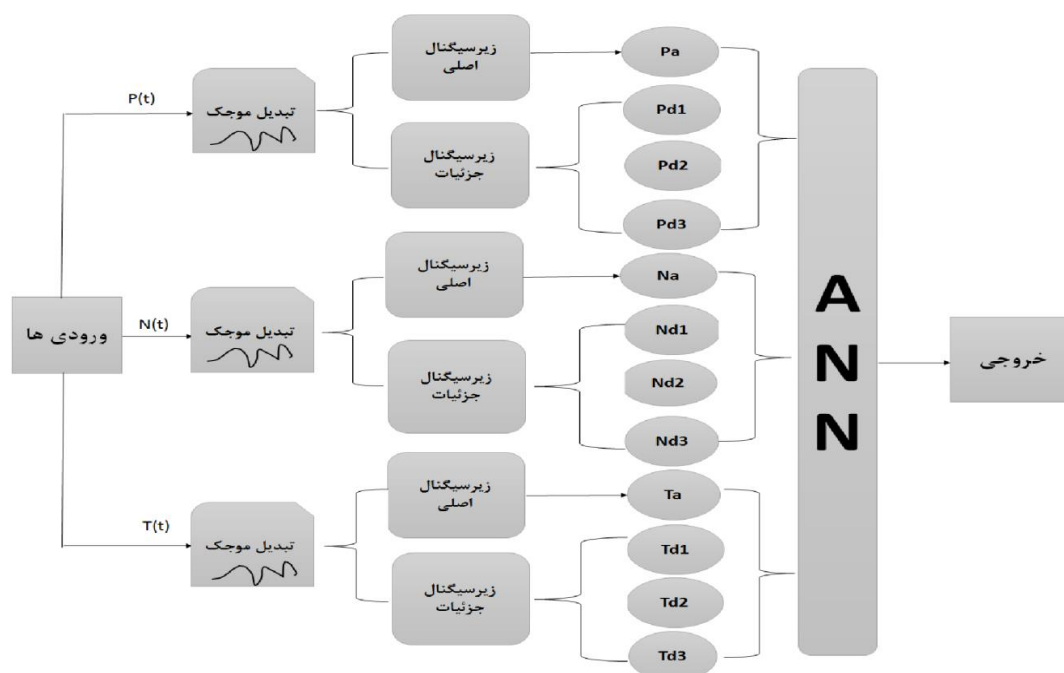
^۴- Approximation (Large Scale)

^۵- Detail (Small Scale)

^۱- Admissibility conditions

^۲- Compact support

^۳- Regularity conditions



شکل (۳): نمای شماتیکی از مدل موجک - شبکه عصبی

میانگین مربعات خطای نرمال شده (NMSE)^۳

$$NMSE(x, y) = \frac{MAE(x, y)}{MAE(x, 0)} = \frac{\sum(x-y)^2}{\sum(x)^2} \quad (۸)$$

ضریب رگرسیون^۴ (R)

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (x_i - \bar{x})^2}} \quad (۹)$$

در این روابط داده واقعی، y_{actual} ، داده $y_{forecast}$ ، داده تخمین زده شده، y_i ، داده مورد نظر، \bar{y} میانگین داده‌ها است.

مینیمم خطای مطلق^۵: در واقع کمترین اختلاف بین مقدار اندازه‌گیری شده با مقدار واقعی است. ماکزیمم خطای مطلق^۶: بیشترین اختلاف بین مقدار اندازه‌گیری شده با مقدار واقعی است.

معیارهای ارزیابی مدل

منظور از ارزیابی مدل به دست آوردن میزان خطای مدل با توجه به داده‌های ورودی داده شده به مدل جهت آموزش و براساس معیارهای مختلف محاسبه خطای می باشد. در این پژوهش برای ارزیابی مدل از معیارهای زیر استفاده شد:

میانگین خطای مطلق^۱ (MAE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{actual} - y_{forecast}| \quad (۶)$$

میانگین مربعات خطا^۲ (MSE)

$$MSE = \frac{1}{n} \sum (y_i - \bar{y})^2 \quad (۷)$$

^۳ -Normalized Mean Square Error

^۴ - Regression

^۵ - Min Abs Error

^۶ - Max Abs Error

^۱ - Mean Absolute Error

^۲ - Mean Squared Error

نتایج و بحث

بهینه‌سازی شد تا بهترین برآورد بدست آید. بهترین ساختار در هر یک از شبکه‌های مربوط به مدل شبکه عصبی مصنوعی با تعداد تکرار ۱۰۰۰ و ۳ بار اجرای شبکه بدست آمده است. جدول ۳ ساختارهای مختلف هریک از شبکه‌ها را نشان می‌دهد براساس معیارهای ارزیابی در این تحقیق شبکه دو بهترین عملکرد را داشته است که نتایج آن در جدول ۴ ارائه شده است.

با استفاده از شبکه عصبی مصنوعی و ساختارهای مختلف، به طوری که در هر ساختار نوع ورودی‌ها، قوانین آموزش و انتقال، همچنین روش‌های مختلف موجود مثل پرسپترون چند لایه، GFF و ... بهترین قوانین آموزش و انتقال، تعداد نرون، تعداد لایه‌های مخفی و تعداد اجرای برنامه، تعداد تکرار هر مرحله مشخص شده سپس بهترین مدل با استفاده از روش الگوریتم ژنتیک با شبکه عصبی مصنوعی

جدول (۳): مشخصات بهترین ساختارها در شبکه‌های مختلف شبکه عصبی مصنوعی

ساختار	شبکه	تابع انتقال	قانون یادگیری	بهترین ساختار شبکه
D1	پرسپترون چندلایه	سیگموئید آکسون خطی	مومنتم	۶-۴-۱
D2	پرسپترون چندلایه	سیگموئید آکسون	پس انتشار ارتجاعی	۴-۵-۱
D3	پرسپترون چندلایه	سیگموئید آکسون خطی	لونیبرگ مارکوارت	۲-۶-۵-۱
D4	پرسپترون چندلایه	تانژانت آکسون	لونیبرگ مارکوارت	۲-۳-۴-۱
D5	پرسپترون چندلایه	سیگموئید آکسون	پس انتشار ارتجاعی	۳-۶-۴-۱
D6	پیشخور تعمیم یافته	سیگموئید آکسون	لونیبرگ مارکوارت	۳-۴-۴-۴-۱

جدول (۴): نتایج بهترین ساختارها در شبکه‌های مختلف مدل شبکه عصبی مصنوعی

ساختار	میانگین مربعات خطا	میانگین مربعات خطای نرمال شده	میانگین خطای مطلق	مینیمم خطای مطلق	ماکزیمم خطای مطلق	ضریب همبستگی
D1	۰/۰۰۸	۰/۷۷۸	۰/۰۶۷	۰/۰۰۰۲	۰/۳۵	۰/۵۲
D2	۰/۰۰۳	۰/۴۴۶	۰/۰۴۳	۰/۰۰۰۳	۰/۱۱	۰/۷۵
D3	۰/۰۰۶	۰/۷۶۹	۰/۰۶۷	۰/۰۰۴۳	۰/۱۵	۰/۵۰
D4	۰/۰۰۴	۰/۴۴۱	۰/۰۳۹	۰/۰۰۰۴	۰/۳۵	۰/۷۴
D5	۰/۰۰۴	۰/۴۸۴	۰/۰۵۰	۰/۰۰۰۹	۰/۱۷	۰/۷۲
D6	۰/۰۱۰	۰/۵۷۲	۰/۰۷۳	۰/۰۰۰۲	۰/۲۶	۰/۷۴

که در این رابطه L سطوح پیشنهادی و N تعداد سری زمانی اعداد می‌باشد. در این پژوهش با $N=300$ ، $L=2$ می‌باشد که برای دقت بیشتر، سطوح ۱ تا ۳ مورد بررسی قرار گرفت. ساختارهای مختلف در جدول ۵ نشان داده شده است. برای این کار از قوانین مختلف یادگیری و توابع انتقال مختلف با تعداد تکرار ۱۰۰۰ و ۳ بار اجرای شبکه در لایه‌های مخفی مختلف استفاده شده است.

در مدل ترکیبی با بررسی مدل‌های مختلف بدین صورت که ابتدا با استفاده از تبدیلات موجک زیر سری‌های مختلف در سطوح مختلف به ازای موجک مادرهای متفاوت مورد بررسی قرار گرفت. برای تعیین سطوح مختلف از رابطه ۱۰ استفاده شد (Nourani et al., 2009).


$$L = \text{Int}[\log(N)] \quad (10)$$

جدول (۵): ساختار مدل ترکیبی شبکه عصبی مصنوعی-موجک


ساختار	مدل	تابع انتقال	قانون یادگیری	بهترین ساختار شبکه
D7	پرسترون چندلایه	سیگموئید آکسون خطی	پله ای	۶-۴-۴
D8	پرسترون چندلایه	تانژانت آکسون	پله ای	۹-۴-۱
D9	پرسترون چندلایه	تانژانت آکسون	لونیبرگ مارکوارت	۱۲-۳-۱
D10	پرسترون چندلایه	سیگموئید آکسون خطی	لونیبرگ مارکوارت	۶-۴-۱
D11	پرسترون چندلایه	سیگموئید آکسون	پس انتشار ارتجاعی	۹-۴-۵-۱
D12	پرسترون چندلایه	تانژانت آکسون	شیب مزدوج	۱۲-۴-۱
D13	پرسترون چندلایه	سیگموئید آکسون خطی	پس انتشار ارتجاعی	۶-۴-۴-۱
D14	پرسترون چندلایه	تانژانت آکسون	لونیبرگ مارکوارت	۹-۴-۱
D15	پرسترون چندلایه	تانژانت آکسون	دلتا باردلنا	۱۲-۴-۱

تحقیق بهترین مدل شبکه عصبی مصنوعی-موجک در ساختار D10 با موجک مادر Db4 و سطح تجزیه ۱ می‌باشد (جدول ۶). شکل ۶ بارش محاسباتی در مقابل مشاهده‌ای را برای ۲ مدل به کار رفته در این تحقیق نشان می‌دهد. شکل ۶- (الف) مربوط به مدل شبکه عصبی مصنوعی و (ب) مربوط به مدل ترکیبی شبکه عصبی مصنوعی-موجک می‌باشد.

شکل ۴ سیگنال اصلی بارش را به عنوان نمونه‌ای از ورودی‌های تحقیق نشان می‌دهد. این سیگنال با استفاده از تبدیل موجک به زیرسیگنال‌هایی تجزیه شده است (شکل ۵). این زیرسیگنال‌ها توسط کدنویسی در نرم‌افزار متلب به عدد تبدیل شده و به عنوان ورودی شبکه عصبی مصنوعی مورد استفاده قرار گرفت. با توجه به معیارهای ارزیابی مدل‌ها در این





شکل (۴): سیگنال اصلی بارش



شکل (۵): زیر سیگنالهای سری زمانی بارش با موجک مادر Db4 (سطح تجزیه ۱)

جدول (۶): نتایج مدل ترکیبی شبکه عصبی مصنوعی-موجک


ضریب همبستگی	میانگین خطای مطلق	میانگین مربعات خطا	موجک مادر	تعداد سطوح	ساختار
۰/۶۷	۰/۰۷	۰/۰۰۸	Haar	۱	D۷
۰/۸۴	۰/۰۴	۰/۰۰۳	Haar	۲	D۸
۰/۷۸	۰/۰۵	۰/۰۰۵	Haar	۳	D۹
۰/۹۲	۰/۰۳	۰/۰۰۲	Db4	۱	D۱۰
۰/۸۵	۰/۰۵	۰/۰۰۴	Db4	۲	D۱۱
۰/۸۵	۰/۰۲	۰/۰۰۱	Db4	۳	D۱۲
۰/۸۵	۰/۰۴	۰/۰۰۳	Sym3	۱	D۱۳
۰/۸۸	۰/۰۴	۰/۰۰۳	Sym3	۲	D۱۴
۰/۷۹	۰/۰۷	۰/۰۰۷	Sym3	۳	D۱۵



شکل (۶): بارش محاسباتی در مقابل مشاهده‌ای. الف-مدل شبکه عصبی. ب-مدل ترکیبی شبکه عصبی-موجک

دارد می‌توان به این نتیجه رسید که دو نقطه مذکور درست برآورد شده‌اند زیرا در صورت اشتباه برآورد شدن ضریب همبستگی در شکل ۷ باید افزایش پیدا می‌کرد. در نتیجه به طور کلی می‌توان نتیجه گرفت که مدل ترکیبی در برآورد نقاط حدی قابلیت خوبی دارد.

با توجه به شکل ۶-ب به نظر می‌رسد مدل ترکیبی در پیش‌بینی دو نقطه بالایی (با توجه به تفاوت زیاد آن‌ها با بقیه داده‌ها) دچار مشکل شده است به همین دلیل شکل ۶-ب با حذف ۲ نقطه مذکور دوباره ترسیم شد (شکل ۷). با توجه به اینکه شکل ۷ ضریب همبستگی کمتری نسبت به شکل ۶-ب



شکل (۷): بارش محاسباتی در مقابل مشاهده‌ای در مدل ترکیبی با حذف ۲ نقطه مشکوک

مدلسازی هستند که علت آن به دلیل ساختار مشتق‌پذیر بودن (که باعث شده توانایی مناسبی برای استفاده در حالات مختلف داشته باشند) این دو تابع

همچنین از بررسی توابع انتقال به کار رفته می‌توان نتیجه گرفت که دو تابع انتقال سیگموئید آکسون و سیگموئید آکسون خطی، توابع انتقال مناسبی برای

گرفت که نتایج آن در جدول (۸) ارائه شده است همچنین مقادیر بارش مشاهده‌ای با بارش‌های پیش بینی شده توسط هر دو مدل در شکل (۸) نشان داده است.

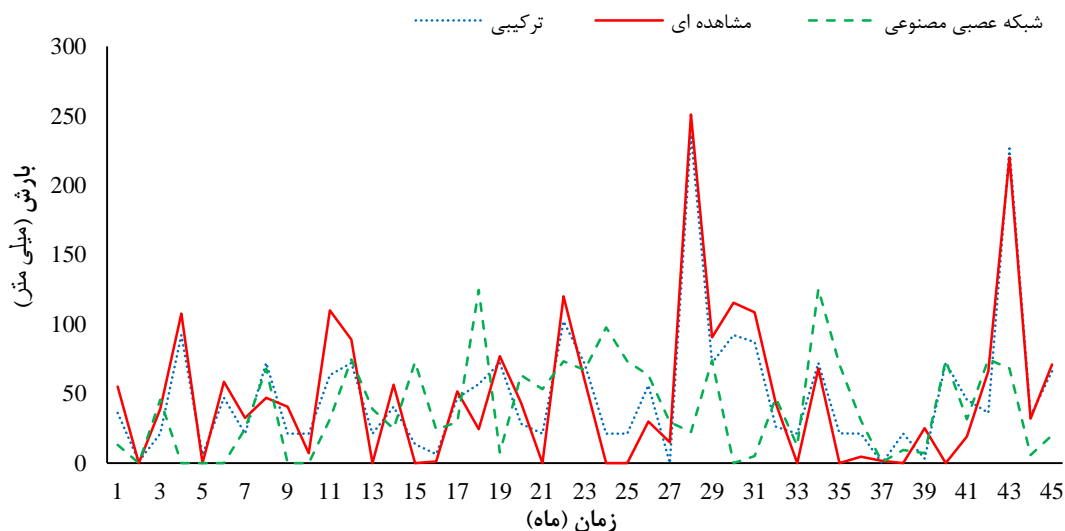
می‌باشد. جدول ۷ ارزیابی عملکرد ساختار D10 را نشان می‌دهد که در این جدول پارامترهای مختلف برای بررسی بارش پیش‌بینی شده نشان داده است. در پایان بهترین ساختار از مدل شبکه عصبی مصنوعی با بهترین ساختار از مدل ترکیبی مورد مقایسه قرار

جدول (۷): ارزیابی عملکرد مدل (ساختار D10)

عملکرد	بارش پیش بینی شده
میانگین مربعات خطا	۰/۰۰۲
میانگین مربعات خطای نرمال شده	۰/۳۵۲
میانگین خطای مطلق	۰/۰۳۰
مینیمم خطای مطلق	۰/۰۰۳
ماکزیمم خطای مطلق	۰/۲۴۳
ضریب همبستگی	۰/۹۲۰

جدول (۸): مقایسه مدل‌های مورد استفاده

نوع مدل	میانگین مربعات خطا	میانگین خطای مطلق	ضریب همبستگی
شبکه عصبی مصنوعی	۰/۰۰۳	۰/۰۴۳	۰/۷۵
شبکه عصبی-موجک	۰/۰۰۲	۰/۰۳۰	۰/۹۲



شکل (۸): مقایسه نتایج مدل‌های مورد استفاده

ترکیبی شبکه عصبی مصنوعی-موجک نسبت به مدل شبکه عصبی مصنوعی دارای دقت بیشتری است، و این به دلیل این است که روی میزان تأثیر داده‌های سری‌زمانی قبل از ورود به شبکه تفکیک‌پذیری صورت می‌گیرد و سیگنال اولیه به چندین زیرسیگنال تجزیه شده، که با این کار این امکان فراهم می‌شود که بتوان از یک آنالیز که تأثیرات کوتاه مدت و بلند مدت را در بر می‌گیرد بهره‌مند شد. با انجام این کار شبکه در ارزیابی و تخمین‌های آینده بهینه‌تر می‌شود. در مدل ترکیبی از ۳ موجک مادر استفاده شد که موجک مادر Db4 در مقایسه با دیگر موجک‌های مادر (یعنی Haar و Sym3) عملکرد بهتری داشت. به عنوان یک نتیجه کلی از این تحقیق می‌توان گفت که، اگر چه با کاهش یا افزایش سطوح در مدل ترکیبی می‌توان دقت مدل را افزایش یا کاهش داد ولی سطح بهینه بر اساس طول سیگنال مشخص می‌شود. همچنین با توجه به دقت مدل ترکیبی می‌توان از آن برای پیش‌بینی‌های بلند مدت و کوتاه مدت استفاده کرد. به طور کلی از این تحقیق این نتیجه حاصل شد که مدل ترکیبی در برآورد نقاط حدی به خوبی عمل می‌کند. همچنین پیشنهاد می‌شود این تحقیق برای داده‌های روزانه و همچنین با بهره گرفتن از داده‌های سرعت باد و تابش خورشید علاوه بر پارامترهای استفاده شده در این تحقیق، مورد بررسی قرار گیرد.

در این تحقیق از داده‌های رطوبت‌نسبی و دما نیز علاوه بر بارش استفاده شد که در ساختارهای برتر هر دو مدل مشاهده شد که پارامترهای رطوبت‌نسبی و دما باعث بهتر شدن نتایج مدل‌سازی شده است پس پیشنهاد می‌شود در مطالعات پیش‌بینی بارش علاوه بر پارامتر بارش از دو پارامتر دما و رطوبت‌نسبی نیز استفاده گردد. نتایج این تحقیق با نتایج (Adamowski, 2010) مبنی بر عملکرد بهتر مدل ترکیبی شبکه عصبی مصنوعی-موجک نسبت به مدل شبکه عصبی مصنوعی مطابقت دارد. از طرفی نتایج حاصل از این تحقیق با نتایج (Nourani et al., 2009) که قابلیت آنالیز موجک را در پیش‌بینی فرآیندهای هیدرولوژیکی، نشان دادند کاملاً منطبق می‌باشد. عبقری (۱۳۸۷) نیز نشان داد که تجزیه سیگنال‌ها با استفاده از تحلیل گسسته موجک الگوهای بارش‌رواناب، موجب افزایش دقت بیشتری نسبت به سایر روش‌های به کار گرفته شده می‌شود که با نتایج این تحقیق مبنی بر تجزیه مستقیم امواج بارندگی ماهانه همخوانی دارد.

نتیجه‌گیری

در این تحقیق از مدل ترکیبی شبکه عصبی مصنوعی-موجک و مدل شبکه عصبی مصنوعی برای پیش‌بینی بارش ایستگاه وراینه استفاده شد. همان‌طوری که از بررسی ساختارهای مختلف در این تحقیق برداشت شد می‌توان نتیجه گرفت که مدل

منابع

- طوفانی، پ.، ا. مساعدی، ا. فاخری فرد. ۱۳۹۰. پیش‌بینی بارش با استفاده از نظریه موجک. نشریه آب و خاک (علوم و صنایع کشاورزی) جلد ۲۵، شماره ۵، ص ۱۲۲۶-۱۲۱۷.
- کماسی، م. ۱۳۸۶. مدل‌سازی بارش- رواناب با استفاده از مدل ترکیبی موجک- شبکه‌عصبی مصنوعی. پایان نامه کارشناسی ارشد، دانشگاه تبریز.
- عبقری، ه. ۱۳۸۷. بررسی روش‌های پیش‌بینی هوشمند مبتنی بر شبکه‌های عصبی موجکی و مدل‌های خود همبستگی دبی ماهانه رودخانه. پایانه نامه دکتری آبخیزداری- منابع آب، دانشگاه تهران.

Adamowski, J., K. Sun. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*, 390: 85-91.

Asadi, S., J. Shahabi, P. Abbaszadeh, S. Tabanmehr. 2013. A New Hybrid Artificial Neural Networks for Precipitation–Runoff Process Modeling. *Neurocomputing*: 05-23.

Chua, L. H. C., T. S. W. Wong. 2010. Improving event-based Precipitation–runoff modeling using a combined artificial neural network–kinematic wave approach. *Journal of Hydrology*, 390(1–2): 92-10.

Fofola, G., E. Kumar. P (eds). 1995. *Wavelet in geophysics*. Academic New York.

Hamzaçebi, C. 2008. Improving artificial neural networks' performance in seasonal time series forecasting. *Information Sciences*, 178(23): 4550-455.

Kisi, O. 2008. Stream flow forecasting using neuro-wavelet technique. *Hydrological Processes*, 22: 4142–4152.

Mallat, S. G. 1998. *A wavelet tour of signal processing*, San Diego.

Nourani, V., M. T. Alami, M. H. Aminfar. 2009. A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*, 22(3): 466-472.

Nourani, V., M. Komasi and A. Mano. 2009. A Multivariate ANN-Wavelet Approach for Precipitation–Runoff Modeling. *Water Resour Manage*, 23: 2877–2894.

Nourani, V., Ö. Kisi, M. Komasi. 2011. Two hybrid Artificial Intelligence approaches for modeling Precipitation–runoff process. *Journal of Hydrology*, 402: 41–59.

Nourani, V., M. Parhizkar. 2013. Conjunction of SOM-based feature extraction method and hybrid wavelet-ANN approach for Precipitation–runoff modeling. *Journal of Hydroinformatics*, 15.3: 829-848

Riad, S., J. Mania, L. Bouchaou, Y. Najjar. 2004. Precipitation-runoff model using an artificial neural network approach. *Mathematical and Computer Modelling*, 40(7-8): 839-846.

Forecasting Monthly Precipitation Using a Hybrid Model of Wavelet Artificial Neural Network and Comparison with Artificial Neural Network

Abazar solgi¹, Heidar Zarei², Amir pourhaghi³, Hamidreza khodabakhshi⁴

Abstract

Doubtlessly the first step in a river management is precipitation prediction of the watershed area. However, considering high-stochastic property of the process, many models are still being developed in order to define such a complex phenomenon in the field of hydrologic engineering. Recently Artificial Neural Network (ANN) is extensively used as a non-linear inter-extrapolator by hydrologists. In the present study, Wavelet Analysis combined with artificial neural network and compared with Artificial Neural Network to predict the precipitation of Varayeneh station in the city of Nahavand. For this purpose, the original time series using wavelet theory decomposed to multi sub-signals. After this these sub-signals are used as input data to Artificial Neural Network to predict monthly Precipitation. The results showed that according to correlation coefficient of 0.92 and mean square error of 0.002 for the hybrid model of Wavelet-Artificial Neural Networks, the performance of this model is better than Artificial Neural Network with correlation coefficient of 0.75 and mean square error of 0.003 and can be used for short and long term precipitation prediction.

Keywords: Artificial Neural Networks, Hybrid Model of Wavelet – Artificial Neural Networks, Nahavand City, Monthly Precipitation Prediction.

¹ Ph.D. Student of Water Resources Engineering, Faculty of Water Sciences, Shahid Chamran University of Ahvaz. 09189499579 A-solgi@mscstu.scu.ac.ir

² Assistant Professor of Department Hydrology and Water Resources, Faculty of Water Sciences, Shahid Chamran University of Ahvaz. Zareih@scu.ac.ir

³ Ph.D. Student of Water Resources Engineering, Faculty of Water Sciences, Shahid Chamran University of Ahvaz. Pourhaghiamir@yahoo.com

⁴ M.Sc. of Agriculture, Deputy Director in planning and development of irrigation and drainage networks Khuzestan Water and Power Authority (KWPA), Ahvaz. Khhamid2000@yahoo.com