



پیش‌بینی رواناب دشت اردبیل با رویکردهای پیش‌پردازش زمانی موجکی

فرناز دانشور وثوقی^{۱*}، رسول صمدزاده^۲

۱- استادیار گروه مهندسی عمران، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران

۲- دانشیار گروه جغرافیا، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران

تأیید نهایی مقاله: ۱۴۰۰/۰۲/۱۵

وصول مقاله: ۱۳۹۹/۱۰/۲۷

چکیده

مدل‌سازی صحیح فرآیند بارش-رواناب به دلیل گستردگی عوامل مؤثر بر بارش و رواناب یکی از پیچیدگی‌های علم هیدرولوژی است. هدف از این پژوهش استفاده از روش‌های پیش‌پردازش زمانی از جمله رفع نویز موجکی و تبدیل موجک برای پیش‌بینی سری‌های زمانی ماهانه رواناب در دشت اردبیل می‌باشد. شبیه‌سازی بارش - رواناب با استفاده از مدل جعبه‌ی سیاه شبکه‌ی عصبی مصنوعی برای سه ترکیب داده‌های بارش و رواناب دشت اردبیل انجام گردید. ترکیب اول و دوم داده‌ها از داده‌های خود ایستگاه در زمان‌های گذشته استفاده می‌کند و ترکیب سوم داده‌ها از داده‌های ایستگاه‌های بالادست (ایستگاه‌های گیلانده و کوزه تپراقی) برای پیش‌بینی رواناب خروجی دشت (ایستگاه سامیان) استفاده می‌کند. نتایج نشان داد که اعمال روش‌های پیش‌پردازش زمانی رفع نویز موجکی و استفاده از تبدیل موجک در شبیه‌سازی بارش-رواناب با مدل شبکه عصبی مصنوعی به ترتیب به‌طور متوسط باعث بهبود ۴ و ۳۹ درصدی در مرحله‌ی آزمایش مدل شده است.

کلمات کلیدی: مدل‌سازی رواناب، تبدیل موجک، رفع نویز موجکی، شبکه‌ی عصبی مصنوعی، دشت اردبیل

۱- مقدمه

از مهم‌ترین و تأثیرگذارترین فرایندهای هیدرولوژیکی، فرآیند پیش‌بینی بارش- رواناب است. این شبیه‌سازی می‌تواند شاخص‌های مناسبی در تخمین شرایط آبی جهت بهره‌گیری بهتر از منابع آب با استفاده از مدیریت صحیح منابع آب ارائه کند. مدل‌های متعددی از جمله مدل‌های مفهومی و مدل‌های عددی مانند مدل‌های جعبه سیاه در شبیه‌سازی پدیده‌های هیدرولوژیکی پیچیده از جمله بارش- رواناب به‌طور گسترده‌ای مورد استفاده قرار می‌گیرند. از معروف‌ترین مدل‌های جعبه می‌توان به شبکه‌عصبی اشاره کرد که دارای کاربردهای متعددی در پیش‌بینی فرایندهای آب‌شناسی است. این مدل توانایی‌های زیادی را در شبیه‌سازی گروه‌های زمانی غیرخطی و ناپایدار (نورانی و همکاران^۱، ۲۰۱۱: ۴۱).

مدل ANN با توجه به خاصیت جعبه سیاه بودن نیازی به دانش قبلی در مورد ماهیت فیزیکی فرآیند نمی‌باشد و به دلیل اعمال یک صافی غیرخطی به نام تابع محرک بر روی نرون‌ها، دارای ماهیت غیرخطی بوده و قابلیت اعمال ورودی‌های چندمتغیره را با ویژگی‌های مختلف دارا می‌باشند (نورانی و همکاران، ۲۰۱۱: ۴۱). مقالات متعددی به کاربردهای موفق ANN در شبیه‌سازی فرآیند بارش- رواناب اشاره کرده‌اند: (هسیو و همکاران^۲ (۱۹۹۵: ۲۵۱۷)؛ انجمن مهندسان عمران آمریکا^۳، (۲۰۰۰: ۲۷)؛ انتر و همکاران^۴، (۲۰۰۶: ۱۲۰۱)؛ نگی و همکاران^۵ (۲۰۲۱)؛ زکیزاده و همکاران^۶ (۲۰۲۰: ۱۰۲۸۹۹)؛ باباعلی و دهقان (۱۳۹۶: ۱۴۹)؛ جهانبخش اصل و همکاران (۱۳۹۸: ۱۰۹)؛ کرمی جوزانی و همکاران (۱۳۹۸: ۱).

اغلب سری‌های زمانی که به عنوان داده‌های خام در مدل‌سازی‌های هیدرولوژیکی استفاده می‌شوند غیرایستا و دارای تمایل بوده و یا نوسانات فصلی را با خود به همراه دارند. هر چند شبکه‌های عصبی در مدل‌سازی‌های هیدرولوژیکی انعطاف مناسبی دارند اما در مواجهه با داده‌های غیر ایستا دچار مشکل می‌شوند. برای کاهش اثر این عوامل در مدل‌سازی‌ها از پیش پردازش زمانی داده‌ها استفاده می‌شود. آنالیز موجک به عنوان یک تبدیل ریاضی، نوسانات کوتاه‌مدت و بلندمدت سری زمانی را تفکیک می‌کند (نورانی و همکاران، ۲۰۰۹: ۴۶۶). در سال‌های اخیر، ترکیب تبدیل موجک و شبکه عصبی مصنوعی با توجه به توانایی‌اش در زمینه پیش‌بینی و شبیه‌سازی، در علوم مختلف محیطی به وسیله‌ی محققین و تصمیم‌گیرندگان مورد استفاده قرار گرفته است. با توجه به بررسی‌های انجام شده در زمینه‌ی مدل‌سازی بارش- رواناب می‌توان به مطالعات کاناس و همکاران^۷

1. Nourani et al.
2. Hsu et al.
3. ASCE
4. Antar et al.

5. Negi et al.
6. Zakizadeh et al.
7. Cannas et al.

(۲۰۰۶: ۱۱۶۴)؛ نورانی و همکاران^۱ (۲۰۰۹: ۲۸۷۷)؛ (۲۰۱۱: ۴۱)؛ (۲۰۱۲: ۷۲۴)؛ (۲۰۱۳: ۲۲۸)؛ هسیو و لی^۲ (۲۰۱۰: ۱۹۰)؛ وانگ و همکاران^۳ (۲۰۱۱: ۲۷۳۴)؛ ماهاسوارا و خوسرا^۴ (۲۰۱۲: ۳۲۰)؛ نایاک و همکاران^۵ (۲۰۱۳: ۵۷)؛ شعیب و همکاران^۶ (۲۰۱۴: ۴۷)؛ بدرزاده و همکاران^۷ (۲۰۱۵: ۱۶۳۳)؛ شعیب و همکاران (۲۰۱۶: ۲۱۱)؛ اویسال و همکاران^۸ (۲۰۱۶: ۶۳۰)؛ علیزاده و همکاران^۹ (۲۰۱۷: ۵۸۸)؛ تیواری و همکاران^{۱۰} (۲۰۱۷: ۵۱) اشاره کرد.

داده سری‌های زمانی هیدرولوژیکی عموماً دارای خطاهای اندازه‌گیری و سامانه‌ای هستند که به وسیله‌ی عوامل زیادی نفوذ پیدا کرده‌اند (قو و همکاران^{۱۱}، ۲۰۱۰: ۳۷۶۳). خطای سامانه‌ای بازخور اختلالات تصادفی کوچک در فرایندهای زودگذر است که مستقیماً در تکامل سامانه در مقیاس زمانی تأثیر می‌گذارد و خطای اندازه‌گیری خطایی است که سبب آن سنجش است. وقتی که داده سری‌های زمانی هیدرولوژیکی خطادار برای تحلیل، محاسبه و پیش‌بینی بکار برده می‌شود قواعد مختلف این سری‌های زمانی شاید به‌طور کامل بازتاب نشود و حتی نتایج اشتباه دریافت شود. از آنجاکه مدل‌های داده‌محور از جمله شبکه‌عصبی وابستگی زیادی به کیفیت داده‌های مورد استفاده دارند بنابراین داده سری‌های زمانی هیدرولوژیکی بهتر است جهت افزایش قابلیت اطمینان و دقت رفع خطا شوند. به این منظور روش‌های کلاسیک رفع خطا ارائه شدند، هر چند که این روش‌ها عمدتاً برای سامانه‌های خطی مناسب هستند درحالی‌که پدیده‌های هیدرولوژیکی غیرخطی هستند. بنابراین کاربرد روش‌های کلاسیک در زمینه‌های هیدرولوژیکی با مشکل مواجه می‌شود. در این پژوهش از روش آستانه‌گذاری نرم موجکی که مناسب برای پدیده‌های خطی و غیرخطی است استفاده خواهد شد که در سال‌های اخیر پیشرفت کرده و توانسته است در رفع خطای سیگنال‌های مختلف موثر واقع شود (حسن‌نژاد و نورانی^{۱۲}، ۲۰۱۲: ۷۴۶).

دونوهو^{۱۳} (۱۹۹۵: ۶۱۳) برای اولین بار نظریه رفع خطا به‌وسیله‌ی آستانه‌گذاری نرم را ارائه کرد. به‌عنوان نمونه می‌توان به کاربرد موفق رفع نویز موجکی با مدل شبکه‌عصبی در شبیه‌سازی جریان کرک موردار^{۱۴} واقع در آمریکا اشاره نمود (حسن‌نژاد و نورانی^{۱۵}، ۲۰۱۲: ۷۴۶). لیو و همکاران^{۱۶} (۲۰۰۴: ۵) از این نظریه برای رفع خطای داده‌های جریان رودخانه بهره برده و به پیش‌بینی سیلاب با شبکه‌عصبی پرداخت و پیشرفت‌های قابل

1. Nourani et al.

2. Hsu and Li

3. Wang et al.

4. Maheswaran and Khosa

5. Nayak et al.

6. Shoaib et al.

7. Badrzadeh et al.

8. Uysal et al.

9. Alizadeh et al.

10. Tiwari et al.

11. Qu et al.

12. Hasan Nejad and Nourani

13. Donoho

14. Creek Murder

15. Hasan Nejad and Nourani

16. Liu et al.

توجهی در مدل مشاهده کرد. جیو و همکاران^۱ (۲۰۱۱: ۱۳۰۷۳) از روش دونوهو (۱۹۹۵: ۶۱۳) بهره جستند. پیش‌بینی جریان رودخانه چانگچین^۲ در چین را با مدل‌های ANN و دستگاه مؤلفه پشتیبانی (SVM^۳) انجام دادند. پرتویان و همکاران (۱۳۹۷) با استفاده از روش رفع نوفه موجکی اقدام به رفع نویز بد از سری‌های زمانی روزانه کرده و سپس با افزودن نویز خوب به این داده‌های رفع نویز شده و تشکیل مجموعه‌های آموزشی مختلف، شبیه‌سازی بارش-رواناب برای ایستگاه پل آنیان واقع در حوضه‌ی آبخیز زرینه رود در سراب سد بوکان، با استفاده از مدل‌های جعبه سیاه ANN و ANFIS انجام شده است.

هدف از پژوهش حاضر بررسی تأثیر دو روش پیش‌پردازش‌های زمانی از جمله تبدیل موجک و روش رفع نویز بر اساس تبدیل موجک در پیش‌بینی رواناب دشت اردبیل با شبکه‌عصبی مصنوعی با داده‌های ورودی مختلف است.

۲- مواد و روش

جهت شبیه‌سازی فرایند بارش-رواناب در خروجی دشت اردبیل با استفاده از مقادیر بارش سه ایستگاه سامیان، گیلانده و کوزه‌تپراقی و رواناب ثبت شده در آن‌ها از نرم افزار متلب^۴، استفاده شد. شبیه‌سازی‌ها با مدل هوش مصنوعی شبکه عصبی برای ورودی‌های مختلف با داده‌های پیش پردازش نشده خام، داده‌های پیش پردازش شده با تبدیل موجک، و بالاخره داده‌های رفع نویز شده با استفاده از تبدیل موجک صورت گرفت.

۲-۱- معرفی منطقه‌ی مورد مطالعه

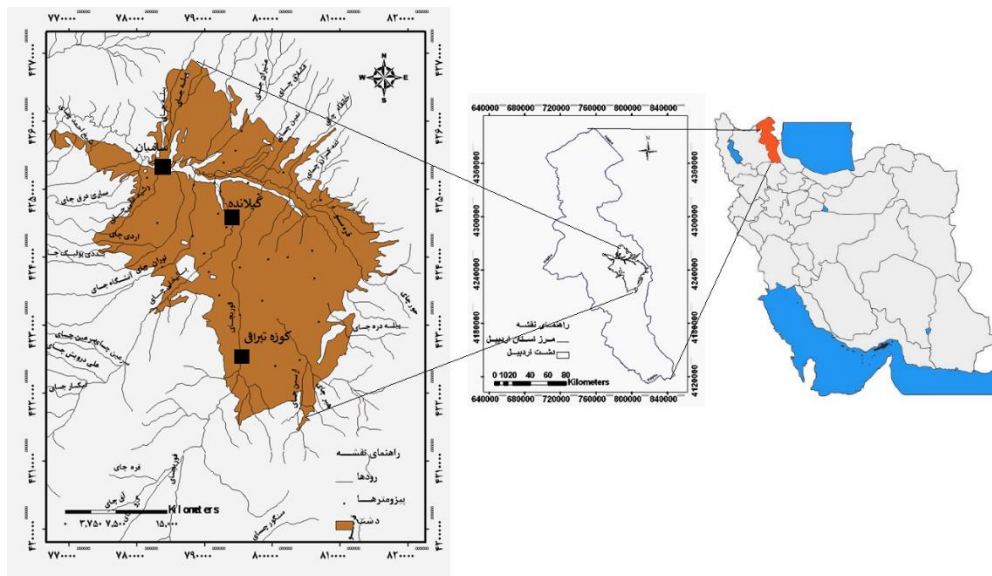
منطقه‌ی مورد مطالعه، دشت اردبیل است که در شمال غربی ایران واقع شده است. این دشت به‌طور تقریبی، در عرض جغرافیایی $38^{\circ}03'$ تا $38^{\circ}27'$ شمالی و طول جغرافیایی $47^{\circ}55'$ تا $48^{\circ}20'$ شرقی واقع شده است. دشت اردبیل مشرف بر ارتفاعات بخش غربی رشته کوه البرز (ارتفاعات تالش) و در امتداد دامنه‌ی شرقی سبلان قرار دارد. مساحت آن در حدود 990 Km^2 می‌باشد. متوسط بارش سالانه در ایستگاه سینوپتیک اردبیل در دوره‌ی زمانی ۱۳۹۱-۱۳۵۰ حدود 304 mm است. پرباران‌ترین ماه سال اردیبهشت و کم باران‌ترین آن ماه مرداد است. میانگین دمای سالانه ایستگاه سینوپتیک اردبیل حدود 9°C است و یکی از نواحی سردسیر ایران محسوب می‌شود.

در این پژوهش از اطلاعات ۳ ایستگاه کوزه تپراقی (K)، گیلانده (G) و سامیان (S) شامل داده‌های بارش (P) و رواناب (R) در مقیاس ماهانه مورد مطالعه قرار گرفته است. طول داده‌های استفاده شده از سال ۱۳۵۸/۷ تا

1. Guo
2. Changchin
3. Support Vector Machine (SVM)

4. Matlab

۱۳۹۸/۶ می‌باشد که از سازمان هواشناسی استان اردبیل و اداره‌ی آب منطقه‌ای اردبیل تهیه گردیده‌اند. لازم به ذکر است که ایستگاه کوزه‌تپراقی روی رودخانه‌ی قوری‌چای، ایستگاه گیلانده روی رودخانه‌ی بالیخلی چای و ایستگاه سامیان روی رودخانه قره‌سو در خروجی دشت واقع شده است. در این دشت رودخانه‌های قوری‌چای و بالیخلی چای در قسمت خروجی دشت به رودخانه‌ی قره‌سو می‌ریزد. شکل ۱ موقعیت جغرافیایی دشت اردبیل و موقعیت ایستگاه‌های باران‌سنجی و هیدرومتری را نشان می‌دهد.



شکل (۱): ایستگاه‌های باران‌سنجی و رواناب حوضه دشت اردبیل
Fig (1): Ase study and position of rainfall and runoff stations

در مدل‌سازی داده‌ها، جهت آموزش از ۷۵ درصد داده‌ها (حدود ۳۰ سال) و برای آزمون مدل‌ها از ۲۵ درصد داده‌ها (حدود ۱۰ سال) استفاده گردید (نورانی و همکاران، ۲۰۰۹: ۲۸۷۷). جهت جلوگیری از ورود داده‌های منفی در مدل شبکه عصبی مصنوعی قبل از آموزش و آزمون مجموعه‌ی داده‌های موجود با استفاده از رابطه‌ی ۱ (بین مقادیر ۰ و ۱ نرمال‌سازی گردید (نورانی و همکاران، ۲۰۰۹: ۲۸۷۷).

$$r_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (1)$$

در این رابطه، X_i مقادیر واقعی مشاهداتی، X_{max} حداکثر مقادیر واقعی و X_{min} حداقل مقادیر واقعی هستند. برای انتخاب بهترین ورودی برای مدل‌سازی ۳ ترکیب انتخاب شدند، و این امر برای پیدا کردن میزان وابستگی

رواناب یک ماه آینده در خروجی دشت (ایستگاه سامیان) ($R_S(t+1)$) به بارش و رواناب این ایستگاه و رواناب ایستگاه‌های کوزه تپراقی و گیلانده (R_G و R_K) طی چند ماه قبل انجام شد. ترکیب ورودی‌ها به صورت زیر هستند:

$$\text{Comb. 1: } R_i(t), R_i(t-1), P_i(t) \quad (۲)$$

$$\text{Comb. 2: } R_i(t), R_i(t-12), R_i(t-24), P_i(t) \quad (۳)$$

$$\text{Comb. 3: } R_K(t), R_G(t), R_G(t-1), R_G(t-12), R_G(t-24) \quad (۴)$$

که در ترکیب‌های فوق $R(t)$ و $P(t)$ به ترتیب رواناب و بارش مشاهداتی در زمان t می‌باشند. i می‌تواند هر یک از سه ایستگاه سامیان، گیلانده و کوزه تپراقی باشد. خصوصیات آماری داده‌های مورد استفاده در ایستگاه سامیان به عنوان نمونه در جدول (۱) ارائه شده‌اند. قبل از اعمال مدل شبکه‌عصبی ورودی‌های مهم شبکه با استفاده از بالاترین ضریب همبستگی خطی انتخاب شدند. مقادیر ضریب همبستگی در جدول ۲ ارائه شده است.

جدول (۱): مشخصات آماری داده‌های بارش و رواناب ماهانه ایستگاه سامیان

Table (1): Statistics of rainfall and runoff time series in Samian station

ایستگاه‌ها	پارامترهای هیدرولوژیکی	مشخصات آماری	کل	آموزش	آزمایش
ایستگاه سامیان	رواناب (m^3/s)	کمینه	۰	۰	۰/۴۳
		بیشینه	۳۰۷۶/۶	۱۱۰۴/۰۴	۳۰۷۶/۶
		میانگین	۱۶۷/۸۲	۱۶۷/۷۴	۱۶۸/۰۸
		انحراف معیار	۲۹۱/۴۸	۳۱۳/۴۲	۲۱۱/۵۳
ایستگاه سامیان	بارش (mm)	کمینه	۰	۰	۰
		بیشینه	۹۴	۹۴	۷۱
		میانگین	۱۹/۶۲	۲۰/۵۳	۱۷/۰۹
		انحراف معیار	۱۹/۲۱	۲۰	۱۶/۳۴
ایستگاه گیلانده	رواناب (m^3/s)	کمینه	۰	۰	۰
		بیشینه	۵۶۳/۵	۵۶۳/۵۰	۴۹۷/۲۱
		میانگین	۶۹/۸۸	۶۳/۶۵	۸۹/۰۷
		انحراف معیار	۹۲/۹۱	۹۱/۳۱	۹۵/۵۳
ایستگاه گیلانده	بارش (mm)	کمینه	۰	۰	۰
		بیشینه	۱۴۱	۱۴۱	۷۶/۵
		میانگین	۲۰/۶۸	۲۰/۸۸	۲۰/۰۴۶
		انحراف معیار	۲۰/۳۳	۲۰/۵۲	۱۹/۸۰

رواناب (m^3/s)				ایستگاه کوزه‌تپراقی
کمینه	۰	۰	۰/۳	
بیشینه	۷۱۷/۷۴	۷۱۷/۷۴	۳۷۴/۹۱	
میانگین	۲۶/۶۳	۲۹/۰۹	۳۶/۶۸	
انحراف معیار	۵۶/۴۰	۵۶/۵۶	۵۶/۶۱	
بارش (mm)				ایستگاه کوزه‌تپراقی
کمینه	۰	۰	۰	
بیشینه	۱۲۸	۱۲۸	۹۳	
میانگین	۱۹/۳۳	۱۹/۰۲	۱۸/۰۸	
انحراف معیار	۲۲/۴۶	۲۱/۳۶	۱۷/۶۰	

جدول (۲): ضریب همبستگی خطی ورودی‌های مختلف با خروجی در ایستگاه‌های سامیان، گیلانده و کوزه‌تپراقی

Table (2): Linear correlation coefficient in Samian, Gilandeh and Kozatopraghi stations

ورودی										خروجی
$R_s(t-24)$	$R_s(t-12)$	$R_s(t-3)$	$R_s(t-2)$	$R_s(t-1)$	$R_s(t)$	$P_s(t-3)$	$P_s(t-2)$	$P_s(t-1)$	$P_s(t)$	$R_s(t+1)$
۰/۵۵۱	۰/۵۴۴	۰/۰۵۹	۰/۱۹۱	۰/۴۷۰	۰/۴۷۰	-۰/۰۷۶	-۰/۰۰۶	۰/۱۵۱	۰/۲۶۷	
$R_G(t-24)$	$R_G(t-12)$	$R_G(t-3)$	$R_G(t-2)$	$R_G(t-1)$	$R_G(t)$	$P_G(t-3)$	$P_G(t-2)$	$P_G(t-1)$	$P_G(t)$	$R_G(t+1)$
۰/۶۳۶	۰/۶۱۷	۰/۱۲۴	۰/۳۰۱	۰/۵۲۳	۰/۸۵۴	-۰/۰۴۴	۰/۰۰۷	۰/۱۰۸	۰/۱۶	
$R_K(t-24)$	$R_K(t-12)$	$R_K(t-3)$	$R_K(t-2)$	$R_K(t-1)$	$R_K(t)$	$P_K(t-3)$	$P_K(t-2)$	$P_K(t-1)$	$P_K(t)$	$R_K(t+1)$
۰/۴۶۱	۰/۴۸۹	-۰/۰۲۱	۰/۰۷۹	۰/۳۰۵	۰/۶۸۰	-۰/۰۶۵	-۰/۰۲	۰/۱۰۵	۰/۲۱۴	
$R_G(t-24)$	$R_G(t-12)$	$R_G(t-3)$	$R_G(t-2)$	$R_G(t-1)$	$R_G(t)$	$P_G(t-3)$	$P_G(t-2)$	$P_G(t-1)$	$P_G(t)$	$R_G(t+1)$
۰/۷۳۱	۰/۷۲۷	-۰/۰۱۳	۰/۱۲۴	۰/۳۰۳	۰/۶۳۰	-۰/۰۸۷	-۰/۰۲۸	۰/۱۰۶	۰/۱۷۹	
$R_K(t-24)$	$R_K(t-12)$	$R_K(t-3)$	$R_K(t-2)$	$R_K(t-1)$	$R_K(t)$	$P_K(t-3)$	$P_K(t-2)$	$P_K(t-1)$	$P_K(t)$	$R_K(t+1)$
۰/۴۷۱	۰/۵۲۹	-۰/۰۳۸	۰/۰۶۹	۰/۲۰۶	۰/۵۲۳	-۰/۰۴	-۰/۰۰۲	۰/۰۸۸	۰/۲۲۸	

۲-۲- تبدیل موجک

تبدیل موجک با مقیاس زمانی یک سیگنال زمانی پیوسته، $x(t)$ ، به صورت زیر تعریف می‌شود:


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

که * تابع مزدوج را نشان می‌دهد. $g(t)$ تابع موجک یا موجک مادر است. پارامتر a فاکتور بزرگنمایی و b نشان‌دهنده‌ی تبدیل موقت تابع g است که امکان مطالعه سیگنال در پیرامون b را می‌دهد (نورانی و همکاران^۱، ۲۰۰۹: ۲۸۷۷).

در این بخش به منظور نشان دادن تغییرات سری‌های زمانی هیدرولوژیکی در مقیاس‌های مختلف سری‌های ماهانه رواناب سه ایستگاه سامیان، گیلانده و کوزه تپراقی توسط تبدیل موجک در نرم‌افزار متلب تجزیه شدند. ضرائب جزئی و تقریبی از تجزیه یک سیگنال توسط تبدیل موجک گسسته حاصل شدند. ضرائب تقریبی (a) نشانگر ضرایب تبدیل موجک با وضوح درشت می‌باشند که روند کلی را در سری نشان می‌دهند و $d1, d2, d3$ ضرایب جزئی می‌باشند که اطلاعات جزئی از روندها در سری‌های زمانی هیدرولوژیکی ارائه می‌دهند انتخاب موجک مادر مناسب نقش مهمی را در تبدیل موجک دارد. با توجه به ساختار موجک مادر Daubechies-4 (db4) و شباهت سری‌های زمانی رواناب سه ایستگاه به آن، موجک مادر db4 می‌تواند ویژگی‌های سیگنال را در برگرد و به‌عنوان موجک مادر تجزیه کننده در این پژوهش انتخاب گردید (پرتویان و همکاران، ۱۳۹۷). در انتخاب درجه تجزیه نیز، سری‌های زمانی رواناب در درجه L ، منجر به $L+1$ زیرسری (یک زیرسری تقریبی $P_a(t)$ و L زیرسری جزئی $Pd_i(t)$ ($i=1, 2, \dots, L$) شد. درجه تجزیه ۳ به‌عنوان درجه تجزیه بهینه مطابق رابطه‌ی زیر در نظر گرفته شد (نورانی و همکاران، ۲۰۱۲: ۷۲۴):

$$L = \log N \quad (6)$$

که در آن L و N به ترتیب درجه تجزیه و طول سری زمانی می‌باشد. در این مطالعه با داشتن $N=528$ ، $L=2/72$ به دست می‌آید که درجه تجزیه ۳ در نظر گرفته شد. به‌عنوان مثال شکل ۲ تجزیه سری زمانی رواناب ایستگاه سامیان را در دشت اردبیل را با موجک مادر db4 در سطح ۳ نشان می‌دهد.



شکل (۲): زیرسری‌های تقریبی و جزئی سری زمانی رواناب ایستگاه سامیان.
Fig (2): Approximation and detail sub-signals of runoff time series in Samian station

۳-۲- روش رفع نویز موجکی

این روش در حال حاضر محبوب‌ترین روش به منظور رفع نویز با استفاده از تبدیل موجک به صورت زیر انجام می‌گیرد: الف) انتخاب موجک مادر مناسب و سطح تجزیه مناسب و تجزیه سری زمانی اصلی در سطح تجزیه L به زیر سری تقریبی A و زیرسری‌های جزئی d_j . ب) اگر قدرمطلق زیرسری‌های جزئی از مقدار آستانه بیشتر شود، آنگاه مقدار تفاضل بین زیرسری جزئی و مقدار آستانه با رابطه‌ی ۷ جایگزین می‌گردد، در غیر این صورت زیرسری‌های جزئی برابر صفر در نظر گرفته می‌شود (دونوهو^۱، ۱۹۹۵: ۶۱۳).

$$d_j(t) = \begin{cases} \text{sgn}(d_j(t))(|d_j(t) - T'| & |d_j(t)| > T' \\ 0 & |d_j(t)| \leq T' \end{cases} \quad (7)$$

در معادله (۷)، T' و $d_j(t)$ ($j = 1, \dots, M$) نشان‌دهنده مقدار آستانه و مقدار مطلق زیر سری‌های جزئی در سطح تجزیه λ_m (ج) تبدیل موجک می‌تواند سری زمانی رفع نویز شده را طی فرآیند از زیرسری‌های جزئی در

1. Donoho

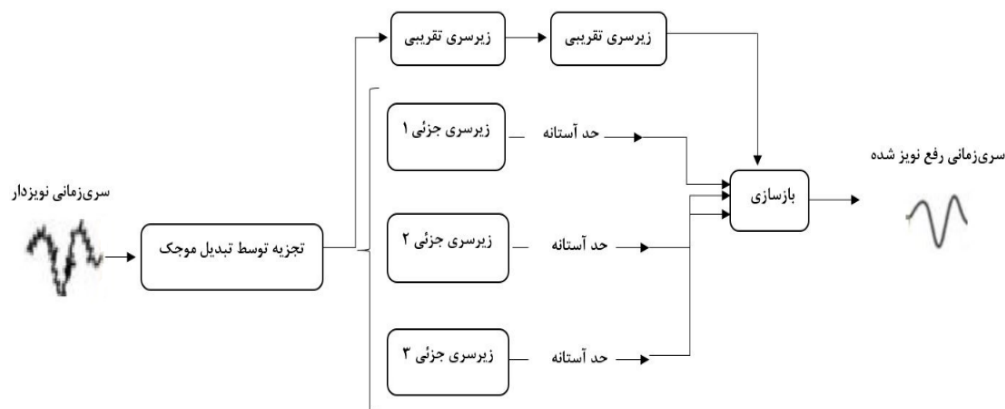
تمام سطوح و زیرسری تقریبی در سطح L بازسازی نماید. مقدار آستانه‌ی انتخابی بصورت زیر تعیین می‌شود (دونوهو، ۱۹۹۵: ۶۱۳):

$$T' = \hat{\sigma} \sqrt{2 \ln(n)} \quad (8)$$

که در آن n تعداد داده‌های سری‌زمانی اولیه (نویزدار) و $\hat{\sigma}$ انحراف معیار نویز می‌باشد که با فرمول زیر محاسبه می‌گردد:

$$\hat{\sigma} = \left[\frac{\text{median}(|d_j(t)|)}{0.6745} \right] \quad (9)$$

$|d_j(t)|$ زیرسری جزئی سری‌زمانی در سطح تجزیه اول می‌باشد. شکل ۳ به صورت شماتیک مراحل رفع نویز موجکی سری‌های زمانی را نمایش می‌دهد.



شکل (۳): شکل شماتیک رفع نویز موجکی داده‌ها (نورانی و موسوی، ۲۰۱۶: ۱۰)

Fig (3): The schematic of the wavelet-based data de-noising (Nourani and Mousavi, 2016: 10)

نوسانات کوچکی سری زمانی رواناب به علت ماهیت سری‌زمانی نبوده اما به طور کلی می‌تواند به دلایل محیطی بوده از جمله نتیجه مصارف کشاورزی و تغییرات اقلیمی در یک کلمه عوامل خارجی باشد. همچنین این نوسانات کوچک می‌تواند مربوط به خطای اندازه‌گیری (نویز) باشد که می‌تواند از طریق فرآیند رفع نویز حذف شود.

۴-۲- معیار ارزیابی موفقیت

دو معیار مختلف ضریب تبیین (DC) (رابطه ۱۰) و جذر میانگین مربع خطاها (رابطه ۱۱) به منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیش‌بینی دقیق‌تر پارامتر رواناب استفاده شده است (نورانی و همکاران^۱، ۲۰۱۱: ۴۱).

$$DC = 1 - \frac{\sum_{i=1}^N (G_{com_i} - G_{obs_i})^2}{\sum_{i=1}^N (G_{obs_i} - \bar{G}_{obs_i})^2} \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (G_{com_i} - G_{obs_i})^2}{N}} \quad (11)$$

که در این روابط N تعداد داده‌های مشاهداتی رواناب، G_{com_i} داده‌های محاسباتی (مقدار پیش‌بینی شده رواناب)، G_{obs_i} داده‌های مشاهداتی رواناب \bar{G}_{obs_i} میانگین داده‌های مشاهداتی رواناب است. هرچه $RMSE$ به صفر و DC به یک نزدیک شود، جواب بهتری برای مدلسازی رواناب حاصل شده است.

۳- یافته‌ها و بحث

در این بخش، نتایج مدل شبکه‌عصبی برای سه حالت شبکه‌عصبی تنها، ترکیب شبکه‌عصبی با تبدیل موجک و شبکه‌عصبی برای ورودی‌های رفع نویز شده برای بهترین شبیه‌سازی‌ها در جداول ۳، ۴ و ۵ ارائه شده و از ارائه نتایج سایر شبیه‌سازی‌ها خودداری شده است. در این جداول، منظور از ساختار شبکه‌عصبی به صورت C-b-a، تعداد نرون‌های لایه ورودی، میانی و خروجی می‌باشد.

۳-۱- نتایج مدل شبکه‌عصبی (ANN)

نتایج شبکه‌عصبی مصنوعی برای سه ترکیب ورودی در جدول (۳) آورده شده است. بررسی نتایج نرم‌افزار شبکه‌عصبی مصنوعی بیانگر آن است که بهترین ترکیب از بین ترکیب‌های ۱ و ۲، ترکیب داده دوم می‌باشد که نسبت به ترکیب داده‌های اول به دلیل در نظر گرفتن نوسانات سالانه سری‌های زمانی رواناب در هر سه ایستگاه نتایج بهتری را ارائه دادند به عبارت دیگر پیش‌بینی رواناب در هر ۳ ایستگاه بیش از آنکه به مقدار آن در ماه گذشته وابسته باشد به مقادیر آن در سال‌های گذشته در این ایستگاه وابسته می‌باشد. بطوریکه در ایستگاه سامیان ترکیب دوم داده‌ها در مرحله‌ی صحت‌سنجی ۳۰/۶۵ درصد و در ایستگاه‌های گیلانده و کوزه‌تپراقی به ترتیب ۹ و ۳۵/۴ درصد نسبت به ترکیب اول داده‌ها افزایش از خود نشان دادند. ترکیب سوم داده‌ها که رواناب ماه آینده

خروجی دشت (ایستگاه سامیان) را با استفاده از داده‌های رواناب دو ایستگاه بالادست گیلانده و کوزه تپراقی مدل‌سازی می‌کند. این مدل دارای مقدار ضریب تبیین 0.73 در مرحله‌ی صحت‌سنجی و مقدار 0.908 در مرحله آموزش نرم افزار می‌باشد هم‌چنین با توجه به نتایج بهتر ترکیب سوم داده‌ها، رواناب خروجی دشت اردبیل به میزان رواناب ایستگاه‌های بالادست خود وابسته می‌باشد، چرا که ایستگاه کوزه تپراقی روی رودخانه‌ی قوری‌چای و ایستگاه گیلانده روی رودخانه‌ی بالیخوچای واقع شده‌اند که در خروجی دشت این دو رودخانه به هم پیوسته و از حوضه خارج می‌شوند. پس رواناب خروجی دشت بیش از آنکه به مقدار خود در زمان‌های گذشته وابسته باشد به تغییرات رواناب دو رودخانه واریزی خود حساس می‌باشد. دقت مدل‌سازی در ترکیب سوم نسبت به ترکیب اول و دوم در ایستگاه سامیان به ترتیب 68% و 31% درصد افزایش داشته است. نتایج ضعیف به عبارت بهتر دقت کم ترکیب اول داده‌ها می‌تواند به دلیل کاهش شدید رواناب دشت در سال‌های اخیر باشد که از روند مشخصی پیروی نکرده و پیش‌بینی این پارامتر را با مشکل مواجه کرده است.

جدول (۳): نتایج مدل‌سازی رواناب با مدل ANN در ایستگاه‌های سامیان، گیلانده و کوزه تپراقی

Table (3): The results of runoff modeling via ANN model in Samian, Gilandeh and Kozatopraghi stations

شماره ترکیب	متغیرهای ورودی به شبکه	متغیر خروجی	ساختار	تعداد تکرار	DC آموزش	DC آزمایش	RMSE آموزش	RMSE آزمایش
۱	$R_S(t), R_S(t-1), P_S(t)$	$R_S(t+1)$		۳-۳-۱	۱۰۰	0.592	0.065	0.051
۲	$R_S(t), R_S(t-12), R_S(t-24), P_S(t)$			۳-۷-۱	۲۰	0.795	0.043	0.043
۳	$R_K(t), R_G(t), R_G(t-1), R_G(t-12), R_G(t-24)$			۳-۳-۱	۱۰	0.908	0.029	0.035
۱	$R_G(t), R_G(t-1), P_G(t)$	$R_G(t+1)$		۳-۷-۱	۸۰	0.751	0.081	0.103
۲	$R_G(t), R_G(t-12), R_G(t-24), P_G(t)$			۳-۴-۱	۲۰۰	0.775	0.074	0.093
۱	$R_K(t), R_K(t-1), P_K(t)$	$R_K(t+1)$		۳-۴-۱	۱۰۰	0.510	0.055	0.066
۲	$R_K(t), R_K(t-12), R_K(t-24), P_K(t)$			۳-۳-۱	۲۰۰	0.820	0.035	0.053

۳-۲- نتایج مدل ترکیبی شبکه عصبی و تبدیل موجک (WT-ANN)

جدول (۴) نتایج سه ترکیب داده را با مدل ترکیبی شبکه عصبی موجکی نشان می‌دهد. با توجه به اینکه در این مدل ترکیبی دو ترکیب اول و دوم یک ورودی را خواهند داشت چون با تجزیه سری زمانی به زیرسری‌های زمانی تمام پریرودهای زمانی از جمله نوسانات سالانه نیز در نظر گرفته می‌شود. با مقایسه نتایج مدل ترکیبی مشاهده می‌شود که در ایستگاه گیلانده کاهش دقت مدل‌سازی با اعمال تبدیل موجک برای هر دو ترکیب داده حاصل شده است. اما در ایستگاه کوزه‌تپراقی سبب افزایش مقدار DC به ترتیب به مقدار ۹۶ و ۴۵ درصد در ترکیب ورودی‌های اول و دوم گردیده است. در ایستگاه سامیان نیز ترکیب دوم نیز نسبت به مدل تکی ۳/۵ درصد افزایش و ترکیب اول داده‌ها ۳۵ درصد افزایش را در دقت مدل‌سازی نمایش داد. هم‌چنین، در مدل ترکیبی شبکه عصبی موجکی ترکیب سوم داده‌ها در ایستگاه سامیان نتایج بسیار خوبی را ارائه داده‌اند که نسبت به مدل شبکه عصبی با همان ترکیب داده‌ها ۱۷٪ افزایش نشان می‌دهد. در ترکیب سوم داده‌ها DC آموزش و آزمایش را به ترتیب تا مقادیر ۰/۸۸ و ۰/۸۵۴ افزایش می‌دهد، که این نتیجه، انطباق هر چه بیشتر داده‌های پردازش شده با تبدیل موجک را با داده‌های مشاهداتی نشان می‌دهد. این افزایش در دقت مدل‌سازی با مدل ترکیبی شبکه عصبی موجکی در هر سه ایستگاه نشان می‌دهد که در سری‌زمانی رواناب دشت اردبیل نوسانات ماهانه و بویژه نوسانات سالیانه نقش مهمی را ایفا می‌کنند.

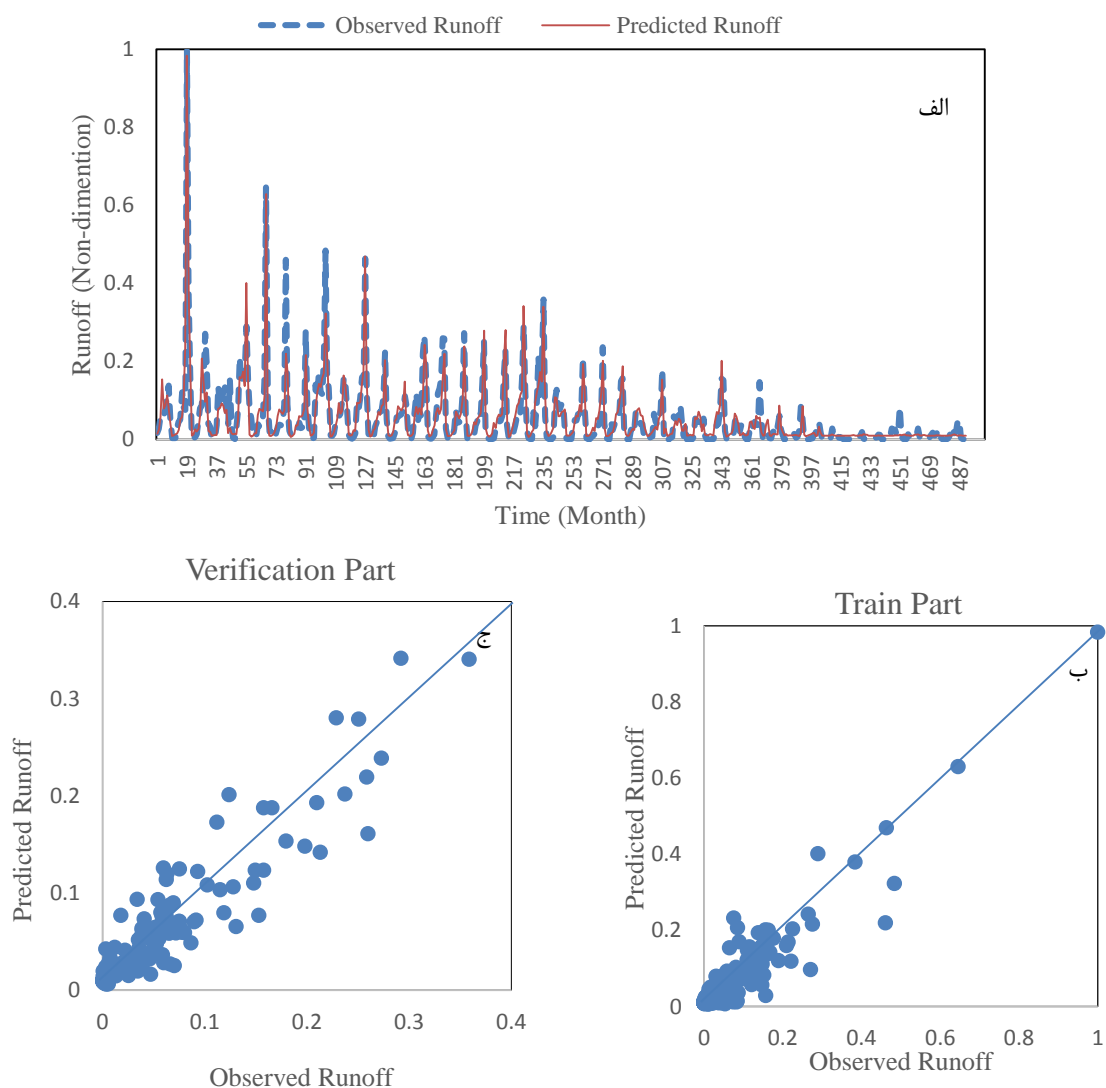
جدول (۴): نتایج مدل‌سازی رواناب با مدل ترکیبی WANN در ایستگاه‌های سامیان، گیلانده و کوزه‌تپراقی
Table (4): The results of runoff modeling via WANN model in Samian, Gilandeh and Kozatopraghi stations

شماره ترکیب	متغیرهای ورودی به شبکه	متغیر خروجی	ساختار	تعداد تکرار	DC آموزش	DC آزمایش	RMSE آموزش	RMSE آزمایش
۱ و ۲	$R_{Si}(t), P_S(t)$	$R_S(t+1)$	۳	۱۰	۰/۷۹۱	۰/۵۸۷	۰/۰۴۷	۰/۰۴۴
۳	$R_{Ki}(t), R_{Gi}(t)$	$R_S(t+1)$	۳	۷۰	۰/۸۸۰	۰/۸۵۴	۰/۰۳۲	۰/۰۲۶
۱ و ۲	$R_{Gi}(t), P_G(t)$	$R_G(t+1)$	۱-۶-۵	۷۰	۰/۷۹۲	۰/۵۹۹	۰/۰۷۳	۰/۱۱۰
۱ و ۲	$R_{Ki}(t), P_K(t)$	$R_K(t+1)$	۱-۶-۵	۱۱۰	۰/۹۳۰	۰/۶۳۷	۰/۰۲۱	۰/۰۴۸

*مقادیر **Ri** زیرسری‌های تجزیه شده سری زمانی رواناب توسط تبدیل موجک در ورودی شبکه

برای ارزیابی مدل در شکل ۴- الف، مقادیر محاسباتی (پیش‌بینی شده) و مقادیر مشاهداتی ایستگاه سامیان برای ترکیب سوم داده‌ها به عنوان نمونه نشان داده شده است. طبق این شکل مشاهده می‌شود که مقادیر مشاهداتی و محاسباتی از انطباق خوبی نسبت به یکدیگر برخوردار می‌باشند. شکل ۴- ب، نمودار مقادیر

مشاهداتی در مقابل مقادیر پیش‌بینی شده برای مقادیر آموزش رواناب سامیان نشان داده شده است. همچنین در شکل ۴-ج، نمودار مقادیر مشاهداتی در مقابل محاسباتی مقادیر صحت‌سنجی (آزمایش) را برای آن ایستگاه نشان داده شده است. با توجه به این اشکال مدل‌سازی از دقت بالایی برای ترکیب سوم داده‌ها برخوردار می‌باشد.



شکل (۴): الف- مقادیر محاسباتی و مقادیر مشاهداتی در حالت نرمال. (ب) نمودار مقادیر مشاهداتی در مقابل محاسباتی برای مقادیر آموزش، (ج) نمودار مقادیر مشاهداتی در مقابل محاسباتی مقادیر آزمایش برای ایستگاه رواناب سامیان

Figure (4): (a) predicted and observed runoff (b) Scatter plot for verification period, (c) Scatter plot for train period in Samian station

۳-۳- نتایج مدل شبکه‌ی عصبی با داده‌های رفع نویز شده

در مرحله‌ی سوم، اقدام به رفع نویز موجکی با استفاده از موجک مادر db4 برای رواناب ایستگاه‌های سامیان، گیلانده و کوزه تپراقی با سطح تفکیک‌پذیری ۳ با توجه به توضیحات مدل ترکیبی شبکه‌عصبی موجکی با آستانه‌های متفاوت انتخاب گردید. نتایج مدل شبکه‌عصبی مصنوعی برای داده‌های رفع نویز شده در جدول ۵ آورده شده است. در این جدول نیز نتایج مدل‌های بهینه ارائه شده و از ارائه سایر نتایج خودداری شده است. نتایج مدل‌های مختلف با ورودی‌های رفع نویز شده در مقایسه با مدل‌ها پیش‌پردازش نشده تغییرات قابل توجهی را از خود نشان ندادند. بطوریکه نتایج شبیه‌سازی ANN با داده‌های رفع نویز شده برای رواناب ایستگاه سامیان در مقایسه با مدل‌سازی با داده‌های پردازش نشده به ترتیب بهبود ۰.۱٪، ۰.۶٪ و ۶/۲ درصدی را برای ترکیب‌های اول، دوم و سوم در مرحله آزمایش نشان می‌دهد. در ایستگاه گیلانده نیز به ترتیب افزایش ۳ درصدی در ترکیب اول داده‌ها در قسمت آزمایش برای داده‌های دی‌نویز شده مشاهده گردید. ترکیب دوم داده‌ها در این ایستگاه تغییری برای داده‌های دی‌نویز شده نسبت به دی‌نویز نشده از خود نشان نداد. ترکیب اول و دوم داده‌های دی‌نویز شده در ایستگاه کوزه‌تپراقی به ترتیب ۰/۶ و ۷ درصد در مقایسه با داده‌های اصلی افزایش دقت در بخش آزمایش مدل را تجربه کردند.

جدول (۵): نتایج مدل‌سازی رواناب با مدل ANN برای داده‌های رفع نویز شده در ایستگاه‌های سامیان، گیلانده و کوزه-تپراقی

Table (5): The results of runoff modeling via ANN model for de-noised data in Samian, Gilandeh and Kozatopraghi stations

شماره ترکیب	متغیرهای ورودی به شبکه	متغیر خروجی	تعداد ساختار تکرار	DC		RMSE
				آموزش	آزمایش	
۱	$R_S(t), R_S(t-1), P_S(t)$	$R_S(t+1)$	۳	۱۰۰	۰/۵۹۴	۰/۰۵۲
۲	$R_S(t), R_S(t-12), R_S(t-24), P_S(t)$		۵	۱۰۰	۰/۸۱۳	۰/۰۴۲
۳	$R_K(t), R_G(t), R_G(t-1), R_G(t-12), R_G(t-24)$	$R_G(t+1)$	۹	۱۰	۰/۸۳۱	۰/۰۳۲
۱	$R_G(t), R_G(t-1), P_G(t)$		۳-۶-۱	۲۱۰	۰/۷۵۴	۰/۰۸۰
۲	$R_G(t), R_G(t-12), R_G(t-24), P_G(t)$	۴-۲-۱	۲۵۰	۰/۷۰۵	۰/۶۸۰	۰/۰۹۳

۰/۰۶۴	۰/۰۵۴	۰/۳۲۷	۰/۵۲۳	۶۰	۳-۳-۱	$R_K(t), R_K(t-1), P_K(t)$	۱
۰/۰۵۶	۰/۰۲۹	۰/۴۷۱	۰/۸۵۴	۱۱۰	۴-۶-۱	$R_K(t+1)$ $R_K(t),$ $R_K(t-12), R_K(t-24), P_K(t)$	۲

در بین مدل‌های مختلف پیش‌بینی رواناب خروجی دشت اردبیل، بهترین نتایج برای ترکیب‌های اول و سوم داده‌ها در مدل ANN با داده‌های پیش‌پردازش شده با تبدیل موجک مشاهده گردید. با این حال دقیق‌ترین نتایج برای ترکیب دوم داده‌ها در مدل ANN با داده‌های رفع نویز شده مشاهده گردید. در مجموع مدل WT-ANN به دلیل داشتن نوسانات سالیانه دقت‌های بالاتری را در ترکیب سوم داده‌ها از خود نشان داد.

۴- نتیجه‌گیری

مدلسازی بارش-رواناب بر پایه‌ی موجک-شبکه عصبی، که روابط غیرخطی را به طور همزمان در مقیاس‌های زمانی مختلف بدست می‌آورد در سال‌های اخیر افزایش یافته است. اگرچه فرکانس‌های گوناگونی می‌تواند در یک پدیده یافت شود، همه‌ی آنها مهم نبوده و تاثیر قابل توجهی در عملکرد مدل مربوطه ندارند. اعمال یک مدل، همانند ANN، بدون پیش‌پردازش مناسب داده‌ها می‌تواند به انحرافی در مدلسازی منجر شود که عموماً به صورت بیش‌سازگاری بروز می‌کند. در این پژوهش ترکیبی از دو روش رفع نویز موجکی و تبدیل موجک برای پیش‌پردازش داده‌های سری زمانی بارش-رواناب قبل از اعمال آنها به مدل ANN بکار رفته است. مقایسه‌ی نتایج مدل‌های پردازش شده و پردازش نشده نشان داد که مدل‌های پیش‌پردازش شده توانسته‌اند مقادیر رواناب را با درصد خطای کمی پیش‌بینی نمایند. در مقایسه‌ی نتایج مدل‌های پیش‌پردازش شده با یکدیگر، بهترین نتایج مربوط به پردازش داده‌ها با استفاده از تبدیل موجک برای ورودی‌های داده‌های رواناب در بالادست خروجی دشت در ایستگاه سامیان می‌باشد. افزایش دقت مدلسازی پدیده بارش-رواناب با استفاده از ابزار تبدیل موجک با یافته‌های کاناس و همکاران (۲۰۰۶: ۱۱۶۴)؛ نورانی و همکاران (۲۰۰۹: ۲۸۷۷)؛ (۲۰۱۱: ۴۱)؛ (۲۰۱۲: ۷۲۴)؛ (۲۰۱۳: ۲۲۸)؛ هسیو و لی (۲۰۱۰: ۱۹۰)؛ وانگ و همکاران (۲۰۱۱: ۲۷۳۴)؛ ماهاسوارا و خوسرا (۲۰۱۲: ۳۲۰)؛ نایاک و همکاران (۲۰۱۳: ۵۷)؛ شعیب و همکاران (۲۰۱۴: ۴۷)؛ بدرزاده و همکاران (۲۰۱۵: ۱۶۳۳)؛ شعیب و همکاران (۲۰۱۶: ۲۱۱)؛ اویسال و همکاران (۲۰۱۶: ۶۳۰)؛ علیزاده و همکاران (۲۰۱۷: ۵۸۸)؛ تیواری و همکاران (۲۰۱۷: ۵۱) همخوانی دارد. در پژوهش پرتویان و همکاران (۱۳۹۷) مشابه این پژوهش استفاده از ابزار رفع نویز موجکی سبب افزایش دقت مدلسازی پدیده بارش-رواناب با شبکه‌ی عصبی شده است.

برای مطالعات آتی پیشنهاد می‌شود که مدل ارائه شده برای سری‌های زمانی روزانه این حوضه و هم‌چنین حوضه‌های دیگر، خصوصاً حوضه‌های خارجی، صورت گرفته تا از این طریق کارایی مدل پیشنهادی در افزایش بازده مدل‌های شبیه‌سازی در حوضه‌های دیگر نیز بررسی شود. توصیه می‌گردد که رفع نویز موجکی برای دیگر سری‌های زمانی هیدرولوژیکی از قبیل رواناب - رسوب نیز بررسی گردد.

۵-منابع

- Alizadeh, M.J., Kavianpour, M.R., Kisi, O. & Nourani, V. (2017). A new approach for simulating and forecasting the rainfall-runoff process within the next two months, *Journal of Hydrology*, 548, 588-597.
- Antar, M.A., I. Ellassiouti & M.N. Alam. (2006). Rainfall-runoff modeling using artificial neural networks technique: a Blue Nile catchment case study, *Hydrological Process*, 20 (5), 1201-1216.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). Artificial Neural Networks in hydrology II: Hydrologic Applications, *Journal of Hydrologic Engineering*, 386, 27-37.
- Babaali, H.R. & Dehghani, R. (2017). Prediction of flood discharge using wavelet neural network, *Journal of Hydrogeomorphology*, 11, 149-168.
- Badrzadeh, H., Sarukkalige, R. & Jayawardena, A.W. (2015). Hourly runoff forecasting for flood risk management: Application of various computational intelligence models, *Journal of Hydrology*, 529 (3), 1633-1643.
- Cannas, B., Fanni, A., See, L. & Sias, G. (2006). Data preprocessing for river flow forecasting using neural networks: Wavelet transforms and data partitioning, *Physics and Chemistry of the Earth, Parts A/B/C*, 31(18), 1164-1171.
- Donoho, D.H. (1995). Denoising by soft-thresholding. *IEEE Transactions on Information Theory*, 41(3), 613-617.
- Guo, J., Zhou, J., Qin, H., Zou, Q. & Li, Q. (2011). Monthly streamflow forecasting based on improved support vector machine model, *Expert Systems with Applications*, 38, 13073-13081.
- Hsu, K., Gupta, H.V. & Sorooshian, S. (1995). Artificial neural network modeling of rainfall runoff process, *Water Resources Research*, 31, 2517-2530.

- Hsu, K.C. & Li, S.T. (2010). Clustering spatial-temporal precipitation data using wavelet transform and self-organizing map neural network, *Advances in Water Resources*, 33, 190–200.
- Jahanbakhsh Asl, S., Asakare, H.A. & Ashrafi, S. (2019). Exponential micro-scale of rainfall-runoff relations of Zard river basin in the context of climate change, *Journal of Hydrogeomorphology*, 21, 109-132.
- Karami Jouzani, M., Ildermi, A. R., Nouri, H. & Pirnia, A. (2019). The effect of climate change on the trend of discharge fluctuations in Gorganrood-Qarasu watershed using general atmospheric circulation models, *Journal of Hydrogeomorphology*, 6 (18), 1-18.
- Liu, G.H., Qian, J.L. & Wang, J.J. (2004). Study of flood forecast based on wavelet soft-threshold technology and ANN, *Journal of Hydroelectric Engineering*, 23(4), 5–10.
- Maheswaran, R. & Khosa, R. (2012). Wavelet–Volterra coupled model for monthly stream flow forecasting, *Journal of Hydrology*, 450–451, 320-335.
- Nayak, P.C., Venkatesh, B., Krishna, B. & Jain, S.K. (2013). Rainfall-runoff modeling using conceptual, data driven, and wavelet based computing approach, *Journal of Hydrology*, 493, 57-67.
- Negi, A., SinghRawat, K., Nainwal, A., ChandraShah, M. & Kumar, V. (2021). Quality analysis of statistical and data-driven rainfall-runoff models for a mountainous catchment, *Materialstoday*, <https://doi.org/10.1016/j.matpr.2020.12.544>.
- Nejad, F. & V. Nourani. (2012). Elevation of wavelet denoising performance via an ANN Based streamflow forecasting model, *International Journal of Computer Science and Management Research*, 1, 764-770.
- 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., Kisi, O. & Komasi, M. (2011). Two hybrid artificial intelligence approaches for modeling rainfall-runoff process, *Journal of Hydrology*, 402, 41-59.
- Nourani, V., Komasi, M. & Alami, M. (2012). Hybrid Wavelet-genetic programming approach to optimize ANN modeling of rainfall-runoff process, *Journal of Hydrologic Engineering*, 16 (6), 724–741.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J. & Gebremicheal, M. (2013). Using self-organizing maps and wavelet transforms for space-time pre-processing of satellite precipitation and runoff data in neural network based rainfall-runoff modeling, *Journal of Hydrology*, 476, 228–243.

- Nourani, V., Hosseini Baghanam, A., Yahyavi Rahimi, A. & Hassan Nejad, F. (2014). Evaluation of wavelet-based de-noising approach in hydrological models linked to artificial neural networks. In: Islam, T., Srivastava, P.K., Gupta, M., Mukherjee, S., Zhu, X. (Eds.), *Artificial Intelligence Techniques in Earth and Environmental Sciences*. Springer.
- Nourani, V. & Mousavi, S. (2016). Spatiotemporal groundwater level modeling using hybrid artificial intelligence-meshless method, *Journal of Hydrology*, 536, 10–25.
- Partovian, A., Nourani, V. & Alami, M.T. (2018). Improving the performance of artificial intelligence software in precipitation-runoff simulation using noise removal-injection method, *Journal of Water Resources Engineering*, 11, 81-94.
- Qu, G., Guo, X., Min, F. & Zhu, Y. (2010). A Study of the Hydrological Prediction Model Based on Wavelet De-noise Method, Sixth International Conference on Natural Computation, 3763 – 3767.
- Shoaib, M., Shamseldin, A.Y. & Melville, B.W. (2014). Comparative study of different wavelet based neural network models for rainfall–runoff modeling, *Journal of Hydrology*, 515, 47-58.
- Shoaib, M., Shamseldin, A.Y., Melville, B.W. & MuneerKhan, M. (2016). A comparison between wavelet based static and dynamic neural network approaches for runoff prediction, *Journal of Hydrology*, 535, 211-225.
- Tiwari, H., Rai, S.P., Sharma, N. & Kumar, D. (2017). Computational approaches for annual maximum River flow series, *Ain Shams Engineering Journal*, 8(1), 51-58.
- Uysal, G., Şensoy, A. & Şorman, A.A. (2016). Improving daily streamflow forecasts in mountainous Upper Euphrates basin by multi-layer perceptron model with satellite snow products, *Journal of Hydrology*, 543 (B), 630-650.
- Wang, Y., Wang, H., Lei, X., Jiang, Y. & Song, X. (2011). Flood simulation using parallel genetic algorithm integrated wavelet neural networks, *Neurocomputing*, 74(17), 2734-2744.
- Zakizadeh, H.R., Ahmadi, H., Zehtabian, G.R., Moeini, A. & Moghaddamnia, A.R. (2020). A novel study of SWAT and ANN models for runoff simulation with application on dataset of metrological stations, *Physics and Chemistry of the Earth, Parts A/B/C*, 120, 102899.