

## کاربرد شبکه عصبی موجک در تخمین رسوبات معلق رودخانه‌ها، مطالعه موردی: رودخانه کشکان-لرستان

حسن ترابی پوده<sup>۱\*</sup>، احمد گودرزی<sup>۲</sup> و رضا دهقانی<sup>۳</sup>

<sup>۱</sup> دانشیار، دانشکده کشاورزی، دانشگاه لرستان و <sup>۲،۳</sup> دانشجوی دکتری، دانشکده کشاورزی، دانشکده کشاورزی، دانشگاه لرستان

تاریخ پذیرش: ۱۳۹۷/۰۴/۱۲

تاریخ دریافت: ۱۳۹۶/۱۰/۰۴

### چکیده

شبیه‌سازی و ارزیابی آورد رسوب رودخانه از جمله مسائل مهم در مدیریت منابع آب می‌باشد. اندازه‌گیری مقدار رسوب به روش‌های متداول عموماً مستلزم صرف وقت و هزینه زیادی بوده، گاهی از دقت کافی نیز برخوردار نیست. در این پژوهش برای تخمین رسوبات رودخانه کشکان واقع در استان لرستان، از شبکه عصبی موجک استفاده شد و نتایج آن با روش‌های مرسوم هوشمند همچون شبکه عصبی مصنوعی مقایسه شد. پارامتر دبی، دما، میزان مواد جامد محلول در آب و بارش به‌عنوان ورودی و دبی رسوب به‌عنوان خروجی مدل در مقیاس زمانی ماهانه طی دوره آماری (۱۳۹۳-۱۳۶۴) انتخاب شد. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا و ضریب نش ساتکلیف برای ارزیابی و نیز مقایسه عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج حاصله نشان داد، ساختار ترکیبی توانسته با استفاده از دو روش هوشمند مورد بررسی، در تخمین میزان رسوب نتایج قابل قبولی ارائه کند. لیکن از لحاظ دقت، مدل شبکه عصبی موجک با بیشترین ضریب همبستگی (۰/۸۵۰)، کمترین ریشه میانگین مربعات خطا ( $0/051 \text{ t day}^{-1}$ ) و نیز معیار نش ساتکلیف (۰/۷۵۸) در مرحله صحت‌سنجی در اولویت قرار گرفت. در مجموع نتایج نشان داد که مدل شبکه عصبی موجک توانایی بالایی در تخمین مقادیر کمینه و بیشینه برخوردار است.

**واژه‌های کلیدی:** استان لرستان، دبی رسوب، شبکه عصبی مصنوعی، شبیه‌سازی، مدیریت منابع آب

### مقدمه

آن، باعث ائتلاف سرمایه‌های ملی می‌شود. بدیهی است که دقت پیش‌بینی میزان رسوب وارده به مخازن سدها، بستگی به روش‌های محاسباتی و معادلات ارائه شده در این زمینه دارد. از طرفی، دامنه کاربرد این روش‌ها به سبب پیچیدگی طبیعت رودخانه‌ها و گوناگونی عوامل مؤثر در پدیده انتقال رسوب محدود می‌باشد و نتایج به‌دست آمده اغلب دارای دامنه نوسان زیادی است (Avarideh و همکاران، ۲۰۰۱). امروزه خاصیت غیر خطی، عدم قطعیت ذاتی برآورد رسوب،

پدیده انتقال رسوب از جمله فرایندهای هیدرودینامیکی مهمی است که بسیاری از سامانه‌های فیزیکی و تأسیسات عمرانی را تحت تأثیر قرار می‌دهد و به‌عنوان یکی از بزرگ‌ترین مشکلات بهره‌برداری از منابع آب‌های سطحی در جهان مطرح است. با توجه به نقش و اهمیت رسوب در عمر مفید سدهای کشور که نقش بزرگی را در توسعه اقتصادی کشور ایفا می‌کنند، عدم توجه به اندازه‌گیری و محاسبه دقیق

بالاتری برخوردار است. Zhu و همکاران (۲۰۰۷) با مطالعه بر روی رودخانه لانگچوانگ جینگ در چین، به مدل‌سازی دبی رسوب با استفاده از شبکه‌های عصبی مصنوعی پرداختند و به این نتیجه دست یافتند که این روش در برآورد بار معلق رسوب موفق بوده است. از سوی دیگر، Kisi و همکاران (۲۰۰۹) در پژوهشی عملکرد مدل‌های شبکه عصبی مصنوعی و سامانه استنتاج عصبی-فازی تطبیقی را در تخمین رسوبات معلق دو ایستگاه کالوس و سالور در ترکیه مورد بررسی قرار دادند، نتایج نشان داد که مدل شبکه عصبی مصنوعی دقت قابل قبولی برای تخمین رسوبات از خود نشان داده است. Nourani و Andalib (۲۰۱۵) عملکرد مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی را برای پیش‌بینی دبی رسوبی رودخانه می‌سی‌سی‌پی با استفاده از پارامترهای دبی و دبی رسوبی در طی دوره آماری ۱۹۸۲-۲۰۱۲ در مقیاس زمانی ماهانه و روزانه مورد بررسی قرار دادند و نشان دادند که مدل شبکه عصبی موجک در مقیاس زمانی ماهانه برای پیش‌بینی دبی رسوبی نسبت به سایر روش‌های هوشمند از دقت قابل توجهی برخوردار است.

Sudhishri و همکاران (۲۰۱۶) به بررسی عملکرد مدل‌های شبکه عصبی مصنوعی، شبکه عصبی موجک و رگرسیون خطی برای پیش‌بینی دبی رسوبی رودخانه رامگانا در حوضه هیمالیا پرداختند و به این نتیجه رسیدند که مدل شبکه عصبی موجک از کارایی بهتری نسبت به سایر مدل‌های هوشمند در پیش‌بینی دبی رسوبی برخوردار است. رودخانه کشکان یکی از مهمترین رودخانه‌های پر آب استان لرستان و مهمترین منبع تأمین کننده آب بخش‌های مختلف نواحی مجاور خود می‌باشد. پژوهش‌های انجام شده نشان می‌دهند که در طی دهه‌های گذشته از میزان جریان خروجی این رودخانه در حوضه کاسته شده که اهمیت مدل‌سازی دبی رسوب آب این رودخانه و اقدامات مدیریتی برای بهبود کیفیت آب آن را بیش از پیش ضروری می‌کند. بر این اساس، با توجه به اهمیت میزان تولید رسوب معلق و کمبود امکانات موجود در ایستگاه‌های هیدرومتری برای تعیین مقدار رسوب واقعی، این پژوهش با هدف کلی شناخت و آزمودن

نیاز به اطلاعات وسیع و پیچیده بودن مدل‌های فیزیکی از جمله دلایلی بوده است که باعث شده محققان برای پیش‌بینی پدیده‌های غیر خطی، روش‌های هوشمند را به کار گیرند که روش شبکه عصبی موجک<sup>۱</sup> و شبکه عصبی مصنوعی<sup>۲</sup> از جمله این روش‌ها است. شبکه‌های عصبی مصنوعی با الهام از سامانه پردازش اطلاعات مغز طراحی شده و توانایی آن در تقریب الگوهای یک مسئله سبب افزایش دامنه کاربرد این شبکه‌ها شده است. در سال‌های اخیر، استفاده از روش‌های هوشمند در مطالعات دبی رسوبی مورد توجه محققین قرار گرفته است که از جمله می‌توان به موارد ذیل اشاره کرد.

Dehghani و همکاران (۲۰۰۸) با مقایسه تخمین بار معلق به دو روش منحنی سنجه رسوب و شبکه عصبی مصنوعی به این نتیجه دست یافتند که شبکه عصبی مصنوعی می‌تواند نسبت به روش منحنی سنجه با دقت بسیار مناسب و با اطمینان بیشتر و بدون دسته‌بندی داده‌ها برای تخمین بار معلق رسوب مورد استفاده قرار گیرد. Vali و همکاران (۲۰۰۸) در تحلیل مقایسه عملکرد شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی برای پیش‌بینی رسوب معلق در حوزه آبخیز اسکندری نشان دادند، شبکه عصبی مصنوعی مدلی مناسب برای برآورد بار رسوبی حوزه آبخیز است. نتایج حاصل از پژوهش Babaei و همکاران (۲۰۱۰) که برای تخمین رسوبات معلق چند ایستگاه هیدرومتری منتخب در استان گلستان از شبکه عصبی مصنوعی استفاده کردند، نشان داد که مدل شبکه عصبی مصنوعی از دقت بالایی در برآورد بار معلق برخوردار است. در پژوهشی دیگر، Dehghani و Vafakhah (۲۰۱۲) در مقایسه روش‌های منحنی سنجه رسوب و شبکه عصبی، بیان داشتند که دقت روش شبکه عصبی نسبت به روش‌های منحنی سنجه رسوب بالاتر است. Sarangi و Bhattacharya (۲۰۰۵) در پژوهشی دبی رسوبی حوضه بانها هندوستان را با استفاده از مدل‌های شبکه‌های عصبی و مدل‌های رگرسیون برآورد کرده و پس از مقایسه نتایج، دریافتند که مدل شبکه عصبی مصنوعی از دقت

<sup>1</sup> Wavelet Neural Network

<sup>2</sup> Artificial Neural Network


چون ایجاد جزایر رسوبی در مسیر رودخانه، کاهش عمر مفید سدها و ظرفیت ذخیره مخازن، خوردگی تأسیسات سازه‌های آبی، وارد شدن خسارات به مزارع، رسوب‌گذاری در کف کانال و بسیاری مسایل و مشکلات دیگر می‌شود. در این تحقیق، به‌منظور پیش‌بینی دبی رسوبی رودخانه کشکان واقع در استان لرستان از داده‌های ماهانه ایستگاه هیدرومتری این رودخانه در طول دوره آماری از سال ۱۳۶۴ تا ۱۳۹۳ از شرکت آب منطقه‌ای استان لرستان اخذ و استفاده شد.

برای مدل‌سازی پارامترهای دبی جریان (Q)، دما (T)، میزان مواد جامد محلول در آب (TDS) و بارش (P) به‌عنوان ورودی و دبی رسوبی (QS) به‌عنوان پارامتر خروجی استفاده شد. این رودخانه، فاقد داده‌های مفقود بوده، آزمون تصادفی بودن داده‌ها قبل از تحلیل و مدل‌سازی انجام گرفت. موقعیت منطقه مورد مطالعه در شکل ۱ نشان داده شده است.

مدل‌های شبکه‌های عصبی موجک و شبکه عصبی مصنوعی در برآورد میزان رسوب بار معلق و مقایسه نتایج آن‌ها با مقادیر مشاهده شده در ایستگاه کشکان به اجرا در آمده است.

## مواد و روش‌ها

**منطقه مورد پژوهش:** حوزه آبخیز کشکان با مساحت ۹۲۷۴/۴ کیلومتر مربع در ناحیه جنوب غربی ایران واقع شده و گستره جغرافیایی آن از ۴۶° ۵۰' تا ۴۶° ۱' عرض ۵۰° طول شرقی و از ۳۲° ۴۰' تا ۳۴° ۲۳' عرض شمالی قرار دارد. این رودخانه یکی از شعب مهم و پر آب رودخانه کرخه بوده، آب‌های منطقه وسیعی از استان لرستان را جمع‌آوری و به رودخانه کرخه می‌رساند. یکی از مسائل مهم در حوزه آبخیز کشکان، وقوع سیلاب‌های بزرگ با حجم رسوب انتقالی زیاد است که هر ساله موجب خسارت‌های بی‌شماری در زمینه انتقال رسوب و رسوب‌گذاری، بروز پیامدهایی



شکل ۱- منطقه مورد پژوهش

$$\varphi_{m,k}(x) = 2^{-m/2} \varphi(2^{-m}x - k) \quad m, k \in \mathbb{Z} \quad (1)$$

اگر  $\varphi(x)$  یک تابع مقیاس مادر در نظر گرفته شود، مقادیر  $2^{-m}$  و  $k$  به‌ترتیب مربوط به گسترش و انتقال تابع مقیاس مادر هستند. توابع مقیاس قدرت تفکیک  $m$  در  $\varphi_{m,k}(x)$  در اصل پایه‌های متعامد فضای برداری  $v_m$  در قدرت تفکیک  $m$  می‌باشند. به‌عبارتی، فضای برداری  $v_m$  حاوی کلیه تقریب‌های تابع  $f(x)$  با قدرت تفکیک  $m$  و به‌وسیله توابع  $\varphi_{m,k}(x)$  است. بنابراین فضاهای برداری  $\{v_m\}$  حاوی تقریب‌های مختلف تابع  $f(x)$  در قدرت تفکیک‌های مختلف

**شبکه عصبی موجک:** شبکه‌های عصبی مبتنی بر ویولت که ویولت نامیده می‌شوند، از ترکیب دو تئوری ویولت‌ها و شبکه‌های عصبی به وجود آمده‌اند (Vapnik, ۱۹۹۸). این شبکه‌ها هم از مزایا و ویژگی‌های شبکه‌های عصبی برخوردارند و هم جذابیت‌ها و انعطاف‌پذیری‌ها و مبانی ریاضی مستحکم ویولت‌ها و تحلیل چند مقیاسی را دارا می‌باشند. در ویولت‌ها از دو دسته توابع ویولت و توابع مقیاس (scaling functions) استفاده می‌شود. یک خانواده از توابع مقیاس  $\varphi(x)$  به‌صورت زیر معرفی می‌شوند.

پنهان می‌باشد، درحالی‌که در شبکه‌های عصبی موجک، توابع موجک به‌عنوان تابع فعال‌سازی لایه پنهان شبکه پیش‌خور، در نظر گرفته می‌شوند. در این شبکه‌ها هر دو پارامتر انتقال و تغییر مقیاس موجک‌ها در کنار وزن‌هایشان بهینه می‌شوند. در مجموع گام‌های مهم در آموزش و صحت‌سنجی شبکه عصبی موجک به‌صورت زیر است.

الف- داده‌های ورودی به دو دسته برای آموزش شبکه و صحت‌سنجی مورد استفاده قرار می‌گیرند.

ب- موجک مادر با احراز شرایط یاد شده پس از اعمال ضرایب انتقال و مقیاس مناسب به موجک فرزند تبدیل می‌شود.

ج- توابع فعال‌سازی نرون‌های لایه پنهان شبکه عصبی با انواع موجک‌های فرزند جایگزین می‌شود.

د- شبکه عصبی ویولت ایجاد شده با استفاده از مجموعه داده‌های مربوط به آموزش شبکه، آموزش داده می‌شود.

ه- عملکرد کلی شبکه موجک با تجزیه و تحلیل نحوه تخمین داده‌های صحت‌سنجی مورد بررسی قرار می‌گیرد و با رضایت‌بخش بودن عملکرد شبکه مرحله آموزش به اتمام می‌رسد. در غیر این صورت مراحل قبل تا دستیابی به بهترین حالت مورد ارزیابی قرار می‌گیرد (Kaveh و Iranmanesh، ۲۰۰۴). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی و یک لایه خروجی در شکل ۲ نشان داده شده است.

**شبکه عصبی مصنوعی:** امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد (Nourani و همکاران، ۲۰۰۹). ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چند لایه<sup>۱</sup> انجام گرفت.

می‌باشند. حال اگر فضای برداری متعامد با  $v_m$  در قدرت تفکیک  $m$  فرض شود، آنگاه می‌توان دسته‌ای دیگر از پایه‌های متعامد فضای  $wm$  که ویولت  $\psi(x)$  نامیده می‌شوند را نیز به‌صورت زیر بیان کرد (Wang و همکاران، ۲۰۰۰).

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

در حالت کلی همه توابع فیزیکی را می‌توان به کمک ویولت‌ها و توابع مقیاس به‌صورت زیر بیان کرد.

$$f(x) = f_0(x) + \sum_{m=-\infty}^0 \sum_{k=-\infty}^{\infty} d_{m,k} \psi_{m,k}(x) \quad (3)$$

$$f_0(x) = \sum_k a_{0,k} \phi_{0,k}(x) \quad (4)$$

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.

شبکه عصبی ویولت بر مبنای روابط (۳) و (۴) شکل می‌گیرد و دارای الگوریتم‌های آموزش مخصوص خود می‌باشد که در پژوهش Shin و همکاران (۲۰۰۵) به‌صورت کامل مورد بررسی قرار گرفته است. لازم به ذکر است که در حالت کلی خانواده ویولت‌های پیوسته نیز به‌صورت زیر بیان می‌شود.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R} \quad (5)$$


و تبدیل ویولت برای توابع پیوسته به‌وسیله رابطه زیر محاسبه می‌شود.

$$W_{a,b}(f) = \tilde{f}_{(a,b)} = \langle \psi_{a,b}(t), f(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (6)$$

که در آن، پارامتر  $a$  به‌عنوان پارامتر گسترش و متناسب با فرکانس می‌باشد (به‌عبارت دیگر پارامتر تأخیر کوچک متناظر با فرکانس بالا و پارامتر تأخیر بزرگ متناظر با فرکانس پایین می‌باشد) و پارامتر  $b$  به‌عنوان پارامتر انتقال و متناسب با زمان است.

**الگوریتم ویولت:** تلفیق تئوری موجک با مفاهیم شبکه عصبی، منجر به ایجاد شبکه عصبی موجک می‌شود و به‌کارگیری آن می‌تواند جایگزین مناسبی در شبکه‌های عصبی پیش‌خور برای تخمین و تقریب توابع غیر خطی اختیاری باشد. در شبکه‌های عصبی پیش‌خور، دارای تابع فعال‌سازی سیگموئید در لایه

<sup>1</sup> Multi-layer perceptron



شکل ۲- نمای کلی یک شبکه عصبی موجک سه لایه‌ای

نسبت به زمان نیز برای مقایسه و تحلیل بیشتر نتایج استفاده شده است.

### نتایج و بحث

یکی از مهمترین مراحل در مدل‌سازی، انتخاب ترکیب مناسبی از متغیرهای ورودی است. در مدل‌های هوشمند انتخاب ورودی‌های اولیه مناسب و تأثیرگذار در پدیده، به منظور آموزش ماهیت سازوکار حاکم بر پدیده باعث بهبود عملکرد خواهد شد. بنابراین، در الگوسازی دبی رسوبی حوضه کشکان نیز سعی شد تا مؤثرترین داده‌های مشاهداتی به‌عنوان داده‌های آموزشی انتخاب شود. از این‌رو ابتدا همبستگی متقابل<sup>۱</sup> بین متغیرهای ورودی و خروجی محاسبه شد و میزان همبستگی بین پارامترهای ورودی و خروجی به منظور دستیابی به مدل بهینه برای مدل‌سازی دبی رسوبی در جدول ۲ ارائه شد. با توجه به این‌که مقدار همبستگی متقابل بین داده‌های ورودی و خروجی که مطابق جدول ۲ بیشتر از ۰/۵۰۰ حاصل شد، ترکیب‌های مختلفی از پارامترهای ورودی به منظور دستیابی به مدل بهینه برای تخمین دبی رسوبی حوضه کشکان استفاده شد که در جدول ۳ مشاهده می‌شود.

در این پژوهش، به منظور پیش‌بینی دبی رسوبی رودخانه کشکان واقع در استان لرستان، از داده‌های ماهانه ایستگاه هیدرومتری این رودخانه، طول دوره آماری از سال ۱۳۶۴ تا ۱۳۹۳ در مقیاس زمانی ماهانه که از شرکت آب منطقه‌ای استان لرستان اخذ شد، استفاده به عمل آمد. برای مدل‌سازی پارامتر دبی

در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا<sup>۱</sup> با ساختار شبکه پیش‌خور<sup>۲</sup> و تعداد سه لایه به‌طور رضایت‌بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد (Nourani و همکاران، ۲۰۱۱). از رایج‌ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی، می‌توان به توابع محرک سیگموئید و تانژانت هیپربولیک اشاره کرد (Johnson و Tokar، ۱۹۹۹). نمونه‌ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی و یک لایه خروجی در شکل ۳ نشان داده شده است.

**معیارهای ارزیابی:** در این تحقیق به منظور ارزیابی دقت و کارایی مدل‌ها، از نمایه‌های ضریب همبستگی (R)، ریشه میانگین مربعات خطا (RMSE) و ضریب نش ساتکلیف (NS) طبق روابط زیر استفاده شد. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (10)$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad -\infty \leq NS \leq 1 \quad (11)$$

که در آن‌ها،  $x_i$  و  $y_i$  به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی  $t_i$ ام،  $N$  تعداد گام‌های زمانی،  $\bar{x}$  و  $\bar{y}$  نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی است. علاوه بر معیارهای بالا از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی-محاسباتی

<sup>۱</sup> Back Propagation (BP)

<sup>۲</sup> Feed forward


<sup>۳</sup> Cross-correlation

اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود (Zhu و همکاران، ۲۰۰۷). برای نرمال‌سازی داده‌های تحقیق از رابطه زیر استفاده شده است.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (12)$$

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

جریان (Q)، دما (T)، میزان مواد جامد محلول در آب (TDS) و بارش (P) به عنوان ورودی و دبی رسوبی ( $Q_s$ ) به عنوان پارامتر خروجی مدل‌ها به کار برده شد. در ادامه، نتایج مدل مورد استفاده ارائه می‌شود. یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد، این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند.



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه

جدول ۲- همبستگی متقابل بین پارامترهای ورودی و خروجی

	Q(t)	T(t)	TDS(t)	P(t)
$Q_s(t)$	۰/۵۰۰	۰/۸۹۰	۰/۸۶۹	۰/۸۷۵

جدول ۳- ترکیب‌های منتخب پارامترهای ورودی مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

شماره	ساختار ورودی	خروجی
۱	Q(t)	$Q_s(t)$
۲	Q(t), T(t)	$Q_s(t)$
۳	Q(t), T(t), TDS(t)	$Q_s(t)$
۴	Q(t), T(t), TDS(t), P(t)	$Q_s(t)$

تنظیم پارامترهای شبکه استفاده می‌شود، استفاده شد. همان‌طور که در جدول ۴ مشاهده می‌شود، ساختار شماره ۳ با ضریب همبستگی ۰/۸۵۰ و کمترین ریشه میانگین مربعات خطا ۰/۰۵۱ تن در روز و ضریب نش ساتکلیف ۰/۷۵۸ متر و ضریب نش ساتکلیف ۰/۸۵۷ در مرحله صحت‌سنجی، نسبت به سایر ساختارها برای مدل‌سازی دبی رسوبی، در مقیاس زمانی ماهانه، مناسب‌تر خواهد بود. در شکل ۴، نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت‌سنجی نشان داده شده است که در این شکل تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان قابل مشاهده


**نتایج شبکه عصبی موجک:** به منظور مدل‌سازی دبی رسوبی رودخانه کشکان واقع در استان لرستان از مدل شبکه عصبی موجکی با لایه‌های پنهان و با تعداد نرون‌های متفاوت استفاده شده است. در مدل عصبی موجکی ابتدا موجک مناسب (سیملت) انتخاب شد. سپس با اعمال تبدیل روی داده‌ها، ضرایب تقریب و جزئیات آن‌ها استخراج شد و داده‌ها به وسیله تابع موجک کلاسه مکزیک به عنوان توابع فعال‌سازی که مشتق دوم تابع گوسی بوده، تبدیل می‌شوند. برای آموزش شبکه از الگوریتم گرادیان نزولی که در یادگیری شبکه‌های عصبی و کمینه‌سازی مقدار خطا و

بیشتر مقادیر کمینه و بیشینه عملکرد خوبی داشته، به طوری که این مقادیر را نزدیک به مقدار واقعی شان تخمین زده است.

است. همان‌طور که مشاهده می‌شود، مدل شبکه عصبی موجکی در تخمین بیشتر مقادیر عملکرد قابل قبولی داشته است. به گونه‌ای که در این شکل نشان داده شده است، مدل شبکه عصبی موجک در تخمین

جدول ۴- نتایج شبکه عصبی موجک برای مدل‌های مختلف و شاخص‌های آماری در مراحل آموزش و صحت‌سنجی

شماره	ساختار	تابع محرک	آموزش			صحت‌سنجی		
			NS	RMSE (tonday <sup>-1</sup> )	R	NS	RMSE (tonday <sup>-1</sup> )	R
۱	۱-۸-۱	کلاه مکزیکی	۰/۷۲۸	۰/۰۷۹	۰/۸۳۷	۰/۰۸۸	۰/۶۹۴	NS
۲	۲-۵-۱	کلاه مکزیکی	۰/۷۴۵	۰/۰۶۳	۰/۸۵۴	۰/۰۸۲	۰/۷۱۵	NS
۳	۳-۷-۱	کلاه مکزیکی	۰/۷۶۱	۰/۰۴۸	۰/۸۷۰	۰/۰۶۴	۰/۷۳۸	NS
۴	۴-۶-۱	کلاه مکزیکی	۰/۷۸۴	۰/۰۳۱	۰/۸۹۱	۰/۰۵۱	۰/۷۵۸	NS




شکل ۴- نمودار مقادیر محاسباتی و مشاهداتی مدل شبکه عصبی موجک برای داده‌های ثبت‌شده مرحله صحت‌سنجی

۵ مشاهده می‌شود، ساختار شماره ۴ با بیشترین ضریب همبستگی ۰/۸۳۴ و کمترین ریشه میانگین مربعات خطا ۰/۰۶۳ تن در روز و ضریب نش ساتکلیف ۰/۷۴۰ در مرحله صحت‌سنجی، نسبت به سایر ساختارها برای مدل‌سازی میزان دبی رسوبی مناسب‌تر خواهد بود. در شکل ۵، نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت‌سنجی نشان داده شده است. در شکل ۵، تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان نشان داده شده است. این شکل، نشان می‌دهد که شبکه عصبی مصنوعی در تخمین مقادیر بیشینه عملکرد خوبی نداشته است، به طوری که این مقادیر را نزدیک به مقدار واقعی شان تخمین زده است.

**نتایج شبکه عصبی مصنوعی:** به منظور مقایسه نتایج مدل شبکه عصبی موجک، از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون چند لایه با لایه پنهان با تعداد نرون‌های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده شد. آموزش شبکه‌های پرسپترون چند لایه با استفاده از الگوریتم آموزش، پس انتشار خطا بنام الگوریتم لونیبرگمارکوارت به دلیل هم‌گرایی سریع‌تر در آموزش شبکه، استفاده شد. 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

جدول ۵- ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی مصنوعی و شاخص‌های آماری در مراحل آموزش و صحت‌سنجی

شماره	ساختار	تابع محرک	آموزش		صحت‌سنجی	
			RMSE (tonday <sup>-1</sup> )	R	RMSE (tonday <sup>-1</sup> )	R
۱	۱-۶-۱	تانژانت هیپربولیک	۰/۸۱۴	۰/۸۳	۰/۷۹۱	۰/۷۰۳
۲	۲-۴-۱	تانژانت هیپربولیک	۰/۸۳۶	۰/۶۹	۰/۸۰۶	۰/۷۱۲
۳	۳-۷-۱	تانژانت هیپربولیک	۰/۸۵۴	۰/۵۱	۰/۸۱۸	۰/۷۲۸
۴	۴-۸-۱	تانژانت هیپربولیک	۰/۸۶۷	۰/۴۴	۰/۸۳۴	۰/۷۴۰



شکل ۵- نمودار مقادیر محاسباتی و مشاهداتی مدل شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله صحت‌سنجی

قبولی از خود نشان داده است، در حالی که مدل شبکه عصبی مصنوعی در تخمین نقاط مشاهداتی بیشینه، توان قابل قبولی نداشته است، که این امر نشان از برتری مدل شبکه عصبی موجک نسبت به شبکه عصبی مصنوعی دارد. همچنین، با توجه به نتایج هر دو روش مذکور، ساختار ترکیبی شماره ۴ بیشترین دقت را از بین چهار ساختار مورد بررسی از خود نشان داده است. بنابراین، می‌توان اظهار کرد که علاوه بر دبی و درجه حرارت، میزان مواد جامد محلول در آب در میزان رسوب پایین‌دست نقش به‌سزایی دارد، بدین‌صورت که میزان مواد جامد محلول در آب با ذرات معلق رسوب در این منطقه مورد مطالعه ارتباط داشته، موجب کاهش میزان رسوب در این منطقه شده است. این نتایج با نتایج پژوهش‌های Sudhishri و همکاران (۲۰۱۶) و Nourani و همکاران (۲۰۱۵) هم‌خوانی دارد. در تبیین نتایج به‌دست آمده می‌توان بیان کرد که تبدیل موجکی با جدا کردن سیگنال به فرکانس‌های بالا و پائین، ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته، دقت مدل را تا حد قابل توجهی بالا می‌برد. سیگنال‌های بالا گذر و پایین گذر

**مقایسه عملکرد مدل‌ها:** در ادامه با انتخاب جواب بهینه هر کدام از مدل‌های هوشمند و مقایسه آن‌ها با یکدیگر مشخص شد، هر دو مدل با دقت خوبی می‌توانند دبی رسوبی رودخانه کشکان را شبیه‌سازی کنند. همان‌طور که در جدول ۶ مشاهده می‌شود، از بین مدل‌های به‌کار رفته، شبکه عصبی موجک با بیشترین دقت (۰/۸۵۰) و کمترین ریشه میانگین مربعات خطا (۰/۰۵۱) تن در روز) و بیشترین ضریب نش-ساتکلیف (۰/۷۵۸) در مرحله صحت‌سنجی، انتخاب شد. مقایسه نتایج مدل‌های شبکه عصبی موجک با مدل شبکه عصبی مصنوعی، حاکی از نزدیک بودن نتایج این دو مدل می‌باشد. در شکل ۶، نتایج مدل انتخاب شده دبی رسوبی در هر دو روش، نسبت به مقادیر مشاهداتی نشان داده شده است. همان‌طور که ملاحظه می‌شود، هر دو روش در تخمین بیشتر مقادیر خوب عمل کرده، در حالی که روش شبکه عصبی موجک، مقادیر کمینه، بیشینه و میانی را به‌خوبی پوشش داده است. همان‌طور که در شکل ۶ مشخص است، شبکه عصبی موجک در تخمین نقاط مشاهداتی کمینه و بیشینه دبی رسوبی عملکرد قابل




نمودار آن نسبت به نمونه داده‌های ثبت شده دوره آماری ترسیم شد (شکل ۷). همان‌طور که در این شکل دیده می‌شود، برای مدل‌های مذکور (شبکه عصبی موجک و شبکه عصبی مصنوعی) بیشتر خطا در نوار  $\pm 5$  درصد قرار گرفته است و بیشترین میزان خطای مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی به ترتیب  $14/055$  - و  $18/740$  - درصد از میانگین مقادیر مشاهداتی می‌باشد.

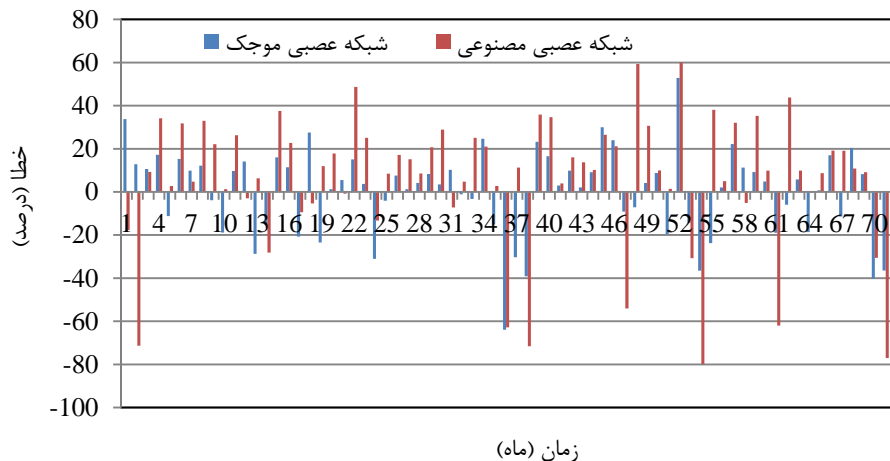
حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد. به علاوه بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم‌تر می‌شود. در نهایت اختلاف مقادیر مشاهداتی میزان دبی رسوبی و محاسباتی بهینه دو مدل به صورت درصدی از میانگین مقادیر مشاهداتی (مقدار خطا)، محاسبه و

جدول ۶- نتایج نهایی حاصل از آموزش و صحت‌سنجی روش‌های شبکه عصبی موجک و شبکه عصبی مصنوعی

مدل	آموزش			صحت‌سنجی		
	R	RMSE (tonday <sup>-1</sup> )	NS	R	RMSE (tonday <sup>-1</sup> )	NS
شبکه عصبی موجک	۰/۸۹۱	۰/۰۳۱	۰/۷۸۴	۰/۸۵۰	۰/۰۵۱	۰/۷۵۸
شبکه عصبی مصنوعی	۰/۸۶۷	۰/۰۴۴	۰/۷۶۸	۰/۸۳۴	۰/۰۶۳	۰/۷۴۰



شکل ۶- نمودار پراکنش و مشاهداتی-محاسباتی مقادیر بهینه مدل شبکه عصبی موجک و شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله صحت‌سنجی



شکل ۷- نمودار خطای بهینه هر دو مدل به صورت درصدی از میانگین مقادیر مشاهداتی

## نتیجه‌گیری

در این پژوهش، سعی بر آن شد که عملکرد مدل‌هایی برای شبیه‌سازی دبی رسوبی رودخانه کشکان واقع در استان لرستان مورد ارزیابی قرار گیرد. مدل‌های به‌کار گرفته شده شامل شبکه عصبی موجک و شبکه عصبی مصنوعی می‌باشد. مقادیر دبی رسوبی مشاهداتی با دبی رسوبی تخمین زده شده در مدل‌های مذکور (شبکه عصبی موجک و شبکه عصبی مصنوعی)، با استفاده از معیارهای ارزیابی مورد مقایسه قرار گرفت. نتایج تحقیق را می‌توان به صورت زیر خلاصه کرد.

نتایج حاصل از پژوهش نشان داد که افزایش تعداد پارامترهای مؤثر در مدل‌های مختلف برای شبیه‌سازی دبی رسوبی موجب عملکرد بهتر در مدل‌سازی می‌شود که با نتایج پژوهش Satari و همکاران (۲۰۱۶) و Rajabi و همکاران (۲۰۱۵) هم‌خوانی دارد. تجزیه و تحلیل نتایج پژوهش‌های مذکور بیان‌کننده این است که افزایش تعداد پارامترهای مؤثر در ورودی موجب گسترش حافظه مدل برای تخمین مقادیر خروجی می‌باشد و همچنین، باعث شده تعداد داده‌ها برای آموزش شبکه بیشتر شده و شبکه به‌خوبی تعمیم داده شود. همچنین، نتایج حاصل از پژوهش نشان داد که

مدل شبکه عصبی موجک، دقت بالاتر و خطای کمتری نسبت به شبکه عصبی مصنوعی دارد. در تبیین این نتایج می‌توان بیان کرد که شبکه عصبی موجک قادر به پیش‌بینی دبی رسوبی در حجم بالا که اندازه‌گیری و کارهای آزمایشگاهی آن‌ها پرهزینه و زمان‌بر هستند، می‌باشد. همچنین، دقت بالای شبکه عصبی موجک ناشی از تجزیه سیگنال با کمک تابع گسسته موجک، منجر به ساده‌تر شدن این سیگنال‌ها شده، باعث ایجاد برتری محسوسی نسبت به مدل شبکه عصبی مصنوعی است. در مجموع این تحقیق نشان می‌دهد، استفاده از مدل شبکه عصبی موجک می‌تواند در زمینه پیش‌بینی دبی رسوبی رودخانه‌ها مؤثر باشد و همچنین، این مدل می‌تواند در نوبه خود برای تسهیل توسعه و پیاده‌سازی استراتژی‌های مدیریت آب‌های سطحی مفید باشد.

## تشکر و قدردانی

نویسندگان مقاله از شرکت آب منطقه‌ای استان لرستان که در جمع‌آوری داده‌های مورد نیاز این پژوهش نهایت همکاری را به عمل آوردند، صمیمانه تشکر می‌کند.

## منابع مورد استفاده

1. Avarideh, F., M. Banihabib and A. Tahershamsi. 2000. Application of artificial neural networks for estimating sediment discharge of rivers. 3rd Iranian Hydraulic Conference, Tehran University (in Persian).
2. Babaei, A., H. Pahlavani and A. Salajegheh. 2009. Evaluation of the efficiency of artificial neural network model in estimating daily suspended sediment intelligence in selected hydrometric stations in Golestan Province. Journal of Watershed Management Sciences and Engineering, 4(13): 61-64 (in Persian).
3. Dehghani, A., M. Zanganeh, A. Mosaedi and N. Kohestani. 2008. Comparison of suspended sediment estimation by artificial neural network and sediment rating curve methods, case study: Doogh River in Golestan Province. Journal of Agricultural Sciences and Natural Resources, 16(1): 266-278 (in Persian).
4. Dehghani, N and M. Vafakhah. 2012. Comparison of daily suspended sediment load estimations by sediment rating curve and neural network models, case study: Ghazaghli Station in Golestan Province. Journal of Water and Soil Conservation Studies, 20(2): 221-230 (in Persian).
5. Kaveh, A. and A. Iranmanesh. 2004. Artificial neural network in optimization of structures. 3rd edition, Publication of Building and Housing Research Center (in Persian).
6. Nourani, V., M.T. Alami and M.H. Aminfar. 2009. A combined neural-wavelet model for prediction of Ligvanchai Watershed precipitation. Engineering Applications of Artificial Intelligence, 22(3): 466-472.
7. Nourani, V., O. Kisi and M. Komasi. 2011. Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. Journal of Hydrology, 402(4): 41-59.
8. Nourani, V. and G.R. Andalib. 2015. Daily and monthly suspended sediment load predictions using wavelet based artificial intelligence approaches. Journal of Mountain Science, 12(3): 85-100.

9. Rajabi, M., M. Feizolahpour and Sh. Rostaei. 2014. Estimating suspended sediment concentration by a neural differential evolution and compare it with ANFIS and RBF models, case study: Givi Chay River. *Geography and Development Magazine*, 39(13): 1-16 (in Persian).
10. Sarangi, A. and A.K. Bhattacharya. 2005. Comparison of artificial neural network and regression models for sediment loss prediction from Banha Watershed in India. *Agricultural Water Management*, 78(3): 195-208.
11. Satari, M.T., A. Rezazade Jodi, F. Safdari and F. Ghahremanzadeh. 2015. Performance evaluation of M5 tree model and support vector regression methods in suspended sediment load modeling. *Journal of Water and Soil Conservation*, 6(1): 109-124 (in Persian).
12. Shin, S., D. Kyung, S. Lee, J. Taik and J. Hyun. 2005. An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28(3): 127-135.
13. Sudhishri, S., A. Kumar and J.K. Singh. 2016. Comparative evaluation of neural network and regression based models to simulate runoff and sediment yield in an outer Himalayan Watershed. *Journal of Agricultural Science and Technology*, 18(3): 681-694.
14. Tokar, A.S. and P.A. Johnson. 1999. Rainfall-runoff modeling using artificial neural. *Journal of Hydrologic Engineering*, 4(3): 1-16.
15. Vali, A., M. Moaeri, M. Ramesht and N. Movahedinia. 2008. An analysis of the comparison of the performance of artificial neural networks and suspended sediment preliminary regression models, case study of Eskandari Watershed in Zayandehrood Basin. *Journal of Natural Geography*, 71(1): 21-30 (in Persian).
16. Wang, D., A.A. Safavi and J.A. Romagnoli. 2000. Wavelet-based adaptive robust m-estimator for non-linear system identification. *American Institute of Chemical Engineers Journals*, 46(3): 1607-1615.
17. Zhu, Y.M., X.X. Lu and Y. Zhou. 2007. Suspended sediment flux modeling with artificial neural network: an example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology*, 84(3): 111-125.