



فصلنامه علوم محیطی، دوره شانزدهم، شماره ۴، زمستان ۱۳۹۷

۱۳۵-۱۵۲

مقایسه مدل‌های Wavelet-GMDH و Wavelet-MLP در پیش‌بینی هدایت الکتریکی (EC) و نسبت جذب سدیم (SAR) در رودخانه زاینده‌رود

مسعود کرباسی* و سعیده دیندار

گروه مهندسی آب، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

تاریخ دریافت: ۱۳۹۶/۰۸/۲۴ تاریخ پذیرش: ۱۳۹۷/۰۹/۱۷

کرباسی، م. و س. دیندار. ۱۳۹۷. مقایسه مدل‌های Wavelet-GMDH و Wavelet-MLP در پیش‌بینی هدایت الکتریکی (EC) و نسبت جذب سدیم (SAR) در رودخانه زاینده‌رود. فصلنامه علوم محیطی. ۱۶(۴): ۱۳۵-۱۵۲.

سابقه و هدف: افزایش تقاضای آب و گسترش آلودگی منابع‌های آب در اثر افزایش فعالیت‌های کشاورزی، شهری و صنعتی موجب ایجاد مشکل‌های محیط زیستی در بسیاری از منطقه‌های جهان شده است. افزایش قابل توجه بار آلودگی و گوناگونی آلاینده‌های مختلف شهری، کشاورزی و صنعتی نیاز به مدیریت تلفیقی کمی و کیفی سیستم‌های منابع‌های آب را بیش از پیش ضروری ساخته است. پیش‌بینی‌های دقیق کوتاه مدت و بلندمدت پارامترهای کیفی رودخانه بویژه برای طراحی سازه‌های هیدرولیکی، برنامه‌ریزی آبیاری، بهره‌برداری بهینه از مخازن و برنامه‌ریزی محیطی ضروری است. با توجه به ویژگی‌های تصادفی بودن رخداد‌های هیدرولوژیکی، پیش‌بینی وضعیت آینده آب‌های سطحی همیشه با نبود قطعیت‌هایی همراه است. هدف پژوهش حاضر، بررسی عملکرد دو نوع شبکه عصبی مصنوعی MLP و GMDH بصورت تکی و همراه با تبدیل موجک گسسته (DWT) برای پیش‌بینی دو پارامتر کیفی مهم هدایت الکتریکی (EC) و نسبت جذب سدیم (SAR) در ایستگاه هیدرومتری زمانخان رودخانه زاینده‌رود در ۱، ۲ و ۳ ماه آینده است.

مواد و روش‌ها: در پژوهش حاضر، داده‌های کیفیت آب رودخانه زاینده‌رود در ایستگاه زمانخان در طول سال‌های ۱۳۶۳ الی ۱۳۸۴ مورد استفاده قرار گرفت. از مجموع ۲۲ سال داده، ۱۵ سال (کمابیش ۷۰ درصد) برای آموزش و ۷ سال (۳۰ درصد) برای آزمون مدل‌های توسعه داده شده مورد استفاده قرار گرفتند. دو نوع موجک مادر dmev و db4 مورد ارزیابی قرار گرفتند همچنین پارامترهای آماری نظیر RMSE و R^2 برای بررسی عملکرد مدل‌ها مورد استفاده قرار گرفتند.

نتایج و بحث: نتایج نشان داد که استفاده از تبدیل موجک گسسته موجب بهبود عملکرد مدل‌ها شده است. ترکیب‌های مختلفی از داده‌های ورودی (تأخیرهای مختلف) و دو نوع موجک‌های مادر مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل‌های ترکیبی موجک-MLP و موجک-GMDH در هر دو پارامتر کیفی EC و SAR در بازه‌های مورد پیش‌بینی نسبت به مدل‌های تکی MLP و GMDH دارای توانایی و دقت بالاتری در پیش‌بینی می‌باشند. نتایج مدل‌های بدون تبدیل موجک تنها در پیش‌بینی SAR یک ماه بعد عملکرد خوبی داشتند و قادر به پیش‌بینی‌های دو و سه ماه بعد نبودند. در پارامتر EC، مدل‌های MLP و GMDH دارای عملکرد بهتری بودند. همچنین نتایج نشان داد که استفاده از تأخیرهای زمانی سالانه موجب افزایش دقت نمی‌شود و در برخی موارد حتی سبب کاهش دقت نیز می‌گردد. بررسی انواع

*Corresponding Author. E-mail Address: m.karbasi@znu.ac.ir

موجک‌های مادر نیز نشان داد که موجک dmey مناسبترین نوع موجک برای پیش‌بینی پارامترهای کیفی EC و SAR می‌باشد. مقایسه دو مدل موجک-MLP و موجک-GMDH نشان دهنده برتری نسبی مدل موجک-MLP بود. با افزایش بازه پیش‌بینی از ۱ ماه تا ۳ ماه آینده دقت مدل‌ها کاهش پیدا کرد. این کاهش دقت در پیش‌بینی پارامتر SAR بیشتر بود، بطوریکه R^2 در پیش‌بینی ۱ ماه بعد SAR برابر ۰/۹۳۶ و در پیش‌بینی ۳ ماه بعد به ۰/۵۱۶ کاهش یافت. در پارامتر EC نیز R^2 در پیش‌بینی ۱ ماه بعد تا ۳ ماه بعد از ۰/۹۸۱ به ۰/۶۴۱ کاهش یافت.

نتیجه‌گیری: نتایج تحقیق حاضر می‌تواند بعنوان مبنایی برای برنامه‌ریزی‌های آینده در مورد کیفیت آب مصرفی باشد. پیشنهاد می‌شود مدل بیان شده در پژوهش حاضر در دیگر رودخانه‌های کشور نیز مورد بررسی قرار گیرد. همچنین ترکیب دیگر مدل‌های هوشمند نظیر ANFIS و SVM با تبدیل موجک نیز می‌توانند مورد بررسی و ارزیابی قرار گیرند.

واژه‌های کلیدی: پارامترهای کیفی آب، پیش‌بینی، موجک، هوش مصنوعی.

مقدمه

پشتیبان و مدل‌های درخت تصمیم از جمله روش‌های محاسباتی نرم هستند که بطور گسترده در زمینه‌های مختلف علوم و مهندسی مورد استفاده قرار گرفته‌اند.

در میان این روش‌ها، شبکه‌های عصبی GMDH بعنوان یک روش شناسایی شبکه هستند که در زمینه‌های مختلف بمنظور شناخت و پیش‌بینی رفتار سیستم‌های ناشناخته و یا پیچیده بر اساس داده‌های ورودی-خروجی بکار برده شده‌اند (Ivakhnenko, 1995) از جمله کاربردهای روش فوق می‌توان به پیش‌بینی عمق آبستگي پایه‌های پل در رسوب‌های چسبنده (Najafzadeh et al., 2013a)، پیش‌بینی آبستگي حول پایه‌های میانی پل‌ها (Najafzadeh et al., 2011)، پیش‌بینی آبستگي در پایه‌های کناری پل در رسوب‌های چسبنده (Najafzadeh et al., 2013b) و پیش‌بینی آبستگي لوله‌های زیر آب (Najafzadeh et al., 2014) اشاره کرد.

در زمینه کاربرد مدل‌های هوش مصنوعی در پیش‌بینی پارامترهای کیفی رودخانه‌ها نیز می‌توان به موارد زیر اشاره کرد. (Karami et al., 2006) در پژوهشی به تهیه مدل پیش‌بینی پارامترهای کیفی آب شامل هدایت الکتریکی (EC)، نسبت جذب سدیم (SAR) و کل املاح محلول (TDS) با استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی کیفیت آب رودخانه کارون پرداختند.

رودخانه‌ها و آب‌های جاری از دیر باز، مورد توجه و نیاز بشر بوده است و برای بهره‌برداری از منابع‌های آبی مناسب، جوامع انسانی و مراکز صنعتی و مراکز صنعتی کشاورزی و غیره بطور معمول در نزدیکی رودخانه‌ها برپا شده است. گسترش روز افزون فعالیت‌های کشاورزی و صنعتی و افزایش قابل توجه حجم فاضلاب‌ها موجب آلودگی منابع‌های آب از جمله رودخانه‌ها شده است (Karami et al., 2006). از این رو بررسی و پیش‌بینی تغییرپذیری پارامترهای کیفی آب در طول یک رودخانه باید مورد بررسی و توجه قرار گیرد. آگاهی از وضعیت کیفی آب‌های سطحی این امکان را فراهم می‌سازد تا ضمن استفاده از آن در موارد مختلف راهکارهایی اتخاذ شود تا کمترین آسیب به منابع‌های آبی وارد شود (Jafarzadeh et al., 2006).

امروزه با پیشرفت علم و تکنولوژی و گسترش استفاده از سیستم‌های کامپیوتری در محاسبه‌های پیچیده، شبکه‌های هوشمند کامپیوتری و بطور کلی هوش مصنوعی از اهمیت روز افزونی برخوردار شده‌اند. هوش مصنوعی سعی در مدلسازی پدیده‌ها و حل مسئله-های دشواری دارد که تحلیل آن‌ها به شیوه‌های ریاضی معمول یا برنامه نویسی تابعی غیرممکن و یا بسیار پیچیده است. شبکه‌های عصبی مصنوعی، سیستم استنتاج فازی-عصبی، برنامه‌ریزی بیان ژن، ماشین بردار

نشان داد هر سه روش عملکرد قابل قبولی در مدل‌سازی دارند. (2017) Haghizadeh *et al.* روند تغییرات زمانی سه پارامتر PH، HCO_3 و Na در رودخانه کهمان را مورد بررسی قرار دادند. نتایج نشان داد HCO_3 روند افزایشی دارد، ولی Na به دلیل نبودن سازنده‌ای نمکی در حوضه رودخانه روند ثابتی دارد و افزایشی نیست. (2018) Yaseen *et al.* از یک نوع مدل فازی عصبی تطبیقی ترکیبی برای پیش‌بینی شاخص کیفی (WQI²) استفاده کردند.

در سال‌های اخیر استفاده از مدل‌های ترکیبی بر پایه موجک در پیش‌بینی سری‌های زمانی هیدرولوژیکی (مانند دبی رودخانه‌ها، خشک‌سالی، بارندگی، سطح آب زیرزمینی و غیره)، مورد توجه بسیاری از محققان بوده است (Nourani *et al.* 2014). (2015) Rajaei *et al.* پیش‌بینی پارامترهای کیفی در رودخانه کرج نشان داد که با تلفیق شبکه‌های عصبی مصنوعی و تئوری موجک زمان محاسبه‌ها کاهش و دقت شبکه افزایش پیدا می‌کند. در پژوهشی (2018) Barzegar *et al.* از ترکیب دو مدل ELM^3 و موجک برای پیش‌بینی EC در رودخانه آجی چای مورد استفاده قرار دادند. نتایج ایشان گویای برتری مدل‌های ترکیبی نسبت به مدل‌های ساده است.

با توجه به مطالب گفته شده، آگاهی از کیفیت آب و تغییرپذیری‌های آن در آینده می‌تواند کمک شایانی به مدیریت منابع آب نماید. پژوهش حاضر برای نیل به هدف بالا و پیش‌بینی دو پارامتر کیفی هدایت الکتریکی و نسبت جذب سدیم صورت پذیرفت.

هدف‌های تحقیق حاضر عبارتند از: ۱- مقایسه عملکرد دو مدل شبکه عصبی مصنوعی MLP و GMDH در پیش‌بینی دو پارامتر EC و SAR در رودخانه زاینده رود، ۲- بررسی اثر ترکیب دو مدل بیان شده با تبدیل موجک گسسته و بررسی تاثیر آن بر دقت مدل، ۳-

نتایج ایشان نشان داد مدل‌های شبکه عصبی با دقت بالایی قادر به پیش‌بینی پارامترهای کیفی آب هستند. (2005) Kurunc *et al.* با استفاده از مدل SARIMA پارامترهای کیفی پتاسیم، سدیم، کلر، منیزیم، کلسیم، سولفات، دما، هدایت الکتریکی، PH و SAR در رودخانه سیرامک ترکیه را پیش‌بینی کردند. (2012) Ahmadi *et al.* برای پیش‌بینی آب رودخانه گنگ در هند بمنظور مدیریت صحیح حوضه آن، از مدل ARIMA استفاده کردند و نتیجه گرفتند که در زمان مناسب می‌توان برای کاهش آلاینده‌ها و رساندن آن‌ها به حد مجاز استانداردها گام‌هایی برداشت. (2009) Najah *et al.* کیفیت آب رودخانه جوهور را با استفاده از بررسی اکسیژن محلول رودخانه با شبکه‌های عصبی مصنوعی بررسی کردند و نتایج پژوهش آن‌ها گویای قدرت و توانایی بالای مدل پیشنهادی برای پیش‌بینی و شبیه‌سازی این پارامترها بود. (2011) Najah *et al.* تکنیک‌های هوشمند عصبی مختلفی را برای پیش‌بینی پارامترهای کیفی اکسیژن محلول (DO) و اکسیژن خواهی بیولوژیکی (BOD) و اکسیژن خواهی بیوشیمی (COD) بکار بردند. هدف آن‌ها نمایش مدلی برای پیش‌بینی پارامترهای کیفی با هدف صرفه‌جویی در هزینه و زمان لازم برای اندازه‌گیری این پارامترها بود. (2014) Sattari *et al.* با استفاده از روش تصمیم‌گیری درختی کیفیت آب برخی از رودخانه‌های واقع در دامنه جنوبی کوه سهند را مورد بررسی قرار داده و برای هر یک از رودخانه‌ها طبقه کیفیت را با استفاده از قوانین اگر آنگاه توسعه دادند. نتایج ایشان نشان داد که روش تصمیم‌گیری درختی قادر است با استفاده از کمترین تعداد پارامتر هیدروشیمیایی طبقه، کیفیت آب را با دقت بسیار بالایی پیش‌بینی کند. (2015) Ghavidel and Zeynalzadeh از روش‌های شبکه عصبی مصنوعی، سامانه استنتاج فازی و برنامه‌ریزی بیان ژن برای مدل‌سازی ویژگی‌های کیفی آب رودخانه بالادست سد مخزنی بوکان واقع در زربینه‌رود استفاده کردند. نتایج

سرچشمه آن ۴۰۵ کیلومتر در غرب شهرستان‌های فریدون شهر و فریدون قرار دارد که بین ۱۲۳ رودخانه اصلی ایران در شماره ۱۱ رودخانه پرجریان و از نظر متوسط دبی سالانه نیز با ۴۱ متر مکعب در ثانیه در شمار ۱۵ رودخانه پرآب ایران است. در تحقیق حاضر از داده‌های کیفیت آب رودخانه زاینده رود در ایستگاه هیدرومتری زمان خان استفاده گردید. داده‌های مورد استفاده مربوط به دوره زمانی ۱۳۶۳ - ۱۳۸۴ می‌باشد. ایستگاه زمان خان در مختصات ۳۲ درجه و ۱۹ دقیقه شمالی و ۵۰ درجه و ۵۱ دقیقه شرقی واقع شده است (شکل ۱). شکل ۲ تغییرپذیری‌های دو پارامتر EC و SAR را در بازه زمانی ۱۳۸۴-۱۳۶۳ نشان می‌دهد. از ۲۲ سال داده موجود، ۱۵ سال (۱۳۶۳-۱۳۷۷) برای آموزش شبکه و ۷ سال (۱۳۷۸-۱۳۸۴) برای آزمون مدل‌های توسعه داده شده، مورد استفاده قرار گرفت. جدول (۱) پارامترهای آماری مربوط به کلیه داده‌ها، داده‌های آموزش و آزمون را نشان می‌دهد.


بررسی تاثیر انتخاب نوع موجک مادر بر دقت مدل، ۴- پیش بینی پارامترهای کیفی در بازه‌های بیشتر از یک ماه (۲ و ۳ ماه) و ۵- بررسی تاثیر داده‌های ورودی به مدل

بررسی منبع‌های قبلی نشان دهنده این مطلب است که تا کنون شبکه عصبی GMDH در پیش‌بینی پارامترهای کیفی استفاده نشده و همچنین پیش‌بینی با افق بیشتر از یک ماه نیز انجام نگرفته است.

مواد و روش‌ها

منطقه مورد مطالعه

حوضه زاینده رود با مساحت ۴۱۵۰۰ کیلومتر مربع در استان اصفهان واقع شده است. این رودخانه از چشمه ریمه (زرد کوه بختیاری) واقع در استان چهارمحال سرچشمه می‌گیرد. از سرچشمه تا انتها که تالاب گاوخونی می‌باشد بیش از ۴۲۰ کیلومتر طول دارد و میانگین حجمی ۹۰۰ میلیون متر مکعب آب در آن تولید می‌شود.



شکل ۱ - تصویر ماهواره‌ای از ایستگاه هیدرومتری زمان خان واقع در رودخانه زاینده‌رود
Fig. 1 - Satellite image of Zaman Khan hydrometric station in Zayandeh-Rood River

جدول ۱ - پارامترهای آماری EC و SAR در داده‌های کلی، آموزش و آزمون

Table 1. Statistical parameters of EC and SAR at Train, Test and all data

داده‌های آزمون Test Data		داده‌های آموزش Train Data		همه داده‌ها All Data		پارامترهای آماری Statistical parameters
SAR	EC	SAR	EC	SAR	EC	
0.288	322	0.315	328	0.306	326	میانگین Mean
0.168	36	0.136	30	0.147	37	انحراف معیار Standard Deviation
0.078	240	0.078	220	0.078	220	حداقل Min
0.767	432	0.989	452	0.989	452	حداکثر Max



شکل ۲ - تغییرپذیری‌های EC و SAR در ایستگاه زمان‌خان رودخانه زاینده رود از سال ۱۳۶۳ تا ۱۳۸۴

Fig. 2 - Variation of EC and SAR at Zaman Khan Station during 1363-1384

آموزش به روش پس انتشار خطا، الگوریتم لوبزگ - مارکوارت، به دلیل همگرایی سریعتر در آموزش شبکه‌های با اندازه متوسط، برای استفاده در تحقیق حاضر انتخاب شده است.

شبکه عصبی GMDH

شبکه عصبی GMDH صورتی از الگوریتم GMDH است که به فرم و ساختار شبکه‌ای بیان شده است. شبکه عصبی GMDH شبکه‌ای خود سازمانده است که از چندلایه و هر لایه از چندین نرون تشکیل شده است. تمامی نرون‌ها از یک ساختار مشابه برخوردارند.

شبکه عصبی MLP

شبکه‌های چند لایه پیشخور یکی از مهمترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشند. بطور معمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نرون‌های پایه) می‌باشند که تشکیل دهنده لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشند. سیگنال ورودی در خلال شبکه و در مسیری رو به جلو بصورت لایه به لایه منتشر می‌شود. این نوع شبکه بطور معمول با عنوان پرسپترون چند لایه (MLP) نامیده می‌شود (Haykin, 1999). از میان روش‌های مختلف

موجکی این است که اطلاعات زمان و فرکانس را بطور مؤثری از سیگنال متغیر در زمان استخراج می‌کند (۱۹۹۱ Rioul and Vetterli). تابع موجک $\psi(t)$ ، موجک در نامیده می‌شود که دارای ویژگی‌های شوک بوده و به سرعت می‌تواند به صفر کاهش پیدا کند. تابع موجک $\psi(t)$ به شکل ریاضی زیر تعریف می‌شود.

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (2)$$

تبدیل‌های موجکی به دودسته موجک پیوسته و گسسته تقسیم می‌شوند. برای کاربردهای عملی، هیدرولوژیست‌ها اغلب سیگنال‌های زمانی پیوسته در اختیار ندارند، بلکه بیشتر سیگنال‌های زمانی گسسته در اختیار آن‌هاست. اگر انتخاب‌های مقیاس و موقعیت مبنی بر مزیت‌های هر دو (مقیاس‌ها و موقعیت‌های دوتایی) باشد، تحلیل‌ها دقیق خواهد بود. در این تحقیق از تبدیل موجک گسسته استفاده شده است.

تبدیل موجک گسسته

تبدیل موجکی گسسته (DWT) در پیش‌بینی‌های هیدرولوژیکی به نسبت بیشتر ترجیح داده می‌شود. بطور معمول در DWT، پارامترهای مقیاس و انتقال بر اساس موقعیت‌های دوتایی پایه‌گذاری می‌شوند، بنابراین می‌توان معادله CWT را به صورت زیر نگاشت.

$$W(\alpha, \beta) = \frac{1}{\sqrt{\alpha}} \sum_{t=1}^{N-1} s(t) \psi^* \left(\frac{t-\beta}{\alpha} \right) dt \quad (3)$$

که N ، طول سیگنال‌های گسسته و $W(\alpha, \beta)$ ضرایب موجک برای موجک گسسته با مقیاس $\alpha = 2^m$ و انتقال $\beta = 2^m n$ می‌باشند. اعداد صحیح m و n به ترتیب میزان تأخیر و انتقال موجک را کنترل می‌کنند. با جایگذاری بجای α و β معادله زیر را خواهیم داشت.

$$W(m, n) = 2^{-m/2} \sum_{t=1}^{N-1} s(t) \psi^*(2^{-m}t - n) \quad (4)$$

تبدیل موجک گسسته نقاط ضعف تبدیل پیوسته را مرتفع ساخته، ضمن اینکه گزینه‌ی مناسبی برای داده‌های گسسته محسوب می‌شود. تجزیه یک سیگنال به دو مؤلفه‌ی تقریب‌ها و جزئیات تقسیم می‌شوند که در واقع تقریب‌ها، فیلترهای پایین‌گذر و جزئیات فیلترهای بالا

ویژگی‌های بارزی که در این نوع از شبکه‌ها دیده می‌شود، گویای آن است که نرون‌های مرحله قبلی و یا لایه قبلی عامل و یا مولد تولید نرون‌های جدید هستند. از میان نرون‌های تولیدشده لزوماً باید تعدادی از آن‌ها حذف شوند تا به این وسیله از واگرایی شبکه جلوگیری بعمل بیاید. به اصطلاح به این‌گونه نرون‌ها، نرون مرده گفته می‌شود. یکی از مسئله‌های مهمی که در شبکه‌های عصبی مصنوعی چندلایه مطرح می‌شود، طراحی ساختار شبکه است. در این طراحی باید تعداد لایه‌ها و نیز ساختار درونی از قبیل تعداد وزن‌ها و میزان اولیه آن‌ها و همچنین تابه محرک هر نرون بصورت مناسب انتخاب شوند تا یک نگاشت مناسب و ایده‌آل میان داده‌های ورودی و خروجی برقرار شود (Ivakhnenko, ۱۹۹۵). ارتباط بین متغیرهای ورودی-خروجی را می‌توان با سری توابع ولترا که مشابه با چندجمله‌ای گسسته شده کولموگروف-گابور است بیان نمود.

$$y = a_0 + \sum_{i=1}^m a_i X_i + \sum_{i=1}^m \sum_{j=1}^m a_{ijk} X_i X_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} X_i X_j X_k + \dots \quad (1)$$

که $X = (x_1, x_2, \dots, x_m)$ بردار متغیرهای ورودی و $A = (a_0, a_1, a_2, \dots, a_m)$ بردار وزن‌ها می‌باشند. چندجمله‌ای کولموگروف-گابور می‌تواند هر توالی تصادفی ایستا را تقریب بزند و توسط هر روش تطبیقی یا یک سیستم معادلات نرمال گوسین قابل محاسبه است. ایواخنکو با الهام از این چندجمله‌ای، الگوریتم GMDH را توسعه داد (Ivakhnenko, 1968).

موجک

تبدیل موجکی، تبدیلی است که سیگنال را به یک مجموعه از توابع اساسی سیگنال تجزیه می‌کند و در حقیقت یک مجموعه تابع اساسی از تأخیر و تغییر در مقیاس موجک مادر به دست می‌آید. تبدیل موجکی سیگنال بصورت همبستگی سیگنال و موجک تبدیل یافته توضیح داده شده است، که این تعریف را از بطن فرمول ضریب موجکی می‌توان دریافت کرد. مزیت مهم تبدیل

گزینش با انتخاب موجک‌های مادر مختلف و انجام روش سعی و خطا است. همچنین ممکن است بهترین انتخاب را بتوان بر مبنای شباهت بین شکل سری زمانی جریان رودخانه و ضریب موجکی وابسته به آن انجام داد. اگرچه این موضوع نیاز به تحقیق وسیعی در بررسی‌های آینده دارد. بعضی از مهمترین موجک‌های مادر عبارت‌اند از: هار، دابچیز (db)، کلاه مکزیکی، سیملت، میر، کوهیفلت و مورلت می‌باشند (Iyengar et al., 2002). بسته به نوع سیگنال و هدف از آنالیز کردن، بهترین نوع موجک مادر را می‌توان به کاربرد. در این مطالعه از موجک‌های db4 و dmev استفاده شده است.

برای بررسی نتایج به‌دست‌آمده در این تحقیق از معیارهای ضریب تبیین R^2 ، جذر میانگین مربعات خطا RMSE، میانگین خطای انحراف MBE و درصد میانگین خطای مطلق MAPE استفاده گردید. این معیارها به‌صورت زیر تعریف می‌شوند.

$$R^2 = \frac{(\sum_{i=1}^N (Q_i - \bar{Q}_i)(P_i - \bar{P}_i))^2}{\sum_{i=1}^N (Q_i - \bar{Q}_i)^2 \sum_{i=1}^N (P_i - \bar{P}_i)^2} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_i - P_i)^2}{N}} \quad (8)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (Q_i - P_i) \quad (9)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Q_i - P_i}{Q_i} \right| \times 100 \quad (10)$$

$$RRMSE = \frac{RMSE}{\bar{O}_i} \times 100 \quad (11)$$

در کلیه در روابط بالا O_i مقادیر مشاهداتی دبی و P_i مقادیر پیش‌بینی‌شده از مدل‌های مختلف و \bar{O}_i و \bar{P}_i نیز به ترتیب میانگین مقادیر مشاهداتی و پیش‌بینی می‌باشند. میزان ضریب تبیین بین صفرتا یک است. راندمان مدل با افزایش میزان R^2 بالا می‌رود و مدل‌سازی بهینه زمانی اتفاق می‌افتد که R^2 برابر یک باشد. بطور کلی ضریب تبیین بزرگتر از ۰/۵ نشان‌دهنده تطابق قابل‌قبول مدل با سیستم واقعی است. معیار ارزیابی MBE بیانگر میانگین خطای انحراف است. این معیار افزون بر دارا بودن علامت مثبت (بیش برآوردی مدل) و منفی (کم برآوردی مدل) مقدار انحراف از مقادیر مشاهده را نیز نشان می‌دهد.

گذر را تداعی می‌کنند. به‌عبارت‌دیگر فرکانس‌های بالا و اغتشاشات، بیشتر خود را در جزئیات نشان داده و فرکانس‌های پایین و تغییرپذیری‌های اقلیمی هموار و طولانی‌مدت، خود را در تقریب‌ها نمایان می‌سازند (Hassanzadeh et al., 2012). در DWT سیگنال اصلی از میان دو فیلتر مکمل عبور می‌کند و بصورت ترکیبی از یک تقریب و یک جز بیرون می‌آید. تقریب (A)، دارای مقیاس بالا و فرکانس پایین و جز (D) دارای مقیاس پایین و فرکانس بالا از اجزا خروجی از سیگنال هستند. بطورمعمول تقریب، مهمترین بخش سیگنال است که اطلاعات پیش‌زمینه داده‌ها را نشان می‌دهد. این فرآیند تجزیه تا رسیدن به سطوح مختلف دقت (n) می‌تواند تکرار شود.

$$signal(s) = Approx_n(t) + Detail_i(t) \quad (5)$$

روند پردازش با تبدیل موجکی گسسته چنین آغاز می‌شود که سیگنال اصلی از میان دو فیلتر مکمل عبور می‌کند و بصورت ترکیبی از یک تقریب^۴ و یک جز^۵ بیرون می‌آید. تقریب (A)، دارای مقیاس بالا و فرکانس پایین و جز (D) دارای مقیاس پایین و فرکانس بالا از اجزا خروجی از سیگنال هستند. این فرآیند تجزیه تا رسیدن به سطوح مختلف دقت، (n) بار می‌تواند تکرار شود (Badrzadeh, 2014). در حالت کلی دو روش متداول برای تعیین تعداد سطح مناسب تجزیه وجود دارد. اولین روش با استفاده از سعی خطا و دومین روش استفاده از رابطه (۶) توسط ونگ و دینگ به شرح زیر می‌باشد:

$$L = INT[Log(N)] \quad (6)$$

در رابطه فوق، L تعداد سطوح تجزیه، N طول سری داده‌های اولیه و INT عملگر صحیح می‌باشد.

موجک مادر

انواع مختلفی از موجک مادر وجود دارد. در مهندسی آب، مهمترین ویژگی هر موجک مادر، شکل آن هست. انتخاب مناسب موجک مادر نگرانی اصلی در مدل‌سازی ترکیبی موجک در هیدرولوژی است. بهترین

انتخاب مناسب نمونه‌های ورودی و خروجی) و منبع‌های محاسباتی باشد. گام دوم مربوط به بازخوانی داده‌ها در محیط نرم‌افزاری مطلب می‌باشد. در این مرحله بعد از فراخوانی داده‌های موردنیاز برای مدل‌سازی، انتخاب افق‌های زمانی برای پیش‌بینی پارامتر کیفی در مقیاس ماهانه انجام گرفت. افق‌های زمانی انتخاب شده شامل افق‌های زمانی یک ماهه، دوماهه و سه ماهه می‌باشد. تعیین ساختارهای ورودی مناسب به مدل برای پیش‌بینی پارامتر کیفی به ازای هر یک از افق‌های زمانی تعیین شده نیز بخشی از مرحله بازخوانی داده‌ها می‌باشد. در جدول (۲) ساختارهای ورودی به مدل‌های MLP و GMDH نشان داده شده است. هدف از تعیین ساختارهای ورودی به شبکه، تشکیل ماتریس داده‌های ورودی و هدف متناظر با هر یک از ساختارهای ورودی به شبکه می‌باشد.

MBE برابر صفر نشان می‌دهد که برآورد مدل خوب بوده و در آن هیچ‌گونه انحرافی وجود ندارد (Kazemi, 2012). *et al.* RRMSE جذر مجموع مربعات خطای بدون بعد می‌باشد. اگر RRMSE کمتر از ۱۰ درصد باشد، مدل بعنوان یک مدل عالی طبقه‌بندی می‌شود. اگر RRMSE بین ۱۰ تا ۲۰ درصد باشد، مدل خوب است. اگر RRMSE بین ۲۰ تا ۳۰ درصد باشد، مدل متوسط و اگر RRMSE بالای ۳۰ درصد باشد، مدل ضعیف طبقه‌بندی می‌شود (Mihoub *et al.*, 2016).

اولین گام در مدل‌سازی و پیش‌بینی پارامتر کیفی رودخانه با استفاده از روش‌های هوش مصنوعی، انتخاب نوع شبکه است. از میان انواع شبکه عصبی، ساختار پرسپترون چندلایه در پیش‌بینی مسئله‌های مختلف در مهندسی آب بهترین عملکرد را دارا می‌باشد، ولی باید دارای تعداد کافی لایه مخفی، داده برای آموزش (با

جدول ۲- پارامترهای مختلف ورودی به مدل MLP و GMDH (منظور از QP، پارامتر کیفی پیش‌بینی شده می‌باشد)
Table 2. Different parameters as input to MLP and GMDH models (QP means forecasted quality parameter)

سری زمانی Times series	داده‌های ورودی Input data	نام مدل Model name	ساختار ورودی Input structure
ماهانه Monthly	EC SAR	M1	QP _{T-1}
		M2	QP _{T-1} , QP _{T-2}
		M3	QP _{T-1} , QP _{T-2} , QP _{T-3}
		M4	QP _{T-1} , QP _{T-2} , QP _{T-3} , QP _{T-4}
		M5	QP _{T-1} , QP _{T-2} , QP _{T-3} , QP _{T-4} , QP _{T-5}
		M6	QP _{T-1} , QP _{T-2} , QP _{T-3} , QP _{T-4} , QP _{T-5} , QP _{T-6}
		M7	QP _{T-1} , QP _{T-2} , QP _{T-3} , QP _{T-4} , QP _{T-5} , QP _{T-6} , QP _{T-12}
		M8	QP _{T-1} , QP _{T-2} , QP _{T-3} , QP _{T-4} , QP _{T-5} , QP _{T-6} , QP _{T-12} , QP _{T-24}
		M9	QP _{T-1} , QP _{T-2} , QP _{T-3} , QP _{T-4} , QP _{T-5} , QP _{T-6} , QP _{T-12} , QP _{T-24} , QP _{T-36}

تعداد نرون‌های لایه ورودی و خروجی تابعی از نوع مسئله است، بدین معنی که با آگاهی از یک مسئله می‌توان تعداد نرون‌های ورودی و خروجی شبکه را به دست آورد (Asadabadi *et al.*, 2014). در این تحقیق، تعداد بهینه نرون‌های لایه میانی شبکه با روش سعی و خطا تعیین گردید.

پس از تعیین ساختارهای ورودی به شبکه، متناظر با هر یک ساختارهای ورودی، ماتریس داده‌های ورودی و هدف به شبکه تشکیل شد. در گام چهارم مجموعه داده‌های آموزش و صحت‌سنجی شبکه انتخاب شد. در تحقیق حاضر از ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد داده‌ها برای صحت‌سنجی استفاده شد. در شبکه‌های عصبی

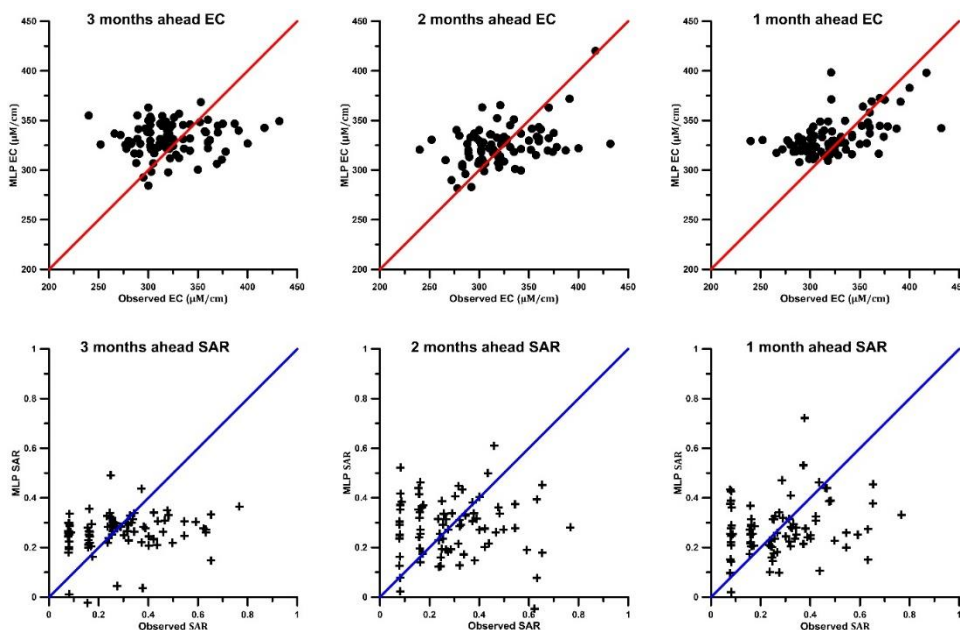
نتایج و بحث

۲ و ۳ ماه بعد عملکرد خوبی نداشته و میزان RRMSE بالای ۳۰ درصد به دست آمده، نشان دهنده عملکرد ضعیف مدل در پیش‌بینی SAR است. شکل (۳) نمودار پراکندگی بین داده‌های مشاهداتی و پیش‌بینی شده یک دو و سه ماه بعد برای مدل MLP را برای پارامترهای EC و SAR نشان می‌دهد. با توجه به شکل (۳) نمودارهای پیش‌بینی SAR نشان دهنده عملکرد ضعیف مدل در پیش‌بینی است. همچنین بررسی ترکیب‌های مختلف ورودی به مدل نیز نشان می‌دهد که مدل‌های با تأخیر ۲ تا ۵ ماه (M2, M3, M4, M5) عملکرد بهتری داشته‌اند و استفاده از تاخیرهای سالانه (M7, M8, M9) تاثیری بر عملکرد مدل نداشته است.

جدول (۳) نتایج پیش‌بینی شبکه عصبی MLP را برای پارامترهای کیفی EC و SAR در بازه‌های زمانی ۱، ۲ و ۳ ماه بعد نشان می‌دهد. با توجه به جدول (۳) مدل شبکه عصبی MLP در پیش‌بینی پارامترهای EC برای یک ماه بعد تا حدودی موفق عمل کرده است ($R^2=0.316$ و $RMSE=31.45$). با توجه به اینکه میزان RRMSE نیز کمتر از ۱۰ درصد می‌باشد، عملکرد مدل تا حدودی مطلوب برآورد می‌شود. در پیش‌بینی دو و سه ماه بعد، EC مقدار RRMSE بین ۱۰ تا ۲۰ درصد است که نشان دهنده عملکرد خوب مدل می‌باشد. با توجه به جدول (۳) مدل شبکه عصبی MLP در پیش‌بینی SAR برای بازه ۱،

جدول ۳- نتایج مدل MLP در پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR
Table 3. MLP results in forecasting EC and SAR parameters 1, 2 and 3 months ahead

پارامتر کیفی Quality parameter	بازه پیش‌بینی (ماهانه) Forecasting interval (Monthly)	بهترین مدل ورودی Best Model Input	RMSE	R ²	MAPE	MBE	RRMSE
EC	1	M4	31.45	0.316	7.88	-	9.76
EC	2	M2	32.88	0.174	7.91	-2.76	10.21
EC	3	M5	38.62	0.013	10.02	-9.34	11.99
SAR	1	M5	0.157	0.126	68.95	0.014	54.42
SAR	2	M4	0.203	0.001	84.50	0.002	70.58
SAR	3	M5	0.171	0.039	68.73	0.026	59.52



شکل ۳- نمودار پراکندگی پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR توسط مدل شبکه عصبی MLP در مقابل مقادیر مشاهداتی

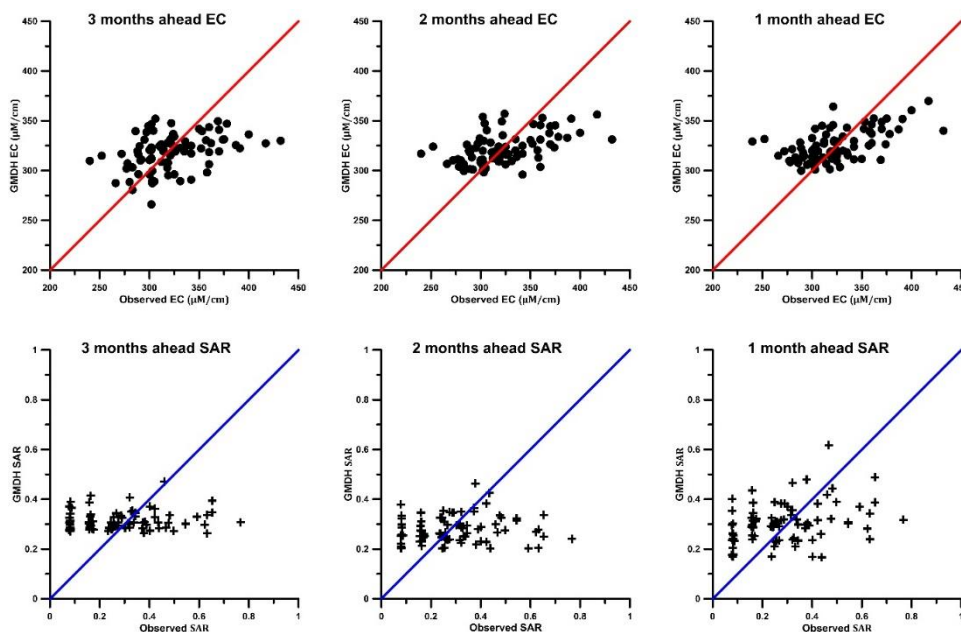
Fig. 3- Scatter plots of forecasting EC and SAR with MLP model in 1, 2 and 3 months ahead vs. observed values

مدل MLP از ۹/۷۶٪ به ۹/۱۸٪ در مدل GMDH کاهش یافته است. کاهش RRMSE در پیش‌بینی های ۲ و ۳ ماه توسط مدل GMDH نیز مشاهده می‌شود. شکل (۴) نمودار پراکندگی بین داده‌های مشاهداتی شده ۱، ۲ و ۳ ماه بعد برای مدل GMDH را برای پارامترهای EC و SAR نشان می‌دهد. بررسی ترکیب ورودی مناسب در مدل GMDH نشان دهنده این موضوع است که در مدل‌های پیش‌بینی ۲ و ۳ ماه بعد، استفاده از تاخیرهای سالانه موجب بهبود عملکرد مدل شده است.

جدول (۴) نتایج پیش‌بینی EC و SAR برای ۱، ۲ و ۳ ماه آینده توسط شبکه عصبی GMDH را نشان می‌دهد. نتایج مدل GMDH نیز نشان دهنده عملکرد بهتر مدل در پیش‌بینی EC است. مدل GMDH نیز به مانند مدل MLP قادر به پیش‌بینی SAR نیست و عملکرد مدل همچنان ضعیف می‌باشد. مقایسه دو مدل GMDH و MLP با توجه به جدول‌های (۳) و (۴) نشان دهنده این موضوع است که مدل شبکه عصبی GMDH تا حدودی بهتر از مدل شبکه عصبی MLP عمل کرده است، کمترین میزان RRMSE در

جدول ۴- نتایج مدل GMDH در پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR
Table 4. GMDH results of forecasting EC and SAR parameters in 1, 2 and 3 months ahead

پارامتر کیفی Quality parameter	بازه پیش‌بینی (ماهانه) Forecasting interval (Monthly)	بهترین مدل ورودی Best Model Input	RMSE	R ²	MAPE	MBE	RRMSE
EC	1	M5	29.58	0.333	7.25	-2.39	9.18
EC	2	M8	31.22	0.237	7.55	0.63	9.70
EC	3	M8	33.54	0.139	8.13	3.60	10.42
SAR	1	M5	0.158	0.125	71.81	-0.014	55.01
SAR	2	M9	0.168	0.021	69.98	0.011	85.38
SAR	3	M3	0.169	0.012	84.53	-0.025	58.68



شکل ۴- نمودار پراکندگی پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR توسط مدل شبکه عصبی GMDH در مقابل مقادیر مشاهداتی
Fig. 4- Scatter plots of forecasting EC and SAR with GMDH model in 1, 2 and 3 months ahead vs. observed values

نداشته است. عملکرد مدل موجک-شبکه عصبی MLP در پیش‌بینی ۲ و ۳ ماه بعد EC نیز عملکرد قابل قبولی بوده و با توجه به میزان RRMSE به‌دست آمده، این مدل دارای عملکرد عالی است. مقایسه دو نوع موجک مورد استفاده در پیش‌بینی ۲ و ۳ ماه بعد نیز نشان دهنده برتری موجک dmey است.

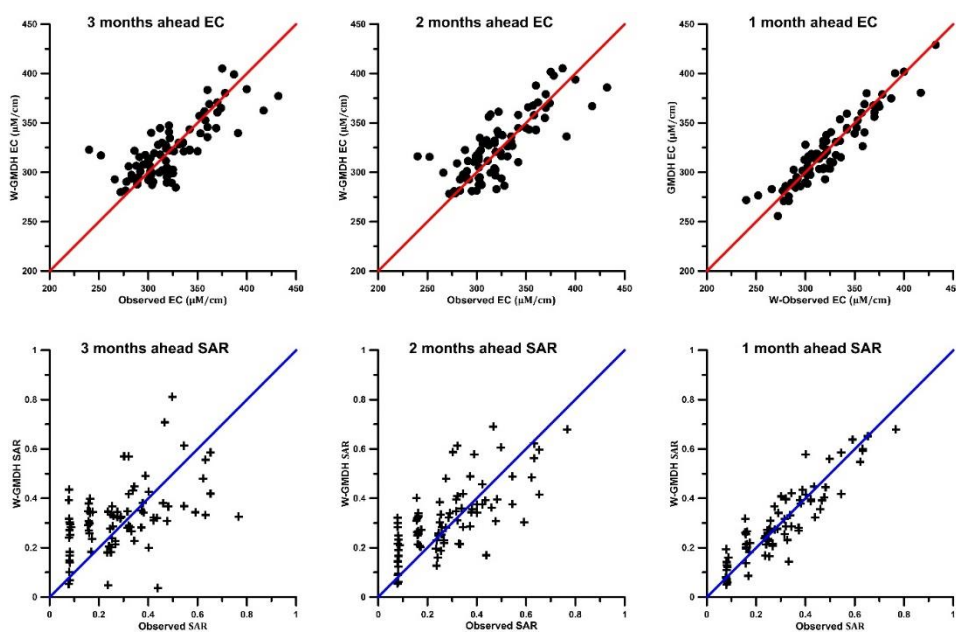
با توجه به جدول (۵) مدل موجک-شبکه عصبی MLP، با نوع موجک dmey، عملکرد خوبی در پیش‌بینی پارامتر SAR برای یک ماه بعد دارد ($R^2=0/936$ و $RRMSE=15$). مقایسه دو نوع موجک db4 و dmey نیز نشان دهنده برتری موجک dmey ($RRMSE=15$) نسبت به موجک db4 ($RRMSE=25/81$) است. نتایج به‌دست آمده برای پیش‌بینی ۲ و ۳ ماه بعد پارامتر SAR نشان دهنده عملکرد ضعیف مدل می‌باشد، هرچند که نتایج در مقایسه با مدل بدون موجک، بهبود یافته است. بررسی ترکیب‌های ورودی بهینه برای پیش‌بینی SAR نشان می‌دهد که تاخیرهای سالانه تأثیری بر بهبود عملکرد مدل‌ها ندارد. شکل (۵) نمودار پراکندگی بین داده‌های مشاهداتی شده ۱، ۲ و ۳ ماه بعد برای مدل ترکیبی موجک-شبکه عصبی MLP و نوع موجک dmey را برای پارامترهای EC و SAR نشان می‌دهد.

بمنظور بررسی تأثیر پیش‌پردازش تبدیل موجک گسسته بر روی داده‌های کیفی آب از دو نوع موجک مادر پر استفاده در مدلسازی پارامترهای هیدرولوژیکی (db4 و dmey) استفاده گردید. با توجه به اینکه تعداد داده‌های سری زمانی ۲۶۴ داده می‌باشد، با توجه به رابطه ۶، سطح تجزیه ۲ به‌دست می‌آید. جدول (۵) نتایج مدل ترکیبی موجک-شبکه عصبی MLP را برای پیش‌بینی EC و SAR نشان می‌دهد. نوع موجک مادر مورد استفاده نیز dmey و db4 می‌باشد. بنابر جدول (۵) تجزیه سری زمانی توسط تبدیل موجک گسسته در هر دو نوع موجک مورد بررسی، موجب بهبود عملکرد مدل شده است. مدل ترکیبی موجک-شبکه عصبی MLP با نوع موجک dmey توانسته است با دقت بسیار بالایی میزان EC را برای یک ماه بعد پیش‌بینی کند ($R^2=0/981$ و $RRMSE=1/63$) و با توجه به میزان RRMSE بعنوان یک مدل عالی طبقه بندی می‌شود. مقایسه کاربرد دو نوع موجک نشان دهنده عملکرد بهتر موجک dmey ($RRMSE=1/63$) نسبت به موجک db4 ($RRMSE=4/17$) است. همچنین برای پیش‌بینی یک ماه بعد EC، ترکیب ورودی M6 بهترین ترکیب ورودی بوده است که نشان دهنده این موضوع است که تاخیرهای سالانه تأثیری بر بهبود عملکرد مدل

جدول ۵- نتایج مدل موجک- MLP در پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR

Table 5. Wavelet-MLP model results in forecasting EC and SAR parameters 1, 2 and 3 months ahead

پارامتر کیفی Quality parameter	بازه پیش‌بینی (ماهانه) Forecasting interval (Monthly)	نوع موجک Wavelet type	بهترین مدل ورودی Best Model Input	RMSE	R ²	MAPE	MBE	RRMSE
EC	1	dmey	M6	5.26	0.981	1.24	-1.24	1.63
EC	2	dmey	M8	16.45	0.803	4.36	-4.12	5.11
EC	3	dmey	M3	22.43	0.641	5.74	0.97	6.97
SAR	1	dmey	M5	0.043	0.936	18.70	-0.007	15.00
SAR	2	dmey	M5	0.120	0.585	43.08	-0.014	4.83
SAR	3	dmey	M4	0.124	0.516	52.82	-0.025	43.17
EC	1	db4	M6	13.41	0.868	3.09	0.384	4.17
EC	2	db4	M5	23.87	0.572	5.88	-1.53	7.41
EC	3	db4	M2	29.49	0.331	6.85	3.19	9.15
SAR	1	db4	M6	0.074	0.818	33.44	-0.021	25.81
SAR	2	db4	M5	0.129	0.405	46.34	0.003	45.09
SAR	3	db4	M4	0.149	0.268	66.99	-0.028	51.90



شکل ۵- نمودار پراکندگی پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR توسط مدل موجک dmey- شبکه عصبی MLP در مقابل مقادیر مشاهداتی
Fig. 5- Scatter plots of forecasting EC and SAR with wavelet-MLP_dmey wavelet model in 1, 2 and 3 months ahead vs. observed values

عصبی MLP در پیش‌بینی ۲ و ۳ ماه بعد EC نیز عملکرد قابل قبولی بوده و با توجه به میزان RRMSE به دست آمده، مدل دارای عملکرد عالی است. مقایسه عملکرد موجک‌های dmey و db4 نشان می‌دهد که موجک dmey در مدل موجک- شبکه عصبی GMDH نیز دارای عملکرد بهتری است.

با توجه به جدول (۶)، مدل موجک- شبکه عصبی GMDH، با نوع موجک dmey، عملکرد متوسط در پیش‌بینی پارامتر SAR برای یک ماه بعد دارد ($R^2=0/841$) و ($RRMSE=23/21$) مقایسه دو نوع موجک db4 و dmey نیز نشان دهنده برتری موجک dmey ($RRMSE=23/21$) نسبت به موجک db4 ($RRMSE=34/38$) است. نتایج به- دست آمده برای پیش‌بینی ۲ و ۳ ماه بعد پارامتر SAR نشان دهنده عملکرد ضعیف مدل می‌باشد. بررسی ترکیب‌های ورودی بهینه برای پیش‌بینی SAR نشان می‌دهد که تاخیرهای سالانه به جز پیش‌بینی ۱ ماه بعد تاثیری بر بهبود عملکرد مدل‌ها ندارد. شکل (۵) نمودار پراکندگی بین داده‌های مشاهداتی شده ۱، ۲ و ۳ ماه بعد

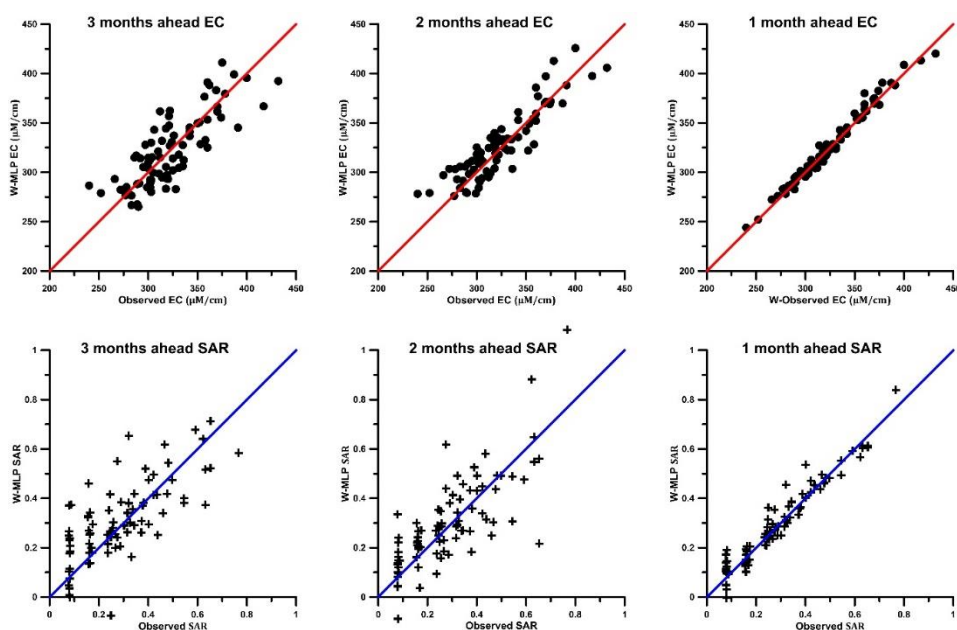
جدول (۶)، نتایج مدل ترکیبی موجک- شبکه عصبی GMDH را برای پیش‌بینی EC و SAR نشان می‌دهد. نوع موجک مادر مورد استفاده نیز dmey و db4 می‌باشد. بنابر جدول (۶) تجزیه سری زمانی توسط تبدیل موجک گسسته در هر دو نوع موجک مورد بررسی، موجب بهبود عملکرد مدل شده است.

مدل ترکیبی موجک- شبکه عصبی GMDH با نوع موجک dmey توانسته است با دقت بالایی میزان EC را برای یک ماه بعد پیش‌بینی کند ($R^2=0/871$) و ($RRMSE=4/01$) و با توجه به میزان RRMSE بعنوان یک مدل عالی طبقه‌بندی می‌شود. مقایسه کاربرد دو نوع موجک نشان دهنده عملکرد بهتر موجک dmey ($RRMSE=4/01$) نسبت به موجک db4 ($RRMSE=4/84$) است. همچنین برای پیش‌بینی یک ماه بعد EC، ترکیب ورودی M6 به مانند مدل موجک- MLP بهترین ترکیب ورودی بوده است که نشان دهنده این موضوع است که تاخیرهای سالانه تاثیری بر بهبود عملکرد مدل نداشته است. عملکرد مدل موجک- شبکه

برای مدل ترکیبی موجک - شبکه عصبی MLP و نوع موجک dmey را برای پارامترهای EC و SAR نشان می- دهد. شکل (۶) نمودار پراکندگی بین داده‌های مشاهداتی شده ۱، ۲ و ۳ ماه بعد برای مدل ترکیبی موجک - شبکه عصبی GMDH و نوع موجک dmey را برای پارامترهای EC و SAR نشان می‌دهد.

جدول ۶- نتایج مدل موجک- GMDH در پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR
Table 6. Wavelet-GMDH model results in forecasting EC and SAR parameters 1, 2 and 3 months ahead

پارامتر کیفی Quality parameter	بازه پیش‌بینی (ماهانه) Forecasting interval (Monthly)	نوع موجک Wavelet type	بهترین مدل ورودی Best Model Input	RMSE	R ²	MAPE	MBE	RRMSE
EC	1	dmey	M6	12.93	0.871	3.18	1.15	4.01
EC	2	dmey	M6	23.09	0.607	5.62	-3.99	7.17
EC	3	dmey	M3	22.58	0.601	5.30	-0.16	7.01
SAR	1	dmey	M7	0.067	0.841	26.05	-0.005	23.21
SAR	2	dmey	M5	0.124	0.505	52.27	-0.031	42.92
SAR	3	dmey	M3	0.158	0.238	69.76	-0.033	54.99
EC	1	db4	M7	15.58	0.812	3.74	-1.14	4.84
EC	2	db4	M7	24.09	0.561	5.71	-3.82	7.48
EC	3	db4	M6	29.77	0.345	7.07	-6.77	9.24
SAR	1	db4	M3	0.099	0.659	44.71	-0.014	34.38
SAR	2	db4	M2	0.137	0.398	59.76	-0.032	47.54
SAR	3	db4	M3	0.153	0.281	72.91	-0.046	53.17



شکل ۶- نمودار پراکندگی پیش‌بینی ۱، ۲ و ۳ ماه بعد EC و SAR توسط مدل موجک dmey- شبکه عصبی GMDH در مقابل مقادیر مشاهداتی
Fig. 6- Scatter plots of forecasting EC and SAR with wavelet-GMDH_dmey wavelet model in 1, 2 and 3 months ahead vs. observed values

نتایج به‌دست آمده در قسمت قبل نشان داد که مدل‌های بر پایه پیش پردازش تبدیل موجک موجب افزایش قابل توجه مدل‌ها گردیده‌اند. نتیجه بالا توسط بیشتر محققانی که مدل‌های ترکیبی بر پایه موجک را با مدل‌های بدون استفاده از موجک مقایسه کرده‌اند،

مقایسه عملکرد دو مدل موجک dmey- شبکه عصبی MLP و موجک dmey- شبکه عصبی GMDH را نشان می‌دهد که مدل موجک- شبکه عصبی MLP در هر دو پارامتر EC و SAR و بازه‌های پیش‌بینی ۱، ۲ و ۳ ماه عملکرد بهتری داشته است.

آب، برای مدل‌سازی دقیقتر نیاز به پیش‌پردازش داده‌های ورودی به مدل است، زیرا تبدیل موجک با جدا نمودن سیگنال به فرکانس‌های بالا و پایین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. مقایسه دو نوع شبکه عصبی MLP و GMDH در مدل‌های بدون موجک نشان دهنده برتری نسبی مدل GMDH است در حالیکه در مدل‌های موجک دار این روند برعکس بود و شبکه عصبی MLP نتایج بهتری را نمایش داد. نتایج این تحقیق نشان داد استفاده از تاخیرهای طولانی مدت سالانه موجب بهبود عملکرد مدل نمی‌شود و در برخی موارد حتی موجب تضعیفتر شدن عملکرد مدل‌ها نیز می‌گردد. نتایج تحقیق حاضر گویای این مطلب بود که پارامتر کیفی EC را می‌توان با دقت قبولی تا ۳ ماه آینده پیش‌بینی نمود، در حالیکه در پیش‌بینی SAR فقط پیش‌بینی یک ماه بعد قابل قبول بود و پیش‌بینی‌های بلندمدت این پارامتر امکان پذیر نبود. مقایسه بین موجک‌های مادر مورد استفاده نیز نشان داد که موجک میر به دلیل پیچیدگی بالاتر و شباهت بیشتر به سری زمانی تبخیر-تغرق مرجع هفتگی می‌تواند، موجب افزایش دقت پیش‌بینی شود. نتایج تحقیق حاضر می‌تواند در برنامه‌ریزی مربوط به پارامترهای کیفی آب مورد استفاده قرار بگیرد.

پی‌نوشت‌ها

- ¹ Discrete Wavelet Transform
- ² Water Quality Index
- ³ Extreme Learning Machine
- ⁴ Approximation
- ⁵ Detail

Abdollahi Asad Abadi, S., Dinpaghoh, Y., MirAbbasi, R., 2014. Forecasting of daily mean discharge at Behesht Abad River using Wavelet transform. *Water and Soil Journal*. 28, 534-545. (In Persian with English abstract).

گزارش شده است (Adamovski and Chan, 2011)، 2014 Nourani et al., 2013 و Ramana et al., 2018 و barzegar et al., 2017 و Khani and Rajae). در مورد توجیه برتری مدل‌های بر پایه موجک می‌توان این‌گونه بیان کرد که سری زمانی هیدرولوژیکی پیچیده با استفاده از تبدیل موجک گسسته به چند سری زمانی ساده تجزیه می‌شود، بنابراین برخی از ویژگی‌های سری زمانی اصلی نظیر دوره‌های روزانه، هفتگی، ماهانه و سالانه به روشنی بیشتری قابل مشاهده است. این برتری را می‌توان حتی در مدل‌های رگرسیونی موجک نیز مشاهده کرد (Patil and Deka, 2015 و Partal, 2015, Kisi).

نتیجه‌گیری

پیش‌بینی کیفیت آب در ماه‌های آینده می‌تواند در برنامه‌ریزی و نحوه مدیریت کیفی رودخانه‌ها تاثیر بسزایی داشته باشد. در تحقیق حاضر عملکرد دو مدل ترکیبی موجک-MLP و موجک-GMDH به همراه دو مدل تکی MLP و GMDH در پیش‌بینی دو پارامتر کیفی EC و SAR در رودخانه زاینده‌رود مورد مقایسه و ارزیابی قرار گرفتند. نتایج نشان داد ترکیب مدل‌ها با تبدیل موجک موجب افزایش دقت می‌شود و مدل‌های تکی در عمل دقت مناسبی را نداشتند. نتیجه بیان شده توسط بسیاری از محققانی که مدل‌های هیبریدی بر پایه موجک را با مدل‌های بدون استفاده از موجک مقایسه کرده‌اند، گزارش شده است. هرچند مدل‌های MLP و GMDH توانایی مدل‌سازی رفتارهای غیرخطی را دارا هستند، ولی با توجه به ویژگی‌های ناپستایی سری‌های زمانی کیفیت

منابع

Adamowski, J. and Chan, H.F., 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*. 407, 28-40.

- Ahmadi, M., Parsaee, A. and Ghaderi, K., 2012. Extracting the prediction of pollution coefficient in rivers using the GMDH group data group and comparison with experimental relationships. 11th Iranian Hydraulic Conference. Urmia. Iran p. 220. (In Persian with English abstract).
- Badrzadeh, H., 2014. River flow forecasting using an integrated approach of wavelet multi-resolution analysis and computational intelligence techniques. PHD Thesis. Curtin University. Australia.
- Barzegar, R., Moghaddam, A.A., Adamowski, J. and Ozga-Zielinski, B., 2018. Multi-step water quality forecasting using a boosting ensemble multi-wavelet extreme learning machine model. *Stochastic Environmental Research and Risk Assessment*. 32, 799-813.
- Haghi Zadeh, A., Yousefi, H., Yarahmadi, Y., Normohammadi, P. and Alijani, R., 2017. Forecasting and Trend Analytics of Water quality parameters using ARIMA series Models in Kahman river watershed. *Ecologyhydrology*. 4, 65-73. (In Persian with English abstract)
- Hassanzadeh, Y. Kordan, A. Fakheri Fard, A., 2012. Prediction of drought, the use of wavelet-neural networks, genetic algorithms and hybrid models. *Journal of Water and Wastewater*. 23, 59-48. (In Persian with English abstract)
- Hayking, S., 1999. *Neural networks: A comprehensive foundation*, 2nd Ed. Prentice-Hall, N.J.
- Ivakhnenko, A.G. and Ivakhnenko, G. A., 1995. The review of problems solvable by algorithms of the Group Method of Data Handling (GMDH)", *Pattern recognition and image analysis*. 5, 527-535.
- Ivakhnenko, A.G., 1968. The group method of data handling—a rival of the method of stochastic approximation. *Soviet automatic control avtomatika*. 1, 43-55.
- Iyengar, S. S. Cho, E. C. and Phoha, V.V., 2002. *Foundations of Wavelet Networks and Applications*. Chapman & Hall/CRC Press.
- Jafar Zadeh, N., Kabi, H. and Sepehr Far, K., 2006. Application Feasibility and Selection of the Most Appropriate Water River Water Quality Index Case Study: Zohreh River, 7th conference on river engineering, Ahvaz, Iran p. 211. (In Persian with English abstract).
- Karami, M., KashefiPour, M., Mazad, H. and Foroughi, H., 2006. Forecasting of Karoon river quality using ANN. 7th conference on river engineering, Ahvaz, Iran. p. 321. (In Persian with English abstract).
- Kazemi Poshtmasari, H., Tahmasby Servestani, Z., Kamkar, B., Shtayy, SH. And Sadegi, S., 2012. Evaluation of geostatistics methods for estimating and zoning primary macro nutrients in some agricultural lands in Golestan province. *Science Journal*. 22, 121-129. (In Persian with English abstract).
- Khani, S. and Rajaei, T., 2017. Modelling of Dissolved Oxygen Concentration and Its Hysteresis Behaviour in Rivers Using Wavelet Transform-Based Hybrid Models. *Clean-Soil, Air, Water*. 45, 212-220.
- Kiş, Ö., 2011. Evapotranspiration modelling using a wavelet regression model. *Irrigation science*. 29, 241-252.
- Kurunç, A., Yürekli, K. and Çevik, O., 2005. Performance of two stochastic approaches for forecasting waterquality and streamflow data from Yesilirmak River, Turkey. *Environmental Modelling Software*. 20, 1195-1200.
- Mihoub R, Chabour N, Guermoui, M., 2016. Modelling soil temperature based on Gaussian process regression in a semi-arid-climate, case

- study Ghardaia, Algeria Geomechanics and Geophysics for Geo-Energy and Geo-Resources. 2, 397-403.
- Najafzadeh, M. and Barani, G.A., 2011. Comparison of group method of data handling based genetic programming and back propagation systems to predict scour depth around bridge piers. *Scientia Iranica*. 18, 1207-1213.
- Najafzadeh, M., Barani, Gh-A. and Azamathulla. H.Md., 2013a. GMDH to Predict Scour Depth around Vertical Piers in Cohesive Soils. *Applied Ocean Research*. 40, 35-41.
- Najafzadeh, M., Barani, Gh-A. and Hessami-Kermani, M., 2013b. Abutment scour in live-bed and clear-water using GMDH Network. *Water Science and Technology*. 67, 1121-1128.
- Najafzadeh, M., G.-A. Barani, and Azamathulla, H., 2014. Prediction of pipeline scour depth in clear-water and live-bed conditions using group method of data handling. *Neural Computing and Applications*. 24, 629-635.
- Najah, A, El-Shafie A, Karim O, Jaafar O, El-Shafie AH., 2011. An application of different artificial intelligences techniques for water quality prediction. *Journal of the Physical Sciences*. 6, 5298-308.
- Najah, A., Elshafie, A., Karim, O.A. and Jaffar, O., 2009. Prediction of Johor River water quality parameters using artificial neural networks. *European Journal of Scientific Research*. 28, 422-435.
- Nourani, V., Hosseini Baghanam, A., Adamowski, J. and Kisi, O., 2014. Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review. *Journal of Hydrology*. 514, 358-377.
- Partal, T., 2015. Comparison of wavelet based hybrid models for daily evapotranspiration estimation using meteorological data. *KSCE Journal of Civil Engineering*. 21, 1-9.
- Patil, A.P. and Deka, P.C., 2015. Performance evaluation of hybrid Wavelet-ANN and Wavelet-ANFIS models for estimating evapotranspiration in arid regions of India. *Neural Computing and Applications*, 22, 1-11.
- Rajae T, Rahimi Benmaran R. and Jafari, H., 2015. Prediction of quality parameters (NO₃, DO) of Karaj River using ANN, MLR, and Denoising-based combined wavelet-neural network based on Models. *Iranian Journal of health and environment*. 4, 511-530. (In Persian with English abstract).
- Ramana, R.V., Krishna, B., Kumar, S.R. and Pandey, N.G., 2013. Monthly rainfall prediction using wavelet neural network analysis. *Water resources management*. 27, 3697-3711.
- Rioul, O.M. Vetterli M., 1991. Wavelets and signal processing. *IEEE SP Magazine*: 14-38
- Zaman Zad, S., Ghavidel, S. and Zeinalzadeh, K., 2015 Estimation of Rivers Dissolved Solids TDS by Soft Computing (Case Study: Upstream of Boukan Dam). *Journal of soil and water*. 29, 1234-1245. (In Persian with English abstract).
- Sattari, M.T, Abbasgoli, M. and Mirabbasi Najafabadi, R., 2014. Surface water quality prediction using decision tree method. *Journal of Water and Irrigation Engineering*. 4, 76-88. (In Persian with English abstract).
- Yaseen, Z.M., Ramal, M.M., Diop, L., Jaafar, O., Demir, V. and Kisi, O., 2018. Hybrid Adaptive Neuro-Fuzzy Models for Water Quality Index Estimation. *Water Resources Management*. 32, 2227-2245.



Environmental Sciences Vol.16 / No.4 / Winter 2019

135-152

Comparison of wavelet-MLP and wavelet-GMDH models in forecasting EC and SAR at Zayandeh-Rood River

Masoud Karbasi* and Saedeh Dindar

Department of Water Engineering, Faculty of Agriculture, University of Zanjan, Zanjan, Iran

Received: 2017.11.15

Accepted: 2018.12.08

Karbasi, M. and Dindar, S., 2019. Comparison of wavelet-MLP and wavelet-GMDH models in forecasting EC and SAR at Zayandeh-Rood River. *Environmental Sciences*. 16(4): 135-152.

Introduction: Increasing water demand and water pollution due to the development of agricultural, urban and industrial activities have caused environmental problems all over the world. The significant increase in water pollution and the diversity of various urban, agricultural and industrial pollutants made the qualitative management of water resources inevitable. Short-term and long-term accurate forecasts of river quality parameters are essential for designing hydraulic structures, irrigation planning, optimal utilization of reservoirs and environmental planning. Given the stochastic characteristics of the hydrological events, forecasting the future status of surface waters is always associated with uncertainties. The purpose of the present study was to investigate the performance of two types of artificial neural networks, namely MLP and GMDH, combined with discrete wavelet transform (DWT), to forecast two important quality parameters, electrical conductivity (EC) and sodium adsorption ratio (SAR) at Zayandeh-Rood River in 1, 2 and 3 months ahead.

Material and methods: In this study, water quality data (EC and SAR) of Zayandeh-Rood River at Zaman Khan Station was used from 1363 to 1384. From 21 years of data, 15 years (approximately 70%) were used for training and 7 years (30%) were used to test the developed models. Two types of mother wavelet dmey and db4 were evaluated. Statistical parameters such as RMSE and R^2 were used to evaluate the performance of the models.

Results and discussion: The results showed that the use of discrete wavelet transform improves the performance of the models. Various combinations of input data (various delays) and two types of mother wavelets were evaluated. The results showed that wavelet-MLP and wavelet-GMDH hybrid models outperform single MLP and single GMDH models at all forecasting intervals. The results of the single MLP and GMDH models were only effective in forecasting SAR one month ahead but practically could not forecast two and three months later. In the EC parameter, the MLP and GMDH models performed better. Also, the results showed that the use of annual time lags does not increase the accuracy and in some cases even reduces it. The

* Corresponding Author. *E-mail Address:* m.karbasi@znu.ac.ir

study of the types of mother wavelets also showed that the dmey wavelet is the most suitable wavelet type to forecast EC and SAR qualitative parameters. The comparison between wavelet-MLP and wavelet-GMDH models showed the relative superiority of the former model. By increasing the forecast period from one month to three months ahead, the accuracy of the models decreased. This decrease in precision was higher in forecasting SAR parameter, e.g. in the one month forecast, R^2 was 0.936 and in the 3 months ahead forecasts it was reduced to 0.516. In the EC parameter, the R^2 fell to 0.641 in 3 months ahead forecasting.

Conclusion: The results of this study can be used as a basis for future planning for water quality. It is suggested that the model presented in this study should be considered in other rivers. Also, the combination of other artificial intelligent models such as ANFIS and SVM with wavelet transform can be evaluated.

Keywords: Water quality parameters, Forecasting, Wavelet, Neural Network.