

Assessment of GRNN model in comparison to ANN and RBF models for estimating confined aquifer parameters

Atefeh Delnaz¹, Gholamreza Rakhshandehroo²,
Mohammad Reza Nikoo^{*3}

Abstract

To achieve an appropriate management of groundwater resources, the accurate estimation of aquifer parameters is essential. In this study, several artificial intelligence models including, Artificial Neural Network (ANN), Generalized Regression Neural Network (GRNN) and Radial Basis Function (RBF) neural network have been developed to estimate the hydraulic parameters of a confined aquifer. One of the many reasons in using the artificial intelligence models to estimate the aquifer parameters, is their high flexibility, especially in non-linear problems. In order to implement these models, after gathering the pumping test data and reducing the dimensions of the data using the Principle Component Analysis (PCA), the artificial neural networks are trained and tested. Under the condition that the well function's error as the output of the artificial intelligence models, lies within an acceptable limit, then the values of aquifer parameters can be determined. The models are applied to a pumping test data in a confined aquifer and the results are compared with those of the graphical Theis curve method. Several statistical errors considering the results of the proposed artificial intelligence models and the graphical Theis curve method are compared and the performance of the models is examined. As an example, the Mean Absolute Relative Error (MARE) in estimating aquifer parameters for ANN model and graphical Theis curve method are 0.5564 and 1.1320 percent, respectively. To this regard, the GRNN is more precise and has much less computational time than the others and may be selected as a superior model in the estimation of confined aquifer parameters.

Keywords: Aquifer parameter estimation, Artificial intelligence models, Artificial neural network, Generalized regression neural network, Pumping test.

Received: 2016/08/26
Accepted: 2016/12/04

کارایی مدل GRNN در قیاس با مدل‌های ANN و RBF در تخمین پارامترهای آبخوان محبوس

عاطفه دل ناز^۱، غلامرضا رخشنده‌رو^۲، محمدرضا نیکو^{*۳}

چکیده

برای مدیریت صحیح منابع آب زیرزمینی، تخمین دقیقی از پارامترهای آبخوان لازم است. در این تحقیق، چندین مدل هوش مصنوعی شامل ANN، GRNN و RBF به منظور تخمین پارامترهای هیدرولیکی یک آبخوان محبوس تدوین شده است. یکی از دلایل استفاده از مدل‌های هوش مصنوعی در پیش‌بینی پارامترهای آبخوان، قابلیت انعطاف‌پذیری بالای این مدل‌ها، در حل مسائل غیرخطی می‌باشد. به منظور به کارگیری این مدل‌ها، پس از جمع‌آوری داده‌های مربوط به آزمایش پمپاژ و کاهش بعد داده‌ها با روش آنالیز مؤلفه‌های اصلی، به آموزش و آزمایش مدل‌های هوش مصنوعی مختلف پرداخته شده است. اگر خطای تابع چاه که متغیر خروجی مدل‌های هوش مصنوعی است، در حد قابل قبول باشد، مقادیر پارامترهای آبخوان به دست آورده می‌شود. مدل‌های مذکور بر روی داده‌های یک آزمایش پمپاژ در آبخوان محبوس آزمایش و نتایج آن‌ها با نتایج روش گرافیکی منحنی تایس مورد مقایسه قرار گرفته است. با قیاس چندین شاخص خطای آماری بر مبنای نتایج مدل‌های هوش مصنوعی پیشنهادی و حل گرافیکی مدل تایس، عملکرد مدل‌های مذکور، بررسی گردیده است. به عنوان مثال، میانگین قدر مطلق خطای نسبی در تخمین پارامترهای آبخوان برای مدل ANN و روش گرافیکی منحنی تایس، به ترتیب ۰/۵۵۶۴ و ۱/۱۳۲۰ درصد بوده است. همچنین در مقایسه مدل‌های مختلف هوش مصنوعی به کار گرفته شده، مدل GRNN از دقت مطلوب و مدت زمان محاسباتی کمتری در تخمین پارامترهای آبخوان برخوردار است و می‌تواند به عنوان مدل برتر در تخمین پارامترهای آبخوان، برگزیده شود.

واژه‌های کلیدی: آزمایش پمپاژ، تخمین پارامترهای آبخوان، شبکه عصبی مصنوعی، شبکه‌های عصبی رگرسیونی تعمیم داده شده، مدل‌های هوش مصنوعی.

تاریخ دریافت مقاله: ۱۳۹۵/۰۶/۰۵
تاریخ پذیرش مقاله: ۱۳۹۵/۰۹/۱۴

1- M.Sc. Student, School of Engineering, Department of Civil and Environmental Engineering, Shiraz University, Shiraz, Iran.

2- Professor, School of Engineering, Department of Civil and Environmental Engineering, Shiraz University, Shiraz, Iran.

3- Assistant professor, School of Engineering, Department of Civil and Environmental Engineering, Shiraz University, Shiraz, Iran.
E-mail: nikoo@shirazu.ac.ir

*- Corresponding Author

- دانشجوی کارشناسی ارشد سازه‌های هیدرولیکی، بخش مهندسی عمران و محیط‌زیست، دانشکده مهندسی، دانشگاه شیراز.

۲- استاد بخش مهندسی عمران و محیط‌زیست، دانشکده مهندسی، دانشگاه شیراز.

۳- استادیار بخش مهندسی عمران و محیط‌زیست، دانشکده مهندسی، دانشگاه شیراز.

*- نویسنده مسئول

مقدمه

نرمالیزه شدند) و قطر چاه بودند. مزیت اصلی استفاده از شبکه عصبی در تخمین پارامترهای آبخوان محبوس، این است که توانایی خوبی در تعیین ضریب ذخیره آبخوان دارد. این در حالی است که تعیین ضریب ذخیره آبخوان با روش‌های سنتی منحنی‌های تیپ، از نظر قابل اطمینان بودن و درست بودن سؤال برانگیز است. لین و چن (۲۰۰۶) با استفاده از مدل شبکه عصبی مصنوعی و ترکیب آن با معادله تایس، به تخمین پارامترهای آبخوان محبوس پرداختند. ایشان با تغییر پارامترهای ورودی و خروجی و تبدیل آن‌ها به یک تابع نگاشت لگاریتمی و استفاده از الگوریتم آموزش پس‌انتشار، یک مدل پیش‌بینی تخمین پارامترهای آبخوان محبوس را ارائه کردند. ایشان با آموزش و راستی آزمایی شبکه به‌وسیله ۱۰۲۰۱ داده غیرواقعی و مقایسه با مدل‌های شبکه عصبی مصنوعی ارائه شده توسط محققین قبلی، به این نتیجه رسیدند که مدل شبکه عصبی توسعه داده شده با ساختار پیشنهادی ایشان، با دقت بیشتر و مدت زمان کمتری قادر به تخمین پارامترهای آبخوان محبوس می‌باشد. سامانی و همکاران (۲۰۰۷) مدل شبکه عصبی پیشنهاد شده توسط لین و چن (۲۰۰۶) برای پیش‌بینی پارامترهای آبخوان محبوس را بهبود نمودند. ایشان الگوریتم لونبرگ-مارکوارت^۳ را به جای الگوریتم کاهش شیب^۴ جایگزین کردند، سپس با استفاده از روش آنالیز مؤلفه‌های اصلی^۵، بعد بردار ورودی به شبکه را کاهش دادند. این کار باعث تغییر معماری شبکه شد که علاوه بر افزایش کارایی شبکه، موجب کم‌شدن زمان محاسبات گردید. کاراهان و آیواز (۲۰۰۸) برای تعیین همزمان توزیع ضریب ذخیره و ضریب انتقال در یک آبخوان ناهمگن از شبکه عصبی مصنوعی پرسپترون چندلایه استفاده نمودند. ایشان جهت آزمایش مدل پیشنهادی خود، یک آبخوان فرضی را به صورت دوبعدی با جریان ناماندگار در *MODFLOW* مدل کردند و مقادیر تراز پیژومتریک را استخراج نمودند. در شبکه عصبی پیشنهادی توسط ایشان، ورودی‌ها شامل مختصات کارترین چاه مشاهده‌ای، تراز پیژومتریک حاصله از نتایج مدل *MODFLOW* و زمان بوده و ضرایب ذخیره و انتقال به‌عنوان خروجی‌های شبکه، در نظر گرفته شدند. پس از اجرای شبکه، حداقل خطای میانگین

مدل‌سازی و مدیریت آب‌های زیرزمینی نیاز به داشتن دانش درزمینه آبخوان و پارامترهای هیدرولیکی نظیر ضریب ذخیره، هدایت هیدرولیکی و ضریب انتقال دارد. به‌دست آوردن دقت قابل قبول در تخمین پارامترهای هیدرولیکی آبخوان‌ها با روش‌های قدرتمند و مؤثر، یکی از مسائل چالش برانگیز در پیشینه آب‌های زیرزمینی از زمان تایس (۱۹۳۵) می‌باشد. تعیین پارامترهای آبخوان، با استفاده از روش‌های معکوس، امری مرسوم و متداول می‌باشد. یکی از این روش‌ها، استفاده از نتایج آزمایش پمپاژ و تخمین پارامترها با روش‌های گرافیکی بر مبنای مدل‌های تحلیلی می‌باشد، که چندان دقیق نبوده و همراه با خطاهای انسانی می‌باشد. مرور پیشینه مطالعات نشان می‌دهد که روش‌های گوناگونی برای تخمین پارامترهای آبخوان وجود دارد. اما در سال‌های اخیر، به دلیل فواید مدل‌های هوش مصنوعی، محققین زیادی از شبکه‌های عصبی مصنوعی جهت تخمین پارامترهای هیدرولیکی آبخوان استفاده نمودند. یکی از دلایل استفاده از شبکه‌های عصبی مصنوعی در پیش‌بینی پارامترهای آبخوان، رفتار غیرخطی و پیچیده آبخوان و قابلیت انعطاف‌پذیری بالای شبکه‌های عصبی مصنوعی، در حل این‌گونه مسائل می‌باشد.

سایر و همکاران (۱۹۹۵) برای تخمین ضریب هدایت هیدرولیکی از شبکه عصبی مصنوعی^۱ پرسپترون چندلایه^۲ استفاده نمودند. داده‌های آموزشی و آزمایش شبکه پرسپترون در این مطالعه، در حدود ۱۲۰۰۰ داده بودند که محققین با معماری $11 \times 15 \times 1$ به بهترین عملکرد مدل رسیدند. داده‌های ورودی به شبکه شامل هدهای هیدرولیکی و خروجی آن تنها ضریب هدایت هیدرولیکی بود. در نهایت ایشان به این نتیجه رسیدند که هدهای به‌دست آمده از شبکه عصبی پرسپترون چندلایه، ۴۰٪ دقیق‌تر از هدهای متناظر بدست آمده از مقدار تخمینی هدایت هیدرولیکی در آزمایش پمپاژ می‌باشد. بالخیر (۲۰۰۲) برای تخمین پارامترهای آبخوان در چاه‌های با قطر زیاد، از *ANN* با الگوریتم آموزش پس انتشار استفاده نمود. داده‌های ورودی ایشان به مدل شبکه عصبی، شامل افت سطح آب در گام‌های زمانی (که این داده‌ها با تقسیم بر مقدار دبی،

3- Levenberg-Marquardt (LM)

4- Gradient Descent (GD)

5- Principle Component Analysis (PCA)

^۱- Artificial Neural Network (ANN)

^۲- Multilayer Perceptron (MLP)

آزمایش فوق توسط مدل‌های شبکه عصبی مصنوعی آموزش داده شده توسط الگوریتم‌های مختلف شامل پس‌انتشار، کاهش شیب و مدل بهینه‌سازی PSO ، شبیه‌سازی شد و از نتایج به دست آمده مشخص شد که شبکه عصبی آموزش داده شده با روش PSO ، مقادیر T و S را با کمترین خطا نسبت به سایر الگوریتم‌ها تخمین می‌زند.

اخیراً ساهین (۲۰۱۶) از روش نظم تابع پایه شعاعی^۴ برای تخمین پارامترهای آبخوان محبوس همگن و ناهمگن استفاده نمودند. ایشان برای بررسی کارایی مدل مذکور در تخمین پارامترهای آبخوان ناهمگن، یک آبخوان ناهمگن فرضی با چند چاه مشاهده‌ای برای یک چاه پمپاژ را در نرم‌افزار $MODFLOW$ مدل‌سازی نمودند. ایشان نشان دادند که مدل هوش مصنوعی مذکور پیشنهادی توسط ایشان، به پارامترهای اضافی، حدس اولیه، درون‌یابی و محاسبات پیچیده برای ارزیابی پارامترهای آبخوان نیاز ندارد. بنابراین روش پیشنهادی ایشان مبنی بر کاربرد مدل هوش مصنوعی $RBFCM$ ، در مقایسه با روش‌های موجود از انعطاف‌پذیری بیشتر و همان میزان دقت، در تخمین پارامترهای آبخوان برخوردار است. هدف ایشان در این تحقیق، جایگزین کردن مدل شبکه عصبی پیشنهادی لین و چن (۲۰۰۶) که توسط سامانی و همکاران (۲۰۰۷) تصحیح شده، با مدل $RBFCM$ می‌باشد که زمان محاسباتی کمتر و عملکرد بهتری نسبت به ANN دارد. در نهایت ایشان به این نتیجه رسیدند که روش پیشنهادی $RBFCM$ می‌تواند با تعداد کمتری داده برای دوره آموزش به‌طور مؤثری جایگزین ANN شود.

مرور پیشینه مطالعات نشان می‌دهد مدل‌های هوش مصنوعی از جمله شبکه‌های عصبی مصنوعی در تخمین پارامترهای هیدرولیکی آبخوان، قابلیت مناسبی داشته‌اند. باوجود اینکه مدل‌های هوش مصنوعی متنوعی از جمله شبکه‌های عصبی شعاع مبنای^۵ و شبکه‌های عصبی رگرسیونی^۶ تمهیم داده شده وجود دارند، اما به نظر می‌رسد تاکنون قابلیت RBF و $GRNN$ در تخمین پارامترهای هیدرولیکی آبخوان‌ها بررسی نشده است. هدف این مقاله مقایسه ساختار مدل شبکه عصبی پیشنهادی لین و چن (۲۰۰۶) که توسط

مربعات^۱ با معماری $4 \times 16 \times 1$ به دست آمد. ایشان به این نتیجه رسیدند که مقادیر ضرایب ذخیره و انتقال به دست آمده از شبکه عصبی پیشنهادی آن‌ها بسیار نزدیک به مقادیر واقعی آن‌ها است. گوهری مقدم و همکاران (۲۰۰۹) از سیستم استنتاج تطبیقی عصبی-فازی^۲ برای محاسبه پارامترهای آبخوان محبوس با استفاده از داده‌های آزمایش پمپاژ استفاده کردند. ایشان به این نتیجه رسیدند که مدل $ANFIS$ می‌تواند با تعداد کمتری داده برای دوره آموزش خود، نسبت به مدل شبکه عصبی مصنوعی، آموزش بهتری ببیند. ایشان همچنین در مورد مطالعاتی خود به این نتیجه رسیدند که مدل $ANFIS$ پیشنهاد شده، پارامترهای آبخوان را با دقت بهتر از مدل‌های گرافیکی و مدل ANN تخمین می‌زند و از جمله مزایای آن دقت بالاتر، زمان آموزش کمتر و ساختار مدلی ساده‌تر است. لین و همکاران (۲۰۱۰) کارایی شبکه عصبی مصنوعی پرسپترون چندلایه را در تخمین پارامترهای آبخوان محبوس، همگن و غیرایزوتروپ بررسی نمودند. ایشان با به‌کارگیری شبکه عصبی ارائه شده توسط لین و چن (۲۰۰۶) و نیز اعمال روش PCA پیشنهاد شده توسط سامانی و همکاران (۲۰۰۷) از ۴۰۰۰ داده جهت آموزش و ۱۰۰۰ داده جهت آزمایش شبکه، استفاده نمودند. در نهایت ایشان نتیجه گرفتند که هم روش شبکه عصبی مصنوعی پرسپترون چندلایه (بدون پیش‌پردازش) و هم روش $ANN-PCA$ (شبکه عصبی پرسپترون چندلایه پیش‌پردازش شده توسط آنالیز مؤلفه‌های اصلی) برای تخمین پارامترهای آبخوان مناسب می‌باشند و نتایج دقیق‌تری نسبت به حل گرافیکی دارند. ایشان به این نتیجه رسیدند که مدل شبکه پرسپترون بدون پیش‌پردازش، نتایج دقیق‌تری نسبت به شبکه با پیش‌پردازش دارند اما کارایی و سرعت اجرای مدل پرسپترون با پیش‌پردازش بیشتر است. چو و مادهیر (۲۰۱۲) پارامترهای آبخوان محبوس را به‌وسیله مدل شبکه عصبی مصنوعی تخمین زدند. ایشان به‌جای استفاده از الگوریتم پس‌انتشار، از روش بهینه‌سازی گروه ذرات^۳ برای آموزش مدل شبکه عصبی مصنوعی استفاده کردند. بعد از آموزش و راستی‌آزمایی شبکه، عملکرد آن به‌وسیله داده‌های دو آزمایش پمپاژ مورد آزمایش قرار گرفت. در این تحقیق، داده‌های

4- Radial Basis Function Collocation Method (RBFCM)

5- Radial Basis Function (RBF) neural network

6- Generalized Regression Neural Network (GRNN)

1- Mean Square Error (MSE)

2- Adaptive Neuro-Fuzzy Inference System (ANFIS)

3- Particle Swarm Optimization (PSO)

مینیمم داده‌های آزمایش از مینیمم داده‌های آموزش بیشتر باشند. همچنین به‌منظور تعیین بهترین مجموعه آموزش و آزمایش از آزمون لون^۱ و تی-تست^۲ در نرم‌افزار SPSS[®] استفاده شده است. در زیر بخش‌های بعدی این دو آزمون به تفصیل توضیح داده خواهند شد.

در گام سوم به آموزش و آزمایش مدل‌های هوش مصنوعی مختلف پرداخته شده است. نحوه انتخاب معماری هر مدل به این صورت می‌باشد که با آموزش مدل‌های هوش مصنوعی به ازای محدوده‌ای از پارامترهای متغیر تأثیرگذار در معماری شبکه نظیر تعداد نورون‌های لایه‌های میانی و پنهانی و شعاع توابع تأثیر، مدل‌ها اجرا می‌شوند. پس از آن با انتخاب بهترین تعداد نورون و بهترین شعاع تأثیر به گونه‌ای که کمترین میزان میانگین قدر مطلق خطای نسبی تابع چاه را داشته باشند، معماری شبکه انتخاب شده‌اند. برای مثال برای شبکه عصبی مصنوعی ابتدا معماری شبکه که شامل تعداد لایه‌ها، تعداد نورون‌های هر لایه، نوع توابع محرک، توابع یادگیری و ... می‌باشد، تعیین گردیده و شبکه پرسپترون چندلایه ساخته می‌شود.

پس از انتخاب معماری شبکه در مدل ANN با اجرای مکرر مدل به ازای معماری انتخاب شده، پارامترهای شبکه MLP تغییر و تنظیم و اصلاح می‌شوند. تنظیم این پارامترها بدین معنی است که به ازای یک نورون ثابت، به‌منظور رسیدن به وزن و بایاس بهتر با توجه به شروع از یک مقدار تصادفی برای وزن‌ها و بایاس‌ها در تکرار اول، مدل چندین بار اجرا شده و سپس شبکه‌ای که کمترین میزان خطا را دارد (از نقطه شروع بهتری برای مقادیر وزن و بایاس استفاده کرده است) به عنوان بهترین شبکه انتخاب می‌گردد. این روش آموزش شبکه‌های عصبی مصنوعی پرسپترون چندلایه، الگوریتم یادگیری پس-انتشار خطا نامیده می‌شود. همچنین برای بهبود سرعت همگرایی این الگوریتم، از الگوریتم لونبرگ-مارکوارت که یکی از روش‌های مؤثر بهینه‌سازی است، استفاده شده است (Azari et al., 2015). شبکه‌های GRNN برخلاف شبکه‌های ANN، نیازی به فرآیند آموزش مکرر همانند آموزش پس‌انتشار ندارند.

سامانی و همکاران (۲۰۰۷) تصحیح‌شده و آنالیز مؤلفه‌های اصلی روی آن صورت گرفته، با مدل‌های هوش مصنوعی دیگری نظیر GRNN و RBF و انتخاب مناسب‌ترین مدل می‌باشد.

روش تحقیق

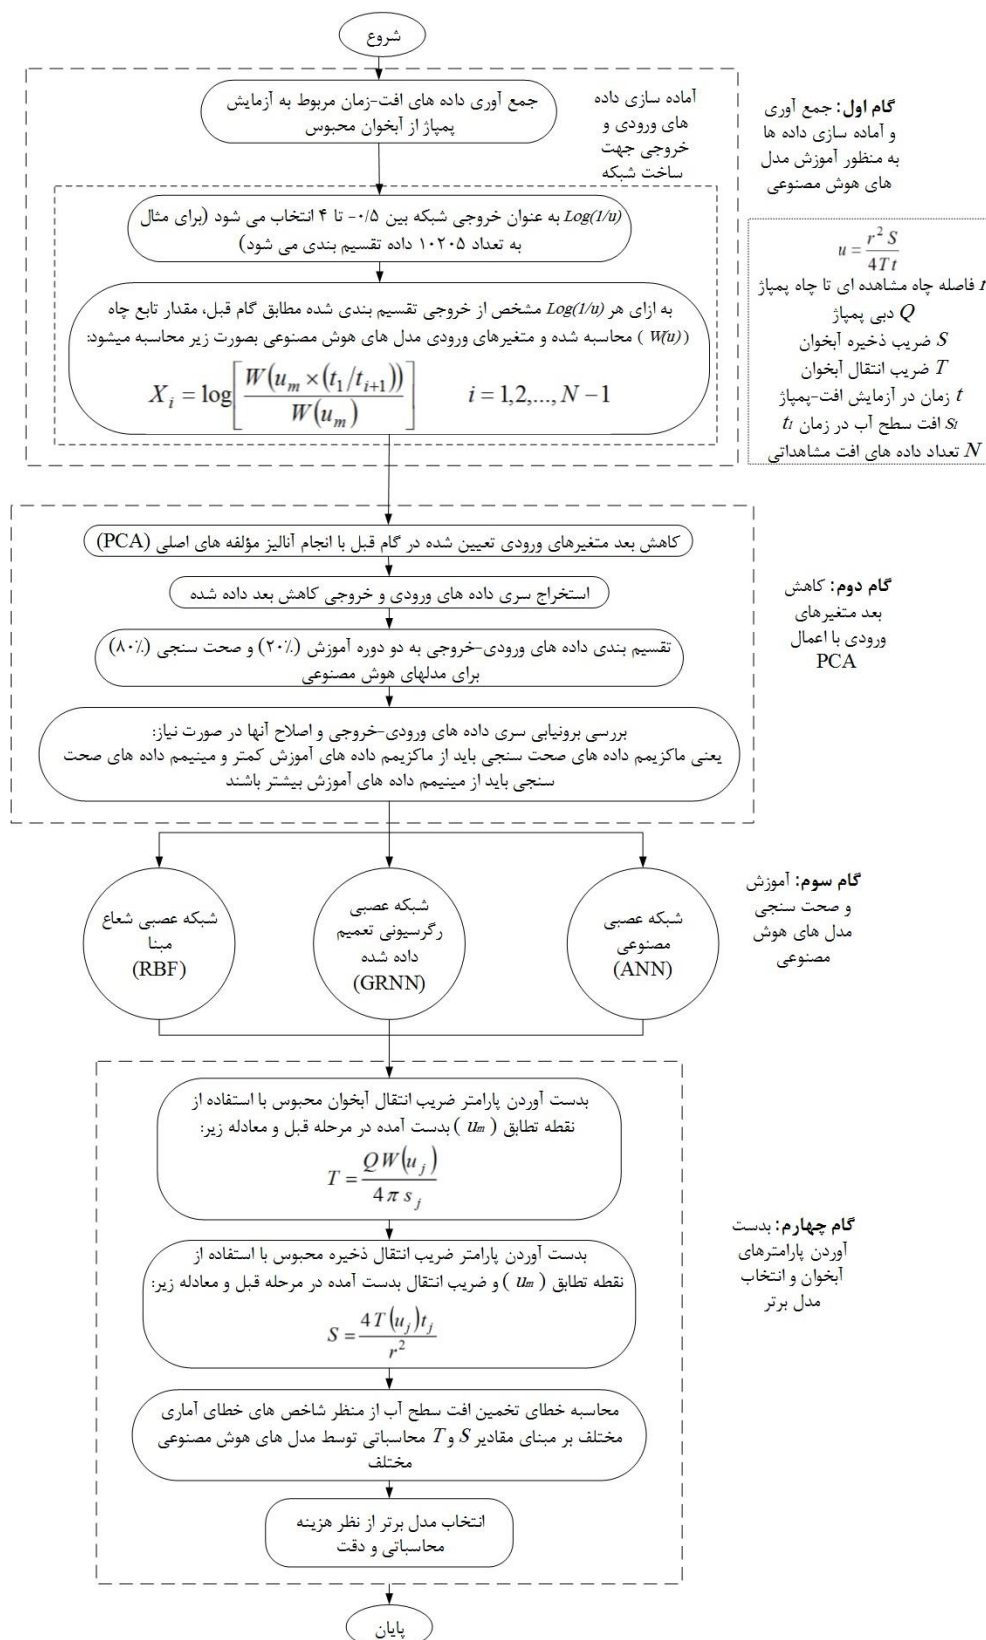
روش تحقیق را می‌توان به‌صورت گام‌های مختلف یک فلوچارت برای مدل‌های هوش مصنوعی، توضیح داد (شکل ۱). در گام اول داده‌های مربوط به آزمایش پمپاژ جمع‌آوری گردیده است و سپس جهت آماده‌سازی آن‌ها برای ورودی و خروجی مدل‌های هوش مصنوعی عملیاتی روی داده‌های افت-زمان صورت پذیرفته است. طبق منحنی‌های تیپ که توسط والتون (۱۹۶۰) ارائه شده است، $\log\left(\frac{1}{u}\right)$ همیشه از ۰/۵- بزرگ‌تر است. وقتی $\log\left(\frac{1}{u}\right)$ بزرگ‌تر از ۴ می‌شود، $\log(W(u))$ به سمت مقدار ثابتی میل می‌کند (لین و چن، ۲۰۰۶). بنابراین $\log\left(\frac{1}{u}\right)$ به عنوان خروجی مدل بین ۰/۵- تا ۴ به تعداد ۱۰۲۰۵ داده تقسیم‌بندی شده است. پس از آن به ازای هر یک $\log\left(\frac{1}{u}\right)$ مشخص از خروجی تقسیم‌بندی شده مقدار تابع چاه $(W(u))$ محاسبه شده است و سپس با داشتن گام‌های زمانی از آزمایش افت-پمپاژ ورودی مدل هوش مصنوعی مطابق زیر محاسبه گردیده است و داده‌های سنتز شده تولید می‌شوند.

$$x_i = \log \left[\frac{W(u \times (t_1/t_{i+1}))}{W(u)} \right] \quad i = 1, 2, \dots, N-1 \quad [1]$$

در معادله بالا N تعداد داده‌های افت مشاهداتی می‌باشد.

در گام دوم پس از آماده‌سازی داده‌های ورودی و خروجی مدل هوش مصنوعی، با استفاده از PCA اقدام به کاهش بعد داده‌ها شده است. در زیربخش‌های بعدی مفصل در مورد PCA توضیح داده خواهد شد. سپس داده‌ها به‌منظور آموزش شبکه به دو دوره آموزش (۸۰٪) و آزمایش (۲۰٪) تقسیم‌بندی شده‌اند. در این مرحله باید برونمایی داده‌های تقسیم‌بندی شده بررسی شود. به این معنی که ماکزیمم داده‌های آزمایش باید از ماکزیمم داده‌های آموزش کمتر و

1- Levene's test
2- T-test



شکل ۱ - فلوچارت تخمین پارامترهای آبخوان محبوس با استفاده از مدل های هوش مصنوعی مختلف.



شکل ۲- فلوچارت ساختار مدل های هوش مصنوعی مختلف.

تأثیری که کمترین میزان خطا را نه تنها در دوره آزمایش بلکه در دوره آموزش هم داشته باشد، بهترین شبکه را بدست می دهد.

پس از آموزش و آزمایش شبکه عصبی، خطای تابع چاه که متغیر خروجی مدل ANN است، در دوره آموزش و آزمایش محاسبه می شود. اگر این خطا در حد قابل قبول نباشد، معماری شبکه را تغییر داده و دوباره فرایند آموزش و آزمایش شبکه تا زمانی که خطای تابع چاه در حد قابل قبول شود، تکرار می گردد. سپس با استفاده از داده های افت چاه (معادله ۲) مدل ANN شبیه سازی می گردد و مختصات نقطه تطابق بر


مبنای $\log \left(\frac{1}{u_m} \right)$ بدست آورده می شود (شکل ۲).

در مورد شبکه های RBF و شعاع مبنا نیز باید گفته شود که تفاوت اساسی این نوع شبکه ها با شبکه های عصبی پرسپترون چندلایه، در بردار ورودی و تابع محرک است. شبکه های شعاع مبنا ساختار دولایه ای پیشخور دارای یک تک لایه پنهانی با تابع انتقال گوسین هستند. در قسمت های بعدی به تفصیل در مورد این شبکه ها توضیح داده خواهد شد.

برای اینکه از بهینه بودن و دقت معماری انتخاب شده در مرحله قبل (آزمایش) اطمینان حاصل نماییم، میزان ۲۰٪ از کل داده های سنتز شده به آزمایش (آزمون) هر مدل اختصاص داده شده است. پس از اجرای مدل ها به ازای تعدادی نورون و شعاع تأثیرهای مختلف، با محاسبه شاخص میانگین قدر مطلق خطای نسبی تابع چاه (خطای بین مقدار واقعی تابع چاه و خروجی مدل) در دوره آموزش و آزمایش، نورون و شعاع

پیرسون ارائه شد (پیرسون، ۱۹۰۱). این آنالیز شامل تجزیه مقادیرهای ویژه ماتریس کواریانس می‌باشد. آنالیز مؤلفه‌های اصلی در تعریف ریاضی یک تبدیل خطی متعامد است که داده را به دستگاه مختصات جدید می‌برد به طوری که بزرگ‌ترین واریانس داده، بر روی اولین محور مختصات، دومین بزرگ‌ترین واریانس بر روی دومین محور مختصات قرار می‌گیرد و همین‌طور برای بقیه. آنالیز مؤلفه‌های اصلی می‌تواند برای کاهش ابعاد داده مورد استفاده قرار بگیرد. به این ترتیب مؤلفه‌هایی از مجموعه داده را که بیشترین تأثیر در واریانس را دارند حفظ می‌کند. روش آنالیز مؤلفه‌های اصلی این امکان را به ما می‌دهد که ارتباط و همبستگی بین داده‌های مورد استفاده را به دست آوریم و بتوانیم ابعاد مجموعه داده‌ها را کاهش دهیم. همچنین این روش با کاهش محاسبات، باعث می‌شود در زمان صرفه‌جویی کنیم (والد و همکاران، ۱۹۸۷؛ جولیف، ۲۰۰۲).

در این روش متغیرهای موجود در یک فضای چند حالته همبسته به یک مجموعه از مؤلفه‌های غیرهمبسته خلاصه می‌شوند که هر یک از آن‌ها ترکیب خطی از متغیرهای اصلی می‌باشند. مؤلفه‌های غیرهمبسته به دست آمده، مؤلفه‌های اصلی^۱ نامیده می‌شوند که از بردارهای ویژه ماتریس کواریانس یا ماتریس همبستگی متغیرهای اصلی به دست می‌آیند. شکل ۳ پراکنش نقاطی را روی دو محور مختصات X_1 و X_2 نشان می‌دهد. برای تعیین جهت عمومی نقاط، یک بیضی رسم می‌شود تا همبستگی بین متغیرها مشخص شود.



شکل ۳ - انتقال داده‌ها به عوامل اصلی.

$$x_i = \log \left[\frac{s_{i+1}}{s_1} \right] \quad i = 1, 2, \dots, N-1 \quad [2]$$

در معادله ۲، N تعداد داده‌های افت مشاهداتی می‌باشد.

لازم به ذکر است که برای شبیه‌سازی مدل هوش مصنوعی، داده‌های ورودی به شبکه، با اعمال PCA روی معادله ۲ هستند.

در گام چهارم پس از آموزش و آزمایش شبکه، با داشتن $\log \left(\frac{1}{u_m} \right)$ به دست آمده از گام قبل و همچنین جهت برطرف نمودن خطای ناشی از در نظر گرفتن گام اول از داده‌های افت-زمان که توسط لین و چن (۲۰۰۶) پیشنهاد شده بود، نقطه تطابق برای تمامی گام‌های افت-زمان، بر مبنای روش پیشنهادی (Azari et al. (2015)، به صورت زیر محاسبه گردید:

$$y = \log \left[\left(\frac{1}{u_m} \right) \times \left(\frac{t_j}{t_1} \right) \right] \quad j = 1, 2, \dots, N \quad [3]$$

$$W(u_j) = W \left(\frac{1}{10^y} \right) \quad j = 1, 2, \dots, N \quad [4]$$

مقادیر ضریب انتقال و ضریب ذخیره آبخوان، با معلوم بودن مقدار دبی پمپاژ و با داشتن $W(u_j)$ ، s_j و t_j به ترتیب با استفاده از معادلات ۵ و ۶ به دست می‌آیند.

$$T = \frac{QW(u_j)}{4\pi s_j} \quad j = 1, 2, \dots, N \quad [5]$$

$$S = \frac{4T(u_j)t_j}{r^2} \quad j = 1, 2, \dots, N \quad [6]$$

در معادلات بالا، r فاصله چاه مشاهده‌ای تا چاه پمپاژ، Q دبی پمپاژ و N تعداد داده‌های افت مشاهداتی می‌باشد.

پس از به دست آمدن مقادیر پارامترهای آبخوان، خطای تخمین افت سطح آب از منظر شاخص‌های خطای آماری مختلف بر مبنای مقادیر پارامترهای آبخوان محاسباتی توسط مدل‌های هوش مصنوعی محاسبه می‌شود و مدل برتر از لحاظ مدت زمان محاسباتی و دقت انتخاب می‌شود.

آنالیز مؤلفه‌های اصلی

آنالیز مؤلفه‌های اصلی تبدیلی در فضای برداری است، که بیشتر برای کاهش ابعاد مجموعه داده‌ها مورد استفاده قرار می‌گیرد. آنالیز مؤلفه‌های اصلی در سال ۱۹۰۱ توسط کارل

1- Principle Component (PC)

شبکه پرسپترون چندلایه

شبکه‌های عصبی پرسپترون چندلایه، شبکه‌های پیش‌خور^۱ شامل یک یا چندلایه پنهانی می‌باشند. یکی از روش‌های آموزش شبکه‌های عصبی مصنوعی پرسپترون چندلایه که به‌طور گسترده‌ای استفاده می‌شود، قانون یادگیری پس‌انتشار^۲ خطا که مبتنی بر قانون یادگیری اصلاح خطا (حرکت در جهت منفی شیب لحظه‌ای تابع عملکرد (تابع خطا) که سبب کاهش خطای مدل می‌شود) است، می‌باشد (دی‌بی‌ک و سولماتین، ۲۰۰۱؛ نگنویتسکی، ۲۰۰۵). قانون پس‌انتشار خطا از دو مسیر اصلی تشکیل می‌شود. در مسیر اول، بردار ورودی به شبکه چندلایه اعمال می‌شود و تأثیراتش از طریق لایه‌های میانی به لایه‌های خروجی انتشار می‌یابد. بردار خروجی تشکیل‌یافته در لایه خروجی، پاسخ واقعی شبکه MLP را تشکیل می‌دهد. در مسیر دوم که به مسیر برگشت موسوم است، پارامترهای شبکه MLP تغییر و تنظیم می‌شوند. این تنظیم، مطابق با قانون اصلاح خطا انجام می‌گیرد. بدین ترتیب وزن نورون‌های لایه میانی به گونه‌ای تغییر می‌یابد که مقدار خطای بین خروجی شبکه عصبی و خروجی واقعی، حداقل گردد (گو، ۱۹۹۵؛ هاگان و همکاران، ۱۹۹۶؛ رفیق و همکاران، ۲۰۰۱). پس از توسعه شبکه عصبی مصنوعی، داده‌ها معمولاً برای دو دوره آموزش و آزمایش تقسیم‌بندی می‌شوند. قانون دقیقی برای تعیین حداقل اندازه مجموعه آموزش و آزمایش وجود ندارد. هر چند در مرور پیشینه مطالعات، پیشنهاداتی در این مورد شده است (بشیر و هاجمیر، ۲۰۰۰). مطابق این پیشنهادات، تقریباً ۸۰٪ کل داده‌ها برای آموزش شبکه کافی می‌باشد و ۲۰٪ باقیمانده برای آزمایش شبکه استفاده می‌شود (باوم و هوسلر، ۱۹۸۹؛ هایکین، ۱۹۹۴؛ دولا و راگرس، ۱۹۹۵؛ زارع و همکاران، ۲۰۱۳). شمای کلی شبکه عصبی MLP آموزش داده شده با الگوریتم پس‌انتشار در این تحقیق، در شکل ۴ نشان داده شده است. همان‌طور که در شکل مشخص است، تک‌تک نورون‌های هر لایه با نورون‌های لایه بعدی مرتبط می‌باشند. در این تحقیق، ساختار و معماری شبکه ANN بر مبنای سعی و خطای انجام‌شده بر روی تعداد نورون‌های لایه میانی، به صورت $۱ \times ۱ \times ۱$ در حالت بهینه بوده است. این شبکه

برخی از نقاط خارج بیضی و البته تجمع تعداد زیادی از آن‌ها روی قطر اصلی بیضی مشاهده می‌شود. جهت اصلی پراکنش نقاط نه در امتداد X_1 و نه در امتداد X_2 است بلکه بین آن‌ها و بیشتر در امتداد قطر اصلی بیضی می‌باشد. این محور PC_1 نامیده می‌شود که اولین جزء اصلی تغییرپذیری X_1 و X_2 می‌باشد. دومین جزء که PC_2 نامیده می‌شود، در امتداد قطر فرعی بیضی است که دقیقاً بر PC_1 عمود بوده و باقی تغییرات در X_1 و X_2 را شرح می‌دهد. PC_1 و PC_2 دو محور جدید برای شرح X_1 و X_2 می‌باشند. بنابراین می‌توان گفت X_1 و X_2 ترکیبی خطی از PC_1 و PC_2 است. یعنی:

$$x_i = a_{i1}PC_1 + a_{i2}PC_2 \quad [7]$$

همچنین می‌توان ارزش مؤلفه‌های اصلی را با استفاده از معادلات ۸ و ۹ به دست آورد:

$$PC_1 = w_1X_1 + w_2X_2 \quad [8]$$

$$PC_2 = w_3X_1 + w_4X_2 \quad [9]$$

به‌طوری که w_i ضریب رگرسیون اجزای اصلی روی متغیرها است.


مؤلفه‌های اصلی را می‌توان با استفاده از مجموعه داده‌های اصلی و در صورت عدم دسترسی به داده‌های اصلی با استفاده از ماتریس کوواریانس یا ماتریس همبستگی محاسبه نمود (فخری محدث، ۱۳۸۹).

تعداد مؤلفه‌های استخراج شده در هر مدل برابر است با تعداد متغیرهایی که بررسی می‌شوند. اما می‌توان تعداد مشخصی از این مؤلفه‌ها را انتخاب نمود. تعداد مؤلفه‌های اصلی باید طوری انتخاب شوند که حداقل ۹۰٪ از کل داده‌ها را در بر بگیرد. معمولاً دو یا سه مؤلفه اول، مقدار قابل توجهی از پراکندگی داده‌ها را در نظر می‌گیرد. بنابراین انتخاب دو یا سه مؤلفه اول برای ادامه کار کفایت می‌کند. لازم به ذکر است که، ۹۰٪ یک معیار منطقی و خوب است اما یک پژوهشگر ممکن است ۸۰٪ را بجای ۹۰٪ انتخاب کند. این مطلب اختیاری است و بستگی به همبستگی متغیرها دارد. یعنی اگر همبستگی‌ها ضعیف و تعداد متغیرها زیاد است، ممکن است درصد کمتری نیز در نظر بگیریم (فخری محدث، ۱۳۸۹، فرشادفر، ۱۳۸۹).

1- Feed-forward networks
2- Back propagation

می‌باشند. لایه ورودی^۳، لایه الگو^۴، لایه جمع‌کننده^۵ و لایه خروجی^۶ (سیگیزوگلو و آلپ، ۲۰۰۶). لایه ورودی اطلاعات مربوط به لایه ورودی را دریافت می‌کند و تعداد نورون‌ها برابر با بعد بردار ورودی می‌باشد. سپس نورون‌های ورودی از لایه ورودی، داده‌ها را به لایه الگو منتقل می‌سازند. لایه الگو یک تبدیل غیرخطی^۷ از فضای ورودی^۸ به فضای الگو^۹ را دارا می‌باشد. نورون‌های لایه الگو (که به‌عنوان نورون‌های الگو نیز شناخته می‌شوند)، می‌توانند رابطه بین نورون ورودی و پاسخ صحیح از لایه الگو، و تعداد نورون‌هایی که برابر با تعداد متغیرهای ورودی هستند را حفظ کنند. لایه جمع‌کننده شامل یک جمع‌کننده ساده و یک جمع‌کننده وزنی می‌باشد. جمع‌کننده ساده مجموع حسابی خروجی از لایه الگو را محاسبه می‌کند و وزن اتصال برابر ۱ است. جمع‌کننده وزنی مجموع وزنی خروجی از لایه الگو را محاسبه می‌کند. پس از اینکه نورون‌های جمع‌شده در لایه جمع‌کننده به لایه خروجی منتقل شدند، خروجی مدل *GRNN* می‌تواند محاسبه شود. در این شبکه‌ها، تعداد نورون‌ها در لایه خروجی برابر با بعد بردار خروجی است (لی و همکاران، ۲۰۱۳). شبکه‌های *GRNN* نیازی به فرآیند آموزش مکرر همانند روش الگوریتم آموزش پس‌انتشار ندارند (چن و همکاران، ۱۹۹۱؛ سیگیزوگلو و آلپ، ۲۰۰۶). این شبکه‌ها اطراف هر کدام از داده‌های مشاهداتی، شعاعی را در نظر می‌گیرد که هر کدام از داده‌های ورودی که در داخل آن شعاع قرار گیرد، آن داده را در تخمین خود برای یک مقدار ورودی جدید، درگیر می‌کند. شعاع تأثیر شبکه *GRNN* مورد استفاده در این تحقیق، بر مبنای آزمون و خطای انجام‌شده برای تعیین بهترین عملکرد مدل (حداقل خطای تخمین)، به میزان ۰/۰۰۰۱ تخمین زده شده است.

یک شبکه سه لایه‌ای است که ۱، ۱۱ و ۱ به ترتیب نمایانگر تعداد نورون‌ها در لایه ورودی، پنهانی و خروجی است. توابع محرک در این شبکه از نوع سیگموئید تانژانت هایپربولیک (*tansig*) و خطی (*purelin*) به ترتیب برای لایه پنهانی و لایه خروجی می‌باشد. نوع یادگیری شبکه نیز الگوریتم پس انتشار خطا و بر مبنای روش بهینه‌سازی لونیگ صورت پذیرفته است.




شکل ۴ - شمای کلی شبکه عصبی *MLP*.

شبکه‌های عصبی رگرسیونی تعمیم داده‌شده

شبکه‌های عصبی رگرسیونی تعمیم داده‌شده^۱، مجموعه‌ای از شبکه‌های *RBF* به همراه یک لایه خطی هستند (چن و همکاران، ۱۹۹۱). مدل *GRNN* بر مبنای یک روش آماری استاندارد به نام رگرسیون کرنل^۲ بنا نهاده شده است (سیگیزوگلو و آلپ، ۲۰۰۶؛ لی و همکاران، ۲۰۱۳). این شبکه‌ها همان‌طور که در شکل ۵ نشان داده شده است، شامل چهار لایه


3- Input layer
4- Pattern layer
5- Summation
6- Output layer
7- Non-linear transformation
8- Input space
9- Pattern space

¹- Generalized Regression Neural Network
²- Kernel regression



شکل ۵ - شمای کلی یک مدل شبکه عصبی مصنوعی GRNN.

تعداد ۱۲ نورون و شعاع تأثیر ۳/۷ به بهترین میزان عملکرد بر اساس سعی و خطای انجام شده، رسیدند.



شکل ۶ - شمای کلی یک مدل شبکه عصبی مصنوعی RBF.

تعیین بهترین مجموعه آموزش و آزمایش از آزمون لون و تی-تست

همان‌طور که ذکر شد، در این تحقیق، بر مبنای مطالعات پیشین، داده‌های ورودی مدل‌های هوش مصنوعی به دو دوره آموزش (۸۰٪) و آزمایش (۲۰٪) تقسیم‌بندی شدند. در ادامه، به منظور ارزیابی ماهیت اطلاعات قرار گرفته در هر دو

شبکه‌های شعاع مبنا

شبکه‌های عصبی شعاع مبنا، ساختار دو لایه‌ای شبکه پیش‌خور^۱ دارند که شامل یک تک‌لایه پنهانی با تابع انتقال گوسین هستند و تعداد نورون‌های لایه میانی نیز به تعداد مشاهدات می‌باشد (میسون و همکاران، ۱۹۹۶؛ دیبیک و همکاران، ۱۹۹۹؛ بولیناریا، ۲۰۰۴). این شبکه‌ها اطراف هر کدام از داده‌های مشاهداتی، شعاعی را در نظر می‌گیرد که هر کدام از داده‌های ورودی که در داخل آن شعاع قرار گیرد، آن داده را در تخمین خود برای یک مقدار ورودی جدید، درگیر می‌کند. ورودی شبکه‌های RBF غیرخطی و خروجی این شبکه‌ها خطی می‌باشد (چن و همکاران، ۱۹۹۱؛ هایکین، ۱۹۹۴). تفاوت اساسی شبکه‌های شعاع مبنا با شبکه‌های پرسپترون چندلایه، در بردار ورودی و تابع محرک است (دیبیک و سولماتین، ۲۰۰۱). در شبکه‌های RBF، ابتدا بردار فاصله میان بردار وزن و بردار ورودی به کمک یک ضرب اسکالر محاسبه می‌شود. سپس بردار حاصل در بردار اریب^۲ ضرب و حاصل ضرب آن به عنوان بردار ورودی شبکه در نظر گرفته می‌شود (چن و همکاران، ۱۹۹۱). شمای کلی شبکه عصبی RBF در شکل ۶ نشان داده شده است. در این تحقیق، در مورد شبکه RBF، محققین با

1- Two-layer feed-forward network
2- Bias

معنی‌داری بین مجموعه آموزش و آزمایش وجود ندارد و مجموعه‌های انتخاب‌شده در این تحقیق مناسب می‌باشند.

جدول ۱ - نتایج تعیین بهترین مجموعه آموزش و آزمایش با استفاده از آزمون لون و تی-تست.

آزمون تی-تست	آزمون لون به‌منظور برابری واریانس‌ها	مقدار معنی‌داری
به‌منظور برابری میانگین		
	با فرض برابر بودن واریانس‌ها	۰/۹۷۳
	با فرض نابرابر بودن واریانس‌ها	-

پس از آماده‌سازی داده‌های ورودی به مدل‌های هوش مصنوعی توسعه داده‌شده (پیش‌پردازش توسط روش PCA و انتخاب تعداد مؤلفه‌های اصلی مناسب و همچنین انجام آزمون لون و تی-تست)، این مدل‌ها به اجرا درآمده و آموزش داده شده و مورد آزمایش قرار گرفتند. سپس افت‌های محاسباتی در دوره آموزش و آزمایش تعیین گردیدند. پس از آن مقادیر افت محاسباتی تعیین‌شده توسط مدل‌های هوش مصنوعی با مقادیر افت مشاهداتی مقایسه گردید.

در این تحقیق، پس از آموزش و آزمایش شبکه، با داشتن $\log\left(\frac{1}{u_m}\right)$ به‌دست آمده و به‌منظور برطرف نمودن خطای ناشی از در نظر گرفتن گام اول از داده‌های افت-زمان، نقطه تطابق برای تمامی گام‌های افت-زمان بر مبنای روش پیشنهادی

Azari et al. (2015)، تصحیح گردید و پارامترهای آبخوان

محاسبه گردید. داده افتی $\left(\log\left(\frac{1}{u}\right), W_j, S_j, t_j\right)$ که حداقل

مقدار جذر نسبی میانگین مربعات خطا^۲ را به‌دست می‌دهد به عنوان نقطه تطابق بهینه انتخاب می‌شود. در آزمایش پمپاژ مورد استفاده در این مطالعه، در هر سه مدل GRNN، ANN و RBF، اولین گام افت-زمان، نقطه تطابق بهینه می‌باشد. برای

بخش آموزش و آزمایش و اطمینان از تعیین بهترین مجموعه ممکن برای آموزش و آزمایش مدل‌های هوش مصنوعی، از آزمون لون و تی-تست استفاده شده است. آزمون لون برای بررسی برابری واریانس‌های دو مجموعه آموزش و آزمایش به کار برده شده است. آزمون لون ابتدا فرضیات آزمون تی-تست (توزیع داده‌ها باید نرمال باشد و تغییرات هر دو مجموعه، تقریباً مساوی باشند) را بررسی می‌کند. با فرض برابر بودن واریانس هر دو مجموعه و برآورده شدن فرضیات مذکور توسط آزمون لون، آزمون تی-تست انجام می‌پذیرد. اگر مقدار معنی‌داری^۱ آزمون لون، بزرگ‌تر از یک مقدار معنی‌دار (معمولاً ۰/۰۵) باشد، نشان‌دهنده برابر بودن واریانس نمونه‌ها می‌باشد (لون، ۱۹۶۰). در این تحقیق به‌منظور انجام آزمون مذکور از نرم‌افزار SPSS[®] استفاده شده است.

نتایج


به‌منظور صحت‌سنجی و تخمین پارامترهای آبخوان محبوس، اطلاعات آزمایش پمپاژی که جزئیات آن در تاد و میز (۲۰۰۵) ارائه شده است، مورد استفاده قرار گرفت. مدل‌های هوش مصنوعی مختلف با اعمال PCA روی داده‌های ورودی به این مدل‌ها، تهیه شد. پس از انجام PCA روی داده‌های ورودی به مدل‌ها، آزمون لون و تی-تست صورت پذیرفته است. جدول ۱ خروجی نرم‌افزار SPSS[®] را پس از انجام آزمون لون و تی-تست به‌منظور بررسی ماهیت اطلاعات موجود در هر دو مجموعه آموزش و آزمایش و تعیین بهترین مجموعه آموزش و آزمایش مدل‌های هوش مصنوعی، نشان می‌دهد. همان‌طور که در جدول ۱ مشاهده می‌گردد، مقدار معنی‌داری آزمون لون برای داده‌های تقسیم‌بندی شده در این تحقیق ۱ بوده که از ۰/۰۵ بزرگ‌تر است، بنابراین فرضیه آزمون تی-تست ارضا شده و واریانس دو نمونه باهم برابر است. در صورت ارضاء فرضیه آزمون تی-تست، مقدار معنی‌داری آزمون تی-تست برای داده‌ها با فرض برابر بودن واریانس‌ها (ردیف اول جدول ۱)، و در غیر این صورت با فرض برابر نبودن واریانس‌ها گزارش می‌شود (ردیف دوم جدول ۱). در این تحقیق مقدار معنی‌داری آزمون تی-تست برای داده‌ها با فرض برابر بودن واریانس‌ها ۰/۹۷۳ است که از ۰/۰۵ بزرگ‌تر است. لذا از لحاظ آماری تفاوت

2- Root Relative Mean Square Error (RRMSE)

1- Significance (Sig.)

$$RRMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{S_o - S_c}{S_o} \right)^2} \quad [10]$$

نمونه نتایج تعیین نقطه تطابق بهینه بر اساس حداقل مقدار شاخص خطای $RRMSE$ برای مدل ANN در شکل ۷ ارائه شده است.



شکل ۷ - تعیین نقطه تطابق بهینه بر اساس حداقل مقدار شاخص خطای

$$RMRE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left| \frac{S_o - S_c}{S_o} \right|} \quad [14]$$

$$Bias = \frac{1}{n} \sum_{i=1}^n (S_o - S_c) \quad [15]$$

$$R^2 = \frac{\sum_{i=1}^n S_o S_c}{\sqrt{\sum_{i=1}^n S_o^2 \sum_{i=1}^n S_c^2}} \quad [16]$$

به منظور مقایسه مدل های هوش مصنوعی پیشنهادی، چندین معیار خطای آماری مختلف شامل میانگین قدرمطلق خطای نسبی^۱، جذر میانگین مربعات خطا^۲، میانگین قدرمطلق خطا^۳، جذر میانگین خطای نسبی^۴، اریب^۵ و ضریب همبستگی^۶ محاسبه شدند:

$$MARE = \frac{1}{n} \sum_{i=1}^n \left| \frac{S_o - S_c}{S_o} \right| \times 100 \quad [11]$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_o - S_c)^2} \quad [12]$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |S_o - S_c| \quad [13]$$

که در معادلات بالا، S_c افت محاسباتی، S_o افت مشاهداتی می باشند. پس از اجرای مدل های هوش مصنوعی ANN ، $GRNN$ و RBF ، مقادیر خروجی از این مدل ها (تابع چاه) به دست آمده و میانگین قدرمطلق خطای نسبی تخمین تابع چاه در دوره آموزش و آزمایش به دست آورده می شود (جدول ۲). لازم به ذکر است که جهت حل معادله تاپس در این تحقیق، از انتگرال گیری عددی در نرم افزار متلب استفاده شده است که این حل با حل تقریبی (سری تیلور برای $0 < u \leq 1$) برای تابع چاه هماهنگی دارد و مشکلی در محاسبه تابع چاه برای زمان های اولیه وجود ندارد. محققان

1- Mean Absolute Relative Error (MARE)

2- Root Mean Square Error (RMSE)

3- Mean Absolute Error (MAE)

4- Root mean relative error (RMRE)

5- Bias

6- Correlation coefficient (R^2)

دقت مطلوبی برخوردار نیست. به منظور درک بهتر روند تغییرات خطا در مدل‌های مختلف و قابلیت شاخص خطای *MARE* در تعیین میزان نسبی خطا، در شکل ۷ میانگین قدرمطلق خطای نسبی در تخمین پارامترهای آبخوان محبوس توسط مدل‌های هوش مصنوعی *ANN*، *GRNN* و *RBF* در قیاس با روش گرافیکی منحنی تاپس نشان داده شده است.

جدول ۳ - شاخص‌های خطای آماری تخمین افت سطح آب بر مبنای پارامترهای آبخوان محبوس توسط مدل‌های *ANN*، *GRNN* و *RBF* در قیاس با روش گرافیکی منحنی تاپس.

روش گرافیکی و مدل‌های هوش مصنوعی مختلف				شاخص‌های خطای آماری
<i>RBF</i>	<i>GRNN</i>	<i>ANN</i>	روش گرافیکی منحنی تاپس	
۱/۹۸۳۶	۰/۵۵۴۱	۰/۵۵۶۴	۱/۱۳۲۰	<i>MARE</i> (%)
۰/۰۱۰۸	۰/۰۰۵۲	۰/۰۰۵۲	۰/۰۰۸۵	<i>RMSE</i> (m)
۰/۰۱۴۹	۰/۰۰۳۰	۰/۰۰۳۰	۰/۰۰۶۵	<i>MAE</i> (m)
۰/۱۴۰۸	۰/۰۷۴۴	۰/۰۷۴۶	۰/۱۰۶۴	<i>RMRE</i>
۰/۰۱۴۹	۰/۰۰۰۳۱	۰/۰۰۰۱۸	-۰/۰۰۱۷	<i>Bias</i> (m)
۱	۱	۱	۰/۹۹۹۹	<i>R</i> ²


می‌توانند در صورت استفاده از حل تقریبی برای تابع چاه در مدل تاپس به این دو مرجع مراجعه کنند (Bateni et al., 1998; Tseng & Lee, 2015).

جدول ۲ - میانگین قدرمطلق خطای نسبی تابع چاه برای مدل‌های هوش مصنوعی مختلف در دوره آموزش و آزمایش.

مدل هوش مصنوعی			دوره آموزش/آزمایش
<i>RBF</i>	<i>GRNN</i>	<i>ANN</i>	
۱/۳۹۹۶	۰/۰۰۰۸۹	۰/۰۰۲۹	آموزش
۱/۱۵۸۱	۰/۰۶۱۱	۰/۰۰۲۲	آزمایش

همان‌طور که از جدول ۲ پیداست، مقادیر میانگین قدرمطلق خطای نسبی تابع چاه برای مدل *RBF* از بقیه مدل‌ها بیشتر است و انتظار می‌رود این روش، دقت کمتری نیز در محاسبه و تعیین پارامترهای آبخوان محبوس داشته باشد.

در جدول ۳ شاخص‌های خطای آماری تخمین افت سطح آب بر مبنای پارامترهای آبخوان محبوس تخمین‌زده شده توسط مدل‌های *ANN*، *GRNN* و *RBF* در قیاس با روش گرافیکی منحنی تاپس ارائه شده است. همان‌طور که از جدول ۳ مشخص است، مدل‌های *ANN* و *GRNN* در مقایسه با روش گرافیکی منحنی تاپس از دقت مطلوبی برخوردار هستند و می‌توانند جایگزین روش گرافیکی منحنی تاپس شوند. درحالی‌که مدل *RBF* نسبت به روش گرافیکی منحنی تاپس از



شکل ۸ - میانگین قدرمطلق خطای نسبی در تخمین پارامترهای آبخوان محبوس توسط مدل های هوش مصنوعی ANN، GRNN و RBF.

با توجه به جدول ۳ و شکل ۷ می توان نتیجه گرفت که مدل RBF با اینکه به تنهایی از دقت مناسبی در تخمین پارامترهای آبخوان برخوردار است، اما در قیاس با روش گرافیکی منحنی تاپس، میانگین قدر مطلق خطای نسبی بیشتری دارد. همچنین مدل های ANN و GRNN در مقایسه با روش گرافیکی منحنی تاپس دقت مطلوبی دارند و می توانند جایگزین روش گرافیکی منحنی تاپس شوند. میانگین قدر مطلق خطای نسبی در تخمین پارامترهای آبخوان محبوس

جدول ۴ - تخمین پارامترهای آبخوان محبوس با استفاده از مدل های ANN، GRNN و RBF و قیاس با روش گرافیکی منحنی تاپس.

روش گرافیکی و مدل های هوش مصنوعی مختلف				پارامترهای هیدرولیکی آبخوان محبوس
RBF	GRNN	ANN	روش گرافیکی منحنی تاپس	
۱۱۷۶/۵	۱۱۳۷/۸	۱۱۳۷/۵	۱۱۱۰	$T \text{ (m}^2/\text{min)}$
$1/9068 \times 10^{-4}$	$1/9352 \times 10^{-4}$	$1/9354 \times 10^{-4}$	$2/06 \times 10^{-4}$	S

- curve matching methods. *Iranian Journal of Science and Technology*, 39(A4), 463.
- Balkhair, K. S., 2002. Aquifer parameters determination for large diameter wells using neural network approach. *Journal of hydrology*, 265(1), 118-128 .
- Basheer, I., & Hajmeer, M., 2000. Artificial neural networks: Fundamentals, computing, design, and application. *Journal of microbiological methods*, 43(1), 3-31 .
- Bateni, S., Mortazavi-Naeini, M., Ataie-Ashtiani, B., Jeng, D., & Khanbilvardi, R. 2015. Evaluation of methods for estimating aquifer hydraulic parameters. *Applied Soft Computing*, 28, 541-549.
- Baum, E. B., Haussler, D., 1989. What size net gives valid generalization?. *Neural computation*, 1(1), 151-160 .
- Bullinaria, J. A., 2004. Introduction to neural networks. Lecture notes. University of Birmingham, UK .
- Ch, S., Mathur, S., 2012. Particle swarm optimization trained neural network for aquifer parameter estimation. *KSCCE Journal of Civil Engineering*, 16(3), 298-307 .
- Chen, S., Cowan, C. F., Grant, P. M., 1991. Orthogonal least squares learning algorithm for radial basis function networks. *IEEE Transactions on neural networks*, 2(2), 302-309 .
- Cigizoglu, H. K., Alp, M., 2006. Generalized regression neural network in modelling river sediment yield. *Advances in Engineering Software*, 37(2), 63-68 .
- Dibike, Y. B., Solomatine, D., Abbott, M. B., 1999. On the encapsulation of numerical-hydraulic models in artificial neural network. *Journal of Hydraulic research*, 37(2), 147-161 .
- Dibike, Y. B., Solomatine, D. P., 2001. River flow forecasting using artificial neural networks. *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 26(1), 1-7 .
- Dowla, F. U., Rogers, L. L., 1995. Solving problems in environmental engineering and geosciences with artificial neural networks: Mit Press, 239 p.
- Goh, A., 1995. Back-propagation neural networks for modeling complex systems. *Artificial Intelligence in Engineering*, 9(3), 143-151 .
- Gohari-Moghadam, M., Samani, N., Sleep, B., 2009. Aquifer parameter determination using a neuro-fuzzy approach. Paper presented at the International Conference on Water Resources: Emphasis on Regional Development, Shahrood University of Technology .

جمع‌بندی و نتیجه‌گیری

در این تحقیق کارایی مدل‌های هوش مصنوعی پیشنهادی بر اساس معادله تاپس، به‌منظور تخمین پارامترهای هیدرولیکی یک آبخوان محبوس بررسی گردید. برای بررسی عملکرد مدل‌های هوش مصنوعی پیشنهادی این مدل‌ها، با روش گرافیکی منحنی تاپس مورد مقایسه قرار گرفتند. نتایج نشان‌دهنده این است که مدل‌های ANN و GRNN در مقایسه با روش گرافیکی منحنی تاپس دقت مطلوب‌تری دارند و می‌توانند جایگزین روش گرافیکی منحنی تاپس شوند. ولی مدل RBF در مقایسه با روش گرافیکی منحنی تاپس از دقت کمتری برخوردار است. برای مثال میانگین قدر مطلق خطای نسبی در تخمین پارامترهای آبخوان برای مدل GRNN و روش گرافیکی منحنی تاپس، به ترتیب ۰/۵۵۴۱ و ۱/۱۳۲۰ درصد بوده است و لذا مدل GRNN می‌تواند جایگزین مناسبی برای حل گرافیکی مدل تاپس باشد. از طرف دیگر، گرچه مدل‌های ANN و GRNN از منظر شاخص خطای آماری میانگین قدر مطلق خطای نسبی در تخمین پارامترهای آبخوان تفاوت معنی‌داری باهم ندارند، اما از نظر مدت زمان محاسباتی (زمان اجرا) و سهولت استفاده می‌توان اشاره نمود که مدل GRNN نسبت به مدل ANN از مدت زمان محاسباتی کمتری برخوردار است. در نتیجه، در مقایسه مدل‌های هوش مصنوعی به کار گرفته شده مدل GRNN از دقت مطلوب و مدت زمان محاسباتی کمتری در تخمین پارامترهای آبخوان برخوردار است و می‌تواند به عنوان مدل برتر، برگزیده شود.

منابع و مراجع

- فرشادفر، ع.، ۱۳۸۹. اصول و روش‌های آماری چند متغیره. انتشارات دانشگاه رازی، ۳۱۲-۳۴۱.
- محدث، ف.، ۱۳۸۹. روش تحلیل مؤلفه‌های اساسی و بررسی عوامل، مطالعه موردی: استخراج شاخص قیمت دارایی‌ها و بررسی اثر آن بر تورم. مجموعه پژوهش‌های اقتصادی بانک مرکزی جمهوری اسلامی ایران.
- Azari, T., Samani, N., & Mansoori, E. 2015. An artificial neural network model for the determination of leaky confined aquifer parameters: An accurate alternative to type

- Rafiq, M., Bugmann, G., Easterbrook, D., 2001. Neural network design for engineering applications. *Computers & Structures*, 79(17), 1541-1552 .
- Sahin, A. U., 2016. A new parameter estimation procedure for pumping test analysis using a radial basis function collocation method. *Environmental Earth Sciences*, 75(3), 1-13 .
- Samani, N., Gohari-Moghadam, M., Safavi, A., 2007. A simple neural network model for the determination of aquifer parameters. *Journal of hydrology*, 340(1), 1-11 .
- Sawyer, C. S., Achenie, L. E., Lieuallen, K. K., 1995. Estimation of aquifer hydraulic conductivities: A neural network approach. *IAHS Publications-Series of Proceedings and Reports-Intern Assoc Hydrological Sciences*, 227, 177-184 .
- Theis, C. V., 1935. The relation between the lowering of the piezometric surface and the rate and duration of discharge of a well using ground-water storage. *Eos, Transactions American Geophysical Union*, 16(2), 519-524 .
- Todd, D. K., Mays, L. W., 2005 .*Groundwater hydrology*: John Wiley & Sons, USA, 636 p.
- Tseng, P.-H., & Lee, T.-C. 1998. Numerical evaluation of exponential integral: Theis well function approximation. *Journal of hydrology*, 205(1), 38-51.
- Walton, W. C., 1960. Leaky artesian aquifer conditions in illinois .
- Wold, S., Esbensen, K., Geladi, P., 1987. Principal component analysis. *Chemometrics and intelligent laboratory systems*, 2(1-3), 37-52 .
- Zare, M., Pourghasemi, H. R., Vafakhah, M., Pradhan, B., 2013. Landslide susceptibility mapping at vaz watershed (iran) using an artificial neural network model: A comparison between multilayer perceptron (mlp) and radial basic function (rbf) algorithms. *Arabian Journal of Geosciences*, 6(8), 2873-2888 .
- Hagan, M. T., Demuth, H. B., Beale, M. H., De Jesús, O., 1996. *Neural network design (Vol. 20) : PWS publishing company Boston*, 800 p.
- Haykin, S., 1994. *Neural networks: A comprehensive foundation: Macmillan college publishing company*. New York, 696 p .
- Jolliffe, I., 2002. *Principal component analysis: Wiley Online Library*, 271 p.
- Karahan, H., Ayvaz, M. T., 2008. Simultaneous parameter identification of a heterogeneous aquifer system using artificial neural networks. *Hydrogeology Journal*, 16(5), 817-827 .
- Levene, H., 1960. Robust tests for equality of variances1. *Contributions to probability and statistics: Essays in honor of Harold Hotelling*, 2, 278-292 .
- Li, H.-Z., Guo, S., Li, C.-J., Sun, J.-Q., 2013. A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm. *Knowledge-Based Systems*, 37, 378-387 .
- Lin, G.-F., Chen, G.-R., 2006. An improved neural network approach to the determination of aquifer parameters. *Journal of hydrology*, 316(1), 281-289 .
- Lin, H. T., Ke, K. Y., Chen, C. H., Wu, S. C., Tan, Y. C., 2010. Estimating anisotropic aquifer parameters by artificial neural networks. *Hydrological processes*, 24(22), 3237-3250 .
- Mason, J., Price, R., Tem'Me, A., 1996. A neural network model of rainfall-runoff using radial basis functions. *Journal of Hydraulic research*, 34(4), 537-548 .
- Negnevitsky, M., 2005. *Artificial intelligence: A guide to intelligent systems: Pearson Education*.
- Pearson, K., 1901. Liii. On lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 2(11), 559-572 .