

## Hybrid Wavelet-M5 Model Application in Rainfall-Runoff Process Forecast (Case study: Aji Chay Catchment)

A. Davanlou Tajbakhsh<sup>1</sup>, V. Nourani<sup>2</sup>,  
and A. Molajou<sup>3\*</sup>

### Abstract

Rainfall-runoff process is one of the most important and complex phenomena in the hydrological cycle and therefore different views have been presented for modeling the phenomenon. Obviously, the recognition of the behavior of the catchment can play an important role in selecting the appropriate model as well as saving time on the simulation. Previous studies have shown that the multi-linear models have an acceptable performance in the case of watersheds which usually have a regular rainfall pattern. In this study, the multi-linear Wavelet-M5 model was introduced and the rainfall-runoff process in the Aji Chay catchment was investigated. At first, the main rainfall and runoff time series were decomposed to several sub-time series by the wavelet transform to overcome its non-stationarity. Then the obtained sub-time series were imposed as input data to M5 model tree to forecast the runoff values and also the results were compared to the other models (i.e. ANN, M5 and WANN) by the root mean squared error and determination coefficient criteria. The results showed that the performance of the proposed hybrid Wavelet-M5 model increased up to 69% compared to the sole M5 model tree for the Aji Chay catchment.

**Keywords:** Artificial Network, Decision Tree, Rainfall-Runoff Modeling, Wavelet Transform.

Received: April 19, 2018

Accepted: September 25, 2018

## بررسی کارایی مدل هیبریدی Wavelet-M5 در پیش‌بینی فرآیند بارش-رواناب (مطالعه موردی: حوضه آبی چای)

علی دوانلو تاجبخش<sup>۱</sup>، وحید نورانی<sup>۲</sup> و امیر مولاجو<sup>۳\*</sup>

### چکیده

فرآیند بارش-رواناب از مهم‌ترین و پیچیده‌ترین پدیده‌ها در چرخه هیدرولوژی بوده لذا در مدل‌سازی آن، دیدگاه‌های متفاوتی برای توسعه و بهبود مدل‌های پیش‌بینی کننده ارائه گردیده است. بدیهی است درک صحیحی از رفتار حوضه می‌تواند نقش مؤثری در انتخاب مدل و همچنین صرفه‌جویی در زمان مربوط به امر شبیه‌سازی ایفا نماید. مطالعات پیشین نشان داده است که جهت مدل‌سازی حوضه‌های آرام که معمولاً دارای الگوی منظم بارش هستند، مدل‌های چندخطی عملکرد قابل قبولی دارند. در این مطالعه ضمن معرفی مدل ترکیبی چندخطی موجک-درخت تصمیم، کارایی آن جهت مدل‌سازی فرآیند بارش-رواناب حوضه آبریز آبی چای مورد مطالعه قرار گرفت. در ابتدا سری‌های زمانی بارش و رواناب با استفاده از تبدیل موجک به چندین زیرسری تجزیه گشته تا بر ناپایداری آن غلبه گردد. سپس زیرسری‌های حاصل به عنوان ورودی به مدل M5 درختی اعمال شد تا پس از طبقه‌بندی داده‌ها، رگرسیون مربوط به هر خوشه ارائه شود. در ادامه نتایج با سایر مدل‌ها (مدل‌های ANN، M5 و WANN) مقایسه گردید که برای این منظور از دو معیار ریشه میانگین مربعات خطا و ضریب تبیین جهت ارزیابی نتایج استفاده شد. نتایج نشان داد که برای حوضه نسبتاً آرام آبی چای عملکرد مدل ترکیبی پیشنهادی موجک-درخت تصمیم نسبت به مدل خام M5 درختی تا ۶۹ درصد بهبود می‌یابد.

**کلمات کلیدی:** تبدیل موجک، درخت تصمیم، شبکه عصبی، مدل‌سازی بارش-رواناب.

تاریخ دریافت مقاله: ۹۷/۱/۳۰

تاریخ پذیرش مقاله: ۹۷/۷/۳

1- M.Sc., Department of Water Resources Engineering, Faculty of Civil Engineering, Univ. of Tabriz, Tabriz, Iran. Email: alidavanlou@yahoo.com

2- Prof., Department of Water Resources Engineering, Faculty of Civil Engineering, Univ. of Tabriz, Tabriz, Iran. Email: vnourani@yahoo.com

3- Ph.D. Student, Department of Water Resources Engineering, Faculty of Civil Engineering, Iran University of Science and Technology, Tehran, Iran. Email: amolajou@yahoo.com

\*- Corresponding Author

۱- کارشناس ارشد مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه تبریز.

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

۳- دانشجوی دکتری مهندسی و مدیریت منابع آب، دانشکده مهندسی عمران، دانشگاه علم و صنعت ایران.

\*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان پائیز ۱۳۹۸ امکانپذیر است.

## ۱- مقدمه

فرآیند بارش-رواناب از مهمترین و پیچیده‌ترین پدیده‌ها در چرخه هیدرولوژی است (Wang et al., 2013). این فرآیند شامل حرکت قطرات باران در حالت‌های مختلف و در نهایت تشکیل رواناب در کانال‌های طبیعی یا مصنوعی می‌باشد. اگر چه بررسی دقیق و جزء به جزء این فرآیند بیشتر از آنکه جنبه مهندسی داشته باشد دارای ساختار و جنبه علمی است؛ اما بسیاری از پروژه‌ها و طرح‌های مهندسی نیازمند داشتن یک تخمین از کمیت و ویژگی‌های رواناب حاصله از بارش هستند. در این زمینه دیدگاه‌ها و روش‌های مختلفی را می‌توان یافت که در پی یافتن راه حلی دقیق برای برآورد رواناب حاصل از بارش در یک ناحیه مشخص می‌باشند که این مهم در واقع، همان هدف نهایی از مدل‌سازی بارش-رواناب در یک حوضه آبریز است (Parisuj et al., 2017). مشکل اصلی در این زمینه، دخالت و تأثیر پارامترهای مختلفی همانند تبخیر، نفوذ، دما و دیگر عواملی است که در علم هیدرولوژی جایگاه ویژه‌ای را به خود اختصاص داده‌اند. از طرفی باید اشاره نمود که فرآیند مدل‌سازی بارش-رواناب یک پدیده غیرخطی بوده و دارای تغییرات زمانی و مکانی گسترده‌ای می‌باشد و در نتیجه به سادگی قابل مدل‌سازی نیست (Nayak et al., 2004). بنابراین جهت مدل‌سازی پدیده به دلیل الگو و ماهیت غیرخطی آن، دیدگاه‌های متفاوتی برای توسعه و بهبود مدل‌های پیش‌بینی کننده آن ارائه گردیده است.

به طور کلی دو نگرش تفهیمی (جعبه سفید) و سیستمی (جعبه سیاه) در مدل‌سازی پدیده‌های هیدرولوژیکی وجود دارد. مدل‌های جعبه سفید بر مبنای روابط و معادلات ریاضی حاکم و پارامترهای فیزیکی موجود در پدیده ارائه می‌شوند و هدف این مدل‌ها تکیه بر انجام تحقیقات علمی در نحوه عمل اصلی هر یک از اجزای چرخه هیدرولوژی به منظور درک کامل مکانیزم و نحوه عمل اجزا با یکدیگر است. در مدل‌های جعبه سیاه نیز ارائه معادلات و روابط ریاضی در آن‌ها ممکن نیست و پارامترهای فیزیکی مؤثر بر آن به راحتی قابل تخمین نیستند. هدف این گروه، توسعه روابط معتبر بین پارامترهای اندازه‌گیری شده چرخه هیدرولوژی است، که از آن‌ها برای حل مسائل فنی و علمی استفاده می‌گردد. مدل‌های جعبه سیاه با دریافت ورودی و انجام یک سری عملیات ریاضی، خروجی مد نظر را تخمین می‌زنند. انواع مدل‌های جعبه سیاه دارای پارامترها و ضرایبی هستند که با توجه به داده‌های ورودی و خروجی مشاهداتی مورد تخمین قرار می‌گیرند. بنابراین مدل‌های جعبه سیاه به داده‌های ورودی و خروجی از نظر کمیت و کیفیت داده‌ها وابسته هستند (Liu and Todini, 2002; ) (Nayak et al., 2004; Danandeh Mehr et al., 2017). به دلیل

ماهیت غیرخطی اکثر فرآیندهای هیدرولوژیکی، امروزه شبکه عصبی مصنوعی (ANN<sup>۱</sup>)، به عنوان یک تابع تخمین‌گر خود سازمان‌ده، به طور گسترده‌ای در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی در فرآیندهای هیدرولوژیکی مورد استفاده قرار گرفته است. به طور کلی اصلی‌ترین و بارزترین مزایای مدل‌های ANN نسبت به سایر روش‌های آماری و مفهومی را می‌توان در قالب مواردی چون عدم نیاز به دانش قبلی، اعمال یک فیلتر غیر خطی تحت عنوان تابع محرک و توانایی پردازش ورودی‌های چند متغیره با خصوصیات متفاوت، دسته‌بندی نمود (Nourani et al., 2009a).

علی‌رغم ماهیت انعطاف‌پذیر ANN در مدل‌سازی فرآیندهای هیدرولوژیکی، این الگوریتم نقایصی را در مواجهه با سیگنال‌های هیدرولوژیکی، که عموماً ناپیوسته بوده و محدوده وسیعی از مقیاس (از چند دقیقه تا چند دهه) را شامل می‌شود، از خود نشان می‌دهد. از این رو، در چنین شرایطی پیش پردازش زمانی و یا مکانی داده‌ها قبل از اعمال آن‌ها به سیستم شبکه عصبی برای غلبه بر این مشکل ضروری می‌باشد (Nourani et al., 2009a,b). توانایی تبدیل موجک در تجزیه هم‌زمان مکانی و زمانی سری‌های ناپیوسته به زیرسری‌های با مقیاس‌های گوناگون، در تفسیر بهتر پدیده‌های هیدرولوژیکی مؤثر می‌باشد. تبدیل موجک، زیرسری‌های مفیدی از سری اصلی حاصل می‌نماید که این زیرسری‌ها با استخراج اطلاعات سودمند در مقیاس‌های مختلف، قابلیت مدل را در پیش‌بینی متغیر مورد نظر بالا می‌برند. تبدیل موجک با تجزیه سری‌های زمانی به کمک ضرایب اندکی به تفسیر ساختار سری و دریافت اطلاعات مفید در مورد تاریخچه آن کمک می‌کند (Danandeh Mehr et al., 2014). در مدل‌سازی بارش-رواناب مدل ترکیبی موجک-شبکه عصبی (WANN<sup>۲</sup>) روشی کارا بوده که از تبدیل موجک برای حصول فرکانس‌های مختلف فرآیند بارش-رواناب و از ANN برای پیش‌بینی رواناب آبی در مقیاس مورد نظر بهره می‌برد. (Nourani et al., 2014) در مقاله‌ای مروری، توانایی مدل هیبریدی WANN در زمینه‌های مختلف هیدرولوژیکی (اعم از بارش-رواناب) در مقیاس‌های کوتاه و بلند مدت را مورد بررسی قرار داده و دریافتند با توجه به استفاده از زیرسری‌های حاصله از تبدیل موجک به عنوان داده‌های ورودی شبکه عصبی و غلبه بر ناپیوستگی موجود، عملکرد مدل به طور چشم‌گیری افزایش می‌یابد. با این وجود نقایصی را می‌توان به آن، از جمله عدم توجه کافی به داده‌های ورودی، پیچیده‌تر شدن محاسبات با افزایش داده‌های ورودی، احتمال وجود خطا و عدم همگرایی در اثر وجود داده‌های نامرتب و نیز کندتر شدن روند آموزش تحت اثر افزایش ابعاد سری‌های زمانی ورودی، وارد دانست (Tajbakhsh, 2017).

از این رو در سال‌های اخیر این ایده شکل گرفت که به دلیل پراکندگی موجود در داده‌های سری زمانی و عیوب برشمرده در فوق، طبقه‌بندی به عنوان ابزار مناسب، می‌تواند سعی در کاهش بی‌نظمی و پیچیدگی‌های مربوطه داشته باشد. یکی از معروف‌ترین و کارآمدترین ابزار داده‌کاوی برای طبقه‌بندی، خوشه‌بندی و ایجاد مدل‌های رگرسیونی، درخت تصمیم می‌باشد (Vakili, 2016). درخت تصمیم، گونه‌ی پرکاربرد در خوشه‌بندی سلسله مراتبی است که تلاش می‌کند تا مشاهدات واقع در هر گروه بیشترین تشابه را از نظر متغیرهای مورد نظر با هم داشته باشند و مشاهدات هر گروه از مشاهدات گروه‌های دیگر بیشترین فاصله را داشته باشد (Nourani and Molajou, 2017; Nourani et al., 2017). همان‌گونه که مشهود است ماهیت فرآیند بارش-رواناب کاملاً غیرخطی و ناپایستا بوده تا جایی که کارایی مدل‌های خطی پیشین در امر شبیه‌سازی مورد قبول واقع نگردید. اما تدریجاً این دیدگاه شکل گرفت که از مدل‌هایی مابین کاملاً خطی و کاملاً غیرخطی (مدل‌های چندخطی) استفاده گردد. در واقع این دسته از مدل‌ها از ویژگی‌های هر دو دسته سود می‌برند. رفتار آن‌ها تا حدودی شبیه مدل‌های غیرخطی بوده (در واقع یک رگرسیون غیرخطی با چند رگرسیون خطی ساده تکه‌ای مدل می‌شود) و همچنین به علت خطی بودن از مزایایی چون اصل جمع آثار قوا، عدم رشد و ثابت ماندن مقدار خطا در اثر بیشتر شدن افق پیش‌بینی، قابل فهم و ساده بودن و نیز خارج شدن از حالت جعبه سیاه بودن محض، برخوردار می‌باشد (Solomatine and Dulal, 2003; Solomatine and Xue, 2004). با توجه به مطالب اشاره شده، در این مطالعه تلاش شد که ابتدا با استفاده از تبدیل موجک، روند موجود در داده‌های سری زمانی مربوط به ایستگاه مورد مطالعه را حذف، سپس با کمک درخت تصمیم، ضمن طبقه‌بندی داده‌ها، مدل رگرسیونی مناسب ارائه گردد.

## ۲- مواد و روش

### ۲-۱- منطقه مورد مطالعه و داده: حوضه آبی‌چای

رودخانه آبی‌چای (تلخه‌رود) در ۱۰ کیلومتری شمال تبریز در دره‌های کوه عینالی (سرخاب) جاری است. این رودخانه از اصلی‌ترین منابع تأمین آب ورودی به دریاچه ارومیه می‌باشد که آب‌های آن از دامنه‌های سبلان جنوبی سرچشمه و در بین راه تمامی آب‌های رودها و دشت‌های شهرستان سراب، بستان‌آباد، اهر، مهران و حومه شمال شرق تبریز در یک بستر بزرگ به آن پیوسته و در نهایت به دریاچه ارومیه جریان می‌یابد. آب رودخانه در ابتدا شیرین بوده، ولی به جهت ورود به جنوب منطقه اهر و عبور از گنبدهای نمکی و معادن، مواد محلول آن افزایش یافته و بر میزان شوری آب رودخانه افزوده می‌شود؛ از این رو به نام آبی‌چای (تلخه‌رود) معروف شده است. میزان آب رودخانه از اوایل

پاییز تا اواخر خرداد سال بعد بسیار پر آب بوده، ولی از اوایل تابستان تا اواخر شهریور ماه به دلیل این که آب رودخانه در مسیر زمین‌های کشاورزی قرار دارد و کشاورزان از آن برای زراعت استفاده می‌کنند، بسیار کم آب می‌شود تا جایی که تقریباً شهریور ماه، آب رودخانه به کلی قطع می‌گردد. حوضه آبریز آبی‌چای به لحاظ موقعیت جغرافیایی بین عرض‌های  $37^{\circ}43'$  تا  $38^{\circ}30'$  شمالی و طول  $45^{\circ}40'$  تا  $47^{\circ}53'$  شرقی واقع شده است. این حوضه از ارتفاع ۳۴۰۰ متری دامنه‌های جنوب و جنوب غربی کوه سبلان و حدود ۳۳ کیلومتری شهرستان سراب شروع شده و با عبور از شمال شهر تبریز، در غرب آذرشهر در ارتفاع ۱۲۷۰ متری به دریاچه ارومیه ختم می‌شود. وسعت این حوضه در حدود ۱۲۷۹۰ کیلومتر مربع است. همانطور که در شکل ۱ نیز نشان داده شده است، در این مطالعه از آمار و اطلاعات ثبت شده برای ایستگاه هیدرومتری ونبار استفاده شده است (Tajbakhsh, 2017; Barzegar et al., 2016).

داده‌های هیدرولوژیکی آمار هواشناسی مورد نیاز برای حوضه آبی‌چای در محدوده سال‌های ۱۳۷۵ (۱۹۹۶ میلادی) تا ۱۳۹۵ (۲۰۱۶ میلادی) در مقیاس روزانه و نیز در محدوده سال‌های ۱۳۵۶ (۱۹۷۷ میلادی) تا ۱۳۹۵ (۲۰۱۶ میلادی) در مقیاس ماهانه از شرکت آب منطقه‌ای آذربایجان شرقی تهیه گردید. لازم به ذکر است که سرآغاز هرگونه مطالعه هیدرولوژی و منابع آب که در آن از سری‌های زمانی داده‌های هواشناسی و هیدرولوژی استفاده می‌شود، کنترل اولیه داده‌های تاریخی است. برای این منظور، محققان مختلف از آزمون‌های مختلفی نظیر آزمون‌های همگنی و بررسی داده‌های پرت استفاده می‌کنند. در بین روش‌های مستقل آزمون همگنی، شاید بتوان روش آزمون همگنی نرمال استاندارد (SNHT<sup>\*</sup>) را یکی از پرکاربردترین روش‌ها دانست. در این پژوهش نیز در گام اول، جهت صحت‌سنجی داده‌ها و به منظور بررسی همگنی آن‌ها، از آزمون همگنی SNHT استفاده شد که برای این منظور نرم‌افزار XLSTAT مورد استفاده قرار گرفت. مشخصات آماری بارش و رواناب برای داده‌های روزانه و ماهانه و نیز نتایج مربوط به آزمون همگنی نرمال استاندارد در جدول ۱ گزارش شده است. بدیهی است که پیش از کسب اطمینان از صحت و کیفیت داده‌های سری‌های زمانی، نمی‌توان اقدام به استفاده از آن‌ها نمود. برای این منظور، آزمون همگنی نرمال استاندارد (SNHT) جهت مطالعه ناهمگنی از نوع تغییر و جایجایی ناگهانی در مقدار میانگین داده‌های مشاهداتی را می‌توان یکی از پرکاربردترین روش‌ها دانست. همان‌طور که مشاهده می‌شود تمام پارامترهای ورودی در سطح اطمینان ۵ درصد فرض صفر یا همان  $H_0$  را تأیید می‌کنند. بنابراین داده‌ها همگن بوده و با اطمینان می‌توان آن‌ها را برای محاسبات و مطالعات بعدی مورد استفاده قرار داد.

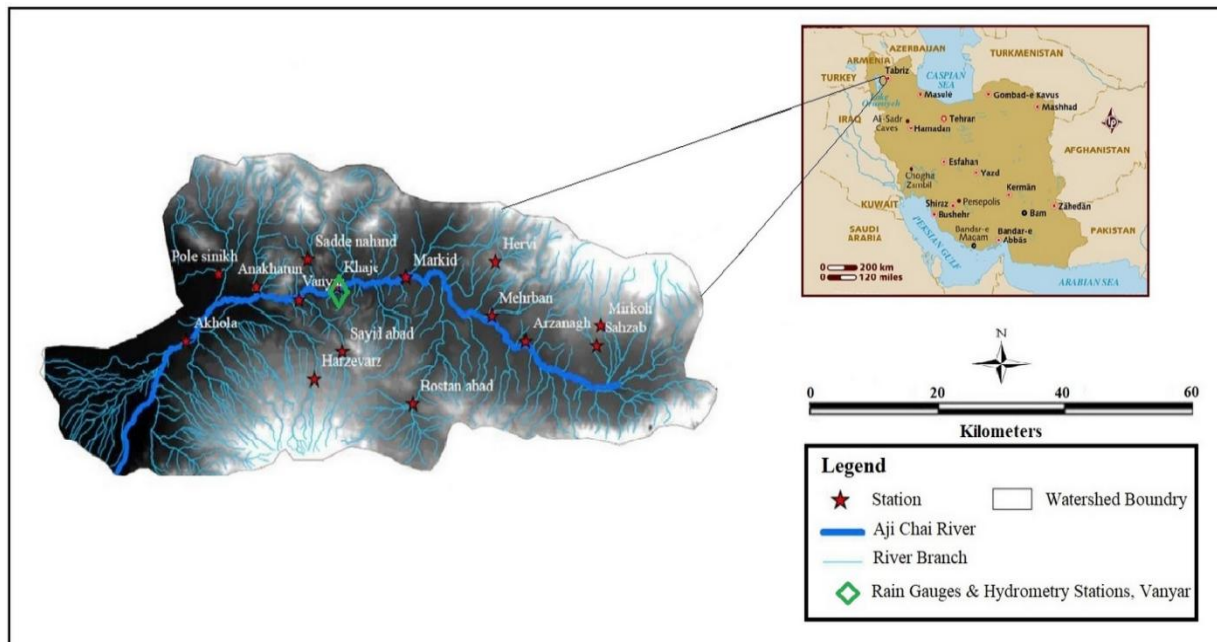


Fig. 1- The location of Vanyar station inside Aji Chai catchment

شکل ۱- نقشه حوضه آبریز آجی چای و موقعیت ایستگاه هیدرومتری ونیار

Table 1- Statistics and SNHT results of daily and monthly rainfall-runoff time series in Vanyar Station

جدول ۱- اطلاعات آماری و نتایج SNHT داده‌های روزانه و ماهانه بارش-رواناب ایستگاه ونیار

Time Scale	Time Series	Statistical Parameters		SNHT	
Daily (1996-2016)	Rainfall (mm)	Min	0	k	376578
		Max	37	t	5785
		Mean	0.66	p-value	0.026
		SD <sup>r</sup>	2.38	$\alpha$	0.05
	Runoff (cms)	Min	0	k	4249443
		Max	190	t	3434
		Mean	8.39	p-value	< 0.001
		SD	16.69	$\alpha$	0.05
Monthly (1977-2016)	Rainfall (mm)	Min	0	k	7198
		Max	137.60	t	177
		Mean	19.01	p-value	0.002
		SD	22.88	$\alpha$	0.05
	Runoff (cms)	Min	0	k	3869
		Max	178.29	t	129
		Mean	15.01	p-value	0.263
		SD	22.80	$\alpha$	0.05

وجود داشته باشد که انجام یک پیش‌پردازش مناسب می‌تواند باعث بهبود کارایی روش‌های داده‌محور گردد. تحلیل موجک یکی از روش‌های پیشنهادی جهت انجام پیش‌پردازش بر روی داده‌ها می‌باشد. به منظور دسته‌بندی داده‌ها به گروه‌های همگن و همچنین بهینه‌سازی ساختار مدل در مرحله سوم، داده‌ها خوشه‌بندی می‌شوند. از مدل درختی M5 که بر اساس روش طبقه‌بندی درختی به ایجاد رابطه بین

## ۲-۲- مدل ترکیبی موجک-درخت تصمیم Wavelet-M5

مدل ترکیبی پیشنهادی Wavelet-M5 متشکل از چهار مرحله می‌باشد. در گام نخست، داده‌های مربوط به فرآیند هیدرولوژیکی بارش-رواناب منطقه مورد مطالعه جمع‌آوری می‌شود. مرحله دوم، پیش‌پردازش داده‌ها می‌باشد؛ چرا که ممکن است به دلیل توزیع‌های گوناگون مکانی و زمانی داده‌ها، تغییراتی در فرآیندهای هیدرولوژیکی

متغیرهای مستقل و وابسته می‌پردازد، استفاده شده است. در آخرین مرحله از مدل پیشنهادی نیز، الگوهای مکرری که در بین داده‌ها وجود دارند، کشف و استخراج شده تا با توجه به آن‌ها در نهایت مدل‌های رگرسیونی درختی برای هر یک از خوشه‌ها ارائه گردند. در ادامه درباره اجزای این مدل ترکیبی، یعنی تبدیل موجک و مدل درختی M5 به تفصیل توضیح داده شده است.

## ۲-۱-۲- تبدیل موجک

تبدیل موجک یکی از تبدیلات ریاضی کارآمد در زمینه پردازش سیگنال می‌باشد. تبدیلات ریاضی برای به دست آوردن اطلاعات اضافی از سیگنال - که از خود سیگنال قابل دست‌یابی نیستند - استفاده می‌شوند. آنالیز موجک همانند آنالیز فوری که یکی از مشهورترین تبدیلات ریاضی است، با بسط تابع‌ها سروکار داشته ولی این بسط بر حسب موجک‌ها صورت می‌گیرد. موجک، تابع مشخص مفروضی با میانگین صفر است و بر خلاف چندجمله‌ای‌های مثلثاتی، در فضا به صورت موضعی بررسی می‌گردند و به این ترتیب ارتباط نزدیک‌تری بین بعضی توابع و ضرایب آن‌ها امکان‌پذیر و پایداری عددی بیشتری در بازسازی و محاسبات فراهم می‌شود. هر کاربردی را که مبتنی بر تبدیل سریع فوری است می‌توان با استفاده از موجک‌ها فرمول‌بندی کرد و اطلاعات فضایی (یا زمانی) موضعی بیشتری به دست آورد (Rezpour, 2012).

تابع موجک، تابعی است که دو ویژگی مهم را دارا باشد: نوسانی بودن و کوتاه مدت بودن. به عبارتی  $\psi(x)$  تابع موجک است اگر و فقط اگر تبدیل فوری آن  $\Psi(\omega)$ ، شرط زیر را ارضا کند (Rezpour, 2012):

$$\int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|}{|\omega|^2} d\omega < +\infty \quad (1)$$

این شرط با عنوان شرط پذیرفتگی موجک  $\Psi(x)$  شناخته می‌شود. رابطه فوق را می‌توان معادل با فرمول زیر دانست که باید ارضا شود (Rezpour, 2012):

$$\Psi(0) = \int_{-\infty}^{+\infty} \Psi(x) dx = 0 \quad (2)$$

این ویژگی تابع با میانگین صفر، چندان محدود کننده نبوده و توابع بسیاری را می‌توان بر اساس آن تابع موجک نامید.  $\Psi(x)$  تابع موجک مادر است که توابع مورد استفاده در تحلیل با دو عمل ریاضی انتقال و مقیاس کردن، در طول سیگنال مورد تحلیل، تغییر اندازه و محل می‌یابند و در نهایت ضرایب موجک در هر نقطه از سیگنال (b) و برای هر مقدار از مقیاس (a) با رابطه زیر قابل محاسبه است (Rezpour, 2012):

$$\Psi_{a,b}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right) \quad (3)$$

عمل مقیاس نمودن، به عنوان یک عمل گر ریاضی، سیگنال را بسط داده و یا فشرده می‌سازد. برای تابع مفروض  $f(t)$ ، اگر  $s < 1$  باشد،  $f(st)$  حالت بسط داده شده  $f(t)$  و اگر  $s > 1$  باشد حالت فشرده شده تابع  $f(t)$  می‌باشد. همانطور که در رابطه ۳ می‌بینیم، در تعریف تبدیل موجک، ترم مقیاس a در مخرج آمده است و لذا عکس آن چه گفته شد، اگر  $a < 1$  باشد، سیگنال فشرده شده و اگر  $a > 1$  باشد سیگنال بسط داده می‌شود. همچنین در رابطه فوق پارامتر b، انتقال یا به زبان ساده‌تر تأخر و تقدم را روی یک تابع مدل می‌کند. در نهایت می‌توان حالت پیوسته تبدیل موجک (که به اختصار CWT<sup>۵</sup> نامیده می‌شود) را به شکل زیر نوشت (Rezpour, 2012):

$$\begin{aligned} \text{CWT}(a, b) &= Wf(a, b) \\ &= \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \Psi\left(\frac{x-b}{a}\right) dx \\ &= \int_{-\infty}^{+\infty} f(x) \Psi_{a,b}(x) dx \end{aligned} \quad (4)$$

## ۲-۲-۲- مدل درختی M5

درخت تصمیم در داده‌کاوی مدلی است که جهت نمایش طبقه‌کننده‌ها و رگرسیون‌ها استفاده می‌شود. همان طور که از نام آن مشخص است، این درخت از تعدادی گره و شاخه تشکیل شده است. در درخت تصمیمی که عمل طبقه‌بندی را انجام می‌دهد، برگ‌ها بیانگر کلاس‌ها هستند. در هر یک از گره‌های دیگر (گره‌های غیربرگ) با توجه به یک یا چند صفت خاصه تصمیم‌گیری صورت می‌گیرد. درخت تصمیم به دلیل سادگی و قابل فهم بودن، تکنیک محبوبی در داده‌کاوی محسوب می‌شود. به عبارت دیگر درخت تصمیم خود به تنهایی همه مطالب را توصیف می‌کند و نیاز به فرد خبره‌ای نیست تا خروجی را تفسیر نماید. در واقع این یک روش گرافیکی است و بدین دلیل تفسیر آن شاید ساده‌تر از تکنیک‌های دیگر طبقه‌بندی باشد. بدیهی است داشتن تعداد گره‌های زیاد در درخت می‌تواند نمایش گرافیکی درخت تصمیم را با مشکل روبرو سازد (Sattari et al., 2013; Nourani and Molajou, 2017).

اولین مرحله برای ایجاد یک مدل درختی، استفاده از یک معیار انشعاب است که توسط یکی از متغیرهای پیش‌بینی کننده انجام می‌پذیرد. معیار انشعاب برای الگوریتم M5 بر اساس عملکرد انحراف استاندارد مقادیر هر کلاس و یا طبقه بوده که در هر گره بدست می‌آید. این روش اساس روش‌های طبقه‌بندی است که آنتروپی نامیده می‌شود (Nourani and Molajou, 2017). آنتروپی می‌تواند به عنوان معیار میزان آشفتگی یک سیستم تفسیر شود. معیار انشعاب بیانگر میزان خطا در آن گره می‌باشد و مدل حداقل خطای مورد انتظار را به عنوان

### ۳- نتایج و بحث

همانگونه که مشهود است عوامل گوناگونی نظیر بارش، تبخیر، پوشش گیاهی و غیره در پدیده رواناب دخیل می‌باشند و انتخاب عوامل تأثیرگذار به عنوان متغیرهای ورودی در پیش‌بینی آن امری حائز اهمیت است. مطالعات پیشین نشان داده است که رواناب نیز مانند پدیده‌های دیگر همانند رسوب، به عنوان پدیده‌ای مارکوف شناخته می‌شود (مقدار فعلی آن بیشترین ارتباط را با مقادیر آن در زمان‌های پیشین دارد). از این رو مقدار رواناب در زمان حال تابعی از مقادیر بارش و رواناب در زمان‌های پیشین خواهد بود. البته شایان ذکر است که اثرات سایر بارش‌های زمان گذشته در رواناب‌های پیشین لحاظ شده است. از این رو رواناب را می‌توان به صورت تابع زیر تعریف نمود (Nourani, 2017):

$$Q_t = f(I_{t-1}, Q_{t-1}, Q_{t-2}, Q_{t-3}, \dots, Q_{t-n}) \quad (8)$$

که در آن،  $I_{t-1}$  بارش در یک گام زمانی قبل و  $Q_{t-n}$  مقادیر رواناب در گام‌های پیشین می‌باشند. شبکه عصبی استفاده شده در مدل‌های ANN/WANN به منظور مدل‌سازی بارش-رواناب حوضه، پرسپترون پیش تغذیه شونده سه لایه (لایه ورودی، یک لایه پنهان و لایه خروجی) می‌باشد که این نوع از مدل‌های شبکه عصبی با الگوریتم انتشار برگشتی، به طور گسترده در مدل‌سازی‌های هیدرولوژیکی استفاده شده است. شکل بهینه شبکه‌های عصبی مصنوعی به صورت آزمون و خطا به دست می‌آید. هدف از این آزمون و خطا، یافتن تعداد نرون‌های لایه پنهان و تعداد تکرار الگوریتم می‌باشد تا به واسطه آن‌ها مدل تعریف گردد. لازم به ذکر است که تعداد تکرارهای آموزشی کم می‌تواند منجر به آموزش ناقص و تعداد تکرارهای زیاد منجر به حفظ یا از برکردن توسط شبکه در مرحله آموزش گردد. لذا بایستی مقدار بهینه‌ای برای تعداد تکرارها در نظر گرفت تا کیفیت مدل برای هر دو مرحله آموزش و آزمایش قابل قبول باشد که با توجه به مطالعات پیشین این تعداد در بین ۱۵۰ تا ۲۰۰ در نظر گرفته می‌شود. به جهت قدرت همگرایی زیاد، برای آموزش شبکه‌های عصبی از الگوریتم لوبنبرگ-مارکوارت استفاده شد. فرآیند آموزش شبکه زمانی متوقف می‌شود که میزان خطا در بین داده‌های آزمایش، شروع به افزایش می‌کند. در این پژوهش از تابع محرک تانژانت سیگموئید، به عنوان هسته غیرخطی شبکه‌های عصبی بهره گرفته شده است (Tajbakhsh, 2017).

مطابق انتظار مدل ANN ساده عملکرد مطلوبی در پیش‌بینی رواناب یک روز جلوتر در حوضه آبی‌چای نداشت. این عملکرد نه چندان مطلوب در پیش‌بینی رواناب یک گام جلوتر در مقیاس ماهانه نیز ضعیف‌تر گشت (جدول ۲). شاید بتوان گفت که مهم‌ترین دلیل این امر عدم توانایی مدل ANN ساده در مواجهه با ناپایداری سری‌های

نتیجه‌ی آزمایش هر صفت در آن گره محاسبه می‌کند. خطای مدل عموماً با اندازه‌گیری دقت پیش‌بینی مقادیر هدف موارد دیده نشده سنجش می‌شود. فرمول محاسبه‌ی کاهش انحراف استاندارد ( $SDR^e$ ) به صورت روابط ذیل می‌باشد (Sattari et al., 2013):

$$SDR = Sd(T_i) - \sum_{i=1}^N \frac{|T_i|}{|T|} Sd(T_i) \quad (5)$$

در این روابط،  $T$  مجموعه‌ای از نمونه‌هاست که به هر گره وارد می‌شود،  $T_i$  نشان دهنده زیر مجموعه‌ای از نمونه‌هاست که  $i$ امین نتیجه‌ی تست پتانسیلی را دارند،  $Sd$  بیانگر انحراف معیار،  $y_i$  مقدار عددی ویژگی هدف نمونه  $i$  و  $N$  شماره‌ی داده‌ها را نشان می‌دهد.

### ۳-۲- مدل ترکیبی موجک-شبکه عصبی WANN

مدل موجک-شبکه عصبی از یک ساختار سه لایه تشکیل یافته است. لایه اول شامل نرون‌های موجکی می‌باشد که ورودی آن‌ها زیرسری‌هایی است که با استفاده از تبدیل موجک بر روی سری‌های زمانی بارش و رواناب حاصل می‌گردد. در مدل موجک-شبکه عصبی برای انجام محاسبات از شبکه عصبی جهت یافتن ضرایب وزن بارش در ساختار شبکه استفاده می‌گردد. در این مدل نخست سری‌های زمانی بارش و رواناب به زیرسری‌هایی با مقیاس‌های متفاوت تجزیه می‌شوند. به عنوان نمونه می‌توان سری زمانی را به یک مقیاس بلند مدت و چند مقیاس کوتاه مدت (برای رهگیری خواص گذرا و نوسانات کوتاه مدت سری) تجزیه نمود. در این صورت زیرسری‌های زمانی که تحت عنوان  $a(t)$  (همانند  $I_a(t)$  و  $Q_a(t)$ ) نام‌گذاری می‌شوند، معرف زیرسری تقریبی (مقیاس بلند مدت)، و برای زیرسری‌های زمانی که تحت عنوان  $d_i(t)$  و  $d_j(t)$  با اندیس‌های  $i$  و  $j$  (همانند  $I_{d_i}(t)$  و  $Q_{d_j}(t)$ ) نام‌گذاری می‌شوند، معرف زیرسری جزئی (مقیاس کوتاه مدت) هستند. پارامترهای  $i$  و  $j$  نیز به ترتیب مرتبه تجزیه سری بارش ( $I(t)$ ) و سری رواناب ( $Q(t)$ ) می‌باشند (Nourani et al., 2014).

### ۴-۲- معیارهای ارزیابی

جهت ارزیابی نتایج از معیارهای ارزیابی ضریب نش-سانتکلیف ( $NSE^y$ ) و ریشه میانگین مربعات خطا ( $RMSE^A$ ) استفاده شده است، که در روابط یاد شده  $N$  تعداد داده‌های مشاهداتی،  $S_{obs}$  داده‌های مشاهداتی،  $S_{pre}$  مقادیر محاسباتی و  $\bar{S}$  میانگین داده‌های مشاهداتی هستند (Nourani, 2017; Sharghi et al., 2018).

$$NSE = 1 - \frac{\sum_{i=1}^N (S_{pre} - S_{obs})^2}{\sum_{i=1}^N (S_{obs} - \bar{S})^2} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (S_{pre} - S_{obs})^2}{N}} \quad (7)$$

زمانی ورودی باشد که با توجه به ماهیت نالیستا بودن پدیده بارش-رواناب اعمال یک پیش‌پردازش مناسب در بهبود کارایی مدل مؤثر می‌باشد (جدول ۳). نکته دیگر که می‌توان به آن اشاره داشت تفاوت دقت مدل در دو مقیاس روزانه و ماهانه می‌باشد. واضح است که در مقیاس روزانه شبکه عصبی با تعداد نمونه ورودی به مراتب بیشتری نسبت به مقیاس ماهانه سر و کار دارد. همین امر سبب می‌شود تا شبکه آموزش بهتری در کالیبراسیون داشته باشد و دقت مدل در مقیاس روزانه نسبت به مقیاس ماهانه افزایش یابد. از این رو نقص دیگری که می‌توان به مدل ANN ساده وارد دانست، وابستگی آن به تعداد داده‌های ورودی می‌باشد که در صورت کم بودن تعداد آن، آموزش شبکه را تحت تأثیر قرار می‌دهد (مسئله‌ای که در مدل‌سازی پدیده‌هایی همانند رواناب-رسوب که تعداد داده‌ها به خصوص در ایران که ثبت آن از دقت کافی برخوردار نیست، باید لحاظ گردد). مسئله دیگر تفاوت ضریب تبیین در دو مرحله آموزش و صحت‌سنجی است که این اختلاف در مقیاس ماهانه بیشتر نمود پیدا می‌کند. واضح است که در مرحله آموزش، تعداد داده‌ها از مرحله صحت‌سنجی بیشتر می‌باشد که سبب اختلاف NSE و به نحوی زیر سؤال رفتن عملکرد مدل می‌گردد به طوری که همین تفاوت نشان‌گر over-fitting و عدم کارایی مدل است.

با برشمردن نقایص فوق، لزوم اعمال یک پیش‌پردازش مناسب (تبدیل موجک) جهت رفع آن و بهبود عملکرد مدل ANN ساده ضروری دانسته شد. در واقع تبدیل موجک با تجزیه نمودن سری‌های زمانی اصلی به چندین زیرسری (در این تحقیق تعداد زیرسری‌های تجزیه شده پنج عدد است که شامل یک زیرسری اصلی و چهار زیرسری جزئی می‌باشد) با اعمال میانگین غیرخطی اقدام به حذف روند موجود در سری‌های زمانی برای غلبه بر نالیستایی می‌پردازد. به عبارت خیلی ساده‌تر تبدیل موجک با بهره بردن از اصل جمع آثار قوا سری زمانی پیچیده را به چند زیرسری ساده تجزیه می‌نماید که برآیند همگی این زیرسری‌ها، سری زمانی اصلی می‌شود (Tajbakhsh, 2017). متعاقباً با اعمال تبدیل موجک، افزایش دقت مدل و بهبود کارایی آن دور از انتظار نیست که با توجه به جدول ۳ شاهد آن هستیم ( $(NSE_{WANN})_{Train or Verify} > (NSE_{ANN})_{Train or Verify}$ ). از این رو مدل هیبریدی موجک-شبکه عصبی به مراتب از مقبولیت بیشتری در مطالعه فرآیند بارش-رواناب برخوردار است. در بررسی پدیده بارش-رواناب در دو مقیاس روزانه و ماهانه شایان ذکر است که به تفاوت ماهیت داده‌ها نیز اشاره نمود. در مقیاس روزانه علاوه بر زیاد بودن تعداد نمونه‌های داده‌های ورودی، داده‌ها ممکن است دارای شوک باشند (یعنی مقادیر رواناب در اثر بارش شدید به طور ناگهانی افزایش یابد). در مقیاس ماهانه علاوه بر تعداد کم نمونه‌ها به نسبت مقیاس

روزانه، دارای ماهیت فصلی می‌باشند (مقدار رواناب در یک ماه خاص بیشترین ارتباط را مقدار رواناب همان ماه در سال قبل دارد). از این رو مدل WANN به واسطه بهره‌مندی از تبدیل موجک و حذف روند موجود، هم بر شوک و هم بر فصلی بودن غلبه می‌نماید؛ از این رو در هر دو مقیاس عملکرد قابل قبولی دارد. نکته حائز اهمیت افزایش تعداد داده‌های ورودی با اعمال تبدیل موجک است. علی‌رغم افزایش دقت مدل حجم محاسبات به طور چشم‌گیری نیز افزایش یافته که بالتبع آن زمان انجام محاسبات به طور فزاینده‌ای افزایش می‌یابد.

تاکنون پدیده بارش-رواناب که پدیده‌ای استوکستیک، غیر خطی و نالیستا می‌باشد، با مدل‌هایی که خود ماهیت غیرخطی داشته، شبیه‌سازی شده‌اند. کاری که مدل درختی M5 انجام می‌دهد، تقسیم این مدل غیرخطی به کلاس‌هایی است که قابل ارائه با یک رگرسیون خطی ساده می‌باشند. در واقع برهم‌نهی این مدل‌های خطی ساده همان رگرسیون غیرخطی ارائه شده توسط مدل ANN می‌باشد (مدل‌های چندخطی دسته‌ای از مدل‌ها هستند که مابین مدل‌های خطی و مدل‌های غیرخطی قرار دارند). از این رو است که دقت مدل درختی M5 تا حدودی شبیه به مدل ANN ساده می‌باشد. نکته مهم دیگر، نزدیک بودن ضریب تبیین در دو مرحله آموزش و صحت‌سنجی می‌باشد. در واقع در کنار ویژگی‌های مثبتی که برای مدل درختی M5 شمرده شد، این مسئله بیشتر جلوه می‌کند که مدل چند خطی مطرحه به تعداد داده وابسته نیست و برای فرآیندهایی که داده‌های زیادی در اختیار نیست، مناسب است. اما در کنار همه جوانب مثبت شمرده شده، مهم‌ترین ملاک ارزیابی یک مدل کارایی و دقت آن می‌باشد. با دقت در جدول نتایج این مسئله آشکار می‌گردد که کارایی مدل M5 تا حدودی شبیه به مدل ANN ساده می‌باشد، از این رو ناخواسته این سؤال مطرح می‌گردد که آیا نالیستایی موجود در سری‌های زمانی ورودی بر عملکرد مدل درختی M5 تأثیرگذار خواهد بود و آیا مدل درختی M5 به تنهایی نیاز به پیش‌پردازش داده‌های سری زمانی را برطرف می‌نماید؟

با توجه به ماهیت استوکستیک و نالیستایی فرآیند بارش-رواناب، همان گونه که مدل ANN ساده با مشکل مواجه شد، مدل M5 نیز عملکرد مطلوبی نداشت. در واقع این نکته به صورت غیر مستقیم تأثیر مثبت و غیر قابل انکار پیش‌پردازش داده‌های سری زمانی خام را بر عملکرد مدل -چه خطی و چه غیرخطی- نشان می‌دهد. لذا با اعمال تبدیل موجک، افزایش دقت مدل و بهبود کارایی آن حاصل می‌شود که با توجه به جدول ۲ این بهبود دیده می‌شود.

**Table 2- Results of different modeling for Vanyar Station at both daily and monthly scales**

جدول ۲- نتایج حاصله از مدل‌های محاسباتی در مقیاس‌های روزانه و ماهانه برای ایستگاه ونیار

Time Scale	Inputs	Output	Model	Hn*	Epoch	NSE		RMSE*	
						Train	Verify	Train	Verify
Daily	I <sub>t</sub> , Q <sub>t</sub>	Q <sub>t+1</sub>	ANN	3	50	0.72	0.68	0.02	0.02
			WANN	4	70	0.97	0.92	0.01	0.01
			M5	-	-	0.70	0.66	0.02	0.04
			WT-M5*	-	-	0.97	0.92	0.02	0.03
Monthly			ANN	7	20	0.59	0.51	0.06	0.05
			WANN	5	10	0.98	0.82	0.01	0.04
			M5	-	-	0.55	0.54	0.11	0.14
			WT-M5	-	-	0.93	0.92	0.03	0.07

\*RMSE is normalized, \*Hn: Hidden neuron, \*WT-M5: Wavelet-M5

تا رفتار آن به رفتار خطی نزدیک گردد. از این رو این امکان میسر خواهد بود که به جای بهره‌مندی از مدل‌های غیرخطی، رفتار آن را با مدل‌های خطی شبیه‌سازی نمود. به همین دلیل در بررسی حوضه آرام نتایج حاصله از مدل خطی بسیار نزدیک به مدل غیرخطی خواهد بود. با توجه به جدول ۳ مشهود است که عملکرد مدل هیبریدی WT-M5 در مرحله صحت‌سنجی، در مقایسه با مدل‌های ANN و M5 به ترتیب ۳۵ و ۳۹ درصد در مقیاس روزانه بهبود یافته است. همین مقادیر در مقیاس ماهانه به ترتیب ۸۰ و ۷۰ درصد می‌باشد که بیانگر کارایی مناسب این مدل می‌باشد. همچنین با دقت در جدول فوق مشاهده می‌شود که تأثیر تبدیل موجک بر بهبود عملکرد مدل ANN ساده در مقیاس روزانه برابر ۳۴٪ و در مقیاس ماهانه برابر ۶۶٪ بوده است. همچنین تأثیر تبدیل موجک بر بهبود عملکرد مدل M5 درختی برای حوضه مذکور در مقیاس روزانه برابر ۳۸٪ و در مقیاس ماهانه برابر ۶۹٪ بوده است.

در ادامه گراف مربوط به سری‌های زمانی محاسباتی از طریق مدل‌های M5 و Wavelet-M5 و سری زمانی مشاهداتی مربوط به مقیاس روزانه و ماهانه جهت درک شهودی توضیحات بیان شده و نیز گراف‌های پراکنده‌گی رواناب مشاهداتی و محاسباتی در هر دو مقیاس مذکور در شکل ۲ ارائه گردیده است.

از این رو مدل هیبریدی Wavelet-M5 به مراتب عملکرد مطلوب‌تری نسبت به مدل M5 دارد. پس یکی از بارزترین نتایجی که می‌توان با توجه به جدول ۳ استنتاج نمود، عدم پیش‌پردازش داده‌ها توسط مدل درختی M5 می‌باشد؛ از این رو نمی‌توان مدل‌های مبتنی بر درخت را به تنهایی به عنوان ابزاری جهت پیش‌پردازش داده‌ها در نظر گرفت. نکته دیگر شبیه بودن نتایج به دست آمده از مدل پیشنهادی با مدل WANN می‌باشد. همین امر سبب می‌گردد تا کارایی مدل هیبریدی Wavelet-M5 مورد قبول واقع گردد. البته مسأله دیگر که می‌توان استنباط نمود توانایی این مدل همانند مدل WANN در غلبه نمودن بر شوک و فصلی بودن به علت برخورداری از تبدیل موجک و حذف روندها می‌باشد. به دلیل این که پایه و اساس این مدل پیشنهادی مدل درختی M5 می‌باشد، تمامی ویژگی‌های مثبتی که برای مدل درختی M5 برشمرده شد، به قوت خود برای مدل Wavelet-M5 برقرار است. همین ویژگی‌ها باعث می‌شود تا به آسانی بتوان تعداد پارامترهای ورودی به مدل را بدون آن که خطای مدل تغییر یافته و زیاد شود، افزایش داد؛ چرا که بر خلاف مدل غیرخطی ANN/WANN هرچقدر ورودی‌ها افزایش یابد آموزش شبکه دچار مشکل نمی‌شود.

نکته‌ای که از آن نباید غافل شد، رفتار حوضه و تأثیر آن بر عملکرد مدل‌ها است. اگر دقیق‌تر به حوضه آبی‌چای توجه شود، این حوضه کاملاً آرام و دارای الگوی منظم بارش است. همین امر سبب می‌شود

**Table 3- The performance evaluation of the hybrid models compared to ANN and M5 model tree**

جدول ۳- ارزیابی عملکرد مدل‌های هیبریدی در مقایسه با مدل‌های ANN و M5

Time Scale	Daily		Monthly	
	Train	Verify	Train	Verification
Model				
WANN vs ANN	34%	35%	66%	60%
WT-M5* vs ANN	34%	35%	57%	80%
WT-M5 vs M5	38%	39%	69%	70%

\*WT-M5: Wavelet-M5



#### ۴- نتیجه گیری

ماهانه برابر ۶۹٪ بوده است. به طور کلی می‌توان نتیجه گرفت که عملکرد مدل هیبریدی پیشنهادی مطلوب بوده و با کیفیت مدل هیبریدی WANN که به عنوان مدلی مطلوب شناخته شده است، برابری می‌نماید. پیشنهاد می‌گردد از مدل Wavelet-M5 در مطالعه سایر فرآیندهای هیدرولوژیکی همانند فرآیند رواناب-رسوب که داده‌های آن به مراتب کمتر از فرآیند بارش-رواناب است، استفاده کرده و عملکرد آن را بررسی نمود. همچنین لازم به ذکر است زمانی که مدل با ورودی‌هایی بیشتر از دو سری زمانی مواجه می‌شود و با انجام تبدیلات موجکی تعداد ورودی‌ها به طور قابل ملاحظه‌ای افزایش می‌یابد که یک محدودیت به حساب می‌آید.

از این رو پیشنهاد می‌گردد که در مطالعات آتی تأثیر انتخاب زیرسری‌های غالب به عنوان ورودی‌های اصلی مدل، روی عملکرد و کارایی مدل بررسی گردد.

در این پژوهش تلاش شد تا ضمن معرفی مدل جدید Wavelet-M5 و بررسی کارایی مدل‌های چندخطی، عملکرد آن بر روی فرآیند بارش-رواناب ایستگاه ونبار مطالعه شود و نتایج با سایر مدل‌ها مقایسه گردد. درک صحیحی از رفتار حوضه می‌تواند نقش مؤثری در انتخاب مدل و همچنین صرفه‌جویی در زمان مربوط به امر شبیه‌سازی ایفا کند. البته باید توجه داشت که تأثیر پیش‌پردازش داده‌ها بر عملکرد هر دو مدل چندخطی و غیرخطی در غلبه بر ماهیت شوک و فصلی بودن سری‌های زمانی بارش-رواناب کاملاً مشهود و غیر قابل انکار است. تأثیر تبدیل موجک بر بهبود عملکرد مدل ANN ساده برای حوضه آجی‌چای در مقیاس روزانه برابر ۳۴٪ و در مقیاس ماهانه برابر ۶۶٪ بوده است. همچنین تأثیر تبدیل موجک بر بهبود عملکرد مدل M5 درختی برای حوضه مذکور در مقیاس روزانه برابر ۳۸٪ و در مقیاس

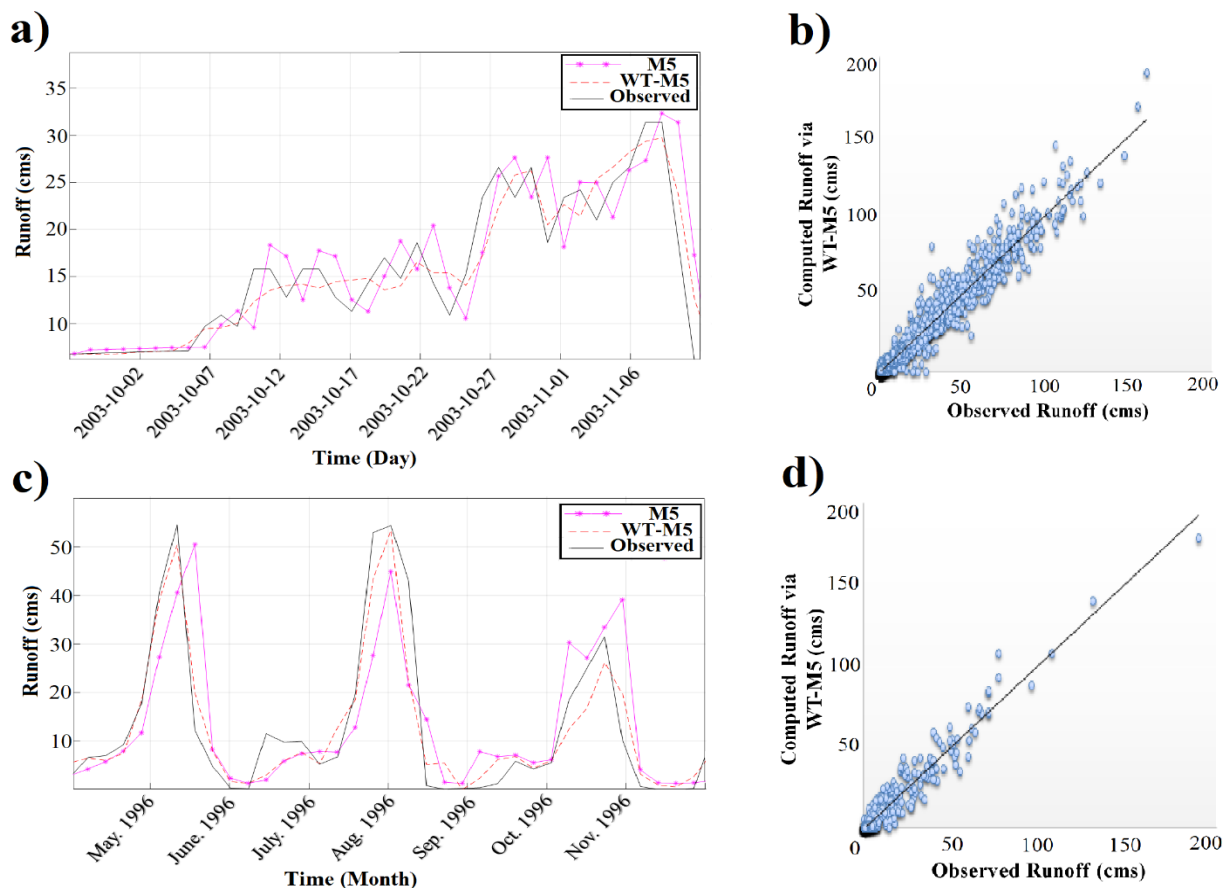


Fig. 2- Observed versus (detailed) computed runoff and scatter plot in Vanyar Station for a, b) daily and c, d) monthly time scales

شکل ۲- سری زمانی رواناب مشاهداتی و محاسباتی (جزیی) و گراف پراکندگی ایستگاه ونبار در مقیاس الف و ب) روزانه پ و ت) ماهانه

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

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

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

Nourani V, Sattari M T, Molajou A (2017) Threshold-based hybrid data mining method for long-term maximum precipitation forecasting. *Water Resources Management* 31(9):2645-2658

Rezapour Khanghah T (2012) Entropy based rainfall-runoff feature extraction method employed in wavelet-ANN modeling. M.Sc. Thesis, Faculty of Civil Engineering, University of Tabriz (In Persian)

Sharghi E, Nourani V, Najafi H, Molajou A (2018) Emotional ANN (EANN) and Wavelet-ANN (WANN) approaches for markovian and seasonal based modeling of rainfall-runoff process. *Water Resources Management* 32(10):3441-3456

Sattari MT, Nahrein F, Azimi V (2013) M5 model trees and neural networks based prediction of daily ETO (case study: Bonab station). *Iranian Journal of Irrigation and Drainage* 7(1):104-113 (In Persian)

Solomatine DP, Dulal KN (2003) Model trees as an alternative to neural networks in rainfall-runoff modelling. *Hydrological Sciences Journal* 48(3):399-411

Solomatine DP, Xue Y (2004) M5 model trees and neural networks: application to flood forecasting in the upper reach of the Huai River in China. *Journal of Hydrologic Engineering* 9(6):491-501

Vakili Sh (2016) Forecasting of monthly precipitation using M5 model tree and classic statistical methods (Case study: Oroumieh synoptic station). *Iran-Water Resources Research* 13(4):179-183

Wang WC, Xu DM, Chau KW, Chen S (2013) Improved annual rainfall-runoff forecasting using PSO-SVM model based on EEMD. *Journal of Hydroinformatics* 15(4):1377-1390

1. Artificial Neural Network
2. Wavelet-Artificial Neural Network (Wavelet-ANN)
3. Standard Deviation
4. Continuous Wavelet Transform
5. Standard Normal Homogeneity Test
6. Standard Deviation Reduction
7. Nash-Sutcliffe Model Efficiency Coefficient
8. Root Mean Square Error

## ۵- مراجع

Barzegar R, Asghari Moghaddam A, Tziritis E (2016) Assessing the hydrogeochemistry and water quality of the Aji-Chay River, northwest of Iran. *Environmental Earth Sciences* 75(23):1486

Danandeh Mehr A, Kahya E, Bagheri F, Deliktas E (2014) Successive-station monthly streamflow prediction using neuro-wavelet technique. *Earth Science Informatics* 7(4):217-229

Danandeh Mehr A, Nourani V, Hrnjica B, Molajou A (2017) A binary genetic programming model for teleconnection identification between global sea surface temperature and local maximum monthly rainfall events. *Journal of Hydrology* 555:397-406

Davanlou Tajbakhsh A (2017) Hybrid data mining models for hydrological forecasts. M.Sc. Thesis, Faculty of Civil Engineering, University of Tabriz (In Persian)

Liu Z, Todini E (2002) Towards a comprehensive physically-based rainfall-runoff model. *Hydrology and Earth System Sciences Discussions* 6(5):859-881

Parisuj P, Goharnejad H, Moazami S (2017) Rainfall-runoff hydrologic simulation using adjusted satellite rainfall algorithms, a case study: Voshmgir Dam Basin, Golestan. *Iran-Water Resources Research* 14(3):140-159

Nayak PC, Sudheer KP, Rangan DM, Ramasastri KS (2004) A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology* 291(1-2):52-66

Nourani V (2017) An emotional ANN (EANN) approach to modeling rainfall-runoff process. *Journal of Hydrology* 544:267-277

Nourani V, Molajou A (2017) Application of a hybrid association rules/decision tree model for drought monitoring. *Global and Planetary Change* 159:37-45