

مدل‌سازی تراز آب زیرزمینی با بهره‌گیری از مدل هیبرید موجک- شبکه عصبی مصنوعی (مطالعه موردي: دشت شریفآباد)

طاهر رجایی^{*} و اکرم زینیوند^۲

^۱ استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه قم

^۲ کارشناس ارشد سازه‌های هیدرولیکی، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه قم

چکیده

منابع آب زیرزمینی یکی از مهم‌ترین منابع تأمین آب می‌باشند، از این‌رو مدل‌سازی آن‌ها بسیار حائز اهمیت می‌باشد. ارزیابی و پیش‌بینی تراز آب زیرزمینی به پیش‌بینی منابع آب زیرزمینی کمک می‌کند. هدف این مطالعه ارزیابی عملکرد سه مدل رگرسیون خطی چندمتغیره (MLR)، مدل هیبرید موجک- شبکه عصبی (WNN) و شبکه عصبی مصنوعی (ANN) در پیش‌بینی سطح آب زیرزمینی (GWL)، بر مبنای دو معیار ریشه خطای مربع متوسط (RMSE) و ضریب کارایی نش- ساتکلیف (E) می‌باشد. داده‌های استفاده شده در این پژوهش مربوط به دو حلقه چاه مشاهده‌ای در حوضه آبریز شریف‌آباد استان قم هستند. مدل‌سازی تراز آب زیرزمینی چاه‌ها با استفاده از داده‌های تراز آب زیرزمینی ۱۵ سال و ۶ ماه، برای پیش‌بینی تراز آب ماهه دوره آزمون انجام شده است. نتایج نشان داده‌اند که مدل موجک- شبکه عصبی تطابق بهتری با مقادیر مشاهده‌ای تراز آب زیرزمینی دارد.

واژگان کلیدی: دشت شریف‌آباد، تراز آب زیرزمینی، شبکه عصبی مصنوعی، تبدیل موجک، رگرسیون خطی چند متغیره.

مناطق خشک و نیمه خشک استان جیلین غربی واقع در چین پرداختند. آن‌ها از داده‌های ۸ ساله یک حلقه چاه مشاهده‌ای در منطقه مورد مطالعه استفاده کردند. مقایسه دو روش بر اساس معیارهای E^۱، RMSE^۲ و MAE^۳ برتری شبکه عصبی پس-انتشار خطرا در پیش‌بینی سری زمانی تراز آب زیرزمینی نشان داد. Banerjee و همکاران [۲] با پیش‌بینی شوری آب زیرزمینی در یکی از جزایر، مجمع‌الجزایر Lakshadweep واقع در سواحل غرب هند، برتری مدل شبکه عصبی را بر مدل‌های ریاضی نشان دادند. آن‌ها دو مدل شبکه عصبی پیش‌خور با الگوریتم انتشار سریع و مدل ریاضی SUTRA^۴، را برای تخمین نرخ پمپاز این، جهت حفظ شوری آب زیرزمینی در منطقه مورد مطالعه به کار گرفتند. Hwa Cho و همکاران [۳] در تحقیقی به ارزیابی عملکرد چهار مدل MLR^۵، ANN^۶، PCR^۷ و PC-ANN^۸ در پیش‌بینی پتانسیل آلودگی آرسنیک آب زیرزمینی، در کشورهای کامبوج، لائوس و تایلند پرداختند.

۱- مقدمه

بهره‌برداری بی‌رویه از منابع آب زیرزمینی در سال‌های اخیر باعث به هم خوردن تعادل طبیعی آن شده و تراز آب زیرزمینی در آبخوان‌های بسیاری از نقاط کشور منفی شده است. به منظور آگاهی از وضعیت این منابع و مدیریت بهینه آن‌ها، لازم است پیش‌بینی دقیقی از نوسانات تراز آب زیرزمینی صورت گیرد. بیشتر سری‌های زمانی هیدرولوژیکی نظریه تغییرات سطح آب زیرزمینی همواره شامل فرایندهای نامانا و پیچیده هستند که با استفاده از مدل‌های خطی متداول و کلاسیک به خوبی قابل توصیف و مدل‌سازی نیستند. بنابر این به منظور مدل‌سازی این پدیده‌های هیدرولوژیکی لازم است از مدل‌های غیر خطی استفاده نمود.

ارزیابی و پیش‌بینی تراز آب زیرزمینی از طریق مدل‌های خاص، به پیش‌بینی منابع آب زیرزمینی کمک می‌کند. با اثبات توانایی‌های مدل‌های هوشمند در مدل‌سازی سری‌های زمانی طی سال‌های اخیر، کاربرد این مدل‌ها در زمینه مدل‌سازی آبهای زیرزمینی شدت گرفته است. Yang و همکاران [۱] به مقایسه مدل‌های سری‌های زمانی یکپارچه (ITS)^۹ و شبکه عصبی مصنوعی پس‌انتشار در پیش‌بینی سطح آب زیرزمینی

2- Nash-Sutcliffe coefficient of efficiency

3- Root mean squared error

4- Mean absolute error

5- Saturated-unsaturated transport

6- Multiple linear regression

7- Multiple linear regression

8- Principal component regression

1- Integrated time series

نمودند. ورودی‌های مدل، میزان برداشت آب از چاه‌های آب شرب، صنعت و کشاورزی، میزان آب ورودی به هر پلیگون بر حسب متر مکعب (تاشی از بارندگی منطقه) و تراز سطح آب در هر پیزومتر در گام زمانی قبل و خروجی مدل، تراز سطح آب در گام زمانی فعلی بوده است. اخیراً در تحقیقی، Mokhtari و همکاران [۱۰] به پیش‌بینی ماهانه تراز آب زیرزمینی دشت شبستر، یکی از زیرحوضه‌های ارومیه، با کمک مدل شبکه عصبی مصنوعی پرداختند. آن‌ها از اطلاعات ۹ ساله سری زمانی تراز آب زیرزمینی در ۱۵ حلقه چاه پیزومتری استفاده نمودند.

با ورود تئوری نوین تبدیل موجک به حیطه علم ریاضی و مهندسی، استفاده از موجک‌ها به عنوان ابزاری قدرتمند در تجزیه و پیش‌پردازش سری‌های زمانی به سرعت افزایش یافته و توانایی آن‌ها در بهبود نتایج پیش‌بینی‌ها به اثبات رسیده است. هر چند مدت زیادی از عمر تئوری موجک نمی‌گذرد، اما طی همین چند سال اندک، پژوهش‌های زیادی در زمینه‌های مختلف با استفاده از آن‌ها صورت گرفته است. در این راست، Rajaei و همکاران [۱۱] مدل تلفیقی شبکه عصبی- فازی- موجکی را برای پیش‌بینی میزان بار سوب معلق رودخانه پیکوس در غرب تنگستان به کار برند. دیگر بار رسوی روزانه این رودخانه در مدت ۷ سال به عنوان ورودی مدل مورد استفاده قرار گرفت. Wang و همکاران [۱۲] به شبیه‌سازی سیل با بهره‌گیری از مدل ترکیبی موجک- شبکه عصبی- الگوریتم ژنتیک^۱ در یکی از زیرحوضه‌های Nen River، واقع در شمال شرق چین پرداختند. Nourani و همکاران [۱۳] دو مدل ترکیبی هوش مصنوعی را برای پیش‌بینی بارش- رواناب، در دو حوضه آبریز لیقوان چای و آجی چای، واقع در شمال غرب ایران در استان آذربایجان مورد استفاده قرار دادند. آن‌ها دو مدل هیبرید SARIMAX-ANN^۲ و wavelet-ANFIS^۳، را بررسی نمودند. در نهایت به این نتیجه رسیدند که مدل wavelet-ANFIS، عملکرد مناسب‌تری را دارا است.

Rajaei [۱۴] با پیش‌بینی روزانه بار سوب معلق در Yadkin River، واقع در ایالات متحده آمریکا، برتری مدل هیبرید موجک- شبکه عصبی را در پیش‌بینی بار معلق رودخانه‌ها نشان داد. Chan و Adamowski [۱۵] از داده‌های ۸ ساله حوضه آبریز شاتوگای در کانادا استفاده کردند و به پیش‌بینی

در این پژوهش، مدل هیبرید PC-ANN توانست ضریب کارایی نش^۴ بالاتری را ارائه نماید. Taormina و همکاران [۴] با استفاده از شبکه عصبی با الگوریتم پس‌انتشار خطاط، سطح آب زیرزمینی آبخوان آزاد ساحلی منطقه لاغون را در ونیز ایتالیا برای ساعات آینده پیش‌بینی کردند. آن‌ها یک بار از داده‌های بارش، تبخیر و تعرق و سطح آب زیرزمینی در زمان‌های قبل و بار دیگر تنها از داده‌های بارش و تبخیر و تعرق به عنوان ورودی مدل استفاده کردند. نتایج مدل‌سازی حاکی از برتری روش اول Mohanty و همکاران [۵] به ارزیابی تطبیقی مدل عددی تفاضل محدود MODFLOW و مدل شبکه عصبی، پیرامون شبیه‌سازی تراز هفتگی آب‌های زیرزمینی ۱۸ حلقه چاه مشاهده‌ای درون یک آبخوان آبرفتی واقع در ادیشهای هند، پرداختند. آن‌ها برای ورودی‌های شبکه عصبی از داده‌های هفتگی بارش، تبخیر، تراز رودخانه، تراز آب در تخلیه، نرخ پمپاز حلقه چاه‌ها و تراز آب زیرزمینی، استفاده کردند. نتایج حاکی از برتری مدل ANN، نسبت به مدل عددی بود. Rajaei و همکاران [۶] نیز به پیش‌بینی روزانه غلظت بار معلق با استفاده از داده‌های سری زمانی روزانه دیگر جریان و غلظت بار معلق، در دو ایستگاه آب‌سنگی رودخانه ساکرامنتو در ایالت کالیفرنیای آمریکا با استفاده از مدل شبکه عصبی مصنوعی پرداختند.

در ایران نیز مطالعاتی در این زمینه طی چند سال گذشته انجام شده است. Fallah-Mehdipour و همکاران [۷] به پیش‌بینی تراز ماهانه آب زیرزمینی دشت کرج، با استفاده از الگوریتم ژنتیک و مدل سیستم استنتاج شبکه عصبی- فازی- تطبیقی پرداختند. آن‌ها از داده‌های تبخیر، بارش و تراز آب زیرزمینی استفاده نمودند. Nikmanesh [۸] به ارزیابی توانائی شبکه‌های عصبی مختلف در پیش‌بینی تراز آب‌های زیرزمینی محدوده ارسنجان در استان فارس پرداخت. ساختارهای مختلف مورد ارزیابی در این تحقیق شامل سه شبکه عصبی (پیشرو^۵، برگشتی^۶ و تابع شعاعی^۷) و دو الگوریتم (لونبرگ- مارکوارت^۸ و پس‌انتشار خطاط^۹) بوده است. Mohtasham و همکاران [۹] به پیش‌بینی سطح ایستابی دشت بیرجند با استفاده از روش شبکه عصبی مصنوعی پرداختند. آن‌ها برای آموزش مدل، از اطلاعات ۱۶ پیزومتر که اغلب دارای بیش از ۱۵ سال آمار بودند، استفاده

1- Nash-sutcliffe coefficient of efficiency

2- Feed forward neural network

3- Recurrent neural networks

4- Radial basis function neural networks

5- Levenberg-marquardt algorithm

6- Error back-propagation algorithm

7- Genetic algorithm-wavelet neural network

8- Seasonal auto regressive integrated moving average with exogenous input-artificial neural network

9- Adaptive neural-fuzzy inference system

NAM^۱، نشان دادند. آن‌ها از داده‌های روزانه تبخیر، دبی و بارش ۲۱ ساله استفاده نمودند. در سال‌های اخیر، ترکیب موجک و شبکه عصبی با توجه به توانایی اش در زمینه پیش‌بینی و شبیه‌سازی، در علوم مختلف مورد استفاده قرار گرفته است، اما استفاده از آن در مطالعات آب‌های زیرزمینی محدود بوده و تحقیق زیادی در این زمینه صورت نگرفته است. بنابر این هدف از این تحقیق نشان دادن پتانسیل مدل ترکیبی تحلیل موجک- شبکه عصبی در پیش‌بینی نوسانات تراز آب زیرزمینی در دشت شریف‌آباد قم می‌باشد. در این مقاله یک روش جدید مبتنی بر ترکیب تبدیل موجک گسسته و شبکه‌های عصبی تأخیر زمانی (W-TDNN)، برای پیش‌بینی تراز آب زیرزمینی، پیشنهاد شده است. در شبکه تأخیر زمانی، از چندین سری زمانی در ورودی شبکه عصبی می‌توان استفاده کرد. از این‌رو، زیر سری‌های تقریب و جزئیات تراز آب زیرزمینی حاصل از تحلیل موجکی، همزمان به عنوان ورودی به شبکه داده شد. در نتیجه، مقادیر آینده سری زمانی اصلی به صورت تابعی از مقادیر گذشته زیر سری‌ها پیش‌بینی می‌شوند. همچنین نتایج مدل پیشنهادی با نتایج حاصل از دو مدل شبکه عصبی و رگرسیون خطی چند متغیره، به منظور بررسی تأثیر تحلیل موجک بر نتایج مدل شبکه عصبی، مورد مقایسه قرار گرفته است. مدل‌های دقیق می‌توانند نوسانات سری زمانی تراز آب زیرزمینی را شبیه‌سازی نمایند و وضعیت آبخوان دشت را در ماههای آتی پیش‌بینی نمایند. بر این اساس، روند کاهش این منبع مهم زیرزمینی، روش‌نمی‌گردد.

۲- مواد و روش‌ها

۱-۱- موقعیت جغرافیایی دشت شریف‌آباد

محدوده مطالعاتی شریف‌آباد با وسعتی معادل ۴۴۱ کیلومتر مربع بین مختصات UTM^۲، X: ۵۲۵۰۰۰، Y: ۳۸۵۰۰۰ و X: ۴۸۵۰۰۰، Y: ۳۸۳۰۰۰ محدوده مطالعاتی مسیله، از جنوب به محدوده مطالعاتی قم و از غرب به محدوده مطالعاتی ساوه محدود می‌گردد. وسعت دشت ۲۸۹ کیلومتر مربع می‌باشد. در محدوده مطالعاتی شریف‌آباد ارتفاعاتی همچون کوههای کفتارکوه بزرگ و کفتارکوه کوچک در ناحیه جنوبی منطقه با ارتفاع تقریبی ۹۸۰ متر و کوه سپرستم با ارتفاع تقریبی ۹۲۰ متر در شمال آن واقع هستند. آبخوان دشت شریف‌آباد در قسمت غرب با آبخوان دشت ساوه هم‌مرز

سطح آب زیرزمینی با استفاده از مدل تلفیقی شبکه‌های عصبی مصنوعی و تبدیلات موجک پرداختند. آن‌ها نتایج پیش‌بینی سطح آب زیرزمینی توسط این مدل تلفیقی را با شبکه عصبی مصنوعی مقایسه کردند. نتایج این مقایسه نشان داد که مدل تلفیقی با دقت بالاتری قادر به پیش‌بینی سطح آب زیرزمینی است.

همچنین، Rajaei و همکاران [۱۶] کاربرد مدل ترکیبی موجک- شبکه عصبی را در پیش‌بینی بار رسوب معلم ایستگاه آبسنجی Iowa River واقع در آمریکا، بررسی نمودند. بدین منظور آن‌ها مدل‌های WNN^۳، SRC^۴ و ANN^۵ را ارزیابی نمودند. سری‌های زمانی دبی رودخانه و بار رسوب معلم روزانه، پارامترهای به کار گرفته شده در مدل‌سازی بودند. نتایج نشان دهنده برتری روش WNN، نسبت به سایر روش‌ها بود. این مدل ترکیبی در ایران نیز مورد توجه قرار گرفت. Nakhaee و همکاران [۱۷] نوسانات سطح آب زیرزمینی در دشت قزوون استان ردهستان را با استفاده از چند نوع موجک مادر^۶ و سطح تجزیه^۷ بهینه، پیش‌بینی نمودند. آن‌ها از داده‌های سطح آب زیرزمینی که به مدت ۱۰ سال در ۲۶ پیزومتر دشت قزوون اندازه-گیری شده بود، به عنوان ورودی شبکه عصبی موجکی استفاده نمودند؛ سپس نتایج مدل شبکه عصبی موجکی را با نتایج حاصل از مدل MODFLOW مقایسه کردند. نتایج بیانگر آن بودند که روش شبکه عصبی موجکی نسبت به روش عددی کارایی بالاتر را دارا می‌باشد. فتحی [۱۸] به پیش‌بینی نوسانات سطح آب زیرزمینی با استفاده از مدل‌های تلفیقی شبکه عصبی- فازی تطبیقی- موجکی، شبکه عصبی- موجکی و مدل خطی ARIMA^۸ در دشت قم پرداخت. وی از داده‌های سری زمانی تراز ماهانه، بارش و متوسط دمای ماهانه استفاده نمود. وی یکبار فقط از تراز آب زیرزمینی و بار دیگر از هر سه پارامتر بارش، تراز و دما با تأخیر سه ماهه، به عنوان ورودی مدل استفاده کرد. در این تحقیق مدل هیبرید شبکه عصبی و موجک با به کارگیری سه پارامتر مذکور به عنوان ورودی، نتایج بهتری را ارائه نمود. نایاک و همکاران [۱۹] برتری عملکرد مدل WNN را در مدل ANN سازی بارش رواناب حوضه‌ای در هند، نسبت به دو مدل

1- Wavelet neural network

2- Sediment rating curve

3- Mother wavelet

4- Decomposition level

5- Autoregressive moving average model

مشخصات چاههای پیزومتری در جدول (۱) و نمودار سری زمانی سطح آب زیرزمینی در شکل (۲) و (۳) آمده است. بر اساس رابطه (۱) ضریب همبستگی تراز آب زیرزمینی برای تأخیرهای ۱، ۳، ۲ و ۴ ماهه محاسبه شده و نتایج در جدول (۲) آورده شده‌اند. مجموعه اعتبارسنجی در محاسبه ضریب همبستگی دوره آموزش استفاده شده است.

جدول ۱- مشخصات دو حلقه چاه پیزومتری مورد مطالعه

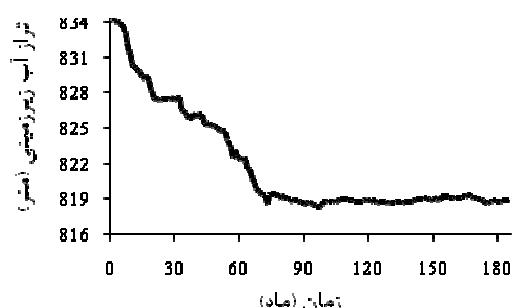
نوع آماربرداری	UTM			نام پیزومتر	شماره پیزومتر
	X	Y	Z		
ماهانه	۴۹۸۳۲۸	۳۸۴۷۳۶۷	۸۵۶/۴۴	جنوب غربی عسکرآباد	۱
ماهانه	۵۰۸۷۴۲	۳۸۴۱۵۲۶	۸۳۹/۴۴	سامآباد	۲

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

جدول ۲- ضریب همبستگی سطح آب زیرزمینی دو حلقه چاه

پیزومتری تا ۴ ماه تأخیر

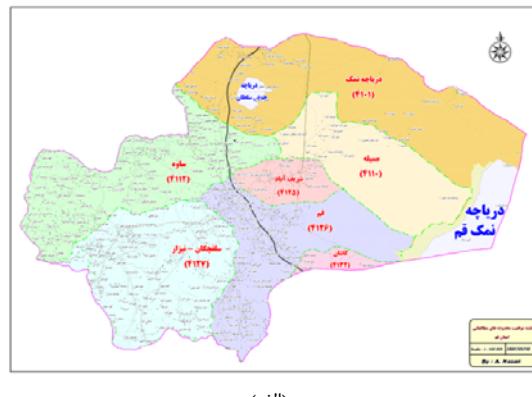
دوره آموزش	دوره آزمون	ضریب همبستگی ماهانه	نام پیزومتر
۰/۹۹۸	۰/۱۸۶	R1	جنوب غربی عسکر آباد
۰/۹۹۷	۰/۵۸۶	R2	
۰/۹۹۵	۰/۱۳۲	R3	
۰/۹۹۲	۰/۱۶۱	R4	
۰/۹۹۳	۰/۷۹۵	R1	سامآباد
۰/۹۹۵	۰/۷۶۱	R2	
۰/۹۷۷	۰/۶۳۸	R3	
۰/۹۶۸	۰/۵۱۹	R4	



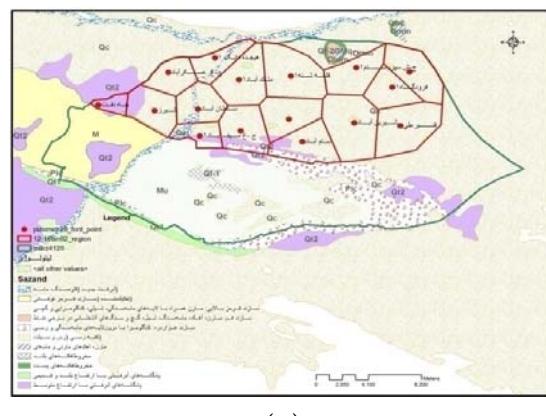
شکل ۲- نمودار تراز آب زیرزمینی پیزومتر ۱

بوده و این محل یک ورودی آب زیرزمینی دشت شریف‌آباد محسوب می‌شود. بیش از ۹۰ درصد آب برداشتی از چاههای پمپاژ این دشت به مصرف کشاورزی می‌رسد. شکل (۱) موقعیت دشت و چاهها را نشان می‌دهد.

مکان‌های مورد مطالعه، دو حلقه چاه پیزومتری واقع در دشت شریف‌آباد می‌باشند. پس از بررسی داده‌های سری زمانی تراز آب زیرزمینی چاههای مشاهده‌ای، مشاهده گردید که در برخی چاهها شماری از داده‌های تراز موجود نمی‌باشد، از این رو حلقه چاههایی که دارای داده‌های کامل بودند انتخاب گردید. از طرفی مدل سازی هر چاه مستقل از چاه دیگر انجام می‌شود و تعداد چاههای انتخابی تأثیری در دقت مدل سازی ندارد. داده‌ها شامل اندازه‌گیری ماهانه تراز آب زیرزمینی این دو حلقه چاه است که مربوط به ۱۵ سال و ۶ ماه از مهرماه ۱۳۷۶ تا اسفند ۱۳۹۱ می‌باشد، که به سه مجموعه آموزش (از مهر ۱۳۷۶ تا دی ۱۳۸۸)، اعتبارسنجی (از بهمن ۱۳۸۸ تا مرداد ۱۳۹۰) و آزمون (از شهریور ۱۳۹۰ تا اسفند ۱۳۹۱) تقسیم شده‌اند.



(الف)

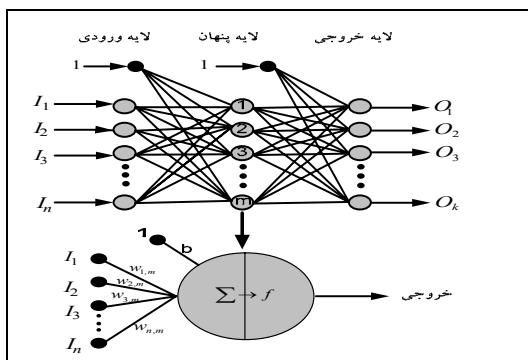


(ب)

شکل ۱- (الف) موقعیت محدوده مطالعاتی شریف‌آباد،

ب) موقعیت چاههای مشاهده‌ای

ارتباط هستند. ورودی هر لایه ممکن است از متغیرهای ورودی یا خروجی گرههای دیگر حاصل شود (شکل ۴)).



شکل ۴- معماری شبکه عصبی مصنوعی

در یک شبکه عصبی مصنوعی، نرون m اطلاعات ورودی خود را از طریق گرههای ورودی I_i دریافت می‌کند. هر یک از این گرههای ورودی، قبل از این که وارد هسته اصلی نرون شود، وزن دار می‌شود. یعنی مقدار هر ورودی در $W_{i,m}$ ضرب می‌شود. سپس این مقادیر در بخش اول پردازشگر با هم جمع شده و مجموع کل ورودی به نرون، تعیین می‌شود.

شبکه استفاده شده برای پیش‌بینی تراز آب زیرزمینی، شبکه عصبی پیش‌خور چند لایه است که به آن شبکه پرسپترون چند لایه (MLP)^۱ هم می‌گویند. معمولاً از قانون یادگیری پسانشار خطای (BPE) برای آموزش این شبکه استفاده می‌شود. به عبارتی، توپولوژی^۲ شبکه‌های پرسپترون چند لایه با قانون پسانشار خطای تکمیل می‌شوند. ساختار شبکه، که می‌توان آن را تحت عنوان معماری شبکه مطرح کرد، بر اساس نوع شبکه، توابع یادگیری و تعداد لایه‌ها همراه با تعداد نرون‌ها مشخص می‌شود. در واقع، این معماری شبکه است که نحوه جریان داده‌های ورودی را برای رسیدن به خروجی مطلوب تعیین می‌کند. بر این اساس از شبکه عصبی پیش‌خور چند لایه برای ساختار مدل و از الگوریتم پسانشار خطای برای بهنگام‌سازی استفاده شد. در این شبکه ازتابع Train LM به عنوان تابع یادگیری برای پسانشار خطای استفاده شد. در مدل شبکه عصبی، داده‌ها به سه قسمت آموزش، اعتبارسنجی و آزمون تقسیم شده‌اند. روند آموزش شبکه تا زمانی که خطای مربع متوسط (MSE)^۳ در مراحل آموزش، اعتبار سنجی و آزمون حداقل گردد، ادامه می‌یابد.



شکل ۳- نمودار تراز آب زیرزمینی پیزومتر ۲

با دقت در سری زمانی چاهها مشاهده می‌شود که هر دو پیزومتر دارای سیر نزولی هستند. به گونه‌ای که پیزومتر ۱ در حدود ۱۵ سال، نزدیک به ۱۵ متر افت تراز داشته است. همچنین در پیزومتر ۲ شاهد نوسانات بیشتری نسبت به پیزومتر ۱ هستیم که در حدود ۱۵ سال، نزدیک به ۸ متر افت تراز مشاهده می‌گردد. طبق گزارش کارشناسان دفتر مطالعات پایه منابع آب شرکت آب منطقه‌ای قم، روند افت سطح ایستابی در نیمه شمالی دشت بیشتر از سایر مناطق است که این امر ناشی از برداشت بیش از حد توان آبخوان در قسمت‌هایی که چاههای بهره‌برداری وجود دارند می‌باشد. با توجه به قرار گرفتن پیزومتر ۱ در نیمه شمالی دشت، شاید به همین دلیل است که افت بیشتری را در این پیزومتر شاهد هستیم.

۲-۲- تحلیل رگرسیون خطی چندمتغیره (MLR)

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

$$y = a_0 + \sum a_i x_i \quad (2)$$

a_i : ضریب متغیرهای مستقل، x_i : مقادیر مشاهده‌ای، a_0 : عرض از مبدأ، y : مقادیر پیش‌بینی شده

۳-۲- مبانی شبکه‌های عصبی مصنوعی (ANN)

شبکه عصبی ترکیبی از بهره‌برداری موازی از المان‌های ساده می‌باشد که از سیستم عصبی الهام گرفته شده است. یک شبکه نمونه از لایه ورودی، لایه میانی (مخفي) و لایه خروجی تشکیل شده است. شمار لایه‌های مخفی و شمار گره‌ها در هر لایه مخفی به طور معمول به وسیله روش آزمون و خطای مشخص می‌شود. گره‌ها در هر لایه با لایه‌های مجاور در یک شبکه به طور کامل در

$$CWT(scale, position) = \int_{-\infty}^{+\infty} f(t)\psi(t)(scale, position)dt \quad (3)$$

یا:

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

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 اعداد حقیقی هستند و s همیشه مثبت است که ممکن است مقادیر پیوسته یا گسسته به خود بگیرد. s و τ در تبدیل موجکی پیوسته دارای مقادیر پیوسته و در تبدیل گسسته دارای مقادیر گسسته هستند. $(t)\psi$ تابع موجک مادر است. عبارت مادر به این دلیل به کار رفته که توابع مختلف به وجود آمده براساس پارامترهای مقیاس و انتقال، همگی از توابع پایه (موجک مادر) ناشی می‌شوند [۲۰]. 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:

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

مقیاس به طور ساده به معنای کشیده شدن یا فشرده شدن موجک می‌باشد و میزان کشش یا مدت زمان موجک را بیان می‌کند. انتقال موجک به طور ساده به مفهوم به تأخیر انداختن یا جلو انداختن موجک و بیان کننده موقعیت موجک روی محور زمان است. تبدیل گسسته موجکی جهت پردازش و تحلیل سری‌های زمانی، بهتر از تبدیل پیوسته موجکی می‌باشد، زیرا داده‌های تبدیل یافته با DWT اجزای اضافی نداشته و بنابراین تبدیل معکوس را می‌توان برای هر دسته از داده‌های زمان-بسامد به کار برد. فرایند تجزیه سیگنال شامل یک یا چند مرحله است که در تجزیه چند مرحله‌ای موج، پس از اولین مرحله تفکیک با تجزیه مجدد قسمت تقریبی، تجزیه موج ادامه می‌یابد. Symlet، Haar، Daubechies از انواع موجک‌های مادر به Mexican Hat، Coiflet، Meyer، Morlet کرد [۲۰]. تحلیل موجک یک روش بسیار جدید در زمینه‌های هیدرولوژی و پژوهش منابع آب است. با استفاده از تحلیل

بر اساس نوع حافظه، شبکه‌های عصبی به دو گروه شبکه‌های عصبی استاتیکی (بدون حافظه) و شبکه‌های عصبی دینامیکی (با حافظه) تقسیم می‌شوند:

الف) شبکه‌های عصبی استاتیکی: در ساختار این نوع شبکه‌ها زمان و پویایی وجود ندارد. خروجی این نوع شبکه‌ها در هر لحظه، تنها به ورودی آن‌ها در همان لحظه بستگی دارد.

ب) شبکه‌های عصبی دینامیکی: شبکه‌های استاتیکی با وجود کارآبی فراوان در حل مسائل مختلف نمی‌توانند فرآیندهای پویا و متغیر با زمان را مدل‌سازی کنند. در این گونه مسائل می‌توان از شبکه‌های دینامیکی یا پویا استفاده کرد. پارامترهای ورودی و خروجی این شبکه‌ها مشابه شبکه‌های استاتیکی است، با این تفاوت که در فرآیند آموزش مدل‌های پویا، مقادیر خروجی به صورت برگشتی و به عنوان ورودی به سیستم برمی‌گردند. شبکه‌های عصبی بازگشتی (RNN)^۱ و شبکه‌های عصبی تأخیر زمانی (TDNN)^۲ از این دسته‌اند.

۴-۲- تبدیل موجک^۳ (WT)

طبق تعریف، موجک یک موج کوچک است که انرژی آن در ناحیه کوچکی متمرکز شده و ابزار مناسبی برای بررسی پدیده‌های گذرا است. موجک، دارای نوسان حداقلی بوده که به سمت صفر نزول می‌کند و این نزول باعثی در جهات مثبت و منفی واقع در دامنه‌اش محدود شود. این مشخصه باعث می‌شود که موجک انعطاف‌پذیر بوده و مانند یک تابع رفتار کند. یافته‌های سال‌های اخیر نشان داده‌اند که تبدیل‌های موجک برای تحلیل و بدون نویز کردن داده‌ها و سیله مناسبی هستند. موجک‌ها توابع ریاضی هستند که یک بیان زمان-مقیاس از سری‌های زمانی و نسبت‌های آن ارائه می‌دهند که این بیان برای تحلیل سری‌های زمانی غیر ایستا مفید است. مزیت تبدیل موجک، توانایی در به‌دست آوردن اطلاعات زمانی، مکانی و فرکانسی یک سیگنال است. با استفاده از این تبدیل می‌توان سیگنال اصلی را به سیگنال‌های پایه سازنده‌اش تجزیه کرد. دو نوع تبدیل موجکی وجود دارد: ۱- تبدیل موجکی پیوسته (CWT)^۴، ۲- تبدیل موجکی گسسته (DWT)^۵. تبدیل موجکی پیوسته با یکی از این روابط بیان می‌شود:

1- Recurrent Neural Networks

2- Time Delay Neural Networks

3- Wavelet Transform

4- Continues Wavelet Transform

5- Discrete Wavelet Transform

انجام شده و پس از خاتمه عملیات، مقادیر پیش‌بینی شده مجدداً به اشل واقعی بازگردانده می‌شوند.

$$x_{normalize} = \frac{x - x_{min}}{x_{max} - x_{min}} \times 2 - 1 \quad (8)$$

۳- نتایج و بحث

در این پژوهش جهت دستیابی به بهترین نتیجه، سه مدل شبکه عصبی مصنوعی، مدل رگرسیون خطی چند متغیره و مدل هیبرید موجک-شبکه عصبی مورد بررسی قرار گرفت. از سری زمانی تراز آب زیرزمینی ۱۵ سال و ۶ ماه دو حلقه چاه پیزومتری به عنوان ورودی شبکه عصبی استفاده شد.

۱-۳- نتایج مدل MLR

در مدل خطی، تحلیل رگرسیون خطی بین مقادیر تراز آب زیرزمینی ماه فعلی تا ۱۴ ماه قبل، با نرمافزار IBM SPSS Statistics 20 انجام شد و بهترین رابطه بین متغیر وابسته و متغیرهای مستقل به دست آمد. سپس به پیش-بینی ۱۹ ماهه تراز آب زیرزمینی براساس رابطه به دست آمده پرداخته شد. نتایج نشان دادند که مدل خطی قادر است تا دو ماه تأخیر برای هر دو پیزومتر، نتایج بهتری را ارائه نماید و برای تأخیرهای بیشتر نتایج غیر قابل قبول هستند. نتایج مدل خطی در جدول (۳) آمده است.

جدول ۳- نتایج مدل MLR

E	RMSE (m)	MLR بهترین رابطه	شماره پیزومتر
۰/۷۵	۰/۰۶۴۲	$y_i = -13.131 + 1.194y_{i-1} - 0.178y_{i-2}$	۱
۰/۳۴	۰/۱۹۹	$y_i = 3.267 + 1.09y_{i-1} - 0.094y_{i-2}$	۲

مشاهده می‌شود که مدل خطی نتیجه بهتری را برای پیزومتر ۱ ارائه نموده است. با توجه به این که تعداد داده‌های مورد استفاده در بخش مدل‌سازی برای هر دو پیزومتر یکسان است، شاید دلیل این موضوع را بتوان وجود نوسانات کمتر در این پیزومتر دانست.

موجک^۱، می‌توان سری زمانی مشاهده‌ای^۲ تراز آب زیرزمینی را به زیر سری‌های تقریب^۳ و جزئیات^۴ پایه سازنده‌اش تجزیه کرد. بر این اساس می‌توان سری‌های زمانی جدید حاصل از این تحلیل را به شکل‌های مختلف به عنوان ورودی‌های شبکه عصبی مورد استفاده قرار داد.

۴-۵-۲- ارزیابی دقیق مدل

به منظور ارزیابی نتایج شبکه عصبی، مدل هیبرید موجک-شبکه عصبی و رگرسیون خطی چند متغیره، از دو معیار ریشه خطای مربع متوسط (RMSE) و ضریب کارایی نش-ساتکلیف 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.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{io} - y_{ip})^2}{n}} \quad (6)$$

$$E = 1 - \frac{\sum_{i=1}^n (y_{io} - y_{ip})^2}{\sum_{i=1}^n (y_{io} - \bar{y}_{io})^2} \quad (7)$$

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

۶-۲- آماده‌سازی داده‌های ورودی

آماده‌سازی داده‌های ورودی به شبکه یکی از نکات مهم در استفاده از شبکه‌های عصبی می‌باشد. این پیش‌پردازش، شامل تبدیل داده‌ها از دامنه تغییرات واقعی خود به دامنه‌ای است که شبکه عصبی در آن دامنه کارایی بهتری دارد. بر مبنای نوعتابع فعال‌سازی مورد استفاده در شبکه، معمولاً دو نوع دامنه عددی ($[1,0]$ ، $[-1,1]$) بر ورودی‌ها اعمال می‌شود. 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 (۸) به بازه $[-1,1]$ تغییر داد. آموزش شبکه با این اطلاعات

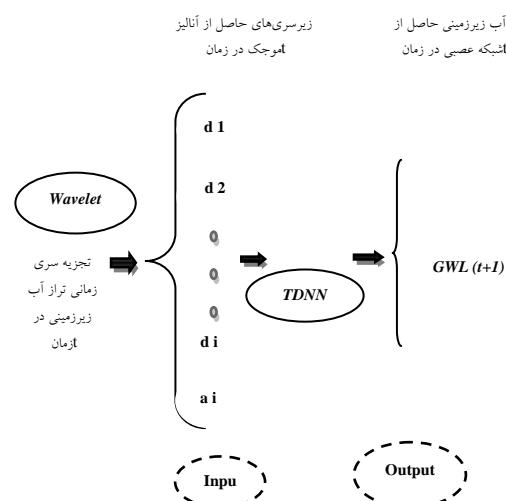
1- Wavelet Analysis

2- Observed Time Series

3- Approximation

4- Detail

سری زمانی اصلی به صورت تابعی از مقادیر گذشته زیرسری‌ها پیش‌بینی می‌شوند. تعداد تأخیر نیز با سعی و خطا مشخص می‌گردد. بر این اساس، زیرسری‌های تقریب و جزئیات تراز آب زیرزمینی حاصل از تحلیل موجکی، هم‌زمان به عنوان ورودی به شبکه داده شد. تعداد نورون‌های لایه اول وابسته به درجه تجزیه موجک، و برابر با $i+1$ است. که درجه تجزیه موجک می‌باشد. در این پژوهش تعداد نورون لایه خروجی ۱ است که همان سطح آب زیرزمینی در زمان $t+1$ می‌باشد. نکته‌ای که در انتخاب تعداد نورون‌های لایه مخفی مورد توجه قرار گرفته است، سادگی شبکه می‌باشد. به عبارتی از بین دو گزینه نسبتاً مشابه گزینه‌ای که تعداد نورون کمتری داشته انتخاب شده است. این امر در راستای اجتناب از پیچیدگی شبکه صورت گرفته است. از زیرسری‌های تقریب و جزئیات حاصل از تبدیل موجک گستته به عنوان ورودی شبکه عصبی استفاده شده و سیگنال اصلی به عنوان هدف شبکه در نظر گرفته شده است (شکل (۵)).



شکل ۵-معماری مدل ترکیبی W-TDNN

در بخش شبکه عصبی مدل ترکیبی نیز، از یک شبکه سه لایه پیش‌خور با الگوریتم LM استفاده شده است. سایر جزئیات همانند مدل NAR می‌باشد. در بحث مدل‌سازی سطح آب زیرزمینی، پارامترهای مختلفی از جمله بارندگی، پمپاز، تبخیر و تعرق، تغذیه به آبخوان، تخلیه از آبخوان، وزش باد، درجه حرارت و ... می‌توانند تأثیرگذار باشند. اما از آن جایی که تمام این عوامل به صورت مستتر در سری زمانی سطح آب زیرزمینی وجود دارند در نتیجه زمانی که سیگنال سطح آب زیرزمینی توسط تبدیل موجک به سیگنال‌های پایه سازنده‌اش تجزیه می‌شود، اثر تمام

۲-۳- نتایج مدل شبکه عصبی خود بازگشتی غیر خطی^۱ (NAR)

در مدل شبکه عصبی NAR، از داده‌های یک سری زمانی استفاده می‌گردد و مقادیر آینده سری زمانی به صورت تابعی از مقادیر گذشته همان سری زمانی پیش‌بینی می‌شوند. بر این اساس، سطح آب زیرزمینی با تأخیرهای^۲ مختلف (از ۱ تا ۱۴ ماه تأخیر) به عنوان ورودی و سیگنال تراز در گام زمانی $t+1$ به عنوان خروجی شبکه در نظر گرفته شده است. در نتیجه، تعداد نورون‌های لایه اول و لایه بیرونی، ۱ می‌باشد. برای انتخاب تعداد نورون‌های بهینه لایه مخفی از روش آزمون و خطا استفاده شده است. در تحقیق حاضر از یک شبکه سه لایه پیش‌خور با تابع فعال‌سازی سیگموئید^۳ در لایه مخفی و تابع فعال‌سازی خطی^۴ در لایه خروجی استفاده شده است. این شبکه‌ها در یک روش یادگیری باناظر^۵ و به وسیله الگوریتم پس‌انتشار خطا^۶ تربیت می‌شوند و بر این اساس، تصحیح خطا را انجام می‌دهند. در واقع، این معماری شبکه است که نحوه جریان داده‌های ورودی را برای رسیدن به خروجی مطلوب تعیین می‌کند. بر این اساس از شبکه عصبی پیش‌خور چند لایه برای ساختار مدل و از الگوریتم پس‌انتشار خطا برای بهره‌گیری از استفاده شد. در این شبکه از تابع لونبرگ - مارکوارت^۷ به عنوان تابع یادگیری برای پس‌انتشار خطا خطا استفاده شد. نتایج مدل شبکه عصبی در جدول (۴) ارائه شده‌اند.

جدول ۴- نتایج مدل شبکه عصبی NAR

شماره پیزومتر	ساختار شبکه	E	RMSE (m)
۱	۱-۵-۱	۰/۸۲	۰/۰۵۳۸
۲	۱-۶-۱	۰/۷	۰/۱۲۳۵

۳-۳- نتایج مدل پیشنهادی موجک- شبکه عصبی تأخیر زمانی^۸ (W-TDNN)

در مدل TDNN، از چندین سری زمانی در ورودی شبکه عصبی می‌توان استفاده کرد. به این ترتیب، از زیرسری‌های حاصل از تجزیه سری زمانی در ورودی شبکه و از داده‌های سری زمانی اصلی، در خروجی شبکه استفاده می‌شود، که مقادیر آینده

1- Nonlinear auto regressive

2- Delay

3- Sigmoid function

4- Linear function

5- Supervised learning

6- Error back-propagation algorithm

7- Levenberg-marquardt function

8- Wavelet-time delay neural networks

طبعیت، به راحتی قابل تشخیص نیستند. شاید عواملی نظیر رواناب‌های دیررس، بارش‌های فصلی و پمپاژ از چاههای کشاورزی که اثرشان روی عمق آب زیرزمینی با تأخیر چند ماهه همراه است، مؤثر بوده‌اند. تراز آب زیرزمینی به عوامل گوناگونی بستگی دارد. به نظر می‌رسد که مهم‌ترین عوامل تأثیرگذار در نوسانات ماهانه سطح آب زیرزمینی دشت شریف‌آباد، پمپاژ از چاههای کشاورزی (اثر کاهشی)، بارندگی، درجه حرارت، نفوذ به آبخوان در فصول بارندگی از طریق نزولات جوی‌ای که مستقیماً بر سطح دشت باریده یا در ارتفاعات (ذوب برف) رخ داده است، تغذیه آبخوان از دشت ساوه و حجم آب قابل برگشت ناشی از مصارف کشاورزی (اثر افزایشی) به آبخوان باشند که آمار دقیقی از آن‌ها در دست نیست. از طرفی تراز آب زیرزمینی ماه فعلی فقط با تراز آب زیرزمینی ماههای قبلی رابطه ندارد و عوامل بسیاری که دخیل هستند این رابطه را پیچیده می‌کنند. حتی اگر از همه عوامل، آمار موجود باشد، باز هم این رابطه قابل نوشتن به صورت یک رابطه ریاضی دقیق نیست. شاید تأثیر همین عوامل است که نتایج مدل هیبرید در سطح چهارم تجزیه حاصل شده است.

همچنین انتخاب مناسب تابع موجک، مسئله مهمی است و تا حد زیادی به مسئله مورد بررسی یعنی طبیعت رخداد پدیده و نوع سری زمانی آن وابسته است. به طور کلی برای سری‌های زمانی سطح آب زیرزمینی، الگوهایی از توابع موجک مادر، که به لحاظ شکل هندسی به خوبی بر منحنی سری‌های زمانی منطبق شوند، مناسب‌ترین تابع خواهد بود. سری زمانی تراز آب زیرزمینی بر خلاف پدیده‌هایی مثل بارش- رواناب، الزاماً ماهیت تک قله‌ای ندارند، بلکه اغلب دارای ویژگی نوسان پی‌درپی و روند کاهشی هستند. بنابر این الگوهایی از توابع موجک مادر که بتواند از نظر شکل هندسی به خوبی بر منحنی سری زمانی تراز آب زیرزمینی منطبق شوند، بهتر می‌توانند عمل نگاشت را انجام دهند و نتایج بهتری در برخواهند داشت.

مدل ترکیبی به این دلیل که از سیگنال‌های تجزیه شده به عنوان ورودی شبکه عصبی استفاده می‌کند، توانسته است خصوصیات غیر خطی و پیچیده تراز آب زیرزمینی را دقیق‌تر از مدل شبکه عصبی و خصوصاً مدل خطی MLR شبیه‌سازی کند. همچنین با توجه به نمودار سری زمانی تراز ماهانه پیزومترها می‌توان دریافت که میزان و شدت نوسانات تراز در ماههای مختلف، بر دقت مدل‌سازی‌ها تأثیرگذار است. نتایج ارزیابی مدل هیبرید برای چاههای پیزومتری دشت در جداول (۵) و (۶) آمده‌اند.

این عوامل در نظر گرفته می‌شود. به عبارت دیگر در تبدیل موجک، با برآش موجک مادر به سیگنال سطح آب زیرزمینی می‌توان تغییرات فصلی، تغییرات بلند مدت، 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 شده است.

باید توجه داشت که تعداد لایه‌های مخفی بیشتر و تعداد نورون بیشتر در لایه مخفی، اگر چه ممکن است دقت محاسبات در آموزش شبکه را بالا ببرند، اما الزاماً دقت مدل را افزایش نخواهد داد. در اجرای شبکه عصبی، برای دو حلقه چاه پیزومتری مشاهده شد که با تأخیر ۱۲ ماهه بهترین مقادیر E و RMSE حاصل گردید. در منطقه مورد مطالعه، پمپاژ از چاههای کشاورزی بیشترین تأثیر کاهشی را روی تراز آب زیرزمینی دارد چرا که ۹۰ درصد آب پمپاژ شده از ۱۳۵ حلقه چاه این دشت به مصرف کشاورزی می‌رسد و شاهد روند کاملاً نزولی در سری زمانی چاه‌ها هستیم. این موضوع از نمودار تراز آب زیرزمینی دو پیزومتر مطالعاتی (شکل‌های (۲) و (۳)) نیز تا حدودی مشهود است.

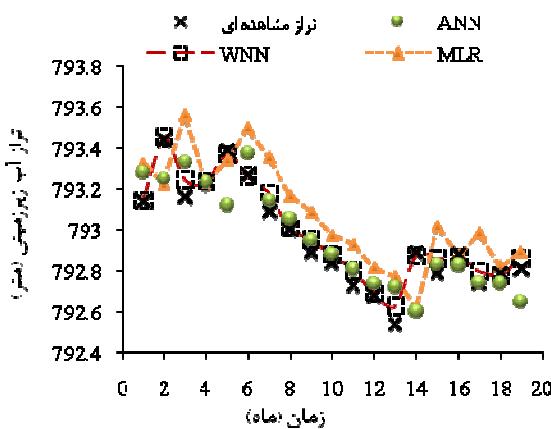
برای ساخت مدل ترکیبی موجک- شبکه عصبی ابتدا در بخش تحلیل موجک گستته^۱، کدنویسی به زبان نرم‌افزار MATLAB R2011b با درجات مختلف تجزیه (از ۱ تا ۵ db5 و db4، db3، db2، Meyer، Haar) سطح و موجک‌های سری زمانی سطح آب زیرزمینی به زیرسی‌های تقریب^۲ و جزئیات^۳ انجام شد. همچنین در ادامه، کدنویسی برای شبکه عصبی با تعداد نورون متغیر در لایه مخفی و تأخیر- های ماهانه متغیر (از ۱ تا ۱۴ ماه تأخیر)، اضافه شد که زیرسی‌های حاصل از هر موجک در سطوح مختلف به عنوان ورودی شبکه عصبی به طور همزمان به شبکه داده شد. خروجی مدل هیبرید، تراز آب زیرزمینی در زمان $t+1$ بوده است.

با ارزیابی نتایج، مشخص شد که تابع موجک Meyer با تأخیر ۴ ماه و در سطح چهارم تجزیه، برای هر دو پیزومتر نتایج بهتری را ارائه نموده است. با توجه به این که تأخیر ۴ ماهه بهترین نتیجه را برای پیزومترها داشته است، به نظر می‌رسد مدل هیبرید، ارتباط‌هایی را بین عمق آب زیرزمینی ماه فعلی با عمق آب زیرزمینی یک تا ۴ ماه قبلی آن‌ها یافته است. ارتباط‌هایی که به دلیل پیچیدگی این پدیده و به طور کلی

1- Discrete wavelet

2- Approximation

3- Detail



شکل ۷- مقایسه نتایج مدل‌ها در دوره آزمون برای پیزومتر ۲

طبق گزارش کارشناسان دفتر مطالعات پایه منابع آب شرکت آب منطقه‌ای استان قم، از آن جا که محدوده مطالعاتی شریف‌آباد تقریباً در انتهای حوضه دریاچه نمک قراردارد، لذا طبیعتاً انتظار می‌رود سطح آب در آن پایین نباشد. ولی به علت برداشت بی‌رویه و تعدد چاه‌های بهره‌برداری که غالباً با دی‌های زیاد و ساعات کارکرد طولانی فعال هستند، افت شدید تراز آب زیرزمینی را در منطقه شاهد هستیم. از طرفی با توجه به سری زمانی سه پیزومتر می‌توان مؤثرتر بودن اثر پمپاژ بی‌رویه را در این کاهش نسبت به سایر عوامل، محتمل دانست. پمپاژ‌های بیش از حد در منطقه مطالعاتی روی کیفیت آب نیز اثرگذار بوده و افزایش شوری آب منطقه را در پی داشته است.

مدل خطی MLR، رگرسیون خطی بین متغیرها را در نظر می‌گیرد. بنابر این این روش برای شبیه‌سازی خصوصیات غیر خطی و پیچیده تراز آب زیرزمینی مناسب نبوده و همان‌گونه که ملاحظه می‌شود، سری زمانی آب زیرزمینی چاه‌های پیزومتری MLR انتخابی دارای افت و خیز بسیار شدید نبودند اما مدل MLR نتوانست در مقایسه با دو مدل دیگر نتایج دقیق‌تری ارائه نماید. بدین ترتیب می‌توان دریافت امکان کارایی بهتر این مدل در سری‌هایی با نوسانات شدید سطح آب زیرزمینی یا تعداد داده‌های کمتر، احتمالاً ضعیف و غیر قابل قبول خواهد بود. در مقایسه با مدل‌های رگرسیونی، مدل‌های هوشمند دارای مزیت قابلیت تنظیم چندین پارامتر هستند و ترکیبات مختلفی را می‌توان به کار برد. هر چند به دلیل همین ویژگی، این مدل‌ها مستعد پدیده بیش‌برازش نیز هستند.

در مقایسه با پژوهش حاضر، Adamowski و همکاران [۱۵] به پیش‌بینی تراز ماهانه آب زیرزمینی در حوضه آبریز شاتوگای در کانادا با استفاده از داده‌های ۸۴ ماهه تراز آب زیرزمینی، دما و

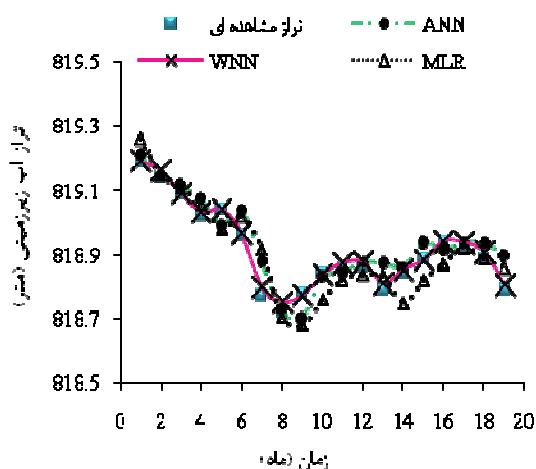
جدول ۵- بهترین نتایج مدل ترکیبی W-TDNN در پیزومتر ۱

E	RMSE (m)	ساختار ANN	i	موجک مادر
۰/۹۵	۰/۰۲۷۸	۳-۳-۱	۲	db2
۰/۹۱	۰/۰۳۶۴	۳-۷-۱	۲	db3
۰/۹۳	۰/۰۳۳۶	۳-۴-۱	۲	db4
۰/۹۳	۰/۰۳۲۴	۳-۴-۱	۲	db5
۰/۹۱	۰/۰۳۶۸	۳-۳-۱	۲	haar
۰/۹۸	۰/۰۱۵۷	۵-۳-۱	۴	Meyer

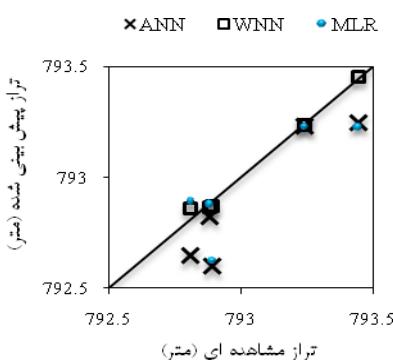
جدول ۶- بهترین نتایج مدل ترکیبی W-TDNN در پیزومتر ۲

E	RMSE (m)	ساختار ANN	i	موجک مادر
۰/۸۷	۰/۰۸۸۶	۴-۳-۱	۳	db2
۰/۸۵	۰/۰۹۳	۵-۷-۱	۴	db3
۰/۸۷	۰/۰۸۶۵	۳-۳-۱	۲	db4
۰/۹	۰/۰۷۵۵	۲-۴-۱	۱	db5
۰/۸۳	۰/۱۲۷۲	۳-۵-۱	۲	haar
۰/۹۴	۰/۰۴۸۳	۵-۶-۱	۴	Meyer

مقادیر تراز مشاهده‌ای برای دوره آزمون، با ترازهای پیش‌بینی شده سه مدل، در پیزومتر ۱ و ۲، مورد مقایسه قرار داده شد (شکل‌های (۶) و (۷)). همانگونه که در شکل مشاهده می‌شود، نتایج مدل هیبرید در هر دو پیزومتر، با مقادیر مشاهده‌ای تطابق بیشتری دارد.



شکل ۶- مقایسه نتایج مدل‌ها در دوره آزمون برای پیزومتر ۱



شکل ۹- پیش‌بینی نقاط بیشینه در پیزومتر ۲

جدول ۸- نتایج مدل‌ها در پیش‌بینی نقاط بیشینه در پیزومتر ۲

WNN (m)	MLR (m)	ANN (m)	- تراز مشاهده- ای (m)	ردیف
۷۹۳/۴۵	۷۹۳/۲۲۵	۷۹۳/۲۴۵	۷۹۳/۴۴	۱
۷۹۳/۲۳	۷۹۳/۲۲۸	۷۹۳/۲۳	۷۹۳/۲۴	۲
۷۹۲/۸۷	۷۹۲/۶۲۴	۷۹۲/۵۹۸	۷۹۲/۸۹	۳
۷۹۲/۸۶	۷۹۲/۸۷	۷۹۲/۸۲۳	۷۹۲/۸۸	۴
۰/۰۲۶	۰/۱۵۷	۰/۱۷۵		RMSE (m)
۰/۹۸۸	۰/۵۸	۰/۵		E

۴- نتیجه‌گیری

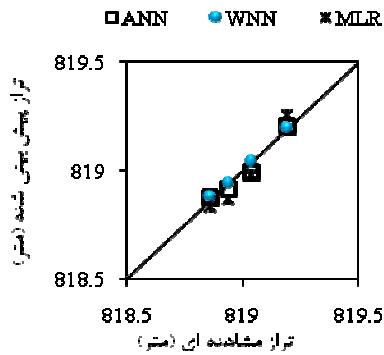
در این پژوهش یک روش جدید مبتنی بر ترکیب تحلیل موجک و شبکه عصبی در پیش‌بینی تراز آب زیرزمینی پیشنهاد گردید. توانایی مدل هیبرید شبکه عصبی و موجک، به عنوان یک ابزار سودمند و البته نسبتاً جدید در مدیریت منابع آب برای پیش‌بینی نوسانات سطح آب زیرزمینی در دشت شریف‌آباد در مقایسه با دو مدل شبکه عصبی و مدل خطی خوب‌بازگشتی چند متغیره، مورد ارزیابی قرار گرفت.

داده‌های ورودی به مدل شبکه عصبی خود بازگشتی غیر خطی، شامل سری زمانی سطح آب زیرزمینی و در مدل ترکیبی موجک-شبکه عصبی تأخیر زمانی، شامل زیرسی‌های تراز آب زیرزمینی حاصل از تبدیل موجک بوده است. بر اساس محاسبه دو معیار E و RMSE، مشخص شد که مدل ترکیبی WNN، با موجک Meyer در سطح چهارم تجزیه، با دقت بالاتری نسبت به دو مدل دیگر قادر به پیش‌بینی ۱۹ ماهه تراز آب زیرزمینی دوره آزمون و نقاط بیشینه در هر دو پیزومتر می‌باشد. ارزیابی نتایج نشان داده است که تحلیل موجکی توانسته است نتایج مدل شبکه عصبی را تا حد قابل ملاحظه‌ای بهبود بخشد؛ به گونه‌ای

بارش پرداختند. آن‌ها از مدل ترکیبی WNN استفاده نمودند. به گونه‌ای که از مجموع زیرسی‌های تقریب حاصل از تجزیه سه سری زمانی تا دو سطح تجزیه، در ورودی شبکه و از سری زمانی تراز در لایه خروجی استفاده کردند. همچنین مدت تأخیر را بین ۱ تا ۴ ماه مورد آزمون و خطای قراردادن که برای تأخیر ۲ ماهه و تعداد ۲ نورون در لایه مخفی به عدد ۰/۹۷ برای ضریب کارایی نش در پیش‌بینی ۸ ماهه دوره آزمون دست یافتند.

۴-۴- ارزیابی نتایج مدل‌ها در پیش‌بینی نقاط بیشینه

از ویژگی‌های یک مدل هیدرولوژیکی خوب، توانایی آن در برآورد و شبیه‌سازی نقاط بیشینه و کمینه می‌باشد. زیرا طراحی-ها معمولاً بر اساس این نقاط انجام می‌شود. در جداول (۷) و (۸)، مقادیر مشاهده‌ای و محاسباتی نقاط بیشینه دوره آزمون، در هر دو پیزومتر نشان داده شده‌اند. نتایج ارزیابی سه مدل در پیش‌بینی نقاط بیشینه برای هر دو پیزومتر در جدول (۹) قابل مشاهده است. بدین ترتیب مدل هیبرید توانسته است با دقت بالایی نقاط اوج سری زمانی را پیش‌بینی نماید (شکل‌های (۸) و (۹)).



شکل ۸- پیش‌بینی نقاط بیشینه در پیزومتر ۱

جدول ۷- نتایج مدل‌ها در پیش‌بینی نقاط بیشینه در پیزومتر ۱

WNN (m)	MLR (m)	ANN (m)	- تراز مشاهده- ای (m)	ردیف
۸۱۹/۱۹۴	۸۱۹/۲۶	۸۱۹/۲۰۵	۸۱۹/۱۹	۱
۸۱۹/۰۴	۸۱۸/۹۸	۸۱۸/۹۹	۸۱۹/۰۴	۲
۸۱۸/۸۷۸	۸۱۸/۸۳۴	۸۱۸/۸۷۶	۸۱۸/۸۶	۳
۸۱۸/۹۴	۸۱۸/۸۷	۸۱۸/۹۱۵	۸۱۸/۹۴	۴
۰/۰۰۹	۰/۰۴	۰/۰۳		RMSE (m)
۰/۹۹۴	۰/۱۸۵	۰/۹۴		E

- [5] Mohanty, S., Jha, M., Kumar, A., Panda, D. K., "Comparative Evaluation of Numerical Model and Artificial Neural Network for Simulating Groundwater Flow in Kathajodi-Suru Inter-basin of Odisha, India", *Journal of Hydrology*, 2013, 495, 38-51.
- [6] Rajaei, T., Mirbagheri, S. A., "Suspended Sediment Modeling in Rivers Using Artificial Neural Networks", *Journal of Civil Engineering*, 2009, 21 (1), 23-47.
- [7] Fallah-Mehdipour, E., Bozorg Haddad, O., Marin, M. A., "Prediction and Simulation of Monthly Groundwater Levels by Genetic Programming", *Journal of Hydro-Environment Research*, 2013, 1-8.
- [8] Nikmanesh, M., Rakhshanderoo, Gh., "Forecasting Groundwater Level In Saadat-Shahr Plain, Iran, Using Artificial Neural Networks", *Journal of Iran-Water Resources Research*, 2011, 7 (1), 82-86.
- [9] Mohtasham, M., Dehghani, A. A., Akbarpur, A., Meftah, M., Etebari, B., "Groundwater Level Determination by Using Artificial Neural Network (Case study: Birjand Aquifer)", *Iranian Journal of Irrigation and Drainage*, 2010, 4 (1), 1-10.
- [10] Mokhtari, Z., Nazemi, A. H., Nadiri, A. A., "Predicting Groundwater Level using Artificial Neural Network Model (Case Study: SHABESTAR Aquifer)", *Quarterly of Applied Geology*, 2012, 4, 345-353.
- [11] Rajaei, T., Nourani, V., Zounemat-Kermani, M., Kisi, O., "River Suspended Sediment Load Prediction: Application of ANN and Wavelet Conjunction Model" *Journal of Hydrologic Engineering*, 2011, 16 (8), 613-627.
- [12] Wang, Y., XiaohuiLei, H., XinshanSong, Y., "Flood Simulation using Parallel Genetic Algorithm Integrated Wavelet Neural Networks", *Neurocomputing*, 2011, 74, 2734-2744.
- [13] Nourani, V., Kisi, O., Komasi, M., "Two Hybrid Artificial Intelligence Approaches for Modeling Rainfall-Runoff Process", *Journal of Hydrology*, 2011, 402, 41-59.
- [14] Rajaei, T., "Wavelet and ANN Combination Model for Prediction of Daily Suspended Sediment Load in Rivers", *Science of The Total Environmental*, 2011, 409, 2917-2928.
- [15] Adamowski, J., Chan, H. F., "A Wavelet Neural Network Conjunction Model for Groundwater Level Forecasting", *Journal of Hydrology*, 2011, 407, 28-40.

که ضریب کارایی نش در پیزومترهای ۱ و ۲ به ترتیب ۰/۹۸ و ۰/۹۴ بوده است. در بررسی نتایج مدل MLR، اگرچه مدل خطی نتایج نسبتاً قابل قبولی در مورد پیش‌بینی نقاط بیشینه هر دو پیزومتر اختیاری ارائه نموده است، اما با توجه به این که تعداد داده‌های آماری این دو پیزومتر ۱۸۶ ماه بوده است و نوسانات ناگهانی و شدید نداشته‌اند نمی‌توان برای سری‌های زمانی با داده‌های کمتر و نوسانات شدیدتر، نتایج قابل قبولی را از این مدل انتظار داشت. با توجه به جدید بودن کاربرد مدل هیبرید مذکور در مدیریت منابع آب، توصیه می‌شود که این مدل، مورد آزمون‌های مختلف قرار گرفته و کاربرد آن در سایر شاخه‌های مدیریت منابع آب، برای مثال در پیش‌بینی روند شوری دشت‌ها، دبی پیک، برآورد رسوب مخازن و غیره نیز بررسی گردد. همچنین با توجه به اهمیت نوع تابع موجک در پیش‌بینی نوسانات سطح آب زیرزمینی در پژوهش‌های آتی می‌توان از توابع موجک دیگر نیز در پیش‌بینی استفاده کرد. استفاده از منطق فازی برای بررسی تأثیر آن بر نتایج مدل هیبرید موجک- شبکه عصبی در پیش-بینی نوسانات سطح آب زیرزمینی و استفاده از ترکیب‌های بهینه زیرسربی‌های تقریب و جزئیات سری زمانی تراز آب زیرزمینی در ورودی شبکه عصبی نیز توصیه می‌گردد.

- مراجع

- [1] Yang, Z. P., Lu, W. X., Long, Y. Q., Li, P. "Application and Comparison of Two Prediction Models for Groundwater Levels: A Case Study in Western Jilin Province, China", *Journal of Arid Environments*, 2009, 73, 487-492.
- [2] Banerjee, P., Singh, V. S., Chattopadhyay, K., Chandra, P. C., Singh, B., "Artificial Neural Network Model as a Potential Alternative for Groundwater Salinity Forecasting", *Journal of Hydrology*, 2011, 398, 212-220.
- [3] Hwa Cho, K., Sthiannopkao, S., A. Pachepsky, Y., Kim, K. W., Ha Kim, J., "Prediction of Contamination Potential of Groundwater Arsenic in Cambodia, Laos, and Thailand using artificial neural network", *Water Research*, 2011, 45, 5535-5544.
- [4] Taormina, R., Chau, K. W., Sethi, R., "Artificial Neural Network Simulation of Hourly Groundwater Levels in a Coastal Aquifer System of the Venice Lagoon", *Engineering Applications of Artificial Intelligence*, 2012, 25, 1670-1676.

- [19] Nayak, P. C., Venkatesh, B., Krishna, B., Jain, S. K., "Rainfall-Runoff Modeling using Conceptual, Data Driven, and Wavelet Based Computing Approach", Journal of Hydrology, 2013, 493, 57-67.
- [20] Polikar, R., "Fundamental Concepts and Overview of the Wavelet Theory", 2nd Edition, 1996.
- [16] Rajaee, T., Mirbagheri, S. A., Nourani, V., Alikhani, A., "Prediction of Daily Suspended Sediment Load Using Wavelet and Neuro-Fuzzy Combined Model", International Journal of Environmental Science and Technology, 2010, 7 (1), 93-110.
- [17] Nakhaee, M., Saberi Nasr, A., "Predicting Groundwater Level Fluctuations of GHARVE Aquifer using Wavelet-Neural Network and comparing with MODFLOW Numerical Model", Journal of Developed Applied Geology, 2012, 1 (4), 47-58,
- [18] Fathi, B., "Prediction of Groundwater Level Fluctuations using combined models Wavelet -Adaptive Fuzzy-Neural Network and Wavelet-Neural Network and Linear Model", MSc Thesis Sharif University of Technology 2012.

EXTENDED ABSTRACT

Modeling of Groundwater Level using ANN–Wavelet Hybrid Model (Case Study: Sharif Abad Plain)

Taher Rajaee*, Akram Zeynivand

Department of Civil Engineering, University of Qom, Qom, Iran

Received: 09 April 2014; **Accepted:** 20 October 2014

Keywords:

Sharif Abad plain, Groundwater level, Artificial neural network, Wavelet transform, Multiple linear regression

1. Introduction

Groundwater resources are one of the main sources of water supply. In recent years, the natural balance between fresh and saline water due to over-exploitation has been deteriorated and groundwater levels GLs in many parts of the country aquifers have turned negative. Evaluation and prediction of groundwater levels through specific models helps in forecasting of groundwater resources. In recent years, artificial neural networks (ANNs) have been used for GL prediction, aquifer parameter determination and groundwater quality monitoring. An important feature of ANN models is their ability to detect patterns in a complex system. Yang et al. [1] evaluated the potential of a BPANN and an Integrated Time Series (ITS) model based on the modern statistical models and techniques for the purpose of predicting the GL in an arid and semi-arid region of China. However, ANNs and other linear and non-linear methods frequently used have limitations with non-stationary data. ANN models cannot handle non-stationary data without input data pre-processing. The methods for dealing with non-stationary data are not as advanced as those for stationary data and additional research is needed to investigate methods that are better able to handle non-stationary data effectively. An example of such a method is wavelet analysis. Wavelet analysis can be used to decompose an observed time series (such as GL) into various components so that the new time series can be used as inputs for an ANN model. In this research, WA-ANN models were developed and compared with ANN and MLR models for forecasting GL at two tubes observed wells in the Sharif Abad watershed in Qom, Iran. In this paper, a new method based on coupling discrete wavelet transforms (WA) and ANN for GL forecasting is proposed. The relative performance of the proposed coupled wavelet-ANN models was compared to regular ANN models and Multiple Linear Regression (MLR) models for monthly GL forecasting. The comparison of the prediction accuracies of the WA-ANN and other models indicated that the proposed WA-ANN model could predict GL time series because of using multi-scale time series data as the ANN input layer.

2. Methodology

2.1. Case study and data

The Sharif Abad watershed is located in the Province of Qom, between the UTM coordinates, Y: 3850000 and X: 525000, Y: 3830000 and X: 485000, which is limited from the North and East to the Masile Plain, from the south to the Qom Plain and from the West to the Save Plain. The variable used to develop and validate the models was monthly groundwater level data recorded at two sites in the Sharif Abad watershed in Qom, Iran.

2.2. Multiple linear regression analysis

Multiple linear regression is a technique to model a linear relationship between a dependent variable and one or more independent variables, which is defined as:

* Corresponding Author

E-mail addresses: trajaee@qom.ac.ir (Taher Rajaee), a_zeynivand@yahoo.com (Akram Zeynivand).

$$y = a_0 + \sum a_i x_i \quad (1)$$

2.3. Artificial neural networks

ANN is a computing tool constructed through many simple interconnected elements called neurons with unique capability of recognizing underlying relationship with input and output events (Fig. 1). An ANN is arranged into discrete layers, consisting of input, hidden, and output. The ANN employed in this paper, namely the multilayer perception, usually referred to as the feed-forward neural network (FFNN) with back-propagation (BP) algorithm. This ANN type can map input real valued vectors into an output of real valued vectors. The process of calibrating the ANN inputs and outputs was carried out with the BP algorithm. The Levenberg-Marquardt algorithm was employed to train the ANN models.

2.4. Wavelet transform

Wavelet transforms have recently begun to be explored as a tool for the analysis, de-noising and compression of signals and images. Wavelets are mathematical functions that give a time-scale representation of a time series and their relationships to analyze time series that contain non-stationary. The main advantage of wavelet transforms are their ability to simultaneously obtain information on the time, location and frequency of a signal. The discrete wavelet transform (DWT) was used to decompose the time series data for the WA-ANN models developed in this study [2].

2.5. Hybrid model of wavelet-ANN (WA-ANN)

WA-ANN models are ANN models that use, as inputs, sub-series components (DWs), which are derived from the DWTs of the original time series data. One of the advantages of the WA-ANN method compared to the ANN method is its ability to identify data components in a time series such as irregular components with multi-level wavelet decomposition. The A three-layer FFNN-LM, which contains one input layer, one hidden layer with sigmoid activation function, and one output layer linear activation function, was applied in this study.

2.6. Evaluation of model accuracy

The performance of different forecasting models can be assessed in terms of goodness of fit once each of the model structures is calibrated using the testing data set. The Nash–Sutcliffe Coefficient Efficiency (CE) and root-mean-squared error (RMSE) were used in this research.

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

$$E = 1 - \frac{\sum_{i=1}^n (y_{io} - y_{ip})^2}{\sum_{i=1}^n (y_{io} - \bar{y}_{io})^2} \quad (3)$$

3. Results and discussion

The ANN models for groundwater level forecasting were developed using the MATLAB R2011b software program. The regular ANN models with regular input data (i.e., those not using wavelet decomposed input data) consisted of an input layer, one single hidden layer, and one output layer consisting of one node denoting the targeted monthly groundwater level. The ANN models were trained and tested based on different numbers of neurons in the hidden layer and Delays. The number of neurons in the hidden layer and delays were optimized using the available data through the use of a trial-and-error procedure. For the three models, the data series were divided into a training set, validation set, and a testing set. In this study we used of different of wavelets and decomposition levels In order to select of the optimum WA-ANN model. In hybrid model, the original data (monthly groundwater level) was decomposed into a series of approximation and details. In the linear model, linear regression analysis was

computed between the values of the current month to 14 months before of the groundwater levels. Results of the three models are presented in Tables 1 and 2.

Table 1. Evaluation of the best WA-ANN models at Peiezometer 1

Mother wavelet type	ANN structure	RMSE (m)	Decomposition level	E
Db2	3-3-1	0.0278	2	0.95
Db3	3-7-1	0.0364	2	0.91
Db4	3-4-1	0.0336	2	0.93
Db5	3-4-1	0.0324	2	0.93
Haar	3-3-1	0.0368	4	0.91
Meyer	5-3-1	0.0157	2	0.98

Table 2. Evaluation of the best WA-ANN models at Peiezometer 2

Mother wavelet type	ANN structure	RMSE (m)	Decomposition level	E
Db2	4-3-1	0.0886	3	0.87
Db3	5-7-1	0.093	4	0.85
Db4	3-3-1	0.0865	2	0.87
Db5	2-4-1	0.0755	1	0.9
Haar	3-5-1	0.1272	2	0.83
Meyer	5-6-1	0.0483	4	0.94

4. Conclusions

Wavelet analysis is a very new method in the areas of hydrology and water resources research. However, over the course of the last 5–6 years, it has begun to be investigated in a variety of hydrological applications. In this paper we evaluated the potential of a WA-ANN, ANN and MLR models for the purpose of predicting the GL in Sharif Abad Plain. In this research, a new method based on combining discrete wavelet transforms (WA) and ANN for GL forecasting applications was proposed. The WA-ANN models were compared to regular ANN models and MLR models for GL forecasting. This study found that the best WA-ANN model was substantially more accurate than the best ANN model and the best MLR model. It is hypothesized that the WA-ANN models are more accurate because wavelet transforms provide useful decompositions of the original time series, and the wavelet-transformed data improves the performance of the ANN forecasting model by analyzing useful information on various decomposition levels. The accurate forecasting results for the Sharif Abad watershed indicate that the WA-ANN model is a potentially very useful new method for GL forecasting. Highly accurate GL forecasting models such as the WA-ANN model that was developed in this study are a useful tool in sustainable groundwater extraction and optimized management in a watershed. It is recommended that future studies should explore the use of the WA-ANN method in GL forecasting for: other watersheds in different geographical regions; other lead times (such as daily, weekly, or yearly forecasting); comparing the wave neural network model with other new methods such as Adaptive Neural-Fuzzy Inference System.

5. References

- [1] Yang, Z. P., Lu, W. X., Long, Y. Q., Li, P, "Application and Comparison of Two Prediction Models for Groundwater Levels: A Case Study in Western Jilin Province, China", Journal of Arid Environments, 2009, 73, 487-492.
- [2] Polikar, R., "Fundamental Concepts and Overview of the Wavelet Theory", 2nd Edition, 1996.