



## مدیریت آب و آبیاری

دوره ۴ ■ شماره ۱ ■ بهار و تابستان ۱۳۹۳

صفحه‌های ۸۷-۷۳

# مدلسازی نوسان‌های ماهانه آب زیرزمینی به وسیله تبدیل موجک و شبکه عصبی پویا

طاہر رجایی\*، هادی ابراهیمی<sup>۲</sup>

۱. استادیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه قم، قم، ایران

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

تاریخ پذیرش مقاله: ۱۳۹۲/۱۲/۰۷

تاریخ وصول مقاله: ۱۳۹۲/۰۷/۰۶

### چکیده

مدلسازی نوسان‌های زمانی آب زیرزمینی، در مدیریت حوزه‌های آبریز و ایجاد تعادل در عرضه و تقاضای آب اهمیت زیادی دارد. در سال‌های اخیر استفاده از تحلیل موجک برای تجزیه سری‌های زمانی و ترکیب آن با شبکه‌های عصبی به صورت گسترده‌ای در مدلسازی پدیده‌های هیدرولوژیکی به کار رفته است. در این تحقیق، توانایی مدل ترکیبی موجک- شبکه عصبی پویا برای پیش‌بینی یک ماه آینده عمق آب زیرزمینی ارزیابی شده و این مدل با مدل‌های شبکه عصبی و رگرسیون خطی چندمتغیره مقایسه شده است. داده‌های استفاده‌شده برای تشکیل مدل‌ها فقط عمق آب زیرزمینی ماهانه است که در دو پیژومتر واقع در دشت قم به مدت ده سال اندازه‌گیری شده است. نتایج نشان داد عملکرد مدل شبکه عصبی چندان رضایت‌بخش نیست. مدل رگرسیون خطی چندمتغیره نیز نتایج دقیقی نداشت و مقدار پیش‌بینی شده با این مدل در اکثر موارد بیشتر از مقدار واقعی بود، درحالی‌که مدل ترکیبی موجک- شبکه عصبی با استفاده از موجک مادر Meyer با دو سطح تجزیه، توانست یک ماه آینده را با ضریب‌های نش  $0.974$  و  $0.993$  به ترتیب برای پیژومترهای ۱ و ۲ پیش‌بینی کند.

**کلیدواژه‌ها:** پیش‌بینی، دشت قم، رگرسیون خطی چندمتغیره، سری زمانی، عمق آب زیرزمینی.

## مقدمه

شبیه‌سازی و پیش‌بینی وضعیت آینده سطح آب زیرزمینی، عاملی مهم در مدیریت و بهره‌برداری از این منابع است. آب‌های زیرزمینی تا کنون با روش‌های مختلفی مدل‌سازی شده‌اند. اگرچه مدل‌های ریاضی و فیزیکی، ابزار اصلی بررسی و شناخت فرایندهای فیزیکی حاکم بر یک سیستم هستند، نبود اطلاعات و داده‌های مورد نیاز این مدل‌ها، آنها را با محدودیت کاربرد روبه‌رو کرده است. این مسئله سبب روی آوردن به مدل‌های آماری یا هوشمند به‌عنوان جایگزین مدل‌های ریاضی و فیزیکی شده است [۱].

مدل‌های شبکه عصبی برای پیش‌بینی عمق آب زیرزمینی به‌صورت گسترده‌ای به‌کار برده شده‌اند. از نمونه تحقیقات داخلی در این زمینه می‌توان به پیش‌بینی تراز آب زیرزمینی ۱۶ پیژومتر واقع در دشت بیرجند اشاره کرد. ورودی این مدل شامل مقدار برداشت از چاه‌ها، مقدار آب ورودی به دشت و تراز آب زیرزمینی در گام قبل و خروجی آن، تراز آب زیرزمینی در گام فعلی بود. پیش‌بینی ۱۲ ماهه با این مدل در مقایسه با مقادیر مشاهده‌شده مناسب بود [۴]. در تحقیق دیگری، برای پیش‌بینی تراز آب زیرزمینی آبخوان محدوده سعادت‌شهر فارس، از شبکه عصبی با پنج ورودی دما، بارندگی، رواناب سطحی ورودی، رواناب سطحی خروجی و هیدروگراف واحد آب زیرزمینی استفاده شد و در نهایت پیش‌بینی دوساله‌ای با مقایسه مقادیر مشاهده‌شده و مدل‌شده انجام گرفت [۷]. در تحقیقی دیگر، برای پیش‌بینی تراز آب زیرزمینی دشت میداوود- دالون استان خوزستان از شبکه عصبی با هشت ورودی دبی، بارش، رطوبت نسبی، تبخیر، ماکزیمم دمای ماهانه، مینیمم دمای ماهانه و سطح آب دو چاه مشاهده‌ای اطراف چاه مورد نظر استفاده شد. در این تحقیق نیز تراز

آب مدل‌شده با تراز آب مشاهده‌شده مقایسه شد [۳]. در سه تحقیق یادشده، نتایج مدل شبکه عصبی با نتایج مدل‌های مرسوم دیگر مقایسه نشده است که این ممکن است از کاستی‌های این تحقیقات باشد.

شبکه‌های عصبی به محدودیت‌هایی در زمینه کار با داده‌های غیرایستا<sup>۱</sup> (داده‌های با خصوصیات آماری متغیر در طول زمان) دچارند. در علم هیدرولوژی، داده‌ها معمولاً غیرایستا هستند [۲]. داده‌های غیرایستا ممکن است ترکیبی از چند داده ایستا باشند. با استفاده از تبدیل‌های موجک می‌توان سری‌های زمانی غیرایستا را به چند سری زمانی ایستا تجزیه کرد و از این سری‌های جدید (با خصوصیات ثابت در طول زمان) به‌عنوان ورودی شبکه عصبی بهره گرفت [۱۵، ۱۶].

تحقیق در مورد ترکیب آنالیز موجک با شبکه عصبی به سال‌های اخیر برمی‌گردد. از اولین تحقیقات انجام‌یافته، استفاده از مدل ترکیبی شبکه عصبی و موجک برای پیش‌بینی بار رسوب معلق رودخانه بود؛ به این صورت که سری زمانی دبی روزانه و سری زمانی بار معلق روزانه رودخانه یادکین<sup>۲</sup> واقع در ایالات متحده، به‌وسیله تبدیل‌های موجک با سطوح مختلف تجزیه شدند و زیرسری‌ها برای شبیه‌سازی بار رسوب معلق، به شبکه عصبی اعمال شدند. برای بررسی صحت این مدل، نتایج آن با نتایج مدل‌های شبکه عصبی، رگرسیون خطی چندمتغیره و منحنی سنجه رسوب مقایسه شد. مقایسه نشان از دقت‌تر بودن مدل ترکیبی شبکه عصبی و موجک نسبت به مدل‌های دیگر داشت [۱۴].

در زمینه آب‌های زیرزمینی، از مدل شبکه عصبی

1. Nonstationary data  
2. Yadkin river

## مواد و روش‌ها

### منطقه تحقیق و داده‌ها

داده‌ها مربوط به دو پیزومتر واقع در دشت قم هستند که در فاصله ۵ کیلومتری از یکدیگر قرار دارند. دشت قم با مساحت ۹۴۰ کیلومتر مربع بین عرض‌های جغرافیایی ۳۴' تا ۵۰' و طول‌های جغرافیایی ۳۴° ۹' تا ۳۴° ۴۴' شرقی قرار دارد و بخشی از محدوده مطالعاتی حوزه آبریز کویر مرکزی ایران است [۵، ۱۱]. شکل ۱ موقعیت منطقه تحقیق را نشان می‌دهد. کاهش رواناب ورودی به دشت قم و تخلیه بی‌رویه آبخوان این دشت از طریق پمپاژ، افت زیاد عمق آب زیرزمینی را در سال‌های گذشته به دنبال داشته است. هجوم آب شور دریاچه نمک از سمت شرق و آلودگی آبخوان با فاضلاب شهر قم از سمت غرب، کیفیت سفره آب زیرزمینی این دشت را تنزل داده است. ویژگی خاص هجوم آب شور دریاچه نمک از سمت شرقی این دشت، سبب جبران افت سطح آب در بخش‌های شرقی آن شده است [۵].

داده‌هایی که برای تشکیل مدل از آن استفاده می‌شود شامل اندازه‌گیری ماهانه عمق آب زیرزمینی دو پیزومتر به مدت ۱۰ سال از فروردین ۱۳۸۱ تا اسفند ۱۳۹۰ است. در این تحقیق به صورت تصادفی ۷۰ درصد داده‌ها برای آموزش<sup>۳</sup>، ۱۵ درصد برای اعتبارسنجی<sup>۴</sup> و ۱۵ درصد برای آزمایش<sup>۵</sup> مدل‌های شبکه عصبی استفاده شده است. ضمن اینکه برای مقایسه و بررسی کارایی مدل‌ها، داده‌های ۱۲ ماه سال ۱۳۹۱ به‌وسیله مدل‌ها شبیه‌سازی شده است (دوره آزمون). جدول ۱ مشخصات دو پیزومتر مطالعاتی و شکل‌های ۲ و ۳ نمودار تغییرات عمق آب زیرزمینی آنها را در طول دوره آماری نشان می‌دهند.

موجکی، به‌منظور پیش‌بینی سطح آب در دشت قروه استفاده شد؛ در این تحقیق از تبدیل‌های موجک و سطوح تجزیه گوناگون استفاده شد و مشخص شد تبدیل‌های موجکی که به سری زمانی شباهت داشته باشند نتایج بهتری در بر دارند [۱۳]. در تحقیق دیگری مدل شبکه عصبی موجکی برای پیش‌بینی عمق آب زیرزمینی دو سایت تحقیقی در ایالت کبک کانادا به‌کار برده شد. به این صورت که داده‌های بارش ماهانه، دمای متوسط ماهانه و عمق آب زیرزمینی متوسط ماهانه با تبدیل موجک تجزیه شده و به‌عنوان ورودی شبکه عصبی استفاده شدند. مقایسه با مدل‌های شبکه عصبی و میانگین متحرک خودبازگشتی یکپارچه<sup>۱</sup> (ARIMA) نشان داد توانایی مدل شبکه عصبی موجکی در پیش‌بینی عمق آب زیرزمینی از دو مدل دیگر بیشتر است [۸].

در این تحقیق برای مدلسازی از تحلیل موجک و نوع خاصی از ترکیب آن با شبکه عصبی پویا<sup>۲</sup> استفاده شده است که روشی جدید در پیش‌بینی عمق آب زیرزمینی است. ابتدا سری زمانی عمق آب زیرزمینی به‌وسیله تبدیل موجک تا دو سطح تجزیه می‌شود و زیرسری‌ها به‌عنوان ورودی و سری اصلی به‌عنوان خروجی به شبکه عصبی پویای تأخیر زمانی اعمال می‌شوند. هدف این تحقیق سنجش کارایی مدل پیشنهادی موجک-عصبی در پیش‌بینی یک ماه آینده عمق آب زیرزمینی دو پیزومتر مطالعاتی واقع در دشت قم و مقایسه آن با مدل‌های شبکه عصبی و رگرسیون خطی چندمتغیره است.

3. Train

4. Validation

5. Test

1. Autoregressive integrated moving average

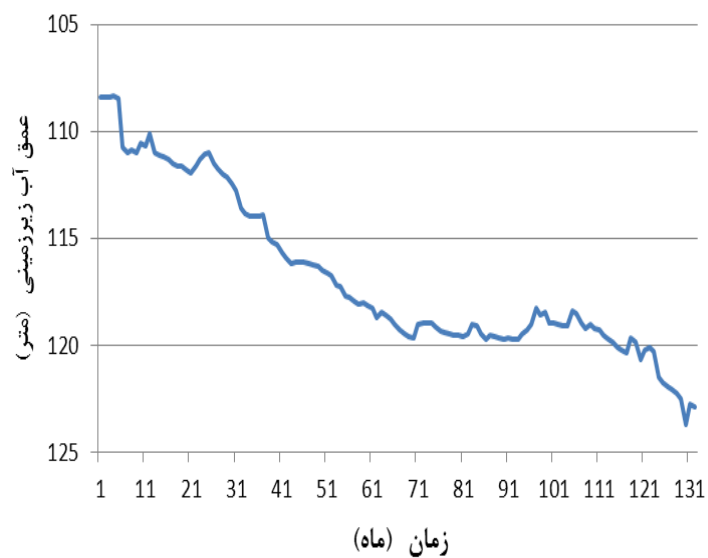
2. Dynamic Neural Network



شکل ۱. منطقه تحقیق

جدول ۱. مشخصات دو پیزومتر تحت مطالعه


شماره پیزومتر	نام پیزومتر	UTM (39 S)			نوع آماربرداری	محدوده زمانی	تعداد داده‌ها
		x	y	z			
۱	فدک	۴۹۹۰۶۸	۳۸۱۷۲۱۸	۹۴۲	ماهانه	۱۳۸۱-۱۳۹۱	۱۳۲
۲	لنگرود	۴۹۸۴۶۹	۳۸۲۲۴۶۱	۹۰۷	ماهانه	۱۳۸۱-۱۳۹۱	۱۳۲



شکل ۲. تغییرات ماهانه عمق آب زیرزمینی پیزومتر ۱ به مدت ۱۱ سال از فروردین ۱۳۸۱ تا اسفند ۱۳۹۱

### مدیریت آب و آبیاری

دوره ۴ ■ شماره ۱ ■ بهار و تابستان ۱۳۹۳



شکل ۳. تغییرات ماهانه عمق آب زیرزمینی پیژومتر ۲ به مدت ۱۱ سال از فروردین ۱۳۸۱ تا اسفند ۱۳۹۱

می‌دهد، می‌تواند سیستم‌های پیچیده را شبیه‌سازی کند. برای آموزش شبکه، الگوریتم‌های مختلفی وجود دارد. روند آموزش شبکه تا زمانی که خطای مراحل آموزش، اعتبارسنجی و آزمایش حداقل شود، ادامه می‌یابد.

### مدل شبکه عصبی TDNN

شبکه‌های عصبی را می‌توان به شبکه‌های ایستا و شبکه‌های پویا دسته‌بندی کرد. تفاوت این دو شبکه در نحوه آموزش آنهاست. هنگام آموزش شبکه‌های عصبی ایستا ترتیب داده‌های ورودی به شبکه مهم نیست؛ اما آموزش شبکه‌های عصبی پویا براساس داده‌هایی انجام می‌گیرد که تأخیر زمانی دارند و وزن‌های شبکه با تأثیر از گام‌های زمانی قبلی تنظیم می‌شوند. در مدل شبکه عصبی پویای TDNN<sup>۲</sup>، از داده‌های دو سری زمانی ورودی و خروجی استفاده می‌شود. این شبکه پس از آموزش، مقدار آینده سری زمانی خروجی را به صورت تابعی از مقادیر گذشته سری زمانی

مدل‌های شبکه عصبی زمانی بهتر عمل می‌کنند که خصوصیات آماری داده‌های آموزش و آزمایش مشابه داشته باشند [۱۴]. با توجه به اینکه داده‌های مجموعه آموزش، اعتبارسنجی و آزمایش تحقیق به صورت تصادفی انتخاب می‌شوند، احتمال مشابهت خصوصیات آماری آنها در مقایسه با زمانی که به صورت دسته‌ای انتخاب می‌شوند، افزایش می‌یابد که این موضوع طبیعتاً دقت مدل را افزایش می‌دهد.


### شبکه‌های عصبی مصنوعی (ANNs)

شبکه‌های عصبی مصنوعی<sup>۱</sup>، الهام گرفته شده از فرایند یادگیری مغز انسان است. یک شبکه عصبی مصنوعی شامل تعداد زیادی نورون مصنوعی است که براساس معماری خاص شبکه به هم متصل شده‌اند. شبکه عصبی با استفاده از آمار گذشته و شبکه‌ای از گره‌ها یا نورون‌های ساده که به یکدیگر متصلند و هر یک عملیات ریاضی ساده‌ای انجام

2. Time Delay Neural Network

1. Artificial Neural Networks

دارد. شبکه عصبی استفاده شده در این تحقیق یک شبکه پویای سه لایه پیش خور با تابع فعالیت تانژانت سیگموید در لایه مخفی و تابع فعالیت خطی در لایه خروجی است. شکل ۴ معماری این شبکه را نشان می دهد [۹].



شکل ۴. معماری شبکه عصبی TDNN سه لایه با ۵ نورون در لایه مخفی و تأخیر d

Cها است. ضریب های موجک تابعی از موقعیت و مقیاس هستند. با ضرب هر کدام از این ضرایب در موجک مادر مناسب جابه جاشده و مقیاس شده، مؤلفه های موجکی سیگنال اصلی به دست می آید [۱۲].

تبدیل موجک پیوسته در تمام مقیاس ها می تواند عمل کند، ولی در عین حال به مقدار زیادی داده و زمان محاسباتی نیاز دارد؛ بنابراین در اکثر تحقیقات، از تبدیل موجک گسسته به دلیل سادگی و سرعت زیاد محاسبات (با توجه به دقت مورد نیاز) استفاده شده است [۵، ۹، ۱۳، ۱۴، ۱۵]. در این تحقیق نیز از تبدیل موجک گسسته استفاده شده است. شکل ۵ تجزیه سیگنال سری زمانی عمق آب زیرزمینی پیزومتر ۲ را به سیگنال های پایه سازنده آن توسط تبدیل موجک meyer با سطح تجزیه ۲ نشان می دهد. همان گونه که در شکل مشخص است، موجک meyer، موجک مادر (S) را به یک موجک تقریب (a<sub>2</sub>) و دو موجک جزئیات (d<sub>1</sub>, d<sub>2</sub>) تجزیه کرده است، به طوری که S = a<sub>2</sub> + d<sub>2</sub> + d<sub>1</sub>.

ورودی، پیش بینی می کند. به عبارت دیگر:

$$y_{t+1} = f(x_t, x_{t-1}, \dots, x_{t-d}) \quad (1)$$

در رابطه ۱، d: تعداد تأخیر؛ y: سری زمانی خروجی؛ و x: سری زمانی ورودی است. امکان اینکه y=x باشد نیز وجود

## تحلیل موجک<sup>۱</sup>

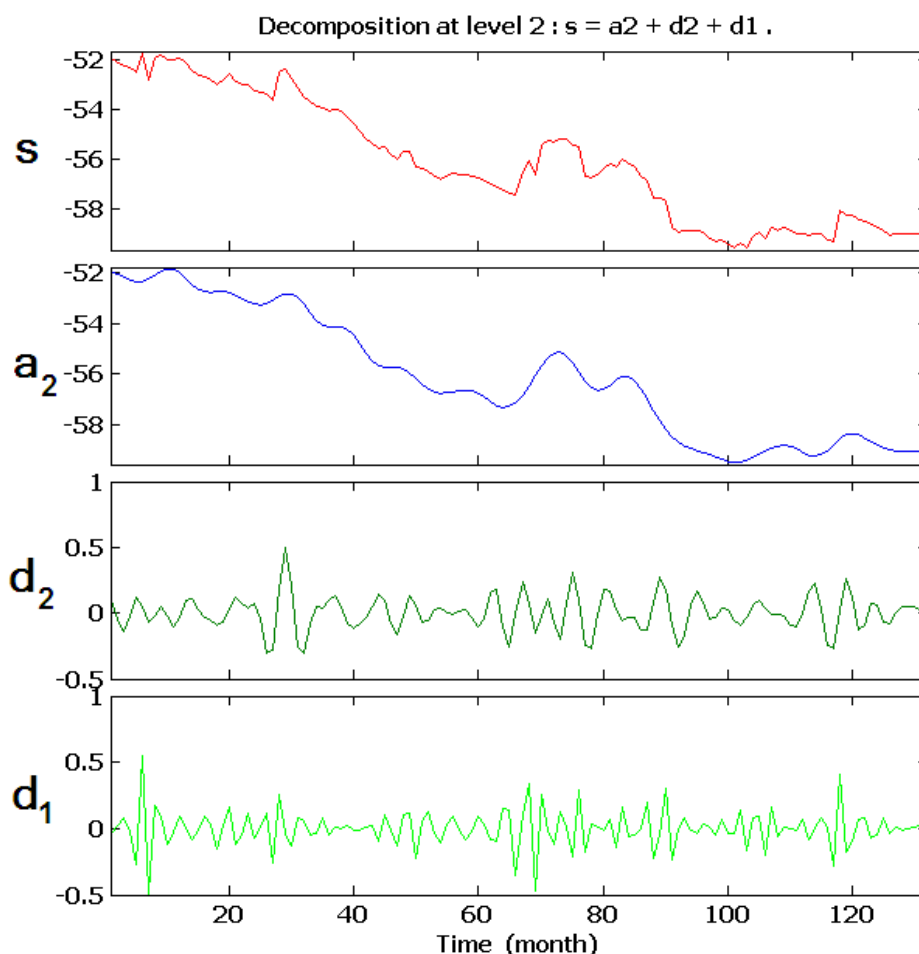
تبدیل های موجک<sup>۲</sup> برای تجزیه و بدون نویز کردن داده ها به کار می روند. به وسیله این تبدیل ها سری های زمانی به موجک هایی تقسیم می شوند که هر یک نسخه ای جابه جاشده و مقیاس شده از موجک مادر هستند. تبدیل موجک بر اساس مقیاس ها و موقعیت هایی که در آن عمل می کند، به دو صورت گسسته و پیوسته انجام می گیرد. تبدیل موجک پیوسته به صورت جمع حاصل ضرب سیگنال f(t) در تابع موجک مادر جابه جاشده و مقیاس شده  $\psi$  در همه زمان ها بیان می شود:

(۲)

$$C(\text{scale}, \text{position}) = \int_{-\infty}^{+\infty} f(t) \psi(\text{scale}, \text{position}, t) dt$$

نتیجه تبدیل موجک پیوسته ضریب های موجک یا همان

1. delay
2. Wavelet Transforms



شکل ۵. تجزیه سیگنال سری زمانی عمق آب زیرزمینی پیژومتر ۲ توسط موجک meyer با سطح تجزیه ۲

رگرسیون است، به گونه‌ای که مقادیر تخمین زده شده بی طرف<sup>۱</sup>، کارا<sup>۳</sup> و سازگار<sup>۴</sup> باشند. بی طرف به این معنا است که مقدار تخمین زده شده برابر مقدار صحیح پارامتر باشد؛ کارا یعنی تخمین گر، واریانس کوچک تری از تخمین گرهای دیگر داشته باشد و سازگار یعنی وقتی اندازه نمونه به بی نهایت میل می کند، بایاس و واریانس تخمین گر به صفر میل کند [۱۴].

2. Unbiased
3. Efficient
4. Consistent

### تحلیل رگرسیون خطی چندمتغیره (MLR)

تحلیل رگرسیون خطی چندمتغیره<sup>۱</sup> تکنیکی برای مدل کردن رابطه خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل است. شکل معمول معادله MLR به این صورت نشان داده می شود:

$$y = a_0 + \sum a_i x_i \quad (3)$$

که  $a_0$ : عرض از مبدأ؛  $a_i$ : ضریب رگرسیون متغیرهای مستقل  $x_i$ ؛ و  $y$ : مقدار پیش بینی شده است. هدف روش رگرسیون خطی چندمتغیره، تعیین پارامترهای معادله

1. Multi Linear Regression

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{i(o)} - Y_{i(p)})^2}{n}} \quad (5)$$

در روابط بالا  $Y_{i(o)}, Y_{i(p)}, Y_m$ : به ترتیب مقادیر مشاهده شده، پیش‌بینی شده و میانگین عمق آب زیرزمینی؛ و  $n$ : تعداد داده‌هاست.  $E = 1$  نشان از این دارد که داده‌های پیش‌بینی شده با داده‌های مشاهده شده همخوانی کامل دارد.  $E = 0$  یعنی دقت پیش‌بینی مدل با دقت میانگین داده‌های مشاهده شده برابر است؛ در حالی که  $E < 0$  زمانی اتفاق می‌افتد که میانگین داده‌های مشاهده شده پیش‌بینی بهتری نسبت به مدل دارد. به‌طور خلاصه اگر  $E$  و  $RMSE$  به ترتیب نزدیک به یک و صفر شوند، مدل پیش‌بینی بهتری دارد.

### نتایج و بحث

شبیه‌سازی عمق آب زیرزمینی دو پیرومتر مطالعاتی با سه مدل رگرسیون خطی چندمتغیره، شبکه عصبی و موجک-عصبی انجام گرفت و ساختاری از این مدل‌ها که بهترین نتایج را داشتند، به کار گرفته شد. جدول‌های ۲ و ۳ نتایج شبیه‌سازی دوره آزمون (۱۲ ماه سال ۱۳۹۱) را با بهترین ساختار هر یک از سه مدل نشان می‌دهند. برطبق این جدول‌ها نتیجه پیش‌بینی عمق آب زیرزمینی یک ماه آینده به وسیله مدل ترکیبی موجک-عصبی بسیار دقیق و بهتر از دو مدل دیگر است. برای پیرومتر ۱ مدل رگرسیون خطی چندمتغیره نتایج بهتری نسبت به مدل شبکه عصبی دارد، در حالی که در پیرومتر ۲ نتایج مدل شبکه عصبی بهتر از مدل رگرسیون خطی چندمتغیره است.

### ترکیب موجک- شبکه عصبی

در مدل ترکیبی موجک با شبکه عصبی TDNN، زیرسری‌هایی که به وسیله تبدیل‌های موجک تولید شده‌اند، با تأخیرهای مختلف به عنوان ورودی شبکه عصبی استفاده شده و خروجی شبکه، عمق آب زیرزمینی در زمان  $t+1$  است. تفاوت این روش با شبکه عصبی تنها، این است که به جای اینکه از داده‌های خام سری زمانی ورودی برای آموزش شبکه استفاده شود، ابتدا سری زمانی ورودی در چند سطح تجزیه می‌شود و سپس به همراه سری زمانی خروجی برای آموزش شبکه به کار می‌رود. در این صورت سری زمانی ورودی به شبکه عصبی به جای یک مؤلفه، چند مؤلفه دارد. مزیت مهم این روش، قابلیت آن در تشخیص اجزای تشکیل دهنده داده‌های غیرایستا به وسیله تجزیه چندسطحی موجکی داده‌ها است.

### مقایسه کارایی مدل‌ها

در این مقاله کارایی مدل‌های شبکه عصبی، ترکیبی موجک-عصبی و رگرسیون خطی چندمتغیره با استفاده از ضریب نش-ساتکلیف ( $E$ ) و ریشه خطای مربع متوسط ( $RMSE$ ) سنجیده می‌شود. ضریب کارایی نش-ساتکلیف<sup>۱</sup> برای ارزیابی توان پیش‌بینی مدل‌های هیدرولوژیکی به کار می‌رود و به صورت زیر تعریف می‌شود:

$$E = 1 - \frac{\sum_{i=1}^n (Y_{i(o)} - Y_{i(p)})^2}{\sum_{i=1}^n (Y_{i(o)} - Y_m)^2} \quad (4)$$

ریشه خطای مربع متوسط، بین داده‌های پیش‌بینی شده و مشاهده شده به صورت زیر تعریف می‌شود:

1. Nash-Sutcliffe model efficiency coefficient



جدول ۲. مقایسه مدل موجک-عصبی با مدل‌های رگرسیون خطی چندمتغیره و شبکه عصبی برای پیش‌بینی یک ماه آینده پیژومتر ۱ در دوره آزمون

مدل	رگرسیون خطی چندمتغیره	شبکه عصبی	موجک- شبکه عصبی
E	۰/۷۱۰	۰/۶۳۸	۰/۹۹۳
RMSE (m)	۰/۵۸۶	۰/۶۵۵	۰/۰۹۰

جدول ۳. مقایسه مدل موجک-عصبی با مدل‌های رگرسیون خطی چندمتغیره و شبکه عصبی برای پیش‌بینی یک ماه آینده پیژومتر ۲ در دوره آزمون

مدل	رگرسیون خطی چندمتغیره	شبکه عصبی	موجک- شبکه عصبی
E	۰/۶۷۶	۰/۷۳۳	۰/۹۷۴
RMSE (m)	۰/۱۲۰	۰/۱۰۹	۰/۰۳۴

جدول ۴. بهترین روابط به دست آمده مدل رگرسیون خطی چندمتغیره برای پیژومترهای ۱ و ۲

پیژومتر	رابطه MLR
۱	$y_t = 1.461 + 0.988y_{t-1}$
۲	$y_t = 1.277 + 0.898y_{t-1} + 0.184y_{t-2} - 0.104y_{t-4}$

زیرزمینی ماه فعلی تابعی از عمق آب زیرزمینی یک ماه قبل است؛ به عبارت دیگر عمق آب زیرزمینی، بیشترین وابستگی را به عمق آب زیرزمینی ماه قبل دارد. استفاده از عمق آب زیرزمینی دو ماه قبل، سه ماه قبل و ... این پیژومتر سبب کاهش دقت مدل شد. در پیژومتر ۲ بهترین رابطه رگرسیون خطی چندمتغیره نشان می‌دهد عمق آب زیرزمینی ماه فعلی تابعی از عمق آب زیرزمینی یک ماه قبل، دو ماه قبل و چهار ماه قبل است، اما همان گونه که ضریب‌ها نشان می‌دهند وابستگی به یک ماه قبل بیشتر از دو ماه و چهار ماه قبل است.

برای مدلسازی هر یک از پیژومترها با شبکه عصبی، گام‌های زمانی قبلی (براساس تعداد تأخیر اعمال شده) ورودی؛ و گام زمانی فعلی، خروجی شبکه هستند. در


برای مدلسازی با روش رگرسیون خطی چندمتغیره، آنالیز رگرسیون خطی بین مقادیر عمق آب زیرزمینی ماه فعلی با عمق آب زیرزمینی ماه قبل، دو ماه قبل، ... تا شش ماه قبل انجام گرفت. در اجرای مدل رگرسیون خطی چندمتغیره، عمق آب زیرزمینی ماه فعلی، متغیر وابسته به عمق آب زیرزمینی ماه‌های قبلی (متغیرهای مستقل) در نظر گرفته می‌شود. برای پیژومترهای ۱ و ۲ بهترین روابط مدل رگرسیون خطی چندمتغیره به دست آمدند (جدول ۴).

افزایش ماه‌های آنالیز به بیش از شش ماه عملاً تأثیری در بهبود عملکرد این مدل ندارد، بلکه فقط حجم محاسبات را افزایش می‌دهد و ممکن است از دقت این مدل نیز بکاهد. براساس جدول ۴، در پیژومتر ۱ بهترین رابطه رگرسیون خطی چندمتغیره نشان می‌دهد عمق آب

پیچیدگی این پدیده و به‌طور کلی طبیعت، به‌راحتی تشخیص‌پذیر نیستند. شاید عواملی نظیر رواناب‌های دیررس (ناشی از رودخانه‌های قمرود و وشنوه)، بارش‌های فصلی و پمپاژ از چاه‌های کشاورزی که اثرشان بر عمق آب زیرزمینی با تأخیر چندماهه همراه است، مؤثر بوده‌اند.

برای مدل ترکیبی موجک-عصبی ابتدا سری زمانی عمق آب زیرزمینی هر پیزومتر به‌وسیله موجک‌های مادر Haar, Db5, Db4, Db3, Db2 و برخی موجک‌های مادر غیرمعمول مثل Meyer, Sym2, Coif1, Rbio1.1، به‌صورت گسسته و با دو سطح تجزیه شدند. دو سطح تجزیه، سه زیرسری تولید می‌کند، بنابراین در این حالت شبکه عصبی سه ورودی دارد. به‌عبارت دیگر ورودی شبکه، گام‌های قبلی سه زیرسری تولیدشده؛ و خروجی، گام فعلی سری زمانی اصلی یا همان عمق آب زیرزمینی است. انتخاب سطح تجزیه براساس فرمول تجربی  $l = \text{int}[\log(n)]$  صورت گرفت (۶، ۸). در این فرمول:  $l$  سطح تجزیه؛ و  $n$ : تعداد داده‌های سری زمانی است. با توجه اینکه تعداد داده‌های این تحقیق، ۱۳۲ است، استفاده از فرمول بالا، سطح تجزیه دو را به‌دست می‌دهد. به‌کار بردن سطح تجزیه بالا مطلوب نیست، زیرا سطح تجزیه بالا با اینکه ممکن است دقت آموزش شبکه را افزایش دهد، نتیجه معکوس روی داده‌های آزمون دارد. همچنین باید توجه داشت که استفاده از تبدیل‌های موجک و تجزیه سری‌های زمانی الزاماً دقت شبکه عصبی را افزایش نخواهد داد. نکته مهم در انتخاب موجک مادر است. موجک مادر باید به طبیعت رخداد پدیده و نوع سری زمانی مشاهده‌شده شبیه باشد. الگوهایی از توابع موجک مادر که بتوانند از نظر شکل هندسی به‌خوبی بر منحنی سری زمانی منطبق شوند، بهتر می‌توانند عمل نگاهشت را انجام دهند و نتایج بهتری در بر خواهند داشت [۶]. شکل ۶ نمودار چند موجک مادر را برای نمونه نشان می‌دهد.

شبکه عصبی TDNN استفاده‌شده در این پژوهش، ۱۲۰ داده سری زمانی عمق آب زیرزمینی به شبکه وارد می‌شوند. در این حالت شبکه آموزش می‌بیند که چگونه گام فعلی یک سری زمانی را تابعی از گام‌های قبلی همان سری زمانی در نظر بگیرد. برای به‌دست آوردن بهترین نتیجه، شبکه با معماری‌های مختلف و به‌کار بردن تعداد تأخیرهای مختلف برای عمق آب زیرزمینی آموزش داده شد و آزمون شد. تأخیرها از یک تا شش ماه آزمایش شد. تعداد لایه‌های مخفی و تعداد نرون‌های لایه مخفی نیز با استفاده از داده‌های موجود و روش سعی و خطا بهینه شد. به‌طور معمول یک لایه مخفی پاسخ مناسبی می‌دهد و به‌طور کلی از بین دو معماری شبکه با دقت برابر، مورد ساده‌تر ترجیح داده می‌شود. برای پیزومتر ۱ بهترین نتیجه شبکه عصبی با معماری ۱-۳-۱ (شبکه سه‌لایه با یک ورودی، سه نرون در لایه مخفی و یک نرون در لایه خروجی) با الگوریتم آموزش لونیگ-مارکوات و با تأخیر ۱ پنج ماه (عمق آب زیرزمینی ماه فعلی تابعی از عمق آب زیرزمینی یک تا پنج ماه قبلی است)، حاصل شد. برای پیزومتر ۲ بهترین نتیجه شبکه عصبی با معماری ۱-۱۰-۱ با الگوریتم آموزش لونیگ-مارکوات و با تأخیر شش ماه حاصل شد. به‌دلیل ماهیت پیچیده و غیرخطی مدل‌های شبکه عصبی نمی‌توان علت این پدیده را به‌روشنی اظهار کرد، ولی با توجه به اینکه تأخیرهای پنج و شش‌ماهه بهترین نتیجه را به‌ترتیب برای پیزومترهای ۱ و ۲ داشته‌اند، به‌نظر می‌رسد این مدل‌ها ارتباط‌هایی را بین عمق آب زیرزمینی ماه فعلی با عمق آب زیرزمینی یک تا پنج و یک تا شش ماه قبلی آنها یافته‌اند؛ ارتباط‌هایی که به‌دلیل



شکل ۶. نمودار برخی توابع موجک مادر ( $\psi$ ) بر روی دامنه آنها (الف Meyer (ب Coif1 (پ Db2 (ت Haar [۱۲].

توجه به شباهت نسبی شکل کلی رفتار نوسان‌های عمق آب زیرزمینی دو پیرومتر (شکل‌های ۲ و ۳)، این نتیجه نشان می‌دهد در موارد مشابه، موجک‌های مختلف به‌طور تقریبی به یک صورت عمل کرده‌اند. موجک‌های دیگر تغییر چندانی در دقت مدل شبکه عصبی ایجاد نکردند و در بعضی موارد سبب کاهش دقت شدند. در مدل ترکیبی نیز ساختار شبکه عصبی و تعداد تأخیر با روش سعی و خطا بهینه شد. در اینجا نیز همانند مدل شبکه عصبی تنها، تأخیرهای پنج و شش ماهه نتایج بهتری داشتند که نشان می‌دهد مدل ترکیبی موجک-عصبی نیز ارتباط‌هایی بین عمق آب زیرزمینی ماه فعلی با عمق آب زیرزمینی یک تا شش ماه قبلی به‌صورت دقیق‌تر و بهتر از مدل شبکه عصبی یافته است.

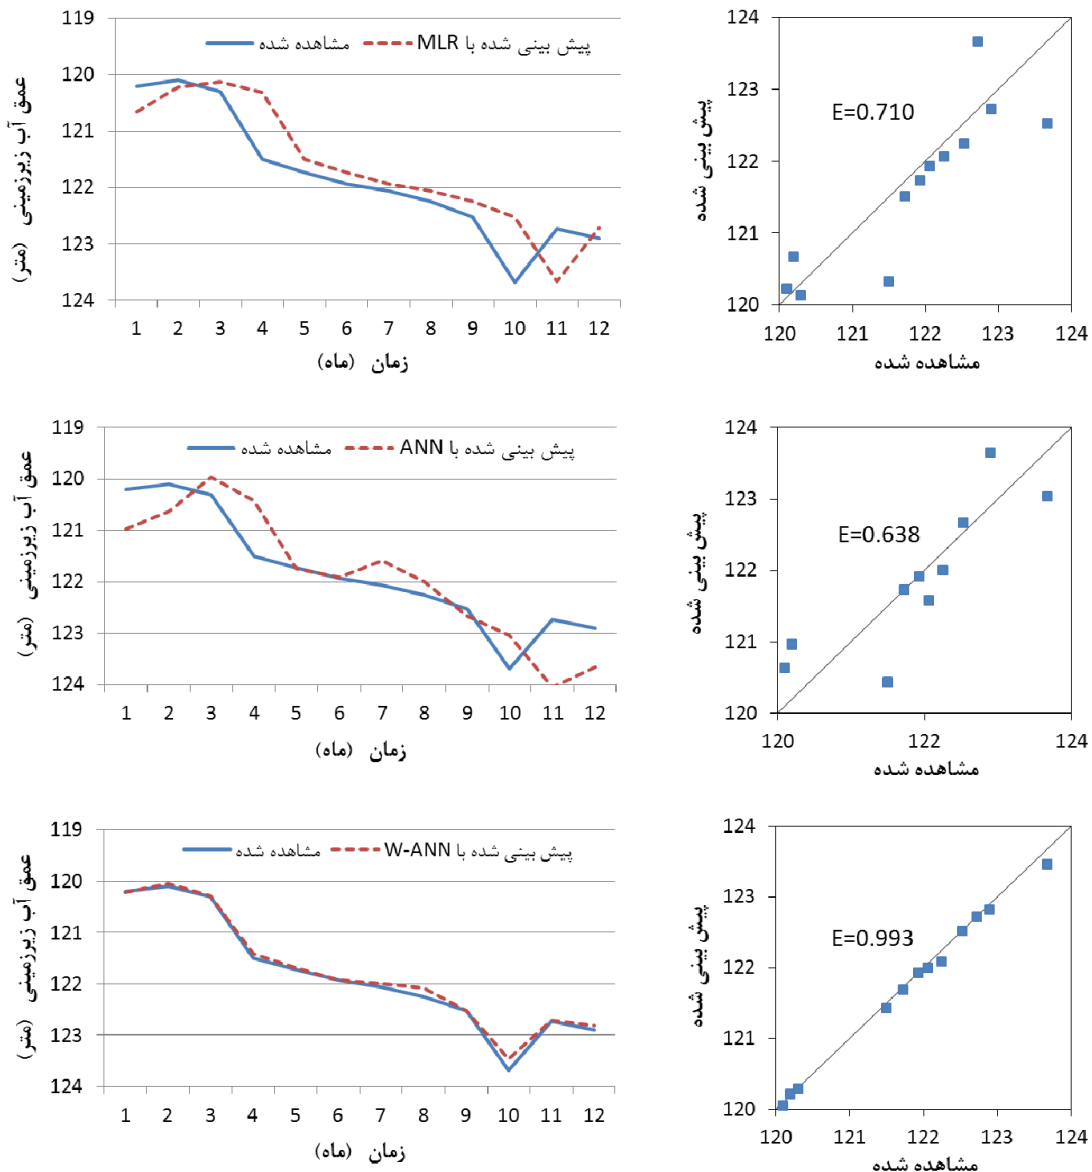
سری زمانی عمق آب زیرزمینی بر خلاف پدیده‌هایی مثل بارش-رواناب [۶] الزاماً ماهیت تک‌قله‌ای ندارند، بلکه اغلب دارای روند کاهشی و ویژگی نوسان پی‌درپی هستند. پیرومترهای این تحقیق نیز این گونه‌اند (شکل‌های ۲ و ۳) و پیدا کردن موجک‌های مادر شبیه آن می‌تواند نتایج بهتری داشته باشد. البته این کار ساده‌ای نخواهد بود و روش سعی و خطا برای پیدا کردن موجک مادر مناسب، آسان‌تر است. جدول ۵ بهترین نتایج مدل ترکیبی موجک-عصبی را در دوره آزمون نشان می‌دهد. برای هر دو پیرومتر، هنگام مدلسازی با روش ترکیبی موجک-عصبی مشاهده شد استفاده از موجک مادر Meyer نتایج بسیار دقیقی تولید می‌کند. ضمن اینکه موجک‌های مادر Haar، Db2 و Db5 نیز برای دو پیرومتر نتایج خوبی داشتند. با

جدول ۵. بهترین نتایج مدل ترکیبی موجک-عصبی مربوط به دوره آزمون

E	RMSE (m)	تأخیر (ماه)	ساختار ANN	سطح تجزیه	موجک مادر	پیرومتر
۰/۸۴۳	۰/۴۳۱	۶	۳-۵-۱	۲	Haar	
۰/۸۲۸	۰/۴۵۲	۵	۳-۶-۱	۲	Db2	
۰/۷۷۱	۰/۵۲۱	۶	۳-۶-۱	۲	Db5	۱
۰/۹۹۳	۰/۰۹۰	۶	۳-۵-۱	۲	Meyer *	
۰/۵۴۳	۰/۷۳۶	۵	۳-۵-۱	۲	Coif1	
۰/۷۳۶	۰/۱۰۴	۵	۳-۵-۱	۲	Haar	
۰/۸۲۰	۰/۰۸۹	۵	۳-۵-۱	۲	Db2	
۰/۹۰۸	۰/۰۶۴	۶	۳-۴-۱	۲	Db5	۲
۰/۹۷۴	۰/۰۳۴	۶	۳-۳-۱	۲	Meyer *	
۰/۷۳۷	۰/۱۰۸	۵	۳-۴-۱	۲	Coif1	

تجزیه شده به عنوان ورودی شبکه عصبی استفاده می کند توانسته است خصوصیات غیرخطی و پیچیده عمق آب زیرزمینی را دقیق تر از مدل شبکه عصبی و مدل رگرسیون خطی چندمتغیره شبیه سازی کند. شکل های ۷ و ۸ عمق آب زیرزمینی مشاهده شده در دوره آزمون را در مقایسه با پیش بینی یکماهه مدل ها به ترتیب برای پیرومترهای ۱ و ۲ نشان می دهند.

بر پایه جدول های ۲ و ۳ بهترین مدل ترکیبی موجک-عصبی توانسته است مقدار RMSE را برای پیرومتر ۱ به مقدار ۸۶ و ۸۵ درصد به ترتیب در مقایسه با بهترین مدل های شبکه عصبی و رگرسیون خطی چندمتغیره و برای پیرومتر ۲ به ترتیب به مقدار ۶۹ و ۷۲ درصد در مقایسه با بهترین مدل های شبکه عصبی و رگرسیون خطی چندمتغیره بهبود بخشد. مدل ترکیبی به این دلیل که از سیگنال های


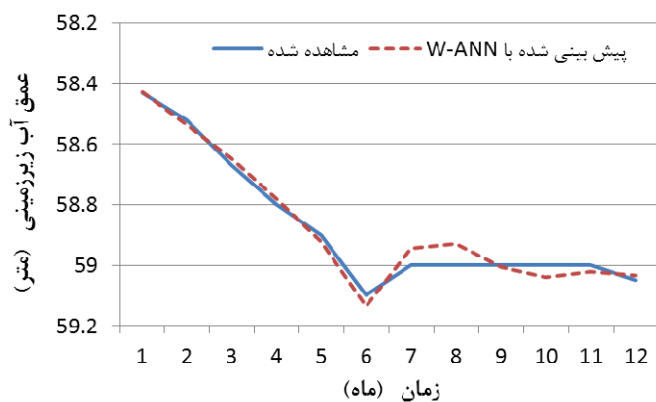

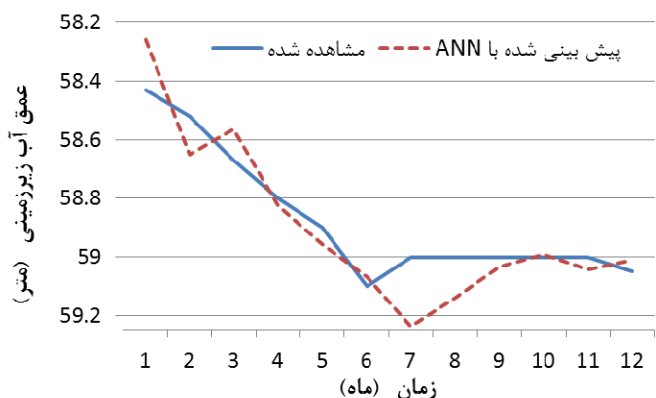

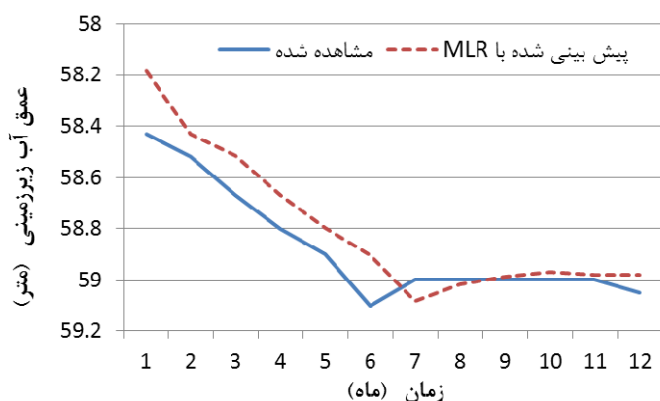


شکل ۷. مقایسه عمق آب زیرزمینی مشاهده شده و پیش بینی شده یک ماه آینده در دوره آزمون برای پیرومتر ۱

## مدلسازی نوسان‌های ماهانه آب زیرزمینی به‌وسیله تبدیل موجک و شبکه عصبی پویا

نیمساز قرار دارند. در مدل شبکه عصبی نقاط اطراف خط نیمساز نوسان کرده‌اند که نشان می‌دهد این مدل از پارامترهای بیشتری برای تنظیم وزن‌ها برخوردار بوده است. در مدل ترکیبی موجک-عصبی نقاط بر خط نیمساز منطبق شده‌اند و برتری این مدل را نشان می‌دهند.

همان‌طور که از شکل‌های ۷ و ۸ مشخص است، مدل رگرسیون خطی چندمتغیره، شکل کلی روند تغییرات عمق آب زیرزمینی را با یک گام تأخیر دنبال کرده است که این موضوع به ماهیت خطی این مدل برمی‌گردد. این مدل در اکثر گام‌ها پیش‌بینی بیشتر از مقدار مشاهده شده دارد. نقاط نمودار پراکنندگی در این مدل، اغلب در سمت راست خط



شکل ۸. مقایسه عمق آب زیرزمینی مشاهده شده و پیش‌بینی شده یک ماه آینده در دوره آزمون برای پیژومتر ۲

## مدیریت آب و آبیاری

دوره ۴ ■ شماره ۱ ■ بهار و تابستان ۱۳۹۳

دو پیژومتر واقع در دشت قم با مدل‌های رگرسیون خطی چندمتغیره، شبکه عصبی و ترکیبی موجک-عصبی اجرا شد. سری زمانی عمق آب زیرزمینی دو پیژومتر این تحقیق، ماهیت نوسانی و روند کاهشی داشت. مدل رگرسیون خطی چندمتغیره در ماه‌های خشک، پیش‌بینی یکماهه دست بالایی داشت که با توجه به شیب زیاد روند کاهش عمق در این ماه‌ها، این موضوع می‌تواند سبب افزایش خطا در پیش‌بینی گام‌های بعدی شود. نتیجه مدل شبکه عصبی نیز چندان رضایت‌بخش نبود، اما مدل ترکیبی موجک-عصبی با استفاده از موجک مادر Meyer که با سیگنال عمق آب زیرزمینی دو پیژومتر مطالعاتی همخوانی داشت، توانست پیش‌بینی یکماهه دقیقی داشته باشد. این موضوع نشان می‌دهد که در صورت استفاده بجای از تبدیل‌های موجک و ترکیب آن با مدل‌های هوشمند، می‌توان سیستم‌های هیدرولوژیکی پیچیده را شبیه‌سازی کرد.

پیشنهاد می‌شود پژوهش‌های بعدی با هدف بررسی کارایی این مدل برای پیش‌بینی عمق آب زیرزمینی دیگر مناطق یا گام‌های زمانی متفاوت (روزانه، هفتگی یا سالانه) انجام گیرد. استفاده از اطلاعات سری‌های زمانی دیگر مثل شدت پمپاژ از چاه‌های مجاور، مقدار بارندگی، دمای هوا و ... نیز می‌تواند برای پیش‌بینی عمق آب زیرزمینی به‌وسیله مدل ترکیبی موجک-عصبی بررسی شود.

### منابع

۱. رجائی ط. و میرباقری س ا (۱۳۸۸) مدل بار معلق رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی. نشریه مهندسی عمران. ۲۱(۱).
۲. علیزاده ا (۱۳۹۰) اصول هیدرولوژی کاربردی. چاپ سی و یکم، انتشارات آستان قدس رضوی: ۷۰۵-۷۰۹.

شکل‌های ۷ و ۸ پیش‌بینی یک ماه آینده را نشان می‌دهند؛ بدیهی است برای پیش‌بینی دو ماه آینده، سه ماه آینده و ... باید از مقادیر پیش‌بینی شده ماه اول، ماه دوم و ... به‌وسیله مدل استفاده کرد. در پیش‌بینی گام‌های بعدی دقت مدل‌ها کاهش می‌یابد. در منطقه تحقیق، پمپاژ از چاه‌های کشاورزی بیشترین تأثیر کاهشی را بر عمق آب زیرزمینی دارد. این موضوع از نمودار عمق آب زیرزمینی دو پیژومتر مطالعاتی (شکل‌های ۲ و ۳) نیز تا حدودی مشهود است. در فصل آبیاری که به‌طور معمول از اردیبهشت تا شهریور است (ماه‌های دوم تا ششم شکل‌های ۷ و ۸)، عمق آب زیرزمینی با شیب تندتری کاهش یافته است. از آنجا که روند کلی سری زمانی عمق آب زیرزمینی دو پیژومتر مطالعاتی کاهشی است، به‌نظر می‌رسد مدل رگرسیون خطی چندمتغیره که در ماه‌های اردیبهشت تا شهریور، پیش‌بینی یکماهه بیشتر از مقدار مشاهده شده دارد، مناسب نباشد. زیرا برآورد دست بالا در گام اول، به دور شدن مقدار پیش‌بینی شده و مشاهده شده در گام‌های بعدی (با توجه به روند کاهشی داده‌های واقعی) منجر می‌شود. برعکس مدلی که پیش‌بینی یکماهه کمتر از مقدار مشاهده شده داشته باشد، در گام‌های بعدی به‌خصوص در فصل خشک سال، احتمال اینکه پیش‌بینی دقیق‌تری داشته باشد بیشتر است [۱۰]. هر چند که پیش‌بینی یکماهه دقیق از هر دو مورد بالا بهتر است. مدل ترکیبی موجک-شبکه عصبی استفاده شده در این تحقیق پیش‌بینی یکماهه دقیقی دارد. ساختار این مدل، با تجزیه سیگنال عمق آب زیرزمینی، وزن‌های شبکه عصبی را به‌گونه‌ای تنظیم می‌کند که روند طبیعی سیستمی را که شبیه‌سازی می‌کند نشان دهند.

### نتیجه‌گیری

در این تحقیق شبیه‌سازی یک ماه آینده عمق آب زیرزمینی

- Neural network toolbox 7 user's guide. The Mathworks, Inc. 951p.
10. Daliakopoulos I N, Coulibaly P and Tsanis I K (2005) Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*. 309(1-4):229–240.
11. Lar consulting engineers co (2013) Qom groundwater quality and contamination studies [Online]. Available at [http://www.lar-co.com/department/selectedprojects/ghom\\_wate\\_rresources.html](http://www.lar-co.com/department/selectedprojects/ghom_wate_rresources.html) (accessed 10 Mar. 2013).
12. Misiti M, Misiti Y, Oppenheim G and Poggi J M (1996) Wavelet toolbox for use with matlab. The Mathworks, Inc. 626p.
13. Nakhaei M and Saberi Nasr A (2012) A combined wavelet-artificial neural network model and its applications to the prediction of groundwater level fluctuations. *Geopersia*. 2(2):77–91.
14. Rajaei T (2011) Wavelet and ANN combination model for prediction of daily suspended sediment load in rivers. *Science of the Total Environment*. 409(15):2917–2928.
15. Rajaei T, Mirbagheri S A, Nourani V and Alikhani A (2010) Prediction of daily suspended sediment load using wavelet and neuro-fuzzy combined model. *International Journal of Environmental Science and Technology (IJEST)*. 7(1):93-110.
16. Rajaei T, Nourani V, Zounemat-Kermani M and Kisi O (2011) River suspended sediment load prediction: Application of ANN and Wavelet conjunction model. *Journal of Hydrologic Eng. ASCE*. 16(8):613-627.
3. ماه‌گلی آ،، چیت‌سازان م. و نیامدپور ا (۱۳۹۰) تعمیم شبکه‌های عصبی مصنوعی با هوشمندی بالا جهت مدل‌سازی آبخوان دشت میداوود- دالون. سی‌امین گردهمایی علوم زمین، سازمان زمین‌شناسی و اکتشافات معدنی کشور، تهران، ایران.
4. محتشم م،، دهقانی ا،، اکبرپور ا،، مفتاح هلقی م. و اعتباری ب (۱۳۸۹) پیش‌بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت بیرجند). *مجله آبیاری و زهکشی ایران*. ۴(۱): ۱-۱۰.
5. نظری ع،، نخعی م،، صادقی راد م. و عرب بافرانی ع (۱۳۸۹) بررسی رخداد نفوذ آب شور دریاچه نمک به آبخوان دشت قم با استفاده از مدل‌سازی کمی آبخوان، دومین کنفرانس سراسری مدیریت جامع منابع آب، دانشگاه شهید باهنر، کرمان، ایران.
6. نورانی و،، حسن زاده ی،، کماسی م. و شرفی ا (۱۳۸۷) مدل‌سازی بارش- رواناب با مدل ترکیبی موجک- شبکه عصبی مصنوعی. چهارمین کنگره ملی مهندسی عمران، دانشگاه تهران، ایران.
7. نیک‌منش م. و رخشنده روغ (۱۳۹۰) ارزیابی توانایی شبکه‌های مختلف عصبی مصنوعی در پیش‌بینی تراز آب زیرزمینی در آبخوان محدوده سعادت شهر فارس. *مجله تحقیقات منابع آب ایران*. ۷(۱): ۸۲-۸۶.
8. Adamowski J and Chan F H (2011) A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*. 407(1- 4):28–40.
9. Beale M H, Hagan M T and Demuth H B (2010)