

مدل ترکیبی موجک و شبکه عصبی برای پیش‌بینی غلظت سولفات و کلراید رودخانه‌ها (مطالعه موردی: رودخانه دز)

طاهر رجایی^{*}، حمیده جعفری^۱

تاریخ دریافت: ۱۳۹۳/۶/۲ تاریخ پذیرش: ۱۳۹۳/۶/۵

چکیده

از مهم‌ترین عوامل مؤثر در توسعه پایدار یک منطقه، فراهم آوردن منابع آب مناسب از نظر کمی و کیفی می‌باشد. در این مطالعه مدل‌های شبکه عصبی مصنوعی، رگرسیون خطی چند متغیره و ترکیب شبکه عصبی- موجک برای پیش‌بینی غلظت سولفات و کلراید در ایستگاه باصدۀ رودخانه دز بررسی شد و تأثیر پیش‌پردازش داده‌ها روی عملکرد مدل‌ها به‌وسیله تجزیه موجک مورد تحقیق قرار گرفت. بدین منظور سری‌های زمانی دبی، سولفات و کلراید مشاهده شده رودخانه، در سطوح مختلفی به زیرسربی‌ها تجزیه شدند. سپس حاصل جمع جبری زیرسربی‌های مؤثر دبی، سولفات و کلراید به عنوان رودی مدل شبکه عصبی برای پیش‌بینی یک ماه بعدی سولفات و کلراید درنظر گرفته شد. نتایج نشان داد که عملکرد پیش‌بینی مدل ترکیبی موجک نسبت به شبکه عصبی و رگرسیون بهتر می‌باشد. همچنین مدل ترکیبی موجک عصبی برای مقادیر پیش‌بینی، پیش‌بینی قابل قبولی را ارائه داد. این مدل، میانگین حداقل خطا را برای مدل‌های رگرسیون و شبکه عصبی در مدل‌سازی کلراید، به ترتیب از ۰/۸۴ و ۰/۶۴ به ۰/۵۲ و در مدل‌سازی سولفات به ترتیب از ۱/۷ و ۰/۹۵ به ۰/۶۳ کاهش داد. همچنین این مدل توانست پدیده هیسترزیس را برای مدل سولفات به خوبی شبیه‌سازی کند، درحالی که مدل رگرسیون در تشخیص آن ناتوان بود.

واژه‌های کلیدی: تبدیل موجک، رودخانه دز، سولفات، شبکه عصبی، کلراید

ستی پیش‌بینی‌های هیدرولوژیکی شده، استفاده از شبکه‌های عصبی مصنوعی می‌باشد. امروزه این مدل‌ها در طیف وسیعی از تحقیقات استفاده می‌شوند. ساندوو و فینچ توانایی شبکه‌های عصبی را برای پیش‌بینی میزان شوری، میزان آبیون‌هایی مانند سولفات و کلراید، مقدار هدایت الکتریکی و میزان جامدات محلول در آب این حوضه را تأیید کردند (Sandhu and Finch, 1995). توشادی و همکاران (۱۳۸۶) برخی پارامترهای کیفیت آب شامل سولفات و کلراید را در رودخانه زاینده‌رود با استفاده از شبکه‌های عصبی شبیه‌سازی نمودند. نتایج نشان داد، پیش‌بینی‌های شبکه عصبی با دقت خوبی صورت گرفته است. گلابی و همکاران (۱۳۸۵) به شبیه‌سازی پارامترهای دبی، کربنات، سولفات، کلراید، هدایت الکتریکی، نسبت جذب سدیم چند ایستگاه مهمن رودخانه کارون پرداختند. نجاج و همکاران توانایی شبکه‌های عصبی را در پیش‌بینی شاخص‌های کیفی آب رودخانه جوهر مالزی و توانایی برآورد پارامترهای کیفیت در این حوضه را مورد تأکید قرار دادند (Najah et al., 2009). نتایج نشان داد که مدل عصبی در پیش‌بینی این پارامترها دقت قابل قبولی دارد. ودیعتی و همکاران (۱۳۹۲) برخی از فراسنج‌های طبیعی رودخانه کارون، مانند اکسیژن محلول، نیترات، کلراید، هدایت الکتریکی و اکسیژن خواهی

مقدمه

رودخانه‌ها از مهم‌ترین منابع تجدیدشونده و حیاتی آب شیرین جهت استفاده در امور کشاورزی، شرب و صنعت به شمار می‌روند. از آنجا که حفاظت کیفی آب رودخانه‌ها، نیاز به سرمایه‌گذاری‌های اضافی جهت تصفیه پساب‌ها یا سیستم‌های جمع‌آوری و کنترل زه‌آب ها دارد، می‌تواند اثرات اقتصادی قابل توجهی داشته باشد. سولفات و کلراید به عنوان پارامترهایی مهم و مورد توجه در ارزیابی کیفی آب از آبیون‌هایی هستند که در تمام آب‌های سطحی یافت می‌شوند. در صورتی که غلظت کلراید در آب زیاد باشد، آب برای رشد گیاه سمی خواهد بود. در صورت وجود یون سولفات در آب، سازه‌های آبی می‌باشند با مصالح ضد سولفات ساخته شود. یون کلراید به دلیل تغییرپذیری شدید، انحلال پذیری بالا و واکنش‌پذیری در فرآیندهای شبیه‌سازی در غالب مطالعات مورد توجه است.

یکی از روش‌هایی که در چند دهه‌ی اخیر جایگزین روش‌های

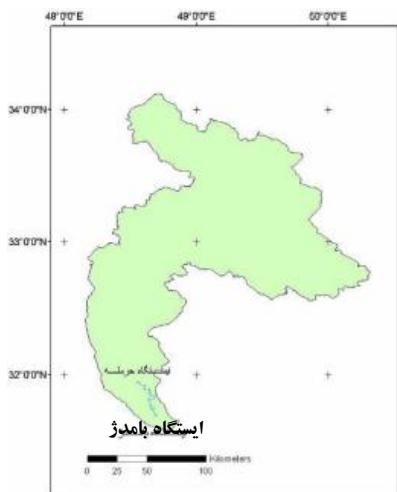
۱- استادیار گروه مهندسی عمران و نویسنده مسئول، دانشگاه قم
۲- دانش آموخته کارشناسی ارشد سازه‌های هیدرولیکی، گروه عمران، دانشگاه قم
(Email: Taher_rajaee@yahoo.com) - نویسنده مسئول:

مواد و روش‌ها

منطقه مورد مطالعه

رودخانه دز یکی از شاخه‌های اصلی تشکیل دهنده رودخانه کارون، دارای پتانسیل‌های مناسبی جهت توسعه و بهره‌برداری از منابع آبی می‌باشد. حوزه آبریز رودخانه دز ۲۳۲۵۰ کیلومتر مربع و طول رودخانه از سرچشمه تا محل تلاقی با کارون حدود ۵۲۰ کیلومتر است. این حوضه از لحاظ موقعیت جغرافیایی بین ۴۸ درجه و ۱۰ دقیقه تا ۵۰ درجه و ۲۱ دقیقه طول شرقی و ۳۱ درجه و ۳۴ دقیقه تا ۳۴ درجه و ۷ دقیقه شمالي محدود شده است. رودخانه دز از دو شاخه اصلی به نام‌های دز بختیاری و دز سیزار تشکیل شده است (شکل ۱). برای انجام پژوهش حاضر از داده‌های شرکت مدیریت منابع آب ایران در ایستگاه بامدز رودخانه دز استفاده شده است.

در این تحقیق از دوره ۲۴۶ ماهه‌ی استفاده شده (فروردین ۷۰ تا شهریور ۹۰)، ۸۰٪ داده‌ها برای آموزش و ۲۰٪ داده‌ها به‌منظور آزمون مدل‌ها استفاده شد.



شکل ۱ - موقعیت ایستگاه بامدز در حوزه رودخانه دز

تحلیل آماری داده‌ها

هر سری زمانی ویژگی‌های رفتاری نهفته‌ای مانند خودهمبستگی، خودشباهتی، خودنسبتی و روند در بازه‌ی تغییرات مقیاسی خود دارد که به این وسیله می‌توان بر تاریخچه‌ی فرآیند آن تسلط پیدا کرده و مقدمات پیش‌بینی رفتار آن را در آینده فراهم ساخت. در جدول ۱ تحلیل آماری داده‌های ماهانه دبی، سولفات و کلراید برای کل دوره و نیز به تفکیک، برای داده‌های دوره آموزش و آزمون ارائه شده است. آنالیز ارائه شده شامل میانگین، کمینه، بیشینه، انحراف معیار (S_d)، ضریب چولگی (C_s)، ضریب خودهمبستگی ۱ ماهه (R_1)، ضریب خودهمبستگی ۲ ماهه (R_2)، ضریب خودهمبستگی ۳ ماهه (R_3) و

بیوشیمیابی را با استفاده از روش استنتاج فازی شبیه‌سازی کردند. نتایج نشان داد که این روش نسبت به روش‌های سنتی خطای کمتری دارد.

پیش‌پردازش روی مدل‌های شبکه عصبی می‌تواند دقت پیش‌بینی را بهبود بخشد. استفاده از تبدیل موجک در پیش‌بینی‌های هیدرولوژیکی کارا بوده و هم‌اکنون نیز در حال گسترش است. نورانی و همکاران ترکیب دو قابلیت شبکه‌های عصبی و آنالیز موجک را در پیش‌بینی فرآیندهای هیدرولوژیکی به نام شبکه‌های عصبی-موجکی، ارائه دادند (Nourani et al., 2009). رجایی مدل جدید شبکه عصبی-موجک را برای بار رسوب معلق روزانه در رودخانه‌ها ارائه داد. نتایج نشان داد که مدل ترکیبی در پیش‌بینی بار رسوب از دقت بیشتری نسبت به مدل‌های دیگر برخوردار است (Rajaee et al., 2011). رجایی و همکاران مدل ترکیبی موجک و شبکه عصبی را برای بار معلق روزانه رودخانه پیشنهاد کردند. با مقایسه نتایج، توانایی بالای ترکیب موجک و شبکه عصبی مشخص گردید (Rajaee et al., 2011).

سینگ مدل ترکیبی شبکه عصبی-موجک را برای پیش-

بینی سیلان به کار برد. نتایج نشان دهنده توانایی بالای مدل ترکیبی

Singh et al., 2012) لانگین و شوانگین مدلی را برای پیش‌بینی کیفی آب بر

اساس موجک و شبکه عصبی ارائه دادند. این پژوهش نشان داد که

استفاده از موجک دقت مدل را نسبت به مدل شبکه عصبی بالا برده است (Longqin and Shuangyin, 2013).

کیان جین و همکاران بار رسوب رودخانه‌ای در چین را به وسیله روش ترکیبی عصبی-

موجک مدل‌سازی کردند (Qian-Jin et al., 2013). نتایج نشان داد

که دقت روش ترکیبی موجک از دو روش دیگر بالاتر است. نورانی و

همکاران از داده‌های ماهواره‌ای بارش روزانه ۴

باران‌سنجد برای پیش‌بینی رواناب روز بعد استفاده کردند. نتایج آن‌ها

حاکی از برتری مدل ترکیبی موجک-عصبی بود (Nourani et al., 2013).

مقاله‌ی حاضر تحقیقی است که از ترکیب شبکه عصبی خودبازگشتی غیرخطی^۱ و موجک، برای پیش‌بینی سری زمانی دو پارامتر کیفی سولفات و کلراید استفاده می‌کند. بدین منظور پس از تحلیل نتایج همبستگی بین پارامترهای سولفات و کلراید با دبی، به کمک خاصیت خودهمبستگی سری‌های زمانی و زیرسری‌ها و انتخاب زیرسری‌های بهینه و جمع جبری آن‌ها، ترکیبات ورودی مختلفی برای پیش‌بینی هر دو پارامتر ایجاد شد. در این مقاله ازتابع موجک Db2 استفاده شده است. در انتهای توانایی تشخیص پدیده هیسترزیس در سه مدل بررسی می‌شود.

هر چه ضریب همبستگی به عدد ۱ نزدیکتر باشد، نشان دهنده سازگاری مناسب بین داده هاست. ضرایب همبستگی بین دو پارامتر سولفات و کلراید با تأخیرهای مختلف سری های زمانی دبی در جدول ۲ نشان داده شده است. بررسی ضرایب همبستگی بین سولفات و دبی نشان می دهد که همبستگی بین SO_4 و Cl با Q_{t-1} بالاتر از سایر موارد است. منفی بودن ضرایب، همبستگی معکوس پارامترها سولفات و کلراید با پارامتر دبی را نشان می دهد.

در صورتیکه داده ها به صورت خام وارد شبکه شوند، به علت تغییرات زیاد داده ها تأثیر متفاوتی بر روی شبکه می گذارند، لذا لازم است متغیرهای ورودی به بازه ای مناسب، منطبق با شکل و رفتار تابع محرك سیگموید منتقل شوند. در این تحقیق از رابطه ۲ برای نرمال سازی داده ها در محدوده [۰/۰، ۱] استفاده شده است (Singh., 2012).

$$X_{\text{norm}} = \frac{X_t - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

ضریب خودهمبستگی ۴ ماهه (R_4) می باشد. باید توجه داشت که مدل های شبکه عصبی زمانی بهتر عمل می کنند که خصوصیات آماری داده های آموزش و آزمون مشابه داشته باشند. بررسی جدول ۱ نشان می دهد که شباهت خصوصیات آماری داده های دوره آموزش و آزمون در حد قابل قبولی می باشد. ضریب چولگی داده های دبی در مقایسه با دو پارامتر دیگر نسبتاً بالا بوده ولی این مقدار پایین بوده و برای مدل سازی مناسب است. بررسی ها نشان می دهد که همبستگی هر دو پارامتر SO_4 و Cl ، به ازای تأخیرهای ۱ تا ۳ ماهه و پارامتر دبی به ازای تأخیرهای ۱ و ۲ ماهه دبی، مقادیر نسبتاً بالایی دارد.

به منظور انتخاب ترکیبات مناسب ورودی مدل های رگرسیون خطی و شبکه عصبی، همبستگی بین سری های زمانی سولفات (SO_4) و کلراید (Cl_t) با دبی جریان زمان حال و تأخیرهای آن محاسبه شد (جدول ۲). رابطه ۱ برای محاسبه ضرایب همبستگی بین سولفات و کلراید به طور جداگانه با دبی به کار گرفته شد.

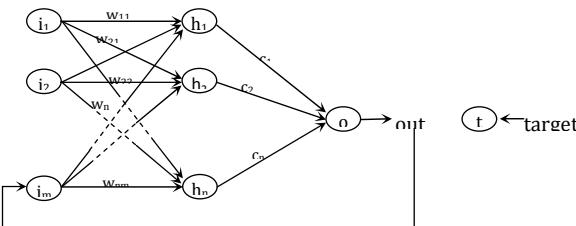
$$R^2 = \frac{\sum(Q_t - \bar{Q})(P_t - \bar{P})}{\sqrt{\sum(Q_t - \bar{Q})^2 \sum(P_t - \bar{P})^2}} \quad (1)$$

جدول ۱ - تحلیل آماری سری های زمانی داده های Cl و SO_4 و Q

کل داده ها			مجموعه آزمون			مجموعه آزمایش			پارامترهای آماری
Q (m^3/s)	SO_4 (mEq/l)	Cl (mEq/l)	Q (m^3/s)	SO_4 (mEq/l)	Cl (mEq/l)	Q (m^3/s)	SO_4 (mEq/l)	Cl (mEq/l)	
۱۱۶	۴/۹	۳/۷۸	۱۰۶/۱۶	۷/۱۱	۵/۳	۱۴۶	۴/۴۳	۳/۴	میانگین
۷۱	۲/۲۵	۱/۴۸	۶۵	۲/۴۴	۱/۴۳	۹۵	۲/۳۳	۱/۵۷	انحراف میانگین (S_d)
۱/۱۱	۰/۲۳	۰/۲۵	۰/۴۵	۰/۵۷	۰/۰۴	۱/۲۶	۰/۳۵	۰/۲	چولگی (C_{sx})
۱۳/۶۴	۰/۹۵	۰/۵	۱۵/۶	۳/۱۵	۳/۵۲	۱۳/۶۴	۰/۹۵	۰/۵	مینیمم
۱/۲۷	۱۲/۵۸	۱۴/۶۵	۴۵۰	۱۲/۵	۸/۲۶	۱۰۰۷	۱۲/۵۸	۱۴/۶۵	ماکزیمم
۰/۶۵	۰/۵۱	۰/۶۵	۰/۷۴	۰/۵۳	۰/۵۲	۰/۵۸	۰/۵	۰/۴۳	R_1
۰/۵۳	۰/۴۵	۰/۵۱	۰/۶۱	۰/۳۱	۰/۵	۰/۴۲	۰/۳۸	۰/۳۶	R_2
۰/۴۳	۰/۳۴	۰/۳۷	۰/۳	۰/۲۵	۰/۳۱	۰/۳۲	۰/۲۳	۰/۱۳	R_3
۰/۳۱	۰/۰۷	۰/۲۱	۰/۲۱	-۰/۱۷	۰/۱	۰/۲۵	-۰/۱	۰/۰۴	R_4

جدول ۲ - ضرایب همبستگی SO_4 و Cl با Q و تأخیرات ۱ تا ۴ روزه

Cl (mEq/l)			SO_4 (mEq/l)			سری های زمانی		
کل داده ها	کل داده ها	آزمایش	آزمون	کل داده ها	آزمایش	آزمون	زمانی	زمانی
-۰/۴۳	-۰/۳۸	-۰/۴۵	-۰/۴۵	-۰/۱۹	-۰/۱۸	-۰/۲۲	Q_t	
-۰/۳۷	-۰/۳۵	-۰/۴۰	-۰/۴۰	-۰/۱۷	-۰/۱۲	-۰/۱۹	Q_{t-1}	
-۰/۲۷	-۰/۲۳	-۰/۳۴	-۰/۳۴	-۰/۰۹	-۰/۰۱	-۰/۱۵	Q_{t-2}	
-۰/۱۴	-۰/۱۱	-۰/۲۹	-۰/۲۹	-۰/۰۴	-۰/۰۴۱	-۰/۰۷	Q_{t-3}	
۰/۰۳	۰/۰۵	۰/۰۴	۰/۰۴	۰/۰۳	-۰/۰۰۳	۰/۰۰۴	Q_{t-4}	



شکل ۳ - معماری شبکه عصبی در حالت حلقه پس خور بسته

شبکه‌های عصبی مصنوعی^۱

شبکه‌های عصبی مصنوعی سیستم‌هایی با پردازش اطلاعات موازی هستند که قادرند روابط پیچیده و غیرخطی بین ورودی و خروجی‌های یک سیستم فیزیکی را توسط شبکه‌ای از گره‌های متصل به هم تعیین نمایند (Haykin., 1994). ورودی‌های شبکه عصبی به سه دسته داده‌های آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند. روند آموزش شبکه تا زمانی که خطای مربع متوسط در مراحل آموزش، اعتبارسنجی و آزمون، حداقل گردد ادامه می‌یابد.

آنالیز موجک^۵

روش متداوول برای کاهش اغتشاش و تجزیه سیگنال به فرکانس‌های سازنده آن، تبدیل فوریه است که در آنالیز و پردازش سیگنال‌ها کاربرد دارد، اما این تبدیل دارای محدودیت‌هایی می‌باشد (Han et al., 2005). نظریه موجک به عنوان ایده‌ای تکمیلی در جهت رفع مشکلات تبدیل‌های فوریه قادر می‌باشد بسیاری از منظورهای پنهان داده‌ای که دیگر روش‌های تحلیل سیگنال، در شناسایی آن‌ها ناتوان هستند را شناسایی کند. موجک، موجی کوچک و نوسان‌کننده است که انرژی آن در ناحیه کوچکی متمرکز شده است. در تبدیل موجک، سیگنال از یک سری از فیلترهای بالاگذر و پایین‌گذر عبور داده می‌شود. بخش حاصل از عبور سیگنال از فیلتر بالاگذر که شامل اطلاعات فرکانس بالا از جمله نویز می‌باشد، جزئیات^۶ نام دارد. بخش حاصل از عبور سیگنال از فیلتر پایین‌گذر که شامل اطلاعات فرکانس پایین و دربرگیرنده مشخصات هویتی در سیگنال است و تغییرات آرام را نشان می‌دهد، تقریبات^۷ نامیده می‌شود. فرآیند تجزیه سیگنال به چندین جزء با ریزنمایی پائین شکسته می‌شود. این حالت درخت تجزیه موجک^۸ نامیده می‌شود که در شکل ۴ نشان داده شده است.تابع موجک که موجک مادر نامیده می‌شود به صورت زیر تعریف می‌شود:

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (5)$$

$\Psi_{a,b}(t)$ با فشرده‌سازی و کشیدن^۹ (t) به دست می‌آید و به صورت زیر تعریف می‌شود:

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad a, b \in R, a \neq 0 \quad (6)$$

در این رابطه_{a,b} $\psi_{a,b}(t)$ موجک‌های پی در پی، مقیاس یا فاکتور فرکانس، b فاکتور زمان و R دامنه اعداد حقیقی هستند. انتقال موجک گستته تابع (t) f(t) به صورت زیر نوشتہ می‌شود:

$$W_\psi f(y, k) = a_0^{-1/2} \int f(t) \psi(a_0^{-1/2} t - kb_0) dt \quad (7)$$

عموماً برای پارامترهای^{۱۰} و^{۱۱} به ترتیب مقادیر ۲ و ۱ انتخاب

شبکه‌های عصبی NAR و NARX

در مدل شبکه عصبی NAR یا خودبارگشته غیرخطی^{۱۲}، تنها داده‌های یک سری زمانی مورد استفاده قرار می‌گیرد و مقادیر آینده سری زمانی به صورت تابعی از مقادیر گذشته همان سری زمانی پیش‌بینی می‌شوند. به عبارت دیگر:

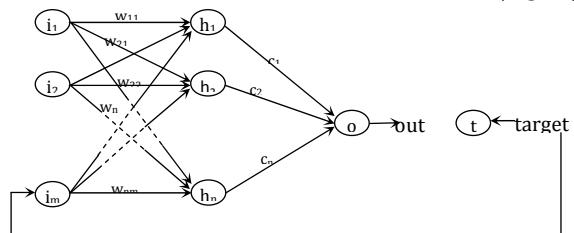
$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-d}) \quad (3)$$

در مدل شبکه NARX، از داده‌های سری زمانی دیگری هم می‌توان استفاده کرد، مثلاً در تحقیق حاضر که از سری‌های زمانی دبی نیز در ترکیب‌های ورودی شبکه عصبی استفاده می‌شود، این مدل به کار می‌رود. به عبارت بهتر:

$$y_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-d}, y_{t-1}, y_{t-2}, \dots, y_{t-d}) \quad (4)$$

در این روابط، d تعداد تأخیر است. برای آموزش مؤثرتر شبکه این حلقه پس خور می‌تواند باز باشد یا حلقه پس خور بسته^{۱۳} باشد. در هنگام آموزش که شبکه خروجی صحیح در دسترس است، می‌توان معماری حلقه پس خور باز^{۱۴} (شکل ۲) را به کار برد و از خروجی پس خور تضمینی استفاده کرد.

اگر حلقه پس خور باز باشد تنها می‌توان یک گام جلو را پیش‌بینی کرد (شکل ۳).



شکل ۲ - معماری شبکه عصبی در حالت حلقه پس خور باز

5- Wavelet analysis

6- Details

7- Approximation

8- Packet decomposition tree

1- Artificial Neural Networks

2- Nonlinear Auto Regressive

3- Close-loop

4- Open-loop

لایه‌های مخفی و خروجی به ترتیب از توابع انتقال سیگموید^۳ و خطی استفاده شد. تعداد نورون‌های لایه مخفی به روش سعی و خطا انتخاب گردید.

مدل پیشنهادی شبکه عصبی-موجک (WANN) فرآیندهای هیدرولوژیکی اغلب به صورت الگوهای پیچیده‌ای از همبستگی‌ها که مقیاس‌های زمانی تودرتو و متعددی را شامل می‌شوند، بیان می‌گردد. بنابراین یک مقدار در یک گروه زمانی در یک زمان خاص نه تنها به مقادیری که بلافضله بعد از آن حاضر می‌شوند، بستگی دارد، بلکه به تغییرات گذشته و آینده‌ی دور نیز بستگی دارد. میزان همبستگی سری‌های زمانی به طور معنی‌داری با انجام پیش‌پردازش موجکی آن‌ها افزایش می‌یابد. که منجر به افزایش قابلیت پیش‌بینی شدن سری‌های زمانی می‌شود.

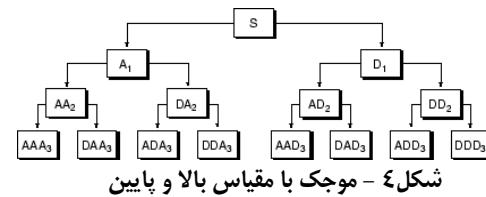
ترکیب موجک و شبکه عصبی، الگوی جدیدی از هوش مصنوعی با نام شبکه عصبی-موجکی را تشکیل می‌دهد. در مدل ترکیبی شبکه عصبی-موجک، زیرسربی‌هایی که توسط تبدیل‌های موجک تولید شده‌اند، به عنوان ورودی شبکه عصبی استفاده می‌شوند. استفاده از تبدیل موجک روی داده‌های سری زمانی قبل از ورود به شبکه این امکان را فراهم می‌کند که به‌توان از یک آنالیز که تأثیرات کوتاه‌مدت و بلندمدت را در بر می‌گیرد بهره‌مند شد. باید توجه داشت که استفاده از تبدیل‌های موجک و تجزیه سری‌های زمانی الزاماً دقت شبکه عصبی را افزایش نخواهد داد، و این نکته مهم در انتخاب موجک مادر است.

در این تحقیق از میان توابع موجک مختلف، موجک Db2 به لحاظ دارا بودن شکل هندسی مناسب برای سری‌های زمانی پارامترهای سولفات، دبی و کلراید استفاده شده است. شکل ۵ سری زمانی اصلی سولفات، کلراید و دبی را نشان می‌دهد. در مدل پیشنهادی، پس از تجزیه موجک به زیرسربی‌ها در ده سطح، ضرایب همبستگی بین زیرسربی‌هایی تولید شده محاسبه می‌شود. زیرسربی‌هایی که همبستگی بالایی دارند انتخاب شده و مجموع آن‌ها به عنوان سری زمانی جدید در نظر گرفته می‌شود. با به کار بردن روش همبستگی سری‌های زمانی می‌توان تعداد و تأخیر زمانی مؤثر عناصر ورودی در شبکه‌های عصبی را تعیین کرد، به‌طوری که با این روش، زیرسربی‌های اضافی و غیرمؤثر حذف و مجموعه داده‌های ورودی پنهانه می‌گردد. به این منظور، ضریب همبستگی هر زیرسربی با سیگال‌های اصلی سولفات، کلراید و دبی محاسبه می‌شود. به‌منظور استفاده از خواص خودهمبستگی زیرسربی‌ها، ضرایب همبستگی بین زیرسربی‌هایی به دست آمده با تأخیر گام‌های زمانی یک و دو ماهه نیز محاسبه شد (جدول ۳).

می‌گردد. با جایگذاری مقادیر و ، انتقال موجک گسسته به صورت زیر تعریف می‌شود:

$$W_{tf}(t, k) = 2^{-\frac{t}{T}} \sum_{n=0}^{N-1} f(n) \bar{\varphi}(2^{-\frac{t}{T}} t - k) dt \quad (8)$$

در این رابطه $W_{tf}(t, k)$ ضریب موجک گسسته با مقیاس (Han, et al. 2005) است $b = i$ و $a =$



رگرسیون خطی چندمتغیره (MLR)

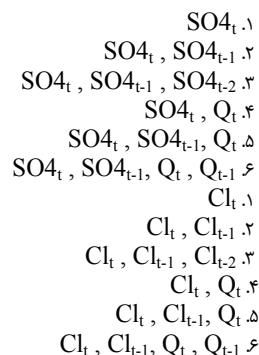
تحلیل رگرسیون خطی چندمتغیره^۱ تکنیکی برای مدل کردن رابطه خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل است. شکل معمول معادله MLR به این صورت نشان داده می‌شود:

$$y = a_0 + \sum a_i x_i \quad (9)$$

که عرض از مبدأ، ضریب رگرسیون متغیرهای مستقل و مقدار پیش‌بینی شده است (Qian-Jin et al., 2013).

مدل سازی

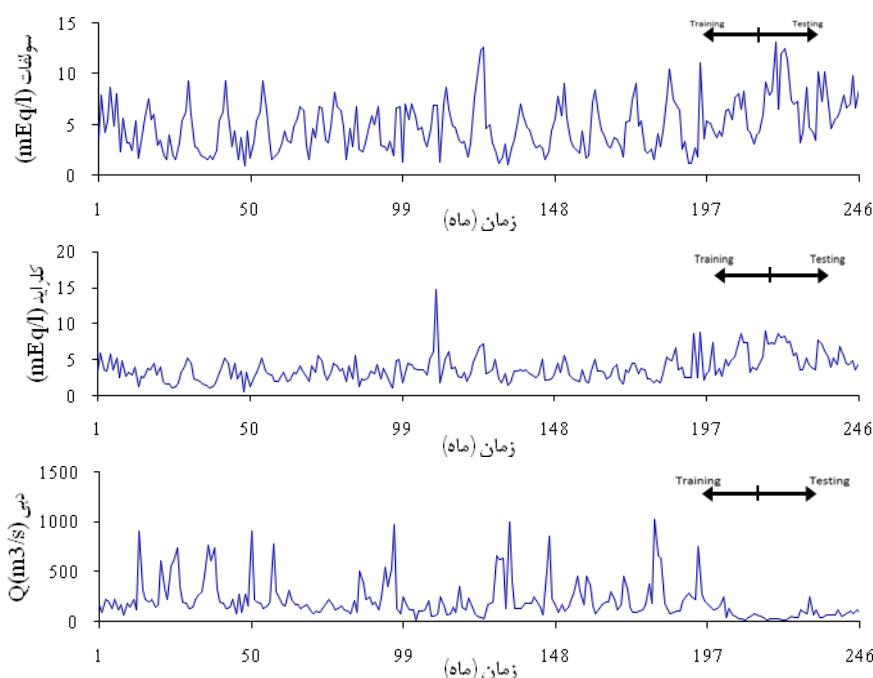
با در نظر گرفتن نتایج تحلیل آماری ارائه شده در جداول ۱ و ۲ ترکیبات مختلف ورودی برای پیش‌بینی میزان SO_4 و Cl ماه آینده در زمان $t+1$ به صورت زیر در نظر گرفته شد.



در این تحقیق به منظور آموزش و آزمون از مدل شبکه عصبی سه لایه با روش پیش‌خور پس انتشار خطای^۲ (FFBP) با الگوریتم آموزشی لونبرگ - مارکوارت استفاده شد. بر اساس تحقیقات، الگوریتم آموزشی لونبرگ-مارکوارت، به دلیل سرعت، دقت و اطمینان بالای آن در پیش‌بینی‌های هیدرولوژیکی مناسب می‌باشد. هم‌چنین برای

مؤثرترین زیرسری‌های تجزیه شده از سیگنال کلراید نیز مربوط به CDW6، CDWApp، CDW9، CDW2، CDW3، CDW1 و CDW7 بود که در این حالت نیز، این زیرسری‌های مؤثر با هم جمع شده و سیگنال اصلی با عنوان W_{t-1} TCDW_t بازسازی می‌شود. با توجه به ارتباط درجه سطوح با تنابوب رخداد زمانی و بازه زمانی اصلی که ۲۴۶ ماه است، انتظار می‌رفت که زیرسری‌های DDW8 و DDW9 و DDW10 با سری زمانی اصلی همبستگی بالایی نداشته باشند.

با توجه به جدول ۳ بالاترین ضریب همبستگی بین زیرسری‌های دبی با یک و دو تأخیر و سولفات مربوط به DDW2، DDW1 به DDW7، DDW5، DDW3، DDW6، DDWApp، DDW5 مربوط به DDW3 می‌باشد. بنابراین جمع این زیرسری‌های منتخب، حالت W_{t-1} TDDW_t، W_{t-1} SDW1، SDW6، SDW5، SDW3، SDW2 ایجاد می‌کند. از بین زیرسری‌های سولفات با یک و دو تأخیر SDW1، SDW6، SDW5، SDW3، SDW2 به عنوان زیرسری‌های منتخب انتخاب شدند که حاصل جمع این زیرسری‌های منتخب با عنوان $TSDW_t$ و W_{t-1} در نظر گرفته شده است.



شکل ۵- سوی‌های زمانی یون سولفات، کلراید و دبی ماهانه ایستگاه مورد مطالعه

جدول ۳- ضرایب همبستگی زیرسری‌های تجزیه شده با سولفات و کلراید

زیرسری‌های سری زمانی دبی	همبستگی بین				زیرسری‌های سری زمانی	همبستگی بین				زیرسری‌های سری زمانی	همبستگی بین			
	کلراید	سولفات	کلراید	سولفات		سولفات	کلراید	سولفات	کلراید		سیگنال اصلی	کلراید	سیگنال اصلی	کلراید
DDW 1	-/-/۱۸	-/-/۰۸	-/-/۱۶	-/-/۰۷	SDW 1	-/-/۲۸	-/-/۱۶	-/-/۱۶	-/-/۱۶	CDW 1	-/-/۱۴	-/-/۱	-/-/۱۴	-/-/۱
DDW 2	-/-/۱۳	-/-/۰۷	-/-/۱۵	-/-/۰۱	SDW 2	-/-/۲۱	-/-/۱۸	-/-/۱۸	-/-/۱۸	CDW 2	-/-/۱۸	-/-/۱۲	-/-/۱۸	-/-/۱۲
DDW 3	-/-/۱۵	-/-/۲۳	-/-/۱۱	-/-/۱۳	SDW 3	-/-/۲۱	-/-/۱۴	-/-/۱۴	-/-/۱۴	CDW 3	-/-/۲۶	-/-/۱۷	-/-/۲۶	-/-/۱۷
DDW 4	-/-/۱۷	-/-/۰۳	-/-/۰۱	-/-/۰۷	SDW 4	-/-/۰۱	-/-/۰۵	-/-/۰۵	-/-/۰۵	CDW 4	-/-/۱۱	-/-/۰۵	-/-/۱۱	-/-/۰۵
DDW 5	-/-/۱۷	-/-/۲۱	-/-/۱۱	-/-/۱۷	SDW 5	-/-/۱۴	-/-/۱	-/-/۱	-/-/۱	CDW 5	-/-/۰۸	-/-/۰۱	-/-/۰۸	-/-/۰۱
DDW 6	-/-/۱	-/-/۲	-/-/۰۹	-/-/۱	SDW 6	-/-/۱۷	-/-/۱۶	-/-/۱۶	-/-/۱۶	CDW 6	-/-/۲۳	-/-/۱۷	-/-/۲۳	-/-/۱۷
DDW 7	-/-/۱۴	-/-/۰۹	-/-/۱۱	-/-/۰۸	SDW 7	-/-/۰۲	-/-/۰۴	-/-/۰۴	-/-/۰۴	CDW 7	-/-/۱۷	-/-/۱۵	-/-/۱۷	-/-/۱۵
DDW 8	-/-/۱	-/-/۰۲	-/-/۰۲	-/-/۰۲	SDW 8	-/-/۱۸	-/-/۱۴	-/-/۱۴	-/-/۱۴	CDW 8	-/-/۰۹	-/-/۰۱	-/-/۰۹	-/-/۰۱
DDW 9	-/-/۱	-/-/۰۱	-/-/۰۹	-/-/۰۱	SDW 9	-/-/۹۱	-/-/۱	-/-/۱	-/-/۱	CDW 9	-/-/۰۲۵	-/-/۲۶	-/-/۰۲۵	-/-/۲۶
DDW 10	-/-/۰۳	-/-/۰۷	-/-/۰۱	-/-/۰۷	SDW 10	-/-/۰۱	-/-/۰۹	-/-/۰۹	-/-/۰۹	CDW 10	-/-/۰۱	-/-/۰۳	-/-/۰۱	-/-/۰۳
DDW App.	-/-/۰۷	-/-/۱۶	-/-/۰۶	-/-/۱۷	SDW App.	-/-/۱۳	-/-/۱۸	-/-/۱۸	-/-/۱۸	CDW App.	-/-/۲۷	-/-/۱۸	-/-/۲۷	-/-/۱۸

جدول ۴- مقایسه ضرایب همبستگی پیش و پس از نویززدایی سیگنال‌ها

سری‌های زمانی اصلی	ضریب همبستگی با سیگنال اصلی سولفات	ضریب همبستگی با سیگنال اصلی کلرايد
-	-۰/۲۲	Qt
-۰/۴	-۰/۱۹	Qt-1
-۰/۳۴	-۰/۱۵	Qt-2
-۰/۴۸	-۰/۲۵	TDDW _t
-۰/۴۳	-۰/۱۹	TDDW _{t-1}
-۰/۳۱	-۰/۱۳۴	TDDW _{t-2}
-۰/۶۱	-۰/۶۳	TS(C)DW _t
۰/۵۴	-۰/۴۸	TS(C)DW _{t-1}
۰/۴۴	۰/۳۴	TS(C)DW _{t-2}

خطا به + نزدیک شود، مدل پیش‌بینی بهتری دارد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (10)$$

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad (11)$$

$$E = 1 - \frac{\sum_{i=1}^n (Y_i - \bar{X}_i)^2}{\sum_{i=1}^n (Y_i - \bar{X})^2} \quad (12)$$

در این روابط، X_i و Y_i به ترتیب آمین داده پارامتر برآورده و اندازه گیری، متوسط داده‌های X_i و n تعداد نمونه‌های مورد ارزیابی است. $E=1$ به این معنی است که داده‌های پیش‌بینی شده با داده‌های مشاهده شده هم خوانی کامل دارد. $E=0$ یعنی پیش‌بینی مدل منطبق بر مقادیر میانگین داده‌ها می‌باشد؛ در حالی که $E < 0$ نشان‌دهنده این است که میانگین داده‌های مشاهداتی نسبت به مدل پیش‌بینی شده دقت پیش‌تری دارد (Zhou et al., 2008).

نتایج و بحث

برای به دست آوردن بهترین نتیجه به منظور پیش‌بینی پارامترهای سولفات و کلرايد، با در نظر گرفتن شدت همبستگی بین پارامترها، ترکیبات مختلف ورودی ایجاد شد. در این مدل‌ها پیش‌بینی MAE و RMSE و E محاسبه شد (دوره آزمون) انجام شد و مقادیر E و $RMSE$ و MAE محاسبه شد (جداول ۱ تا ۴). در اجرای مدل رگرسیون خطی چندمتغیره، سولفات و کلرايد ماه فعلی به عنوان متغیر وابسته و داده‌های مربوط به ماه‌های قبل به عنوان متغیر مستقل در نظر گرفته شدند. روابط مربوط به مدل رگرسیون برای ترکیبات ورودی شش گانه در جدول ۵ و نتایج در جدول ۶ نمایش داده شده است. بهترین نتیجه برای هر دو پارامتر سولفات و کلرايد در این مدل مربوط به ترکیب ورودی ۱ با ضریب تبیین $0/۲۳$ و $0/۳۸$ می‌باشد. مدل بعدی که در این تحقیق مورد استفاده قرار گرفت، مدل شبکه عصبی بود. این مدل‌ها بر اساس تعداد لایه‌های مخفی، تعداد نرون‌های لایه مخفی و تعداد تأخیرها (۱ تا ۴ ماه قبل) آموزش داده شد و مورد آزمون قرار گرفتند.

به منظور ایجاد ترکیب‌های ورودی مناسب به مدل شبکه عصبی، ضرایب همبستگی بین سیگنال حاصل از جمع جبری زیرسروی‌ها با تأخیرات مختلف و سری زمانی اصلی سولفات و دبی مطابق جدول ۴ محاسبه می‌شود. همانطور که در این جدول مشخص است، ضرایب همبستگی بین دبی و سیگنال بدون پیش‌پردازش سولفات $-۰/۲۲$ و کلرايد $-۰/۴۵$ می‌باشد. در حالی که حذف نویز به وسیله موجک این ضریب را به $-۰/۲۵$ و $-۰/۴۸$ بهبود داده است. همچنین همبستگی بین تأخیرات یک ماهه دبی در پارامتر کلرايد از $-۰/۴۳$ به $-۰/۴۳$ افزایش یافته است. با مقایسه ضرایب خودهمبستگی سولفات و کلرايد در جدول ۴ مشخص می‌شود که پیش‌پردازش آنالیز موجک، در تمامی حالات این ضرایب را افزایش داده است.

با استفاده از نتایج تحلیل آماری در جدول ۴ ترکیب‌های زیر برای هر یک از دو پارامتر سولفات و کلرايد به عنوان ورودی شبکه عصبی - موجک در نظر گرفته می‌شود، تا بهترین پیش‌بینی حاصل شود.

$$\begin{aligned} & TSDW_{t,1} \\ & TSDW_{t-1}, TSDW_{t,2} \\ & , TSDW_{t-1}, TSDW_t TSDW_{t-2,2} \\ & , TDDW_t, TSDW_t TSDW_{t-1,2} \\ & TDDW_t, TSDW_t TSDW_{t-1,1}, TDDW_t, \\ & \quad TCDW_{t,1} \\ & , TCDW_{t-1}, TCDW_{t,2} \\ & , TCDW_{t-1}, TCDW_t TCDW_{t-2,2} \\ & , TDDW_t, TCDW_t TCDW_{t-1,2} \\ & TDDW_t, TCDW_t TCDW_{t-1,1}, TDDW_t \end{aligned}$$

معیارهای ارزیابی مدل

در این تحقیق سه شاخص معیاری شامل ریشه میانگین مربعات خطای بین داده‌های پیش‌بینی و مشاهده شده ($RMSE$)، میانگین قدر مطلق خطای (MAE)، ضریب کارایی نش-ساتکلیف یا ضریب تبیین (E) به عنوان ارزیابی توان پیش‌بینی مدلها، روابط ۱۲ تا ۱۰ مورد استفاده قرار گرفته است. به طور کلی هرچه ضریب تبیین به ۱ و

جدول ۵ - روابط مربوط به مدل رگرسیون خطی چند متغیره

ترکیبات	MLR(CL)	MLR(SO4)
۱	$y_t = 2.64 + 0.2143y_{t-1}$	$y_t = 2.35 + 0.4684y_{t-1}$
۲	$y_t = 2.18 + 0.1736y_{t-1} + 0.177y_{t-2}$	$y_t = 2.29 + 0.455y_{t-1} + 0.027y_{t-2}$
۳	$y_t = 2.44 + 0.194y_{t-1} + 0.1968y_{t-2} - 0.116y_{t-3}$	$y_t = 2.82 + 0.46y_{t-1} + 0.137y_{t-2} - 0.235y_{t-3}$
۴	$y_t = 1.87 + 0.448y_{t-1} - 0.067x_{t-1}$	$y_t = 4.218 + 0.2358y_{t-1} - 0.006x_{t-1}$
۵	$y_t = 2.15 + 0.32y_{t-1} + 0.12y_{t-2} + 0.054x_{t-1}$	$y_t = 3.34 + 0.16y_{t-1} + 0.32y_{t-2} - 0.09x_{t-1}$
۶	$y_t = 2.23 + 0.268y_{t-1} - 0.08y_{t-2} + 0.109x_{t-1} - 0.14x_{t-2}$	$y_t = 3.78 + 0.188y_{t-1} + 0.1y_{t-2} + 0.109x_{t-1} - 0.14x_{t-2}$

جدول ۶ - نتایج به دست آمده از مدل رگرسیون خطی چندمتغیره برای ترکیبات ۱ تا ۶

ترکیبات	MLR (SO4)						MLR (CI)					
	*۱	۲	۳	۴	۵	۶	*۱	۲	۳	۴	۵	۶
E	.۰/۲۳	.۰/۱۳	.۰/۱۵	-.۰/۱۲	-.۰/۲۵	.۰/۰۵	.۰/۳۸	.۰/۲۶	.۰/۳۳	.۰/۳۵	.۰/۲۳	-.۰/۰۹
MAE(mEq/l)	۱/۷	۱/۸۳	۱/۹۱	-	-	-	.۰/۸۴	۱/۲۱	.۰/۹۳	.۰/۸۸	۱/۲	-
RMSE(mEq/l)	۱/۰۹	۱/۳۹	۱/۴۳	-	-	-	.۰/۶۸	۱/۲۳	۱/۱	.۰/۷۶	۱/۲۶	-

آزمون حداقل گردد. همانطور که از نتایج جدول ۷ مشخص است، افزودن دبی جریان، نتایج را بهبود نمی‌دهد. بهترین پیش‌بینی برای کلراید از ترکیب ۴ (وابستگی کلراید به کلراید و دبی زمانی حال) با معناری ۴-۳-۲ و الگوریتم آموزش لونبرگ-مارکوارت حاصل شد. همان‌گونه که از نتایج شخصی است، مدل شبکه عصبی نتایج دقیقتری نسبت به مدل رگرسیون خطی دارد. رگرسیون خطی ضعیف بوده و قادر به شیوه‌سازی نوسانات شدید و پی در پی و پیش‌بینی مناسب SO_4 و CI نیست.

در مدل پیشنهادی عصبی-موجک زیرسی‌های تقریب و جزئیات به دست آمده از تجزیه موجکی سیگنالی SO_4 , Cl و Q در ده سطح مورد بررسی قرار گرفتند. هر یک از زیرسی‌ها نماینده بی‌نظمی‌ها، تغییرات و جهش‌های سریع در هر یک از گروه‌های زمانی سولفات، کلراید و دبی می‌باشد. گروه‌های زمانی پس از حذف اختلالات دارای همبستگی بالاتری می‌باشند که به علت افزایش حافظه سری زمانی می‌باشد.

تعداد لایه‌های مخفی و تعداد نرون‌های لایه‌ی مخفی هر شبکه با استفاده از تعداد داده‌های موجود و روش سعی و خطا بهینه شد. باید توجه داشت که تعداد لایه‌های مخفی بیشتر و تعداد نرون بیشتر در لایه‌ی مخفی، اگرچه ممکن است دقت محاسبات در آموزش شبکه را بالا ببرد ولی الزاماً دقت مدل را در پیش‌بینی داده‌های اعتبارسنجی و آزمون افزایش نخواهد داد. بنابراین از بین دو معناری شبکه با دقت برابر، موردنی که سادگی بیشتری داشته باشد مناسب‌تر است. در هنگام آموزش شبکه می‌بایست به مسئله یادگیری اضافی^۱ دقت شود. در این حالت حین آموزش شبکه خطای مجموعه آموزشی به مقدار بسیار ناچیزی می‌رسد، ولی هنگام معرفی داده‌های جدید (اعتبارسنجی و آزمون) خطای مدل زیاد می‌شود؛ در واقع شبکه در مرحله آموزش، روند داده‌ها را یاد نگرفته بلکه با به حافظه سپردن داده‌ها از بهینه کردن وزن ممانتع می‌کند و از این رو نتایج قابل تعیین به مرحله آزمون نمی‌باشد. بنابراین بهترین عملکرد شبکه عصبی زمانی است که خطای هر سه مرحله آموزش، اعتبارسنجی و

جدول ۷ - نتایج به دست آمده از مدل شبکه عصبی برای ترکیبات ۱ تا ۶

ترکیب‌ها	ANN (SO4)						ANN (CI)					
	۱	*۲	۳	۴	۵	۶	۱	۲	۳	*۴	۵	۶
تعداد نرون‌های لایه پنهان	۵	۸	۶	۹	۸	۵	۶	۶	۹	۸	۵	۹
E	.۰/۶۵	.۰/۷۵	.۰/۷۳	.۰/۶۱	.۰/۶۶	.۰/۵۹	.۰/۶۹	.۰/۷۱	.۰/۷۴	.۰/۷۹	.۰/۷۴	.۰/۶۸
MAE(mEq/l)	.۰/۲۳	.۰/۹۵	.۰/۹۷	۱/۳۱	۱/۱۸	۱/۳۴	۱/۱۳	.۰/۹۳	.۰/۸۷	.۰/۶۴	.۰/۸۶	۱/۱۸
RMSE(mEq/l)	.۰/۴۶	.۰/۲۷	.۰/۳۵	.۰/۵۸	.۰/۴۱	.۰/۶۱	.۰/۸۵	.۰/۸۲	.۰/۷۸	.۰/۳۶	.۰/۶۷	۸

زمانی و مکانی آلاینده‌ها از طریق جداسازی نشانه‌ها از حافظه سری زمانی این دو پارامتر قابل پیش‌بینی می‌شود. هر یک از ده سطح تجزیه سیگنالی آنالیز موجک ارتباط‌های تناوبی و همبستگی بین پارامترهای سولفات، کلراید و دبی را به صورت ماهانه رمزگشایی کردند. تأثیرات دبی در این روابط به صورت مستقیم اعمال شد. با توجه به رابطه معکوس دبی و غلطات آلاینده‌ها، مقادیر بیشینه برای هر دو پارامتر در فصول خشک و ماههای گرم مشاهده شد. شدت تبخیر در این منطقه به این رابطه کمک می‌کند. نتایج نشان‌دهنده نقش مؤثر دبی در پیش‌بینی پارامتر کلراید می‌باشد، در حالیکه لحاظ کردن مستقیم زیرسربی‌های تجزیه شده دبی از سیگنال اصلی آن در ترکیبات پیش‌بینی سولفات راه‌گشا نبوده است. با بررسی خطای RMSE در جدول ۸، مدل ترکیبی Db2 توانست خطای را در دو مدل دیگر رگرسیون و شبکه عصبی برای سولفات به مقدار قابل توجهی کاهش دهد.

با توجه به شکل ۶ و ۷، نمودار مدل ترکیبی موجک-عصبی با نمودار مقادیر مشاهده شده تطابق بیشتری دارد. عملکرد ضعیف روش رگرسیون خطی در شکل ۴ با پراکندگی داده‌ها در اطراف خط نیمساز دیده می‌شود. نقاط این پراکندگی اکثراً در سمت راست خط نیمساز قرار دارد. هرچه این نقاط به نیمساز نزدیک‌تر باشند، پیش‌بینی بهتر انجام شده است. به نظر می‌رسد روش رگرسیون بر مبنای بازه آموزش که ۱۹۷ ماه اول دوره را در بر می‌گرفت، مدل مقادیر میانگینی را ارائه داده و در هیچ یک از نوسان‌ها و پیک‌ها با مقادیر مشاهداتی تطابق ندارد. در واقع مدل رگرسیون شکل کلی روند تغییرات را با یک گام تأخیر دنبال کرده، که این موضوع به ماهیت خطی این مدل بر می‌گردد. این روش قادر به تشخیص روابط پیچیده بین داده‌های سری زمانی نبوده و پیش‌بینی با خطای نسبتاً بالایی همراه است، در صورتیکه با توجه به شکل ۶ شبکه عصبی بهتر توانسته ساز و کارهایی را برای جبران تغییرات به وجود آمده در طول زمان، ارائه دهد. به خصوص مقادیر بیشینه و کمینه را به خوبی شناسایی کرده ولی در بیشینه‌ها مقادیر را اندکی کمتر از مقادیر واقعی پیش‌بینی کرده است.

به این ترتیب سیگنالی بهینه شده از جمع زیرسربی‌های مؤثر و با همبستگی بالا به دست آمد و تحت شش ترکیب ارائه شده فوق به شبکه عصبی اعمال شدند. در این مدل از تابع موجکی Db2 به علت شکل هندسی مشابه با سری‌های زمانی سولفات و کلراید استفاده شد. مطابق جدول ۸ بهترین نتیجه برای پارامتر سولفات در ترکیب ۲ و پارامتر کلراید در ترکیب ۴ با ضریب تبیین ۸۱/۰ و ۸۴/۰ به دست آمد. این نتیجه در مقایسه با دو روش قبلی رگرسیون و عصبی به ترتیب برای سولفات ۰/۰۶ و ۰/۰۵ و برای کلراید ۰/۰۵ و ۰/۴۶ افزایش را نشان می‌دهد. جدول ۸ به وضوح برتری مدل ترکیبی شبکه عصبی-موجک را نسبت به مدل‌های شبکه عصبی و رگرسیون خطی نشان می‌دهد. تغییرات فرکانسی پارامترهای سولفات و کلراید به عوامل گوناگونی بستگی دارد. برخی از این عوامل مانند تبخیر، فرسایش و آبشویی و انتقال رسوبات، ساختار زمین‌شناسی و سازندۀ‌های منطقه، افزایش سطح تماس با سایر کانی‌ها، دخالت‌های انسانی، عبور از لایه‌های گچی و نمکزار اثر افزایشی و برخی دیگر مانند افزایش ناگهانی دبی رودخانه و سیلان اثر کاهشی دارد. البته در صورتیکه افزایش دبی منجر به افزایش فرسایش شود، این رابطه افزایشی خواهد بود. تأثیر هر یک از این عوامل در طول زمان، به صورت ضمنی در بین داده‌ها قرار گرفته است.

آنالیز رگرسیون کلیات روند تغییرات سری زمانی را نشان می‌دهد و توانسته جزئیات را شبیه‌سازی کند، در حالیکه مدل شبکه عصبی با بهینه کردن وزن‌ها تا حد قابل قبولی توانسته سولفات و کلراید را پیش‌بینی نماید. مدل ترکیبی موجک-عصبی با تجزیه سری زمانی با ماهیت کاملاً نوسانی، به زیرسربی‌هایی ایستا عملکرد بهتری از خود نشان داده است. آلودگی شیمیایی رودخانه ذر به دلیل ورود پساب کارخانجات اطراف به خصوص کارخانجات کاغذسازی پارس، کشت و صنعت نیشکر هفت تپه و شیر پاستوریزه شوش و همچنین ورود رواناب و زه‌آب زمین‌های کشاورزی اطراف می‌باشد که به دلیل برهم‌کش بالقوه‌ای که بین آلاینده‌گی آن‌ها وجود دارد، بسیار پیچیده می‌باشد. منطقی است که با این روابط غیرخطی، نتیجه مناسبی از طریق آنالیز رگرسیون حاصل نمی‌شود. در این میان، روابط پیچیده

جدول ۸ - نتایج به دست آمده از مدل ترکیبی شبکه عصبی-موجک برای ترکیبات ۱ تا ۶

مدل‌ها	WANN (SO4)						WANN (Cl)					
	۱	۲*	۳	۴	۵	۶	۱	۲	۳	۴*	۵	۶
تعداد نمونه‌های لایه پنهان	۷	۵	۴	۹	۷	۵	۱۱	۹	۹	۵	۷	۹
E	.۶۳	.۸۱	.۷۱	.۶۸	.۷۱	.۵۹	.۶۸	.۷۳	.۷۸	.۸۴	.۷۸	.۶۵
MAE(mEq/l)	۱/۲۶	.۶۳	۱/۱۲	.۹۳	.۸۸	.۳۱	۱/۱۵	.۹	.۹	.۵۲	.۸۳	۱/۲۳
RMSE(mEq/l)	۳/۱۵	.۱۵	.۳۸	.۴۷	.۳۸	.۶	.۸۶	.۷۹	.۷۷	.۲۹	.۶۵	.۹۶

حلقه، سماند (Hysteresis)

اطلاع از تغییرات میزان یونهای معلق در مقابل نوسانات ناگهانی و تدریجی دبی رودخانه‌ها از مسائل مهم در مدیریت حوزه‌های آبخیز می‌باشد. در برخی موارد این تغییرات موجب پیدیده پسماند می‌شود، به این معنی که تغییرات سولفات وابسته به تغییرات دبی می‌باشد و اگر تغییرات دوره‌ای سولفات با تأخیر در پی تغییرات دبی رخ دهد، احتمال پسماند وجود دارد. (Williams, G., 1989) پنج کلاس معمولی از حلقه‌های پسماند را شامل: ساعتگرد پاد ساعتگرد، شکل ۸ مانند، خطی و خطی به اضافه یک حلقه معرفی نمود. با بررسی و تحلیل این منحنی‌ها می‌توان از منابع آلاینده و نحوه انتقال آن آگاهی یافت. در شکل ۸ یک رویداد سیل در بازه زمانی آزمون بین ماههای بهمن ۸۸ تا تیر ۹۰ برای پارامتر سولفات رسم شده است. در مورد کلاید، با بررسی روابط و نمودارها، این پیدیده مشاهده نشد. همانطور که از شکل مشخص است، روش رگرسیون این پیدیده را تشخیص نداده و رابطه‌ای خطی را از دو پارامتر دبی و سولفات ارائه کرده است. طبق این رابطه با کاهش دبی، میزان سولفات کاهش می‌یابد. این در حالیست که مدل شبکه عصبی و ترکیبی موجک قادر به مدل کردن، شرایط نظری پیدیده هیسترزیس، روابط جریان، می‌باشد.

نتیجہ گیری

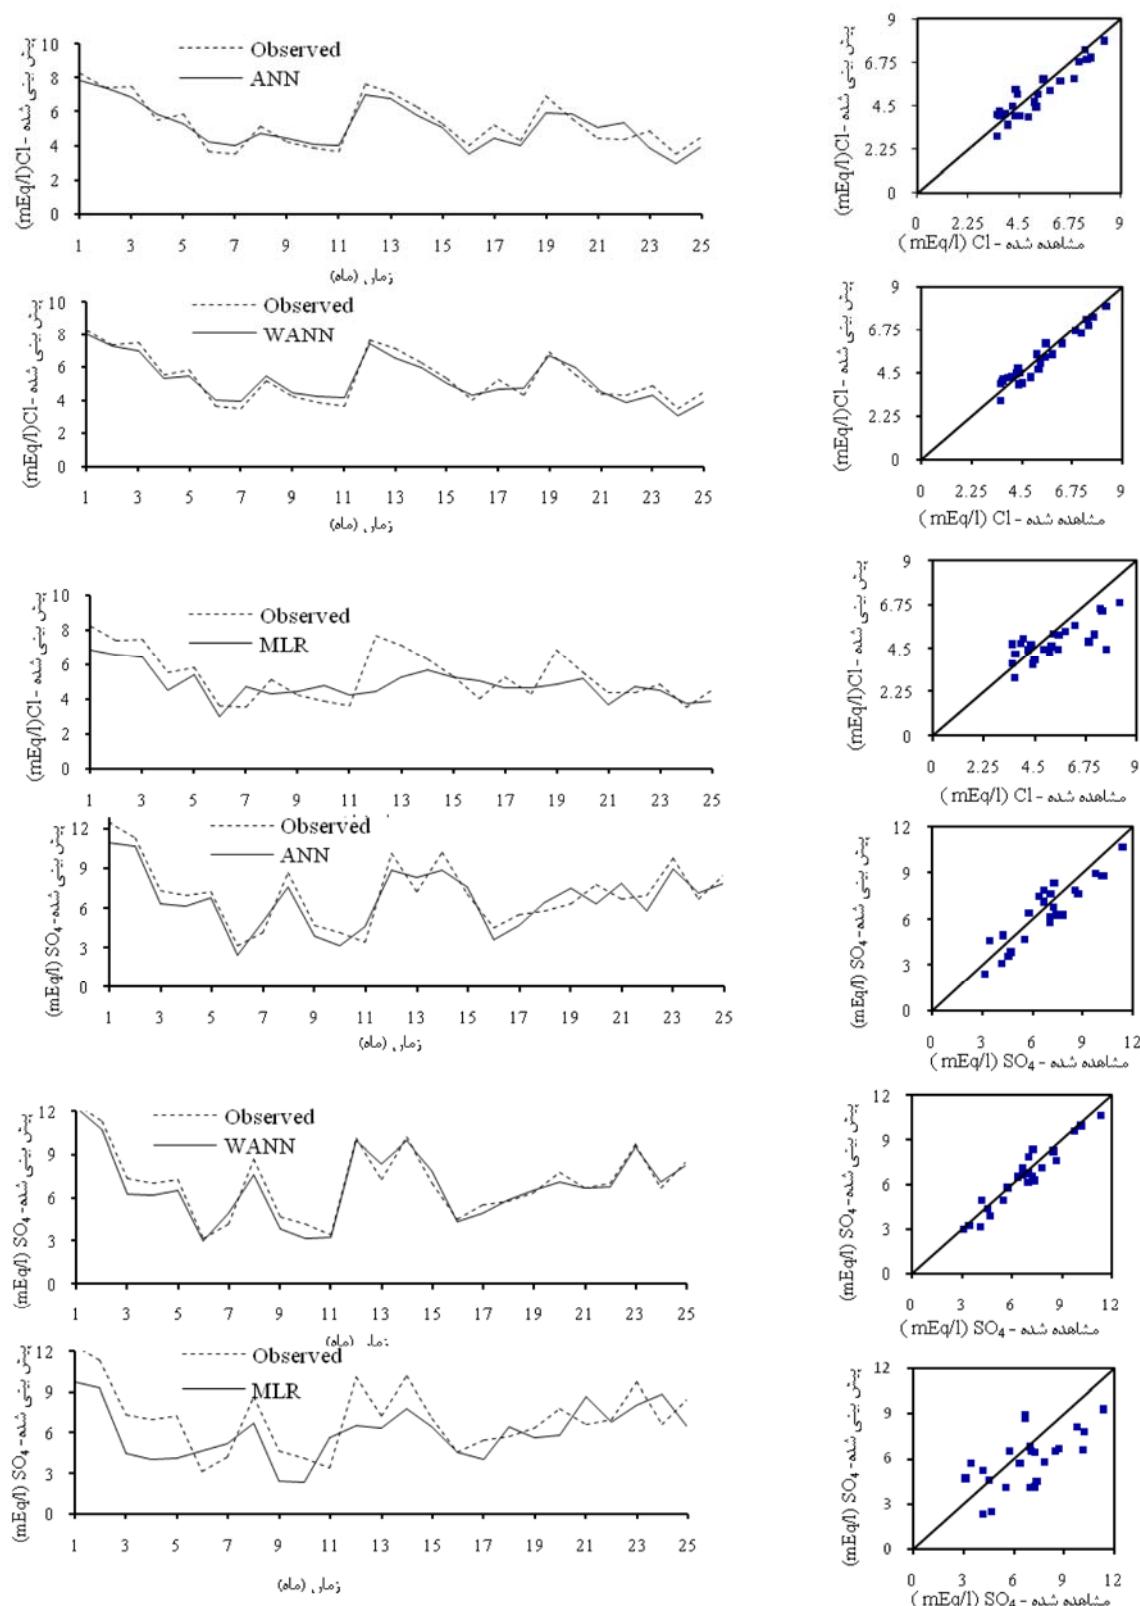
در این تحقیق کاربرد مدل‌های شبکه عصبی، ترکیب شبکه عصبی-موجک و رگرسیون خطی چندمتغیره در پیش‌بینی مقادیر سولفات و کلراید آب رودخانه دز در ایستگاه بامدز بررسی شد. به دلیل اینکه سری زمانی سولفات و کلراید غیرایستا با ماهیتی نوسانی هستند، فقط لحاظ نمودن تغییرات زمانی، آنها راه‌گشای نسبی باشد.

در این مدل نقاط اطراف خط نیم‌ساز نوسان کرده‌اند که نشان می‌دهد این مدل از پارامترهای بیشتری برای تنظیم وزن‌ها برخوردار بوده است. این حالت در نمودار مربوط به موجک به دقت بیشتری می‌رسد به طوریکه نقاط، بر خط نیم‌ساز انباتیگر خوبی دارند. شبکه عصبی-موجکی نه تنها قادر به تشخیص تغییرات سری زمانی بوده بلکه نقاط شکستگی، بیشینه و کمینه را به خوبی پیش‌بینی کرده است. با بررسی نقاط شکستگی نمودارهای شبکه عصبی و مدل ترکیبی می‌توان دریافت که عملکرد موجک باعث شده که در قله‌ها با تشخیص داده‌های مؤثر به سمت دقیق‌تر شدن پیش‌رفته است. ساختار این مدل با تجزیه سیگنال، وزن‌های شبکه عصبی را به گونه‌ای تنظیم می‌کند که روند طبیعی سیستمی را که شبیه‌سازی می‌کند نشان می‌دهد.

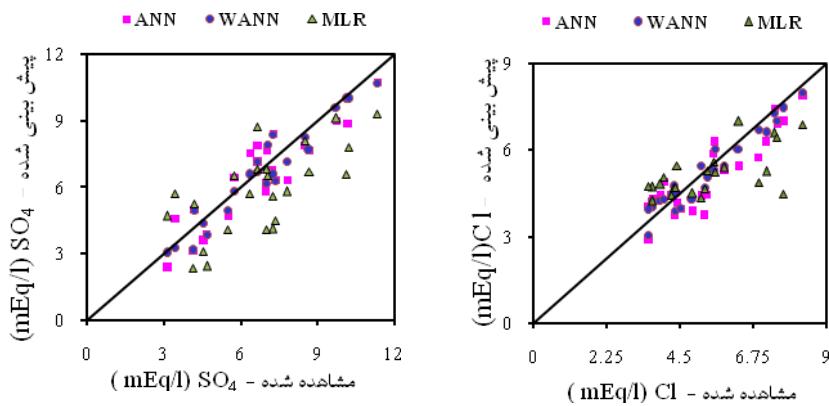
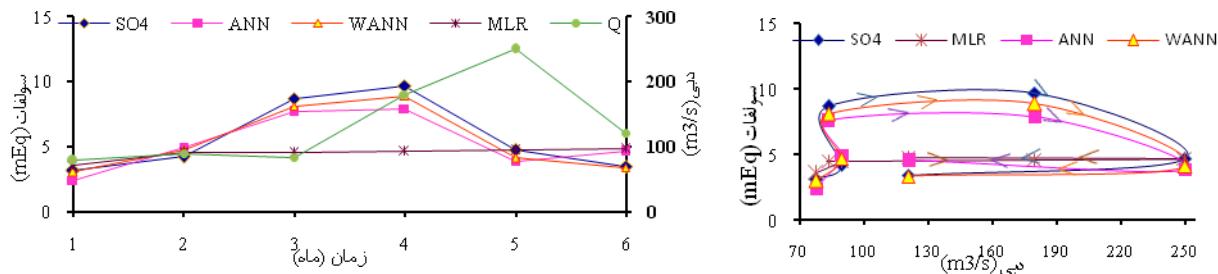
با توجه به جدول ۹، توانایی و ویژگی موجک در تخمین و شبیه-سازی نقاط پیک (نسبت به دو روش دیگر) دیده می شود. جدول ۶
توان پیش‌بینی مقادیر بیشینه و کمینه در ۲۵ ماهه آخر بازه زمانی را
توسط سه مدل نشان می دهد. استفاده همزمان شبکه‌های عصبی و
تبديل موجک در افزایش ضریب کارایی و کاهش میزان خطای داده-
های محاسباتی به مشاهداتی، موقفیت آمیز بوده است. شبکه‌های
عصبی و موجکی قادر هستند که یک فضای چندگانه را حتی در
صورت ناقص بودن اطلاعات تطبیق دهند. بیشترین مقدار سولفات و
کلراید آب در تابستان و پاییز مشاهده می شود، لذا آب رودخانه در
ماهه‌ای تابستان و پاییز از نظر سولفات آلوده به نظر می رسد و این،
گهیان، روابط ای. دارد، امت با میان، دی. و شدت تبخیر است.

جدول ۹ - بیشینه مقادیر بیشینه بازه آزمون توسط سه مدل برای کلارین و سولفات

ردیف					سولفات (mEq/l) پارامتر					کلراید (mEq/l) پارامتر					سولفات (mEq/l) پارامتر						
ردیف	تاریخ	MLR	WANN	ANN	ردیف	تاریخ	MLR	WANN	ANN	ردیف	تاریخ	MLR	WANN	ANN	ردیف	تاریخ	MLR	WANN	ANN		
۱	شهریور ۸۸	۵/۱۶	۷/۹۹	۶/۸۷	۸۸	شهریور ۱۳	۱۰/۲۳	۱۲/۲۷	۹/۸	۱	شهریور ۸۸	۹/۸	۱۲/۲۷	۱۰/۷	۲	مهر ۸۸	۹/۳	۱۰/۷	۶/۴۴	۷	آبان ۸۸
۲	مهر ۸۸	۶/۴۴	۵/۴۴	۶/۸	۸۸	مهر ۱۳	۱۰/۶۹	۱۰/۷	۹/۳	۲	مهر ۸۹	۶/۵۶	۹/۹۶	۸/۸۶	۳	مهراد ۸۹	۶/۵۶	۹/۹۶	۸/۸۶	۴/۲	مرداد ۸۹
۳	مهراد ۸۹	۶/۵۶	۹/۹۶	۸/۸۶	۸۹	مهراد ۱/۱	۱/۱	۸/۸۶	۹/۹۶	۴	مهراد ۸۹	۸/۷	۸/۷	۹/۹۶	۵	تیر ۹۰	۹/۱	۹/۷۶	۸/۸۶	۶/۳	شهریور ۸۹
۴	تیر ۹۰	۹/۱	۹/۷۶	۸/۸۶	۸۹	اسفند ۱۰/۲	۱۰/۲	۸/۸۶	۹/۹۶	۵	تیر ۹۰	۹/۱	۹/۱	۹/۵۹	۶	شهریور ۸۹	۹/۳	۶/۵۸	۴/۰۳	۴/۲	مرداد ۸۹
۵	شهریور ۸۹	۹/۳	۶/۵۸	۶/۳	۸۹	اسفند ۱۱/۳	۱۱/۳	۱۰/۶۹	۱۰/۷	۶	شهریور ۸۸	۹/۳	۹/۳	۹/۳	۷	مهر ۸۸	۹/۳	۵/۴۴	۵/۴۴	۶/۸	۷/۸۴
مجموع	-	-	-	-	-	۱۲/۵	-	-	-	۷	-	-	-	۸	-	-	-	-	-	۳۵/۴	۳۳/۸۱
خطا (%)	-	-	-	-	-	۴۸/۳۵	۵۲/۴۹	۴۲/۵۶	-	۹	۴۸/۳۵	۵۲/۴۹	۴۲/۵۶	-	۱۰	٪۱۰	٪۴۸	٪۲۱	-	٪۷/۹	٪۴/۸۹
RMSE	-	-	-	-	-	۱/۱۷	۰/۳۴	۲/۴۷	-	۱۱	۱/۱۷	۰/۳۴	۲/۴۷	-	-	-	-	-	-	۰/۷۷	۰/۳۷



شکل ۶ - مقایسه مقادیر سولفات و کلراید اندازه گیری شده و پیش بینی برای هر سه مدل

شکل ۷ - مقایسه نتایج پیش‌بینی مدل‌های ANN، WANN و MLR در برابر مقادیر مشاهداتی برای SO_4^{2-} و Cl^- 

شکل ۸ - نمودار دبی و سولفات مشاهده شده و پیش‌بینی شده، رابطه هیسترزیس بین دبی و سولفات در یک بازه از دوره آزمایش

منابع

گلابی، م.، موسوی جهرمی، س.ج و کرمی، ب.، ۱۳۸۵. شبیه‌سازی EC SAR و رودخانه کارون با استفاده از ۲۰۰۰ Qnet. هفتمین سمینار بین‌المللی مهندسی رودخانه، دانشگاه شهید چمران اهواز.

نوشادی، م.، سالمی، ح و احمدزاده، م.، ۱۳۸۶. شبیه‌سازی و پیش‌بینی برخی از پارامترهای کیفیت آب رودخانه زاینده رود با استفاده از شبکه عصبی مصنوعی، نشریه آب و فاضلاب، شماره ۶۴، زمستان، ۱۳۸۶، صص ۴۹-۶۵.

ودیعتی، م.، نخعی، م.، امرایی، و و میرعربی، ع.، ۱۳۹۲. ارزیابی کیفیت آب رود کارون با استفاده از شبیه‌سازی استنتاج فازی. مجله مهندسی منابع آب، سال ششم، تابستان ۱۳۹۲، صص ۴۹-۴۹.

Han,J.G., Ren,W.X and Sun,Z.S. 2005. Wavelet packet based damage identification of Beam structures. International Journal of Solids and Structures 4: 6610-6627.

Haykin,S. 1994. Neural Networks: A comprehensive foundation. MacMillan, New York. 432-444.

Longqin,X and Shuangyin,L. 2013. Study of short-term water quality prediction model based on wavelet

نتایج تحقیق نشان داد که موجک با درک مکانیسم سری زمانی قادر است تفسیری را از ساختار سری زمانی و اطلاعات مهم و کلیدی را از حافظه آن استخراج کند. مشخص شد که روش رگرسیون دقیق لازم برای پیش‌بینی را نداشت و به خصوص در پیش‌بینی نقاط بیشینه و کمینه، بسیار ضعیف عمل می‌کند، در حالیکه دو مدل دیگر پیش‌بینی مناسبی داشتند. مدل ترکیبی موجک عصبی توانست خطای در مدل‌های شبکه عصبی و رگرسیون کاهش دهد و ضریب کارایی E را بهبود ببخشد. برای تجزیه سری‌های زمانی از موجک مادر Db2 استفاده شد که از نظر شکل هندسی به سیگنال سری زمانی سولفات و کلراید شبیه‌تر بود. در این مقاله با مدل پیشنهادی ارائه شده (که از آنالیز موجک استفاده می‌کند)، نتایج مدل شبکه عصبی بهبود یافت. نوآوری این تحقیق بررسی پدیده هیسترزیس در دو پارامتر کیفیت ترکیبی عصبی-موجک به خوبی این پدیده را تشخیص می‌دهند، در صورتیکه رگرسیون قادر به نشان دادن این پدیده نمی‌باشد. پیشنهاد می‌شود در تحقیقات بعدی به منظور کاهش اغتشاشات سیگنال از سری‌های زمانی روزانه یا هفتگی در بازه زمانی طولانی-تری استفاده شود. هم‌چنین از پارامتر تبخیر به عنوان سیگنالی تأثیرگذار در روابط هیدرولوژیکی این منطقه در ترکیبات ورودی به مدل شبکه عصبی استفاده شود.

- prediction of daily suspended sediment load in rivers. *Science of The Total Environment.* 409: 2917-2928.
- Rajaee,T., Nourani,V., Zounemat-Kermani,M and Kisi,O. 2011. River Suspended Sediment Load Prediction: Application of ANN and Wavelet Conjugent Model. *Journal of Hydrologic Eng., ASCE.* 8: 613-627.
- Sandhu,N., and Finch,R. 1995. Methodology for flow and salinity estimation in the Sacramento-San Joaquin Delta and Suisun Marsh, Chapter 7. Artificial neural networks and their applications, 85: 343-365.
- Singh,R.M. 2012. Wavelet-ANN Model for Flood Events. *Advances in Intelligent and Soft Computing*, Springer. 131: 165-175.
- Williams,G. 1989. Sediment concentration versus water discharge during single hydrologic events in rivers. *Journal of Hydrology.* 111: 89-106.
- Zhou,H.C., Peng,Y., and Liang,G.H. 2008. The research of monthly discharge predictor-corrector model based on wavelet decomposition. *Water Resour Manage.* Springer. 22(2): 217-227.
- neural network. Elsevier, *Journal. Mathematical and Computer Modelling.* 58: 807-813.
- Najah,A., Elshafie,A., Karimi,O and Jaffer,O. 2009. Prediction of Johor river water quality Parameters using artificial neural networks. *Europ J Sci Res.* 28: 422-35.
- Nourani,V., Alami,M.T and Aminfar,M.H.. 2009. A Combined Neural-Wavelet Model for Prediction of Ligvanchai Watershed Precipitation. *Engineering Application of Artificial Intelligence.* 22: 146-477.
- Nourani,V., Hosseini Baghanam, A., Adamowski,A and Gebremichael,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. Elsevier, *Journal of Hydrology.* 476: 228-243.
- Qian-Jin,L., Zhi-Hue,S., Nu-Fang,F., Hua-De,Z and Lei,A. 2013. Modeling the daily suspended sediment concentration in a hyper concentrated river on the Loess Plateau, China, using the Wavelet-ANN approach. Elsevier, *Journal of Geomorphology.* 186: 181-190.
- Rajaee,T. 2011. Wavelet-ANN combination model for

Wavelet and ANN Combination Model for Prediction of Sulfate and Chloride Concentrations in Rivers (Case Study: Dez River)

T. Rajaee^{1*}, H. Jafari²

Received: Apr. 22, 2014 Accepted: Aug. 27, 2014

Abstract

One of the most important factors in sustainable development of watersheds is suitable water resources availability in terms of quantity and quality. This study considered artificial neural network (ANN), wavelet analysis and ANN combination (WANN), multi linear regression (MLR) models for monthly Sulfate (SO_4) and Chloride (Cl) modeling in the Dez River Bamdezh station and investigates the effects of data preprocessing on model performance using discrete wavelet. For this purpose, wavelet analysis and ANN model, observed time series of river discharge and SO_4 and Chloride were decomposed at different scales by wavelet analysis. Then, total effective time series of discharge and $\text{SO}_4(\text{Cl})$ were imposed as inputs to the neural network model for prediction of $\text{SO}_4(\text{Cl})$ in one-month-ahead. Results showed that the WANN model performance was better in prediction rather than the ANN and multi linear regression models. The wavelet analysis model produced reasonable predictions for the extreme values. This model dropped the mean absolute percentage error for the multi linear regression model and the ANN model for the Chloride modeling from 0.84 and 0.64, respectively, to 0.52, and SO_4 modeling from 1.7 and 0.95, respectively, to 0.63. Furthermore, the model could be employed to simulate hysteresis phenomenon for SO_4 modeling, while multi linear regression method is incapable in this event.

Key words: Artificial neural network, Wavelet transform, Sulfate(SO_4), Chloride(Cl), Dez River.

1- Assistant Professor, Dept., of Civil Eng., University of Qom. Qom

2- Former MSc Student in Hydraulic Structure, Dept., of Civil Eng., University of Qom, hhjafari@yahoo.com

(* -Corresponding Author Email: Taher_rajaee@yahoo.com.)