



## Prediction of Ground Water Level of Bostan Abad Using Combining Artificial Intelligence Models

A.A. Nadiri<sup>1\*</sup>, Z. Taherkhani<sup>2</sup> and F. Sadeghi Aghdam<sup>3</sup>

### Abstract

Bostan Abad aquifer located in East Azerbaijan Province is the main supplier of water in the region. To predict the groundwater level changes, numerical models have some limitations such as high complexity, money and time consumption, and demanding of a lot of data. For this reason, in the present study the artificial intelligence models including feed forward neural networks (FNN), recurrent neural networks (RNN), and gene expression programming (GEP) were used. Classification of parameters was carried out before modeling, due to the heterogeneity of the aquifer. Precipitation, evaporation, discharge of Ojan River, and groundwater level at a previous time step ( $t_{0-1}$ ), were used as input parameters in the models. Despite the acceptable results of all three models, based on the average RMSE of each cluster in the training and testing steps, combining the artificial intelligence models using a non-linear neural network as a combiner was adopted to achieve better results than the three individual models. The results showed a decrease in the average error with a value of 17% in the RMSE for each category in the Supervised Intelligent Committee Machine (SICM) compared to that of each individual model. The SICM was adopted to evaluate the effect of reducing 30 and 50 percent of the extraction well discharges on groundwater level. The results indicated that the increasing water level in most of the piezometers are remarkable. This reflects the higher impact of pumping in the amount of groundwater fluctuation relative to the climate change effect in the study area.

**Keywords:** Gene Expression Programming, Water Table, Bostan Abad Plain, Artificial Neural Network, Supervised Intelligent Committee Machine.

Received: November 29, 2016

Accepted: February 28, 2017

## پیش بینی سطح آب زیرزمینی دشت بستان آباد با استفاده از ترکیب نظارت شده مدل های هوش مصنوعی

عطاالله ندیری<sup>۱\*</sup>، زهرا طاهرخانی<sup>۲</sup> و فریبا صادقی اقدم<sup>۳</sup>

### چکیده

آبخوان دشت بستان آباد واقع در استان آذربایجان شرقی تأمین کننده اصلی نیازهای آبی منطقه می باشد. با توجه به برخی محدودیت های مدل های عددی مثل زمان بر و پرهزینه بودن و نیاز به داده های زیاد، در این تحقیق از مدل های هوش مصنوعی شامل شبکه های عصبی پیشرو (FNN)، شبکه های عصبی برگشتی (RNN) و برنامه نویسی بیان ژن (GEP) جهت بررسی تغییرات سطح آب زیرزمینی دشت استفاده شده است. دسته بندی پیرومترها به دلیل ناهمگنی آبخوان، قبل از مدل سازی صورت پذیرفت. پارامترهای بارش، تبخیر، دبی خروجی رودخانه اوجان و سطح آب زیرزمینی در یک زمان قبل به عنوان ورودی مدل ها مورد استفاده قرار گرفت. با وجود نتایج قابل قبول هر سه مدل بر اساس متوسط RMSE هر دسته در مراحل آموزش و آزمایش، جهت استفاده از کارایی هر سه مدل و دستیابی به نتیجه بهتر، از روش ترکیبی مدل های هوش مصنوعی با استفاده از یک شبکه عصبی مصنوعی به عنوان ترکیب کننده غیرخطی استفاده گردید. نتایج نشانگر کاهش متوسط خطای هر دسته در مدل هوش مصنوعی مرکب نسبت به مدل های منفرد به مقدار میانگین ۱۷٪ در مقادیر RMSE می باشد. با استفاده از نتایج مدل هوش مصنوعی مرکب، تأثیر کاهش ۳۰ و ۵۰ درصدی پمپاژ از چاه های بهره برداری بر روی سطح آب زیرزمینی مورد بررسی قرار گرفت. نتایج نشانگر بالا رفتن قابل توجه سطح آب در اکثر پیرومترها می باشد. این موضوع نشان دهنده تأثیر بالای مقادیر پمپاژ نسبت به تغییرات آب و هوایی در تغییرات سطح آب زیرزمینی منطقه مطالعاتی می باشد.

**کلمات کلیدی:** برنامه ریزی بیان ژن، تراز آب زیرزمینی، دشت بستان آباد، شبکه عصبی مصنوعی، هوش مصنوعی مرکب نظارت شده.

تاریخ دریافت مقاله: ۹۵/۹/۹

تاریخ پذیرش مقاله: ۹۵/۱۲/۱۰

1- Associated Professor, Department of Geology, Faculty of Natural Sciences, Tabriz University, Tabriz, Iran. Email: Nadiri@tabrizu.ac.ir

2- M.Sc Student in Hydrogeology, Faculty of Natural Sciences, Tabriz University, Tabriz, Iran

3- Ph.D Student in Hydrogeology, Faculty of Natural Sciences, Tabriz University, Tabriz, Iran

\*- Corresponding Author

۱- دانشیار گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز، ایران

۲- دانشجوی کارشناسی ارشد هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز، ایران

۳- دانشجوی دکترا هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز، ایران

\*- نویسنده مسئول

بحث و مناظره (Discussion) در مورد این مقاله تا پایان اسفند ۱۳۹۶ امکان پذیر است.

بالایی در پیش‌بینی سطح ایستابی دارد. برای مدل‌سازی نوسانات ماهانه تراز آب زیرزمینی (Coulibali et al., 2001) از شبکه عصبی مصنوعی استفاده نمودند و بررسی نتایج کارایی بالای شبکه عصبی مصنوعی را در پیش‌بینی سطح آب ارائه نمودند. (Yoon et al., 2011) در یک مطالعه مقایسه‌ای، کارایی شبکه‌های عصبی مصنوعی و ماشین بردار پشتیبان (SVM) را در پیش‌بینی سطح آب زیرزمینی آبخوان‌های ساحلی مورد بررسی قرار دادند و نشان دادند که میانگین مربعات خطا در هر دو مرحله آموزش و آزمایش در مدل شبکه عصبی مصنوعی کمتر از ماشین بردار پشتیبان است. الگوریتم‌های تکاملی توانایی مدل‌سازی فرآیندهای کاملاً غیرخطی و پویا را دارا می‌باشند. برنامه‌ریزی بیان ژن<sup>۳</sup> (GEP) یک الگوریتم تکاملی مبتنی بر جمعیت است (Ferreira, 2001) که از نسل برنامه‌ریزی ژنتیک<sup>۴</sup> (GP) به شمار می‌آید (Imani et al., 2001). برنامه‌ریزی ژنتیک و برنامه‌ریزی بیان ژن از جدیدترین الگوریتم‌های فراکاوشی هستند که به دلیل دارا بودن دقت کافی، مورد توجه پژوهش‌گران به ویژه در زمینه مطالعات هیدرولوژیکی و هیدروژئولوژیکی قرار گرفته‌اند (Shiri et al., 2013; Ahmadi., 2014). از جمله مطالعات هیدرولوژیکی و هیدروژئولوژیکی صورت گرفته با استفاده از GP می‌توان به پیش‌بینی و شبیه‌سازی سطح آب زیرزمینی با استفاده از برنامه‌نویسی ژنتیک و مقایسه آن با نروفازی در دشت کرج توسط (Mehdipour et al., 2013) اشاره نمود. نتایج بیان کرد که مقادیر RMSE در روش GP نسبت به روش نروفازی برای چاه‌های مشاهده‌ای در مرحله آزمایش و آموزش به ترتیب ۸/۳۵ و ۱۱/۳۳ درصد کاهش را نشان می‌دهد. برای مدل‌سازی بارش-رواناب، (Liong (2002) از برنامه‌نویسی ژنتیک استفاده کردند. نتایج نشان داد که دقت پیش‌بینی رواناب بر اساس ریشه میانگین مربعات خطا و ضریب همبستگی از قابلیت قبول بالایی برخوردار است، بنابراین ارتباط بین بارش و رواناب ناشی از آن در مدل GP می‌تواند جایگزین مناسبی برای مدل‌های ریاضی بارش و رواناب باشد. بر اساس مطالعات اخیر انجام شده روش‌های مختلفی برای پیش‌بینی سطح آب‌های زیرزمینی استفاده شده است، دلیل آن را می‌توان در مزایا و معایب ذاتی هر یک از روش‌های هوش مصنوعی دانست. لذا اخیراً روش‌های ترکیبی برای استفاده همزمان از مزایای مدل‌های مختلف هوش مصنوعی ارائه شده است که از آن جمله می‌توان به مدل هوش مصنوعی مرکب نظارت‌شده<sup>۵</sup> (SICM) که در تحقیقات هیدرولوژیکی و هیدروژئولوژیکی استفاده شده اشاره نمود (Fijani et al., 2013; Nadiri et al., 2017; Tayfur et al., 2014). مدل هوش مصنوعی مرکب نظارت‌شده اولین بار توسط (Nadiri et al., 2013 a) جهت ترکیب نتایج هوش مصنوعی و برای بدست آوردن خروجی نهایی بهتر نسبت به تک‌تک مدل‌های هوش مصنوعی به منظور پیش‌بینی غلظت

در چند دهه اخیر عوامل چالش برانگیزی مانند رشد جمعیت، عوامل آب و هوایی و همچنین تحولات اجتماعی-اقتصادی، باعث افزایش نیاز روزافزون به منابع آبی گردیده است و بهره‌برداری از منابع آب زیرزمینی به عنوان جایگزین کمبود آب در مصارف مختلف صورت می‌گیرد. لذا نیاز به مدیریت یکپارچه این منابع بیش از پیش محسوس می‌گردد و پیش‌بینی سطح آب زیرزمینی جهت برنامه‌ریزی مدیریت یکپارچه امری بسیار ضروری می‌باشد. ارزیابی تغییرات تراز آب زیرزمینی و پیش‌بینی آن با توجه به وجود پارامترهای متنوع مرتبط با موضوع نظیر متغیرهای هیدرولوژیکی، زمین‌شناسی، خاک‌شناسی و غیره یک مسئله غیرخطی و پیچیده می‌باشد (Copola et al., 2003; Daliakopoulos et al., 2005). مدل‌های عددی و هوش مصنوعی گوناگونی برای شبیه‌سازی این فرآیند پیچیده توسط محققین پیشنهاد شده است (Nourani et al., 2008; Mehdipour et al., 2013; Nayak et al., 2006; Moghaddam et al., 2009). مدل‌های هوش مصنوعی<sup>۱</sup> (AI) مانند شبکه‌های عصبی مصنوعی<sup>۲</sup> و برنامه‌ریزی بیان ژن به دلیل عدم نیاز به داده‌های زیاد و زمان کالیبراسیون کم، به مدل‌های عددی برتری نسبی دارند. یکی از موانع اصلی در استفاده گسترده از مدل‌های تصمیم‌گیری در دنیای واقعی، حجم محاسباتی بالای آن‌ها است. پیشرفت‌های اخیر در روش‌های محاسباتی کارآمد و ابزارهای بهینه‌ساز قوی سبب رفع این موانع گردیده است. زمان محاسبات از مدت‌ها به عنوان یک عارضه مهم در استفاده از روش پیوند یافته شبیه‌سازی-بهینه‌سازی برای مشکلات صحرایی مطرح شده است. راه‌حل این مشکل استفاده از مدل‌های جایگزین مبتنی بر شبکه‌های عصبی مصنوعی در مدل‌های شبیه‌سازی-بهینه‌سازی برای مسائل مدیریتی آب زیرزمینی است (Ketabchi and Ataie-Ashtiani, 2015; Ataie-Ashtiani et al., 2014). از اواخر دهه ۹۰، شبکه‌های عصبی مصنوعی (ANN) در مسائل هیدروژئولوژی و هیدروژئولوژی مثل مدل‌سازی بارش و رواناب، پیش‌بینی جریان رودخانه‌ها، مدل‌سازی آب‌های زیرزمینی، کیفیت آب، مدیریت منابع آب، پیش‌بینی بارش و سری‌های زمانی و غیره مورد استفاده قرار گرفته‌اند (Kumar et al., 2005; Sulaiman et al., 2011). از مطالعات هیدروژئولوژیکی انجام شده در این زمینه می‌توان به پیش‌بینی سطح ایستابی در زهکشی زیر سطحی مزارع با استفاده از شبکه عصبی مصنوعی توسط (Yang et al., 1997) اشاره نمود که از بارش روزانه، پتانسیل تبخیر و سطح ایستابی در گام زمانی قبل به عنوان ورودی و سطح ایستابی در گام زمانی آینده به عنوان خروجی مدل استفاده کردند. نتایج نشان داد که شبکه عصبی مصنوعی توانایی

فلوراید آب زیرزمینی منطقه ماکو در آذربایجان غربی ارائه شد. از مطالعات انجام شده در زمینه مدل هوش مصنوعی مرکب در علوم مختلف می‌توان به تخمین هدایت هیدرولیکی با استفاده از هوش مصنوعی مرکب توسط (Tayfur et al., 2014) اشاره کرد. آنها در این مطالعه از مدل‌های منطبق فازی سوگنو، ممدانی، شبکه عصبی و نروفازی برای تخمین هدایت هیدرولیکی آبخوان دشت تسوج سود جستند. نتایج نشان داد که مدل ترکیبی نتایج بهتری نسبت به مدل‌های منفرد ارائه می‌دهد. از مطالعات هیدروژئولوژیکی صورت گرفته در دشت بستان‌آباد می‌توان به بررسی هیدروژئولوژیکی دشت بستان‌آباد و ارائه راه‌حل‌های مدیریتی با استفاده از مدل ریاضی اشاره کرد (Jahedan, 2008). در مطالعه حاضر پیژومترها به دلیل ناهمگنی آبخوان دسته‌بندی شدند و سپس با استفاده از پارامترهای موثر بر نوسانات سطح آب زیرزمینی، اقدام به پیش‌بینی سطح آب زیرزمینی با استفاده از روش‌های هوش مصنوعی شامل شبکه عصبی پیشرو، شبکه برگشتی و برنامه‌ریزی بیان ژن گردید. سپس مدل هوش مصنوعی مرکب با استفاده از یک شبکه عصبی مصنوعی به عنوان ترکیب‌کننده غیرخطی مدل‌های هوش مصنوعی منفرد، اجرا گردید. با توجه به افت متوسط ۱/۵ متری سطح آب زیرزمینی در پیژومترهای موجود در دشت بستان‌آباد برای بازه زمانی ۱۳۸۷-۱۳۹۳ و به منظور مدیریت موثر منابع آب در این دشت با استفاده از نتایج مدل مرکب سناریوی تعریف گردید تا بر اساس آن بتوان نتیجه کاهش برداشت از چاه‌های بهره‌برداري موجود در دشت بستان‌آباد را بر سطح آب زیرزمینی مورد بررسی قرار داد. بیش‌تر مطالعات قبلی صورت گرفته از مدل‌های منفرد جهت پیش‌بینی سطح آب پیژومترها به صورت منفرد بهره گرفته‌اند. در این تحقیق پیژومترها دسته‌بندی شدند و مدل‌های منفرد و مدل هوش مصنوعی مرکب برای پیژومترهای هر دسته اجرا گردید. همچنین در این مطالعه سناریوی جهت ارائه راه‌کارهای مدیریتی برای دشت تعریف گردید.

## ۲- منطقه مطالعاتی

دشت بستان‌آباد یکی از زیر حوضه‌های آبریز دریاچه ارومیه می‌باشد که در شمال باختر ایران و در استان آذربایجان شرقی، در فاصله ۴۵ کیلومتری جنوب شرق شهرستان تبریز واقع شده است. موقعیت منطقه مطالعاتی مطابق شکل ۱ ارائه شده است. مساحت کل این حوضه آبریز و وسعت این دشت به ترتیب ۵۹۴ و ۲۰۲/۵۹ کیلومتر مربع می‌باشد که از شمال به محدوده کردکندی، از جنوب غرب به دامنه‌های کوه سه‌پند و از غرب به محدوده مطالعاتی تبریز و از شرق به محدوده مطالعاتی سراب محدود شده است. رودخانه اوجان تنها منبع آب

سطحی محدوده می‌باشد که از ارتفاعات بیوک‌داغ در غرب محدوده سرچشمه گرفته و در امتداد غرب به شرق جریان می‌یابد و بعد از دریافت جریان شاخه‌های مختلف و با گذر از داخل شهرستان بستان‌آباد در نهایت به رودخانه آجی‌چای می‌پیوندد. راه‌های ارتباطی منطقه مطالعاتی، اتوبان تبریز-تهران است که از بخش شمال غرب وارد شده و پس از طی مسافتی از جنوب شرق خارج می‌شود. همچنین در داخل شهر بستان‌آباد جاده اردبیل از این راه منشعب و به طرف شمال ادامه می‌یابد. اقلیم منطقه در اقلیم‌نمای آمبرژه در محدوده خشک سرد قرار دارد. همچنین متوسط میزان بارش سالیانه ۲۷۶ میلی‌متر (بر اساس داده‌های ایستگاه بستان‌آباد، ۱۳۹۳-۱۳۶۸)، متوسط تبخیر سالیانه ۱۰۸۲/۳ میلی‌متر (بر اساس داده‌های ایستگاه قوریگل، ۱۳۹۳-۱۳۸۱) و متوسط دبی خروجی سالیانه رودخانه اوجان ۱۳۸/۸ متر مکعب در ثانیه (بر اساس داده‌های ایستگاه هیدرومتری بستان‌آباد، ۱۳۹۳-۱۳۸۷) می‌باشد. در آبخوان آزاد دشت بستان‌آباد تعداد ۱۵ رشته قنات، ۲۰ دهنه چشمه و ۶ چاه بهره‌برداري وجود دارد. در سال‌های اخیر تعداد ۷ قنات و ۶ چشمه بر اثر افت سطح آب زیرزمینی در منطقه خشک شده است که نشان‌دهنده شرایط بحرانی منطقه می‌باشد. از بین ۱۹ پیژومتر حفر شده در دشت تنها ۱۴ پیژومتر دارای اطلاعات کامل و تعداد ۵ پیژومتر نقص داده فراوانی داشتند که امکان بازسازی برای آنها وجود نداشت. نیمی از ۱۴ پیژومتر موجود دارای داده‌های ۶ ساله (در بازه مهر ۱۳۸۷ تا شهریور ۱۳۹۳) و بقیه پیژومترهای موجود دارای داده‌های ۱۱ ساله (مرداد ۱۳۸۲ تا شهریور ۱۳۹۳) می‌باشند. بر اساس داده‌های سطح تراز آب زیرزمینی (مهرماه سال ۹۳) جهت جریان در دشت بستان‌آباد از حاشیه‌ها به سمت مرکز دشت می‌باشد، به طوری که جریان از شمال شرق دشت خارج می‌شود (شکل ۲). با توجه به لاگ‌های چاه‌های مشاهده‌ای و اکتشافی، تغییرات ضخامت اشباع آبخوان از ۱۵ تا ۱۱۰ متر می‌باشد. به طوری که بیشترین ضخامت اشباع مربوط به شمال و شمال غرب دشت است که مقدار آن ۹۰ تا ۱۱۰ متر می‌باشد. کمترین ضخامت اشباع در محل گمانه پیژومتری خیرآباد به ۱۵ متر می‌رسد.

## ۳- روش‌های کاربردی پژوهش

### ۳-۱- مدل‌های هوش مصنوعی

در این تحقیق از سه مدل شبکه عصبی پیشرو<sup>۶</sup> (FNN)، شبکه عصبی برگشتی<sup>۷</sup> (RNN) و برنامه‌ریزی بیان ژن برای پیش‌بینی سطح آب زیرزمینی دشت بستان‌آباد بهره گرفته شده است. هر سه مدل هوش مصنوعی مزیت‌های خاص خود را دارند.

پردازشگر تشکیل شده‌اند که محل پردازش داده‌ها است. شمار لایه‌های مخفی و شمار گره‌ها در هر لایه مخفی به طور معمول به وسیله روش آزمون و خطا مشخص می‌شود. گره‌های لایه‌های مجاور در شبکه به طور کامل با هم در ارتباط هستند. هر گره دارای یک تابع تبدیل‌گر است و ورودی‌های هر گره از متغیرهای خروجی گره‌های مجاور و وزن ارتباطی بین آنها حاصل می‌گردد (Nadiri et al., 2015). شکل ۳ تصویر شماتیکی از یک شبکه عصبی مصنوعی پیشرو را نشان می‌دهد، که از چهار گره در لایه ورودی، سه گره در لایه میانی و یک گره در لایه خروجی تشکیل شده است و نمادهای GWL مربوط به پارامتر سطح تراز آب زیرزمینی، P بارش، E تبخیر و D دبی رودخانه می‌باشد. بر اساس توپولوژی و ساختار شبکه‌های عصبی مصنوعی به دو نوع کلی شبکه پیشرو و شبکه برگشتی تقسیم می‌شوند. توپولوژی شبکه پیشرو شامل مجموعه‌ای از نرون‌هاست که با نرون‌های لایه دیگر مرتبط هستند و به طور معمول شامل یک لایه ورودی، یک لایه مخفی و یک لایه خروجی است (Nourani et al., 2009). برای انجام مدل‌سازی داده‌ها پس از نرمال‌سازی به دو زیر مجموعه شامل مرحله آموزش، مرحله آزمایش تقسیم می‌شوند. در شبکه‌های عصبی برگشتی، برگشت از لایه خروجی به لایه ورودی رخ می‌دهد. وجه تمایز شبکه عصبی پیشرو از برگشتی وجود حداقل یک ارتباط برگشت است (Chiang et al., 2004).

### ۳-۱-۲- مدل برنامه‌ریزی بیان ژن (GEP)

برنامه‌ریزی بیان ژن شبیه الگوریتم‌های ژنتیک<sup>A</sup> (GA) و برنامه‌ریزی ژنتیک (GP) می‌باشد. الگوریتم‌های ژنتیک از افراد مجزا استفاده کرده، سپس آنها را بر اساس برزاش انتخاب می‌کند و در نهایت با استفاده از یک یا چند عملگر ژنتیکی تغییرات ژنتیکی را اعمال می‌کند (Mitchell, 1996). تفاوت اساسی بین الگوریتم‌های یاد شده به طبیعت هر کدام برمی‌گردد به طوری که در GA، افراد رشته‌های خطی با طول ثابت هستند (کروموزوم)، در حالی که در GP افراد نهادهای غیرخطی در شکل‌ها و اندازه‌های مختلف (درخت تجزیه) هستند و در GEP افراد به صورت ردیف‌های علامت‌دار با طول ثابت (کروموزوم) رمزگذاری می‌شوند که سپس به صورت غیرخطی و با شکل و اندازه متفاوت به وسیله درخت بیان نمایان می‌گردند. چون در روش برنامه‌ریزی بیان ژن تمام ساختارهای شاخه‌ای در اندازه و شکل‌های متفاوت، در کروموزوم‌های خطی با طول ثابت کدگذاری می‌شوند باعث جداسازی کامل فنوتیپ از ژنوتیپ شده، در نتیجه سیستم می‌تواند از تمام مزایای تکاملی بهره‌مند گردد (Ferreira, 2001).

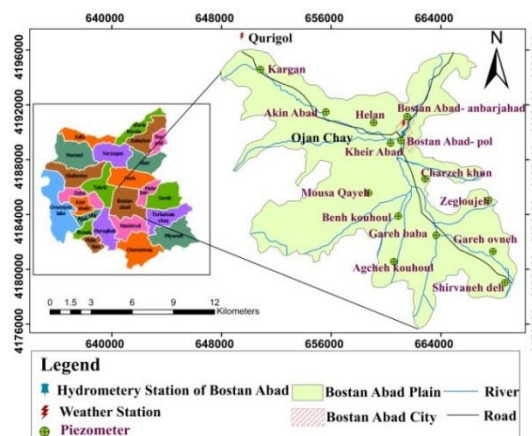


Fig. 1- Location of the study area

### شکل ۱- موقعیت منطقه مورد مطالعه

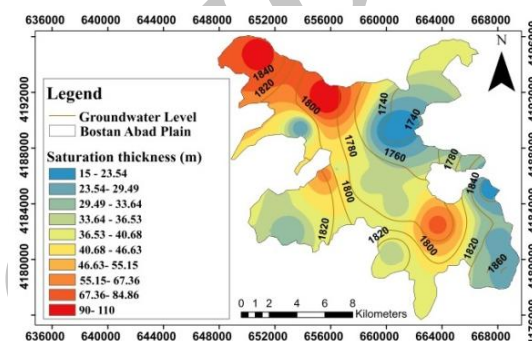


Fig. 2- Groundwater level in September 2014 and average saturation thickness of alluvial in Bostan Abad plain aquifer

### شکل ۲- سطح تراز آب زیرزمینی در مهر ۱۳۹۳ و متوسط ضخامت اشباع آبرفت در آبخوان دشت بستان‌آباد

لذا جهت استفاده از مزیت‌های هر سه مدل، و رسیدن به نتایج بهتر از مدل هوش مصنوعی مرکب نظارت‌شده (SICM) استفاده گردید.

### ۳-۱-۱- مدل شبکه عصبی مصنوعی (ANN)

مدل‌های شبکه عصبی مصنوعی، سال‌های زیادی به امید رسیدن به عملکردی مشابه کارایی انسان در زمینه سرعت و شناخت تصویر مورد مطالعه قرار گرفته است (Lippman, 1987). این مدل‌ها یک سیستم پردازش اطلاعات با توزیع موازی هستند که عملکردی مشابه شبکه‌های عصبی زیستی مانند مغز انسان دارند (Haykin, 1999). ساختار عادی یک شبکه عصبی مصنوعی، معمولاً از لایه ورودی، لایه‌های میانی (مخفی) و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای ورودی داده‌ها است. آخرین لایه، لایه خروجی مقادیر پیش‌بینی‌شده به وسیله شبکه می‌باشد و خروجی مدل را معرفی می‌کند. لایه میانی یا مخفی که از گره‌های

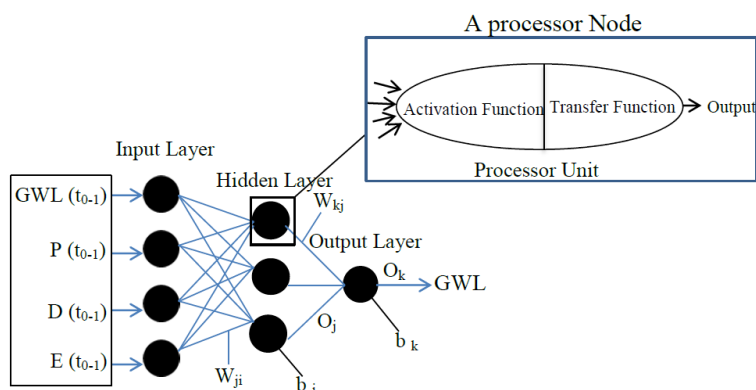


Fig. 3- Schematic illustration of a feedforward artificial neural network and a processor node

شکل ۳- تصویر شماتیکی از یک شبکه عصبی مصنوعی پیشرو و یک گره پردازشگر

برنامه‌ریزی بیان ژن ویرایش جدیدی از برنامه‌ریزی ژنتیک است که به استنتاج برنامه‌های رایانه‌ای با اندازه‌ها و شکل‌های مختلف می‌پردازد. فرآیند گام به گام برنامه‌ریزی ژنتیک به صورت مراحل زیر است (Borelli et al., 2006): ۱- یک جمعیت اولیه از توابع مرکب نشان دهنده مدل‌های پیش‌بینی ایجاد می‌شود، ۲- هر یک از افراد توسط تابع برازش مورد ارزیابی قرار می‌گیرند، ۳- در هر تولید فرایندهای زیر برای انتخاب یک جمعیت جدید دنبال می‌شود، ۳-۱- انتخاب یکی از عملگرهای تقاطع، کپی و جهش، ۳-۲- انتخاب تعداد مناسبی از افراد جمعیت ۳-۳- استفاده از عملگر انتخاب شده برای تولید فرزندان (GEP برخلاف GP و GA چندین عملگر ژنتیکی برای تکثیر افراد با اصلاحات دارد (Lopes and Weinert, 2004)، ۳-۴- قرار دادن فرزندان در جمعیت جدید، ۳-۵- مدل با استفاده از برازش‌های مختلف مورد ارزیابی قرار می‌گیرد، ۴- گام سوم تا رسیدن به حداکثر تولید تکرار خواهد شد.

$$E_{avg} = \frac{1}{K} \sum_{i=1}^K E_i = \left( \frac{1}{K} \right) \sum_{i=1}^K [e_i^2] \quad (2)$$

با فرض وجود  $i$  سیستم پیش‌بینی  $i=1, \dots, K$  بردار هدف و  $GWL_i$  خروجی هر سیستم خواهد بود و در رابطه فوق  $[e_i]$  امید ریاضی است و متوسط خطا برای هر یک از سیستم‌های هوش مصنوعی به صورت معادله (۲) محاسبه می‌شود.

که در رابطه فوق  $k$  تعداد سیستم‌های استفاده شده،  $E_i$  خطای هر سیستم و  $E_{avg}$  متوسط خطای هر سیستم می‌باشد. لذا با اعمال روش متوسط‌گیری از بردار خروجی هر یک از سیستم‌های پیش‌بینی  $GWL_i$ ، خروجی مدل هوش مصنوعی مرکب  $GWL_{CM}$  به صورت معادله (۳) خواهد بود:

$$GWL_{CM} = \frac{1}{K} \sum_{i=1}^K \hat{GWL}_i \quad (3)$$

بنابراین برای مربع خطای مدل هوش مصنوعی مرکب خواهیم داشت:

$$E_{CM} = \left[ \left( \hat{GWL}_{CM} - GWL \right)^2 \right] = \left[ \left( \frac{1}{K} \sum_{i=1}^K \hat{GWL}_i - GWL \right)^2 \right] = \left[ \left( \frac{1}{K} \sum_{i=1}^K e_i \right)^2 \right] \quad (4)$$

با در نظر گرفتن نامعادله کاجی<sup>۹</sup> در معادله (۵) می‌توان نشان داد بر اساس معادله (۶) مدل هوش مصنوعی مرکب کمترین خطا را نسبت به هر یک از مدل‌های استفاده شده خواهد داشت.

$$(a_1 b_1 + a_2 b_2 + \dots + a_n b_n)^2 \leq (a_1^2 + a_2^2 + \dots + a_n^2) \times (b_1^2 + b_2^2 + \dots + b_n^2) \quad (5)$$

$$E_{CM} = \left[ \left( \frac{1}{K} \sum_{i=1}^K \hat{GWL}_i - GWL \right)^2 \right] \leq \left( \frac{1}{K} \right) \sum_{i=1}^K [e_i^2] = E_{avg} \quad (6)$$

پس از این مطالعه برای اولین بار (Nadiri et al., 2013a) روش مدل مرکب نظارت‌شده را برای ترکیب مدل‌های هوش مصنوعی در تخمین پارامترهای هیدروژئولوژی و هیدرولوژیکی ارائه کرد که در چند سال

برنامه‌ریزی بیان ژن ویرایش جدیدی از برنامه‌ریزی ژنتیک است که به استنتاج برنامه‌های رایانه‌ای با اندازه‌ها و شکل‌های مختلف می‌پردازد. فرآیند گام به گام برنامه‌ریزی ژنتیک به صورت مراحل زیر است (Borelli et al., 2006): ۱- یک جمعیت اولیه از توابع مرکب نشان دهنده مدل‌های پیش‌بینی ایجاد می‌شود، ۲- هر یک از افراد توسط تابع برازش مورد ارزیابی قرار می‌گیرند، ۳- در هر تولید فرایندهای زیر برای انتخاب یک جمعیت جدید دنبال می‌شود، ۳-۱- انتخاب یکی از عملگرهای تقاطع، کپی و جهش، ۳-۲- انتخاب تعداد مناسبی از افراد جمعیت ۳-۳- استفاده از عملگر انتخاب شده برای تولید فرزندان (GEP برخلاف GP و GA چندین عملگر ژنتیکی برای تکثیر افراد با اصلاحات دارد (Lopes and Weinert, 2004)، ۳-۴- قرار دادن فرزندان در جمعیت جدید، ۳-۵- مدل با استفاده از برازش‌های مختلف مورد ارزیابی قرار می‌گیرد، ۴- گام سوم تا رسیدن به حداکثر تولید تکرار خواهد شد.

### ۳-۱-۳- مدل هوش مصنوعی مرکب نظارت شده (SICM)

یک مدل مرکب هوشمند دارای معماری موازی از مدل‌های هوش مصنوعی است که به وسیله ترکیب خروجی‌های مدل‌ها، خروجی منحصر به فرد و کلی با استفاده از مزایای همه مدل‌های درگیر حاصل می‌نماید (Chen and Lin, 2006). دو روش ترکیبی برای مدل‌های هوش مصنوعی عبارت است از میانگین‌گیری ساده و وزنی که نتایج میانگین‌گیری وزنی عموماً مقبولتر بوده است (Nadiri et al., 2013). آنها بر اساس فرمول‌بندی زیر اثبات کردند که مدل‌های ترکیبی خطای کمتر از هر یک از مدل‌های منفرد هوش مصنوعی خواهند داشت:

$$E_i = \left[ \left( \hat{GWL}_i - GWL \right)^2 \right] = \left[ e_i^2 \right] \quad (1)$$



### ۳-۲- آنالیز داده‌ها

از بین پیژومترهای موجود در دشت، ۱۴ پیژومتر بر اساس کامل بودن اطلاعات سطح آب برای مدل‌سازی انتخاب شدند. تعداد ۷ پیژومتر دارای داده سطح آب، در بازه زمانی مهر ۱۳۸۷ تا شهریور ۱۳۹۳ و تعداد ۷ پیژومتر در بازه زمانی مرداد ۱۳۸۲ تا شهریور ۱۳۹۳ می‌باشند. پس از آنالیز حساسیت و انتخاب ورودی‌های مختلف، در نهایت بارش ماهانه (P)، تبخیر ماهانه (E)، دبی خروجی ماهانه رودخانه اوجان (D) و سطح آب زیرزمینی پیژومترهای مربوطه (GWL) در گام زمانی ( $t_0$ ) به عنوان ورودی‌های مدل‌های زمانی مورد استفاده قرار گرفت. خروجی مدل‌های زمانی، سطح آب زیرزمینی در گام زمانی ( $t_0$ ) است. قابل ذکر است که از میان پیژومترهای انتخابی، ۵ پیژومتر آغچه‌کهل، بستان‌آباد نزدیک پل، بنه‌کهل، زگلوجه، قره‌بابا با کمبود داده در یک ماه و یا دو ماه مواجه بودند، که برای رفع این مشکل و همچنین جهت تصحیح داده‌های پرت از روش Spline استفاده شد. بارش ماهانه توسط ایستگاه باران‌سنجی بستان‌آباد، تبخیر ماهانه توسط ایستگاه تبخیرسنجی قوریگل، دبی خروجی رودخانه اوجان توسط ایستگاه هیدرومتری بستان‌آباد و سطح آب زیرزمینی پیژومترهای استفاده شده در این مطالعه توسط شرکت آب منطقه‌ای استان آذربایجان شرقی اندازه‌گیری شده است. در مدل‌سازی نیز مقدار ۸۰ درصد داده‌ها برای مرحله آموزش و ۲۰ درصد بقیه برای مرحله آزمایش مورد استفاده قرار گرفت. به دلیل وجود ناهمگنی در منطقه همچنین اجرای مدلی واحد برای پیژومترهایی که سطح آب زیرزمینی نزدیک به هم را دارند، پیژومترها بر اساس متوسط تراز سطح آب و متوسط نوسانات سالانه توسط نرم‌افزار SPSS (v. 21) خوشه‌بندی شدند. که بر این اساس، خوشه‌بندی سلسله‌مراتبی<sup>۱۲</sup> (HCA) و روش Ward's (که برای اندازه‌گیری تفاوت بین دسته‌ها از روش فاصله اقلیدسی<sup>۱۳</sup> استفاده شد) انتخاب گردید (Nadiri et al., 2013b). بدین ترتیب پیژومترهای دارای داده ۱۱ ساله با فاصله پیوندی ۹ که در این فاصله پیژومترهای یک دسته بیشترین شباهت را بر اساس پارامترهای ذکر شده برای دسته‌بندی دارند به دو دسته دوتایی و یک دسته سه‌تایی و پیژومترهای دارای داده ۶ ساله با فاصله پیوندی ۶ به دو دسته دوتایی و یک دسته سه‌تایی تقسیم شدند. نتایج آن در شکل ۵ (الف و ب) ارائه شده است. دسته ۱ شامل پیژومترهای (آغچه‌کهل و شیروانده)، دسته ۲ (خیرآباد و بستان‌آباد نزدیک پل)، دسته ۳ (کرگان، اکین‌آباد و بنه‌کهل)، دسته ۴ (قره‌وانه و زگلوجه)، دسته ۵ (موسی‌قیه، چرزه‌خون و قره‌بابا) و دسته ۶ (بستان‌آباد روبروی انبار جهاد و هلان) می‌باشد. در دسته‌بندی پیژومترها با داده ۱۱ ساله، پیژومترهایی که بیشترین متوسط نوسانات سالانه و متوسط تراز سطح آب نزدیک به هم را به خود اختصاص

گذشته در پارامترهای متفاوتی از قبیل تخمین هدایت هیدرولیکی و ارزیابی آسیب‌پذیری آب‌های زیرزمینی مورد استفاده قرار گرفته است (Fijani et al., 2013; Tayfur et al., 2014; Nadiri et al., 2017). شکل ۴ مدل هوش مصنوعی مرکب نظارت شده (SICM) را برای سه مدل هوش مصنوعی به کار گرفته شده به منظور پیش‌بینی سطح تراز آب، نشان می‌دهد که از یک شبکه عصبی مصنوعی به عنوان ترکیب کننده غیرخطی بهره گرفته است (شکل ۳). شبکه عصبی تنظیم وزن‌های ورودی هر نرون عصبی را با آموزش نظارت‌شده انجام می‌دهد. این روش آموزش شامل بهینه‌سازی و تنظیم تکراری وزن‌های اتصال و مقادیر آستانه برای هر یک از گره‌ها برای به حداقل رساندن تابع خطا می‌باشد. مدل هوش مصنوعی مرکب نظارت شده می‌تواند به صورت معادلات ریاضی (۷) تا (۹) بیان گردد، که در آن سطح آب زیرزمینی حاصل از هر یک از مدل‌ها به عنوان ورودی مدل هوش مصنوعی مرکب استفاده می‌شود.

$$\hat{GWL}_i = AI_i(P(t_{0-1}), E(t_{0-1}), D(t_{0-1}), GWL(t_{0-1})) \quad (7)$$

$$O_j = f_1\left(b_j + \sum_i w_{ji} \hat{GWL}_i\right) \quad (8)$$

$$O_k = \hat{GWL}_{SICM} = f_2\left(b_k + \sum_j w_{kj} O_j\right) \quad (9)$$

$\hat{GWL}_i$  خروجی مدل‌های هوش مصنوعی (سطح آب زیرزمینی) که به عنوان  $i$  ورودی برای شبکه عصبی مصنوعی محسوب می‌شود.  $f_1$  و  $f_2$  توابع فعال‌سازی به ترتیب برای لایه پنهان و خروجی هستند.  $O_j$  خروجی زمین‌گره در لایه میانی،  $w_{ji}$  و  $w_{kj}$  به ترتیب وزن‌های لایه مخفی و خروجی و  $b_j$  و  $b_k$  بایاس‌هایی هستند که به ترتیب برای تنظیم مقدار متوسط در لایه پنهان و لایه خروجی استفاده شده‌اند.  $O_k$  خروجی نهایی مدل هوش مصنوعی مرکب است (ASCE, 2000). در این مطالعه در مرحله اول سطح آب زیرزمینی با استفاده از مدل‌های هوش مصنوعی شامل FNN، RNN، FNN، GEP و پیش‌بینی گردید. و در مرحله دوم یک شبکه عصبی غیرخطی نظارت‌شده برای تخمین بهتر سطح آب زیرزمینی ایجاد گردید.




Fig. 4- Supervised Intelligent Committee machine  
شکل ۴- مدل هوش مصنوعی مرکب نظارت شده

داده‌اند شامل قره‌بابا، موسی‌قیه و چرزه‌خون در یک دسته و پیزومترهای بستان‌آباد روبروی انبار جهاد و هلان با کمترین متوسط نوسانات سالانه و متوسط تراز سطح آب نزدیک به هم نیز در یک دسته قرار می‌گیرند. این ویژگی در پیزومترها با داده ۶ ساله نیز صدق می‌کند. به طوری که پیزومترهای اکین‌آباد، بنه‌کهل و کرگان با بیشترین متوسط نوسانات سالانه در یک دسته و پیزومترهای آغچه‌کهل، شیروانه‌ده، با کمترین نوسانات سالانه و متوسط تراز آب نزدیک به هم در یک دسته قرار گرفته‌اند.

#### ۴- نتایج و بحث

##### ۴-۱- مدل‌سازی هوش مصنوعی

##### ۴-۱-۱- مدل‌های شبکه عصبی مصنوعی

برای اجرای مدل شبکه عصبی پیشرو و برگشتی برای هر دسته ابتدا تمام داده‌های ورودی ذکر شده در بخش آنالیز داده‌ها نرمال‌سازی شدند. در ابتدا سطح آب زیرزمینی پیزومترهای موجود در هر دسته توسط شبکه عصبی پیشرو پیش‌بینی گردید که از شبکه سه لایه با الگوریتم لونیبرگ-مارکوارت<sup>۱۴</sup> (LM) به‌عنوان تابع آموزش جهت تسریع همگرایی استفاده شد. تعداد بهینه گره‌های لایه میانی به روش آزمون و خطا و بر اساس کمترین خطای مدل برای شش دسته، سه گره تعیین گردید. همچنین تعداد گره‌های لایه خروجی بر اساس تعداد پیزومتر موجود در هر دسته مشخص گردید. تابع تبدیلگر در لایه میانی از نوع سیگموئید تانژانتی<sup>۱۵</sup> و در لایه خروجی خطی<sup>۱۶</sup> می‌باشد. تعداد ماکزیمم دوره‌های آموزش نیز تعداد ۵۰۰ برای تمامی دسته‌ها در نظر گرفته شد. به این ترتیب شبکه عصبی پیشرو برای ۳ دسته با داده ۱۱ ساله و ۳ دسته با داده ۶ ساله اجرا گردید. در دسته‌های ۱، ۲، ۳ و ۶ ماکزیمم دوره آموزش سبب توقف آموزش گردید و در دسته‌های ۴ و ۵ به ترتیب پس از ۳۹ و ۲۴۶ دوره آموزشی، آموزش متوقف شد. شبکه عصبی برگشتی با الگوریتم لونیبرگ-مارکوارت، تعداد ماکزیمم دوره

آموزش ۵۰۰ برای ۶ دسته اجرا گردید. تعداد بهینه گره‌های لایه میانی بر اساس آزمون و خطا برای دسته‌های ۱ تا ۶ به ترتیب ۲، ۴، ۳، ۴، ۳، ۵ تعیین گردید. همچنین تعداد گره‌های لایه خروجی بر اساس تعداد پیزومتر موجود در هر دسته مشخص شد. در شبکه عصبی برگشتی دوره‌های آموزشی برای دسته‌های ۱ تا ۶ به ترتیب ۲۷، ۱۹، ۱۸، ۲۲، ۲۱ و ۲۳ سبب توقف آموزش شدند. با توجه به نتایج حاصل از دو مدل که در شکل ۸ ارائه شده است، دو مدل بر اساس ضریب بازده نش-ساتکلیف (شکل ۸ الف و ب) و جذر میانگین مربع خطا (شکل ۸ ج و د) نتایج قابل قبولی را ارائه داده‌اند. مدل شبکه عصبی پیشرو بر اساس میانگین خطای مدل‌ها در هر دسته، در دسته‌های ۲ (خیرآباد، بستان‌آباد نزدیک پل)، ۶ (بستان‌آباد نزدیک انبار جهاد، هلان)، ۴ (قره‌اونه، زگلوچه) و ۳ (بنه‌کهل، اکین‌آباد، کرگان) بهترین نتیجه را حاصل کرده است. اما در دسته ۱ (شیروانه‌ده و آغچه‌کهل) نتایج با شبکه عصبی برگشتی مشابه است و در دسته ۵ (موسی‌قیه، چرزه‌خون و قره‌بابا) شبکه عصبی برگشتی خطای کمتری را حاصل کرده است.

علت کارایی بهتر مدل شبکه عصبی برگشتی در دسته ۵ با بیشترین متوسط نوسانات ماهانه در بین ۱۴ پیزومتر را می‌توان به ماهیت این مدل در وجود حداقل یک ارتباط برگشت در شبکه، تعدیل پذیری وزن‌ها و کاهش ابعاد ورودی شبکه در نتیجه آن کاهش زمان آموزش اشاره کرد.

##### ۴-۱-۲- مدل برنامه‌ریزی بیان ژن (GEP)

برای اجرای مدل GEP از ورودی‌های مشابه با مدل شبکه عصبی مصنوعی استفاده گردید. تعیین توابع و عملگرهای ریاضی در مدل‌سازی برنامه‌ریزی بیان ژن دارای اهمیت است زیرا این توابع و عملگرها در رابطه‌ای که بین ورودی‌های مدل در درخت بیان<sup>۱۷</sup> به وجود می‌آید تأثیر می‌گذارند.




Fig. 5- Clustering piezometers by HCA method, a) with 11-year data and b) With 6-year data

شکل ۵- خوشه‌بندی پیزومترها به روش HCA، الف) با داده ۱۱ ساله و ب) با داده ۶ ساله

یکی از فواید مدل‌سازی به روش برنامه‌ریزی بیان ژن ایجاد درخت بیان است. روابط حاصل شده هر زیر درخت برای پیژومترهای انتخابی در محدوده مطالعاتی که نشان‌دهنده تاثیر پارامترهای استفاده شده به عنوان ورودی در پیش‌بینی سطح آب زیرزمینی در زمان  $t_0$  می‌باشد، مطابق جدول ۳ ارائه شده است. در این روابط  $d_0, d_1, d_2, d_3$  به ترتیب نشان‌دهنده پارامترهای بارش در زمان  $(t_0-1)$ ، دبی خروجی رودخانه اوجان در زمان  $(t_0-1)$ ، سطح آب زیرزمینی در زمان  $(t_0-1)$  و تبخیر در زمان  $(t_0-1)$  می‌باشد. مقادیر  $GiCi$  به عنوان ضرایب ثابت در بیان درختی حاصل از مدل‌سازی هر پیژومتر در روابط جای‌گذاری شده‌اند. با توجه به این که مدل GEP نتایج قابل قبولی را ارائه داده است، ولی در مقایسه‌ی ضریب بازده نش- ساتکلیف و خطای مربوط به مدل‌های FNN و RNN، این دو مدل کارایی بهتری را در پیش‌بینی سطح آب زیرزمینی این دشت نشان می‌دهند. به طوری که بر اساس متوسط خطای پیش‌بینی هر دسته در مرحله آموزش و آزمایش بیشترین خطا برای مدل‌های FNN، RNN و GEP مربوط به دسته پنجم و به ترتیب ۴۷ سانتی‌متر، ۴۶ سانتی‌متر و ۵۲ سانتی‌متر می‌باشد. بر اساس نتایج ارائه شده سه مدل شکل ۷، پیژومترهای بنه‌کهل، موسی‌قیه، قره‌اونه، چره‌خون و قره‌بابا، بیشترین RMSE را نشان می‌دهند. دلیل این امر می‌تواند بالا بودن متوسط تغییرات ماهانه سطح آب زیرزمینی این پیژومترها در بین ۱۴ پیژومتر باشد که به ترتیب برابر با ۰/۴۷، ۰/۵، ۰/۵، ۰/۵۶، ۰/۸۴ متر می‌باشد. همان‌گونه که مشاهده می‌شود بیشترین خطا مربوط به پیژومتر قره‌بابا با ۰/۸۴ متر تغییرات متوسط ماهانه سطح آب زیرزمینی است.

در مرحله بعد به منظور تعیین بهتر توابع و عملگرها، پیژومتر مرکزی (موسی‌قیه) به عنوان پیژومتری که بیان‌گر ویژگی‌های کل دشت باشد برای مدل‌سازی انتخاب گردید. بر اساس مقایسه RMSE و  $R^2$  حاصل از کاربرد توابع مختلف ریاضی، تابع  $F_1$  به عنوان بهترین تابع عملگر برای مدل انتخاب گردید (جدول ۱). در مرحله بعد انتخاب تابع برازش با هدف یافتن راه‌حلی که برای تمامی موارد برازش به اندازه یک خطای معین به خوبی عمل کند (Ferreira, 2001)، تابع برازش RMSE مورد استفاده قرار گرفت. انتخاب ساختار و معماری کروموزوم شامل تعداد کروموزوم، طول سر (یا حد بالایی برای اندازه برنامه‌های کدگذاری شده در ژن) و تعداد ژن که برای پیژومتر مرکزی با روش آزمون و خطا تعیین گردید، به ترتیب برابر ۵۰، ۸ و ۳ است. همچنین از عملگر جمع (+) به عنوان تابع پیوند دهنده<sup>۱۸</sup> بین زیر شاخه‌ها استفاده گردید. در آخرین مرحله عملگرهای ژنتیک و نرخ آنها مطابق جدول ۲ برای اجرای مدل تعیین گردید.

با انجام مراحل ذکر شده مدل‌سازی با استفاده از نرم افزار GeneXproTools (v.4.0)، برای پیژومتر مرکزی و ۱۳ پیژومتر انتخابی دیگر به دلیل قابلیت نرم‌افزار در پیش‌بینی تنها یک خروجی، سطح آب پیژومترها به صورت منفرد پیش‌بینی گردید. در شکل ۶ نمودار پراکندگی حاصل از مدل‌سازی پیژومتر مرکزی که معرف ویژگی‌های کلی دشت است در مرحله آموزش و آموزش نشان داده شده است.

Table 1- Comparison of different types of functions and operators applied in the central piezometer modeling

جدول ۱- مقایسه حالات مختلف توابع و عملگرهای استفاده شده در مدل‌سازی پیژومتر مرکزی

Functions	Mathematical Functions Set	Train		Test	
		$R^2$	RMSE(m)	$R^2$	RMSE(m)
$F_1$	{x, +, -, +}	0.99	0.47	0.98	0.51
$F_2$	{e <sup>x</sup> , Ln, x, +, -, +}	0.97	0.67	0.91	1.12
$F_3$	{X <sup>3</sup> , X <sup>2</sup> , 3Rt, Sqrt, x, +, -, +}	0.97	0.67	0.91	1.11
$F_4$	{Ln, e <sup>x</sup> , X <sup>3</sup> , X <sup>2</sup> , 3Rt, Sqrt, x, +, -, +}	0.96	0.66	0.91	1.08
$F_5$	{Arctgx, Cosx, Sinx, Sqrt, 3Rt, X <sup>2</sup> , X <sup>3</sup> , e <sup>x</sup> , Ln, x, +, -, +}	0.97	0.65	0.91	1.1

Table 2- Genetic operators and optimal rates applied in the modeling of the central piezometer of Bostanabad Plain

جدول ۲- عملگرهای ژنتیک و نرخ بهینه مورد استفاده در مدل‌سازی پیژومتر مرکزی دشت بستان‌آباد

Genetic operators	Value	Genetic operators	Value
Mutation rate	0.044	One point recombination rate	0.3
Inversion rate	0.1	Two point recombination rate	0.3
IS transposition rate	0.1	Gene recombination rate	0.1
RIS transposition rate	0.1	Gene transposition rate	0.1



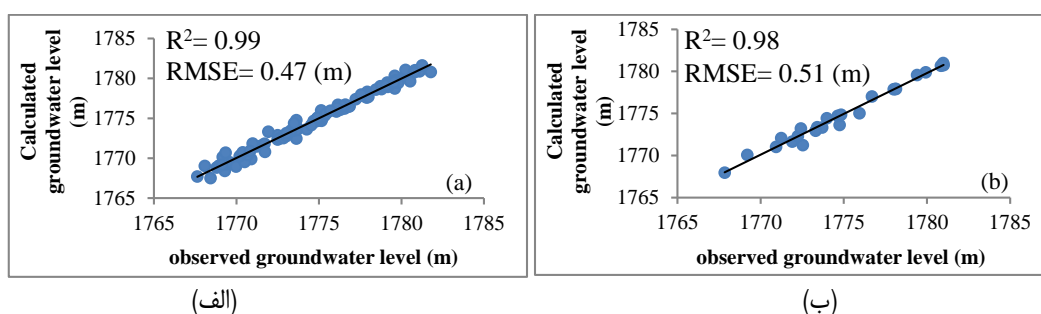


Fig. 6- Scatter plot obtained from central piezometer modeling a) training step and b) testing step  
 شکل ۶- نمودار پراکندگی حاصل از مدل‌سازی پیزومتر مرکزی الف) مرحله آموزش و ب) مرحله آزمایش

Tabele 3- Relationships obtained from each sub-tree to predict groundwater level in selected piezometers

Piezometer	Relationships obtained from each sub-tree to predict groundwater level
Shirvaneh deh	$GWL = ((2.33 - ((d_1 - 3.35) + d_2)) + d_3) + d_2 + (((3.85 + d_0) + d_3) + (d_1 - d_0)) - d_3 + ((-9.59 + d_2) - d_3)$
Agcheh kouhoul	$GWL = (7.32 + d_2) + (d_2/d_2) + (-8.46)$
Kheir Abad	$GWL = (-8.73 * (d_1 / (d_1 + ((d_1 + d_2 + d_1)))) + ((9.99 - d_3 - ((19.98) * 9.99))) / (d_2) + d_2$
Bostan Abad- pol	$GWL = d_2 + (((d_1 + d_1) * 8.21) / 4.45) / (d_2 + d_1) + (-7.88 / (((d_1 * d_3) + (d_2 - 7.88) / -7.88))$
Bostan Abad- anbarjahad	$GWL = ((d_0 + ((-9.43 * d_3) * d_1)) / (d_3 * (d_3 + d_1))) + (((-4.85 + 4.85) * -4.85) / d_2) + (((d_2 - 2.49) + 2.49) * 2.49) / 2.49$
Helan	$GWL = ((-0.99 - d_0) - (((d_1 - d_3) / -0.99) / d_2)) + (d_2 + d_0) + ((d_1 + d_2) / d_2)$
Gareh ovneh	$GWL = (-1.27 - (((d_0 + d_3) * 6.5) / ((-1.27 + d_2) + d_0))) + d_2 + 1.66$
Zegloujeh	$GWL = (((d_0 + d_1) * 5.39) - (d_3 + d_0)) / d_2 + ((d_1 - d_3) / ((d_2 + d_2) + d_0)) + ((7.91 / (((d_3 * -8.02) + d_2) + d_3)) + d_2)$
Mousa Kayeh	$GWL = ((1.87 + ((0.26 / (d_1 + 1.87))) + d_2) + (-1.97 - d_0) + (d_0 - d_3) / (((d_2 - d_3) - d_3) + (-0.54 + d_1)))$
Charzeh khun	$GWL = (-4.46 * (((d_0 + d_1) - d_3) / ((d_1 - d_1) - d_2))) + (-7.37 / (((d_3 + d_0) * d_3) - 9.52) - 9.52) + d_2$
Gareh baba	$GWL = 0.31 + (((((5.62 + d_3) + -9.40) * -9.40) / d_2) + d_2) + (-2.35 / (((d_3 - (d_1 + d_3)) - d_3))$
Behn kouhoul	$GWL = (((d_3 - 7.80) - d_0) * d_0) / (-3.90 * d_2) + d_2 + (8.33 / (((d_3 + d_1) + d_1) + d_1))$
Akin Abad	$GWL = d_2 + (7.55 / ((d_2 - ((d_1 * d_1) * d_0)) / 7.55)) + (((d_3 / -5.64) + 5.64) / (d_2 / (d_1 + 5.64)))$
Kargan	$GWL = (2.68 / (2.91 + d_1)) + ((-6.55 * ((d_3 + 2.80) - (d_1 / -2.80))) / d_2) + d_2$

هوش مصنوعی مرکب اجرا گردید. ساختار شبکه شامل لایه ورودی، لایه میانی و لایه خروجی است، تعداد گره‌های لایه ورودی با توجه به تعداد پیزومترهای موجود در هر دسته و تعداد مدل‌های استفاده شده تعیین شد به طوری که در دسته‌های شامل ۲ پیزومتر ۶ ورودی و در دسته‌های شامل ۳ پیزومتر ۹ ورودی تعیین گردید. تعداد گره‌های لایه خروجی که همان سطح آب پیش‌بینی شده توسط مدل در گام زمانی (t) است بر اساس تعداد پیزومترهای موجود در هر دسته تعیین گردید. همچنین تعداد بهینه گره‌های لایه میانی به روش آزمون و خطا برای دسته‌های ۱ تا ۶ به ترتیب ۵، ۴، ۴، ۴ و ۵ تعیین گردید. تابع تبدیل‌گر در لایه میانی از نوع سیگموئید تانژانتی و در لایه خروجی خطی می‌باشد. از الگوریتم لونیگ-مارکوارت به عنوان الگوریتم یادگیری استفاده شد. همچنین تعداد ماکزیمم دوره آموزش ۵۰۰ برای تمام دسته‌ها مشخص شد و ماکزیمم دوره آموزشی در همه دسته‌ها سبب توقف آموزش گردید. مقدار خطا و ضریب بازده نش-ساتکلیف بدست آمده از اجرای مدل برای هر دسته در شکل ۷ گزارش شده است. بر اساس متوسط خطای هر دسته در مرحله آموزش و آزمایش

با توجه به این موضوع که همه مدل‌های به کار گرفته شده در این تحقیق خطای قابل قبولی را ارائه داده‌اند، به طور قطع نمی‌توان یک مدل را به عنوان کارآمدترین مدل در پیش‌بینی سطح آب زیرزمینی این دشت معرفی کرد. بنابراین برای رسیدن به پیش‌بینی بهتر و همچنین استفاده از کارایی‌های هر سه مدل، از مدل مرکب نظارت شده برای این دشت استفاده گردید.

#### ۳-۱-۴- مدل هوش مصنوعی مرکب نظارت شده

برای ترکیب نتایج مدل‌های FNN، RNN اجرا شده برای دسته پیزومترها و مدل GEP اجرا شده برای پیزومترهای دارای داده‌های ۱۱ و ۶ ساله از مدل هوش مصنوعی مرکب نظارت شده استفاده گردید. در این مطالعه از یک شبکه عصبی مصنوعی پیشرو به عنوان ترکیب کننده غیرخطی نتایج استفاده شد. خروجی مدل‌های FNN، RNN اجرا شده برای هر دسته و خروجی مدل GEP اجرا شده برای ۱۴ پیزومتر به صورت منفرد بعد از نرمالیزه شدن به عنوان ورودی شبکه عصبی مصنوعی استفاده شدند. به این ترتیب برای هر دسته یک مدل

مقدار ورودی‌های مدل را بر سطح آب زیرزمینی منطقه مورد بررسی قرار داد تا از نتایج آن جهت مدیریت صحیح منابع آبی دشت به عنوان یکی از اهداف پیش‌بینی سطح آب زیرزمینی با حداقل خطا که با توجه به نتایج ارائه شده توسط مدل‌های هوش مصنوعی محقق شده، بهره‌برداری است.

در این تحقیق تأثیر کاهش ۳۰ و ۵۰ درصدی تخلیه از چاه‌های بهره‌برداری بر روی سطح آب زیرزمینی مورد بررسی قرار گرفت. با توجه به میانگین آبدهی ویژه ۴ درصد (First Consulting Engineering Company (2012) تغییرات افت ناشی از کاهش ۳۰ و ۵۰ درصدی تخلیه از چاه‌های بهره‌برداری محاسبه گردید و بر سطح آب زیرزمینی پیش‌بینی شده توسط ۳ مدل اجرا شده، به عنوان ورودی مدل هوش مصنوعی مرکب اعمال شد. در نهایت با استفاده از نتایج مدل هوش مصنوعی مرکب، شبیه‌سازی برای پیژومترهای موجود در ۶ دسته اجرا گردید. نتایج مربوطه در جدول ۴ گزارش شده است. با توجه به نتایج کاهش تخلیه از چاه‌های بهره‌برداری افزایش قابل توجه تراز سطح آب زیرزمینی مشاهده گردید. به جز پیژومتر آغچه‌کهل که کاهش تخلیه تأثیری بر سطح آب زیرزمینی نداشت که می‌توان بیان کرد که سطح آب در این پیژومتر کم‌تر تحت تأثیر برداشت قرار دارد.

برای مدل هوش مصنوعی مرکب اجرا شده نسبت به مدل‌های RNN و FNN، GEP دسته‌های ۱، ۲، ۳، ۴، ۵ و ۶ به ترتیب ۲۵٪ (۴ سانتی‌متر)، ۲۱٪ (۳ سانتی‌متر)، ۱۰٪ (۳ سانتی‌متر)، ۱۵٪ (۵ سانتی‌متر)، ۱۵٪ (۷ سانتی‌متر) و ۱۴٪ (۲ سانتی‌متر) کاهش خطا را نشان می‌دهند. همچنین با اجرای مدل مرکب، ضریب بازده نش-ساتکلیف پیژومترهای بستان‌آباد روبروی انبار جهاد، بستان‌آباد نزدیک پل و اکین‌آباد در مرحله آزمایش بهبود یافته است. بیشترین خطا در مدل عددی اجرا شده در منطقه، در انتهای کالیبراسیون (Jahedan (2008) ۷/۲ متر و مربوط به پیژومتر زگلوچه است. این در حالی است که مدل‌های هوش مصنوعی اجرا شده برای پیژومتر مذکور در بدترین حالت سطح آب زیرزمینی را با خطا ۰/۲۷ متر در مرحله آزمایش پیش‌بینی کرده است. این خطا در مدل هوش مصنوعی مرکب به ۰/۲۲ متر در مرحله آزمایش کاهش یافته است و این موضوع کارایی مدل‌های هوش مصنوعی را در پیش‌بینی سطح آب زیرزمینی با وجود پیچیدگی‌های هیدرولوژیکی موجود در منطقه و همچنین محدودیت در دسترسی به داده‌ها را نشان می‌دهد.

#### ۴-۲- تعریف سناریو

با توجه به مدل‌های هوش مصنوعی اجرا شده در دشت بستان‌آباد سناریویی تنظیم شد تا بر اساس آن بتوان تأثیرات افزایش یا کاهش

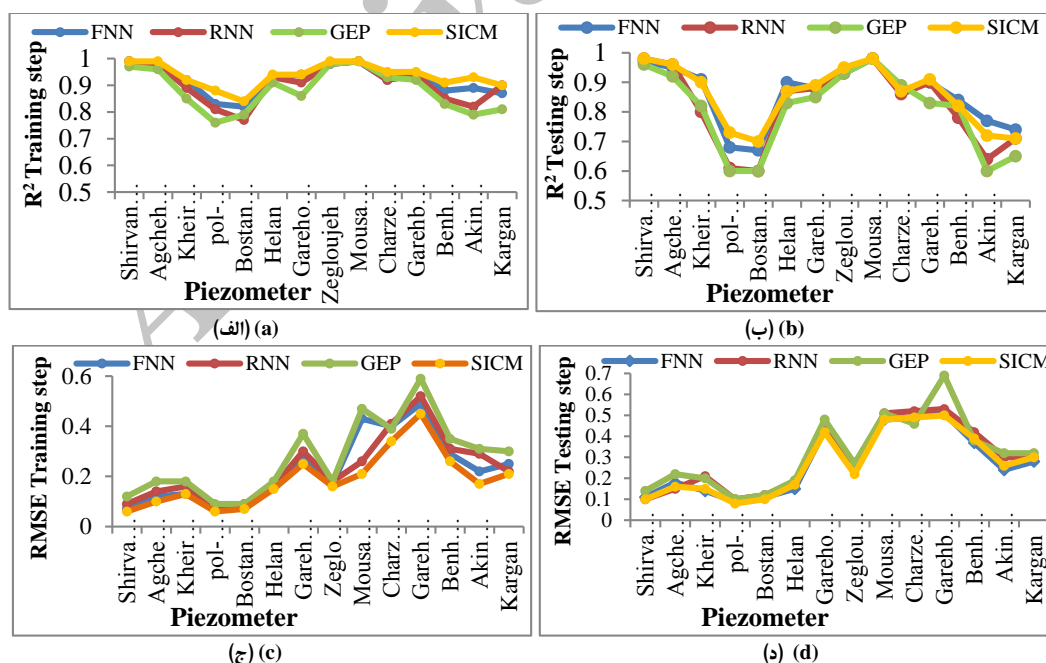


Fig. 7- Comparison of the models results for selected piezometers a)  $R^2$  : training step b)  $R^2$  : testing step c) RMSE(m) : training step d) RMSE(m): testing step

شکل ۷- مقایسه نتایج مدل‌های به کار گرفته شده برای پیژومترهای انتخابی الف)  $R^2$  مرحله آموزش ب)  $R^2$  مرحله آزمایش ج) RMSE(m) مرحله آموزش و د) RMSE(m) مرحله آزمایش

## ۵- نتیجه گیری

مدل با بهره‌گیری از مزایای همه مدل‌های اجرا شده توانست متوسط RMSE پیش‌بینی هر دسته را برای دسته‌های ۱، ۲، ۳، ۴، ۵ و ۶ به ترتیب ۴، ۳، ۳، ۵، ۷ و ۲ سانتی‌متر کاهش دهد. همچنین نتایج بیان داشت که مدل‌ها، سطح آب پیژومترهایی را که تغییرات متوسط ماهانه سطح آب کمتری دارند با دقت بالاتری پیش‌بینی می‌کنند. در نهایت با استفاده از نتایج پیش‌بینی حاصل از مدل هوش مصنوعی مرکب اجرا شده برای همه دسته‌ها، سطح آب زیرزمینی در پیژومترها در صورت کاهش ۳۰ و ۵۰ درصدی پمپاژ از چاه‌های بهره‌برداری شبیه‌سازی گردید. نتایج نشان داد که کاهش این پارامتر، در تمام پیژومترهای انتخابی سبب افزایش سطح آب زیرزمینی نشده است. بنابراین جهت مدیریت منابع آب در این دشت می‌بایست پاسخ پیژومترها نسبت به تغییر شرایط در نظر گرفته شود و بر اساس آن برنامه‌ریزی صورت گیرد. این موضوع همچنین نشان‌دهنده تأثیر بالای مقادیر پمپاژ نسبت به تغییرات آب و هوایی در منطقه می‌باشد. همین‌طور می‌توان پیشنهاد کرد، مناطقی که کاهش برداشت تأثیر کمی روی افزایش سطح آب داشته محل مناسبی برای جایگزینی حفر چاه‌های برداشت نسبت به برخی مناطق دیگر که با تأثیر بالایی رو به رو هستند می‌باشند.

در این مطالعه سطح آب زیرزمینی دشت بستان‌آباد با استفاده از روش‌های هوش مصنوعی مانند شبکه عصبی پیشرو، برگشتی و برنامه‌ریزی بیان ژن پیش‌بینی گردید. پارامترهای بارش، تبخیر، دبی خروجی رودخانه اوجان و سطح آب زیرزمینی در زمان (t0-1) به عنوان ورودی مدل‌ها استفاده شدند. بر اساس میانگین RMSE هر دسته برای هر مدل اجرا شده در این تحقیق، شبکه عصبی پیشرو جز در دسته ۱ که نتایج مشابهی با برگشتی دارد و دسته ۵ که مدل شبکه برگشتی بهتر عمل کرده است، نتایج بهتری را نسبت به دو مدل شبکه عصبی برگشتی و برنامه‌ریزی بیان ژن ارائه کرده است. برای رسیدن به خطای کمتر و همچنین استفاده از کارایی هر سه مدل به عنوان مدل‌های کارآمد در مدل‌سازی مسائل پیچیده و پیش‌بینی مسائل هیدرولوژیکی و هیدروژئولوژیکی از مدل هوش مصنوعی مرکب بهره گرفته شد. در این مطالعه برای اجرای مدل هوش مصنوعی مرکب، سطح آب زیرزمینی پیش‌بینی شده توسط سه مدل با به کارگیری مدل شبکه عصبی به صورت غیرخطی ترکیب شدند. نتایج نشانگر کارایی بالاتر مدل (SICM) نسبت به سه مدل اجرا شده دیگر می‌باشد. این

**Table 4- The impacts of reducing withdrawal from pumping wells in the area on groundwater level**  
جدول ۴- نتایج کاهش تخلیه از چاه‌های پمپاژ موجود در منطقه بر سطح آب زیرزمینی

Class	Piezometer	Average variations of groundwater level simulated by SICM model (m)	
		Reducing 50% of discharge	Reducing 30% of discharge
1	Shirvaneh deh	+0.36	+0.22
	Agcheh kouhoul	Zero	Zero
2	Kheir Abad	+0.35	+0.29
	Bostan Abad- pol	+0.28	+0.21
3	Benh kouhoul	+0.99	+0.55
	Akin Abad	+0.06	+0.02
	Kargan	+0.17	+0.08
4	Gareh ovneh	+0.73	+0.44
	Zegloujeh	+0.18	+0.11
5	Mousa Qayeh	+1.58	+0.95
	Charzeh khun	+0.55	+0.33
	Gareh baba	+1.38	+0.84
6	Bostan Abad- anbarjihad	+0.15	+0.09
	Helan	+1.14	+0.7

- 11- Nash-Sutcliffe Efficiency of Coefficient
- 12- Hierarchical Clustering Analysis
- 13- Euclidean Distance
- 14- Levenberg-Marquardt
- 15- Tansig
- 16- Purlin
- 17- Expression Tree
- 18- Linking Function

## پی‌نوشت‌ها

- 1- Artificial Intelligence
- 2- Artificial Neural Networks
- 3- Gene Expression Programming
- 4- Genetic Programming
- 5- Supervised Intelligent Committee Machine
- 6- Feedforward Neural Network
- 7- Recurrent Neural Network
- 8- Genetic Algorithm
- 9- Cauchy's Inequality
- 10- Root Mean Squared Error

- Bonab plain aquifer, Iran. *Journal of Hydrology* 503:89-100
- Yekom Consulting Engineering Company (2012) groundwater studies of Bostan Abad aquifer. Ministry of Energy- Regional Water Company of East Azarbaijan 1-6 (In Persian)
- Haykin S (1999) *Neural networks: A comprehensive foundation*. 2nd ed, Prentice-Hall, Englewood Cliffs, 842p
- Imani M, You RJ, Kuo ChY (2014) Forecasting Caspian sea level changes using satellite altimetry data (June 1992–December 2013) based on evolutionary supportvector regression algorithms and gene expression programming. *Journal of Global and Planetary Change* 121:53-63
- Jahedan N (2008) Hydrogeology study of Bostan Abad plain and presentation management solutions using mathematical models. Master's Thesis, Tabriz University (In Persian)
- Karimpouli S, Fathian Pour N, Roohi J (2010) A new approach to improve neural networks' algorithm in permeability prediction of petroleum reservoirs using supervised committee machine neural network (SCMNN). *Journal of Petroleum Science and Engineering* 73:227-232
- Ketabchi H, Ataie-Ashtiani B (2015) Review: Coastal groundwater optimization- advances, challenges, and practical solutions. *Hydrogeology Journal* 23:1129-1154
- Kumar ARS, Sudheer KP, Jain SK, Agarwal PK, (2005) Rainfall-runoff modeling using artificial neural networks: Comparison of network types. *Hydrological Processes* 19(6):1277–1291
- Liong SY, Gautam TR, Khu ST, Babovic V, Keijzer M, Muttil N (2002) Genetic programming: A new paradigm in rainfall runoff modeling. *Journal of the American Water Resources Association* 38 (3):705–718
- Lippman, R (1987) An introduction to computing with neural nets. *IEEE ASSP Mag* 4:4-22
- Lopes HS, Weinert WR (2004) EGIPSYS: An enhanced gene expression programming approach for symbolic regression problems. *International Journal of Applied Mathematics and Computer Science* 14(3):375-384
- Mehdipour FE, BozorghHaddad O, Marino MA (2013) Prediction and simulation of monthly groundwater levels by genetic programming. *Journal of Hydro-environment Research* 7(4):253-260
- Ahmadi F, Radmanesh F, Mirabbasi Najafabadi R (2014) Comparison of genetic programming and support vector machine methods in prediction of daily stream flow (Case study: Barandoezchay River). *Journal of Water and Soil (Agricultural Sciences and Technology)* 1(6):1162-1171 (In Persian)
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000). Artificial neural network in hydrology, partI and II. *Journal of Hydraulic Engineering* 5:2 115-137
- Ataie-Ashtiani B, Ketabchi H, Rajabi MM (2014) Optimal management of freshwater lens in a small island using surrogate models and evolutionary algorithms. *Journal of Hydrologic Engineering* ASCE 19(2):339-354
- Borelli A, De Falco I, Della C A, Nicodemi M, Trautteur G (2006) Performance of genetic programming to extract the trend in noisy data series. *Physica A: Statistical Mechanics and its Applications* 370(1):104-108
- Chen CH, Lin Z SH (2006) A committee machine with empirical formulas for permeability prediction. *Computer and Geoscience*. 32(4):485–49
- Chiang YM, Chang LCh, Chang FJ (2004) Comparison of static-feedforward and dynamic-feedback neural networks for rainfall–runoff modeling. *Journal of Hydrology* 290(3-4):297-311
- Coppola E, Szidarovszky F, Poulton M, Charles E (2003) Artificial neural network approach for predicting transient water level in a multilayered groundwater system under variable state, pumping, and climate conditions. *Journal of Hydrologic Engineering* 8(6):348-360
- Coulibaly P, Anclil F, Aravena R, Brnard B (2001) Artificial neural network modeling of water table depth fluctuations. *Water Resources Research* 37(4):885-896
- Daliakopoulos NI, Coulibaly P, Tsanis IK (2005) Groundwater level forecasting using artificial neural networks. *Journal of Hydrology* 309(1-4):229-240
- Ferreira C (2001) Gene expression programming: A new adaptive algorithm for solving problems. *Complex System* 13(2):87–129
- Fijani E, Nadiri A, Moghaddam A A, Tsai F T C, Dixon B (2013) Optimization of DRASTIC method by supervised committee machine artificial intelligence to assess groundwater vulnerability for Maragheh–

- river mouth. *Journal of Urban and Environmental Engineering* 3(1):1-6
- Nourani V, Moghaddam AA, Nadiri A O (2008) An ANN-based model for spatiotemporal groundwater level forecasting. *Journal of Hydrological Processes* 22:5054-5066
- Sharkey AJC (1996) On combining artificial neural nets. *Connection Science* 8:299-314
- Shiri J, Kisi O, Yoon H, Lee KK (2013) Predicting groundwater level fluctuations with meteorological effect implications—A comparative study among soft computing techniques. *Journal of Computers and Geosciences* 56:32-44
- Sulaiman M, Shafie A, Karim O, Basri H (2011) Improved water level forecasting performance by using optimal steepness coefficients in an artificial neural network. *Water Resources Management* 25(10):2525-2541
- Tayfur G, Nadiri AA, Moghaddam AA (2014) Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water Resources Management* 28:1173-1184
- Yang CC, Prasher SO, Lacroix R, Sreekanth S, Patni NK, Masse L (1997) Artificial neural network model for subsurface drained farmland. *Journal of Structural Engineering* 123:285-292
- Yoon H, Jun SC, Hyun Y, Bae GO, Lee KK (2011) A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology* 396:128-138
- Mitchell M (1996) An introduction to genetic algorithms. MIT Press, 158p
- Moghaddam AA, Nourani V, Nadiri A (2009) Prediction of temporal and spatial of groundwater level in Tabriz metro area using neural kriging models. *Journal of Iran-Water Resources Research* 5(1):14-24(In Persian)
- Nadiri A (2015) Application of artificial intelligence methods in geosciences and hydrology. OMICS Group International, 126p
- Nadiri A, Gharekhani M, Khatibi R, Sadeghfam S, Asghari Moghaddam A (2017) Groundwater vulnerability indices conditioned by supervised intelligence committee machine (SICM). *Journal Science of the Total Environment* 574:691-706
- Nadiri A, Moghaddam AA, Tsai FTC, Fijani E (2013b) Hydrogeochemical analysis for Tasuj plain aquifer, Iran. *Journal of Earth System Science* 122(4):1091-1105
- Nadiri AA, Fijani E, Tsai FTC, Moghaddam AA (2013a) Supervised committee machine with artificial intelligence for prediction of fluoride concentration. *Journal of Hydroinformatics* 15(4):1474-1490
- Naftaly U, Intrator N, Horn D (1997) Optimal ensemble averaging of neural networks. *Comput in Neural Systems* 8:283-296
- Nayak P, Rao YRS, Sudheer (2006) Ground water level forecasting in a shallow aquifer using artificial neural network approach. *Water Resources Management* 20:77-90
- Nourani V (2009) Using artificial neural networks (ANNs) for sediment load forecasting of Talkherood