

پیش‌بینی دبی سیلابی با استفاده از شبکه‌ی عصبی موجک

حمیدرضا باباعلی^۱

رضا دهقانی^{۲*}

چکیده

سیل یکی از بلایای طبیعی مهمی است که همه ساله باعث ایجاد خسارت‌های مالی و جانی فراوانی به جوامع مختلف می‌گردد. به همین دلیل محققان سعی نموده‌اند که تغییرات کمی این پدیده را حتی‌المقدور به طور دقیق مورد بررسی قرار دهند. در این پژوهش جهت تخمین دبی سیلابی ایستگاه کهمان‌الشترا واقع در استان لرستان از مدل شبکه‌ی عصبی موجک استفاده شد و نتایج آن با سایر روش‌های هوشمند از جمله شبکه‌ی عصبی مصنوعی مقایسه گردید. برای این منظور از پارامتر حداکثر بارش ۲۴ ساعته در مقیاس زمانی روزانه با تأخیرهای مختلف در طی دوره‌ی آماری (۱۳۸۰-۱۳۹۱) به عنوان ورودی و دبی حداکثر روزانه به عنوان پارامتر خروجی مدل‌ها انتخاب گردید. معیارهای ضریب همبستگی، ریشه‌ی میانگین مربعات خطای و میانگین قدرمطلق خطای برای ارزیابی و عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج نشان داد هر دو مدل قابلیت خوبی در تخمین دبی سیلابی دارند، لیکن از لحاظ دقت، مدل شبکه‌ی عصبی موجک عملکرد بهتری نسبت به شبکه‌ی عصبی مصنوعی از خود نشان داده است.

کلمات کلیدی: دبی سیلابی، شبکه‌ی عصبی موجک، شبکه‌ی عصبی مصنوعی، الشتر.

۱- استادیار گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم‌آباد، خرم‌آباد

۲- دانشجوی دکترای سازه‌های آبی، دانشگاه لرستان، خرم‌آباد (نویسنده‌ی مسئول)

E-mail:reza.dehghani67@yahoo.com

مقدمه

ایران به دلیل وسعت زیاد، اقلیم‌های مختلف و تغییرهای زمانی و مکانی بارش‌ها در بیشتر حوضه‌های آبخیز، همه‌ساله می‌توان شاهد سیلاب‌های عظیمی در اکثر مناطق کشور بود که بسیاری از آنها، خسارات جانی و مالی فراوانی را به بار می‌آورند (مهدوی، ۱۳۷۶). امروزه یکی از ابزارها و روش‌های مطرح در مقابله با پدیده سیل که در برخی از کشورهای جهان رایج گشته، سیستم‌های پیش‌بینی و هشدار سیل می‌باشد که تجارب دهه‌های اخیر در این کشورها، نشان داده که با اجرا و طراحی صحیح این سیستم‌ها، می‌توان خسارات جانی و مالی ناشی از سیل را به میزان چشمگیری کاهش داد (معماری و حبیب‌نژاد، ۱۳۸۵). امروزه سیستم‌های هوشمند به طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد، که روش شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی از جمله‌ی این مدل‌ها است (خسروی و همکاران، ۱۳۹۱). در سال‌های اخیر استفاده از روش‌های هوشمند مورد بررسی در مطالعات پیش‌بینی دبی سیلابی مورد توجه محققان قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود. نگارش و همکاران (۱۳۹۲) در پژوهشی دیگر جهت پیش‌بینی سیلاب رودخانه‌ی سرباز از شبکه‌ی عصبی مصنوعی و داده‌های روزانه‌ی اقلیمی و هیدرولوژیکی سه ایستگاه سرباز، ایرانشهر و پیردان طی یک دوره‌ی ۲۸ ساله بهره گرفتند برای این منظور از سه شبکه‌ی پرسپترون چندلایه، پس انتشار و Radial Basis جهت پیش‌بینی سیلاب رودخانه‌ی سرباز استفاده کردند با بررسی همبستگی بین این داده‌ها و دبی رودخانه‌ی سرباز پارامترهای مؤثر بر سیلاب انتخاب و پس از نرمالیزه کردن داده‌ها، مدل‌های مختلف ایجاد نمودند و نشان دادند مدل شبکه‌ی عصبی پیش‌بینی بهتری نسبت به روش رگرسیونی از سیلاب رودخانه‌ی سرباز ارائه می‌دهد. نجفی و همکاران (۱۳۹۴) به شبیه‌سازی دبی حداکثر لحظه‌ای در ایستگاه‌های هیدرومتری

هفت‌حوض، سولقان، قلاک و مقصودیبک در کلان‌شهر تهران با استفاده از شبکه عصبی مصنوعی پرداختند در ابتدا با استفاده از نرم‌افزار Excel نمودار دبی‌های حداکثر لحظه‌ای هر کدام از ایستگاه‌های هیدرومتری ترسیم و سپس برای ساختن شبکه‌ی عصبی در نرم‌افزار NeroSlution5، از پیش‌فرض پرسپترون چندلایه (MLPS) جهت شبیه‌سازی و تحلیل داده‌های دبی حداکثر لحظه‌ای ایستگاه‌های مورد مطالعه، استفاده کردند و نشان دادند در همه‌ی ایستگاه‌های مورد بررسی، استفاده از شبکه‌ی عصبی مصنوعی جهت شبیه‌سازی دبی‌های حداکثر لحظه‌ای با استفاده از داده‌های دبی حداکثر روزانه و ماهانه از کارایی بالایی برخوردار است. اوکان^۱ (۲۰۱۲) مدل شبکه‌ی عصبی موجکی برای پیش‌بینی جریان ورودی به مخزن سد کمیر در ترکیه مورد بررسی قرارداده و جهت پیش‌بینی جریان ورودی مخزن سد از مقیاس زمانی ماهانه با ترکیب موجک گسسته و بهینه‌سازی الگوریتم‌های مبتنی بر لونبرگ - مارکوارت استفاده نمود. نتایج حاصله نشان داد شبکه‌ی عصبی موجکی یک مدل مناسب برای پیش‌بینی جریان ورودی به مخزن سد بوده و می‌تواند نسبت به مدل رگرسیون چندگانه عملکرد قابل قبولی داشته باشد. نتایج حاصل از پژوهشی السافی^۲ (۲۰۱۴) که جهت پیش‌بینی سیل در ایستگاه دانگلا سودان از شبکه‌ی عصبی مصنوعی استفاده نمود نشان داد شبکه‌ی عصبی مصنوعی مدلی مناسب و قابل اعتماد جهت پیش‌بینی دبی سیل است. آچور و همکاران^۳ (۲۰۱۵) دقت مدل‌های شبکه‌ی عصبی مصنوعی و رگرسیون خطی چندمتغیره را در پیش‌بینی جریان ایستگاه میربک الجزایر مورد بررسی قرار دادند و نتایج بر اساس معیار ضریب همبستگی نشان داد، مدل شبکه‌ی عصبی مصنوعی عملکرد بهتری در مقایسه با

1- Okkan

2- Elsafi

3- Aichouri et al.,

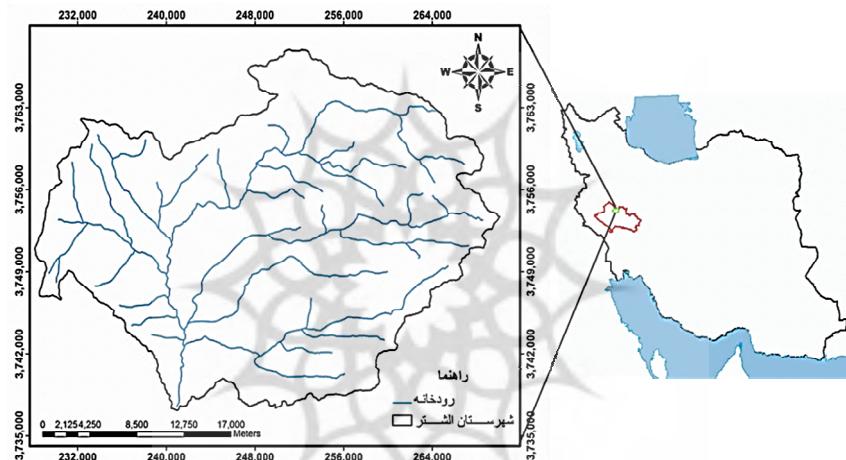
رگرسیون خطی چندمتغیره داشته است. وانتاین و همکاران^۱ (۲۰۱۶) کارایی شبکه‌ی عصبی موجک را جهت پیش‌بینی دبی سیلابی روانه‌ی آلبرتا در کانادا مورد بررسی قرار دادند که نتایج حاصله نشان داد مدل شبکه‌ی عصبی موجک خطاپی ناچیز در تخمین دبی داشته و نیز نسبت به روش شبکه‌ی عصبی مصنوعی در تخمین اکثر مقادیر دقت بالایی دارد. در مجموع با توجه به پژوهش‌های انجام‌شده و ذکر این نکته که دشت الشتر به عنوان مهم‌ترین منبع تأمین‌کننده آب بخش‌های مختلف و نواحی مجاور خود می‌باشد، و نیز از جمله منابع تأمین‌کننده محصولات کشاورزی استان لرستان می‌باشد بنابراین اهمیت تخمین دبی سیلابی و اقدامات مدیریتی جهت جلوگیری از رخداد سیل ضروری است. لذا، هدف از این تحقیق تخمین دبی سیلابی با کمک شبکه‌ی عصبی موجک و مقایسه‌ی نتایج آن با مدل شبکه‌ی عصبی مصنوعی می‌باشد.

مواد و روش‌ها

– منطقه‌ی مورد مطالعه

منطقه‌ی مورد مطالعه شهرستان الشتر واقع در استان لرستان می‌باشد. این منطقه بین طول‌های "۴۸° ۴' شرقی و عرض‌های "۱۲° ۵۸' ۴۷° شمالی واقع شده است. محدوده‌ی مطالعاتی الشتر دارای ۸۱۱ کیلومتر مربع مساحت است که از این مقدار ۱۵۹ کیلومتر مربع دشت با ارتفاع متوسط ۱۶۲۰ متر و ۶۵۲ کیلومتر مربع با ارتفاع متوسط ۲۲۴۰ متر می‌باشد. این دشت دارای یک سفره زیرزمینی آبرفتی می‌باشد و دارای وضعیت آب سطحی و زیرزمینی نسبتاً خوبی می‌باشد. در شکل (۱) موقعیت ایستگاه مطالعاتی نشان داده شده است. در این تحقیق داده‌های متغیرهای کمی در مقیاس زمانی روزانه شامل دبی جریان (Q) بر حسب m³/s و

بارش (P) بر حسب میلی متر (mm) مربوط به ایستگاه کهمن‌الشت واقع در استان لرستان از سال ۱۳۸۰ تا ۱۳۹۱ که در شرکت آب منطقه‌ای استان لرستان در دسترس بود، استفاده شد. در جدول (۱) خصوصیات آماری پارامترهای مورد استفاده نشان داده شد. این رودخانه، فاقد داده‌های مفقود بوده و آزمون تصادفی بودن داده‌ها قبل از تحلیل و مدلسازی انجام گرفت.



شکل (۱) موقعیت منطقه مورد مطالعه

جدول (۱) محدوده‌ی پارامترهای مورد استفاده جهت آموزش و صحبت‌سنگی داده‌ها

پارامتر	آموزش	صحبت‌سنگی
انحراف مینیمم	انحراف چولگی میانگین مازکیم معیار چولگی	انحراف میانگین مازکیم معیار
۵/۲۲۰	۴/۳۱۷	۴۹
۱/۶۱۶	۰/۸۶۸	۶/۳۸۰
		۰/۰۳۸
		۷/۰۱۹
		۳/۰۲۸
		۵۰/۲۰۰
		۰/۲۳۵
		۰/۰۸۸
		Q(t),m ³ /s
		P(t),mm

- شبکه‌ی عصبی موجک

شبکه‌های عصبی مبتنی بر ویولت که ویونت نامیده می‌شوند از ترکیب دو تئوری ویولت‌ها و شبکه‌های عصبی به وجود آمده‌اند (واپنیک^۱، ۱۹۹۸). این شبکه‌ها هم از مزايا و ويژگي های شبکه‌های عصبی برخوردارند و هم جذابیت‌ها و انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولت‌ها و آنالیز چندمقیاسی را دارا می‌باشند. در ویولت‌ها از دو دسته توابع ویولت و توابع مقیاس (scaling functions) استفاده می‌شود. يك خانواده از توابع مقیاس $(\phi(x))$ به صورت زیر معرفی می‌شوند:

$$\phi_{m,k}(x) = 2^{-m/2} \phi(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad \text{رابطه‌ی (۱)}$$

اگر $\phi(x)$ را يك تابع مقیاس مادر در نظر بگیریم، مقادیر 2^{-m} و k به ترتیب مربوط به گسترش و انتقال تابع مقیاس مادر هستند. توابع مقیاس رزولوشن m ، $\phi_{m,k}(x)$ در اصل پایه‌های متعامد فضای برداری v_m در رزولوشن m می‌باشند. به عبارتی فضای برداری v_m حاوی کلیه‌ی تقریب‌های تابع $f(x)$ با رزولوشن m و توسط توابع $\phi_{m,k}(x)$ می‌باشد. بنابراین فضاهای برداری $\{v_m\}$ حاوی تقریب‌های مختلف تابع $f(x)$ در رزولوشن‌های مختلف می‌باشند. حال اگر w_m را فضای برداری متعامد با v_m در رزولوشن m فرض کنیم آنگاه می‌توان دسته‌ای دیگر از پایه‌ای متعامد ضای w_m که ویولت $\psi(x)$ نامیده می‌شوند را نیز به صورت زیر بیان نمود (وانگ و همکاران^۲، ۲۰۰۰):

$$m, k \in \mathbb{Z} \quad \psi_{m,k}(x) = 2^{-m/2} \psi(2^{-m}x - k) \quad \text{رابطه‌ی (۲)}$$

در حالت کلی همه‌ی توابع فیزیکی را می‌توان به کمک ویولت‌ها و توابع مقیاس به صورت زیر بیان نمود:

1- Vapnik

2- Wang et al.,

$$f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{\infty} d_{m,k} \psi_{m,k}(x) \quad \text{رابطه‌ی (۳)}$$

$$f_0(x) = \sum_k a_{0,k} \phi_{0,k}(x) \quad \text{رابطه‌ی (۴)}$$

روابط فوق بیان می‌دارند که هر تابع فیزیکی را می‌توان ابتدا به کمک تعدادی توابع مقیاس در رزولوشن صفر تقریب زد و سپس به کمک توابع ویولت در رزولوشن‌های مختلف آن تقریب را تا میزان دقت مورد نظر ادامه داد.

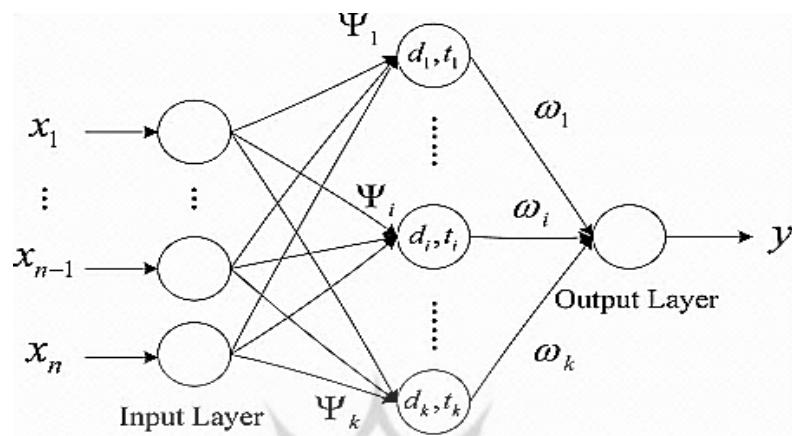
شبکه‌ی عصبی ویونت بر مبنای روابط (۳) و (۴) شکل می‌گیرد و دارای الگوریتم‌های آموزش مخصوص خود می‌باشد که در پژوهش شین و همکاران^۱ (۲۰۰۵) به صورت کامل مورد بررسی قرار گرفته است. لازم به ذکر است در حالت کلی خانواده‌ی ویولت‌های پیوسته نیز به صورت زیربیان می‌شود:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in R \quad \text{رابطه‌ی (۵)}$$

و تبدیل ویولت برای توابع پیوسته به وسیله‌ی رابطه‌ی زیر محاسبه می‌شود:

$$W_{ab}(f) = \tilde{f}_{(ab)} = \langle \psi_{ab}(t), f(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad \text{رابطه‌ی (۶)}$$

در اینجا پارامتر a به عنوان پارامتر گسترش و متناسب با فرکانس می‌باشد (به عبارت دیگر پارامتر تأخیر کوچک متناظر با فرکانس بالا و پارامتر تأخیر بزرگ متناظر با فرکانس پایین می‌باشد) و پارامتر b به عنوان پارامتر انتقال و متناسب با زمان می‌باشد. نمونه‌ایی از ساختار شبکه‌ی سه‌لایه‌ای متشکل از یک لایه‌ی ورودی، یک لایه‌ی مخفی، و یک لایه‌ی خروجی در شکل (۲) نشان داده شده است.



شکل (۲) نمای کلی یک شبکه‌ی عصبی موجک سه‌لایه‌ای

- شبکه‌ی عصبی مصنوعی

امروزه شبکه‌ی عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (نورانی و همکاران^۱، ۲۰۰۹). ساختار شبکه‌ی عصبی معمولاً از لایه‌ی ورودی، لایه‌ی میانی و لایه‌ی خروجی تشکیل شده است. لایه‌ی ورودی یک لایه‌ی انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه‌ی میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه^۲ انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطای^۳ با ساختار شبکه‌ی پیش‌خور^۴ و تعداد سه لایه به طور رضایت‌بخشی در حل

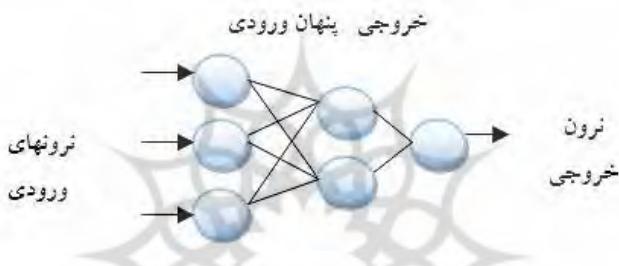
1- Nourani et al.,

2- Multi-Layer Perceptron

3- Back Propagation (BP)

4- Feed Forward

مسائل پیچیده‌ی مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (توكارو جانسون^۱، ۱۹۹۹). از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد (نورانی و همکاران^۲، ۲۰۰۹). نمونه‌ایی از ساختار شبکه‌ی سه لایه‌ای متشکل از یک لایه‌ی ورودی، یک لایه‌ی مخفی، و یک لایه‌ی خروجی در شکل (۳) نشان داده شده است.



شکل (۳) نمای کلی یک شبکه‌ی عصبی مصنوعی سه لایه

معیارهای ارزیابی

در این تحقیق به منظور ارزیابی دقیق و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی (R)، ریشه‌ی میانگین مربعات خطا (RMSE) و میانگین قدر مطلق خطا (MAE) طبق روابط زیر استفاده گردید. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و صفر می‌باشد.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad \text{رابطه‌ی (۸)}$$

1- Tokar and Johnson
2- Nourani et al.,

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - y_i)^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum |x_i - y_i| \quad (10)$$

در روابط بالا و به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی آم، تعداد گام‌های زمانی، و نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی است. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی-محاسباتی نسبت به زمان نیز جهت تحلیل بیشتر نتایج استفاده شده است.

بحث و نتایج

در این پژوهش به منظور مدل‌سازی دبی سیلابی از مدل‌های شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی استفاده شد. یکی از مهم‌ترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. از این‌رو ابتدا همبستگی متقابل^۱ بین متغیرهای ورودی و خروجی محاسبه گردید و پارامترهای ورودی به منظور دستیابی به مدل بهینه جهت تخمین میزان دبی سیلابی ایستگاه الشتر انتخاب و در جدول (۲) ارایه شد.

جدول (۳) همبستگی متقابل بین پارامترهای ورودی و خروجی

	P(t)	P(t-1)	P(t-2)	P(t-3)	P(t-4)
Q(t)	۰/۴۰۰	۰/۳۲۰	۰/۲۵۰	۰/۱۰۰	۰/۱۰۰

در این جدول P(t)، P(t-1)، P(t-2)، P(t-3) و P(t-4) (به ترتیب حداکثر بارش روزانه در یک تا چهار روز قبل) به عنوان ورودی و Q(t) (حداکثر دبی سیلابی در زمان t) به عنوان خروجی مدل در نظر گرفته شد. با توجه به همبستگی متقابل و

1- Cross-correlation

معنی‌دار بین داده‌های ورودی و خروجی، ترکیب‌های مختلفی از پارامترهای ورودی به منظور دستیابی به مدل بهینه جهت تخمین دبی سیلابی استفاده شد که در جدول (۲) آمده است.

جدول (۳) ترکیب‌های منتخب پارامترهای ورودی مدل‌های شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی

شماره	ساختار ورودی	خروجی
۱	P(t)	Q(t)
۲	P(t),P(t-1)	Q(t)
۳	P(t),P(t-1),P(t-2)	Q(t)
۴	P(t),P(t-1),P(t-2),P(t-3)	Q(t)
۵	P(t),P(t-1),P(t-2),P(t-3),P(t-4)	Q(t)

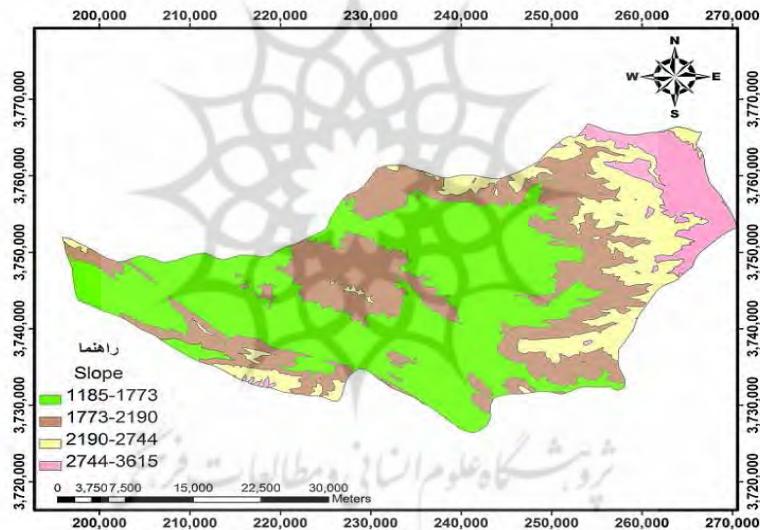
یک نکته‌ی مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه‌ی تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقیقی شبکه می‌شود (ژو و همکاران^۱. ۲۰۰۷). برای نرمال‌سازی داده‌های تحقیق از رابطه‌ی زیر استفاده شده است:

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه‌ی (۱۱)}$$

که در آن X_n مقدار نرمال شده ورودی X_i ، X_{\min} و X_{\max} به ترتیب حداقل و حداقل داده‌ها می‌باشد.

همچنین در شکل (۴) نقشه‌ی شب منطقه‌ی مورد مطالعه نشان داده شد،

همانطور که در این شکل مشخص است بیشترین میزان شبیب منطقه در کلاس ۴ و در ناحیه‌ی شمال شرقی منطقه‌ی مورد مطالعه قرار دارد در صورتی که اکثر قسمت‌های منطقه دارای شبیب کم و در کلاس ۱ قرار دارند که در نتیجه می‌توان اظهار نمود شبیب منطقه که‌مان‌الشتر واقع در استان لرستان از سمت شمال به جنوب کاهش می‌یابد. از سوی دیگر با توجه به اینکه ایستگاه هیدرومتری که‌مان در قسمت جنوب حوضه‌ی آبریز قرار دارد بیشترین میزان دبی خروجی با توجه به شکل (۴) در این ایستگاه عبور می‌نماید.



شکل (۴) نقشه شبیب منطقه مورد مطالعه

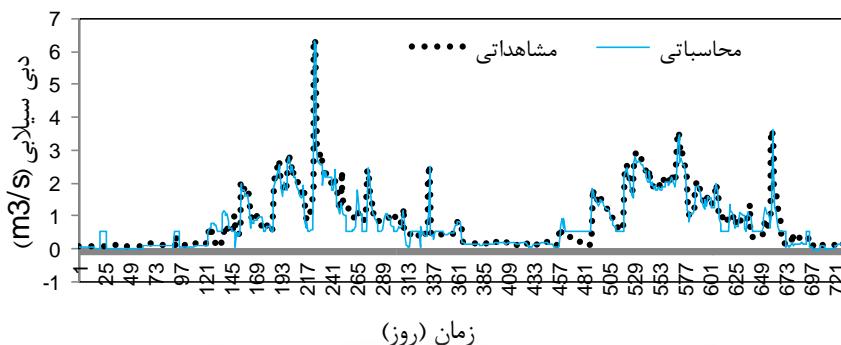
– نتایج شبکه‌ی عصبی موجک

به منظور مدل‌سازی دبی سیلابی ایستگاه الشتر از مدل شبکه‌ی عصبی موجکی با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شده است. همانطور که در

جدول (۴) مشاهده می‌شود ساختار شماره ۵ با ضریب همبستگی ۰/۹۲۰ و کمترین ریشه‌ی میانگین مربعات خطا ۰/۰۰۵ متر و کمترین میانگین قدر مطلق خطا ۰/۰۰۳ متر در مرحله‌ی صحبت‌سنگی نسبت به سایر ساختارها جهت مدل‌سازی دبی سیلابی در مقیاس زمانی روزانه مناسب‌تر خواهد بود. در شکل (۵) نمودار بهترین مدل حاصل‌شده برای داده‌های بخش صحبت‌سنگی نشان داده شده است. که در این شکل (۴) تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان قابل مشاهده است، همانطور که مشاهده می‌شود مدل شبکه‌ی عصبی موجکی در تخمین اکثر مقادیر عملکرد قابل قبولی داشته است. همانطور که در این شکل نشان داده شده است مدل شبکه‌ی عصبی موجک در تخمین اکثر مقادیر کمینه و بیشینه عملکرد خوبی داشته، به طوری که این مقادیر را نزدیک به مقدار واقعی‌شان تخمین زده است، که این نتایج با پژوهش معروفی و همکاران (۱۳۹۱) همخوانی دارد در تبیین این نتایج می‌توان بیان نمود تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چندمقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد.

جدول (۴) ساختار و توابع محرك بهینه در مدل‌سازی شبکه‌های عصبی موجک و شاخص‌های آماری در مراحل آموزش و صحبت‌سنگی

شماره ساختار	تابع محرك	صحبت سنگی			آموزش		
		MAE (m ³ /s)	RMSE (m ³ /s)	R	MAE (m ³ /s)	RMSE (m ³ /s)	R
۱-۵-۱	کلاه مکزیکی	۰/۰۱۷	۰/۰۳۱	۰/۸۲۱	۰/۰۱۵	۰/۰۳۱	۰/۸۳۷
۲-۷-۱	کلاه مکزیکی	۰/۰۱۲	۰/۰۲۰	۰/۸۴۷	۰/۰۱۱	۰/۰۲۳	۰/۸۵۶
۳-۴-۱	کلاه مکزیکی	۰/۰۰۹	۰/۰۱۵	۰/۸۶۴	۰/۰۰۶	۰/۰۱۲	۰/۸۷۰
۴-۶-۱	کلاه مکزیکی	۰/۰۰۵	۰/۰۰۹	۰/۸۸۲	۰/۰۰۴	۰/۰۰۷	۰/۹۰۱
۵-۸-۱	کلاه مکزیکی	۰/۰۰۳	۰/۰۰۵	۰/۹۲۰	۰/۰۰۲	۰/۰۰۳	۰/۹۴۱



شکل (۵) نمودار حاصل از مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل شبکه‌ی عصبی موجک برای داده‌های مرحله‌ی آموزش و صحتسنجی

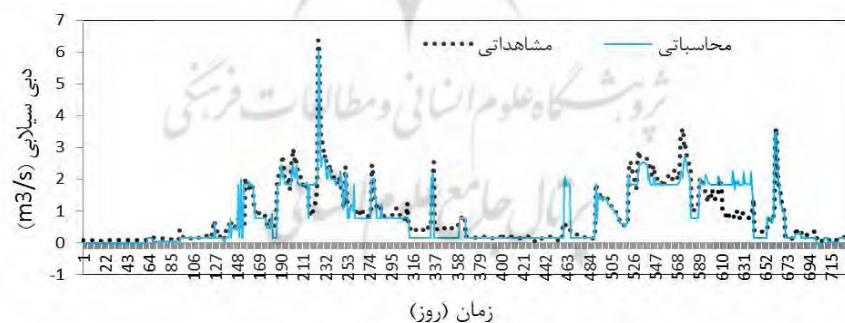
- نتایج شبکه‌ی عصبی مصنوعی

همچنین جهت مقایسه نتایج شبکه‌ی عصبی موجک به منظور مدلسازی دبی سیلانی دشت الشتر واقع در استان لرستان از مدل شبکه‌ی عصبی مصنوعی از نوع شبکه پرسپترون با تعداد نرون‌های متفاوت استفاده شده است. در جدول (۵) نتایج حاصل از مقایسه عملکرد ساختارهای مختلف به کار رفته به همراه پارامترهای آماری داده‌های بخش آموزش و صحتسنجی ارائه شده است. همانطور که در جدول (۵) مشاهده می‌شود ساختار شماره ۵ با بیشترین ضریب همبستگی ۰/۸۹۰ و کمترین ریشه میانگین مربعات خطای ۰/۰۰۶ متر و کمترین میانگین قدرمطلق خطای ۰/۰۰۳ متر در مرحله‌ی صحتسنجی نسبت به سایر ساختارها جهت مدلسازی دبی حداثر روزانه مناسب‌تر خواهد بود. در شکل (۶) نمودار مقادیر مشاهداتی و محاسباتی و نمودار پراکنش نشان داده شده است همان‌طور که در شکل (۶) مشخص است تطابق مقادیر محاسباتی دبی حداثر روزانه مدل شبکه‌ی عصبی مصنوعی با مقادیر مشاهداتی در برخی نقاط وجود دارد. به گونه‌ای که در شکل (۶) این امر مشهود است که مدل مذکور در تخمین نقاط بیشینه و کمینه‌ی ضعیف

عمل کرده است که این نتایج با پژوهش آچور و همکاران (۲۰۱۵) مطابقت دارد در تبیین این نتایج می‌توان بیان نمود در تبیین این نتایج می‌توان بیان نمود با توجه به ساختار شبکه‌های عصبی مصنوعی، ویرگی عمده‌ی آن سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم الگو پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اخلاق قابل توجه در صورت بروز اشکال در بخشی از اتصال‌ها به دلیل توزیع وزن‌های شبکه است.

جدول (۵) ساختار و تابع محرك بهینه در مدل‌سازی شبکه‌های عصبی مصنوعی و شاخص‌های آماری در مراحل آموزش و صحبت‌سنجه

شماره	ساختار	تابع محرك	آموزش			صحبت سنجه		
			MAE (m ³ /s)	RMSE (m ³ /s)	R	MAE (m ³ /s)	RMSE (m ³ /s)	R
۱	۱-۷-۱	تائزانت هیپربولیک	۰/۰۱۷	۰/۰۳۴	۰/۸۱۷	۰/۰۱۶	۰/۰۳۳	۰/۸۲۱
۲	۲-۶-۱	تائزانت هیپربولیک	۰/۰۱۲	۰/۰۲۵	۰/۸۳۶	۰/۰۱۳	۰/۰۲۴	۰/۸۴۸
۳	۳-۸-۱	تائزانت هیپربولیک	۰/۰۰۹	۰/۰۱۸	۰/۸۵۳	۰/۰۰۷	۰/۰۱۵	۰/۸۶۷
۴	۴-۹-۱	تائزانت هیپربولیک	۰/۰۰۵	۰/۰۱۱	۰/۸۷۵	۰/۰۰۵	۰/۰۰۸	۰/۸۹۰
۵	۵-۵-۱	تائزانت هیپربولیک	۰/۰۰۳	۰/۰۰۶	۰/۸۹۰	۰/۰۰۳	۰/۰۰۵	۰/۹۱۰



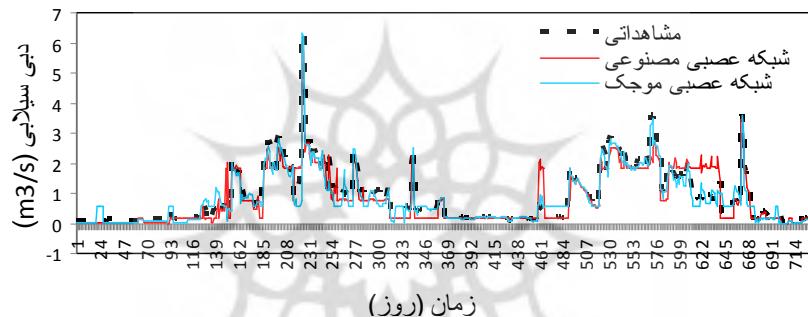
شکل (۶) نمودار حاصل از مقادیر محاسباتی و مشاهداتی نسبت به زمان مدل شبکه‌ی عصبی مصنوعی برای داده‌های مرحله‌ی آموزش و صحبت‌سنجه

– مقایسه‌ی عملکرد مدل‌ها

در ادامه با انتخاب جواب بهینه هر کدام از مدل‌ها و مقایسه آنها با یکدیگر مشخص شد، هر دو مدل با دقت خوبی می‌توانند دبی سیلابی را شبیه‌سازی کنند که از بین مدل‌های به کار رفته مدل شبکه‌ی عصبی موجک، بیشترین دقت $R=0.920$ و کمترین ریشه میانگین مربعات خطأ $RMSE=0.005m$ و کمترین میانگین قدر مطلق خطأ $MAE=0.003$ در مرحله‌ی صحتسنجی را دارد. همانطور که در شکل (۷) نتایج هر دو مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده است مدل شبکه‌ی عصبی موجک در تخمین اکثر مقادیر عملکرد قابل قبولی دارد به گونه‌ای که کلیه مقادیر را نزدیک به مقدار واقعی تخمین زده است. همچنین این نتایج با پژوهش‌های وانتاین و همکاران^۱ (۲۰۱۶) و معروفی و همکاران (۱۳۹۱) همخوانی دارد در تبیین این نتایج می‌توان بیان نمود تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی، بالا می‌برد. سیگنال‌های بالا گذر و پائین گذر حاصل از تجزیه موجک، برآش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم‌تر می‌شود.

جدول (۶) نتایج نهایی حاصل از آموزش و صحبت‌سنگی مدل‌های شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی

آموزش			مدل		
MAE (m ³ /s)	RMSE (m ³ /s)	R	MAE (m ³ /s)	RMSE (m ³ /s)	R
۰/۰۰۳	۰/۰۰۵	۰/۹۲۰	۰/۰۰۲	۰/۰۰۳	۰/۹۴۱
۰/۰۰۳	۰/۰۰۶	۰/۸۹۰	۰/۰۰۳	۰/۰۰۵	۰/۹۱۰



شکل (۷) نمودار پراکنش و مشاهداتی - محاسباتی مقادیر بهینه مدل شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی برای داده‌های ثبت شده‌ی مرحله‌ی آموزش و صحبت‌سنگی

نتیجه‌گیری

در پژوهش حاضر عملکرد مدل‌های شبکه‌ی عصبی موجک و شبکه‌ی عصبی مصنوعی را جهت مدلسازی دبی حداکثر روزانه ایستگاه الشتر واقع در استان لرستان با استفاده از پارامترهای بارش طی تأخیرهای متفاوت، در طی دوره‌ی آماری (۱۳۸۰-۱۳۹۱) مورد ارزیابی قرار گرفت. مقادیر دبی سیلابی مشاهداتی با دبی سیلابی تخمین زده شده این مدل با استفاده معیارهای ارزیابی بررسی گردید. نتایج حاصل از پژوهش نشان داد افزایش تعداد پارامتر مؤثر در مدل‌های مختلف جهت شبیه‌سازی موجب عملکرد بهتر در تخمین دبی سیلابی می‌شود. علاوه‌بر آن

مشاهده گردید در مدل شبکه‌ی عصبی موجک با داشتن حداقل پارامترهای ورودی قادر به پیش‌بینی دمای دبی سیلابی با دقت بالایی می‌باشد. همچنین نتایج تحقیق با استفاده از معیارهای ارزیابی نشان داد که مدل شبکه‌ی عصبی موجک دقت بالا و خطای ناچیز در تخمین دبی سیلابی و قابلیت بسیار بالایی در تخمین برخی مقدادر کمینه، بیشینه و میانی نسبت به شبکه‌ی عصبی مصنوعی دارد. در تبیین این نتایج می‌توان بیان نمود شبکه‌ی عصبی موجک قادر به پیش‌بینی دبی سیلاب در حجم بالا، که احتیاج به اندازه‌گیری و کارهای آزمایشگاهی آنها پرهزینه و زمانبر هستند، می‌باشد. همچنین دقت بالای شبکه‌ی عصبی موجک ناشی از تجزیه‌ی سیگنال با کمک تابع گسسته موجک، منجر به ساده‌تر شدن این سیگنال‌ها شده و باعث ایجاد برتری محسوسی نسبت به مدل شبکه‌ی عصبی مصنوعی می‌باشد. در مجموع این تحقیق نشان می‌دهد استفاده از مدل شبکه‌ی عصبی موجک می‌تواند در زمینه‌ی تخمین دبی سیلابی مؤثر باشد و همچنین این مدل می‌تواند در نوبه‌ی خود برای سهیل توسعه و پیاده‌سازی استراتژی‌های مدیریت منابع آب مفید باشد.

منابع

- نگارش، حسین؛ ازدری‌مقدم، مهدی و محسن آرمش (۱۳۹۲)، کاربرد شبکه‌ی عصبی مصنوعی در شبیه‌سازی و پیش‌بینی سیلاب در حوضه‌ی آبریز سرباز، فصلنامه‌ی جغرافیا و توسعه، دوره‌ی ۱۱، شماره‌ی ۳۱، صص ۱۵-۲۸.
- معماری، علیرضا و محمود حبیب‌نژادروشن (۱۳۸۵)، مطالعه‌ی سیستم‌های پیش‌بینی سیل در ایران و نقش آنها در حفاظت از اراضی و مناطق مسکونی حاشیه‌ی مسیل‌ها، اولین همایش ملی مهندسی مسیل‌ها.
- Aichouri, I., Hani, A., Bougerira, N., Djabri, L., Chaffai, H., Lallahem, S. (2015), **River Flow Model Using Artificial Neural Networks**, Energy Procedia, Vol. 74, No. 4: PP. 1007-1014.
- Elsafi, H., (2014), **Artificial Neural Networks (ANNs) for flood forecasting at Dongola Station in the River Nile, Sudan**, Alexandria Engineering Journal, Vol. 53, No. 3: PP. 655-662.
- Kasiviswanathan, K.S., Jianxun, H., Sudheer, K.P., Joo-Hwa, T., (2016), **Potential application of wavelet neural network ensemble to forecast streamflow for flood management**, Journal of Hydrology, Vol. 536, No. 4: PP. 161-173.
- Kisi, O., Karahan, M., Sen, Z. (2006), **River suspended sediment modeling using fuzzy logic approach**, Hydrol Process, Vol. 20, No. 1: PP. 4351-4362.
- Nagy, H., Watanabe, K., Hirano, M. (2002), **Prediction of sediment load concentration in rivers using artificial neural network model**, Journal of Hydraulics Engineering, Vol. 128, No. 4: PP. 558-559.
- Nourani, V., Kisi, Ö., Komasi, M., (2011), **Two hybrid artificial intelligence approaches for modeling rainfall-runoff process**, Journal of Hydrology, Vol. 402, No. (1-2): PP. 41–59.
- Nourani, V., Alami, MT., Aminfar, MH. (2009), **A combined neural-wavelet model for prediction of Ligvanchai watershed**

- precipitation**, Engineering Applications of Artificial Intelligence, Vol. 22, No. 2: PP. 466-472.
- Okkan, U., (2012), **Wavelet neural network model for reservoir inflow prediction**, Jornal of Scientia Iranica, December, Vol. 19, No. 6: PP. 1445-1455.
- Shin, S., Kyung, D., Lee, S., Taik & Kim, J., Hyun, J., (2005), **An application of support vector machines in bankruptcy prediction model**, Expert Systems with Applications, Vol. 28, No.1: PP. 127-135.
- Tokar, A., Johnson, P. (1999), **Rainfall-Runoff Modeling Using Artificial Neural Networks**, J Hydrol. Eng, Vol. 4, No. 3: PP. 232-239.
- Vapnik, VN. (1988), **Statistical Learning Theory**, Wiley, New York.
- Wang, D., Safavi, AA., Romagnoli, JA., (2000), **Wavelet-based adaptive robust M-estimator for non-linear system identification**, AIChE Journal, Vol. 46, No. 8: PP.1607-1615.
- Zhu, YM., Lu, XX., Zhou, Y., (2007), **Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjian River in the Upper Yangtze Catchment**, Geomorphology, Vol. 84, No. 1: PP. 111-125.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرستال جامع علوم انسانی