

نشریه تحقیقات کاربردی علوم جغرافیایی، سال شانزدهم، شماره ۴۲، پاییز ۹۵

پیش بینی تراز آب زیرزمینی حوضه آبریز شریف آباد قم با استفاده از مدل‌های موجک-عصبی و برنامه‌ریزی ژنتیک

دریافت مقاله: ۹۳/۳/۸ پذیرش نهایی: ۹۵/۸/۲۴

صفحات: ۲۶-۷

طاهر رجایی: دانشیار آب و محیط زیست، گروه مهندسی عمران، دانشگاه قم، قم، ایران^۱

Email: Trajaee@qom.ac.ir

اکرم زینی‌وند: کارشناس ارشد سازه‌های هیدرولیکی، گروه مهندسی عمران، دانشگاه قم، قم، ایران

Email: a_zeynivand@yahoo.com

حمیده جعفری: دانشجوی دکتری آب و سازه‌های هیدرولیکی، گروه مهندسی عمران، دانشگاه قم، قم، ایران

Email: h.jafari@stu.qom.ac.ir

چکیده

در این تحقیق پیش‌بینی تراز آب زیرزمینی حوضه آبریز شریف‌آباد استان قم با بهره‌گیری از برخی مدل‌های هوشمند می‌باشد. به این منظور از داده‌های ماهیانه تراز آب زیرزمینی در سه حلقه چاه مشاهده‌ای واقع در حوضه آبریز شریف‌آباد در مدل‌سازی‌ها استفاده شده است. جهت مقایسه نتایج حاصل از مدل‌های هیبرید آنالیز موجک-شبکه عصبی (WNN)، برنامه‌ریزی ژنتیک (GP)، رگرسیون خطی چند متغیره (MLR) و شبکه عصبی مصنوعی (ANN) از دو معیار ریشه خطای مربع متوسط (RMSE) و ضریب کارایی نش-ساتکلیف (E) استفاده شده است. نتایج تحقیق نشان داده است که مدل ترکیبی موجک-عصبی پیش‌بینی دقیقتری برای تراز آب زیرزمینی ماهانه نسبت به مدل‌های ANN، GP و MLR ارائه داده، به طوریکه ضریب نش در مدل ترکیبی برای پی‌زومترهای ۱، ۲ و ۳ به ترتیب ۰/۹۸، ۰/۹۸ و ۰/۹۵ حاصل شده است.

کلید واژگان: دشت شریف‌آباد، تراز آب زیرزمینی، شبکه عصبی، آنالیز موجک، برنامه‌ریزی ژنتیک.

مقدمه

مدل‌سازی آب‌های زیرزمینی گام مهمی در مدیریت منابع آب به شمار می‌رود. این مدل‌سازی تاکنون با ابزارهای مختلفی انجام یافته است. طی سال‌های اخیر کاربرد مدل‌های

^۱ نویسنده مسئول: قم، بلوار الغدیر، دانشگاه قم، دانشکده فنی و مهندسی، گروه مهندسی عمران

هوشمند نظیر شبکه عصبی مصنوعی، منطق فازی، سیستم عصبی-فازی و الگوریتم ژنتیک در زمینه مدل سازی آب های زیرزمینی شدت گرفته است. در این راستا یانگ و همکاران (۲۰۰۹: ۴۸۷) به مقایسه مدل های سری زمانی یکپارچه و شبکه عصبی پس انتشار در پیش بینی سطح آب زیرزمینی مناطق خشک و نیمه خشک استان جیلین غربی واقع در چین پرداختند. نتایج تحقیق نشان دهنده برتری شبکه عصبی پسگرد خطا بوده است. تائورمینا و همکاران (۲۰۱۲: ۱۶۷۰) با استفاده از شبکه عصبی با الگوریتم پس انتشار خطا، سطح آب زیرزمینی آبخوان آزاد ساحلی منطقه لاگون را در ونیز ایتالیا برای ساعات آینده پیش بینی کردند. موهانتی و همکاران (۲۰۱۳: ۳۸) به ارزیابی تطبیقی مدل عددی تفاضل محدود MODFLOW و مدل شبکه عصبی، پیرامون شبیه سازی تراز هفتگی آب های زیرزمینی ۱۸ حلقه چاه مشاهده ای درون یک آبخوان آبرفتی واقع در ادیشای هند پرداختند. نتایج حاکی از برتری مدل ANN نسبت به مدل عددی بود. میکانیک و همکاران (۲۰۱۳: ۱۱) به پیش بینی بارش بلند مدت به کمک شبکه های عصبی در ویکتوریای ایتالیا پرداختند. نتایج ارزیابی نشان داد که پتانسیل مدل ANN در پیش بینی بهتر بارش بلند مدت فصلی بیشتر از مدل MLR^۱ است. بانرجی و همکاران (۲۰۱۴: ۸۱) به مطالعه یک حوضه آبریز کشاورزی در شمال هند پرداختند. نتایج پژوهش حاکی از پتانسیل چشمگیر شبکه عصبی در پیش بینی دقیق تغییرات فصلی آبخوان به منظور صرفه جویی آب زیرزمینی در مصارف کشاورزی و استفاده پایدار از منابع آب زیرزمینی بوده است.

در ایران نیز مطالعاتی در این زمینه انجام یافته است. محتشم و همکاران (۱۳۸۹: ۱) به پیش بینی سطح ایستابی دشت بیرجند با بهره گیری از مدل شبکه عصبی پرداختند. مختاری و همکاران (۱۳۹۱: ۳۴۵) به پیش بینی ماهانه تراز آب زیرزمینی دشت شبستر (یکی از زیرحوضه های ارومیه) با مدل شبکه عصبی پرداختند. آنها از اطلاعات ۹ ساله سری زمانی تراز آب زیرزمینی در ۱۵ حلقه چاه پیزومتری استفاده نمودند.

در فرایندهای هیدرولوژیکی معمولاً با داده های غیرایستا^۲ سروکار داریم. با وجود انعطاف پذیری شبکه عصبی در پیش بینی سری های زمانی، گاهی این شبکه ها در پیش بینی سری های زمانی به شدت غیرایستا، با مشکل مواجه می شوند. با استفاده از تبدیل موجک می توان یک سری زمانی غیرایستا را به چندین سری زمانی ایستا تجزیه کرد. رجایی و همکاران (۲۰۱۰: ۲۰۱۰)

^۱. Artificial Neural Network

^۲. Multiple Linear Regression

^۳. Non stationary

۹۳) مدل نروفازی-موجکی را برای پیش‌بینی میزان بار رسوب معلق رودخانه پیکوس در غرب تگزاس بکار بردند. دبی و بار رسوبی روزانه این رودخانه در مدت ۷ سال به عنوان ورودی مدل مورد استفاده قرار گرفت. رجایی (۲۰۱۱: ۲۹۱۷) با پیش‌بینی بار رسوب معلق در رودخانه Yadkin، برتری مدل هیبرید موجک-شبکه عصبی را در پیش‌بینی بار معلق رودخانه‌ها نشان داد. در پژوهش دیگری رجایی و همکاران (۲۰۱۱: ۶۱۳) کاربرد مدل ترکیبی موجک-عصبی را در پیش‌بینی بار رسوب معلق ایستگاه آب‌سنجی Iowa واقع در آمریکا، بررسی نمودند. نتایج نشان دهنده برتری روش مدل ترکیبی نسبت به سایر روش‌ها بود. آداموسکی و چن (۲۰۱۱: ۲۸) از داده‌های ۸ ساله حوضه آبریز شاتوگای در کانادا استفاده کرده و به پیش‌بینی سطح آب زیرزمینی با استفاده از مدل عصبی-موجک پرداختند. نتایج این تحقیق نشان داد که مدل تلفیقی با دقت بالاتری قادر به پیش‌بینی سطح آب زیرزمینی است. نورانی و همکاران (۲۰۱۳: ۲۲۸) به بررسی تأثیر پیش پردازش آنالیز موجک بر مدل ترکیبی^۱ SOM-FFNN در پیش‌بینی بارش- رواناب بر اساس داده‌های روزانه سری زمانی بارش و رواناب در حوضه‌ای در اتیوپی پرداختند. نتایج حاکی از بهبود نتایج مدل سازی بوده است. نایاک و همکاران (۲۰۱۳: ۵۷) نیز برتری عملکرد مدل WNN^۲ را در مدل سازی بارش رواناب حوضه‌ای در هند، نسبت به دو مدل ANN و NAM^۳، نشان دادند. نخعی و همکاران (۱۳۹۱: ۴۷) نیز نوسانات سطح آب زیرزمینی در دشت قروه استان کردستان را با استفاده از مدل عصبی- موجک پیش‌بینی نمودند. نتایج بیانگر آن بود که مدل ترکیبی از دقت بالاتری برخوردار می‌باشد.

هدف از انجام پژوهش حاضر پیش‌بینی تراز آب زیرزمینی حوضه آبریز شریف‌آباد استان قم با بهره‌گیری از برخی مدل‌های هوشمند (شبکه عصبی، مدلی ترکیبی موجک-شبکه عصبی و برنامه‌ریزی ژنتیک) در یک گام پیش‌رو می‌باشد. مدل ترکیبی علاوه بر پیش‌بینی سری زمانی ۲۴ ماهه دوره آزمون قادر به پیش‌بینی تراز آب زیرزمینی یک ماهه در آبخوان مورد مطالعه خواهد بود. همچنین نتایج مدل پیشنهادی با نتایج حاصل از سه مدل شبکه عصبی، رگرسیون خطی چند متغیره و برنامه‌ریزی ژنتیک به منظور بررسی تأثیر آنالیز موجک بر نتایج مدل شبکه عصبی، مورد مقایسه قرار گرفته است. مدل‌های دقیق می‌توانند نوسانات سری زمانی تراز آب زیرزمینی را شبیه‌سازی نموده و وضعیت آبخوان دشت را در ماه‌های آتی پیش‌بینی نمایند.

1. Self-Organizing Map-Feed Forward Neural Network

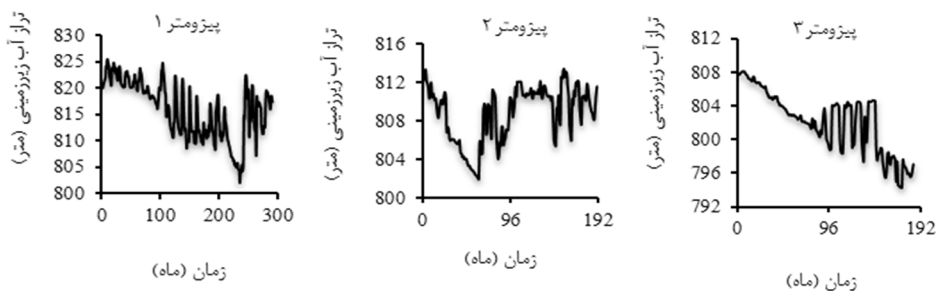
2. Wavelet Neural Network

3. Nedbor-Afstromnings-Model

جدول ۱ ارائه شده است. داده‌ها برای پیژومتر ۱ در محدوده زمانی آذرماه ۱۳۶۷ تا اسفندماه ۱۳۹۱، به سه مجموعه آموزش (آذرماه ۱۳۶۷ تا اسفندماه ۱۳۸۵)، اعتبارسنجی (فروردین‌ماه ۱۳۸۶ تا اسفندماه ۱۳۸۹) و آزمون (فروردین‌ماه ۱۳۹۰ تا اسفندماه ۱۳۹۱)، برای پیژومتر ۲ در محدوده زمانی فروردین‌ماه ۱۳۷۶ تا اسفندماه ۱۳۹۱، به سه مجموعه آموزش (فروردین‌ماه ۱۳۷۶ تا اسفندماه ۱۳۸۷)، اعتبارسنجی (فروردین‌ماه ۱۳۸۸ تا اسفندماه ۱۳۸۹) و آزمون (فروردین‌ماه ۱۳۹۰ تا اسفندماه ۱۳۹۱) و برای پیژومتر ۳ در محدوده زمانی مهرماه ۱۳۷۶ تا اسفند ۱۳۹۱، به سه مجموعه آموزش (مهرماه ۱۳۷۶ تا اسفندماه ۱۳۸۷)، اعتبارسنجی (فروردین‌ماه ۱۳۸۸ تا اسفندماه ۱۳۸۹) و آزمون (فروردین‌ماه ۱۳۹۰ تا اسفندماه ۱۳۹۱) تقسیم شده است. شکل ۲ نمودار سری زمانی سطح آب زیرزمینی پیژومترها را نشان می‌دهد.

جدول (۱). مشخصات سه حلقه چاه پیژومتری مورد مطالعه

شماره پیژومتر	نام پیژومتر	UTM		
		X	Y	Z
۱	شیرین‌آباد	۵۱۲۷۹۱	۳۸۴۳۱۲۲	۸۵.۸۲۹
۲	بین مظفرآباد و قمروود	۵۰۷۷۱۶	۳۸۴۳۳۳۱	۳۴.۸۴۲
۳	قنبرعلی	۵۱۶۳۶۵	۳۸۴۲۸۸۸	۳۲.۸۲۳



شکل (۲). تغییرات ماهانه تراز آب زیرزمینی پیژومترهای ۱، ۲ و ۳

تحلیل آماری داده‌ها

تحلیل آماری داده‌ها در جدول ۲ نشان داده شده است. این جدول شامل مقدار بیشینه، مقدار کمینه، میانگین، انحراف معیار (S_d)، ضریب چولگی (C_s)، ضریب همبستگی یک ماهه (R_1)، ضریب همبستگی دو ماهه (R_2)، ضریب همبستگی سه ماهه (R_3) و ضریب همبستگی چهار

ماهه (R_4)، می‌باشد. بر اساس رابطه (۱) ضریب همبستگی تراز آب زیرزمینی برای های ۱، ۲، ۳ و ۴ ماهه در دوره‌های آموزش و آزمون، محاسبه شده است:

$$R = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad \text{رابطه (1)}$$

در جدول (۲) داده‌های اعتبارسنجی جزء داده‌های آموزش لحاظ شده است.

جدول (۲). ضریب همبستگی ماهانه سطح آب زیرزمینی

پیزومتر ۳		پیزومتر ۲		پیزومتر ۱		پارامتر آماری
آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	
۷۹۶/۲۳۴۲	۸۰۲/۹۸۸۸	۸۱۰/۱۶۷۱	۸۰۸/۶۱۷۷	۸۱۶/۱۲۴۶	۸۱۵/۹۵۸۶	میانگین
۸۱۱/۳۵	۸۰۲/۱	۸۰۷/۶۷	۸۰۱/۹۴	۷۹۴/۲۷	۷۹۵/۴۷	کمینه
۷۹۸/۰۷	۸۰۸/۱۲	۲/۸۱۲	۴۱/۸۱۳	۶۱/۸۱۹	۵۱/۸۲۵	بیشینه
-۰/۲۳۰۵	-۰/۳۵۸۳	-۰/۲۲۸۳	-۰/۵۲۶۳	-۰/۵۷۰۲	-۰/۳۱۶۲	C_s
۲۳۶۷/۱	۳/۰۴۹۷	۳۶۱۸/۱	۳/۰۲۴۲	۷۲۸۷/۲	۵۸۵۸/۵	S_d
۰/۵۰	۰/۹۲	۰/۶۷	۰/۹۱	۰/۸۵۷	۰/۹۲۸	R_1
۰/۳۶	۰/۸۲	۰/۱۴۷	۰/۸۲	۰/۶۱۶	۰/۸۵	R_2
-۰/۰۰۲	۰/۷۳	-۰/۳۶	۰/۷۵	۰/۳۷	۰/۷۸	R_3
-۰/۳	۰/۶۶	-۰/۴۶	۰/۷۱	۰/۱۰۹	۰/۷۲	R_4

شبکه‌های عصبی مصنوعی

مدل شبکه عصبی خودبازگشتی غیرخطی^۱ (NAR)

معماری شبکه عصبی از سه نوع لایه (ورودی، پنهان و خروجی) تشکیل شده است. لایه ورودی داده‌ها را در شبکه توزیع می‌کند. لایه پنهان داده‌های دریافت شده از لایه ورودی را پردازش نموده و لایه خروجی نتایج را به ازای ورودی‌های مشخص استخراج می‌کند. هر یک از لایه‌های شبکه عصبی، دارای تعدادی نرون هستند. نرون‌های لایه‌های مختلف با هم در ارتباط بوده و عملیات پردازش داده‌ای در آن‌ها صورت می‌گیرد. (کیا، ۱۳۸۹: ۳۵). در این مقاله، برای مدل سازی شبکه عصبی از کد نویسی در نرم افزار متلب استفاده شده است. در مدل شبکه

^۱. Nonlinear Auto Regressive

عصبی NAR از داده‌های سطح آب زیرزمینی با تأخیرهای مختلف (از ۱ تا ۱۴ ماه) به عنوان ورودی شبکه استفاده شده است. تراز آب زیرزمینی در گام زمانی $t+1$ به عنوان خروجی شبکه در نظر گرفته شده است. برای انتخاب تعداد نرون‌های بهینه لایه مخفی از روش آزمون و خطا استفاده شده است. در تحقیق حاضر از یک شبکه سه لایه پیش‌خور با تابع فعال‌سازی تانژانت سیگموئید^۱ در لایه مخفی و تابع فعال‌سازی خطی^۲ در لایه خروجی استفاده شده است. این شبکه‌ها در یک یادگیری نظارت شده^۳ و به وسیله الگوریتم پس‌انتشار خطا^۴ آموزش دیده و بر این اساس تصحیح خطا را انجام می‌دهند. در این شبکه از تابع لونیبرگ - مارکوارت^۵ بعنوان تابع یادگیری استفاده شد.

آنالیز موجک

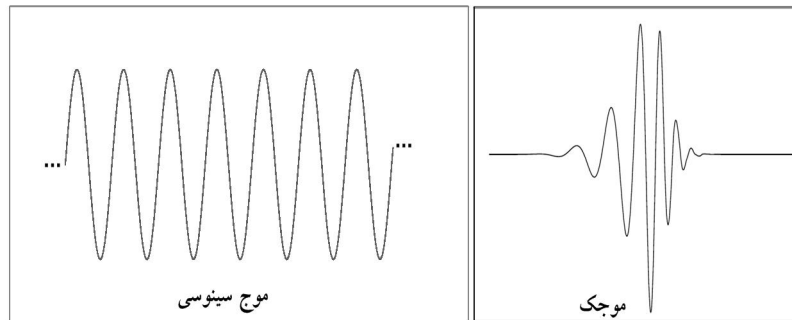
مدل هیبرید موجک- شبکه عصبی (WNN)

تبدیل موجک یک تبدیل ریاضی است که از توابع پایه‌ای به نام موجک استفاده می‌کند. تبدیل موجک این قابلیت را دارد که یک سیگنال را به صورت زمان-مقیاس بررسی نماید. با استفاده از تبدیل یا آنالیز موجک می‌توان یک سیگنال یا سری زمانی مادر را به موجک‌هایی با سطح تفکیک و مقیاس‌های مختلف تجزیه کرد. بر اساس این ویژگی مهم تبدیل موجک، می‌توان سری‌های زمانی غیرایستا و گذرا را به صورت موضعی مورد تجزیه و تحلیل قرار داد. شکل ۳ یک موج سینوسی با انرژی نامحدود و یک موجک با انرژی محدود و متمرکز حول یک نقطه را نشان می‌دهد.

شرط مقبولیت موجک عبارت است از (Cohen et al., ۱۹۹۶: ۱۱۶۴)

$$\int \psi(t) dt = 0 \quad \text{رابطه (2)}$$

1. Tan- Sigmoid Function
2. Linear Function
3. Supervised Learning
4. Back-Propagation Algorithm
5. Levenberg -Marquardt Algorithm



شکل (۳). شکل شماتیک یک موج سینوسی و یک موجک

که در آن $\psi(t)$ تابع موجکی می‌باشد. دو نوع تبدیل موجکی وجود دارد: ۱- تبدیل موجکی پیوسته $^1(CWT)$ ، ۲- تبدیل موجکی گسسته $^2(DWT)$. تبدیل موجکی پیوسته با یکی از روابط (۳ و ۴) بیان می‌شود (Partal, ۲۶: ۲۰۰۹):

$$CWT(\text{Scale, Position}) = \int_{-\infty}^{\infty} f(t) \psi(t)(\text{Scale, Position}) dt \quad \text{رابطه (3)}$$

یا به صورت زیر:

$$CWT_S^\psi(s, \tau) = \frac{1}{\sqrt{s}} \int S(t) \psi_{s,\tau}^*(t) dt \quad \text{رابطه (4)}$$

رابطه فوق تابعی از دو متغیر S و τ است که τ نشان دهنده انتقال، S بیانگر مقیاس (عکس بسامد) و علامت * نشان دهنده مزدوج مختلط است. S و τ در تبدیل موجکی پیوسته دارای مقادیر پیوسته و در تبدیل گسسته دارای مقادیر گسسته هستند. (Cannas et al., ۱۱۶۴: ۲۰۰۶). کلیه توابعی که از تابع مادر ساخته می‌شوند، موجک‌های دختر نامیده می‌شوند که از رابطه ۵ به دست می‌آیند. (ضریب مقیاس با یکی از حروف a یا S نشان داده می‌شود):

$$\psi_{s,\tau}(t) = \psi\left(\frac{t-\tau}{s}\right) \quad \text{رابطه (5)}$$

شکل (۵) طرح شماتیک تبدیل موجک را نشان می‌دهد. در پژوهش حاضر از تبدیل موجک گسسته برای تجزیه سیگنال تراز آب زیرزمینی ماهانه به سیگنال‌های تقریب^۳ و جزئیات^۴

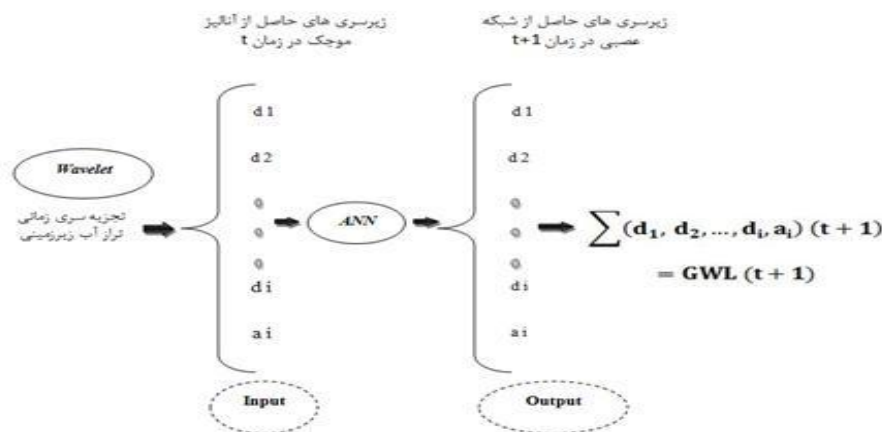
1. Continues Wavelet Transform

2. Discrete Wavelet Transform

3. Approximation

4. Detail

استفاده شده است. در نهایت، خروجی مدل ترکیبی نیز تراز آب زیرزمینی در زمان $t+1$ می-باشد. برای ساخت مدل ترکیبی موجک-عصبی ابتدا در بخش آنالیز موجک گسسته^۱، کدنویسی به زبان نرم افزار MATLAB R2011b، با درجات مختلف تجزیه (از ۱ تا ۵ سطح) و موجک‌های مادر Haar^۲، Meyer^۳، db۲، db۳، db۴، db۵ (دابیچز ۲ تا ۵) برای تجزیه سری زمانی سطح آب زیرزمینی به زیرسری‌های تقریب و جزئیات $(+ \dots + d_2(t) + d_1(t) = GWL(t)$ در یک بخش و همچنین در ادامه، برنامه‌ای برای شبکه عصبی با تعداد نورون متغیر در لایه مخفی و های ماهانه متغیر (از ۱ تا ۱۴ ماه)، در بخش دیگر نوشته شد. در بحث مدل‌سازی سطح آب زیرزمینی، پارامترهای مختلفی از جمله بارندگی، پمپاژ، تبخیر و تعرق، تغذیه به آبخوان، تخلیه از آبخوان، وزش باد، درجه حرارت و ... می‌توانند تأثیرگذار باشند، اما از آنجاییکه تمام این عوامل بصورت مستتر در سری زمانی سطح آب زیرزمینی وجود دارند، در نتیجه زمانی که سیگنال سطح آب زیرزمینی توسط تبدیل موجک به سیگنال‌های پایه سازنده-اش تجزیه می‌شود، اثر تمام این عوامل در نظر گرفته می‌شود. به عبارت دیگر در تبدیل موجک، با برازش موجک مادر به سیگنال سطح آب زیرزمینی می‌توان تغییرات فصلی، تغییرات بلندمدت، روند و ... را از سیگنال سطح آب زیرزمینی استخراج نمود. به همین دلیل، در این پژوهش تنها از پارامتر سری زمانی سطح آب زیرزمینی استفاده گردیده است.



شکل (۵). ساختار مدل ترکیبی

1. Discrete Wavelet
2. Haar
5. Meyer
4. Daubechies

تحلیل رگرسیون خطی چند متغیره (MLR)

تحلیل رگرسیون خطی چند متغیره تکنیکی برای مدل کردن رابطه خطی بین متغیر وابسته و یک یا چند متغیر مستقل است. این تحلیل در نرم افزار IBM SPSS Statistics ۲۰ انجام شده است. رابطه (۶):

$$y = a_0 + \sum a_i x_i \quad \text{رابطه (6)}$$

a_i : ضریب متغیرهای مستقل، x_i : مقادیر مشاهده‌ای، a : عرض از مبدا، y : مقادیر پیش‌بینی شده برنامه‌ریزی ژنتیک (GP)

فرایند شبیه‌سازی در GP به این صورت است که ابتدا مجموعه‌هایی که می‌توانند جهت انتخاب متغیرها و عملگرها در فرایند جستجو به کار روند، معرفی می‌شوند. سپس کروموزوم‌ها بوسیله انتخاب یک مجموعه جواب اولیه تصادفی از مجموعه‌های اتصال و توابع ایجاد می‌شوند، سپس تابع هدف متناظر با هر کروموزوم محاسبه می‌شود. سپس مجموع تفاوت مقادیر محاسباتی و مشاهداتی کمینه می‌شود. در مرحله بعد عملگرهای ژنتیک (تزیوج و جهش) اعمال می‌شوند. در ادامه، فرایند توسعه‌ای تکراری در مورد فرزندان انجام می‌شود تا در نهایت پس از تعداد تکرار مشخصی که روند تغییرات تابع هدف در آن تقریباً ثابت گردید، مقدار بهینه یا نزدیک به بهینه بعنوان جواب مسئله استخراج گردد. در این مقاله برای پیش‌بینی به روش GP از نرم افزار Discipulus محصول مؤسسه فنی رجیستر (۱۹۹۸) استفاده شده است. برای معیار توقف در این نرم افزار میزان حداکثر تعداد اجرا و میزان تولید بدون بهبود ۳۰۰ در نظر گرفته شده است.

ارزیابی دقت مدل‌ها

به منظور ارزیابی نتایج مدل‌سازی از دو معیار ریشه خطای مربع متوسط ($RMSE$) و ضریب کارایی یا ضریب تبیین (E) استفاده شده است. بهترین و دقیق‌ترین مدل، مدلی است که در آن E به ۱ و $RMSE$ به صفر نزدیک‌تر باشد. رابطه‌های (۷) و (۸):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{io} - y_{ip})^2}{n}} \quad \text{رابطه (7)}$$

- 1- Genetic Programming
- 2- Root Mean Square Error
- 3- Efficiency coefficient

$$E = 1 - \frac{\sum_{i=1}^n (y_{io} - y_{ip})^2}{\sum_{i=1}^n (y_{io} - \bar{y}_{io})^2} \quad \text{رابطه (8)}$$

y_{io} : مقادیر مشاهداتی، y_{ip} : مقادیر پیش‌بینی شده، n : تعداد داده‌ها، \bar{y} : میانگین مشاهداتی

آماده‌سازی داده‌های ورودی

آماده سازی داده‌های ورودی به شبکه نوعی پیش‌پردازش است که شامل تبدیل داده‌ها از دامنه تغییرات واقعی خود به دامنه‌ایست که شبکه عصبی در آن دامنه کارایی بهتری دارد. با توجه به استفاده از تابع تانژانت سیگموئید در لایه مخفی و فرم خاص این تابع، بهتر است مقیاس داده‌های ورودی به شبکه را قبل از استفاده، با رابطه (۹) به بازه $[-1, 1]$ تغییر داد.

$$x_{normalize} = \frac{(x - x_{min})}{(x_{max} - x_{min})} \times 2 - 1 \quad \text{رابطه (9)}$$

نتایج

در مدل رگرسیون، آنالیز رگرسیون خطی بین مقادیر تراز آب زیرزمینی دوره آموزش و اعتبارسنجی برای ماه فعلی تا ۱۴ ماه قبل ($t-1, t-2, \dots, t-14$)، بهترین رابطه بین متغیر وابسته و متغیرهای مستقل بدست آمد. سپس به پیش‌بینی ۲۴ ماهه تراز آب زیرزمینی در دوره آزمون، بر اساس رابطه بدست آمده پرداخته شد. داده‌های ورودی سری زمانی تراز آب زیر زمینی بوده است. نتایج حاصل از مدل رگرسیونی در جدول (۳) ارائه شده است.

جدول (۳). نتایج مدل MLR

شماره	بهترین رابطه MLR	(ماه)	E	RMSE (m)
۱	$y_t = 59.777 + 0.955y_{t-1} - 0.028y_{t-2}$	۲	۰/۷۳	۱/۳۸
۲	$y_t = 70.407 + 0.913y_{t-1}$	۱	۰/۴۲	۲/۰۲۸
۳	$y_t = 78.615 + 1.125y_{t-1} - 0.223y_{t-2}$	۲	-۰/۳۱	۳۸/۱

با دقت در نتایج جدول دیده می‌شود که مدل خطی برای پیرومتر ۱ نتیجه قابل قبولی را نسبت به دو پیرومتر دیگر ارائه نموده است. با دقت در نمودار سری زمانی پیرومترها (شکل ۲)، واضح است که علاوه بر اینکه پیرومتر ۱ دارای مجموعه آموزش بزرگتری برای مدل سازی است، همچنین نسبت به دو پیرومتر دیگر نوسانات شدید و ناگهانی کمتری دارد. در نهایت می‌توان بر اساس نتایج جدول (۲)، غیرقابل قبول بودن عملکرد این مدل را در شبیه‌سازی سری‌های زمانی با نوسانات شدید و پی در پی، محتمل دانست.

نتایج حاصله از مدل شبکه عصبی برای سه پیژومتر در جدول (۴) ارائه شده است.

جدول (۴). نتایج ارزیابی مدل شبکه عصبی مصنوعی

شماره	(ماه)	ساختار شبکه	RMSE (m)	E
۱	۲	۱-۳-۱	۱/۳۵	۰/۷۴
۲	۷	۱-۶-۱	۰/۸۲۹	۰/۶۱
۳	۱۲	۱-۳-۱	۱/۱۷۹	۰/۵۰

همان گونه که مشاهده می شود مدل شبکه عصبی برای پیژومتر ۳ نتیجه خوبی ارائه نکرده است. با دقت در نمودار سری زمانی پیژومتر ۳ می توان دریافت که سری زمانی دارای دو فاز کاملاً متفاوت می باشد، در فاز اول تراز آب زیرزمینی روندی کاملاً نزولی (با نوسانات کم) و در فاز دوم نوسانات شدید و پی در پی (با ماهیت چندقله ای) دارد. به همین دلیل، با توجه به خصوصیت شبکه های عصبی در پیش بینی یک سری زمانی می توان گفت که چون شبکه عصبی بر اساس فاز اول آموزش دیده، لذا نتوانسته در شبیه سازی فاز دوم (که شامل داده های دوره آزمون نیز می باشد) موفق عمل نماید.

نتایج حاصل از مدل GP برای سه پیژومتر مورد بررسی، در جدول (۵) ارائه شده است. مطابق این جدول نتایج پیژومتر ۱ بهتر از پیژومتر ۲ می باشد.

جدول (۵). نتایج ارزیابی مدل GP

شماره پیژومتر	۱			۲			۳		
	تأخیر (ماه)	تعداد اجرا	E	تأخیر (ماه)	تعداد اجرا	E	تأخیر (ماه)	تعداد اجرا	E
۱	۳	۱۰۰	۰/۴۶	۲	۱۰۰	۰/۴۳	۳	۱۰۰	-
۲	۴	۱۰۰	۰/۵۶	۳	۱۰۰	۰/۴۳	۴	۱۰۰	۱۲/۰
۳	۷	۱۰۰	۰/۳۷	۴	۱۰۰	۰/۵۳	۷	۱۰۰	۰/۱
RMSE (m)	۵۳/۱	۴۸/۱	۶۱/۱	۰/۹۱	۱۲/۱	۱/۰۸	۲۱/۲	۱۷/۱	۱۵/۱

نتایج مدل ترکیبی موجک-عصبی برای چاه های پیژومتری در جداول ۶ تا ۸ ارائه شده است. بر اساس دو معیار ارزیابی ذکر شده، تابع موجک Meyer در سطح دوم تجزیه، با زمانی ۴ ماهه و ۳ نرون در لایه مخفی، نتایج بهتری را برای تمام پیژومترها ارائه داده است.

جدول (۶). بهترین نتایج مدل ترکیبی W-NARNN دوره آزمون در پیزومتر ۱

E	RMSE (m)	ساختار ANN	تأخیر (ماه)	سطح تجزیه	موجک مادر
۰/۹۱	۰/۷۹	۴-۳-۴	۳	۳	db۲
۰/۹۴۴	۰/۶۳	۴-۵-۴	۴	۳	db۳
۰/۹۴	۰/۶۵	۴-۴-۴	۳	۳	db۴
۰/۹۶	۰/۴۹	۴-۴-۴	۴	۳	db۵
۰/۸۱	۱۴/۱	۳-۴-۳	۲	۲	haar
۰/۹۸	۰/۳	۳-۳-۳	۴	۲	Meyer

مدل ترکیبی به این دلیل که از سیگنال‌های تجزیه شده به عنوان ورودی شبکه عصبی استفاده می‌کند، توانسته خصوصیات غیرخطی و پیچیده تراز آب زیرزمینی را دقیق‌تر از مدل شبکه عصبی تنها و خصوصاً مدل خطی MLR شبیه‌سازی کند.


جدول (۷). بهترین نتایج مدل ترکیبی W-NARNN دوره آزمون در پیزومتر ۲

E	RMSE (m)	ساختار ANN	تأخیر (ماه)	سطح تجزیه	موجک مادر
۰/۸۳	۰/۵۴۸	۴-۳-۴	۳	۳	db۲
۰/۸۹	۰/۴۴	۵-۴-۵	۴	۴	db۳
۰/۹۲	۰/۳۷	۵-۵-۵	۴	۴	db۴
۰/۸۸	۰/۴۴۷	۴-۵-۴	۴	۳	db۵
۰/۷۸	۰/۶۱	۲-۴-۲	۳	۱	haar
۰/۹۸	۰/۱۶	۳-۳-۳	۴	۲	Meyer


جدول (۸). بهترین نتایج مدل ترکیبی W-NARNN دوره آزمون در پیزومتر ۳

E	RMSE	ساختار	تأخیر	سطح	موجک
۰/۵۳۵	۰/۸۸۵	۴-۳-۴	۳	۳	db۲
۰/۷۸۹	۰/۵۵۵	۵-۵-۵	۲	۴	db۳
۰/۸۲	۰/۵۱	۳-۷-۳	۳	۲	db۴
۰/۶۸۷	۰/۶۷	۴-۳-۴	۴	۳	db۵
۰/۲۶	۱/۰۳۶	۲-۵-۲	۱	۱	haar
۰/۹۵	۰/۲۶۴	۳-۳-۳	۴	۲	Meyer

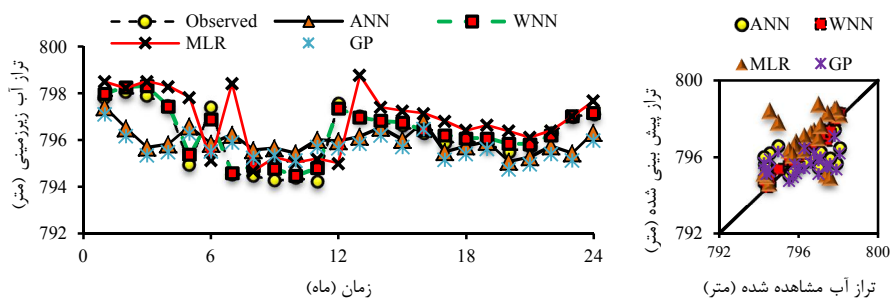
در شکل‌های (۶، ۷ و ۸) مقادیر تراز مشاهده‌ای با مقادیر ترازهای پیش‌بینی شده توسط هر چهار مدل، برای هر سه پیزومتر ارائه شده است.



شکل (۶). نتایج مدل‌ها در دوره آزمون برای پیژومتر ۱



شکل (۷). نتایج مدل‌ها در دوره آزمون برای پیژومتر ۲



شکل (۸). نتایج مدل‌ها در دوره آزمون برای پیژومتر ۳

همانگونه که از شکل‌های (۶ تا ۸) مشاهده می‌شود، آنالیز موجک در هر سه پیژومتر، باعث بهبود چشمگیر نتایج مدل شبکه عصبی تنها شده و دیده می‌شود که نتایج مدل ترکیبی تطابق بیشتری با مقادیر مشاهده‌ای در پیژومترها دارد. در مدل ترکیبی استفاده از سطح تجزیه

بالا مطلوب نبود، زیرا اگرچه سطح تجزیه بالا دقت آموزش شبکه را افزایش می‌دهد اما نتیجه معکوس روی داده‌های اعتبارسنجی و آموزش دارد.

تراز آب زیرزمینی به عوامل گوناگونی بستگی دارد. با توجه به اطلاعات بدست آمده از مطالعات قبلی صورت گرفته در منطقه مطالعاتی، احتمالاً مهم‌ترین عوامل تأثیرگذار در نوسانات سطح آب زیرزمینی پیرومترهای انتخابی این دشت، پمپاژ از چاه‌های کشاورزی، درجه حرارت و تغذیه آبخوان از دشت ساوه می‌باشد که آمار دقیقی از آن‌ها در دست نمی‌باشد. به نظر می‌رسد مدل ترکیبی، ارتباطات بین تراز آب زیرزمینی ماه فعلی با تراز آب زیرزمینی ماه‌های قبل را یافته است. ارتباط‌هایی که به دلیل پیچیدگی این پدیده و به طور کلی طبیعت، به راحتی قابل تشخیص نمی‌باشند. در ارتباط تراز آب زیرزمینی ماه فعلی و ماه قبل عوامل بسیاری دخیل بوده که اگر حتی از همه عوامل آمار موجود باشد، باز هم این روابط قابل ارائه بصورت یک رابطه ریاضی دقیق نمی‌باشد. از آنجا که محدوده مطالعاتی شریف‌آباد تقریباً در انتهای حوضه دریاچه نمک قرار دارد، لذا طبیعتاً انتظار می‌رود سطح آب در آن پایین نباشد، ولی به علت برداشت بی‌رویه و تعدد چاه‌های بهره‌برداری (که غالباً با دبی‌های زیاد و ساعات کارکرد طولانی فعال هستند)، افت شدید تراز آب زیرزمینی در منطقه دیده می‌شود. از طرفی با توجه به سری زمانی سه پیرومتر می‌توان مؤثرتر بودن اثر پمپاژ بی‌رویه را در این کاهش تراز، نسبت به سایر عوامل، محتمل دانست.

پیش‌بینی یک ماهه تراز آب زیرزمینی

پیش‌بینی تراز آب زیرزمینی ماهانه یک گام پیش‌رو، در فروردین ماه ۱۳۹۲ در جدول ۹ ارائه شده است. دیده می‌شود که مدل ترکیبی در پیش‌بینی یک گام پیش‌رو نیز نتایج دقیق‌تری ارائه نموده است. در پیرومتر ۲ ملاحظه می‌شود که مدل رگرسیونی برخلاف عملکرد ضعیف خود در پیش‌بینی‌های دوره آزمون، پیش‌بینی قابل قبولی ارائه نموده است. اگرچه نمی‌توان با اطمینان در این مورد بحث کرد اما بر اساس نتایج حاصل از عملکرد مدل خطی حاضر در این پژوهش، شاید بتوان گفت که مدل خطی گاه‌ها در پیش‌بینی نقطه‌ای پدیده‌ها نتایج قابل قبولی ارائه نموده است اما در شبیه‌سازی یک سری زمانی پی در پی با نوسانات شدید نتوانسته کارایی قابل قبولی داشته باشد. مدل GP نیز برای پیرومترهای ۱ و ۲ با خطای کمتری پیش‌بینی را انجام داده است.

جدول (۹). پیش‌بینی یک ماهه تراز آب زیرزمینی در چاه‌های مشاهده‌ای

پیزومتر ۱		پیزومتر ۲		پیزومتر ۳		
تراز	خطا (%)	تراز	خطا (%)	تراز	خطا (%)	
۸۱۶/۶۴۷۱	۰/۰۴۳	۸۱۱/۱۷۱	۰/۰۳۴	۷۹۶	۰/۱۲۱	ANN (m)
۸۱۷/۰۴۶۵	-۰/۰۰۵۶	۸۱۱/۵۹۵	-۰/۰۱۷۹	۷۹۷/۲۹	-۰/۰۴	WNN (m)
۸۱۷/۳۷۰۱	-۰/۰۴۵	۸۱۱/۴۱۶	۰/۰۰۴۱۸	۷۹۷/۶۳۹	-۰/۰۸۴	MLR (m)
۸۱۶/۵۴	۰/۰۵۷	۸۱۱/۰۸	۰/۰۴۵	۷۹۵/۸۹	۰/۱۳۲	GP (m)
۸۱۷		۸۱۱/۴۵		۷۹۶/۹۷		مشاهده‌ای (متر)

ارزیابی مدل‌ها در پیش‌بینی نقاط بیشینه

جداول (۱۰، ۱۱ و ۱۲) نتایج مدل‌سازی نقاط بیشینه سری زمانی تراز آب زیرزمینی سه پیزومتر را نشان می‌دهد.

جدول (۱۰). نتایج ارزیابی مدل‌ها در پیش‌بینی نقاط بیشینه در پیزومتر ۱

ردیف	تراز مشاهده‌ای (m)	GP (m)	ANN (m)	MLR (m)	WNN (m)
۱	۸۱۷/۲۵	۸۱۷/۰۸	۸۱۷/۱۲۷۸	۸۱۷/۵۵۹۳	۸۱۶/۸۱۵
۲	۸۱۲/۸۵	۸۱۱/۷۲	۸۱۱/۸۵۱۴	۸۱۱/۸۹۸۵	۸۱۲/۹۹۲۶
۳	۸۱۲/۸۵	۸۱۱/۷۸	۸۱۳/۲۵۸۴	۸۱۳/۳۳۱	۸۱۲/۷۳۹۴
۴	۸۱۹/۶۱	۸۱۸/۰۳	۸۱۷/۰۹۳۲	۸۱۷/۲۴۹۱	۸۱۹/۵۳۶۹
۵	۸۱۸/۵۸	۸۱۹/۸۸	۸۱۶/۶۲۸	۸۱۷/۱۱۴۹	۸۱۸/۲۳۸۹
	RMSE (m)	۱/۵۵	۱/۵	۱/۶۲	۰/۲۶
	E	۰/۷۴	۰/۷۸	۰/۷۲	۰/۹۹

جدول (۱۱). نتایج ارزیابی مدل‌ها در پیش‌بینی نقاط بیشینه در پیزومتر ۲

ردیف	تراز مشاهده‌ای (m)	GP (m)	ANN (m)	MLR (m)	WNN (m)
۱	۸۱۲/۲	۸۱۱/۶۱	۸۱۱/۷۰۸۳	۸۱۱/۴۶۱۷	۸۱۱/۸۹۰۵
۲	۸۱۰/۵۴	۸۰۸/۶۸۱	۸۱۱/۷۲۲۱	۸۰۷/۴۳	۸۱۰/۳۳۶۵
۳	۸۱۰/۶۴	۸۰۹/۵۲	۸۰۹/۷۸۵۸	۸۱۰/۲۴۷۴	۸۱۰/۵۸۱۷
۴	۸۱۱/۸۴	۸۱۰/۲۳	۸۱۰/۰۶۱۱	۸۱۰/۰۶۴۸	۸۱۱/۷۸۲۶
۵	۸۰۸/۹۷	۸۱۰/۳۳	۸۱۰/۰۶۱۱	۸۰۹/۲۳۴۴	۸۰۹/۱۲۹۱
۶	۸۱۱/۶۲	۸۱۱/۲۳	۸۱۱/۳۷۶۵	۸۱۱/۳۶۱۳	۸۱۱/۷۰۳۹
	RMSE (m)	۱/۱۸	۱/۱۲	۱/۳۸	۰/۱۷
	E	۰/۰۶	-۰/۰۸۵	-۰/۰۶۴	۰/۹۷

جدول (۱۲). نتایج ارزیابی مدل‌ها در پیش‌بینی نقاط بیشینه در پیزومتر ۳

ردیف	تراز مشاهده‌ای (m)	GP(m)	ANN (m)	MLR (m)	WNN (m)
۱	۷۹۸/۰۷	۷۹۵/۳۴	۷۹۵/۵۰۹۹	۸۱۱/۴۶۱۷	۷۹۸/۲۸۱۸
۲	۷۹۷/۴۲	۷۹۱/۹۸	۷۹۵/۸۵۲۴	۸۰۸/۸۰۹۷	۷۹۵/۱۳۱۷
۳	۷۹۴/۴۲	۷۹۲/۱۲	۷۹۵/۴۵۴۵	۸۱۰/۲۴۷۴	۷۹۵/۰۴۷
۴	۷۹۷/۵۹	۷۹۸/۴۳	۷۹۵/۹۷۰۸	۸۱۰/۰۶۴۸	۷۹۵/۰۱۳۱
۵	۷۹۶/۰۱	۷۹۴/۱۲	۷۹۵/۷۴۸۵	۸۰۹/۳۳۴۴	۷۹۶/۴۲۳۱
۶	۷۹۷/۱۲	۷۹۵/۰۳	۷۹۶/۳۱۳۱	۸۱۱/۳۶۱۳	۷۹۷/۶۸۳۱
	RMSE (m)	۳۸/۱	۲۴/۱	۱/۴۵۹	۰/۲۴
	E	-۰/۰۱۲	-۰/۰۳	-۰/۴۱۹	۰/۹۵

در جداول فوق برای مقایسه عملکرد مدل‌ها، نقاط پیک سری زمانی انتخاب شده‌اند. مدل موجک-عصبی، نسبت به دو مدل دیگر، توانسته است با دقت بالاتری نقاط بیشینه را در چاه-های مشاهده‌ای پیش‌بینی نماید.

نتیجه‌گیری

در تحقیق حاضر به پیش‌بینی تراز آب زیرزمینی آبخوان دشت شریف‌آباد استان قم با استفاده از مدل شبکه عصبی، مدل رگرسیون خطی، مدل برنامه‌ریزی ژنتیک و مدل ترکیبی موجک-شبکه عصبی پرداخته شده است. با توجه به نتایج ضعیف مدل خطی MLR و همچنین با دقت در نمودار سری زمانی پیزومترها می‌توان دریافت که این مدل، رگرسیونی خطی بین متغیرها در نظر می‌گیرد، لذا این روش برای شبیه‌سازی خصوصیات غیرخطی و پیچیده تراز آب زیرزمینی و نوسانات شدید و پی در پی مناسب نخواهد بود. در مقایسه با مدل‌های رگرسیونی، مدل‌های هوشمند دارای مزیت قابلیت تنظیم چندین پارامتر می‌باشند. نتایج تحقیق نشان داد که مدل GP نسبت به مدل رگرسیون دقت بالاتری دارد. براساس دو معیار ارزیابی E و $RMSE$ ، مشخص شد که مدل ترکیبی WNN، با موجک مادر Meyer، توانسته بهترین نتایج را در پیش‌بینی ۲۴ ماهه دوره آزمون، پیش‌بینی یک گام پیش‌رو و همچنین پیش‌بینی نقاط پیک ارائه نماید. تجزیه چند سطحی داده‌ها با کمک آنالیز موجک، توانسته تا حد قابل توجهی نتایج مدل شبکه عصبی را بهبود بخشد، به گونه‌ای که برآورد تراز آب زیرزمینی با مدل ترکیبی WNN تا ۲۴ ماه در دشت شریف‌آباد با ۳ پیزومتر مورد بررسی، دارای دقت بسیار خوبی بود. اعمال آنالیز موجک بر سیگنال تراز آب زیرزمینی، در افزایش دقت نتایج شبکه عصبی بسیار مؤثر بوده

است. مزیت مدل ترکیبی نسبت به مدل شبکه عصبی، قابلیت آن در تشخیص اجزاء تشکیل دهنده داده توسط تجزیه چند سطحی موجکی داده‌هاست.

نتایج مدل‌سازی‌های تحقیق نشان داد که ترکیب موجک و شبکه عصبی، در بازه‌های زمانی نایستا با دقت مناسبی عمل می‌کند. به عبارت دیگر، در ابتدا بوسیله تجزیه موجکی اختلالات از روند اصلی جدا شده و سپس شبکه عصبی با تشخیص تعداد تأخیرها و همچنین دور یا نزدیک بودن زمان وقوع نویزها نسبت به گام زمانی پیش‌بینی، تخمین واقعی‌تری از پارامتر مورد نظر ارائه می‌دهد. با توجه به سری زمانی سه پیرومتر و مشاهده افت تراز آب زیرزمینی و همچنین اطلاعات بدست آمده از مطالعات قبلی صورت گرفته در منطقه، می‌توان مؤثرتر بودن اثر پمپاژ بی‌رویه را در کاهش تراز آب زیرزمینی محتمل دانست.

به دلیل انعطاف‌پذیری بالای مدل‌های هوشمند پیشنهاد می‌شود رویکردهای دیگری نیز در پیش‌بینی تراز آب زیرزمینی بررسی گردد که از این بین می‌توان به ترکیب منطق فازی با مدل هیبرید آنالیز موجک-عصبی و نیز استفاده از ترکیب‌های بهینه زیرسری‌های تقریب و جزئیات سری زمانی تراز آب زیرزمینی در مدل‌سازی اشاره نمود.

منابع و مأخذ

۱. کیا، مصطفی (۱۳۸۹). شبکه‌های عصبی در متلب، نشر کیان‌رایانه سبز، چاپ دوم، صص ۴۰-۳۵.
۲. محتشم، محسن، دهقانی، امیر احمد، اکبرپور، ابوالفضل، مفتاح حلقی، مهدی و بهروز اعتباری (۱۳۸۹). پیش‌بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت بیرجند)، مجله آبیاری و زهکشی ایران، شماره ۱، جلد ۴، صص ۱۰-۱.
۳. مختاری، زینب، ناظمی، امیر حسین و عطا اله ندیری (۱۳۹۱). پیش‌بینی تراز آب زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی (مطالعه موردی: دشت شبستر)، فصلنامه زمین-شناسی کاربردی، سال ۸، شماره ۴، صص ۳۵۳-۳۴۵.
۴. نخعی، محمد و امیر صابری نصر (۱۳۹۱). پیش‌بینی نوسانات سطح آب زیرزمینی دشت قروه با استفاده از شبکه عصبی-موجکی و مقایسه آن با مدل عددی MODFLOW، مجله زمین-شناسی کاربردی پیشرفته، شماره ۴، جلد ۱، صص ۵۸-۴۷.

Adamowski, Jan and Chan, Hiu Fung., (2011). *A wavelet neural network conjunction model for groundwater level forecasting*. Journal of Hydrology, 407, 28-40.

Banerjee Chattopadhyaya, Pallavi and Rangarajana, R., (2014). *Application of ANN in sketching spatial nonlinearity of unconfined aquifer in agricultural basin*. Agricultural Water Management, 133, 81–91.

Cannas, B., Fanni, A., See, L. and Sias, G., (2006). *Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning*. Physics and Chemistry of the Earth, 31 (18), 1164–1171.

Cohen A and Kovacevic J., (1996). *Wavelets: the mathematical background*. Proc IEEE, 84(4), 514–22.

Mekanik, F., Imteaz, M.A., Gato-Trinidad, S., and Elmahdi, A., (2013). *Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes*. Journal of Hydrology, 503, 11–21.

Mohanty, S., Jha, Madan K., Kumar, Ashwani and Panda, D. K., (2013). *Comparative evaluation of numerical model and artificial neural network for simulating groundwater flow in Kathajodi–Suru Inter-basin of Odisha, India*. Journal of Hydrology, 495, 38–51.

Nayak, P. C., Venkatesh, B., Krishna, B. and Jain, Sharad K., (2013). *Rainfall-runoff modeling using conceptual, data driven, and wavelet based computing approach*. Journal of Hydrology, 493, 57–67.

Nourani, Vahid, Hosseini Baghanam, Aida, Adamowski, Jan and Gebremichael, Mekonnen., (2013). *Using self-organizing maps and wavelet transforms for space-time pre-processing of satellite precipitation and runoff data in neural network based rainfall-runoff modeling*. Journal of Hydrology, 476, 228–243.

Partal, T., (۲۰۰۹). *River flow forecasting using different artificial neural network algorithms and wavelet transform*. Canadian Journal of Civil Engineering, 36 (1), 26–38.

Rajaei, Taher, Mirbagheri, S. Ahmad, Nourani, Vahid and Alikhani, A., (2010). *Prediction of daily suspended sediment load using wavelet and neuro-fuzzy combined model*. Int. Journal of Environment Science Technology, Vol.۷, No.۱, ۹۳-۱۱۰.

Rajaei, Taher, Nourani, Vahid, Zounemat-Kermani, Mohammad and Kisi, O., (2011). *River Suspended Sediment Load Prediction: Application of ANN and Wavelet Conjunction Model*. Journal of Hydrology Engineering, Vol. 16, No. 8, 613–627.

Rajaei, Taher., (2011). *Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers*. Science of the Total Environment, 409, 2917–2928.

Taormina, Riccardo, Chau, Kwok-wing and Sethi, Rajandrea., (2012). *Artificial neural network simulation of hourly groundwater levels in a coastal aquifer system of the Venice lagoon*. Engineering Applications of Artificial Intelligence, 25, 1679-1676.

Yang, Z. P., Lu, W. X., Long, Y. Q., and Li, P., (2009). *Application and comparison of two prediction models for groundwater levels: A case study in Western Jilin Province, China*. Journal of Arid Environments, 73, 487-492.