

## مقاله علمی-پژوهشی

# کاربرد الگوریتم K-Star در پیش‌بینی تراز آب زیرزمینی (مطالعه موردی: دشت آسپاس)

\*نوید راهنما قهفرخی<sup>۱</sup>، حیدر زارعی<sup>۲</sup>، فرشاد احمدی<sup>۳\*</sup>

تاریخ دریافت: ۱۴۰۱/۰۶/۲۹ تاریخ پذیرش: ۱۴۰۱/۱۱/۱۳

## چکیده

در این مطالعه تراز سطح آب زیرزمینی دشت آسپاس واقع در شمال غربی حوضه آبریز دریاچه‌های طشك-بختگان مهارلو در استان فارس با استفاده از داده‌های ۳۹ پیزومتر در محدوده آبخوان در دوره آماری ۱۳۸۰-۹۶ شبیه‌سازی شد. در این خصوص از دو مدل K-Star و ANN با تأخیرهای ۱، ۲ و ۳ در دو فاز آموزش و آزمایش استفاده شد. مدل ANN در این مطالعه علاوه بر تأخیرهای یاد شده با تعداد لایه پنهان و نورون متفاوت نیز مورد بررسی قرار گرفت. با توجه به افت و نوسانات سطح آب زیرزمینی در دوره آماری یاد شده، آبخوان مورد مطالعه به ۴ منطقه a، b، c و d تقسیم شد. نتایج شبیه‌سازی تراز سطح آب زیرزمینی در منطقه a عملکرد بهتری نسبت به مدل K-Star با ۲ تأخیر در این منطقه عملکرد را رانده کرده است. مدل ANN با ۲ لایه پنهان و نورون در منطقه b، با ۲ لایه پنهان و نورون در منطقه c و با ۴ لایه پنهان و نورون در منطقه d بهترین الگو برای شبیه‌سازی مقادیر تراز سطح آب زیرزمینی معرفی شدند. به طور متوسط الگوهای برتر معرفی شده در مناطق b، c و d توانستند میزان خطای را در ترتیب K-Star بـ ۴۲.۵٪ و ۸۱ درصد بهبود بخشدند. عملکرد ضعیف مدل K-Star در دو منطقه b و d نیز بدوضوح قابل مشاهده می‌باشد. به طور کلی نتایج نشان داد که تأخیر ۱ مدل ANN در مناطق سه‌گانه a، b و c با تعداد لایه پنهان و نورون‌های مختلف بهترین عملکرد را در شبیه‌سازی مقادیر تراز سطح ایستابی داشته است.

**کلیدواژه‌ها:** افت سالانه، پیزومتر، شبکه عصبی مصنوعی، مدل K-Star، نوسان آب زیرزمینی.

شدن رویرو شده‌اند (Salari et al., 2021). در یک منطقه، زمانی که نرخ پمپاژ بزرگ‌تر از کل تخلیه باشد، ذخیره آب زیرزمینی به‌طور مداوم برای متعادل کردن نرخ پمپاژ استفاده می‌شود، بنابراین سطح آب زیرزمینی (GWL) به‌طور مداوم کاهش می‌یابد. هنگامی که نرخ پمپاژ کمتر از کل تخلیه باشد، سیستم آب زیرزمینی به حالت تعادل جدیدی می‌رسد. زمان مورد نیاز برای رسیدن به تعادل جدید معمولاً بسیار طولانی است و کاهش GWL می‌تواند بسته به ویژگی‌های سیستم آب زیرزمینی، ماهیت تعذیه و تخلیه و همچنین الگو و نرخ پمپاژ بیش از حد چاه‌ها باشد (Zhou, 2009).

در کشورهایی مانند ایران که با کمبود منابع آبی مواجه‌اند، توجه به کلیه منابع آبی از اهمیت بالایی برخوردار است. به همین خاطر، برای توسعه پایدار از مدیریت یکپارچه استفاده می‌شود. اولین قدم در مدیریت یکپارچه منابع آب، شناخت دقیق مشخصات هر آبخوان است که یکی از مهم‌ترین مشخصات آن، سطح آب زیرزمینی است. در این راستا، محققان راه حل‌هایی برای مدیریت آب‌های زیرزمینی با توجه به روش‌های شبیه‌سازی و پیش‌بینی و اقدامات کنترل شده ارائه کرده‌اند (Afkhamifar et al., 2020).

## مقدمه

آب‌های زیرزمینی یک منبع مهم آب شیرین برای مصارف آشامیدنی، کشاورزی و صنعتی در بسیاری از کشورها است (Yadav et al., 2020). آب‌های زیرزمینی منبع اساسی برای فعالیت‌های آبیاری و آب آشامیدنی، به ویژه در مناطق خشک و نیمه‌خشک است (Sharafati et al., 2020). در سال‌های اخیر با توجه به برداشت‌های بی‌رویه از منابع آب زیرزمینی، اغلب آبخوان‌های کشور با چالش‌های زیادی مانند خشک شدن چشمدها و قنات‌ها، افت زیاد سطح آب، زرون‌نشست زمین، کاهش کیفیت آب و در نهایت ممنوعه و بحرانی

- ۱- دانشجوی کارشناسی ارشد مهندسی منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز.
  - ۲- دانشیار گروه هیدرولوژی و منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز.
  - ۳- نویسنده مسئول و استادیار گروه هیدرولوژی و منابع آب، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز
- (Email: f.ahmadi@scu.ac.ir) - نویسنده مسئول:

نتایج به بالاترین دقت برستند.

Iqbal et al. (2020) آب‌های زیرزمینی محدوده رودخانه راوی<sup>۱</sup> و سوتلچ<sup>۲</sup> را با استفاده از شبکه‌های عصبی مصنوعی (ANN) و متغیرهای هواشناسی (بارندگی (R)، حداکثر دما (Max.T)، دمای حداقل (Min.T)، تابش خورشیدی (S.R)، باد (W)، رطوبت نسبی (R.H)، ارتفاع از سطح (E)، سطح چند ضلعی (A) و اعماق سطح آب (D/W) شبیه‌سازی کردند. با استفاده از انواع مختلف معماری شبکه، مانند تعداد نورون‌ها، لایه‌های پنهان و تابع فعال‌سازی با درصد متفاوتی از داده‌ها در آموزش، اعتبارسنجی و آزمایش مورد مطالعه گرفت. معیارهای عملکرد میانگین مربع خطأ (MSE)، میانگین خطای مطلق (MAE) و ضریب تعیین (R) نشان دادند که مدل ANN با تک لایه پنهان، ۲۴ نورون، ۸۰ درصد داده‌ها برای آموزش، ۱۰ درصد برای اعتبارسنجی، ۱۰ درصد برای آزمایش و استفاده از تابع فعال‌سازی سیگموئید، مقادیر MAE، MSE و R به ترتیب برابر با ۰/۰۳۳۸، ۰/۰۰۲۳ و ۰/۰۹۷؛ برای قبل از موسمی و ۰/۰۳۱، ۰/۰۰۲۱ و ۰/۰۹۷۴ برای مورد پس از موسمی است به دست آمد.

الگوریتم K-Star یک روش طبقه‌بندی مبتنی بر مثال است که بر اساس موارد آموزشی مشابه، طبقه‌بندی را انجام می‌دهد و در مقایسه با الگوریتم‌های ماشین یادگیری، نتایج مطلوبی را ارائه می‌کند. این مدل در سال‌های اخیر در مطالعات مختلفی مورد بررسی قرار گرفته است. Khosravi et al. (2019) با استفاده از نه مدل، از جمله پنج الگوریتم داده کاوی و مدل K-Star و چهار سیستم استنتاج عصبی فازی تطبیقی (ANFISs)، به پیش‌بینی و شبیه‌سازی تبخیر-تعرق مرجع (ETo) در ایستگاه‌های هواشناسی در بغداد و موصل (عراق) پرداختند. بررسی‌ها روی دقت مدل‌سازی با ترکیب‌های مختلف پارامترهای رودودی نشان داد که علی‌رغم ساختارهای مختلف مدل‌ها، هیچ ترکیب ورودی واحدی یک نتیجه مدل‌سازی ثابت را نشان نداد. برای هر دو ایستگاه، مدل ANFIS-GA به طور کلی بیشترین قدرت پیش‌بینی را نشان داد در حالی که الگوریتم درخت تصادفی ضعیفترین را نشان داد.

Charles et al. (2021) یک مدل مؤثر برای پیش‌بینی کیفیت آب با استفاده از الگوریتم K-Star، روش نمونه‌برداری مبتنی بر مجموعه (SEM) و واحد رمزگذاری خودکار متغیر (VAE) به نام مدل SEM-VAE معرفی کردند. مدل SEM-VAE از مدیریت داده‌های عدم تعادل کلاس مبتنی بر SEM استفاده می‌کند. علاوه بر این، فرآیند پیش‌بینی مبتنی بر VAE برای تعیین سطح کیفیت واقعی آب را انجام دادند. برای انجام فرآیند شبیه‌سازی، نمونه‌های آب زیرزمینی از منطقه دارماپوری<sup>۳</sup> در تامیل نادو<sup>۱</sup> جمع‌آوری شده و با استفاده از

منابع آب زیرزمینی، ارزیابی اثرات پارامترهای مختلف، روی تراز آب زیرزمینی می‌باشد. پیش‌بینی تعییرات تراز آب زیرزمینی در اثر تعییر عوامل مؤثر، بهوسیله مدل‌سازی امکان پذیر می‌باشد. در این راستا روش‌های مختلفی بر مبنای مدل‌های مفهومی، فیزیکی، عددی، آماری و غیره وجود دارد (Salari et al., 2021). شبیه‌سازی جریان آب زیرزمینی با استفاده از مدل‌های ریاضی یک روش مطالعه غیرمستقیم است که می‌تواند با استفاده از یک سری معادلات ریاضی در شرایط واقعی آبخوان شبیه‌سازی شود. وضعیت آینده منابع آب را می‌توان با استفاده از مدل‌های ریاضی پیش‌بینی کرد (Kheirandish et al., 2020). اگرچه مدل‌های فیزیکی و ریاضی ابزار اساسی و دقیقی جهت تعیین متغیرهای هیدروژئولوژیکی و درک فرآیندهای صورت گرفته در یک سیستم می‌باشند، اما دارای محدودیت‌های هزینه‌ای و زمانی هستند. جدا از این دو مورد، این مدل‌ها نیازمند اطلاعات دقیق و متنوع ورودی هستند که نیازمند حجم زیاد محاسبات و زمان طولانی برای ساخت و اجرای مدل می‌باشد. از سوی دیگر، در اغلب موارد ضروری است مدل شبیه‌سازی با مدل‌هایی چون بهینه‌سازی به جهت مدیریت بهینه از منابع آب زیرزمینی ترکیب شوند که تلفیق مدل‌های فیزیکی و عددی این تبادل را دشوار و گاه‌ناممکن می‌کند. با توجه به توضیحات و مشکلات موجود در استفاده از مدل‌های مذکور در برخی موارد لازم است از مدل‌های هوشمند و غیرخطی به جای مدل‌های عددی و فیزیکی استفاده کرد (Ghourdoyee Milan et al., 2020).

پیشرفت در مدل‌سازی رایانه‌ای، قدرت محاسبات و پردازش اطلاعات منجر به ایزارهای بهبود یافته و عملی برای درک بهتر سیستم‌های طبیعی بسیار پیچیده شده است. مطالعات زیادی بر روی کاربرد روش‌های یادگیری ماشین در علم هیدروژئولوژی متتمرکز شده است (Kombo et al., 2020). طی دهه‌های گذشته، مدل‌های هوش مصنوعی به دلیل مزیت‌های خود نسبت به مدل‌های عددی مورد توجه بسیاری قرار گرفته‌اند و کارایی آن‌ها در پیش‌بینی سیستم‌های هیدروژئولوژیک پیچیده کارآمد به اثبات رسیده است (Nguyen et al., 2020; Nhu et al., 2020; Pham et al., 2019; Xu et al., 2020; Eslami et al., 2022 2020).

همچنین مطالعات متعددی از شبکه‌های عصبی مصنوعی با ساختارهای مختلف برای سطح آب زیرزمینی (GWL) و شبیه‌سازی پتانسیل استفاده کرده و عملکرد Lallahem et al., 2005; Taormina et al., 2012; Mirarabi et al., 2019 Banadkooki et al., 2020; Jaferi et al., 2019; Khedri et al., 2020; Kombo et al., 2020; Maroufpoor et al., 2020; Nazeri-Tahroudi et al., 2020; Tabatabaei et al., 2021; Raji et al., 2022 رگرسیون اولیه ماشین‌هایی مانند ANN باید بهینه‌سازی شوند تا

1 - Ravi

2 - Sutlej

3 - Dharmapuri

تراز سطح آب زیرزمینی در مقیاس سالانه در دوره آماری ۱۳۹۶-۱۳۸۰ استفاده شده است که از شرکت سهامی آب منطقه‌ای استان فارس اخذ شده است. متوسط افت سطح آب زیرزمینی در دوره آماری مورد بررسی در منطقه مورد مطالعه حدود ۷ متر و متوسط سطح آب زیرزمینی نیز در منطقه مورد مطالعه حدود ۴ متر می‌باشد. شکل ۱ موقعیت منطقه مورد مطالعه و هم‌چنین موقعیت سایت‌های نمونه‌برداری را در منطقه مورد مطالعه نشان می‌دهد. جدول ۱ خصوصیات داده‌های مورد بررسی را نشان می‌دهد.

### شبکه عصبی مصنوعی

روش شبکه عصبی مصنوعی برای بار اول توسط McCulloch and Pitts (1943) مطرح گردید و به علت یک ساختمان ساده، سرعت و قدرت محاسباتی آن خیلی زیاد مورد توجه قرار گرفته شد. شبکه عصبی مصنوعی در مطالعات هیدرولوژیک و مدیریت منابع آب داری کاربرد زیادی است. پیش‌بینی سطح آب از طریق روش معمولی نیاز به تخمین دقیق رواناب از یک رویداد بارندگی معین و یک مدل هیدرولوژیکی دقیق برای یک دبی معین دارد. تولید رواناب به شدت به توبوگرافی حوضه، شبکه رودخانه، خصوصیات خاک و رطوبت پیشین بستگی دارد. از طرف دیگر، مدل‌های هیدرولوژیکی فقط برای تعداد محدودی از مقطع م وجود هستند. همه این پارامترها همیشه در دسترس نیستند، بنابراین تخمین سطح آب را بسیار پیچیده می‌کند (Bustami et al., 2007).

### الگوریتم K-star

الگوریتم K-star را می‌توان به عنوان روشی برای تجزیه و تحلیل خوش‌های تعریف کرد که هدف اصلی آن تقسیم  $n$  مشاهده به خوشه است، به طوریکه در آن، هر مشاهده به خوشه با نزدیکترین میانگین تعلق دارد. الگوریتم K-star را می‌توان به عنوان یک روش یادگیری مبتنی بر نمونه توصیف کرد که از تئوری آنتروپی به عنوان اندازه‌گیری فاصله استفاده می‌کند. این روش با ارائه یک رویکرد سازگار برای مدیریت خصوصیات ارزشمند واقعی، ویژگی‌های نمادین و مقادیر از دست رفته امکان دریافت اطلاعات را از داده‌های موجود به حداقل می‌رساند. در الگوریتم K-star فاصله از یک نمونه به نمونه دیگر را می‌تواند به عنوان پیچیدگی تبدیل یک نمونه به نمونه دیگر توصیف شود (Granata et al., 2019).

همان‌گونه که ذکر شد K-star از یکتابع فاصله آنتروپی استفاده می‌کند. فاصله آنتروپیک برای به دست آوردن نمونه‌هایی که بیشترین شbahت را از مجموعه داده‌ها به یکدیگر دارند استفاده می‌کند. فرض کنید که  $a$  و  $b$  نمونه‌های مورد بررسی باشند، در این صورت  $P^*$  را می‌توان به عنوان احتمال هر مسیر توصیف کرد که از  $a$  به  $b$  است. بنابراین رابطه  $P$  به شرح زیر قابل بیان می‌باشد (Cleary and

متغیرهای فیزیکی و شیمیایی متمایز مورد بررسی قرار گرفتند. مقادیر شبیه‌سازی نشان داد که مدل SEM-VAE توانسته است بالاترین دقت را در شبیه‌سازی برآورد کند. ANN به دلیل توانایی آن در تعیین نتایج از داده‌های دیده نشده و مناسب در مدل‌سازی سیستم‌های پویا بر اساس زمان واقعی انتخاب می‌شود. این ویژگی‌های شبکه عصبی مصنوعی برای پیش‌بینی سطح آب مناسب هستند زیرا روابط فیزیکی آن‌ها به خوبی درک نشده است. ANN در دهه گذشته در مهندسی منابع آب نیز مورد استفاده قرار گرفته است که می‌توان از اولین مطالعات به پیش‌بینی سیلان (Garcia-Bartual, 2002; Wright and Dastorani, 2001) مدل‌سازی بارش-رواناب (Tokar and Johnson, 1999; Dolling (Thirumalaiah and Deo, 2000 and Varas, 2001; wright et al., 2002 Huang et al., 2003) (Huang et al., 2003) اشاره کرد. اطلاعات بیشتر در مورد ANN ها را می‌توان در مطالعات Haykin (1999) مشاهده کرد. با توجه به استفاده کمتر از الگوریتم K-Star در بحث شبیه‌سازی و مدل‌سازی متغیرهای هیدرولوژیک، در این مطالعه عملکرد الگوریتم K-Star در شبیه‌سازی مقادیر تراز سطح ایستابی در دشت آسپاس استان فارس مورد بررسی قرار گرفت. جهت مقایسه نتایج شبیه‌سازی و بررسی عملکرد الگوریتم K-Star، از مدل ANN نیز با الگوهای ورودی مختلف و تأخیرهای مختلف استفاده شد. در واقع هدف این مطالعه شبیه‌سازی تراز سطح ایستابی دشت آسپاس با استفاده از مدل‌های K-Star و ANN با تأخیرها و الگوهای ورودی مختلف و مقایسه عملکرد آن‌ها می‌باشد.

### مواد و روش‌ها

#### منطقه مورد مطالعه

منطقه مورد مطالعه در این تحقیق دشت آسپاس در استان فارس می‌باشد. دشت آسپاس در شمال غربی حوضه آبریز دریاچه‌های طشك-بختگان مهارلو در استان فارس واقع در ۳۰ کیلومتری جنوب غربی شهرستان اقلید و محدوده ۳۰ درجه و ۱۷ دقیقه تا ۳۰ درجه و ۵۴ دقیقه طول شرقی واقع شده است. سطح کلی منطقه مورد مطالعه حدود ۱۶۲۹ کیلومتر مربع است، که ۹۷۳ کیلومتر مربع آن را کوهستان و ۶۵۶ کیلومتر مربع آن را دشت تشکیل می‌دهد. بیشینه ارتفاع در منطقه ۳۴۰۲ متر و کمترین نقطه با ارتفاع ۲۱۳۶ متر در نزدیکی رحمت آباد واقع شده است. در مجموع از داده‌های ۳۹ حلقه چاه در محدوده دشت استفاده شده است. در این مطالعه از داده‌های

مناسب‌ترین نمونه را برای داده مورد نظر انتخاب نمود. در این مطالعه از بسته نرم افزاری Weka برای محاسبه مدل K-Star استفاده شده است.

: (Trigg, 1995)

### معیارهای ارزیابی

در این مطالعه از چندین معیار ارزیابی NSE و RMSE جهت بررسی مدل‌های مختلف مورد بررسی قرار گرفت.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (S_i - O_i)^2} \quad (6)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (S_i - O_i)^2}{\sum_{i=1}^N (S_i - \bar{O})^2} \quad (7)$$

که  $O_i$  برابر با مقادیر مشاهداتی،  $S_i$  مقادیر محاسباتی یا شبیه‌سازی شده،  $N$  برابر با تعداد داده‌ها و  $\bar{O}$  نیز متوسط داده‌های Nash, J. E., & Sutcliffe, 1970; Krause et al., 2005 مشاهداتی می‌باشد (

که در آن  $t$  نشان‌دهنده مقدار  $T$  یک مجموعه‌ای از تبدیلات داده‌است) بوده و  $p$  یک تابع احتمال است. با در نظر گرفتن اینکه شرایط زیر را دارد:

$$\sum_b P^*(b|a) = 1, \quad 0 \leq P^*(b|a) \leq 1 \quad (2)$$

با توجه به روابط فوق تابع K-star به شرح زیر بیان می‌شود:

$$K^*(b|a) = -\log P^*(b|a) \quad (3)$$

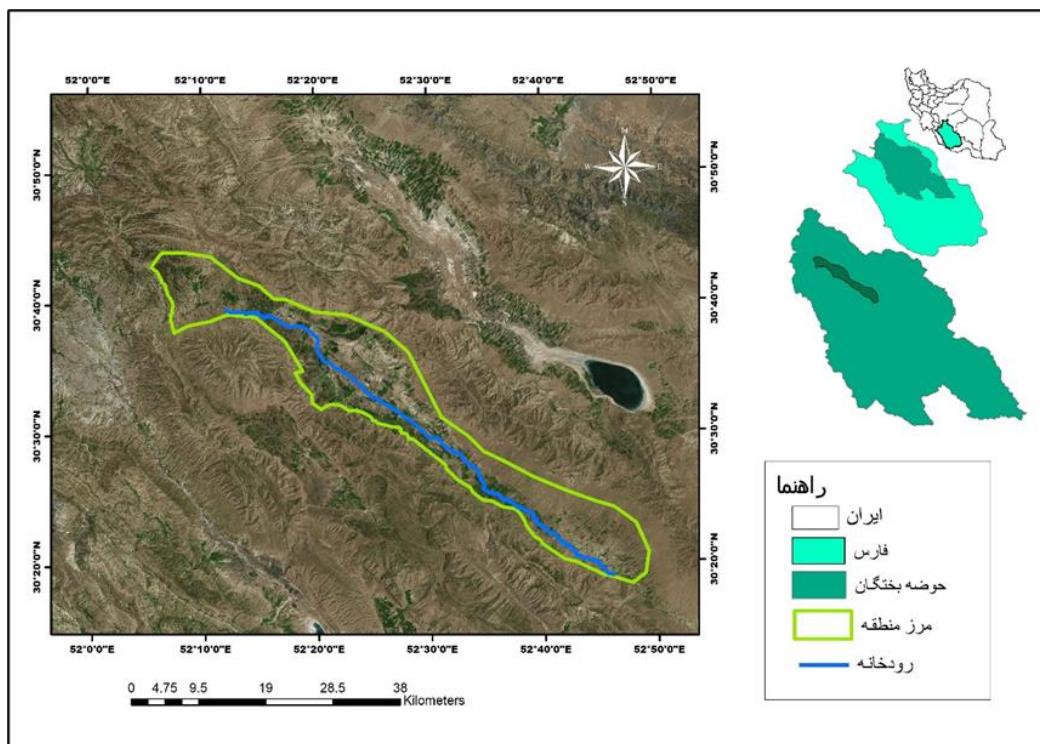
$$K^*(b|a) \geq 0, \quad K^*(b|a) + K^*(c|b) \geq K^*(c|a) \quad (4)$$

روابط فوق نماینده اعداد صحیح بوده و برای اعداد پیوسته به صورت زیر بازنویسی می‌شوند:

$$P^*(b|a) = P^*(i) = \frac{s}{\sqrt{2s-s^2}} \left( \frac{1-\sqrt{2s-s^2}}{1-s} \right), \quad i = |a-b|$$

$$K^*(b|a) = K^*(i) = \frac{1}{2} \log \left( \sqrt{2s-s^2} \right) - \log(s) + i \left[ \log(1-s) - \log(1-\sqrt{2s-s^2}) \right] \quad (5)$$

که در آن  $s$  پارامتر مدل بوده و بین صفر و یک متغیر است. با داشتن این روابط می‌توان با استفاده از مقادیر احتمالاتی محاسبه شده



شکل ۱- موقعیت منطقه مورد مطالعه

جدول ۱- خصوصیات آماری داده‌های سطح آب زیرزمینی منطقه مورد مطالعه

ایستگاه	طبقه	تغییرات	ضریب معیار	انحراف معیار	متوسط (متر)	ایستگاه	طبقه	تغییرات	ضریب معیار	انحراف معیار	متوسط (متر)	ایستگاه
د خیر	a	۰/۶۸	۶/۷۳	۹/۸۲	حاجی آباد	d	۰/۱۸	۰/۷۶	۴/۲۵	کنار جاده سده	۱۵/۱۰	دوراهی بابائی
دوروه ک اردلی	a	۰/۲۳	۳/۴۸	۳/۴۱	تزدیک سده	c	۰/۰۹	۴/۲۲	۴۶/۹۵	دوراهی آسپاس سده	۴۰/۱۶	شهرک اردلی
الله آباد	b	۰/۲۹	۴/۹۷	۱۷/۱۵	شرکت خوشایند	d	۰/۰۸	۱/۴۵	۱۷/۹۱	کنار جاده رودخانه سفید	۴۹/۵۴	شهر آشوب
شهر بالا	b	۰/۱۶	۶/۰۵	۳۷/۱۹	رودخانه سفید	c	۰/۱۰	۳/۴۸	۳۴/۴۸	ده نو کنار روستا	۱۸/۷۳	شمال رضا آباد
حسین آباد	a	۰/۳۲	۳/۴۹	۱۰/۷۸	دوراهی خسرو شیرین	a	۰/۶۱	۳/۰۸	۵/۰۲	سده بند بهرام	۹/۱۳	حسین آباد
احمدآباد له داز	b	۰/۲۴	۲/۲۱	۸/۲۹	سهیانو	c	۰/۳۶	۳/۶۵	۱۰/۰۵	راه قدیم سده رودخانه سفید	۱۱/۰۹	دردانه سرهنگ معینی
سیریانو	b	۰/۳۳	۳/۶۱	۰/۴۵	درمانه	d	۰/۳۳	۱/۴۵	۴/۴۳	حاجی آباد کنار رودخانه	۲۳/۱۶	شمال شهرک سیریانو
دردانه	b	۰/۴۴	۲/۹۴	۴/۸۴	رحمت آباد	b	۰/۶۶	۲/۲۱	۳/۳۶	مهگان	۸/۵۵	حسن آباد
کناس	a	۰/۶۴	۵/۴۸	۵/۴۸	شولان	a	۰/۶۲	۵/۳۵	۸/۵۶	دوراهی شولان ده خیر	۱۷/۰۸	کناس
جنوب سیریانو	d	۰/۲۱	۱/۱۹	۵/۶۱	پهلوانی کنار زهکش	b	۰/۶۳	۲/۸۰	۴/۴۱	پهلوانی پهلوان	۴/۰۵	احمدآباد
اصح آباد	b	۰/۱۱	۴/۰۵	۳۷/۹۰	پاسگاه آسپاس	a	۰/۱۳	۳/۰۶	۲۴/۱۷	پاسگاه آسپاس	۵/۹۵	نصرآباد
تخت چمن	b	۰/۲۲	۵/۱۶	۵/۱۶	بابابائی	d	۰/۴۴	۱/۱۳	۲/۵۶	دهنه	۲۳/۲۹	دهنه

۱۳۸۰ و بیشترین نوسان در این دوره

دسته b: بیشترین افت سطح آب زیرزمینی در دوره آماری ۹۶-

۱۳۸۰ و کمترین نوسان در این دوره

دسته c: کمترین افت سطح آب زیرزمینی در دوره آماری ۹۶-

۱۳۸۰ و بیشترین نوسان در این دوره

دسته d: کمترین افت سطح آب زیرزمینی در دوره آماری ۹۶-

۱۳۸۰ و کمترین نوسان در این دوره

با توجه به متوسط افت سالانه، بیشینه افت سالانه و نوسانات

سالانه آن، پیزومترهای مورد مطالعه به شرح جدول ۱ طبقه‌بندی شد.

در نهایت با توجه به شرایط موجود، ۳۹ چاه مورد بررسی به ۴ گروه

تقسیم گردید. سپس با استفاده از پلیگون‌بندی تیسن، برای هر گروه a

تا d، بر اساس متوسط وزنی، یک سری زمانی معرف گروه تولید شد.

در ادامه به شبیه‌سازی سری زمانی تراز سطح آب زیرزمینی در ۴ گروه

ایجاد شده با استفاده از مدل‌های ANN و K-Star پرداخته می‌شود.

در خصوص استفاده از مدل ANN، مدل با تأخیرهای ۱ تا ۳ برای

داده‌های مورد مطالعه اعمال شد. برای هر تأخیر، لایه‌های پنهان و

## برآورد حدود اطمینان

حدود اطمینان شبیه‌سازی به صورت رابطه ۸ قابل برآورد می‌باشد.

$$CI = \bar{O} \pm z \frac{s}{\sqrt{N}} \quad (8)$$

که  $\bar{O}$  متوسط داده‌های مشاهداتی،  $z$  برابر با مقدار سطح اطمینان،  $N$  برابر با تعداد داده‌ها و  $s$  نیز انحراف میانه‌ها می‌باشد.

## نتایج و بحث

## طبقه‌بندی اطلاعات تراز سطح آب زیرزمینی

در این مطالعه، با توجه به تغییرات افت و نوسانات سطح آب زیرزمینی در منطقه مورد مطالعه، چاه‌های موجود به ۴ دسته a تا d به شرح زیر طبقه‌بندی شد:

دسته a: بیشترین افت سطح آب زیرزمینی در دوره آماری ۹۶-

به الگوهای (4,2) و Test (2,4) با میزان خطای ۱/۸ متر می‌باشد. با توجه به فاز آزمایش، برترین الگوی گروه b با تعداد تأخیر ۱، الگوی (4,2) و Test (2,4) معرفی می‌شود. نتایج شبیه‌سازی مقادیر تراز سطح ایستابی گروه b با تعداد تأخیر ۱ با استفاده از الگوهای (4,2) و Test (2,4) به صورت شکل ۲-۲ نشان دهنده تعداد نورون می‌باشد. واژه Train و Test نیز به ترتیب معرف مجموعه آموزش و آزمایش می‌باشد. به طور مثال، Train (2,3) مجموعه آموزش متاثر از مدل ANN با ۲ لایه پنهان و ۳ نورون را نشان می‌دهد. برای فاز آموزش از ۸۰ درصد داده‌ها و برای فاز آزمایش از ۲۰ درصد داده‌های مورد مطالعه در هر گروه استفاده شد.

کمترین میزان خطا در گروه c با تعداد تأخیر ۱، در فاز آموزش برابر با ۰/۸۱ متر و متعلق به الگوی (4,6) Train، با تعداد ۴ لایه پنهان و تعداد ۶ نورون می‌باشد. در گروه c با تعداد تأخیر ۱، مقادیر Train NSE بین ۰/۸۵ تا ۰/۹۲ متغیر بوده که بیشترین مربوط به (4,6) و کمترین کارایی مربوط به (3,6) Train می‌باشد که در فاز آزمایش نیز این الگو از میزان کارایی کمتر و میزان خطای بیشتری برخوردار می‌باشد. در گروه c با تعداد تأخیر ۱، در فاز آزمایش میزان خطای شبیه‌سازی تراز سطح ایستابی با توجه به آماره RMSE بین ۰/۸۲ تا ۰/۸۵ متر متغیر بوده که بیشترین میزان خطا مربوط به Test (3,6) و کمترین آن مربوط به الگوی (2,6) می‌باشد. با توجه به فاز آزمایش، برترین الگوی گروه c با تعداد تأخیر ۱، الگوی (2,6) معرفی می‌شود که در شکل ۲-۲ نشان داده شده است. با توجه به حدود اطمینان شبیه‌سازی شده در سطح ۹۵ درصد، می‌توان مشاهده کرد که تمامی مقادیر شبیه‌سازی شده به غیر از ۱ نمونه، در محدوده اطمینان واقع شده‌اند که این موضوع بیانگر عملکرد خوب الگوی Test (2,6) در شبیه‌سازی تراز سطح ایستابی در منطقه c در تأخیر ۱ در فاز آزمایش می‌باشد.

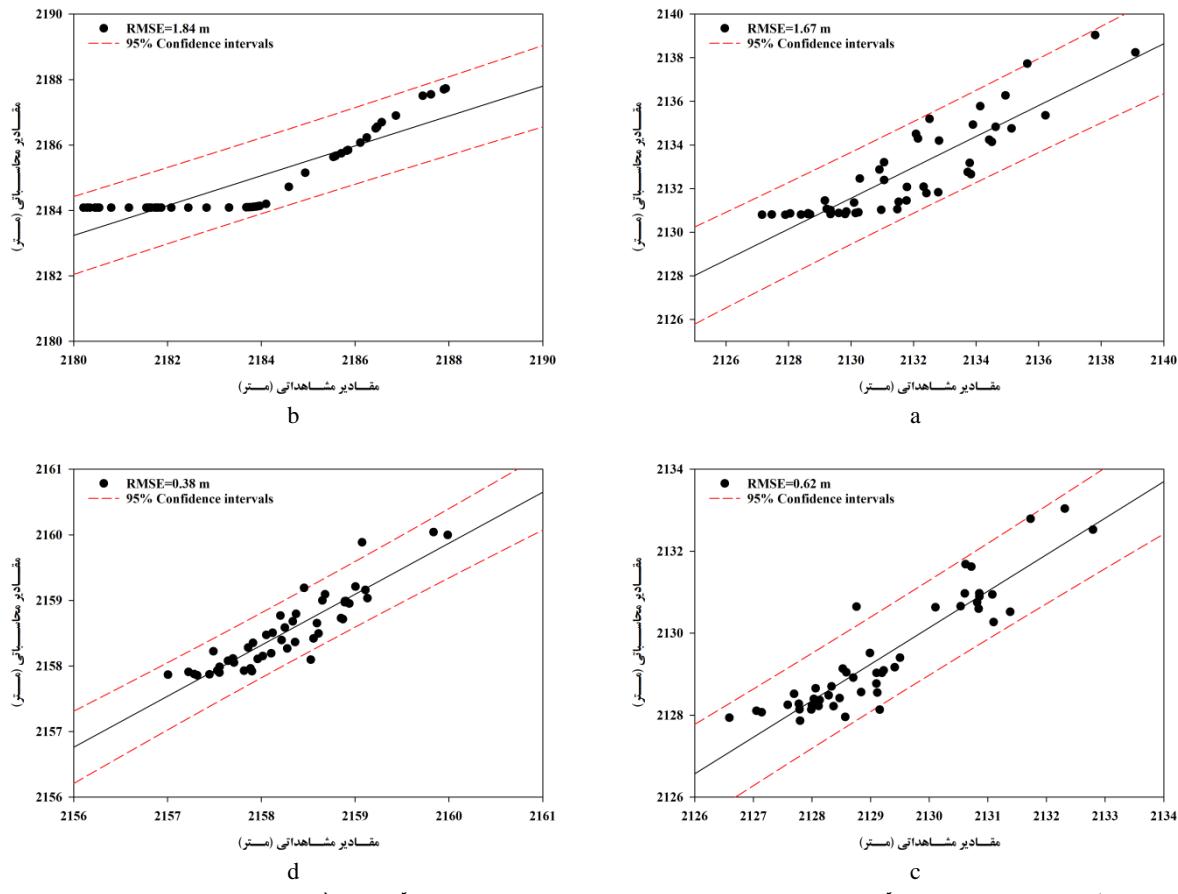
در گروه d با تعداد تأخیر ۱، در فاز آموزش کمترین میزان خطای متعلق به الگوی (3,5) Train و با توجه به معیار RMSE برابر با ۰/۳۸ متر با تعداد ۳ لایه پنهان و تعداد ۵ نورون می‌باشد. البته میزان خطای با توجه به آماره RMSE بین ۰/۳۸ تا ۰/۵۵ متر متغیر بوده که این میزان خطای با توجه به دامنه تغییرات مقادیر مشاهداتی برای همه الگوهای ورودی رضایت‌بخش می‌باشد. در فاز آزمایش نیز میزان خطای شبیه‌سازی تراز سطح ایستابی با توجه به آماره RMSE بین ۰/۲۸ تا ۰/۲۷۵ متر متغیر بوده که بیشترین میزان خطا مربوط به الگوی (2,6) و کمترین آن مربوط به الگوی (4,5) Test می‌باشد. آنچه بهوضوح مشاهده می‌شود، برتری تعداد نورون ۵ نسبت به سایر تعداد نورون‌ها در گروه d با تعداد تأخیر ۱ می‌باشد. نتایج شبیه‌سازی مقادیر تراز سطح ایستابی گروه d با تعداد تأخیر ۱ با استفاده از الگوی (4,5) Test به صورت شکل ۲-۲ ارائه شد. با توجه به شکل ۲ می‌توان به صورت خلاصه الگوهای (4,2)، Train، (2,6) و Train (2,4) را به عنوان مناسب‌ترین الگوهای ورودی به ترتیب برای مناطق a، b، c و d با تأخیر ۱ در نظر گرفت.

تعداد نورون‌های مختلف نیز بررسی شده است. ترکیب‌هایی که برای هر تأخیر استفاده شد به صورت (a,b) Train و (a) Test ارائه و معرفی شده است که در این مخفف‌سازی، a بیانگر تعداد لایه پنهان و b نیز نشان دهنده تعداد نورون می‌باشد. واژه Train و Test نیز به ترتیب معرف مجموعه آموزش و آزمایش می‌باشد. به طور مثال، Train (2,3) مجموعه آموزش متاثر از مدل ANN با ۲ لایه پنهان و ۳ نورون را نشان می‌دهد. برای فاز آموزش از ۸۰ درصد داده‌ها و برای فاز آزمایش از ۲۰ درصد داده‌های مورد مطالعه در هر گروه استفاده شد.

### نتایج بررسی دقت مدل ANN در شبیه‌سازی تراز سطح ایستابی با تأخیر ۱

در این بخش نتایج شبیه‌سازی تراز سطح آب زیرزمینی را با یک تأخیر و با استفاده از تعداد ۲، ۳ و ۴ لایه پنهان و تعداد ۲ تا ۶ نورون برای هر لایه پنهان ارائه شده است. نتایج ارزیابی مدل ANN در شبیه‌سازی مقادیر تراز سطح ایستابی با استفاده از آماره‌های جذر میانگین مربعات خطأ (RMSE) و آماره نش-ساتکلیف (NSE) بررسی شد. با توجه به آماره RMSE، کمترین میزان خطا در گروه a با تعداد تأخیر ۱، در فاز آموزش برابر با ۰/۹۹ متر و متعلق به الگوی (4,5) Train، با تعداد ۴ لایه پنهان و تعداد ۵ نورون می‌باشد. در گروه a با تعداد تأخیر ۱، مقادیر NSE بین ۰/۸۹ تا ۰/۹۲ متغیر بوده که بیشترین مربوط به (4,5) Train و کمترین کارایی مربوط به (4,6) Train می‌باشد. در گروه a با تعداد تأخیر ۱ در فاز آزمایش RMSE میزان خطای شبیه‌سازی تراز سطح ایستابی با توجه به آماره NRMSE و NRMSE بین ۰/۱۵ تا ۰/۱۶۷ متر متغیر بوده که بیشترین میزان خطای مربوط به الگوی (3,4) Train و کمترین آن مربوط به الگوی (4,2) Test می‌باشد که الگوی برتر در این فاز به صورت شکل a-۲ می‌باشد. با توجه به فاز آزمایش، بهترین الگوی گروه a با تعداد تأخیر ۱، الگوی (4,2) معرفی می‌شود. با توجه به شکل ۲ می‌توان همیستگی قابل قبولی بین مقادیر مشاهداتی و شبیه‌سازی شده مشاهده کرد. با توجه به حدود اطمینان شبیه‌سازی شده در سطح ۹۵ درصد، می‌توان مشاهده کرد که تمامی مقادیر شبیه‌سازی شده در محدوده اطمینان واقع شده‌اند که این موضوع بیانگر عملکرد خوب الگوی (4,2) در شبیه‌سازی تراز سطح ایستابی در منطقه a تأخیر ۱ در فاز آزمایش می‌باشد.

کمترین میزان خطا در گروه b با تعداد تأخیر ۲، در فاز آموزش برابر با ۰/۳۳ متر و متعلق به الگوی (3,5) Train، با تعداد ۳ لایه پنهان و تعداد ۵ نورون می‌باشد. در گروه b با تعداد تأخیر ۱، در فاز آزمایش میزان خطای شبیه‌سازی تراز سطح ایستابی با توجه به آماره RMSE بین ۰/۸ تا ۰/۹/۶ متر متغیر است که بیشترین میزان خطا مربوط به دو الگوی (3,4) و (4,5) Train و کمترین آن مربوط



شکل ۲- نتایج شبیه‌سازی مقادیر سطح آب زیرزمینی با تأخیر ۱ با استفاده از مدل ANN در فاز آزمایش (a: منطقه a، b: منطقه c و d: منطقه d)

به شکل ۳ مشاهده می‌شود. با توجه به شکل ۳، در فاز آزمایش کمترین میزان خطای شبیه‌سازی تراز سطح آب زیرزمینی به الگوی (2,2) Test می‌باشد که می‌توان همبستگی قابل قبولی بین مقادیر مشاهداتی و شبیه‌سازی شده مشاهده کرد و هیچ مورد بیش تخمینی و یا کم تخمینی مشاهده نمی‌شود. در فاز آزمایش کمترین میزان خطای شبیه‌سازی تراز سطح آیستابی گروه c با توجه به آماره RMSE، مربوط به الگوی (3,3) Test می‌باشد. با توجه به شکل ۳-۳ دو مورد شبیه‌سازی خارج از محدوده شبیه‌سازی را می‌توان در فاز آزمایش در این الگو مشاهده می‌شود. با توجه به فاز آزمایش، برترین الگوی گروه d با تعداد تأخیر ۲، الگوی (3,2) Train معرفی می‌شود که نتایج شبیه‌سازی این الگو به صورت شکل ۳-۳ می‌باشد. با توجه به این شکل، می‌توان یک مورد خارج از محدوده اطمینان و دو مورد روی حدود اطمینان شبیه‌سازی را مشاهده کرد. در سایر موارد همبستگی قابل قبولی بین مقادیر مشاهداتی و شبیه‌سازی وجود دارد.

## نتایج بررسی دقیقی مدل ANN در شبیه‌سازی تراز سطح آیستابی با تأخیر ۲

نتایج بررسی همبستگی و میزان خطای شبیه‌سازی تراز سطح آیستابی منطقه مورد مطالعه با مدل ANN و تأخیر ۲ به صورت شکل ۳ ارائه شد.

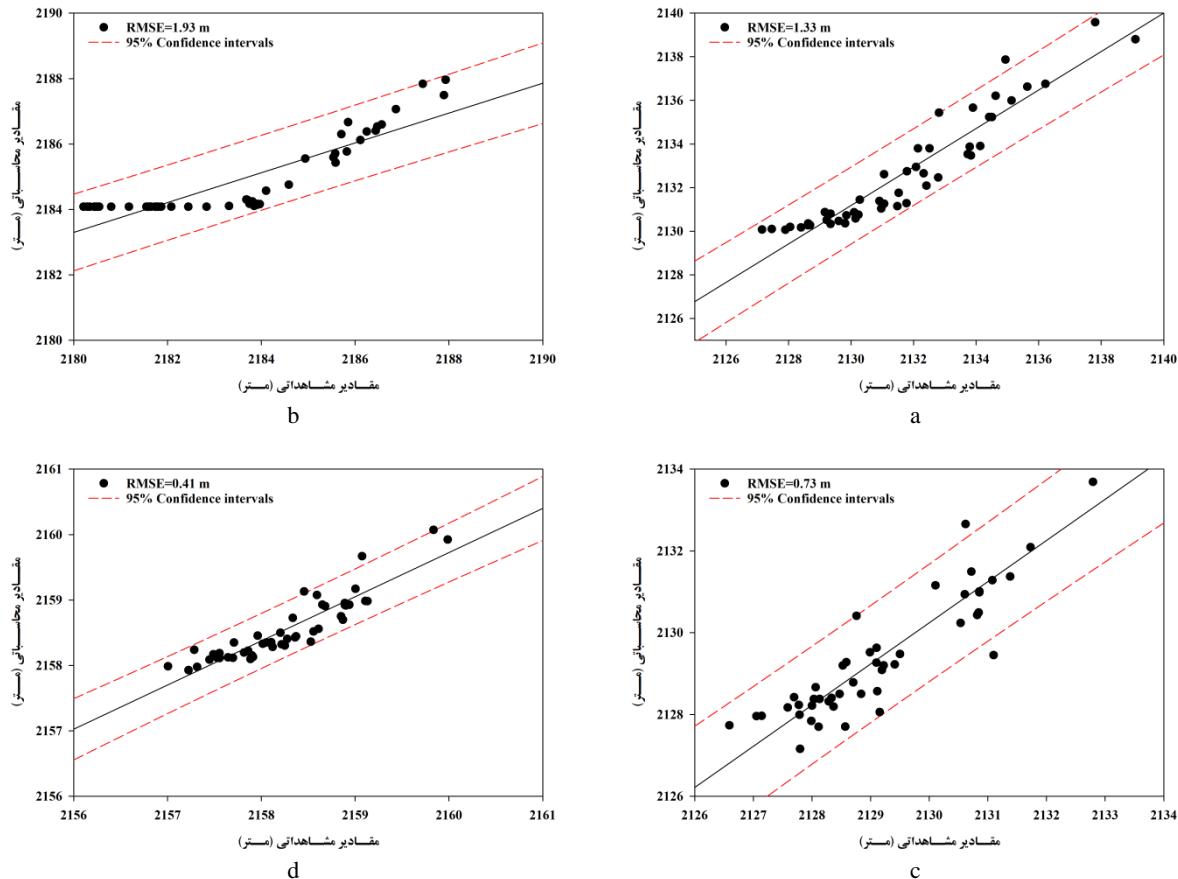
با توجه به آماره RMSE، کمترین میزان خطای تراز سطح آب در گروه a با تعداد Train تأخیر ۱، در فاز آموزش برابر با ۰/۲۶ متر و متعلق به الگوی (4,5)، با تعداد ۴ لایه پنهان و تعداد ۵ نورون می‌باشد که مقادیر Train NSE بین ۰/۹۹ تا ۰/۹۵ متفاوت بوده که بیشترین مربوط به (4,5) و کمترین کارایی مربوط به (3,2) Train می‌باشد. در فاز آزمایش میزان خطای شبیه‌سازی تراز سطح آب زیرزمینی با توجه به آماره RMSE، بین ۱/۳۳ تا ۶/۷۲ متر متغیر بوده که بیشترین میزان خطای مربوط به الگوی (3,4) و کمترین آن مربوط به الگوی Test (2,2) می‌باشد که در شکل ۳-۳ a-۳ شده است. یک مورد خارج از حدود اطمینان ۹۵ درصد و یک مورد روی حدود اطمینان با توجه

ایستابی منطقه مورد مطالعه با مدل ANN و تأخیر ۳ به صورت شکل ۴ ارائه شد.

نتایج بررسی دقت مدل ANN در شبیه‌سازی تراز سطح

ایستابی با تأخیر ۳

نتایج بررسی همیستگی و میزان خطای شبیه‌سازی تراز سطح



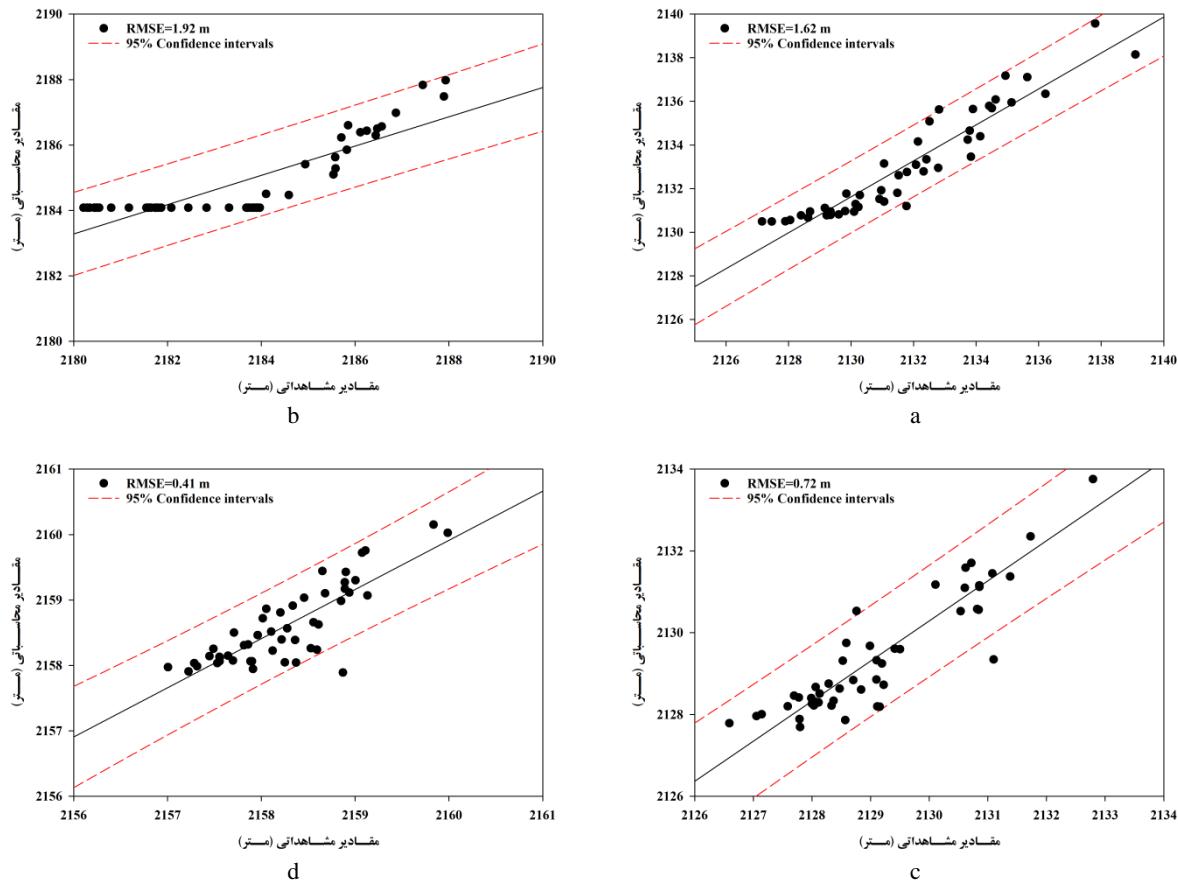
شکل ۳- نتایج شبیه‌سازی مقادیر سطح آب زیرزمینی با تأخیر ۲ با استفاده از مدل ANN در فاز آزمایش (a: منطقه a, b: منطقه b, c: منطقه c و d: منطقه d)

تعداد تأخیر ۳، در فاز آزمایش، الگوی (4,4) به عنوان الگوی Test برتر شناسایی شده و نتایج شبیه‌سازی تراز سطح ایستابی در این گروه به صورت شکل b-۴ می‌باشد که نشان‌دهنده عملکرد خوب الگوی (4,4) Test در شبیه‌سازی تراز سطح ایستابی در منطقه b در تأخیر ۳ در فاز آزمایش می‌باشد. با توجه به شکل ۴-۳، در گروه c، در فاز آزمایش میزان خطای شبیه‌سازی تراز سطح ایستابی با توجه به آماره RMSE بین ۰/۵۷ تا ۰/۷۲ متر متغیر بوده که بیشترین میزان خطای مربوط به الگوی (4,2) Test و کمترین آن مربوط به الگوی (2,2) Test می‌باشد. با توجه به فاز آزمایش، برترین الگوی گروه c با تعداد تأخیر ۳، الگوی (2,3) Test معرفی می‌شود که نتایج شبیه‌سازی مقادیر تراز سطح ایستابی گروه a با تعداد تأخیر ۳ با استفاده از الگوی (2,2) Test ایستابی گروه a-۴ ارائه شد. با توجه به حدود اطمینان شبیه‌سازی شده در سطح ۹۵ درصد، می‌توان مشاهده کرد که تمامی مقادیر شبیه‌سازی شده در محدوده اطمینان واقع شده‌اند که این موضوع بیانگر عملکرد خوب الگوی (2,2) Test در شبیه‌سازی تراز سطح ایستابی در منطقه a در تأخیر ۳ در فاز آزمایش می‌باشد. در گروه b با

در فاز آزمایش میزان خطای شبیه‌سازی تراز سطح ایستابی با توجه به آماره RMSE، با تأخیر ۳ مدل ANN در منطقه a بین ۱/۶۲ تا ۶/۶۴ متر متغیر بوده که بیشترین میزان خطای مربوط به الگوی (3,6) و کمترین آن مربوط به الگوی (2,2) Test می‌باشد. با توجه به فاز آزمایش، برترین الگوی گروه a با تعداد تأخیر ۳، الگوی (2,2) Test معرفی می‌شود که نتایج شبیه‌سازی مقادیر تراز سطح ایستابی گروه a با تعداد تأخیر ۳ با استفاده از الگوی (2,2) Test ایستابی گروه a-۴ ارائه شد. با توجه به حدود اطمینان شبیه‌سازی شده در سطح ۹۵ درصد، می‌توان مشاهده کرد که تمامی مقادیر شبیه‌سازی شده در محدوده اطمینان واقع شده‌اند که این موضوع بیانگر عملکرد خوب الگوی (2,2) Test در شبیه‌سازی تراز سطح ایستابی در منطقه a در تأخیر ۳ در فاز آزمایش می‌باشد. در گروه b با

مشاهده کرد.

با تعداد تأخیر ۳، الگوی Test (3,5) معرفی می‌شود که می‌توان همبستگی قابل قبولی بین مقادیر مشاهداتی و شبیه‌سازی شده



شکل ۴- نتایج شبیه‌سازی مقادیر سطح آب زیرزمینی با تأخیر ۳ با استفاده از بهترین مدل ANN در فاز آزمایش a: منطقه a؛ b: منطقه b؛ c: منطقه c و d: منطقه d

با توجه به نتایج مقادیر RMSE و NSE ارائه شده در جدول ۲ می‌توان مشاهده کرد که در فاز آموزش از بین تأخیرهای مختلف، تأخیر ۳ (الگوی Train(a3)) بهترین تأخیر با کمترین میزان خطأ و بیشترین کارایی می‌باشد. میزان خطای ۰/۵۴ متر و کارایی ۹۴ درصد در فاز آموزش برای منطقه a با توجه به الگوریتم K-Star حاصل شد. در فاز آزمایش، الگوی Test(a2) بهترین عملکرد و کمترین میزان خطأ در شبیه‌سازی مقادیر تراز سطح آب زیرزمینی را برای منطقه a برآورد کرد. میزان خطای ۰/۵۰ متر و کارایی ۹۶ درصد در شبیه‌سازی مقادیر تراز سطح آب زیرزمینی در منطقه a در فاز آموزش توسط مدل K-Star حاصل شد. نتایج شبیه‌سازی تراز سطح ایستابی منطقه a در فاز آموزش با استفاده از الگوی برتر (تعداد تأخیر ۲) به صورت شکل a-۵ ارائه شد. با توجه به این شکل می‌توان تطبیق خوبی بین مقادیر مشاهداتی و شبیه‌سازی شده مشاهده کرد. مقادیر شبیه‌سازی شده

نتایج شبیه‌سازی مقادیر تراز سطح ایستابی مناطق مورد بررسی (a تا d) با استفاده از الگوریتم K-Star

در این قسمت نیز همانند سایر الگوهای ANN، شبیه‌سازی مقادیر تراز سطح ایستابی مناطق مورد بررسی در دو فاز آموزش و آزمایش بررسی شد. ۲۰ درصد داده‌ها برای فاز آموزش و ۸۰ درصد نیز برای فاز آزمایش در نظر گرفته شد. در مدل K-Star، الگوهای ورودی با ۱، ۲ و ۳ تأخیر مورد بررسی قرار گرفته‌اند. در ادامه نتایج به صورت Train(a1) و Test(a1) به ترتیب برای تأخیر اول بخش آموزش و تأخیر اول فاز آزمایش معرفی شدند. برای سایر نواحی مورد بررسی نیز به همین صورت کدگذاری شد. شبیه‌سازی مقادیر تراز سطح ایستابی در منطقه a با سه تأخیر (۱، ۲ و ۳) در دو فاز آموزش و آزمایش بررسی و نتایج با استفاده از دو آماره RMSE و NSE بررسی و نتایج به صورت جدول ۲ ارائه شد.

فاز آموزش نتایج مطلوبی ارائه کند، اما در فاز آزمایش عملکرد مناسبی در منطقه b نداشت. با توجه به شکل b-۵ می‌توان مشاهده کرد که مدل K-Star در برخی نقاط نتایج مشابهی ارائه کرده است که بیانگر عدم قطعیت مدل در شبیه‌سازی تراز سطح ایستاتیک در منطقه b می‌باشد.

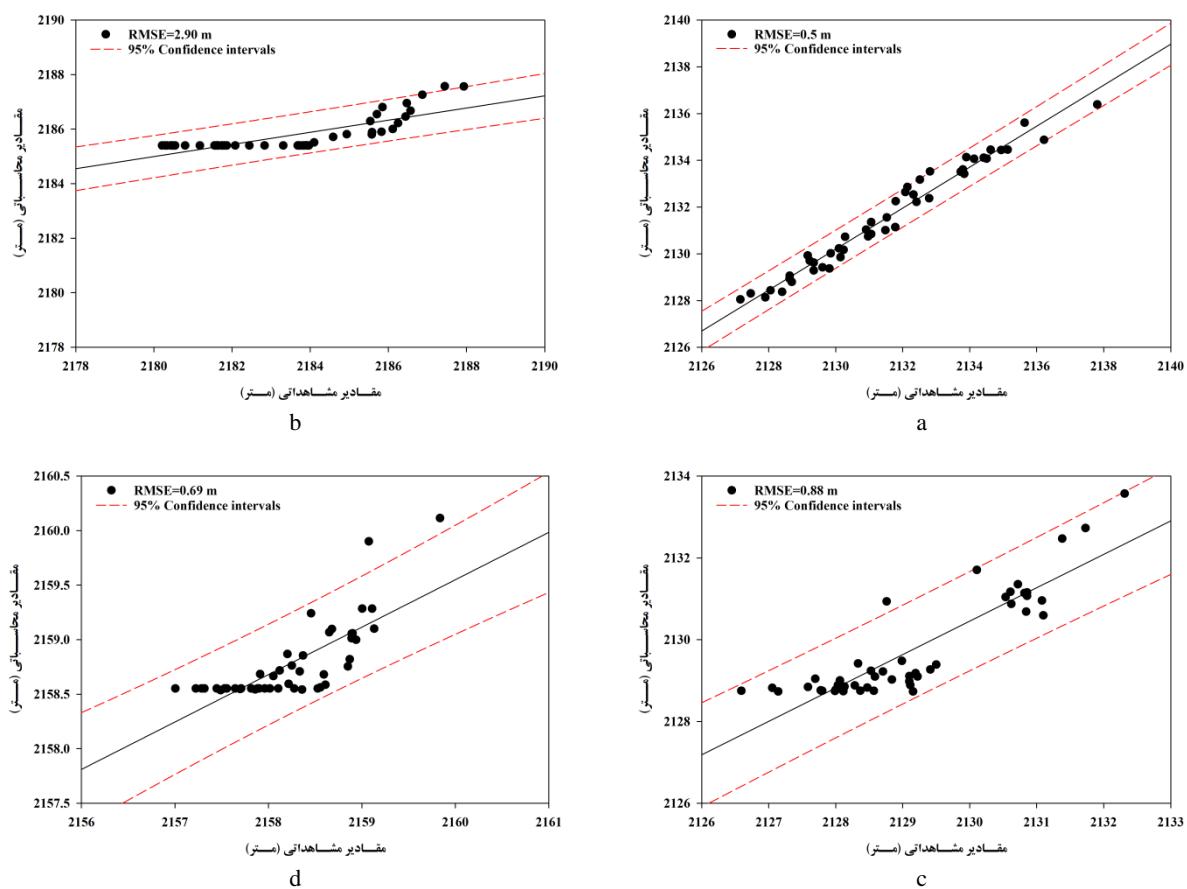
در فاز آموزش، توانایی مدل K-Star با توجه به نتایج مقادیر NSE ارائه شده در جدول ۲ بین ۸۶/۰ تا ۹۷/۰ به ترتیب برای تأخیر ۱ و تأخیر ۳ به دست آمد. در فاز آموزش از بین تأخیرهای مختلف، تأخیر ۳ (الگوی Train(a3)) بهترین تأخیر با کمترین میزان خطأ و بیشترین کارایی می‌باشد. میزان خطای ۴۵/۰ متر و کارایی ۹۷ درصد در فاز آموزش برای منطقه b با تأخیر ۳ به دست آمد. در فاز آزمایش، الگوی Train(a2) بهترین عملکرد و حاصل شد. اما در فاز آزمایش، الگوی Test(a2) بهترین عملکرد و کمترین میزان خطأ در شبیه‌سازی مقادیر تراز سطح آب زیرزمینی را برای منطقه c به همراه داشت که میزان خطای ۸۸/۰ متر و کارایی ۵۸ درصد نتیجه شبیه‌سازی مقادیر تراز سطح آب زیرزمینی در منطقه c توسط مدل K-Star بود.

همگی در محدوده اطمینان ۹۵ درصد قرار گرفته است. الگوی Test(a2) به خوبی توانسته است تراز سطح ایستاتیک منطقه a را شبیه‌سازی کند.

نتایج ارائه شده در جدول ۲ بیانگر برتری الگوی (Train(a3)) بر اساس معیارهای RMSE و NSE در فاز آموزش می‌باشد. از بین تأخیرهای مختلف، تأخیر ۳ (الگوی Train(a1)) همانند منطقه a، بهترین تأخیر با کمترین میزان خطأ و بیشترین کارایی می‌باشد. میزان خطای ۲۹/۰ متر و کارایی ۹۹ درصد در فاز آموزش برای منطقه b با توجه به الگوریتم K-Star حاصل شد که دقت و کارایی قابل قبولی می‌باشد. اما در فاز آزمایش نتایج رضایت‌بخشی در شبیه‌سازی تراز سطح ایستاتیک منطقه b به دست نیامد. کارایی مدل K-Star در شبیه‌سازی مقادیر تراز سطح ایستاتیک در منطقه b منفی برآورد شد که نشان‌دهنده عملکرد ضعیف مدل K-Star می‌باشد. کمترین میزان خطأ در شبیه‌سازی مقادیر تراز سطح آب زیرزمینی در منطقه b در فاز آزمایش ۲۹/۰ متر به دست آمد که نشان‌دهنده عملکرد ضعیف مدل K-Star در فاز آزمایش می‌باشد. با این که مدل K-Star توانست در

جدول ۲- نتایج ارزیابی دقت و کارایی مدل K-Star با تأخیرهای مختلف در تخمین تراز آب زیرزمینی

منطقه مورد بررسی	مرحله بررسی	الگو	NSE	RMSE (m)
آموزش	Train (a1)		.۸۸	۱/۲۳
	Train (a2)		.۹۴	.۹۲
	Train (a3)		.۹۸	.۵۴
آزمایش	Test (a1)		-۰/۸۶	۳/۴۴
	Test (a2)		.۹۶	.۵۰
	Test (a3)		-۰/۱۰	۲/۷۶
آموزش	Train (a1)		.۹۸	.۴۵
	Train (a2)		.۹۸	.۳۹
	Train (a3)		.۹۹	.۲۹
آزمایش	Test (a1)		-۱/۴۲	۳/۴۷
	Test (a2)		-۰/۸۱	۳/۰۱
	Test (a3)		-۰/۶۹	۲/۹۰
آموزش	Train (a1)		.۸۶	۱/۰۶
	Train (a2)		.۹۳	.۷۷
	Train (a3)		.۹۷	.۴۵
آزمایش	Test (a1)		.۴۱	۱/۰۵
	Test (a2)		.۵۸	.۸۸
	Test (a3)		.۵۳	.۹۳
آموزش	Train (a1)		.۸۲	.۴۴
	Train (a2)		.۹۰	.۳۳
	Train (a3)		.۹۷	.۱۸
آزمایش	Test (a1)		-۰/۹۶	.۸۶
	Test (a2)		-۰/۲۷	.۶۹
	Test (a3)		-۰/۳۳	.۷۰



شکل ۴- نتایج شبیه‌سازی مقادیر سطح آب زیرزمینی با تأخیر ۱ با استفاده از بهترین مدل K-Star در فاز آزمایش (a: منطقه a؛ b: منطقه b؛ c: منطقه c و d: منطقه d)

توجه به شکل ۲-۴ می‌توان مشاهده کرد که همانند منطقه b، در منطقه d نیز نتایج شبیه‌سازی تراز سطح ایستابی رضایت‌بخش نبوده و مدل K-Star نتوانسته دامنه تغییرات داده‌ها را به خوبی شبیه‌سازی کند. مقادیر شبیه‌سازی شده یکسان را نیز می‌توان در این نمودار مشاهده کرد. در مورد شکل ۴-۴ نتایج نشان داد که مدل به ازای مقادیر مختلف مشاهداتی، یک عدد ثابت شبیه‌سازی کرده است که این مورد می‌تواند نقطه ضعف مدل بیان شود.

#### نتایج مقایسه الگوهای مدل بررسی در مناطق مورد بررسی

برترین الگوهای مدل ANN و K-Star در شبیه‌سازی مقادیر تراز سطح ایستابی در مناطق مورد مطالعه به صورت جدول ۳ ارائه شد. با توجه به جدول ۳ و آماره‌های RMSE و NSE می‌توان مشاهده کرد که مدل K-Star کمترین میزان خطا در شبیه‌سازی تراز سطح ایستابی در منطقه a را داشته که با ۲ تأخیر مورد استفاده قرار گرفته است. ضریب کارایی مدل K-Star با دو تأخیر در منطقه a حدود ۹۶

با توجه به شکل ۵-۵ تطابق خوبی بین مقادیر مشاهداتی و شبیه‌سازی شده مشاهده نمی‌شود. مقادیر شبیه‌سازی شده همگی به غیر از یک مورد در محدوده اطمینان ۹۵ درصد قرار گرفته است. الگوی Test(a2) به خوبی توانسته است تراز سطح ایستابی منطقه c شبیه‌سازی کند.

در فاز آموزش با توجه به نتایج مقادیر RMSE و NSE ارائه شده در جدول ۲ می‌توان مشاهده کرد که از بین تأخیرهای مختلف، همانند مناطق a، b و c تأخیر ۳ (الگوی Train(a3)) بهترین تأخیر با کمترین میزان خطأ و بیشترین کارایی در منطقه d می‌باشد. میزان خطای ۰/۱۸ متر و کارایی ۹۷ درصد در فاز آموزش در منطقه b به ترتیب با توجه به آماره‌های RMSE و NSE به دست آمد. در فاز آزمایش، الگوی Test(a2) مدل K-Star به عنوان بهترین الگو شناسایی شد اما میزان عملکرد و میزان خطای آن در شبیه‌سازی مقادیر تراز سطح آب زیرزمینی در منطقه d رضایت‌بخش نیست. میزان خطای ۰/۷۰ متر و کارایی ۳۲/۰ در شبیه‌سازی مقادیر تراز سطح آب زیرزمینی در منطقه d در قابل قبول نمی‌باشد. با

در منطقه d نیز برترین الگوهای مدل ANN و K-Star در شبیه‌سازی مقادیر تراز سطح ایستابی به صورت جدول ۳ قابل مشاهده می‌باشد. با توجه به جدول ۳ و آماره‌های RMSE و NSE می‌توان مشاهده کرد همانند مناطق b و c مدل K-Star عملکرد خوبی در شبیه‌سازی مقادیر تراز سطح ایستابی نداشته و بیشترین میزان خطا در شبیه‌سازی تراز سطح ایستابی در منطقه d را دارد. ضریب کارایی مدل K-Star با دو تأخیر در منطقه d حدود ۰/۲۷ است که نسبت به الگوهای مدل ANN کمتر می‌باشد. با توجه به جدول ۳ می‌توان مشاهده کرد که تأخیر ۱ مدل ANN با تعداد ۴ لایه پنهان و ۵ نورون بهترین الگو برای شبیه‌سازی تراز سطح ایستابی در منطقه d می‌باشد.

درصد می‌باشد. با توجه به جدول ۳ و آماره‌های RMSE و NSE در توان مشاهده کرد که مدل ANN با تعداد تأخیر ۳ و تعداد لایه پنهان ۴ و تعداد نورون ۴ کمترین میزان خطا در شبیه‌سازی تراز سطح ایستابی در منطقه b می‌باشد. در این منطقه، مدل K-Star کمترین میزان کارایی و بیشترین میزان خطا را دارد. با توجه به جدول ۳ و K-Star آماره‌های RMSE و NSE می‌توان مشاهده کرد که مدل K-Star در هر سه تأخیر، نتایج بهتری نسبت به مدل K-Star ارائه کرده است. با تعداد تأخیر ۱، الگوی Test(2,6) بهترین الگو برای شبیه‌سازی مقادیر تراز سطح ایستابی در منطقه c می‌باشد که میزان خطای ۰/۶۲ متر و کارایی ۸۲ درصد را برآورد کرده است.

**جدول ۳- خلاصه نتایج بهترین مدل‌های مورد مطالعه در مناطق مختلف در تخمین تراز آب زیرزمینی**

NSE	RMSE (m)	الگو	تأخیر	مدل
.۰/۶۳	۱/۶۷	Test(4,2)	۱	a
.۰/۷۶	۱/۳۳	Test(2,2)	۲	
.۰/۶۵	۱/۶۲	Test(2,2)	۳	
.۰/۹۶	۰/۵۰	Test(a2)	۲	
.۰/۳۷	۱/۸۴	Test(2,4)	۱	b
.۰/۳۰	۱/۹۳	Test(2,2)	۲	
.۰/۳۰	۱/۹۲	Test(4,4)	۳	
-۰/۶۹	۲/۹۰	Test(a3)	۳	
.۰/۸۲	.۰/۶۲	Test(2,6)	۱	c
.۰/۷۴	.۰/۷۳	Test(3,3)	۲	
.۰/۷۵	.۰/۷۲	Test(2,3)	۳	
.۰/۵۸	.۰/۸۸	Test(a2)	۲	
.۰/۶۷	.۰/۳۸	Test(4,5)	۱	d
.۰/۶۰	.۰/۴۱	Test(3,2)	۲	
.۰/۴۰	.۰/۵۱	Test(3,5)	۳	
-۰/۲۷	.۰/۶۹	Test(a2)	۲	

منطقه b شامل پیزومترهای الله آباد، شهر آشوب، شهر بالا، شمال رضا آباد، احمدآباد له دراز، سیربانو، شمال شهرک سیربانو، دردانه، احمدآباد، نصرآباد، تخت چمن، دوراهی شولان ده خیر، مهگان و رحمت آباد

در این منطقه با توجه به تغییرات آماره‌های ارزیابی، مدل ANN با تأخیر ۱ و با تعداد لایه پنهان ۲ و تعداد نورون ۴ به عنوان مدل و الگوی برتر شناخته و معرفی می‌شود. منطقه c شامل پیزومترهای رودخانه سفید، کنار جاده رودخانه سفید، دوراهی خسرو شیرین، سده بند بهرام و نزدیک سده در منطقه c نیز با توجه به آماره‌های ارزیابی فاز آزمایش، مدل ANN با تعداد تأخیر ۱، با تعداد لایه پنهان ۲ و تعداد نورون ۶

#### جمع‌بندی و خلاصه نتایج

نتایج بررسی میزان خطا و کارایی مدل‌های ANN و K-Star با الگوها و تأخیرهای مختلف در شبیه‌سازی تراز سطح ایستابی منطقه مورد مطالعه نشان داد که در مناطق مورد بررسی، بهترین نتایج به شرح زیر می‌باشد:

منطقه a شامل پیزومترهای ده خیر، کناس، دوراهی بابائی، شهرک اردلی، حسین آباد، ده نو کنار روستا، حسن آباد، دوراهی پهلوانی و شولان:

در این منطقه با توجه به فاز آزمایش، مدل K-Star نتایج بهتری نسبت به مدل ANN داشته و با تأخیر ۲ به عنوان الگوی برتر معرفی می‌شود.

شد. این الگو در مقایسه با بهترین الگوی تأخیر ۲، بهترین الگوی تأخیر ۳ و بهترین مدل K-Star به ترتیب میزان خطای شبیه‌سازی را حدود  $4/3$  و  $57/6$  درصد بهبود بخشیده است. درصد بهبودی مدل ANN نسبت به مدل K-Star چشمگیر می‌باشد.

در منطقه c الگوی برتر مدل ANN (الگوی Test(2,6)) در تأخیر ۱ نسبت به تأخیر ۲ و ۳ مدل ANN به ترتیب درصد بهبودی ۱۸ و ۱۶ درصدی را به همراه داشته که همانند منطقه b و d از نوع تأخیر اول می‌باشد. الگوی برتر منطقه c نسبت به مدل K-Star حدود ۴۲ درصد توانسته است میزان خطای را کاهش دهد. میزان خطای  $4/2$  متر و کارایی  $82$  درصد نتیجه شبیه‌سازی تراز سطح ایستابی در منطقه c با استفاده از مدل ANN با تأخیر ۱ و ۲ لایه پنهان و  $6$  نورون می‌باشد.

در منطقه d همانند منطقه b، مدل K-Star نتایج رضایت‌بخشی در شبیه‌سازی تراز سطح آب ارائه نکرده است. تأخیر اول مدل ANN با الگوی Test(4,5) در منطقه d به عنوان مدل برتر با میزان خطای  $0/38$  متر و کارایی  $67$  درصد انتخاب شده است که نسبت به تأخیر دوم و سوم مدل ANN به ترتیب میزان خطای را حدود  $8$  و  $34$  درصد بهبود بخشیده است. این بهبودی در میزان خطای نسبت به مدل K-Star حدود  $81$  درصد می‌باشد. مدل K-Star در منطقه b و d ضریب کارایی نش-ساتکلیف منفی ارائه کرده است که نسبت به سایر مدل‌های مورد بررسی قابل قبول نمی‌باشد. بهطور کلی با توجه به اینکه مدل ANN هم در تعداد مختلف نرون‌ها و هم در تعداد مختلف تاخیرها، بررسی شده است، کارایی برتری ارائه کرده و توانسته است بهینه‌ترین مدل را در خصوص شبیه‌سازی‌ها ارائه کند. این مدل نسبت به مدل K-Star، یک مولفه اضافی (تعداد نرون) را نیز بررسی کرده است که سبب برتری آن شده است.

### منابع مورد استفاده

Afkhamifar, S. and Sarraf, A. 2020. Prediction of groundwater level in Urmia Plain aquifer using hybrid model of wavelet Transform-Extreme Learning Machine based on quantum particle swarm optimization. *Watershed Engineering and Management*. 12(2): 351-364. doi: 10.22092/ijwmse.2019.126515.1669

Banadkooki, F. B., Ehteram, M., Ahmed, A. N., Teo, F. Y., Fai, C. M., Afan, H. A., ... and El-Shafie, A. 2020. Enhancement of groundwater-level prediction using an integrated machine learning model optimized by whale algorithm. *Natural Resources Research*. 29(5): 3233-3252.

Bustami, R., Bessaïh, N., Bong, C. and Suhaili, S. 2007. Artificial Neural Network for Precipitation and Water Level Predictions of Bedup River. *IAENG International Journal of Computer Science*. 34(2).

به عنوان مدل برتر معرفی شد.

منطقه d شامل پیزومترهای بابائی، حاجی آباد، کنار جاده سده، دوراهی آسپاس سده، شرکت خوشایند، راه قدیم سده روختانه سفید، حاجی آباد کنار روختانه، دردانه سرهنگ معینی، پهلوانی کنار زهکش، جنوب سیربانو و پاسگاه آسپاس در منطقه d نیز همانند منطقه b، عملکرد مدل K-Star بسیار ضعیف می‌باشد. در این منطقه نیز مدل ANN با تأخیر ۱، تعداد لایه پنهان  $4$  و تعداد نورون  $5$  به عنوان مدل برتر در شبیه‌سازی تراز سطح ایستابی معرفی شد.

### نتیجه‌گیری

در این مطالعه جهت شبیه‌سازی تراز سطح ایستابی در دشت آسپاس از مقادیر تراز سطح ایستابی پیزومترهای موجود در منطقه مورد مطالعه استفاده شد. در این خصوص ابتدا بر اساس میزان افت سالانه و تغییرات تراز سطح ایستابی در پیزومترهای مورد مطالعه، ابتدا آبخوان دشت مورد بررسی به  $4$  زیر خواسته تقسیم شده و شبیه‌سازی به صورت متوسط تراز سطح ایستابی  $4$  منطقه a, b, c و d بررسی شد. جهت شبیه‌سازی تراز سطح ایستابی در دشت مورد مطالعه از دو مدل ANN و K-Star بهره گرفته شد. تعداد تاخیرهای  $1$ ،  $2$  و  $3$  برای هر دو مدل در نظر گرفته شد. در خصوص مدل ANN تعداد نورون و لایه پنهان مختلف نیز بررسی شد. در هر دو مدل از  $80$  درصد داده‌ها برای فاز آموزش و  $20$  درصد داده‌ها برای فاز آزمایش استفاده شد. نتایج بررسی مدل ANN در شبیه‌سازی تراز سطح ایستابی در مناطق مورد مطالعه نشان داد که این مدل در فاز آموزش در همه مناطق نتایج مطلوبی ارائه می‌کند. اما با توجه به اهمیت صحتسنجی مدل در فاز آزمایش، نتایج مدل ANN در مناطق b, c و d بهتر از مدل K-Star می‌باشد. در این سه مناطق، تعداد تأخیر ۱ بهترین تأخیر در هر سه منطقه می‌باشد. در دو منطقه b و c تعداد لایه پنهان  $2$  و در منطقه d تعداد لایه پنهان  $4$  به عنوان بهترین تعداد لایه پنهان جهت شبیه‌سازی تراز سطح ایستابی انتخاب شدند. اما در منطقه a نتایج شبیه‌سازی مدل K-Star بهتر از مدل ANN بود که تعداد تأخیر  $2$  در مدل K-Star به عنوان تأخیر برتر انتخاب شد.

نتایج بررسی میزان خطای در شبیه‌سازی تراز سطح ایستابی در منطقه a نشان داد که مدل K-Star نسبت به مدل ANN در تأخیر  $1$ ،  $2$  و  $3$  به ترتیب میزان بهبودی خطای حدود  $234$ ،  $166$  و  $224$  درصد داشته است. بهترین مدل‌ها از نظر مدل ANN در هر تأخیر توانایی رقابت با مدل K-Star را در منطقه a نداشتند. در سه منطقه دیگر این شرایط بر عکس بوده است و مدل K-Star نتوانسته است کارایی خوبی در شبیه‌سازی مقادیر تراز سطح ایستابی ارائه کند.

در منطقه b الگوی Test(2,4) با تأخیر ۱ بهترین الگو معرفی

- intelligence models for reference evaporation simulation: A case study in Iraq. *Computers and Electronics in Agriculture*. 167: 105041.
- Kombo, O. H., Kumaran, S., Sheikh, Y. H., Bovim, A. and Jayavel, K. 2020. Long-term groundwater level prediction model based on hybrid KNN-RF technique. *Hydrology*. 7(3): 59.
- Krause, P., Boyle, D. P. and Bäse, F. 2005. Comparison of different efficiency criteria for hydrological model assessment. *Advances in Geosciences*. 5: 89-97.
- Lallahem, S., Mania, J., Hani, A. and Najjar, Y. 2005. On the use of neural networks to evaluate groundwater levels in fractured media. *Journal of Hydrology*. 307(1-4): 92-111.
- Maroufpoor, S., Bozorg-Haddad, O. and Maroufpoor, E. 2020. Reference evapotranspiration estimating based on optimal input combination and hybrid artificial intelligent model: Hybridization of artificial neural network with grey wolf optimizer algorithm. *Journal of Hydrology*. 588: 125060.
- McCulloch, W. S. and Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of Mathematical Biophysics*. 5(4): 115-133.
- Mirarabi, A., Nassery, H. R., Nakhaei, M., Adamowski, J., Akbarzadeh, A. H. and Aljani, F. 2019. Evaluation of data-driven models (SVR and ANN) for groundwater-level prediction in confined and unconfined systems. *Environmental Earth Sciences*. 78(15): 1-15.
- Nash, J. E. and Sutcliffe, J. V. 1970. River flow forecasting through conceptual models part I—A discussion of principles. *Journal of Hydrology*. 10(3): 282-290.
- Nazeri-Tahroudi, M. and Ramezani, Y. 2020. Estimation of dew point temperature in different climates of Iran using support vector regression. *Quarterly Journal of the Hungarian Meteorological Service*. 124(4): 521-539.
- Nguyen, P. T., Ha, D. H., Avand, M., Jaafari, A., Nguyen, H. D., Al-Ansari, N., ... and Pham, B. T. 2020. Soft computing ensemble models based on logistic regression for groundwater potential mapping. *Applied Sciences*. 10(7): 2469.
- Nhu, V. H., Mohammadi, A., Shahabi, H., Shirzadi, A., Al-Ansari, N., Ahmad, B. B., ... & Nguyen, H. 2020. Monitoring and assessment of water level fluctuations of the Lake Urmia and its environmental consequences using multitemporal Landsat 7 ETM+ images. *International Journal of Environmental Research and Public Health*. 17(12): 4210.
- Pham, B. T., Jaafari, A., Prakash, I., Singh, S. K., Quoc, N. K. and Bui, D. T. 2019. Hybrid computational intelligence models for groundwater potential Charles, J., Vinodhini, G. and Nagarajan, R. 2021. A Machine Learning based Variational Autoencoder Model for Water Quality Prediction. *Journal of Green Engineering*. 1: 2029-2040.
- Cleary, J. G. and Trigg, L. E. 1995. K\*: An instance-based learner using an entropic distance measure. In *Machine Learning Proceedings*. 108-114. Morgan Kaufmann.
- Dawson, C. W. and Wilby, R. L. 2001. Hydrological modelling using artificial neural networks. *Progress in Physical Geography*. 25(1): 80-108.
- Eslami, P., Nasirian, A., Akbarpour, A. and Nazeri Tahroudi, M. 2022. Groundwater estimation of Ghayen plain with regression-based and hybrid time series models. *Paddy and Water Environment*. 1-12.
- Garcia-Bartual, R. 2002. Short term river flood forecasting with neural networks. 1st international congress on environmental modelling and software - lugano, switzerland - june 2002
- Ghourdoyee Milan, S., Aryaazar, N., Javadi, S., Razdar, B. 2020. Simulation of groundwater head using LS-SVM and comparison with ANN & MLR. *Hydrogeology*. 5(1): 118-133. doi: 10.22034/hydro.2020.10455
- Granata, F., Di Nunno, F., Gargano, R. and de Marinis, G. 2019. Equivalent discharge coefficient of side weirs in circular channel—A lazy machine learning approach. *Water*. 11(11): 2406.
- Haykin, S. 1999. *Neural Networks, a comprehensive foundation*, Prentice-Hall Inc. Upper Saddle River, New Jersey. 7458, 161-175.
- Huang, W., Murray, C., Kraus, N. and Rosati, J. 2003. Development of a regional neural network for coastal water level predictions. *Ocean Engineering*. 30(17): 2275-2295.
- Iqbal, M., Naeem, U. A., Ahmad, A., Ghani, U. and Farid, T. 2020. Relating groundwater levels with meteorological parameters using ANN technique. *Measurement*. 166: 108163.
- Jaafari, A., Panahi, M., Pham, B. T., Shahabi, H., Bui, D. T., Rezaie, F. and Lee, S. 2019. Meta optimization of an adaptive neuro-fuzzy inference system with grey wolf optimizer and biogeography-based optimization algorithms for spatial prediction of landslide susceptibility. *Catena*. 175: 430-445.
- Khedri, A., Kalantari, N. and Vadiati, M. 2020. Comparison study of artificial intelligence method for short term groundwater level prediction in the northeast Gachsaran unconfined aquifer. *Water Supply*. 20(3): 909-921.
- Khosravi, K., Daggupati, P., Alami, M. T., Awadh, S. M., Ghareb, M. I., Panahi, M., ... and Yaseen, Z. M. 2019. Meteorological data mining and hybrid data-

- Hydrologic Engineering. 5(2): 180-189.
- Tokar, A. S. and Johnson, P. A. 1999. Rainfall-runoff modeling using artificial neural networks. Journal of Hydrologic Engineering. 4(3): 232-239.
- Wright, N. G. and Dastorani, M. T. 2001. Effects of river basin classification on artificial neural networks based ungauged catchment flood prediction. 3rd International Symposium on Environmental HydraulicsAt: Phoenix, Arizona.
- Wright, N. G., Dastorani, M. T., Goodwin, P. and Slaughter, C. W. 2002. A combination of neural networks and hydrodynamic models for river flow prediction. In Fifth International Conference on Hydroinformatics, Cardiff, UK
- Xu, Z., Huang, X., Lin, L., Wang, Q., Liu, J., Yu, K. and Chen, C. 2020. BP neural networks and random forest models to detect damage by *Dendrolimus punctatus* Walker. Journal of Forestry Research. 31(1): 107-121.
- Yadav, B., Gupta, P. K., Patidar, N. and Himanshu, S. K. 2020. Ensemble modelling framework for groundwater level prediction in urban areas of India. Science of the Total Environment. 712: 135539.
- Zhou, Y. 2009. A critical review of groundwater budget myth, safe yield and sustainability. Journal of Hydrology. 370(1-4): 207-213.
- mapping. Catena. 182: 104101.
- Raji, M., Tahroudi, M. N., Ye, F. and Dutta, J. 2022. Prediction of heterogeneous Fenton process in treatment of melanoidin-containing wastewater using data-based models. Journal of Environmental Management. 307: 114518.
- Salari, S., Moghaddasi, M., Mohammadi Ghalehi, M. and Akbari, M. 2021. Groundwater Level Prediction in Golpayegan Aquifer Using ANFIS and PSO Combination. *Iranian Journal of Soil and Water Research.* 52(3): 721-732. doi: 10.22059/ijswr.2021.314323.668814.
- Sharafati, A., Asadollah, S. and Neshat, A. 2020. A new artificial intelligence strategy for predicting the groundwater level over the Rafsanan aquifer in Iran. Journal of Hydrology. 591: 125468.
- Tabatabaei, S. M., Nazeri Tahroudi, M. and Hamraz, B. S. 2021. Comparison of the performances of GEP, ANFIS, and SVM artificial intelligence models in rainfall simulation. Quarterly Journal of the Hungarian Meteorological Service. 125(2): 195-209.
- Taormina, R., Chau, K. W. and Sethi, R. 2012. Artificial neural network simulation of hourly groundwater levels in a coastal aquifer system of the Venice lagoon. Engineering Applications of Artificial Intelligence. 25(8): 1670-1676.
- Thirumalaiah, K. and Deo, M. C. 2000. Hydrological forecasting using neural networks. Journal of

## Application of K-star Algorithm for Groundwater Level Forecasting (Case study: Aspas plain)

N. Rahnama Gahfarokhi<sup>1</sup>, H. Zarei<sup>2</sup>, F. Ahmadi<sup>3\*</sup>  
Received: Sep.20, 2022      Accepted: Feb.02, 2023

### Abstract

In this study, the groundwater level of Aspas Plain, located in the northwest of the catchment area of Tashk and Bakhtegan Lakes in Fars province, was simulated using the data of 39 piezometers in the aquifer plain in the period of 2001-2017. In this regard, K-Star and ANN models with 1, 2 and 3 lags were used in two phases of training and testing. ANN model in this study was also investigated with the number of hidden layers and different neurons in addition to the mentioned lags. According to the drop and fluctuations of the groundwater level in the mentioned statistical period, the studied aquifer was divided into 4 regions a, b, c and d. The results of the simulation of the groundwater level in area "a" showed that the K-Star model with 2 lags performed better than the ANN model in different lags. But in the other three regions, the ANN model with a lag-1 has provided the best performance. ANN model with 2 hidden layers and 4 neurons in region b, with 2 hidden layers and 6 neurons in region c, and with 4 hidden layers and 5 neurons in region d were introduced as the best model for simulating groundwater level values. On average, the best models introduced in regions b, c and d were able to improve the error rate by 57, 42 and 81%, respectively, compared to the K-Star model. The poor performance of the K-Star model in two regions b and d is also clearly visible. In general, the results showed that lag-1 of the ANN model had the best performance in simulating the values of the groundwater level in the three regions b, c and d with the number of hidden layers and different neurons.

**Keywords:** Annual Decline, Artificial Neural Network, Fluctuation of Groundwater, K-Star Model, Piezometer.

1 - Ms.C Student, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

2 - Associate Professor, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

3 - Assistant Professor, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

Corresponding Author E-mail: f.ahmadi@scu.ac.ir