

## تخمین پارامترهای هیدرودینامیکی آبخوان محبوس با استفاده از مدل فازی سوگنو

حامد محمودی حاجیلاری<sup>۱</sup>، عطاالله ندیری<sup>۲\*</sup>، طاهره آذری<sup>۳</sup>، سینا صادق فام<sup>۴</sup>، هادی محمودی حاجیلاری<sup>۵</sup>

۱. دانشجوی کارشناسی ارشد، دانشکده علوم طبیعی، دانشگاه تبریز
۲. دانشیار گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز
۳. دکتری هیدروژئولوژی، بخش علوم زمین شیراز، دانشگاه شیراز
۴. استادیار گروه مهندسی عمران، دانشکده فنی مهندسی، دانشگاه مراغه
۵. دانشجوی کارشناسی، دانشکده فنی مهندسی، دانشگاه آزاد اسلامی تبریز

(تاریخ دریافت ۱۳۹۶/۱۰/۱۱؛ تاریخ تصویب ۱۳۹۷/۰۴/۲۵)

## چکیده

شناخت دقیق پارامترهای هیدروژئولوژیکی مانند قابلیت انتقال، هدایت هیدرولیکی و ضریب ذخیره یا آبدهی ویژه از جمله پارامترهای مهم برای پیش‌بینی شرایط آبخوان هستند که عموماً تعیین آنها برای نقاط مختلف آبخوان با هزینه‌های فراوانی انجام می‌شود. در سال‌های اخیر، از مدل‌های هوش مصنوعی به عنوان جایگزین روش‌های انطباق منحنی تیپ برای تعیین پارامترهای هیدرودینامیکی آبخوان‌ها استفاده شده است. بنابراین، در مطالعه حاضر نیز برای تعیین پارامترهای هیدرودینامیکی آبخوان محبوس از منطق فازی سوگنو استفاده شد. ابتدا دقت، قابلیت اطمینان و توانایی تعمیم این مدل فازی از طریق آزمایش آن با داده‌های افت-زمان واقعی تأیید شد. سپس، نتایج به دست آمده از این مدل با نتایج به دست آمده از روش گرافیکی تائیس و شبکه عصبی مصنوعی مقایسه شد. مقایسه RRMSE مدل شبکه عصبی مصنوعی و مدل فازی به منظور تخمین قابلیت انتقال آبخوان و ضریب ذخیره در مرحله آزمایش نشان داد مدل فازی، خطا را به ترتیب ۹/۲۱ و ۱۱/۶۶ درصد نسبت به شبکه عصبی کاهش می‌دهد. بنابراین، نتایج به دست آمده از روش گرافیکی تائیس، شبکه عصبی مصنوعی و مدل منطق فازی در مرحله صحت‌سنجی نشان می‌دهند مدل فازی سوگنو در کنار دو روش یادشده توانایی تعیین پارامترهای آبخوان تحت فشار را دارد. این کارایی نسبی بیشتر منطق فازی سوگنو را می‌توان در توانایی ذاتی آن در کار با داده‌ها و پارامترهای دارای عدم قطعیت نسبت به روش گرافیکی تائیس و شبکه عصبی مصنوعی دانست.

**کلیدواژگان:** آبخوان محبوس، آنالیز مؤلفه اصلی (PCA)، شبکه عصبی مصنوعی، منحنی تیپ تائیس، منطق فازی سوگنو.

## مقدمه

یکی از اهداف مهم مدیریت و بهره‌برداری بهینه از آب زیرزمینی، پیش‌بینی شرایط آبخوان‌ها است که انجام این کار مستلزم شناخت دقیق پارامترهای هیدروژئولوژیکی شامل هدایت هیدرولیکی و ضریب ذخیره یا آبدهی ویژه است. هدایت هیدرولیکی، از مهم‌ترین این پارامترها است که بسیاری از خصوصیات جریان آب در محیط‌های متخلخل را از طریق آن می‌توان ارزیابی کرد چرا که پارامترهای دیگری نیز وجود دارند که مقادیرشان به هدایت هیدرولیکی وابسته است. به دلیل اهمیت زیاد این پارامتر در مطالعات آب‌های زیرزمینی و مدیریت یکپارچه و بهره‌برداری بهینه از منابع آب زیرزمینی، روش‌های آزمایشگاهی و صحرایی متنوعی طی سالیان گذشته توسعه پیدا کرده‌اند. از جمله روش‌های صحرایی تخمین هدایت هیدرولیکی می‌توان به روش‌های پمپاژ اشاره کرد. تا کنون چندین روش معمول برای آزمایش پمپاژ ارائه شده است [۱-۴]. همچنین، برای تعیین این پارامتر در آزمایشگاه نیز تا کنون چندین روش مشهور ارائه شده است [۵-۷]. روش آزمون پمپاژ بهترین روش برای شناخت دقیق پارامترهای هیدروژئولوژیکی است. یکی از روش‌های پردازش داده‌های آزمون پمپاژ، روش گرافیکی است که از سال ۱۹۳۵ برای بررسی آبخوان‌های تحت فشار استفاده شده است [۱]. این روش با وجود کارایی زیاد و توسعه وسیع، نقایصی دارد از جمله عدم قطعیت زیاد، وابسته‌بودن نتایج به کارشناس و زمان‌بر بودن و به تبع آن پرهزینه‌بودن است. اخیراً مدل شبکه‌های عصبی مصنوعی به منظور رفع نقایص یادشده برای روش‌های گرافیکی و پردازش داده‌های آزمون پمپاژ استفاده شده است. در مطالعات انجام شده در زمینه مدل‌های شبکه عصبی ایجادشده برای پردازش داده‌های آزمون پمپاژ، پس از اینکه منحنی تیپ تاپس به آن‌ها آموزش داده شد با یک هزار مجموعه داده افت-زمان سنتز شده بدون خطا آزمایش شده است. در نهایت، قابلیت تعمیم و عملکرد این مدل با استفاده از یک مجموعه داده پمپاژ واقعی ارزیابی شده و بررسی نتایج نشان داده است که این مدل می‌تواند جایگزین مناسبی برای روش‌های گرافیکی معمول باشد [۸-۱۰]. در مطالعه دیگری، سه مدل GRNN، ANN و RBF نیز به طور هم‌زمان و به منظور تعیین پارامترهای هیدرودینامیکی آبخوان تحت فشار استفاده شده‌اند و نتایج مقایسه سه مدل بیان‌کننده توانایی مدل GRNN نسبت به دو

مدل دیگر بوده است [۱۱]. مدل شبکه‌های عصبی مصنوعی از کاراترین روش‌های هوش مصنوعی است و به طور وسیعی در مدل‌سازی پارامترهای هیدرولوژیکی و هیدروژئولوژیکی استفاده شده است [۱۲-۱۹]. با وجود کارایی زیاد مدل‌های شبکه عصبی مصنوعی در مدل‌سازی سیستم‌های غیر خطی، مدل‌های فازی روش مناسب‌تری برای بررسی پارامترهایی با عدم قطعیت زیاد در بین روش‌های هوش مصنوعی است [۲۰]. از آنجا که پارامترهای هیدروژئولوژیکی نیز مقادیر قطعی و ثابت ندارند و در بیشتر مواقع با عدم قطعیت همراه هستند، برای تخمین این پارامترها احتمالاً مدل‌های منطق فازی مناسب‌تر خواهند بود [۲۱-۲۳]. در چند سال گذشته مطالعات مختلفی برای تخمین پارامترهای هیدروژئولوژیکی با استفاده از روش‌های منطق فازی انجام شده است [۲۴-۳۱]. بنابراین، در تحقیق حاضر کارایی مدل فازی سوگونو برای پردازش داده‌های آزمون پمپاژ در تخمین پارامترهای هیدروژئولوژیکی آبخوان تحت فشار ارزیابی شده و همچنین مقایسه میان نتایج این روش و روش گرافیکی تاپس صورت گرفته است تا روشی کارا برای پردازش داده‌های آزمون پمپاژ ارائه و نقایص کارهای قبلی برطرف شود. یکی از هدف‌های مهم در خور یادآوری افزایش دقت و سرعت در تعیین پارامترهای آبخوان تحت فشار است که تعیین هرچه دقیق‌تر این پارامترها سبب مدیریت بهتر منابع آب می‌شود.

## مواد و روش

آزمون‌های پمپاژ به طور وسیعی برای تعیین پارامترهای هیدرودینامیکی آبخوان استفاده می‌شوند. هنگامی که یک چاه پمپاژ کامل با میزان ثابت از یک آبخوان محبوس<sup>۱</sup> پمپاژ می‌شود، یک مخروط افت در سطح پیزومتریک آب زیرزمینی ایجاد می‌شود. اولین بار تاپس در سال ۱۹۳۵ راه حل تحلیلی برای پردازش داده‌های پمپاژ برای محاسبه پارامترهای هیدروژئولوژیکی ارائه کرد که در نهایت به روش گرافیکی منجر شد. حل تحلیلی تاپس [۱] معمولاً برای محاسبه ضریب ذخیره و قابلیت انتقال آبخوان محبوس هموژن و ایزوتروپ استفاده می‌شود. بر اساس روش تاپس، مقدار افت حاصل از پمپاژ در چاه‌های مشاهده‌ای در حالت ناپایدار با روابط ۱-۳ محاسبه می‌شود:

به دست آمده از مدل شبکه عصبی مربوط به هر یک از رکوردهای افت-زمان را به عنوان نقطه انطباق در نظر گرفتند و پارامترهای آبخوان را محاسبه کردند. رکوردی که پارامترهای آبخوان توسط آن محاسبه شده، کمترین ریشه میانگین مربعات خطای نسبی (RRMSE) را برای افت تخمین زده شده توسط مدل شبکه عصبی ایجاد کرد و به عنوان نقطه انطباق بهینه برای تعیین پارامترهای آبخوان در نظر گرفته شد. سپس، نتایج به دست آمده از مدل شبکه عصبی با نتایج به دست آمده از روش گرافیکی انطباق منحنی تیپ مقایسه شد. نتایج این تحقیقات نشان داد مدل شبکه عصبی می‌تواند پارامترهای آبخوان محبوس را با دقت و سرعت بیشتری نسبت به روش گرافیکی انطباق منحنی تیپ تعیین کند [۳۳].

موضوع درخور یادآوری این است که تا به حال از مدل منطق فازی برای تعیین و پیش‌بینی پارامترهای آبخوان تحت فشار استفاده‌ای نشده است. تمامی مراحل آموزش، آزمایش و صحت‌سنجی مدل منطق فازی مانند مدل شبکه عصبی ساخته شده توسط لین و چن در سال ۲۰۰۶ است. بنابراین، تفاوت میان تحقیق حاضر و تحقیقات یاد شده در مدل استفاده شده است. مدل طراحی شده در قالب یک برنامه رایانه‌ای در محیط نرم‌افزار متلب تهیه شد. این برنامه داده‌های آزمون پمپاژ را دریافت کرده و مقادیر پارامترهای آبخوان‌های محبوس [T,S] را برای کاربر محاسبه می‌کند. هدف تحقیق حاضر، طراحی مدل منطق فازی برای مدل‌سازی تابع چاه تاپس (رابطه ۱)، پیش‌بینی مختصات نقطه انطباق و تعیین پارامترهای آبخوان‌های محبوس و مقایسه نتایج به دست آمده از این روش با روش منحنی تیپ است. به رغم تعداد زیاد مقاله‌های کار شده در زمینه کاربرد روش منطق فازی در هیدرولوژی، تحقیقاتی در هیدرولوژی آب زیرزمینی و به خصوص تخمین پارامترهای آبخوان انجام نشده است. به منظور حل این مسئله، از یک مدل منطق فازی استفاده شد.

#### سیستم استنتاج فازی

تئوری فازی برای اولین بار در سال ۱۹۶۵ توسط لطفی‌زاده در مقاله‌ای با عنوان «مجموعه‌های فازی» ارائه شد [۳۴]. تئوری فازی، شامل تمام تئوری‌هایی می‌شود که از مفاهیم اساسی مجموعه‌های فازی یا توابع عضویت استفاده

$$s = \frac{Q}{4\pi T} W(u) \quad (1)$$

$$W(u) = \int_u^{\infty} \frac{1}{y} \exp(-y) dy \quad (2)$$

$$u = \frac{r^2 S}{4Tt} \quad (3)$$

که به ترتیب  $s$  مقدار افت اندازه‌گیری شده در زمان  $t$  در یک چاه مشاهده‌ای واقع در فاصله  $r$  چاه پمپاژ،  $T$  [L<sup>2</sup>T<sup>-1</sup>] قابلیت انتقال آبخوان<sup>۱</sup>،  $S$  ضریب ذخیره آبخوان<sup>۲</sup>، [L<sup>3</sup>T<sup>-1</sup>]  $Q$  دبی چاه پمپاژ و  $W(u)$  تابع چاه تاپس است.

تاپس در سال ۱۹۳۵ نمودار  $W(u)$  در مقابل مقادیر  $u$  را ترسیم کرده و منحنی تیپ آبخوان‌های محبوس را ایجاد کرد. برای تعیین مقادیر پارامترهای آبخوان محبوس (T و S) داده‌های افت-زمان مربوط به یک آزمون پمپاژ روی کاغذ لگاریتمی با مقیاس مشابه منحنی تیپ تاپس ترسیم می‌شود. منحنی افت-زمان روی منحنی تیپ تاپس قرار داده می‌شود، به گونه‌ای که محورهای مختصات هر دو منحنی با هم موازی باشد و بیشتر نقاط داده‌های مشاهده‌ای روی منحنی تیپ قرار گیرد. در این حالت یک نقطه انطباق انتخاب می‌شود. مختصات نقطه انطباق روی هر دو منحنی  $[\frac{1}{u}_m, W(u)_m, s_m, t_m]$  ثبت می‌شود. سپس، با استفاده از مقادیر مختصات نقطه انطباق و روابط ۱ و ۳ پارامترهای آبخوان (T و S) تعیین می‌شوند. پارامترهای آبخوان محاسبه شده با روش گرافیکی منحنی تیپ به دلیل خطاهای فردی و گرافیکی بحث‌برانگیزند. در سال‌های اخیر برخی روش‌های مناسب براساس شبکه‌های عصبی مصنوعی<sup>۴</sup> به عنوان یک روش جایگزین برای تعیین پارامترهای آبخوان توسعه یافته‌اند تا خطاهای ناشی از روش‌های گرافیکی انطباق منحنی تیپ<sup>۵</sup> را حذف کنند [۸، ۱۰، ۳۲ و ۳۳]. ساخت مدل‌های شبکه عصبی پس از اینکه منحنی تیپ تاپس به آنها آموزش داده شد، با یک هزار مجموعه داده افت-زمان سنتز شده بدون خطا آزمایش شد. در این مرحله آذری و همکارانش به منظور انتخاب نقطه بهینه برای تخمین دقیق پارامترهای هیدروژئولوژیکی آبخوان‌های محبوس، خروجی

1. Transmissibility
2. Storage coefficient
3. Well function
4. Artificial Neural Networks- ANNs
5. Type Curve Matching Techniques – TCMT

مجموعه الگوهای ورودی آموزش تولیدشده به عنوان بردار ورودی به مدل فازی استفاده شوند، باید مستقل بودن داده‌ها با استفاده از روش کاهش ابعاد داده<sup>۱</sup> بررسی شود [۳۶]. کاهش ابعاد داده‌ها معمولاً با استفاده از روش PCA انجام می‌شود [۳۷]. بنابراین، با نرمال‌سازی الگوهای ورودی آموزش و اعمال تکنیک PCA، ابعاد داده‌های ورودی کاهش می‌یابند و داده‌های اضافی حذف می‌شوند. PCA داده‌ها را به سیستم مختصات جدید تبدیل می‌کند، به گونه‌ای که بیشترین واریانس داده‌ها را به مختصات اول نسبت می‌دهد و مؤلفه اصلی اول را ایجاد می‌کند. همچنین، بیشترین واریانس دوم را به مختصات دوم اختصاص داده و مؤلفه اصلی دوم را می‌سازد. بنابراین، این روند با همین ترتیب پیش می‌رود تا مؤلفه‌ای که کوچک‌ترین مقدار واریانس را شامل می‌شود، ایجاد شود. وقتی آنالیز کامل شد، مؤلفه‌های به دست آمده درجه متفاوتی از همبستگی با متغیرهای مشاهده‌ای را نشان خواهند داد، اما به طور کامل با یکدیگر مرتبط نیستند. یکی از پارامترهای مهم در روش PCA، حداقل درصد واریانس<sup>۲</sup> است. با در نظر گرفتن یک حداقل درصد واریانس معین، می‌توان مؤلفه‌های اصلی که سهم کمتری از این مقدار را نسبت به واریانس کل در مجموعه داده‌ها دارند، حذف کرد و به این ترتیب ابعاد مجموعه داده‌ها، بدون اینکه هیچ اطلاعاتی از دست برود، کاهش داده می‌شود [۳۸]. سامانی و همکارانش [۸] و لین و همکارانش [۱۰] با موفقیت از روش PCA برای کاهش ابعاد بردارهای ورودی استفاده کردند و یک شبکه با ساختار ثابت برای تعیین دقیق پارامترهای آبخوان‌های محبوس ایزوتروپ، آیزوتروپ و آبخوان‌های محبوس نشتی طراحی کردند. جدول ۱ پارامترهای PCA الگوهای آموزش  $X_i$  را که با استفاده از رابطه ۴ تولید شده، نشان می‌دهد. مؤلفه‌های اصلی با در نظر گرفتن کمترین درصد واریانس ۰/۱ درصد استخراج شدند. همان‌گونه که مشاهده می‌شود، مؤلفه اصلی اول ۹۹/۹۰۶ درصد از واریانس کل داده‌های آموزش را شامل می‌شود. واریانس محاسبه‌شده توسط مؤلفه دوم کوچک‌تر از حداقل درصد واریانس است (۰/۰۹۳۹ < ۰/۱) بنابراین می‌توان از آن صرف نظر کرد. این موضوع نشان می‌دهد عناصر بردار ورودی آموزش می‌تواند با یک عنصر به

می‌کند. منطق فازی به عنوان جایگزینی برای توضیح عدم قطعیت استفاده شده است. مجموعه‌های فازی مرزهای مبهم و تدریجی بین مرزهای تعریف‌شده دارند، که برای مقابله با ماهیت عدم قطعیت در سیستم و خطاهای انسانی مناسباند [۲۰].

هر مجموعه فازی به وسیله یک تابع عضویت نشان داده می‌شود. تابع عضویت اشکال مختلفی مانند گوسی، مثلثی، دوزنقه‌ای، سیگموئید و غیره دارد. هر سیستم فازی شامل سه بخش اصلی می‌شود: ۱. فازی کردن داده‌ها؛ ۲. سیستم استنتاج فازی (قوانین فازی)؛ ۳. غیرفازی سازی داده‌ها. در فازی سازی، ورودی‌ها از طریق تابع عضویت مربوط به مجموعه فازی مناسب تغییر می‌یابند و نتایج فازی سازی شده از طریق سیستم استنتاج فازی به دست می‌آید. در مرحله آخر از اجتماع خروجی‌ها و غیرفازی سازی آنها نتایج نهایی به دست می‌آید. بر اساس نوع تابع عضویت، مدل فازی به دو نوع ممدانی و سوگنو تقسیم می‌شود. در روش ممدانی توابع عضویت خروجی، مجموعه‌های فازی هستند، اما در مدل سوگنو خروجی به صورت ثابت یا خطی است که توسط روش دسته‌بندی به دست می‌آید [۳۵].

## نتایج

### تولید الگوهای ورودی آموزش

برای تولید الگوهای آموزش مدل فازی، ابتدا مقادیر  $\log\left(\frac{t_i}{u}\right)_m$  در محدوده (۰/۵ - تا ۴)، مطابق منحنی تیپ ارائه شده توسط تاپس به عنوان خروجی (هدف) مدل فازی انتخاب شدند [۳]. بنابراین، ۱۰۲۰۵ مجموعه بردار ورودی آموزش که هر یک N-1 عنصر دارند با انتخاب بازه  $\log\left(\frac{t_i}{u}\right)_m$  برای ۰/۰۰۰۴۴۱ تولید شدند که در شکل ۲ نشان داده شده است. بر این اساس، اندازه ماتریس داده ورودی  $[(N-1) \times 10205]$  است. سپس، برای همه مجموعه‌های  $\left[\log\left(\frac{t_i}{u}\right)_m\right]$  تابع چاه  $W(u)$  با استفاده از رابطه ۲ محاسبه شد. در مرحله بعد الگوهای آموزش  $X_i$  با معادله ۴ و مطابق شکل ۱ تولید شد:

$$X_i = \log \left[ \frac{W(u_m \times t_i / t_{i+1})}{W(u_m)} \right] \quad (4)$$

اندیس m به نقطه انطباق اشاره می‌کند و  $i=1, 2, \dots, N-1$  که N تعداد داده‌های افت-زمان است. قبل از اینکه

سوگنو استفاده شد. برای خوشه‌بندی داده‌ها، از روش خوشه‌بندی کاهشی استفاده شد. مهم‌ترین پارامتر در این روش شعاع خوشه‌بندی است که براساس کمینه RRMSE تعیین می‌شود. نتایج نشان داد بهینه‌ترین شعاع خوشه‌بندی ۰/۱ است که مقدار کمینه RRMSE را برابر  $10 \times 7/08$  ایجاد می‌کند. پارامترهای به کار گرفته‌شده طی فرایند آموزش در جدول ۲ نشان داده شده‌اند.


جای تعداد رکوردها در داده‌های افت-زمان که در هر آزمون پمپاژی تغییر می‌کند، ثابت شود. بنابراین، کاربرد PCA تعداد عناصر بردار ورودی و نیز مدت زمان لازم برای آموزش و آزمایش مدل فازی را کاهش می‌دهد.

### ساخت مدل فازی

در این قسمت از تحقیق برای تعیین ضرایب هیدرودینامیک آبخوان و نقطه انطباق بهینه از روش

جدول ۱. پارامترهای مؤلفه اصلی مجموعه آموزش آبخوان محبوس

مؤلفه اصلی	مقدار ویژه	واریانس (درصد)	واریانس تجمعی (درصد)
PC1	۳۹/۹۶۲۴	۹۹/۹۰۶	۹۹/۹۰۶
PC2	۰/۰۳۷۶	۰/۰۹۳۹	۹۹/۹۹۹۹
PC3	۰/۰۰۰۰۴۲۶	۰/۰۰۰۱	۱۰۰



شکل ۱. نمایش گرافیکی تولید بردارهای ورودی و خروجی (هدف) مدل فازی [۹]

جدول ۲. پارامترهای به کاررفته در آموزش مدل فازی در آبخوان محبوس

پارامتر	مقدار
میزان یادگیری	۰/۵
معیار همگرایی	$10^{-6}$
بیشترین چرخه آموزش	۱۰۰۰۰
تعداد الگوهای آموزش	۱۰۲۰۵

سنتز شده با استفاده از حل تحلیلی تاپس روابط ۱-۳ برای آبخوان محبوس و از ترکیب مقادیر ایده آل  $T$  و  $S$  به ترتیب در محدوده  $10^2$  تا  $10^6$  مترمربع در روز و  $10^{-6}$  تا  $10^{-2}$  با انتخاب تعدادی گام‌های زمانی مطابق شکل ۱ تولید شدند. داده‌های سنتز شده با استفاده از رابطه ۷ به نسبت‌های افت تبدیل شدند [۳۲] که به عنوان بردارهای ورودی آزمایش  $(X_i)$  در مدل‌های آموزش دیده استفاده شدند:

$$X_i = \log(s_{i+1}) - \log(s_i) = \log\left(\frac{s_{i+1}}{s_i}\right) \quad (7)$$

$s_i$  افت ثبت شده در زمان  $t_i$  است. با اعمال PCA بر بردارهای ورودی  $(X_i)$ ، نسبت‌های افت کاهش یافته  $\left[\log\left(\frac{s_{i+1}}{s_i}\right)\right]$  PCA تولید شدند. مدل آموزش داده شده، نسبت‌های افت کاهش یافته (نسبت‌های افتی که PCA بر آنها اعمال شد) را دریافت می‌کند و مقدار  $\log\left(\frac{1}{u}\right)_m$  را محاسبه می‌کنند که با استفاده از روابط ۱-۳ به  $T$  و  $S$  تبدیل می‌شوند. شکل‌های ۲ و ۳ نمودارهای پراکنش<sup>۱</sup> و بهترین خط تناسب<sup>۲</sup> بین پارامترهای هدف و محاسبه شده  $(T, S)$  توسط مدل آموزش داده شده آبخوان محبوس را نشان می‌دهند. همان طور که در این شکل‌ها نشان داده شده است، این مدل طراحی شده می‌تواند پارامترهای آبخوان را با دقت زیادی در محدوده وسیعی از مقادیر آزمایشی محاسبه کند. در تمامی نمودارها مقدار  $R^2$  مساوی یک و مقدار RRMSE بسیار نزدیک به صفر هستند (جدول ۳). این مقادیر نشان‌دهنده دقت زیاد پیش‌بینی مدل تدوین شده در شبیه‌سازی دقیق سیستم واقعی (رابطه ۱) است [۳۷].

دو معیار زیر برای ارزیابی دقت مختصات نقطه انطباق (هدف مدل) به کار گرفته شد:

الف) ریشه میانگین مربع خطای نسبی (RRMSE) هدف تخمین زده شده (رابطه ۵):

$$RRMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n \left(\frac{\hat{y}_j - y_j}{y_j}\right)^2} \quad (5)$$

که  $\hat{y}_j$  هدف شبیه‌سازی شده یا محاسبه شده توسط مدل فازی،  $y_j$  هدف واقعی و  $n$  تعداد الگوهاست. کمترین مقدار RRMSE بیشترین دقت پیش‌بینی را نشان می‌دهد. RRSME مساوی صفر نشان‌دهنده دقت ۱۰۰ درصد است. ب) ضریب تبیین ( $R^2$ ) (determination coefficient) (رابطه ۶):

$$R^2 = 1 - \frac{\sum (y_j - \hat{y}_j)^2}{\sum y_j^2 - \frac{\sum \hat{y}_j}{n}} \quad (6)$$

$R^2=1$  نشان‌دهنده ۱۰۰ درصد تناسب بین مقادیر خروجی مدل و مقادیر هدف است. جدول ۳ مقادیر هر دو معیار یاد شده به همراه زمان مورد نیاز برای آموزش مدل طراحی شده آبخوان محبوس را نشان می‌دهد. مقادیر  $R^2$  و RRMSE دقت و راندمان بالای مدل پیشنهادی را نشان می‌دهند.

#### آزمایش مدل‌ها


به منظور ارزیابی عملکرد مدل تدوین شده با ساختار بهینه در تعیین مختصات نقطه انطباق و پارامترهای آبخوان از الگوهای آزمایش استفاده می‌شود. بهترین نتیجه از عملکرد روش فازی زمانی به دست می‌آید که مدل آموزش دیده کوچک‌ترین خطای پیش‌بینی را برای مجموعه داده‌های آزمایش که متفاوت از مجموعه داده‌های آموزش هستند، تولید کند.

عملکرد مدل آموزش دیده با یک هزار مجموعه داده افت-زمان سنتز شده بدون خطا آزمایش شد. این داده‌های


جدول ۳. زمان مورد نیاز آموزش، RRMSE (درصد) و  $R^2$  مربوط به مقدار  $\text{Log}(1/u_m)$  مدل فازی سوگنو در مرحله آموزش و RRMSE (درصد) در مرحله آزمایش

RRMSE (آزمایش)		$R^2$ (آموزش)	RRMSE (آموزش)		مدل
S	T	$\text{Log}(1/u_m)$	$\text{Log}(1/u_m)$	زمان مورد نیاز آموزش (ثانیه)	
(ضریب ذخیره)	(قابلیت انتقال)	۱	$7/0.8 \times 10^{-3}$	۱۵۰	شبکه فازی سوگنو
$7/5 \times 10^{-10}$	۰/۰۱۲۸				

$R^2$  هر دو پارامتر یادشده در مدل فازی برابر ۱ محاسبه شد



شکل ۲. نمودار پراکنش پارامتر T محاسباتی آبخوان محبوس در مقابل هدف با استفاده از مدل فازی سوگنو



شکل ۳. نمودار پراکنش پارامتر S محاسباتی آبخوان محبوس در مقابل هدف با استفاده از مدل فازی سوگنو

آزمون پمپاژ واقعی (داده افت - زمان) استفاده شده است تا دقت و عملکرد شبکه پیشنهادی ارزیابی شود. این مجموعه داده‌ها از تاد و میز اقتباس شده است [۳۸]. طی این آزمون پمپاژ یک چاه کامل با میزان ثابت ۲۵۰۰ مترمکعب در روز و در آبخوانی محبوس پمپاژ شد و

#### صحت‌سنجی مدل‌ها

هدف اصلی از صحت‌سنجی مدل این است که اطمینان بیشتری از پاسخ سیستم (پیش‌بینی مدل) به دست آوریم. بنابراین، پیش‌بینی مدل باید از نظر فیزیکی هم قابل قبول باشد. به همین دلیل، در این مرحله از یک مجموعه داده

جایگزین کردن مقادیر مختصات نقطه انطباق در روابط ۱-۳ مقادیر پارامترهای آبخوان محبوس ( $T, S$ ) تعیین شدند. آن داده افت  $\left[\left(\frac{1}{u}\right)_j, W_{jz}, s_{jz}, t_j\right]$  که حداقل مقدار RRMSE افت تخمین زده شده نسبت به رکوردهای افت واقعی را تولید می‌کند، به عنوان مختصات نقطه انطباق بهینه انتخاب می‌شود. این داده مقادیر پارامترهای آبخوان را با بیشترین دقت ممکن تعیین می‌کند. مقادیر پارامترهای آبخوان ( $T, S$ ) با استفاده از مدل طراحی شده تعیین و نتایج در جدول ۴ آورده شده و با مقادیر به دست آمده از روش انطباق منحنی تیپ مقایسه شده است. مقایسه مقادیر RRSME روش انطباق منحنی تیپ و مدل فازی سوگنو، دقت بیشتر مدل فازی سوگنو را نشان می‌دهد. در این آزمون پمپاژ رکورد دهم از داده‌های افت-زمان که کمترین مقدار RRMSE را ایجاد کرد، به عنوان نقاط انطباق بهینه مدل فازی انتخاب شد (شکل ۴). نتایج به دست آمده از آموزش، آزمایش و صحت‌سنجی شبکه عصبی مصنوعی به ترتیب در جدول‌های ۴ و ۵ نشان داده شده است. همان طور که از نتایج پیداست، شبکه عصبی مصنوعی نیز توانایی زیادی برای تخمین پارامترهای آبخوان تحت فشار دارد. مقایسه نتایج به دست آمده از شبکه عصبی مصنوعی و مدل منطق فازی بیان‌کننده این موضوع است که گرچه شبکه عصبی مصنوعی در مرحله آموزش دقت بیشتری نسبت به مدل منطق فازی دارد، مدل منطق فازی در مرحله آزمایش دارای دقت بیشتری نسبت به شبکه عصبی مصنوعی است.

داده‌های افت-زمان یک چاه مشاهده‌ای در فاصله ۶۰ متری از چاه پمپاژ به ثبت رسید. برای تعیین پارامترهای آبخوان با مدل‌های فازی طراحی شده ابتدا مجموعه داده افت-زمان به نسبت‌های افت تبدیل شدند و سپس تکنیک PCA بر آنها اعمال شد. مجموعه داده‌های کاهش یافته به عنوان بردارهای ورودی به مدل طراحی شده وارد شد تا مقدار مختصات نقطه انطباق  $\log\left(\frac{1}{u}\right)_m$  توسط مدل تعیین شوند [۸].

### تعیین پارامترهای آبخوان

مختصات نقطه انطباق تعیین شده توسط مدل فازی تدوین شده مربوط به آزمون پمپاژ برای تمامی رکوردهای افت-زمان مطابق شکل ۱ به شرح زیر تنظیم شد (روابط ۸-۱۲):

$$\hat{y} = \log\left(\frac{1}{u}\right)_j = \log\left[\left(\frac{1}{u}\right)_m \times \left(\frac{t_j}{t_1}\right)\right], j=1, 2, \dots, N \quad (8)$$


$$\left(\frac{1}{u}\right)_j = \left[\left(\frac{1}{u}\right)_m \times \left(\frac{t_j}{t_1}\right)\right] = 10^{\hat{y}} \quad (9)$$

$$W_m = W(u_j) = W\left(\frac{1}{10^{\hat{y}}}\right) \quad (10)$$

$$s_m = s_j \quad (11)$$

$$t_m = t_j \quad (12)$$

با استفاده از روابط ۸-۱۲ و با توجه به استفاده از نقطه انطباق بهینه مجموعه افت-زمان ساخته شد. به این صورت که با استفاده از نقطه انطباق بهینه و با استفاده از تأثیر داده‌های افت-زمان، ضریب ذخیره و قابلیت انتقال آبخوان برای هر یک از داده‌های افت-زمان محاسبه شد. با



شکل ۴. نمودار RRMSE نشان‌دهنده رکورد افت-زمان بهینه مجموعه داده آزمون پمپاژ واقعی محاسبه شده با مدل فازی



جدول ۴. پارامترهای محاسبه شده آبخوان با استفاده از مدل های طراحی شده روش انطباق منحنی تیپ، شبکه عصبی مصنوعی و مدل منطق فازی [۳۷]

پارامترهای آبخوان		عنوان روش
T (m <sup>2</sup> /day)	S (10 <sup>-4</sup> )	
۱۱۱۰	۲/۰۶	انطباق منحنی تیپ
۱۱۳۶	۱/۹۳	فازی سوگنو
۱۱۳۶/۳	۱/۹۲	شبکه عصبی

جدول ۵. زمان مورد نیاز آموزش، RRMSE (درصد) و R<sup>2</sup> مربوط به مقدار Log (1/u<sub>m</sub>) مدل شبکه عصبی مصنوعی در مرحله آموزش و RRMSE (درصد) در مرحله آزمایش

مدل	زمان مورد نیاز آموزش (ثانیه)	RRMSE (آموزش)	R <sup>2</sup> (آموزش)	RRMSE (%) (آزمایش)	S	T
		Log (1/u <sub>m</sub> )	Log (1/u <sub>m</sub> )			
شبکه عصبی مصنوعی	۱۷۰	۳/۱۶ × ۱۰ <sup>-۵</sup>	۱	۰/۰۱۴۱	۸/۴۹ × ۱۰ <sup>-۱۰</sup>	

R<sup>2</sup> هر دو پارامتر یادشده در مدل شبکه عصبی مصنوعی برابر ۱ محاسبه شد

### بحث و نتیجه گیری

باشد و درصد اطمینان این مدل در تخمین پارامترهای آبخوان تحت فشار افزایش یابد. درخور یادآوری است که نتایج دو مدل در مرحله صحت سنجی بسیار نزدیک به هم است و دو مدل قابلیت زیادی برای تخمین پارامترهای آبخوان تحت فشار دارند، ولی همان طور که اشاره شد توانایی مدل منطق فازی در کار با پارامترهای دارای عدم قطعیت زیاد نسبت به شبکه عصبی مصنوعی بیشتر است. در ضمن، چون داده های افت-زمان و همچنین ضریب ذخیره و قابلیت انتقال آبخوان عدم قطعیت دارند، مدل منطق فازی توانایی بیشتری برای کار با این داده ها دارد. مهم ترین مزیت مدل منطق فازی نسبت به روش های گرافیکی و به خصوص منحنی تیپ تاپس علاوه بر دقت و سرعت، توانایی آن به منظور کار با داده های با عدم قطعیت بالاست. روش های گرافیکی و به خصوص منحنی تیپ تاپس به دلیل دخیل بودن دانش کاربر هنگام استفاده از این روش ها در هر بار تعیین پارامترهای هیدرودینامیکی آبخوان برای یک سری داده افت-زمان ثابت جواب های متفاوتی را ارائه می دهد. مدل منطق فازی ارائه شده در تحقیق حاضر این نقیصه را رفع کرده است. به این صورت که برای یک مجموعه داده افت-زمان ثابت در هر بار محاسبه پارامترها جواب یکسانی ارائه داده می شود. مقایسه نتایج مدل فازی تولید شده با نتایج مدل های هوش مصنوعی استفاده شده در

در این مقاله مدل منطق فازی برای مدل سازی تابع چاه تاپس و تعیین پارامترهای آبخوان های محبوس طراحی شد. بنابراین، هدف از تحقیق حاضر، ارزیابی توانایی مدل منطق فازی سوگنو برای تعیین پارامترهای آبخوان تحت فشار و مقایسه نتایج به دست آمده از این روش و روش های پیشین (شبکه عصبی مصنوعی و روش گرافیکی تاپس) است. نتایج نشان داد مدل منطق فازی می تواند پارامترهای آبخوان های محبوس را با دقت و سرعت زیادی تعیین کرده و خطاهای گرافیکی روش انطباق منحنی تیپ را حذف کند. بنابراین، مدل فازی سوگنو دقت و سرعت بیشتری داشته است. پس این روش به عنوان یک روش جایگزین دقیق، کارآمد و با کاربرد آسان نسبت به روش های گرافیکی انطباق منحنی تیپ برای تعیین پارامترهای آبخوان های محبوس توصیه می شود. البته، مدل شبکه عصبی مصنوعی نیز سرعت و دقت زیادی دارد و خطاهای گرافیکی روش انطباق منحنی تیپ را از بین می برد. همان طور که در جدول های یادشده آمده است، گرچه خطای شبکه عصبی مصنوعی در مرحله آموزش نسبت به مدل منطق فازی سوگنو کمتر است، خطای مدل منطق فازی سوگنو در مرحله تست نسبت به شبکه عصبی کمتر است که این موضوع سبب می شود قابلیت مدل منطق فازی در مرحله صحت سنجی بیشتر

- by artificial neural networks. *Hydrol Process.* 2010;(24): 3237–3250.
- [11]. Delnaz A, Rakhshandehroo GH, Nikoo M. Assessment of GRNN model in comparison to ANN and RBF models for estimating confined aquifer parameters. *Hydrogeology.* Summer 2017, Page 102-117 [ Persian].
- [12]. Schaap M G, Leij F J. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil Tillage Res.* 1998;47:37– 42.
- [13]. Merdun H, Inar O C, Meral R, Apan M. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil Tillage Res.* 2006; 90:108–116.
- [14]. Nayak P C, Rao Y R S, Sudheer K P. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resour Manag.* 2006;20(1):77–90.
- [15]. Tayfur G, Moramarco T, Singh V P. Predicting and forecasting flow discharge at sites receiving significant Lateral inflow. *Hydrol Process.* 2007; 21(14):1848–1859.
- [16]. Mohanty S, Jha M K, Kumar A, Sudheer K P. Artificial neural network modeling for groundwater level forecasting in a River Island of Eastern India. *Water Resour Manag.* 2010;24(9):1845–1865.
- [17]. Motaghian H R, Mohammadi J. Spatial estimation of saturated hydraulic conductivity from terrain attributes using regression, kriging and artificial neural networks. *Pedosphere.* 2011; 21(2):170–177.
- [18]. Shirmohammadi B, Vafakhah M, Moosavi V Moghaddamnia, A. Application of several data-drive techniques for predicting groundwater level. *Water Resour Manag.* 2013; 27(2):419–432.
- [19]. Nadiri AA, Gharekhani M, Khatibi R, Sadeghfam S, Asghari Moghaddam A. Groundwater vulnerability indices conditioned by Supervised Intelligence Committee Machine (SICM). *Science of The Total Environment.* 2017;574: 691-70.
- [20]. Tayfur G, Nadiri, AA, Asghari Moghaddam A. Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation. *Water Resour Manage.* 2014; 28:1173–1184.
- [21]. Ross J, Ozbek M, Pinder G F. Hydraulic conductivity estimation via fuzzy. *Math Geol.* 2007;39(8):765–780.
- مقالات مشابه (که در مقدمه آمده است) بیان کننده این موضوع است که مدل فازی تولیدشده توانایی زیادی در تخمین پارامترهای هیدرودینامیکی آبخوان تحت فشار دارد. نکته درخور یادآوری دیگر بیان این موضوع است که نتایج به دست آمده از شبکه عصبی استفاده شده در تحقیق حاضر در مقایسه با نتایج تحقیقات مشابه صورت گرفته توسط شبکه عصبی مصنوعی [۸–۱۰] دقت بیشتری در تمامی مراحل آموزش، آزمایش و صحت سنجی دارد.

### منابع

- [1]. Theis C V. The relationship between the lowering of the piezometric surface and the rate and duration of discharge of a well using ground-water storage. *Trans Am Geophys Union.* 1935; (16): 519–524.
- [2]. Chow V T. On the determination of transmissibility and storage coefficients from pumping test data. *Trans. Amer. Geophysical Union.* 1952; 33: 397-404.
- [3]. Cooper H H, Jacob C E. A generalized graphical method for evaluating formation constants and summarizing well field history. *Trans. Amer. Geophysical union.* 1946; 27: 526-534.
- [4]. Neuman S P. Analysis of pumping test data from anisotropic unconfined aquifers considering delayed gravity response. *water resources research.* 1975; 11: 329-342.
- [5]. Hazen A. Some physical properties of sands and gravels. *Massachusetts state board of health 24th Annual Report.* 1892;539-556.
- [6]. Shepherd R G. Correlations of permeability and grain size. *Ground Water.*1989; 27: 633-638.
- [7]. Alyamani M, Sen Z. Determination of hydraulic conductivity from complete grain size distribution curves. *Ground Water.* 1993; 31: 551-555.
- [8]. Samani N, Gohari-Moghaddam M, Safavi A A. A simple neural network model for the determination of aquifer parameters. *J Hydrol.* 2007; 340(1–2):1–11.
- [9]. Lin G F, Chen G R. An improved neural network approach to the determination of aquifer parameters. *J Hydrol.* 2006;316(1–4): 281–289.
- [10]. Lin H T, Ke K Y, Chen Ch H, Wu Sh Ch, Tan Y Ch. Estimating anisotropic aquifer parameters

- [22]. Olatunji S O, Selamat A, Abdulraheem A. Modeling the permeability of carbonate reservoir using type-2 fuzzy logic systems. *Comput Ind.* 2011; 62:147–163.
- [23]. Colin, F, Guillaume S, Tisseyre B. Small catchment agricultural management using decision variables defined at catchment scale and a fuzzy rule-based system: a Mediterranean vineyard case study. *Water Resour Manag.* 2011;25(11):2649–2668.
- [24]. Bárdossy A, Disse M. Fuzzy rule-based models for infiltration. *Water Resour Res.* 1993; 29(2):373–382.
- [25]. Tutmez B, Hatipoglu Z. Spatial estimation model of porosity. *Comput Geosci.* 2007; 33:465–475.
- [26]. Chu H J, Chang L C. Application of optimal control and fuzzy theory for dynamic groundwater remediation design. *Water Resour Manag.* 2009;23(4):647–660.
- [27]. Helmy T, Fatai A, Faisal K. Hybrid computational models for the characterization of oil and gas reservoirs. *Expert Syst Appl.* 2010;37(7):5353–5363.
- [28]. Anifowose F, Abdulraheem A. Fuzzy logic-driven and SVM-driven hybrid computational intelligence models applied to oil and gas reservoir characterization. *J Nat Gas Sci Eng.* 2011; 3(3):505–517.
- [29]. Tayfur G. *Soft computing in water resources engineering.* WIT Press, Southampton. 2012.
- [30]. Morankar D V, Raju K S, Kumar D N. Integrated sustainable irrigation planning with multiobjective fuzzy optimization approach. *Water Resour Manag.* 2013;27(11):3981–4004.
- [31]. Nadiri A A, Gharekhani M, Khatibi R, Sadeghfam S and Asghari Moghaddam A. Groundwater vulnerability indices conditioned by Supervised Intelligence Committee Machine (SICM). *Science of The Total Environment.* 2017; 574: 691-706.
- [32]. Lin G F, Chen G R. Determination of aquifer parameters using radial basis function network approach. *J Chinese Inst Engrs.* 2005; 28(2):241-249.
- [33]. Azari T, Samani N, and Mansoori E. An artificial neural network model for the determination of leaky confined aquifer parameters. an accurate alternative to type curve matching methods. *Iranian Journal of Science & Technology.* 2015;39(A4): 463-472.
- [34]. Zadeh LA. Fuzzy sets. *Information and Control.* 1965; 8 (3): 338–353.
- [35]. Nadiri AA, Fijani E, Tsai FT-C, Asghari Moghaddam A. Supervised committee machine with artificial intelligence for prediction of fluoride concentration. *Journal of Hydroinformatics.* 2013;15: 1474–1490
- [36]. Maier H R, Jain A, Dandy G C, Sudheer K P. Methods used for the development of neural networks for the prediction of water resource variables in river systems. current status and future directions. *Environ Model Softw.* 2010; 25(8): 891-909.
- [37]. Wu W, Dandy G C, Maier H R. Protocol for developing ANN models and its application to the assessment of the quality of the ANN model development process in drinking water quality modeling. *Environ Modell Softw.* 2014 ;(54):108–127.
- [38]. Todd D K, Mays LW. *Groundwater Hydrology.* New York: Wiley. 2005.