



Technical Note

Spatial-Temporal Disaggregation of Rainfall
Time Series Using Wavelet-Artificial Neural
Network Hybrid ModelN. Farboudfam¹, V. Nourani^{2*} and B. Aminnejad³

Abstract

Due to the need to simulate rainfall time series at different time scales for engineering purposes on one hand and lack of recordings for these parameters in small scales caused by the administrative and financial problems, on the other hand, disaggregation of rainfall time series to the desired scale is an essential topic in water resources engineering. In this study, to disaggregate Tabriz and Sahand rain gauges time series, the wavelet-artificial neural network (WANN) hybrid model is proposed according to nonlinear characteristics of the time scales. For this purpose, ten years of daily data from four rain gauges and monthly data from six rain gauges in Urmia Lake Basin were decomposed with wavelet transform. Then using mutual information and correlation coefficient criteria, the subseries were ranked and dominant subseries were used as input to ANN model for disaggregating the monthly rainfall time series into daily time series. Results obtained by the WANN disaggregation model were also compared with the results of ANN and conventional multiple linear regression models. The efficiency of WANN model at validation stage for Tabriz rain gauge showed an increase of up to 8.5% and 33% with regards to ANN and multiple linear regression models. For Sahand rain gauge a respectively increase of up to 13.7% and 26% were remarked. It was concluded that WANN hybrid model can be considered as an accurate model for disaggregation of the hydro-climatological time series.

Keywords: Rainfall Time Series, Disaggregation, Artificial Neural Networks, Wavelet Transform, Hybrid Model.

Received: April 12, 2017

Accepted: July 15, 2017

یادداشت فنی

ریزمقیاس کردن مکانی-زمانی سری‌های زمانی بارش با
استفاده از مدل ترکیبی موجک-شبکه عصبی مصنوعینیما فربودفام^۱، وحید نورانی^{۲*} و بابک امین‌نژاد^۳

چکیده

با توجه به نیاز شبیه‌سازی سری‌های زمانی بارش در مقیاس‌های مختلف برای مقاصد مهندسی از یک طرف و عدم ثبت این پارامترها در مقیاس‌های ریز بدلیل مشکلات اجرایی و اقتصادی از طرف دیگر، ریزمقیاس کردن بارش به مقیاس مورد نظر، یک امر ضروری می‌باشد. در این مطالعه، برای ریزمقیاس کردن سری زمانی بارش ایستگاه‌های تبریز و سهند، با توجه به ویژگی‌های غیرخطی مقیاس‌های زمانی، مدل ترکیبی موجک-شبکه عصبی مصنوعی (WANN^۱) پیشنهاد شده است. برای این هدف داده‌های سری زمانی ماهانه شش ایستگاه و روزانه چهار ایستگاه بارش در حوضه آبریز دریاچه ارومیه، برای ۱۰ سال بوسیله تبدیل موجک به زیرسری‌های زمانی تجزیه شده و سپس با استفاده از معیارهای اطلاعات متقابل و ضریب همبستگی، زیرسری‌ها رتبه‌بندی شده و برای ریزمقیاس کردن سری زمانی ماهانه ایستگاه‌های تبریز و سهند به روزانه، زیرسری‌های برتر به عنوان داده‌های ورودی به مدل شبکه عصبی مصنوعی (ANN^۲) وارد شد. نتایج بدست آمده از مدل WANN، با نتایج حاصل از کاربرد ANN و روش کلاسیک رگرسیون چند متغیره خطی، مقایسه شد. در مجموع نتایج مدل WANN نسبت به مدل‌های ANN و رگرسیون چند متغیره خطی برای اعتبارسنجی در حالت بهینه ایستگاه تبریز به ترتیب ۸/۵٪ و ۳۳٪ و در حالت بهینه ایستگاه سهند، به ترتیب ۱۳/۷٪ و ۲۶٪ افزایش نشان داد. لذا ملاحظه شد که روش WANN نسبت به دو روش دیگر، دقت بالاتری داشته و به عنوان روشی مناسب جهت ریزمقیاس کردن پارامترهای هیدروکلیماتولوژیکی پیشنهاد می‌شود.

کلمات کلیدی: سری‌های زمانی بارش، ریزمقیاس کردن، شبکه‌های عصبی مصنوعی، تبدیل موجک، مدل ترکیبی.

تاریخ دریافت مقاله: ۹۶/۱/۲۳

تاریخ پذیرش مقاله: ۹۶/۴/۲۴

1- Ph.D. Candidate, Department of Civil Engineering, Roudehen Branch, Islamic Azad University, Tehran, Iran.

2- Professor, Department of Civil Engineering, Tabriz University, Tabriz, Iran. Email: nourani@tabrizu.ac.ir

3- Assistant Professor, Department of Civil Engineering, Roudehen Branch, Islamic Azad University, Tehran, Iran.

*- Corresponding Author

۱- کاندیدای دکتری گروه مهندسی عمران-آب، واحد رودهن، دانشگاه آزاد اسلامی، تهران، ایران.

۲- استاد گروه مهندسی عمران-آب، دانشگاه تبریز، تبریز، ایران.

۳- استادیار گروه مهندسی عمران-آب، واحد رودهن، دانشگاه آزاد اسلامی، تهران، ایران.

*- نویسنده مسئول
بحث و مناظره (Discussion) در مورد این مقاله تا پایان بهار ۱۳۹۸ امکانپذیر است.

۱- مقدمه

بارش متغیری تصادفی بوده و عدم قطعیت در تخمین آن، برنامه‌ریزی و مدیریت بهینه منابع آب را برای متولیان و تصمیم‌گیرندگان مشکل می‌سازد. کمبود اطلاعات در بسیاری از زمینه‌ها و تحلیل‌های هیدروکلیماتولوژیکی، منجر به ارایه روش‌هایی جهت تولید اطلاعات مصنوعی از روی اطلاعات مشاهداتی شده است و در اکثر اوقات، یک فرآیند تصادفی هیدروکلیماتولوژیکی باید در مقیاس‌های زمانی مختلف مورد مطالعه قرار گیرد. لیکن چگونگی تولید سری‌های زمانی سازگار در مقیاس‌های زمانی بزرگ و کوچک مشکل می‌باشد.

سری‌های زمانی عموماً به دو روش آماری و دینامیکی، ریزمقیاس می‌شوند. در ریزمقیاس کردن آماری یک ارتباط آماری با استفاده از رگرسیون ساده، چند متغیره، شبکه عصبی و غیره بین رفتار واقعی سنجنده و خروجی مدل ایجاد می‌شود. مدل‌های ریزمقیاس کردن آماری از رفتار سیستم در دوره آماری استفاده کرده و برای مکان مورد نظر می‌توانند وضعیت سری‌های زمانی بارش را مدل نمایند. حال آنکه این مدل‌های آماری نمی‌توانند رفتاری خارج از رفتار دوره آماری و مشاهداتی را تولید نمایند.

در ارتباط با پیش‌بینی سری‌های زمانی توسط پژوهشگران، مطالعاتی با استفاده از روش‌های هوش مصنوعی و مدل‌های موجک-شبکه عصبی مصنوعی^۱ انجام گرفته است که منجر به ارتقای نتایج نسبت به روش‌های ریاضی و آماری کلاسیک شده است (Poustizadeh and Najafi, 2011; Ghorbani et al., 2015). روش‌های ریاضی و آماری کلاسیک متعددی در خصوص ریزمقیاس کردن سری‌های زمانی بارش توسط پژوهشگران مورد استفاده قرار گرفته است. عموماً روش‌های کلاسیک ریزمقیاس کردن، دارای ذات خطی بوده و در مواجهه با فرآیندهای بارش که ماهیتی غیرخطی دارند دارای محدودیت می‌باشند. با عنایت به ماهیت غیرخطی سری‌های زمانی بارش، در سال‌های اخیر، مطالعات مختلفی برای مدل‌سازی بارش با مدل‌های غیرخطی هوش مصنوعی توسعه یافته و برای ریزمقیاس کردن سری‌های زمانی بارش نیز مورد استفاده قرار گرفته است (Burian et al., 2000; Burian et al., 2001; Burian and Durrans, 2002; Tripathi et al., 2006; Rajee and Mujumdar, 2011; Kalra et al., 2013; Kim and Singh, 2015). روش‌های هوش مصنوعی ریزمقیاس کردن با وجود ماهیت غیرخطی، در مواجهه با داده‌های ناپیوسته دارای ضعف بوده و با عنایت به اینکه اکثر سری‌های زمانی بارش دارای ناپیوستگی می‌باشند، استفاده از روش‌هایی که کارایی بیشتری در لحاظ کردن ناپیوستگی‌ها در مدل‌سازی داشته باشد احساس می‌شود. با عنایت به ناپیوستگی

سری‌های زمانی بارش، در سال‌های اخیر پژوهش‌های هرچند محدود در خصوص ریزمقیاس کردن بارش با استفاده از تبدیل موجک صورت گرفته است (Rashid et al., 2015; Kim et al., 2016). ترکیب تئوری موجک و شبکه‌های عصبی منجر به توسعه و کاربرد مدل‌های شبکه‌های عصبی موجکی در مطالعات هیدروکلیماتولوژیکی شده است که در این مدل‌های موجک-شبکه عصبی مصنوعی (WANN) علاوه بر وزن‌های شبکه عصبی، موقعیت و مقیاس موجک‌ها بهینه‌سازی می‌شوند (Adamowski and Sun, 2010; Tiwari and Chatterjee, 2010; Adamowski and Prasher, 2012; Okkan and Serbes, 2013; Nourani et al., 2009; Nourani et al., 2011; Nourani et al., 2014).

در این تحقیق از تبدیل موجک به عنوان عامل پیش‌پردازش‌کننده در ساختار مدل‌های هوش مصنوعی به منظور کاهش خطا و ناپیوستگی داده‌ها استفاده می‌شود که یک روش تازه بوده و تاکنون در زمینه ریزمقیاس کردن، تحقیقی صورت نگرفته است، در ترکیب با مدل شبکه عصبی مصنوعی^۲ و برای ریزمقیاس کردن بارش استفاده شده که مهمترین تفاوت آن با مبحث پیش‌بینی در یکسان نبودن سائز ورودی و خروجی مدل و همچنین چند ایستگاهی بودن می‌باشد و نشان از نوآوری تحقیق دارد.

۲- روش تحقیق

در این تحقیق، از شبکه عصبی مصنوعی به عنوان یکی از ابزارهای هوش مصنوعی و محاسباتی نرم و تبدیل موجک برای ریزمقیاس کردن مکانی (چند ایستگاهی) و زمانی بارش استفاده شده است. برای این منظور در ابتدا، داده‌های ورودی در مقیاس‌های بزرگ زمانی برای چند ایستگاه تهیه شد و نرمال‌سازی و پیش‌پردازش داده‌ها صورت گرفت. سپس در دو حالت با تبدیل موجک و بدون تبدیل موجک اقدام به ریزمقیاس کردن شد. در حالت با تبدیل موجک، ابتدا سری‌های زمانی با استفاده از تبدیل موجک و در مرتبه L به زیر سری‌های زمانی در مقیاس‌های مختلف تجزیه شده و سپس زیر سری‌ها با معیارهای اطلاعات متقابل (MI^3) ^۳ و ضریب همبستگی (CC^4) ^۴ رتبه‌بندی شده و زیرسری‌های برتر انتخاب گردیده و این زیر سری‌ها به عنوان ورودی به مدل شبکه عصبی مصنوعی اعمال شد (Nourani et al., 2014; Yang et al., 2000; Swinscow and Campbell, 1997). در حالت بدون تبدیل موجک نیز، داده‌های خام اصلی وارد مدل شبکه عصبی مصنوعی شده و خروجی حاصل شد. در مرحله بعد نتایج حاصل از مدل‌های ریزمقیاس کردن مختلف این تحقیق، صحت‌سنجی گردید و نتایج حاصل با مدل رگرسیون خطی چند متغیره، مقایسه و مدل دقیق‌تر انتخاب گردید.

۳- نتایج و بحث

در این تحقیق، از دوازده الگوی ورودی مختلف برای ریزمقیاس کردن بارش ایستگاه‌های تبریز و سهند استفاده شد که الگوهای ورودی مربوط به ایستگاه بارش تبریز به شرح جدول ۱ می‌باشد.

جداول ۲ و ۳، به ترتیب نتایج ریزمقیاس کردن را با استفاده از مدل WANN برای ایستگاه‌های تبریز و سهند نشان می‌دهند.

در مدل موجک-شبکه عصبی مصنوعی، در ایستگاه تبریز، بهترین ساختار با هفت نرون در لایه مخفی و تعداد تکرار ۱۱۰ با موجک مادر sym3 و در ایستگاه سهند، بهترین ساختار با پنج نرون در لایه مخفی و تعداد تکرار ۱۰۰ با موجک مادر coif1 حاصل شده است. برای ایستگاه تبریز، ضریب تبیین ۰/۷۵ برای آموزش و ۰/۶۴ برای اعتبارسنجی و برای ایستگاه سهند، ضریب تبیین ۰/۷۴ برای آموزش و ۰/۵۸ برای اعتبارسنجی مدل‌سازی ریزمقیاس کردن، نشان‌دهنده اجرای مناسب مدل موجک-شبکه عصبی مصنوعی در مدل‌سازی ریزمقیاس کردن می‌باشد.

در شکل‌های ۱ و ۲ نیز به ترتیب پراکندگی داده‌های مشاهداتی و محاسباتی بارش حول نیمساز در بهینه‌ترین حالت حاصل از مدل ریزمقیاس کردن موجک-شبکه عصبی مصنوعی در مرحله اعتبارسنجی برای ایستگاه‌های تبریز و سهند قابل مشاهده می‌باشد.

در این تحقیق از داده‌های بارش ده سال حوضه آبریز دریاچه ارومیه در دوره ۲۰۰۰ الی ۲۰۰۹ استفاده گردید. حوضه دارای ایستگاه‌های باران‌سنج متعدد می‌باشد که با عنایت به همبستگی بیشتر بین ایستگاه‌ها، داده‌های شش ایستگاه تبریز، سراب، سهند، مراغه، بناب و اهر انتخاب و در این مطالعه مورد استفاده قرار گرفته است. ۷۵ درصد از این داده‌ها برای آموزش و ۲۵ درصد آن برای صحت‌سنجی در نظر گرفته شد. ریزمقیاس کردن با استفاده از داده‌های روزانه چهار ایستگاه (سراب، مراغه، بناب و اهر) و داده‌های ماهانه هر شش ایستگاه، برای یافتن داده‌های روزانه ایستگاه‌های تبریز و سهند انجام شد.

در این مطالعه از چهار موجک مادر متداول $db2^6$, $Harr$, $Coif1^5$ و $sym3^7$ برای تجزیه سری‌های زمانی به زیر سری‌های و از مدل ANN پیشرو با الگوریتم انتشار برگشتی ($FFNNs^8$) با ساختار سه لایه‌ای استفاده شد (Kim and Valdés, 2003).

برای ارزیابی مقدار کارایی و دقت مدل‌ها از ریشه مربعات خطاها ($RMSE^9$) و ضریب تبیین (DC^{10}) استفاده شده است (Nourani et al., 2009). با عنایت به اینکه در سری‌های زمانی بارش در مقیاس روزانه، خیلی از روزها به دلیل عدم بارش، می‌تواند صفر باشد، از ضریب تبیین به جز صفر ($DC_{\text{except zero}}$) نیز برای مقایسه و ارزیابی بهتر نتایج استفاده شده است.

Table 1- Different input patterns of ANN model at Tabriz rain gauge station
جدول ۱- الگوهای ورودی مدل شبکه عصبی مصنوعی برای ایستگاه بارش تبریز

Number of input pattern	Input pattern
1	$DR1(t) = f\{MR2(t), MR1(t)\}$
2	$DR1(t) = f\{MR3(t), DR3(t), MR2(t), MR1(t)\}$
3	$DR1(t) = f\{MR4(t), DR4(t), MR3(t), DR3(t), MR2(t), MR1(t)\}$
4	$DR1(t) = f\{MR5(t), DR5(t), MR4(t), DR4(t), MR3(t), DR3(t), MR2(t), MR1(t)\}$
5	$DR1(t) = f\{MR6(t), DR6(t), MR5(t), DR5(t), MR4(t), DR4(t), MR3(t), DR3(t), MR2(t), MR1(t)\}$
6	$DR1(t) = f\{MR6(t), DR6(t), MR5(t), DR5(t), MR4(t), DR4(t), MR3(t), DR3(t), MR1(t)\}$
7	$DR1(t) = f\{DR6(t), DR5(t), DR4(t), DR3(t), MR1(t)\}$
8	$DR1(t) = f\{MR6(t), DR6(t-1), MR5(t), DR5(t), MR4(t), DR4(t), MR3(t), DR3(t), MR2(t), MR1(t)\}$
9	$DR1(t) = f\{MR6(t), DR6(t), MR5(t), DR5(t-1), MR4(t), DR4(t), MR3(t), DR3(t), MR2(t), MR1(t)\}$
10	$DR1(t) = f\{MR6(t), DR6(t), MR5(t), DR5(t), MR4(t), DR4(t-1), MR3(t), DR3(t), MR2(t), MR1(t)\}$
11	$DR1(t) = f\{MR6(t), DR6(t), MR5(t), DR5(t), MR4(t), DR4(t), MR3(t), DR3(t-1), MR2(t), MR1(t)\}$
12	$DR1(t) = f\{MR6(t), DR6(t-1), MR5(t), DR5(t-1), MR4(t), DR4(t-1), MR3(t), DR3(t-1), MR2(t), MR1(t)\}$

توجه: MR مخفف بارش ماهانه و DR مخفف بارش روزانه و شماره ایستگاه‌های بارش تبریز، سهند، سراب، مراغه، بناب و اهر به ترتیب یک الی شش می‌باشد.
Note: MR= Monthly Rainfall, DR= Daily Rainfall, and the respective Station Numbers for Tabriz, Sahand, Sarab, Maragheh, Bonab, and Ahar are 1 to 6.

Table 2- Resulted RMSE and determination coefficient for disaggregated daily rainfall at Tabriz station based on wavelet-ANN hybrid model

جدول ۲- نتایج ضریب تبیین و خطاهای حاصل از ریزمقیاس کردن مدل موجک-شبکه عصبی مصنوعی در ایستگاه تبریز

Input Pattern No	Wavelet type	Decomposition level	Best Epoch	Best ANN structure	Determination coefficient (DC)		Root Mean Square Error (RMSE)		Ranking
					Calibration	Verification	Calibration	Verification	
5	coif1	3	140	(40-5-1)	0.80	0.58	1.142	1.330	8
	db2	3	110	(40-7-1)	0.77	0.58	1.215	1.325	7
	Harr	3	130	(40-15-1)	0.76	0.62	1.255	1.259	4
	sym3	3	160	(40-10-1)	0.80	0.59	1.129	1.315	6
With MI Ranking	coif1	3	110	(10-5-1)	0.77	0.63	1.228	1.254	3
	db2	3	200	(10-8-1)	0.72	0.60	1.359	1.298	5
	Harr	3	170	(10-6-1)	0.76	0.51	1.248	1.435	11
	sym3	3	110	(10-7-1)	0.75	0.64	1.266	1.223	1
With CC Ranking	coif1	3	190	(10-5-1)	0.68	0.64	1.438	1.231	2
	db2	3	200	(10-5-1)	0.67	0.58	1.467	1.334	9
	Harr	3	180	(10-5-1)	0.72	0.54	1.357	1.398	10
	sym3	3	170	(10-5-1)	0.63	0.48	1.560	1.479	12

Table 3- Resulted RMSE and determination coefficient for disaggregated daily rainfall at Sahand station based on wavelet-ANN hybrid model

جدول ۳- نتایج ضریب تبیین و خطاهای حاصل از ریزمقیاس کردن مدل موجک-شبکه عصبی مصنوعی در ایستگاه سهند

Input Pattern No	Wavelet type	Decomposition level	Best Epoch	Best ANN structure	Determination coefficient (DC)		Root Mean Square Error (RMSE)		Ranking
					Calibration	Verification	Calibration	Verification	
5	coif1	3	120	(40-8-1)	0.84	0.56	0.880	1.297	2
	db2	3	120	(40-7-1)	0.77	0.49	1.064	1.391	11
	Harr	3	170	(40-6-1)	0.76	0.52	1.075	1.355	6
	sym3	3	120	(40-5-1)	0.76	0.50	1.079	1.377	9
With MI Ranking	coif1	3	100	(10-5-1)	0.74	0.58	1.125	1.267	1
	db2	3	140	(10-5-1)	0.74	0.53	1.129	1.339	3
	Harr	3	130	(10-6-1)	0.66	0.53	1.289	1.339	4
	sym3	3	180	(10-6-1)	0.72	0.51	1.176	1.366	7
With CC Ranking	coif1	3	180	(10-5-1)	0.76	0.53	1.072	1.340	5
	db2	3	130	(10-5-1)	0.79	0.50	1.016	1.382	10
	Harr	3	150	(10-5-1)	0.73	0.49	1.135	1.395	12
	sym3	3	160	(10-5-1)	0.74	0.50	1.116	1.372	8

در جدول ۴، نتایج مقایسه‌ای سه روش ریزمقیاس کردن در دو ایستگاه تبریز و سهند آورده شده است. نتایج حاکی از این است که با توجه به این معیار نیز، مدل ریزمقیاس کردن موجک-شبکه عصبی مصنوعی، نسبت به دو مدل دیگر نتایج بهتری را نشان داده است.

همانطور که شکل نشان می‌دهد این مدل قادر به یافتن الگویی مناسب برای ریزمقیاس کردن بوده و توانایی شبیه‌سازی پیک‌ها را دارا می‌باشد.




Fig. 1- Scatter plot of observed versus disaggregated rainfall (in mm) using WANN for Tabriz station

شکل ۱- پراکندگی داده‌های مشاهداتی و محاسباتی بارش (میلیمتر) حول نیمساز در بهینه‌ترین حالت حاصل از مدل ریزمقیاس کردن WANN برای ایستگاه تبریز




Fig. 2- Scatter plot of observed versus disaggregated rainfall (in mm) using WANN for Sahand station
 شکل ۲- پراکندگی داده‌های مشاهداتی و محاسباتی بارش (میلی‌متر) حول نیمساز در بهینه‌ترین حالت حاصل از مدل ریزمقیاس کردن WANN برای ایستگاه سهند

Table 4- Comparison of RMSE and determination coefficients resulted from the rainfall disaggregation using the three models

جدول ۴- نتایج مقایسه‌ای ضریب تبیین و خطاهای حاصل از ریزمقیاس کردن بارش با سه مدل

Model	Model type	Case Study	Determination coefficient (DC)		Root Mean Square Error (RMSE)		$DC_{Except\ Zero}$
			Calibration	Verification	Calibration	Verification	
Multiple Linear Regression	Linear	Tabriz	0.55	0.48	1.717	1.478	0.38
ANN	Non-linear		0.64	0.59	1.525	1.316	0.54
WANN	Hybrid		0.75	0.64	1.266	1.223	0.60
Multiple Linear Regression	Linear	Sahand	0.58	0.46	1.431	1.434	0.31
ANN	Non-linear		0.67	0.51	1.268	1.364	0.36
WANN	Hybrid		0.74	0.58	1.267	1.408	0.42

زمانی بارش، به منظور ریزمقیاس کردن و شبیه‌سازی، استفاده از مدل موجک-شبکه عصبی مصنوعی به نتایج بهتری منجر گردید. چرا که تبدیل موجک با تجزیه سری زمانی به فرکانس‌های بالا و پایین ویژگی‌های چند مقیاسی سری زمانی را در اختیار گذاشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. در هر دو ایستگاه، روش موجک-شبکه عصبی مصنوعی نسبت به دو روش دیگر، دقت بالاتری داشته و به عنوان روشی مناسب جهت ریزمقیاس کردن پارامترهای هیدروکلیماتولوژیکی پیشنهاد گردید. همچنین در مدل ترکیبی، ضریب تبیین به جز صفر نیز بالا بوده و تطابق زیادی در بین سری‌های زمانی به جز صفر مشاهداتی و محاسباتی بارش وجود دارد.

ریزمقیاس کردن بارش با مدل‌های ترکیبی سایر مدل‌های هوش مصنوعی با تبدیل موجک و مقایسه نتایج با این تحقیق و ریزمقیاس کردن سایر پارامترهای هیدروکلیماتولوژیکی با مدل‌های این تحقیق و همچنین ریزمقیاس کردن به مقیاس زمانی ریزتر مثل مقیاس ساعتی با مدل ترکیبی پیشنهادی و همچنین ریزمقیاس کردن سری‌های بارش مربوط به داده‌های مدل‌های گردش عمومی (GCMs) می‌تواند

دلیل نتایج بهتر مدل موجک-شبکه عصبی مصنوعی این است که ایستگاه‌ها از لحاظ مکانی و زمانی می‌توانند با تأخیرهای مختلف تأثیرگذار باشند که در این مدل ترکیبی، علاوه بر پیش پردازش و تقسیم داده‌ها به زیر سری‌ها، به هر زیر سری وزن متناسب با آن زیر سری اعمال و سپس مدل‌سازی شده که با توجه به ارتقای نتایج نسبت به مدل شبکه عصبی مصنوعی، حاکی از تأثیر مثبت تبدیل موجک در مدل‌سازی و ریزمقیاس کردن می‌باشد.

۴- نتیجه‌گیری و پیشنهادها

در این مطالعه نتایج مدل ترکیبی موجک-شبکه عصبی مصنوعی با مدل شبکه عصبی مصنوعی و مدل کلاسیک رگرسیون خطی چند متغیره، برای ریزمقیاس کردن بارش از مقیاس ماهانه به روزانه در حوضه آبریز دریاچه ارومیه مقایسه گردید و نتیجه‌ای که از این مقایسه گرفته شد حاکی از برتری مدل ریزمقیاس کردن موجک-شبکه عصبی مصنوعی نسبت به دو مدل دیگر بود. با اینکه مدل ANN بخاطر در اختیار داشتن هسته غیرخطی توانایی مدل‌سازی رفتارهای غیرخطی را داراست، ولی با توجه به ویژگی‌های نالیستایی و غیرخطی بودن سری

Kim S, Singh V (2015) Spatial disaggregation of areal rainfall using two different artificial neural networks models. *Water* 7(6):2707-2727

Kim T, Valdés J (2003) Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering* 8(6):319-328

Nourani V, Baghanam AH, Adamowski J, Kisi O (2014) Applications of hybrid wavelet-artificial intelligence models in hydrology: A review. *Journal of Hydrology* 514(1):358-377

Nourani V, Kisi O, Komasi M (2011) Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology* 402(1):41-59

Nourani V, Komasi M, Mano A (2009) A multivariate ann-wavelet approach for rainfall-runoff modeling. *Water Resources Management* 23(14):2877-2894

Nourani V, Ranjbar S, Tootoonchi F (2015) Change detection of hydrological processes using wavelet-entropy complexity measure case study: Urmia lake. *Journal of Civil and Environmental Engineering* 45.3(80):75-86 (In Persian)

Okkan U, Serbes Z (2013) The combined use of wavelet transform and black box models in reservoir inflow modeling. *Journal of Hydrology and Hydromechanics* 61(2):112-119

Poustizadeh N, Najafi N (2011) Discharge prediction by comparing artificial neural network with fuzzy inference system case study: Zayandeh rud river. *Journal of Iran-Water Resources Research* 7(2):92-97 (In Persian)

Raje D, Mujumdar P (2011) A comparison of three methods for downscaling daily precipitation in the punjab region. *Hydrological Processes* 25(23):3575-3589

Swinscow TDV, Campbell M J (1997) *Statistics at square one*, ninth edition. BMJ Publishing Group, University of Southampton, 140p

Tiwari M, Chatterjee C (2010) Development of an accurate and reliable hourly flood forecasting model using wavelet-bootstrap-ANN (WBANN) hybrid approach. *Journal of Hydrology* 394(3):458-470

Tripathi S, Srinivas V, Nanjundiah R (2006) Downscaling of precipitation for climate change scenarios: A support vector machine approach. *Journal of Hydrology* 330(3):621-640

Yang HH, Vuuren SV, Sharma S, Hermansky H (2000) Relevance of time-frequency features for phonetic and speaker-channel classification. *Speech Communication* 31(1):35-50

از تحقیقات پیش‌روی در آینده باشد. ریزمقیاس کردن سری‌های زمانی دو یا چند ایستگاه به صورت همزمان با مدل ترکیبی پیشنهادی و همچنین مقایسه نتایج مدل ترکیبی پیشنهادی با سایر مدل‌های کلاسیک ریزمقیاس کردن از جمله مدل‌های Hyetos یا Mudrain و یا سایر مدل‌های هوش مصنوعی، می‌تواند برای ادامه این تحقیق، پیشنهاد گردد.

پی‌نوشت‌ها

- 1- Wavelet-Artificial Neural Network
- 2- Artificial Neural Network
- 3- Mutual Information
- 4- Correlation Coefficient
- 5- Coiflet-1
- 6- Daubechies-2
- 7- Symmlet-3
- 8- Feed-Forward Neural Networks
- 9- Root Mean Square Error
- 10- Coefficient of Determination

۵- مراجع

Adamowski J, Prasher S (2012) Comparison of machine learning methods for runoff forecasting in mountainous watersheds with limited data. *Water and Land Development* 17(1):89-97

Adamowski J, Sun K (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(1):85-91

Burian S, Durrans S (2002) Evaluation of an artificial neural network rainfall disaggregation model. *Water Science and Technology* 45(2):99-104

Burian S, Durrans S, Nix S, Pitt R (2001) Training artificial neural networks to perform rainfall disaggregation. *Journal of Hydrologic Engineering* 6(1):43-51

Burian S, Durrans S, Tomić S, Pimmel R, Wai C (2000) Rainfall disaggregation using artificial neural networks. *Journal of Hydrologic Engineering* 5(3):299-307

Ghorbani MA, Azani A, Mahmoudi Vanolya S (2015) Rainfall-runoff modeling using hybrid intelligent models. *Journal of Iran-Water Resources Research* 11(2):146-150 (In Persian)

Kalra A, Miller W, Lamb K, Ahmad S, Piechota T (2013) Using large-scale climatic patterns for improving long lead time streamflow forecasts for gunnison and san juan river basins. *Hydrological Processes* 27(11):1543-1559