

## الگو بندی هیدروگراف معرف آبخوان با مدل مفهومی مادفلو و فرامدل شبیه ساز شبکه عصبی - فازی (مطالعه موردی)

معصومه زینعلی<sup>۱</sup>، محمدرضا گلابی<sup>۲\*</sup>، سهیلا فرزی<sup>۳</sup>، فریدون رادمنش<sup>۴</sup>

تاریخ دریافت: ۱۳۹۶/۱۱/۲۰ تاریخ پذیرش: ۱۳۹۷/۳/۵

### چکیده

کاهش نزولات جوی، محدود بودن منابع آب و برداشت روزافزون از آب‌های زیرزمینی موجب افت سطح ایستابی دشت‌ها شده است و بنابراین الگو بندی آب‌های زیرزمینی به عنوان ابزار کارآمد جهت مدیریت و حفاظت این منابع مطرح می‌باشد. در این مطالعه از اطلاعات آماری ماهانه سطح پیژومترها برای ۵ سال آبی (۸۸-۸۹ تا ۹۳-۹۲) مربوط به سطح ۸ پیژومتر آبخوان دشت لور-اندیمشک، استفاده شد. در ابتدا با استفاده از روش تسین، میانگین وزنی هر پیژومتر بدست آمد و سری زمانی تراز آب زیرزمینی دشت که بیانگر هیدروگراف معرف آبخوان منطقه مورد مطالعه است، محاسبه گردید. سپس با استفاده از مدل مفهومی آب زیرزمینی مادفلو و فرامدل شبیه‌ساز عصبی-فازی، هیدروگراف معرف آبخوان مدل‌سازی شد و نتایج با هم مقایسه گردید. نتایج نشان داد که مدل مفهومی مادفلو با ضریب تبیین ۰/۷۸۳۶ در مرحله تست نسبت به فرامدل شبیه‌ساز عصبی-فازی با ضریب تبیین ۰/۶۳۴۸ دارای عملکرد بهتری می‌باشد.

**واژه‌های کلیدی:** فرامدل شبیه‌ساز عصبی-فازی، مدل‌سازی، مدل مادفلو، هیدروگراف معرف آبخوان

### مقدمه

و بهتر از پتانسیل‌های آبی موجود در دشت‌ها، عمیقاً احساس می‌شود. از اساسی‌ترین موارد در مدیریت کمی منابع آب زیرزمینی تخمین سطح آب با استفاده از داده‌های برداشت شده از شبکه چاه‌های مشاهده‌ای می‌باشد (زارعی و همکاران، ۱۳۸۶). در پژوهشی از مدل شبکه عصبی مصنوعی RBF هیبرید برای پیش‌بینی تراز آب زیرزمینی دشت شاهرود استفاده شد که نشان داد هیبرید بودن شبکه باعث افزایش دقت روش نسبت به شبکه RBF پایه می‌شود (اکبرزاده و همکاران، ۱۳۹۵). به منظور پیش‌بینی سطح آب زیرزمینی یک دشت از روش‌های هوش مصنوعی و زمین آمار استفاده شد. نتایج نشان داد با افزایش بازه زمانی پیش‌بینی خطای مدل ترکیبی (کوکرینجینگ عصبی) افزایش می‌یابد که بیش‌تر به دلیل افزایش خطای مدل شبکه عصبی مصنوعی با افزایش بازه زمانی پیش‌بینی می‌باشد و خطای مدل زمین آمار (کوکرینجینگ) نامحسوس به نظر می‌رسد (ندیری و همکاران، ۱۳۹۵). در پژوهشی به بررسی کارایی تکنیک شبکه عصبی مصنوعی و سری‌های زمانی را در پیش‌بینی سطح ایستابی آب زیرزمینی پرداخته شد که نشان داد هر دو تکنیک شبکه عصبی و سری زمانی، در پیش‌بینی سطح ایستابی چاه‌های منطقه کارایی و دقت بالایی دارند (پورمحمدی و همکاران، ۱۳۹۲). نتایج پیش‌بینی نوسانات سطح آب زیرزمینی در دشت مروست با مدل‌های سری زمانی و شبکه عصبی نشان داد مدل شبکه عصبی نسبت به سری

کاهش نزولات جوی و خشکسالی‌های اخیر و در نتیجه کمبود آب در پهنه وسیعی از کشور و افزایش میزان تقاضا برای مصارف مختلف، مدیریت منابع آب‌های سطحی و زیرزمینی را ضروری می‌سازد. آب‌های زیرزمینی در بسیاری از کشورها از جمله ایران، یکی از منابع اصلی تامین آب برای مصارف شرب، صنعت و کشاورزی می‌باشند. در بسیاری از کشورهای خشک جهان از جمله ایران اصلی‌ترین منبع تامین آب، ذخایر آب زیرزمینی است. لذا استفاده بهینه از منابع آب‌های زیرزمینی، مستلزم مدیریت صحیح در بهره‌برداری و سواد علمی و فنی بر سیستم منابع آبی هر منطقه است. برای اعمال یک مدیریت صحیح نیاز به شناسایی، به مدل درآوردن و تخمین سطح آب زیرزمینی در دشت‌ها جهت برنامه‌ریزی‌های بلندمدت و استفاده بیش‌تر

- ۱- دانش آموخته کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی کرمانشاه
  - ۲- دانشجوی دکتری منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز
  - ۳- دانش آموخته کارشناسی ارشد آبیاری و زهکشی، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه
  - ۴- دانشیار گروه منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز
- \* - نویسنده مسئول: (Email: hamidgolabi65@gmail.com)

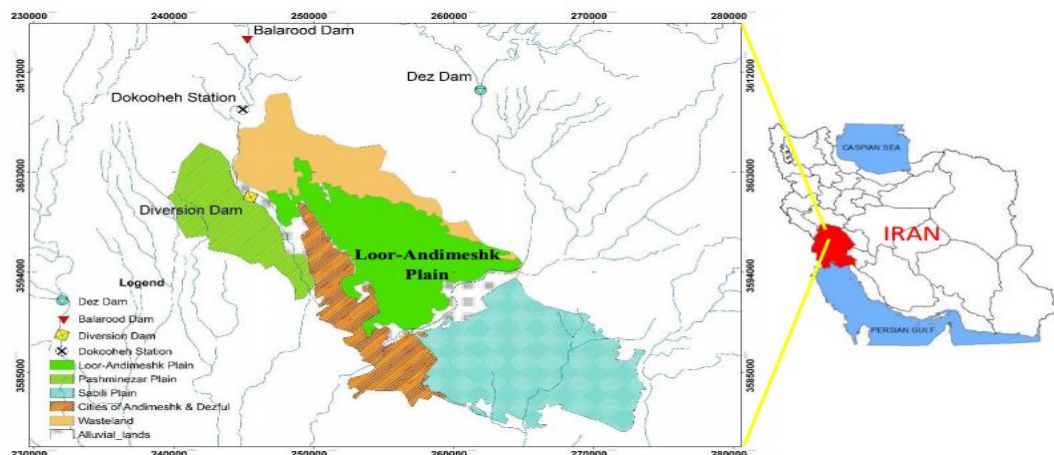
## مواد و روش‌ها

### محدوده مطالعاتی

محدوده مطالعاتی، دشت لور- اندیمشک، قسمتی از دشت دزفول-اندیمشک با مساحتی حدود ۲۱۴ کیلومتر مربع است که در حوضه آبریز رود دز و در شمال شهرستان اندیمشک، بین طول جغرافیایی  $48^{\circ} 09'$  تا  $48^{\circ} 47'$  شرقی و عرض جغرافیایی  $32^{\circ} 32'$  تا  $32^{\circ} 36'$  شمالی قرار گرفته و از جمله دشت‌های شمال جلگه خوزستان، در دامنه‌های غربی رشته کوه‌های زاگرس می‌باشد. این حوضه جزئی از بخش مرکزی شهرستان اندیمشک محسوب می‌شود و از شمال و شمال شرق به محدوده دریاچه سد دز، از شرق به شهر دزفول و رودخانه دز، از جنوب به شهر اندیمشک و از غرب و جنوب غرب به رودخانه بالارود ختم می‌شود. موقعیت منطقه مورد مطالعه در شکل ۱ نشان داده شده است. به جهت بررسی تغییرات سطح آب زیرزمینی، جهت جریان آب زیرزمینی، نقاط تغذیه و تخلیه و سایر ارزیابی‌های هیدروژئولوژیکی، وجود یک شبکه‌ی پیزومتری مناسب در منطقه ضروری می‌باشد. در منطقه‌ی دشت لور - اندیمشک، ۸ حلقه پیزومتر که پراکنش نسبتاً خوبی در منطقه دارد، شبکه‌ی پیزومتری دشت را تشکیل می‌دهد. برای انجام این مطالعه با استفاده از مختصات جغرافیایی هر پیزومتر و اطلاعات آماری ماهانه مربوط به سطح ۸ پیزومتر آبخوان دشت لور-اندیمشک، برای ۵ سال آبی (۸۹-۸۸ تا ۹۳-۹۲) و با استفاده از روش تسین در محیط GIS، میانگین وزنی هر پیزومتر بدست آمد و سری زمانی تراز آب زیرزمینی دشت که بیانگر هیدروگراف معرف آبخوان منطقه مورد مطالعه است، محاسبه گردید (شکل ۲). سپس با استفاده از مدل مفهومی آب زیرزمینی مادفلو و فرا مدل شبیه ساز عصبی-فازی هیدروگراف معرف آبخوان طی مراحل زیر مدل سازی شد و نتایج با هم مقایسه گردید.

زمانی تلفیقی، برتری جزئی نشان داد (ملکی نژاد و پور شرعیاتی، ۱۳۹۲). در پژوهش دیگری با استفاده از روش‌های شبکه عصبی و ماشین بردار پشتیبان براساس سری‌های زمانی دراز مدت سطح ایستابی را پیش‌بینی کردند. نتایج نشان داد که پیش‌بینی عملکرد برگشت‌پذیر مدل ماشین بردار پشتیبان، برتر از مدل شبکه عصبی می‌باشد (Yoona et al., 2016). از شبکه عصبی مصنوعی برای پیش‌بینی تراز آب زیرزمینی در آبخوان کانیاکومری، تامیل نادو، هند نیز استفاده شده است (Stanley et al., 2017). نتایج پیش‌بینی نوسانات سطح آب زیرزمینی با استفاده از مدل‌های ترکیبی موجک و شبکه عصبی نشان داد، استفاده از شبکه‌های تقویت عصبی WA عملکرد بهتری برای پیش‌بینی سطح آب زیرزمینی در مقایسه با مدل‌های مبتنی بر شبکه عصبی داشته‌اند (Barzegar et al., 2017). همچنین نتایج استفاده از ترکیب موجک MARS و مدل درختی M5 برای پیش‌بینی سطح آب زیرزمینی، نشان داد که مدل W-MARS دقت بیشتری نسبت به مدل درختی M5 در پیش‌بینی سطح آب زیرزمینی دارد (Rezaie-balf et al., 2017).

اکثر مطالعات انجام شده مربوط به پیش‌بینی در زمینه آب‌های زیرزمینی مربوط به پیش‌بینی سطح ایستابی است و کم‌تر به هیدروگراف معرف آبخوان توجه شده است. لذا هدف از این مطالعه در ابتدا مدل سازی هیدروگراف معرف آبخوان با استفاده از مدل مفهومی مادفلو و سپس مقایسه نتیجه با مدل سازی به روش فرا مدل شبیه‌ساز عصبی-فازی است که برای اولین بار در این مطالعه برای این هدف مورد استفاده قرار گرفته است و سوال اساسی این تحقیق این است که آیا برای مدل سازی هیدروگراف معرف آبخوان، در شرایط کمبود داده و اطلاعات، فرامدل شبیه ساز عصبی-فازی می‌تواند جایگزین مناسبی برای مدل مفهومی مادفلو باشد.

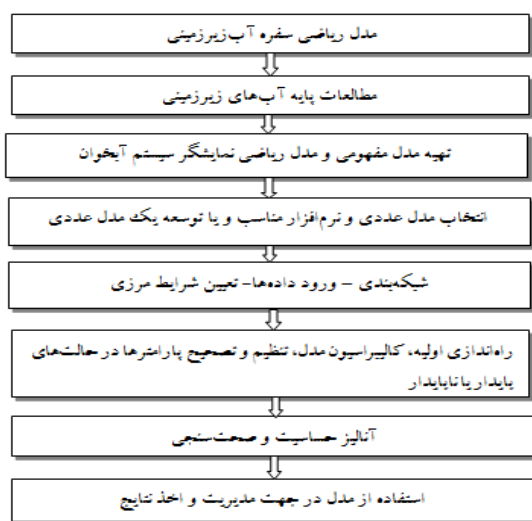


شکل ۱- موقعیت منطقه مورد مطالعه



شکل ۲- هیدروگراف واحد دشت لور- اندیمشک از مهر ۱۳۸۸ تا شهریور ۱۳۹۳

مدل‌سازی قرار می‌گیرند، حداقل باشد. اگرچه بارهای هیدرولیکی در این گره‌ها که گره‌های غیر فعال نامیده می‌شوند، محاسبه نمی‌گردد، اما در آریه‌ای که مدل از آن استفاده می‌کند فضایی را اشغال می‌کنند. مشکل گره‌های غیرفعال از آنجا منشا می‌گیرد که شبکه تفاضلات محدود شکلی مربعی یا مستطیلی دارند، اما محدوده‌ای که می‌خواهیم آن را مدل‌سازی کنیم غالباً به این اشکال نمی‌باشند (Anderson and Woessner., 1992).



شکل ۳- روند مدل‌سازی کمی آبخوان یک منطقه

### شرایط مرزی و اولیه

انتخاب سطح و شرایط مرزی را شاید بتوان مهم‌ترین گام در تهیه مدل مفهومی دانست. انتخاب سطح و شرایط مرزی نامناسب ممکن است منجر به ایجاد نقص در مدل گردد و پاسخ مدل به استرس‌های

### مدل مفهومی آب زیرزمینی MODFLOW

مدل MODFLOW برای ارزیابی کمی آب‌های زیرزمینی پیشنهاد شده است. MODFLOW یک ماژول سه بعدی مدل جریان آب زیرزمینی تفاضلات محدود است که توسط سازمان زمین شناسی ایالت متحده آمریکا (USGS) تهیه شده است. در ابتدا برای تهیه مدل مفهومی از فرضیات لازم (فرم هندسی مرزها و محدوده سفره، جریان حاکم بر سفره، نوع تشکیلات زمین‌شناسی و نوع رژیم جریان) استفاده می‌شود و با وارد کردن داده‌های ورودی به فرمت خاص، مدل MODFLOW اجرا می‌شود که معادله‌ی حرکت جریان، به روش عددی تفاضل محدود حل می‌شود. در نهایت مدل تهیه شده کمی آبخوان را با پارامترهای ورودی و انسجی، آنالیز حساسیت و در نهایت صحت‌سنجی می‌شود. در اینصورت می‌توان در پیش‌بینی‌های آینده از آن‌ها استفاده کرد. روند مدل‌سازی کمی آبخوان توسط این مدل در شکل ۳ نمایش داده شده است. در این تحقیق از کد MODFLOW در نرم افزار GMS<sup>۲</sup> جهت مدل‌سازی آب زیرزمینی در منطقه مورد مطالعه استفاده شده است (جهت مطالعه بیشتر در باره نرم افزار GMS و کد مورد استفاده به EMRL<sup>۳</sup>، مراجعه کنید) (EMRL., 2010).

### انتخاب جهت و اندازه شبکه مدل

جهت و اندازه شبکه را باید به گونه‌ای انتخاب کرد که در حالت افقی محور  $x$  و  $y$  آن در راستای  $K$  و  $Ky$  قرار گیرد و در حالت سه بعدی محور  $Z$  هم راستا با  $Kz$  باشد. در مدل‌های تفاضل محدود باید توجه داشت که تعداد گره‌هایی که در خارج از مرزهای محدوده

1- united states Geological Survey

2-Groundwater Modeling System

3- Environmental Modeling Research Laboratory

### واسنجی مدل در حالت ماندگار

بعد از اینکه تمام بسته‌ها ساخته شد و اطلاعات مورد نیاز مدل تکمیل شد، مدل اجرا گردید و در این مرحله از کار عملیات واسنجی مدل انجام گرفت و در حالت ماندگار مدل کالیبره شد. کالیبراسیون مدل از روش رگرسیون غیرخطی و با استفاده از MODFLOW 2000 انجام گرفت. در واسنجی حالت ماندگار هدایت هیدرولیکی دشت و ضریب گذردهی مرزها بهینه شد.

### واسنجی مدل در حالت غیر ماندگار

این مرحله از کار پس از واسنجی مدل برای حالت ماندگار، انجام شد و دوره‌های تنش حالت غیر ماندگار به تدریج به مدل اضافه شده و مدل در هر مرحله واسنجی گردید. در حالت ماندگار بعد از کالیبره شدن مقادیر هدایت هیدرولیکی و ضریب گذردهی<sup>۲</sup> سلول‌های مرزی<sup>۳</sup> را که بهینه شدند در مدل غیر ماندگار ثابت در نظر گرفته شد و از همین مقادیر بهینه برای کالیبره کردن مدل در حالت غیر ماندگار استفاده شد و مدل با استفاده از پارامترهای آینده‌ی ویژه و تغذیه واسنجی مجدد گردید.

### صحت سنجی مدل

در صحت‌سنجی مدل، کلیه پارامترهای دوره واسنجی ثابت شد و هدف از این کار این بود که مدل استرس‌های دوره صحت‌سنجی را تخمین بزند. در واقع صحت‌سنجی فرایندی است که طی آن اطمینان حاصل می‌شود کلیه فرایندهایی که در ارتباط بین استرس‌های وارده و پاسخ مدل به آن‌ها تاثیر گذارند به درستی در نظر گرفته شده است (Bear., 2010).

### فرامدل شبیه ساز عصبی-فازی

نظریه مجموعه فازی توسط پروفیسور لطفی‌عسگرزاده مشهور به زاده در سال ۱۹۶۵ پیشنهاد شد و به طور گسترده در بسیاری از زمینه‌ها استفاده می‌شود (Ross., 1995). این تئوری، ابزاری توانمند و انعطاف‌پذیر برای مدل‌سازی عدم قطعیت‌ها و عدم صراحت‌های موجود در دنیای واقعی و بیان عبارت‌های زبانی برگرفته از تجربه و دانش بشر در قالب روابط ریاضی به شمار می‌آید. پیچیدگی و عدم قطعیت در سیستم‌های هیدرولوژیکی، کمبود اطلاعات در بسیاری از فرآیندهای هیدرولوژیکی، مبهم و غیرصریح بودن این داده‌ها موجب شد تا استفاده از تئوری فازی در زمینه هیدرولوژی و بارش-رواناب که از اصلی‌ترین فرآیندهای هیدرولوژیکی است افزایش یابد (Ross., 1995). با این وجود، مشکل اصلی منطق فازی این است که روند سینماتیکی برای یک کنترل‌کننده فازی وجود ندارد. به

وارده را متفاوت از پاسخ سیستم واقعی به استرس‌ها نماید (Lu et al., 2013). در حالت ماندگار مرزها تاثیر زیادی روی الگوی جریان آب‌های زیرزمینی دارند ولی در حالت غیرماندگار مرزها در صورتی بر روی جواب‌های مدل تاثیر خواهند گذاشت که اثر استرس‌های وارده به سیستم جریان، به مرزها برسد. هفت نوع مرز می‌توان برای مدل‌های جریان در نظر گرفت که عبارتند از: مرز بار ثابت، مرز بار مشخص، خط جریان، مرز با جریان مشخص، مرز جریان وابسته به بار هیدرولیکی، سطح آزاد و سطح تراوش.

### شرایط اولیه

توزیع بار هیدرولیکی دشت در آغاز شبیه‌سازی شرایط اولیه می‌باشد. بنابراین شرایط اولیه نوعی مرز زمانی برای سیستم مورد مطالعه است.

### تعیین سقف و کف لایه آبدار

با استفاده از مقاطع ژئوفیزیکی تهیه شده دشت و اطلاعات چاه‌های مشاهده‌ای که به سنگ کف برخورد کرده‌اند، نقشه ارتفاع سنگ کف تهیه می‌گردد.

### تغذیه

تغذیه دشت یکی از پارامترهای مهم در مدل آب زیرزمینی می‌باشد. برای در نظر گرفتن تغذیه در منطقه مطالعاتی از بسته تغذیه<sup>۱</sup> با پسوند RCH استفاده می‌گردد. معمولاً به دلیل ویژگی‌های مختلف خاک‌شناسی، زمین‌شناسی، پوشش گیاهی، شدت بارندگی و شیب زمین، در نقاط مختلف میزان تغذیه آب‌های زیرزمینی متفاوت می‌باشد. در مدل آب زیرزمینی از آنجا که معمولاً اطلاعات کمی از میزان تغذیه در مناطق مختلف در دسترس است، پارامتر تغذیه برای محدوده وسیعی در نظر گرفته می‌شود و در طول کالیبراسیون بهینه می‌گردد (آذری، ۱۳۹۲).

### پارامترهای هیدرودینامیکی آبخوان

در این مرحله تخمین پارامترهای هیدرودینامیکی آبخوان با روش زون‌بندی بر اساس لوگ حفاری چاه‌های مشاهده‌ای، اکتشافی و پیرومتری و همچنین مقاطع ژئوفیزیکی تهیه شده از منطقه انجام می‌گیرد. با توجه به جنس خاک و رسوبات هر زون مقادیر اولیه هدایت هیدرولیکی و آینده‌ی ویژه تخمین زده می‌شود و در نهایت در مرحله‌ی کالیبراسیون برای هر زون مقدار بهینه شده هدایت هیدرولیکی و آینده‌ی ویژه لحاظ می‌گردد.

2- Conductance

3 -General Head Boundary

1 - Recharge

مدل فازی تاکاگی - سوگنو درجه اول هستند (نورانی و صالحی، ۱۳۸۷). مطابق شکل ۴ ساختار سیستم استنتاج فازی-عصبی تطبیقی شامل پنج لایه می‌باشد (Nourani and Komasi., 2013).  
 لایه اول، گره‌های ورودی: هر گره از این لایه، مقادیر عضویتی که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تولید می‌کنند.

$$\begin{aligned} O_{1i} &= \mu_{A_i}(x) \quad i=1, 2, 3, \dots, n \\ O_{2i} &= \mu_{i-2}(x) \quad i=3, 4, \dots, n \end{aligned} \quad (3)$$

$x$  و  $y$  ورودی‌های غیرفازی به گره  $i$ ،  $A_i$  و  $B_i$ : برچسب‌های زبانی هستند که به ترتیب با توابع عضویت مناسب  $\mu_{A_i}$  و  $\mu_{B_i}$  مشخص می‌شوند. باید پارامترهای این توابع عضویت که به عنوان پارامترهای مقدماتی در این لایه شناخته می‌شوند، مشخص شوند.  
 لایه دوم، گره‌های قاعده: در لایه دوم، عملگر "و" (AND) به کار برده می‌شود تا خروجی (قوه اشتعال) که نمایانگر بخش مقدم آن قانون است بدست آید. قوه اشتعال به مقدار درجه‌ای که بخش مقدم یک قانون فازی برآورده شده، گفته می‌شود و به تابع خروجی آن قانون، شکل می‌دهد. از این رو، خروجی‌های  $O_{2,K}$  این لایه، حاصل ضرب درجات مربوط به لایه اول هستند.

$$O_{2,K} = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad (4)$$

لایه سوم، گره‌های متوسط: هدف اصلی در لایه سوم، تعیین نسبت هر قوه اشتعال به عنوان  $i$  امین قانون به مجموع همه قوه اشتعال قوانین می‌باشد در نتیجه  $w_i$  قوه اشتعال نرمال شده به دست می‌آید.

$$O_{3,i} = \frac{w_i}{\sum_{K=1}^4 w_K} \quad (5)$$

لایه چهارم، گره‌های نتیجه: تابع گره چهارمین لایه توزیع  $i$  امین قانون را به کل خروجی محاسبه می‌کند و به صورت رابطه (۶) تعریف می‌شود:

$$O_{4,i} = \overline{w}_1 f_i = w_i (p_i x + q_i y + r_i) \quad (6)$$

که در آن:  $w_1$  خروجی  $i$  امین گره از لایه قبلی است.  $(p_i, q_i, r_i)$  ضرایب این ترکیب خطی بوده، همچنین مجموعه پارامترهای بخش تالی مدل فازی تاکاگی - سوگنو نیز می‌باشند.  
 لایه پنجم، گره‌های خروجی: این تک گره، خروجی کلی را با جمع کردن همه سیگنال‌های ورودی محاسبه می‌کند. بنابراین، در این لایه فرآیند غیرفازی‌سازی، نتایج هر قانون فازی را به خروجی غیرفازی تغییر شکل می‌دهد.

عبارت دیگر، یک شبکه عصبی این توانایی را دارد که از محیط آموزش ببیند، جفت‌های ورودی و خروجی، ساختار خود را خود مرتب کند و با شیوه‌ای مناسب، تعامل خود را تطبیق دهد. بدین منظور یانگ و همکاران در سال ۱۹۹۷ مدل سیستم شبکه عصبی - فازی تطبیقی را ارائه کردند که قابلیت ترکیب توانایی دو روش مذکور را داشت (Jang et al., 1997).

سیستم استنتاج عصبی فازی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند و همچنین با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، در مدل‌سازی فرایندهایی همچون هیدرولوژی، هیدروژئولوژی، مدیریت مخازن و برآورد بار رسوب معلق بسیار قدرتمند می‌باشد (Nayak et al., 2004; Kisi., 2009). مدل فازی عصبی تطبیقی براساس تغییر در میزان مقادیر و دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب بر اساس حداقل خطای موجود عمل می‌کند. در مدل سیستم استنتاج عصبی فازی تطبیقی از روش استنتاجی تاکاگی سوگنو<sup>۱</sup> استفاده می‌شود. زمانی عمل شبیه‌سازی به درستی استفاده شده است که تمامی پارامترهای موثر در ساختار مدل طوری تعیین گردند که مقدار خطای مدل به حداقل مقدار خود برسد و همچنین مقادیر کارایی، بیش‌ترین مقدار را داشته باشند.

### ساختار و الگوریتم

سیستم استنتاج فازی-عصبی تطبیقی قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد و همچنین دارای این مزیت است که اجازه استخراج قوانین فازی را از اطلاعات عددی یا دانش متخصص می‌دهد و به طور تطبیقی یک قاعده-بنیاد می‌سازد. علاوه بر این، می‌تواند تبدیل پیچیده هوش بشری به سیستم‌های فازی را تنظیم کند. مشکل اصلی مدل پیش‌بینی سیستم شبکه عصبی - فازی تطبیقی احتیاج نسبتاً زیاد به زمان برای آموزش ساختار و تعیین پارامترها می‌باشد. به منظور ساده‌سازی، فرض می‌شود که سیستم استنتاجی مورد نظر دو ورودی  $x$  و  $y$  و یک خروجی  $z$  دارد. برای یک مدل فازی تاکاگی سوگنو درجه اول، می‌توان یک مجموعه قانون نمونه را با دو قانون اگر-آنگاه فازی به صورت زیر بیان کرد.

قانون اول: اگر  $x$  برابر  $A_1$  و  $y$  برابر  $B_1$  باشد آنگاه:

$$z_1 = p_1 x + q_1 y + r_1 \quad (1)$$

قانون دوم: اگر  $x$  برابر  $A_2$  و  $y$  برابر  $B_2$  باشد آنگاه:

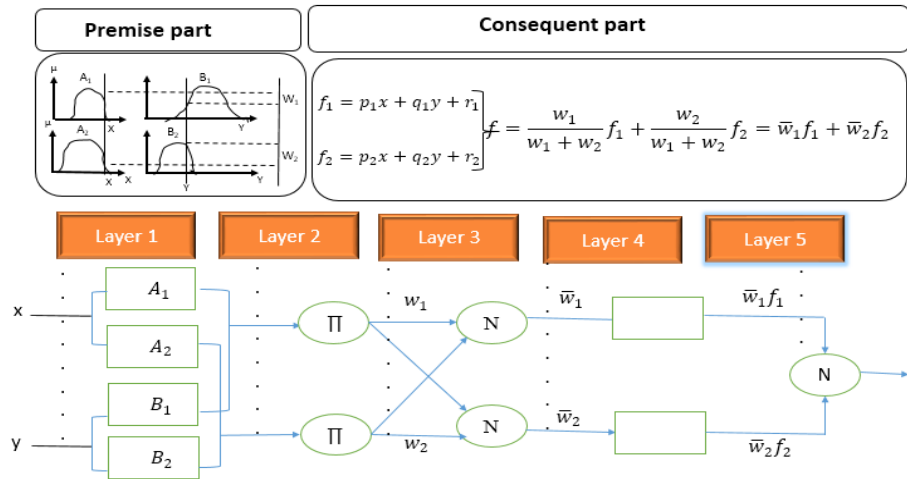
$$z_2 = p_2 x + q_2 y + r_2 \quad (2)$$

که در آن:  $p_i, q_i, r_i$  ( $i=1,2$ ) پارامترهای خطی در بخش تالی


استفاده قرار گرفت. روند آموزش دو مرحله دارد: مرحله اول با ثابت فرض کردن پارامترهای بخش مقدماتی، از روش حداقل مربعات، پارامترهای بخش تالی تعیین شد. سپس در مرحله دوم، سیگنال‌های خطا پس انتشار می‌یابند. روش شیب پس انتشار به این جهت به کار می‌رود تا پارامترهای مقدماتی از طریق حداقل کردن تابع هزینه درجه دوم کلی، اصلاح شود. در شکل ۵ ساختاری از عملکرد و ارتباط بین لایه‌ها در مدل سیستم استنتاج عصبی فازی تطبیقی آورده شده است.

$$O_{5,i} = \overline{w_1 f_i} = \frac{\sum_{i=1}^4 w_i f_i}{\sum_{i=1}^4 w_i} \quad (7)$$

ویژگی متمایز کننده ANFIS، فراهم کردن الگوریتم یادگیری پیوندی روش شیب پس انتشار و روش حداقل مربعات، به منظور اصلاح پارامترها می‌باشد. روش شیب پس انتشار جهت تنظیم پارامترهای غیرخطی مقدماتی به کار گرفته می‌شود، در حالی که روش حداقل مربعات جهت تعیین پارامترهای خطی بخش تالی مورد



شکل ۴- سیستم ANFIS معادل با سیستم فازی سوگنو با تابع عضویت مثلثی



شکل ۵- ساختار لایه‌ها در مدل سیستم استنتاج فازی عصبی تطبیقی

سازی استفاده شده است (گلابی و همکاران، ۱۳۹۲).

$$y = 0.1 + \left( 0.8 \times \left( \frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) \right) \quad (8)$$

x: داده مورد نظر، x: میانگین داده‌ها،  $x_{\min}$  و  $x_{\max}$ : به ترتیب حداکثر و حداقل داده‌ها و y: داده استاندارد شده می‌باشد. در این تحقیق از ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ درصد برای مرحله تست استفاده شده است.

### ساختارهای مختلف برای مدل‌سازی

برای اجرای فرامدل شبیه‌ساز عصبی- فازی، ۵ نوع ترکیب به عنوان پارامترهای ورودی مطابق جدول ۱ مورد بررسی قرار گرفت. پارامتر  $L_t$  تراز آب زیرزمینی در دوره زمانی ماهانه و پارامترهای  $L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}, L_{t-5}$  تراز آب زیرزمینی در دوره‌های زمانی گذشته می‌باشد. به منظور هماهنگی بهتر داده‌ها و افزایش سرعت اجرای مدل، داده‌ها با استفاده از روش استانداردسازی به اعدادی بین صفر تا یک تبدیل شدند و از رابطه ۸ برای استاندارد

جدول (۱)- ترکیب‌های مختلف مدل عصبی-فازی

ترکیب ورودی خروجی	
$L_t, L_{t-1}$	۱
$L_t, L_{t-1}, L_{t-2}$	۲
$L_t, L_{t-1}, L_{t-2}, L_{t-3}$	۳
$L_t, L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}$	۴
$L_t, L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}, L_{t-5}$	۵

ردیف و ۴۵ ستون) با فواصل ۵۰۰ متر ساخته شد که شامل ۸۱۶ سلول فعال و ۱۵۲۴ سلول غیر فعال بود. در این مطالعه برای شبیه‌سازی مرزهای ورودی و خروجی دشت لور- اندیمشک از بسته مرز بار عام استفاده شده است. برای تعیین شرایط اولیه با بررسی هیدروگراف واحد دشت لور- اندیمشک مشخص شد که نوسان سطح آب در سال آبی ۹۱-۱۳۸۹ حالت ماندگارتی نسبت به سایر سال‌ها دارد، بنابراین در مدل آب زیرزمینی آذر ماه سال ۱۳۹۰، به عنوان ماه ماندگار در نظر گرفته شد. مدل حالت ماندگار، برای دوره ماندگار آذر ۹۰ کالیبره شده و به عنوان اولین دوره تنش مدل غیرماندگار انتخاب گردید. مدل حالت ماندگار به سطح آب اولیه حساس نمی‌باشد. اما در صورتی که معادله جریان در منطقه غیرخطی باشد، ممکن است به ازای سطح اولیه مختلف آب جواب‌های مدل متفاوت باشند. به همین خاطر در این تحقیق از بسته‌های PCG2<sup>۱</sup> و یا DE4<sup>۲</sup> برای در نظر گرفتن این حالت استفاده شد. در این بسته‌ها متغیرهایی وجود دارد که با تنظیم آن‌ها می‌توان معادله‌های جریان غیرخطی را به درستی حل کرد. کد MODFLOW-2000 بارهای هیدرولیکی محاسبه شده در دوره ماندگار را به عنوان سطح آب اولیه برای مدل غیرماندگار در نظر می‌گیرد. لذا بارهای هیدرولیکی محاسبه شده در هر گام زمانی، سطح آب اولیه برای گام زمانی بعدی می‌باشد و بطور هم‌زمان پارامترهای مجهول مدل تخمین زده می‌شود. در این مطالعه همچنین با استفاده از مقاطع ژئوفیزیکی تهیه شده دشت و اطلاعات چاه‌های مشاهده‌ای که به سنگ کف برخورد کرده‌اند نقشه ارتفاع سنگ کف دشت لور تهیه گردید. برای پارامتر تغذیه چون در مدل آب زیرزمینی معمولاً اطلاعات کمی از میزان تغذیه در مناطق مختلف در دسترس است، پارامتر تغذیه برای محدوده وسیعی در نظر گرفته شد و در طول کالیبراسیون بهینه گردید. بعد از اینکه تمام بسته‌ها ساخته شد و اطلاعات مورد نیاز مدل تکمیل شد، مدل اجرا شد. اما مقادیر محاسبه شده و مشاهداتی اختلاف چشمگیری داشتند بنابراین در این مرحله از

### معیارهای ارزیابی مدل‌ها

برای ارزیابی مدل‌ها از سه معیار، ضریب تبیین ( $R^2$ )، جذرمیانگین مربعات خطا (RMSE) و شاخص کلی عملکرد مدل (OI) استفاده شد. روابط (۱۰ و ۱۱) این معیارها را نشان می‌دهد.

$$RMSE = \sqrt{\frac{\sum (Q_{obs} - Q_{pre})^2}{n}} \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2} \quad (10)$$

$$OI = \frac{1}{2} \left( 2 - \frac{RMSE}{Q_{max} - Q_{min}} + \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2} \right) \quad (11)$$

که در آن‌ها: n: تعداد داده‌ها،  $\bar{Q}$ : میانگین داده‌های مشاهداتی،  $Q_{obs}$  و  $Q_{pre}$ : به ترتیب داده‌های مشاهداتی و محاسباتی،  $Q_{min}$  و  $Q_{max}$ : حداکثر و حداقل داده‌ها می‌باشند. ضریب  $R^2$  میزان انطباق داده‌هایی که توسط مدل به وجود می‌آید و داده‌های واقعی را نشان می‌دهد. RMSE جذرمیانگین مربع خطاهای داده‌های محاسباتی و مشاهداتی را بیان می‌کند. واضح است که هر چه مقدار این عدد کم‌تر باشد به تبع، آموزش و شبیه‌سازی داده‌ها بهتر صورت گرفته است. OI شاخص کلی عملکرد مدل است. هر چه RMSE کم‌تر باشد، پیش‌بینی دقیق‌تر است. OI بین مقادیر  $-\infty$  تا یک تغییر می‌کند. هر چه مقدار شاخص کلی عملکرد مدل به یک نزدیک‌تر باشد نشان‌دهنده یک تناسب کامل بین مقادیر تجربی و پیش‌بینی می‌باشد (Mattar and Alamoud., 2015).

### نتایج و بحث

#### مدل مفهومی MODFLOW

در این مطالعه، جهت شبکه‌بندی در راستای شمال غربی و با زاویه ۱۲ درجه منحرف شد و ابعاد سلول‌های شبکه  $500 \times 500$  متر در نظر گرفته شد. لذا شبکه بندی مدل با تعداد ۲۳۴۰ سلول (۵۲

1- Preconditioned Conjugate-Gradient solver

2-Direct Solver




نتایج حاصل از بررسی ترکیب‌های مختلف مدل عصبی فازی در جدول ۲ ارائه شده است. در بین این ترکیب‌ها، ترکیب شماره ۵ و ۴ و ۳ به ترتیب با ۵ تاخیر زمانی و ۴ تاخیر زمانی و ۳ تاخیر زمانی در مرحله آموزش به ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشتند و با افزایش تاخیرهای زمانی ضریب تبیین مدل بهتر شده است و ضریب تبیین آن‌ها به ترتیب برابر ۰/۹۹۵۲ و ۰/۹۲۷۵ و ۰/۹۲۵۰ می‌باشد و همچنین جذر میانگین مربعات خطای مرحله تست ترکیب شماره ۵ برابر ۰/۰۰۷۷ و ترکیب ۴ برابر ۰/۰۲۹۷ و ترکیب ۳ برابر ۰/۰۳۰۲ می‌باشد و با افزایش تاخیرهای زمانی همچنین جذر میانگین مربعات خطا نیز کاهش پیدا کرده است. از طرفی در بین این ترکیب‌ها در مرحله تست ترکیب شماره ۳ و ۲ و ۵ با ۳ تاخیر زمانی و ۲ تاخیر زمانی و ۵ تاخیر زمانی به ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشتند و ضریب تبیین آن‌ها به ترتیب برابر ۰/۶۳۴۸ و ۰/۶۲۵۹ و ۰/۵۸۰۰ می‌باشد و همچنین جذر میانگین مربعات خطای مرحله تست ترکیب شماره ۳ برابر ۰/۱۴۷۷ و ترکیب ۲ برابر ۰/۱۵۲۸ و ترکیب ۵ برابر ۰/۲۶۳۳ می‌باشد. در کل ترکیب ۳ با ۳ تاخیر زمانی، عملکرد بهتری نسبت به سایر ترکیب‌ها داشته است و بعد از آن ترکیب ۵ با افزایش تاخیر زمانی نسبت به ترکیب ۳ عملکرد بهتری داشته است. با توجه به نتایج ترکیب‌های مختلف می‌توان به این نتیجه رسید که تقریباً با ۳ تاخیر زمانی می‌توان به نتایج قابل قبولی در آموزش و تست فرامدل شبیه ساز عصبی-فازی رسید. شکل ۸ مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه ساز عصبی-فازی در مرحله تست را نشان می‌دهد. با توجه به این شکل عملکرد مدل مناسب بوده است.

کار عملیات واسنجی مدل انجام شد و در حالت ماندگار مدل کالیبره شد. کالیبراسیون مدل از روش رگرسیون غیرخطی و با استفاده از MODFLOW-2000 انجام گرفت. در این روش برای هر پارامتر مقادیر اولیه تخمین زده شد و با روش سعی و خطا کالیبراسیون انجام شد با این هدف که اختلاف مقادیر محاسباتی و مشاهداتی کم‌تر از یک متر باشد. در واسنجی حالت ماندگار هدایت هیدرولیکی دشت و ضریب گذردهی مرزها بهینه گردید. در شکل ۶ اجزای مدل عددی تهیه شده و تراز آب زیرزمینی دشت در حالت ماندگار بعد از عملیات واسنجی نشان داده شده است. در مرحله بعد، واسنجی مدل در حالت غیر ماندگار به مدت ۳/۵ سال (مهرماه سال ۸۸ تا اسفند ۹۱) انجام شد و دوره‌های تنش حالت غیر ماندگار به تدریج به مدل اضافه شده و مدل در هر مرحله واسنجی شد و در نهایت بعد از واسنجی حالت غیر ماندگار، یک سال و نیم دیگر به دوره شبیه سازی اضافه شد تا مدل برای این دوره ۱۸ ماهه صحت‌سنجی گردد. صحت‌سنجی مدل به مدت ۱/۵ سال و از فروردین ۹۲ تا شهریور ۹۳ انجام شد.



نتایج حاصل از بررسی مدل نشان داد که مدل مفهومی مادفلو دارای ضریب تبیین ۰/۹۱۲۸ در مرحله آموزش و ضریب تبیین ۰/۷۸۳۸ در مرحله تست و جذر میانگین مربعات خطا در مرحله آموزش ۰/۳۳۷ و جذر میانگین مربعات خطا در مرحله تست ۰/۴۴۹ بوده است. شکل ۷ مقایسه مقادیر مشاهداتی را با مقادیر برآوردی برای مدل مفهومی مادفلو در مرحله تست نشان می‌دهد. با توجه به این شکل عملکرد مدل مناسب بوده است.

### نتایج فرامدل شبیه ساز عصبی - فازی



شکل ۶- اجزای مدل عددی تهیه شده و تراز آب زیرزمینی دشت در حالت ماندگار

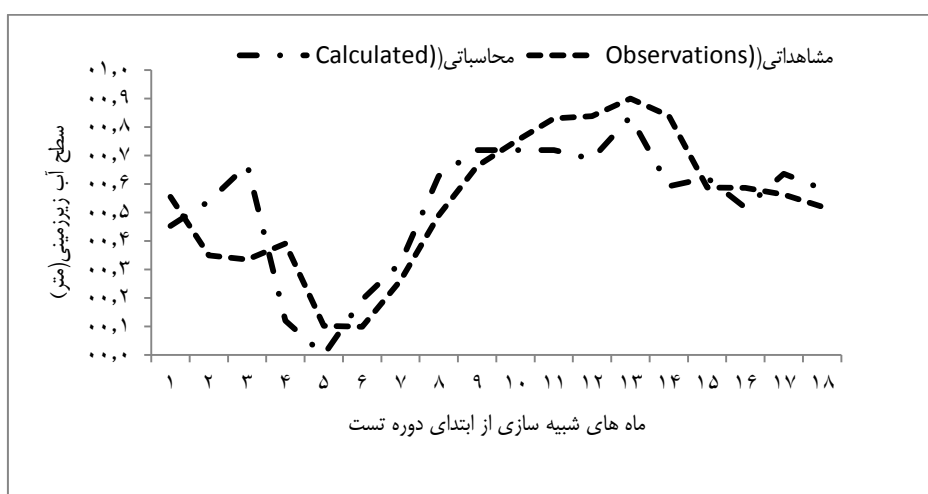





شکل ۷- مقایسه نتایج مدل مفهومی مادفلو با مقادیر مشاهده‌ای، مرحله تست

جدول ۲- بهترین ساختار مدل عصبی فازی

تست RMSE	آموزش RMSE	تست R <sup>2</sup>	آموزش R <sup>2</sup>	تعداد تابع عضویت	نوع تابع عضویت خروجی	نوع تابع عضویت ورودی	الگوی به کار گرفته شده
۰/۱۷۱۳	۰/۰۴۸۷	۰/۵۷۳۶	۰/۸۰۵۳	۳	constant	مثلثی Trimf	$L_{t-1}$
۰/۱۵۲۸	۰/۰۴۶۵	۰/۶۲۵۹	۰/۸۲۳۰	۳ ۳	constant	مثلثی Trimf	$L_{t-1}, L_{t-2}$
۰/۱۴۷۷	۰/۰۳۰۲	۰/۶۳۴۸	۰/۹۲۵۰	۳ ۳ ۳	constant	Trapmf دوزنقه ای	$L_{t-1}, L_{t-2}, L_{t-3}$
۰/۲۳۲۷	۰/۰۲۹۷	۰/۴۷۲۹	۰/۹۲۷۵	۳ ۳ ۳ ۳	constant	Trapmf دوزنقه ای	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}$
۰/۲۶۳۳	۰/۰۰۷۷	۰/۵۸۰۰	۰/۹۹۵۲	۳ ۳ ۳ ۳ ۳	constant	Trapmf دوزنقه ای	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}, L_{t-5}$



شکل ۸- مقایسه نتایج مدل عصبی فازی با مقادیر مشاهده‌ای، مرحله تست

ساز عصبی- فازی دارای جذر میانگین مربعات خطای کم‌تری در مرحله تست و آموزش نسبت به مدل مفهومی مادفلو داشته است. بر اساس معیار OI که هرچه مقادیر به یک نزدیک‌تر باشد مدل عملکرد بهتری دارد، مشاهده می‌شود که مدل مادفلو در مرحله تست دارای معیار OI بیش‌تری نسبت به فرامدل شبیه‌سازعصبی- فازی بوده است و در مرحله آموزش این مقدار کم‌تر است و می‌توان با مشاهده مقادیر جدول ۳ به این نتیجه رسید که در شرایط کمبود داده و اطلاعات اگرچه رایج است تا از مدل‌های بر مبنای فازی استفاده شود ولی در این مطالعه موردی، فرامدل شبیه‌ساز عصبی- فازی نمی‌تواند جایگزین مناسبی برای مدل مفهومی مادفلو، باشد و این فرامدل شبیه‌ساز، اگرچه توانایی آموزش بالایی نسبت به مدل مفهومی مادفلو دارد ولی در مرحله تست عملکرد ضعیفی از خود نشان داد.

#### مقایسه نتایج مدل‌های استفاده شده

در این قسمت به منظور این که مقایسه‌ی مناسبی بین عملکرد دو مدل صورت گیرد مقایسه کمی بین دو مدل صورت گرفت. برای مقایسه کمی بین دو مدل از سه معیار ارزیابی به نام‌های ضریب تبیین، جذر میانگین مربعات خطا و شاخص کلی عملکرد مدل استفاده شد. نتایج این بررسی در جدول ۳ ارائه شده است. با توجه به جدول ۳ و مقایسه مدل‌های مادفلو و فرامدل شبیه‌ساز عصبی- فازی مشاهده می‌شود که در مرحله آموزش ضریب تبیین مدل مادفلو با توجه به ورودی‌های متعدد و داده‌های مختلف که می‌گیرد از ضریب تبیین فرامدل شبیه‌ساز عصبی- فازی در مرحله آموزش این کم‌تر شده است ولی در مرحله تست مقدار ضریب تبیین مدل مفهومی مادفلو از مدل شبیه ساز عصبی- فازی بیش‌تر گردیده است. از طرفی با توجه به پارامتر جذر میانگین مربعات خطا، مشاهده می‌شود که فرامدل شبیه

جدول ۳- مقایسه مدل‌های استفاده شده در این تحقیق

OI		RMSE		R2		مدل
تست	آموزش	تست	آموزش	تست	آموزش	
۰/۸۲۶۶	۰/۹۲۰۵	۰/۴۴۹۱	۰/۳۳۷۳	۰/۷۸۳۶	۰/۹۱۲۸	MODFLOW
۰/۷۱۵۵	۰/۹۳۱۵	۰/۱۴۷۷	۰/۰۳۰۲	۰/۶۳۴۸	۰/۹۲۵۰	ANFIS

دشت دز). پایان نامه دکتری، دانشگاه شهید چمران اهواز.

## نتیجه گیری

پورمحمدی، س.، ملکی نژاد، ح.، پورشرعیاتی، ر. ۱۳۹۲. مقایسه کارایی روش‌های شبکه عصبی و سری‌های زمانی در پیش‌بینی سطح آب زیرزمینی (مطالعه موردی: زیرحوزه بختگان استان فارس). نشریه پژوهش‌های حفاظت آب و خاک گرگان. ۲۰: ۴-۲۶-۲۵۱.

خاشعی سیوکی، ع.، قهرمان، ب.، کوچک‌زاده، م. ۱۳۹۲. مقایسه مدل‌های شبکه عصبی مصنوعی، ANFIS و رگرسیون در برآورد سطح ایستابی آبخوان دشت نیشابور. نشریه آبیاری و زهکشی ایران. ۷: ۱-۲۲-۱۰.

زارعی، ح.، آخوندعلی، ع.م. ۱۳۸۶. مقایسه روش‌های زمین آماری و آمار کلاسیک در ترسیم هیدروگراف واحد آب زیرزمینی. طرح پژوهشی سازمان آب و برق خوزستان، ص ۷۱.

ستوده‌پور، م.، فریدونی، م. ۱۳۹۳. شبیه‌سازی تراز آب زیرزمینی با استفاده از مدل‌های فازی عصبی و مقایسه آن با مدل‌های سری زمانی (مطالعه موردی: دشت جم). پانزدهمین کنفرانس دانشجویان عمران سراسر کشور، ارومیه، انجمن علمی دانشجویی عمران دانشگاه ارومیه.

گلابی، م.ر.، آخوندعلی، ع.م.، رادمش، ف. ۱۳۹۲. مقایسه عملکرد الگوریتم‌های مختلف شبکه عصبی مصنوعی در مدل‌سازی بارندگی فصلی (مطالعه موردی: ایستگاه‌های منتخب استان خوزستان). نشریه تحقیقات کاربردی علوم جغرافیایی. ۳۰: ۱۶۹-۱۵۱.

مسلمی، خ. ۱۳۹۰. پیش‌بینی سطح آب زیرزمینی دشت بسطام با استفاده از مدل شبکه عصبی مصنوعی (ANN) و شبکه استنتاج تطبیقی عصبی فازی (ANFIS). پایان نامه کارشناسی ارشد، کتابخانه مرکزی دانشگاه صنعتی شاهرود.

ملکی نژاد، ح.، پورشرعیاتی، ر. ۱۳۹۲. کاربرد و مقایسه مدل سری زمانی تجمعی و مدل شبکه عصبی مصنوعی در پیش‌بینی تغییرات سطح آب زیرزمینی (مطالعه موردی: دشت مروست). علوم و مهندسی آبیاری (مجله علمی کشاورزی). ۳۶: ۳-۹۲-۸۱.

در این تحقیق از دو مدل به نام‌های مدل مفهومی مادفلو و فرامدل شبیه‌ساز عصبی- فازی جهت مدل‌سازی هیدروگراف معرف آبخوان استفاده شد. هدف از این مطالعه نشان دادن تفاوت‌های بین دو مدل و همچنین بررسی توانایی آن‌ها برای مدل‌سازی نوسانات سطح ایستابی دشت لور- اندیمشک بوده است. نتایج نشان داد که مدل مفهومی مادفلو با ضریب تبیین ۰/۷۸۳۶ در مرحله تست نسبت به فرامدل شبیه‌ساز عصبی- فازی با ضریب تبیین ۰/۶۳۴۸ دارای عملکرد بهتری می‌باشد و این می‌تواند به این دلیل باشد که در مدل‌سازی هیدروگراف معرف در شرایط داده‌های کم چون در مدل مادفلو پارامترهای جانبی بیش‌تری به‌عنوان ورودی، برای مدل‌سازی تراز آب زیرزمینی وارد مدل شدند به دقت آن افزوده شده و باعث عملکرد بهتر این مدل مفهومی شده است و می‌توان به این نتیجه رسید که در شرایط کمبود داده و اطلاعات اگرچه رایج است تا از مدل‌های بر مبنای فازی استفاده شود ولی در این مطالعه موردی و برای این منظور خاص، فرامدل شبیه‌ساز عصبی- فازی نتوانست جایگزین مناسبی برای مدل مفهومی مادفلو باشد. نتایج این مطالعه در قسمت مدل‌سازی با فرامدل شبیه‌ساز عصبی- فازی با مطالعات مسلمی (۱۳۹۰) و خاشعی سیوکی و همکاران (۱۳۹۲) و ستوده پور و فریدونی (۱۳۹۳) همخوانی دارد. ولی با توجه به این که اولین بار است که چنین مقایسه‌ای انجام می‌گیرد و این از نوآوری‌های تحقیق حاضر است می‌توان به عنوان پیشنهاد از مدل‌های شبیه‌ساز دیگر استفاده کرد و نتایج را با هم مقایسه کرد.

## منابع

- اکبرزاده، ف.، حسن پور، ح.، امام قلی زاده، ص. ۱۳۹۵. پیش‌بینی تراز آب زیرزمینی دشت شاهرود با استفاده از شبکه عصبی مصنوعی تابع پایه شعاعی. دانشگاه علوم کشاورزی و منابع طبیعی ساری پژوهشنامه مدیریت حوزه آبخیز. ۷: ۱۳-۱۱۸-۱۰۴.
- آذری، آ. ۱۳۹۲. شبیه‌سازی و بهینه‌سازی چند منظوره برای مدیریت بهره‌برداری تلفیقی منابع آب در شرایط برهم کنش آب سطحی و زیرزمینی با استفاده از روش الگوریتم ژنتیک (مطالعه موردی:

- Journal of Hydrology. 372. 1-4: 68-79.
- Lu, C., Chen, Y., Zhang, C., Luo, J. 2013. Steady-state freshwater-seawater mixing zone in stratified coastal aquifers. *Journal of Hydrology*. 230:52-67.
- Nourani, V., Komasi, M. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology*. 490: 41-55.
- Mattar, M.A., Alamoud, A.I. 2015. Artificial neural networks for estimating the hydraulic performance of labyrinth-channel emitters. *Computers and Electronics in Agriculture*. 114:189-201.
- Nayak, P.C., Sudheer, K.P., Rangan, D.M., Ramasastri, K.S. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*. 291.1-2: 52-66.
- Rezaie-balf, M., Naganna, S.R., Ghaemi, A., Deka, P.C. 2017. Wavelet coupled MARS and M5 model tree approaches for groundwater level forecasting. *Journal of Hydrology*. 553:356-373.
- Ross, T.J. 1995. *Fuzzy logic with engineering application*. McGraw Hill Inc., USA.
- Stanley Raj, A., Hudson Oliver, D., Srinivas, Y., Viswanath, J. 2017. Wavelet based analysis on rainfall and water table depth forecasting using Neural Networks in Kanyakumari district, Tamil Nadu, India. *Groundwater for Sustainable Development*. 5: 178-186.
- Yoona, H., Hyunb, Y., Leec, K. Ha, K.K. Kim, G.B. 2016. A method to improve the stability and accuracy of ANN- and SVM-based time series models for long-term groundwater level predictions. *Computers and Geosciences*. 90. PA:144-155.
- ندیری، ع.، نادری، ک.، اصغری مقدم، ا.، حبیبی، م. ح. ع. ۱۳۹۵. پیش بینی زمانی و مکانی سطح آب زیرزمینی با استفاده از روش های هوش مصنوعی و زمین آمار (مطالعه موردی: آبخوان دشت دوزدوزان). *نشریه جغرافیا و برنامه ریزی*. ۲۰. ۵۸ : ۲۸۱-۳۰۱.
- نورانی، و.، صالحی، ک. ۱۳۸۷. مدل سازی بارش- رواناب با استفاده از شبکه عصبی فازی تطبیقی و مقایسه آن با شبکه عصبی و روش استنتاج فازی. *مطالعه موردی: (منطقه ليقوان چای در استان آذربایجان شرقی)*. چهارمین کنگره ملی مهندسی عمران، دانشگاه تهران.
- Anderson, M.P., Woessner, W.W. 1992. *Applied groundwater modeling flow and adjective Transport*. Imprint: Academic Press, first Edition. 381p. 138-141
- Barzegar, R., Fijani, E., Asghari Moghaddama, A., Tziritis, E. 2017. Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *Science of the Total Environment*. 20-31.
- Bear, J. 2010. *Modeling Groundwater Flow and Contaminant Transport*. Springer Verlag. 23. 834 P.
- Jang, J.S.R., Sun, C.T., Mizutani, E. 1997. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice-Hall International. New Jersey. first Edition. 614p. 232-236
- Kisi, O. 2009. Evolutionary fuzzy models for river suspended sediment concentration estimation.

## Hydrograph Model Representing Aquifer with the Model of the Madflow and Meta model Neural-fuzzy Network Simulator (case study)

M. Zeinalie<sup>1</sup>, M. R. Golabi<sup>2\*</sup>, S. Farzi<sup>3</sup>, F. Radmanesh<sup>4</sup>

Received: Feb.09, 2018

Accepted: May.26, 2018

### Abstract

Decreasing atmospheric precipitation, limiting water resources and increasing drainage of groundwater has led to a reduction in the surface of the plain, and therefore an underground water map is an effective tool for managing and protecting these resources. In this study, the monthly statistical data of the surface of piezometers for 5 years water (89-88 to 93-92) related to the 8-pisometer level of the Lower-Andimeshk plain aquifer. At the beginning, using the Tesine method, the weighted average of each piezometer was obtained and the time series of the groundwater level of the plain, which represents the hydrograph of the representative water column of the study area, was calculated. Then, using the concept of groundwater of the Modflow and supermodel of the neuro-fuzzy simulator, the hydrograph represented the aquifer modeling and the results were compared. The results showed that the concept model of Modflow with a coefficient of explanation of 0.736 in the test phase compared to the neuro-fuzzy simulator model with a coefficient of explanation of 0.6348 has better performance.

**Keyword:** Hydrograph representing aquifer, Madflow model, Modeling, Meta model neural-fuzzy Simulator

1- Graduated Master of Water Resources Engineering, Department of Water Engineering, Faculty of Agriculture, Razi University, Kermanshah, Iran

2- Ph.D. Student, Department of Water Resources Engineering, Faculty of Water Sciences, Shahid Chamran University, Ahvaz, Iran

3- Graduated Master of Irrigation and Drainage, Department of Water Engineering, Faculty of Agriculture, Razi University, Kermanshah, Iran

4- Associate Professor of Water Resources Engineering, Faculty of Water Science, Shahid Chamran University, Ahvaz, Iran

(\*- Corresponding Author Email: Hamidgolabi65@gmail.com)