

## تخمین تغییرات سطح آب زیرزمینی با استفاده از چهار تکنیک متفاوت شبکه عصبی تکاملی، مطالعه موردی: دشت عباس استان ایلام

محمدجواد رضایی<sup>۱</sup>، محمدرضا رضایی<sup>۲</sup> و جعفر رضایی<sup>۳\*</sup>

<sup>۱</sup> کارشناسی ارشد کامپیوتر، گروه کامپیوتر، دانشگاه آزاد اسلامی کرمانشاه، کرمانشاه، ایران، <sup>۲</sup> کارشناس ارشد مهندسی آبیاری و زهکشی، گروه آبیاری و زهکشی، دانشگاه اراک، ایران و <sup>۳</sup> مربی پژوهشی، بخش تحقیقات اقتصادی اجتماعی و ترویج کشاورزی، مرکز تحقیقات کشاورزی و منابع طبیعی ایلام، سازمان تحقیقات، آموزش و ترویج، ایلام، ایران

تاریخ پذیرش: ۱۳۹۸/۰۴/۰۵

تاریخ دریافت: ۱۳۹۷/۱۲/۲۶

### چکیده

در نواحی خشک و نیمه‌خشک، آب عمده‌ترین عامل محدودیت کشاورزی است. در این مناطق، به دلیل کمبود جریان‌های سطحی، فشار عمده بر آب‌های زیرزمینی وارد می‌شود. منابع آب زیرزمینی محدوده مورد مطالعه (دشت عباس) نیز به دلیل استفاده بی‌رویه دچار افت شدید سطح آب شده است. در این پژوهش، از چهار مدل متفاوت شبکه عصبی تکاملی شامل، شبکه عصبی پرسپترون چندلایه با الگوریتم ژنتیک (ANN-GA)، شبکه عصبی پرسپترون چندلایه با بهینه‌سازی ازدحام ذرات (ANN-PSO)، شبکه عصبی پرسپترون چندلایه با الگوریتم رقابت استعماری (ANN-ICA) و شبکه عصبی پرسپترون چندلایه با بهینه‌سازی کلونی مورچگان (ANN-ACOR) برای تخمین سطح آب زیرزمینی بر طبق جریان ورودی زیرزمینی، نفوذ موثر از بارندگی، نفوذ موثر از جریان سطحی و سیلاب، نفوذ موثر از آب برگشتی کشاورزی، جریان خروجی زیرزمینی، برداشت از آبخوان برای کشاورزی، تبخیر از سطح آب زیرزمینی و داده‌های گذشته سطح آب زیرزمینی استفاده شد. ترکیب ورودی‌ها با استفاده از تجزیه و تحلیل خودهمبستگی، خودهمبستگی جزئی و همبستگی متقابل برای هر مدل آماده شده است. مدل‌های بهینه با تغییر پارامترهای کنترلی به دست آمده‌اند. بهترین دقت از بین مدل‌های ارائه شده برای ورودی  $(Q_{i-1}, Q_{r-1}, Q_{p-1}, Q_{in_t}, GWL_{t-2}, GWL_{t-1})$  و  $(Q_{e-1}, Q_{w-1}, Q_{out-1})$  به دست آمده است. دقت میانگین مربعات خطا در فاز آزمایش برای مدل‌های ANN-PSO، ANN-ICA، ANN-ACOR به ترتیب برابر ۱/۲۲۰۸، ۰/۹۴۵۶ و ۱/۷۷۲۰ و برای مدل ANN-GA برابر ۰/۸۷۳۹ به دست آمده است. میانگین خطای نسبی مدل ANN-GA برابر ۳/۶ درصد و ضریب تعیین آن ۰/۹۳۸۸ است. با توجه به نتایج به دست آمده مدل ANN-GA عملکرد بهتری نسبت به سه مدل دیگر برای تخمین سطح آب زیرزمینی از خود نشان داده است.

**واژه‌های کلیدی:** الگوریتم رقابت استعماری، الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات، بهینه‌سازی کلونی مورچگان، پرسپترون

### مقدمه

که آب‌های زیرزمینی در برخی مناطق به‌عنوان منابع ذخیره در نظر گرفته می‌شوند، در حالی که در مناطق دیگر ممکن است، از آن‌ها برای تامین آب شرب

یکی از منابع اصلی تامین آب خانگی، کشاورزی و اهداف صنعتی آب زیرزمینی است. شایان ذکر است

کاهش دهد و حتی می‌تواند به خشکی سفره منجر شود.

به‌طور معمول، روش‌های عددی مبتنی بر فیزیک برای تعیین سامانه جریان آب زیرزمینی و تغییرات پیش‌بینی از سطح آب زیرزمینی استفاده می‌شود. نتایج این رویکردها بر اساس حل معادلات حاکم بر جریان در لایه‌های متخلخل از طریق شرایط مناسب اولیه و مرزی آبخوان به‌دست می‌آید (Yoon و همکاران، ۲۰۱۱). روش دیگر جایگزین برای شبیه‌سازی و پیش‌بینی تغییرات سطح آب زیرزمینی، بر اساس تکنیک‌های مدل‌سازی سری زمانی (شامل مدل‌های خطی و غیرخطی) استوار است. این تکنیک‌ها به داده‌های سری زمانی تغییرات سطح آب زیرزمینی (به‌طور معمول برای یک دوره طولانی) و احتمالاً برخی از متغیرهای ورودی مرتبط (مانند بارش) وابسته است. با این حال، خروجی این مدل‌ها محدود به پیش‌بینی تغییرات زمانی در یک منطقه خاص است (Yoon و همکاران ۲۰۱۱؛ Khalil و همکاران، ۲۰۱۵). از روش‌های داده‌محور غیرخطی محبوب برای شبیه‌سازی آب زیرزمینی، رویکرد محاسبات نرم است که شامل شبکه‌های عصبی مصنوعی (ANN)، شبکه‌های موجی، سامانه‌های استنتاج تطبیقی نوروفازی، رگرسیون بردار پشتیبان، روش همبستگی تصادفی شبکه تطبیقی و غیره می‌باشد (Zeng و همکاران، ۲۰۱۶). امتیاز قابل توجه تکنیک‌های محاسبات نرم در مدل‌سازی سامانه‌ها این است که نیازی به یک رابطه فیزیکی خوش‌تعریف برای تبدیل یک ورودی به یک خروجی ندارند (Nayak و همکاران، ۲۰۰۴). در میان انواع مختلف رویکردهای محاسبات نرم، مدل‌های شبکه عصبی مصنوعی به‌طور مطلوب برای شبیه‌سازی هیدرولوژی غیرخطی از قبیل بارندگی (Acharya و همکاران، ۲۰۱۴)، تبخیر و تعرق (Kisi و همکاران، ۲۰۱۵) و جریان رودخانه (Zounemat-Kermani و همکاران، ۲۰۱۳) مورد استفاده قرار گرفته است. تا به امروز، برخی از محققان از شبکه عصبی برای مدل‌سازی تغییرات آب زیرزمینی استفاده کرده‌اند (Daliakopoulos و همکاران، ۲۰۰۵؛ Chan و Adamowski، ۲۰۱۰؛ Dash و همکاران، ۲۰۱۰).

به‌علت دسترس‌پذیری آن‌ها استفاده شود (Daliakopoulos و همکاران، ۲۰۰۵؛ Nayak و همکاران، ۲۰۰۶). تجزیه و تحلیل سطح آب زیرزمینی یک عامل ضروری برای حفظ دسترسی آن است. مدل‌سازی و پیش‌بینی سطح آب زیرزمینی برای حفاظت از محیط زیست، حفظ کردن تعادل سامانه آب زیرزمینی، کنترل تغییرات سطح آب زیرزمینی و محافظت از تشدید نشست زمین اهمیت دارد. تکنیک‌ها و راه‌حل‌های مدیریت آب‌های زیرزمینی و اقدامات کنترلی به‌وسیله پژوهشگران و متصدیان برای مقابله با مشکلات دراز مدت نشست زمین و حفاظت منابع آب زیرزمینی ارائه شده است (Affandi و Watanabe، ۲۰۰۷؛ Mohanty و همکاران، ۲۰۱۵). علاوه بر این، بعضی موضوعات از قبیل تخلیه منابع آب زیرزمینی، تناقض بین استفاده از آب‌های زیرزمینی و آب‌های سطحی و پتانسیل آلودگی آب‌های زیرزمینی می‌تواند به‌عنوان برخی نگرانی‌ها دسته‌بندی شوند که پتانسیل این را دارند که به مسائل مهمی تبدیل شوند، ولی باید اذعان کرد که مهمتر از همه این‌ها گسترش حوضه آبخوان است. نتایج تخلیه آبخوان می‌تواند منجر به جیره‌بندی آب محلی، کاهش شدید بازدهی محصولات کشاورزی، تغییر کیفیت آب‌های زیرزمینی و تغییر الگوی جریان آب‌های زیرزمینی شود (Nayak و همکاران، ۲۰۰۶). برای یک سامانه آب زیرزمینی، سطح آب زیرزمینی از عوامل زیادی متاثر است. در کنار بارش و تبخیر، عوامل پمپاژ مصنوعی، ساختار زمین‌شناسی، نفوذپذیری مواد آبخوان و غیره نیز بر سطح آب زیرزمینی تاثیر می‌گذارند. در صورت امکان تمام این پارامترهای تاثیرگذار باید برای مدل‌سازی بهتر سطح آب زیرزمینی مورد توجه قرار گیرد. پمپاژ مصنوعی از چاه‌ها تاثیر زیادی بر سطح آب زیرزمینی به‌خصوص در مجاورت چاه دارد. اگر آب به سرعت از زمین خارج شود، سطح سفره زیرزمینی کاهش می‌یابد و این خود باعث فرورفتگی مخروطی در اطراف چاه می‌شود. بر طبق شرایط هیدرولوژی و زمین‌شناسی آبخوان، سطح آب زیرزمینی می‌تواند به مقدار کمی تا صدها پا کاهش یابد. پمپاژ مصنوعی بیش از حد می‌تواند سفره آب زیرزمینی را به وسعت بزرگ‌تری

موثر از آب برگشتی کشاورزی، جریان خروجی زیرزمینی، برداشت از آبخوان برای کشاورزی و تبخیر از سطح آب زیرزمینی است.

### مواد و روش‌ها

**منطقه مورد مطالعه:** دشت عباس در استان ایلام در بخش جنوب غربی ایران در عرض جغرافیایی ۳۲ و طول جغرافیایی ۴۷ قرار گرفته است. داده‌های استفاده شده در این مطالعه سطح آب زیرزمینی، بارش، تبخیر، متوسط دمای سالانه و نفوذ موثر بین سال‌های ۱۳۷۲ تا ۱۳۹۴ است. میانگین بارش این دشت در حدود ۲۵۲ میلی‌متر که عمدتاً در فصل پاییز و زمستان رخ می‌دهد است. شکل ۱، موقعیت دشت عباس در ایران را نشان می‌دهد. در منطقه مورد مطالعه، آب‌های زیرزمینی منبع اصلی آب شرب و قسمتی از آب کشاورزی هستند، به دلیل افزایش تقاضا از منابع ذخیره آب، نظارت بر سفره‌های آب به‌وسیله مدیران برای ارزیابی شرایط آب زیرزمینی فعلی و بلند مدت در دشت عباس مورد نیاز است.

**داده‌ها و اطلاعات مورد نیاز بیان آب زیرزمینی:** مولفه‌های بیان آب زیرزمینی با کلیه ورودی‌ها و خروجی‌ها آبخوان با توجه معادله بیان آب زیرزمینی یک لایه آبدار از رابطه زیر به دست می‌آید (Alizadeh, 2001).

$$\left[ \left( \begin{array}{c} (Q_{in} + Q_p + Q_r + Q_{AR} + Q_I + Q_{mi}) \\ -(Q_{out} + Q_w + Q_d + Q_e) \end{array} \right) \times (1) \right] t = \pm \Delta V$$

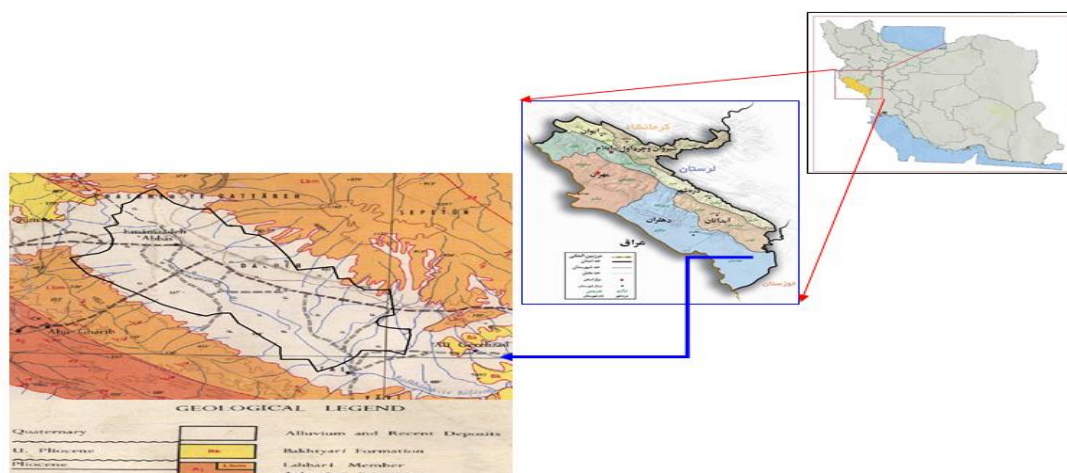
که در آن،  $Q_{in}$  میزان جریان ورودی به محدوده بیان،  $Q_p$  میزان نفوذ از بارندگی،  $Q_r$  آب نفوذی از رواناب و سیلاب،  $Q_{AR}$  آب نفوذی از عملیات تغذیه مصنوعی،  $Q_I$  آب برگشتی از آبیاری زمین‌های کشاورزی،  $Q_{mi}$  آب برگشتی از فاضلاب‌های شهری و صنعتی،  $Q_{out}$  میزان جریان خروجی زیرزمینی،  $Q_w$  آب خروجی از چشمه‌ها، چاه‌ها و قنات‌ها،  $Q_d$  آب خروجی از زهکشی‌ها،  $Q_e$  آب تبخیرشده از سفره آب زیرزمینی،  $t$  پارامتر زمان و  $\Delta V$  تغییرات حجم آب ذخیره‌شده در آبخوان است (Hou, 2016; Iwalewa, 2016). از همین مولفه‌ها هم برای محاسبه بیان در تحقیقات خود استفاده کرده‌اند. دشت مورد مطالعه

۲۰۱۱؛ Tahershamsi و Sheikholeslami, 2011؛ Khalil و همکاران، 2015؛ Sun و همکاران، 2016). بیشتر این مطالعات اشاره کرده‌اند که شبکه عصبی مصنوعی (به‌عنوان مدل غیرخطی) ساده‌تر، سریع‌تر برای توسعه و نتایج دقیق و جامعی نسبت به مدل‌های مبتنی بر فیزیک یا عددی داشته است. با این حال، برخی از مقالات نشان می‌دهند که شبکه‌های عصبی می‌توانند برای پیش‌بینی تغییرات آب زیرزمینی کوتاه مدت قابل اطمینان باشند. Sun و همکاران (2016) گزارش داده‌اند که شبکه‌های عصبی قادر به تولید پیش‌بینی دقیق سفره آب زیرزمینی برای یک روز هستند، در حالی که عملکرد شبکه زمانی که به سه یا هفت روز افزایش می‌یابد، منجر به کاهش عملکرد می‌شود. در مطالعه دیگر، Mohanty و همکاران (2015) نشان داده‌اند که مدل شبکه عصبی نتایج بهتری در زمان‌های کوتاه‌مدت نسبت به زمان‌های بلندمدت ارائه می‌دهد.

برای آموزش مدل‌های شبکه عصبی برای تخمین سطح آب زیرزمینی از الگوریتم‌های متفاوتی می‌توان استفاده کرد. بیشتر روش‌های مرسوم برای آموزش شبکه‌های عصبی از گرادینان نزولی با استفاده از انتشار به عقب برای محاسبه گرادینان واقعی استفاده می‌کنند (Daliakopoulos و همکاران، 2005). در سال‌های اخیر، برخی از محققین از تکنیک‌های تکاملی برای تخمین تغییرات سطح آب زیرزمینی از جمله الگوریتم ژنتیک (Dash و همکاران، 2010؛ Jalakamali و Jalakamali, 2011)، الگوریتم رقابت استعماری (Tahershamsi و Sheikholeslami, 2011)، بهینه‌سازی ازدحام ذرات (Xi و همکاران، 2012؛ Gaur و همکاران، 2013) و مقایسه این روش‌ها با هم (Kisi و همکاران، 2017) استفاده کرده‌اند.

با توجه به شناخت نویسنده‌گان این مطالعه، مقاله مرتبطی با مقایسه چهار شبکه عصبی تکاملی ANN-GA، ANN-ICA، ANN-PSO و ANN-ACOR برای مدل‌سازی سطح آب زیرزمینی انتشار نیافته است. هدف اصلی این مطالعه، بررسی دقت مدل‌های ذکر شده برای تخمین سطح آب زیرزمینی بر طبق داده‌های جریان ورودی زیرزمینی، نفوذ موثر از بارندگی، نفوذ موثر از جریان سطحی و سیلاب، نفوذ

فاقد طرح تغذیه مصنوعی ( $Q_{AR}$ )، طرح زهکشی ( $Q_d$ ) و به دور از مناطق شهری و صنعتی ( $Q_{mi}$ ) استفاده نشده است. به همین دلیل از این داده‌ها برای مطالعه



شکل ۱- موقعیت مکانی منطقه مورد مطالعه

جدول ۱- تغییرات بیلان آب زیرزمینی با استفاده از رابطه (۱) در سال‌های ۱۳۷۲-۱۳۹۴

بیلان (M.C.M)	عوامل تخلیه (M.C.M)			عوامل تغذیه (M.C.M)				سال
	$Q_e$	$Q_w$	$Q_{OUT}$	$Q_i$	$Q_R$	$Q_P$	$Q_{IN}$	
-۱۴/۹۵	۰	۴۰/۹	۲/۰۹	۱۲/۲۷	۱/۱۳	۵/۹	۱۰	۱۳۷۲-۷۳
-۱۱/۱۱	۰	۴۰/۹	۲/۲	۱۲/۲۷	۱/۲۸	۴/۹	۱۴/۸	۱۳۷۳-۷۴
-۸/۵	۰	۴۰/۹	۲/۲	۱۲/۲۷	۰/۸۹	۷/۸	۱۴/۹	۱۳۷۴-۷۵
-۹/۲	۰	۴۰/۹	۱/۹۸	۱۲/۲۷	۰/۵۷	۷/۳	۱۴/۸	۱۳۷۵-۷۶
-۹/۱۴	۰	۴۰/۹	۱/۹۳	۱۲/۲۷	۲/۷۸	۵/۸	۱۴/۱	۱۳۷۶-۷۷
-۶/۱۵	۰	۴۰/۹	۲/۴۱	۱۲/۲۷	۱/۲۵	۹/۳	۱۵/۶	۱۳۷۷-۷۸
-۱۰/۹۸	۰	۴۰/۹	۲/۳۶	۱۲/۲۷	۰/۲۷	۵/۲	۱۵/۸	۱۳۷۸-۷۹
-۱۱/۸۵	۰	۴۰/۹	۲/۵	۱۲/۲۷	۰/۷۴	۳/۴	۱۶/۴	۱۳۷۹-۸۰
-۹/۸۲	۰	۴۰/۹	۲/۵۳	۱۲/۲۷	۰/۶۴	۵/۳	۱۶/۶	۱۳۸۰-۸۱
-۱۰/۱۱	۰	۴۰/۹	۲/۶۶	۱۲/۲۷	۰/۱۴	۵/۵	۱۶/۸	۱۳۸۱-۸۲
-۹/۴۱	۰	۴۰/۹	۲/۸۸	۱۲/۲۷	۱/۳۶	۴/۴	۱۷/۶	۱۳۸۲-۸۳
-۶/۳۱	۰	۴۰/۹	۲/۶۴	۱۲/۲۷	۱/۶۲	۶/۹	۱۷/۷	۱۳۸۳-۸۴
-۷/۰۳	۰	۴۰/۹	۲/۷۷	۱۲/۲۷	۰/۶۳	۶/۶	۱۸/۴	۱۳۸۴-۸۵
۱۰/۷۶	۰/۱۱	۲۰/۹	۲/۸۴	۱۲/۲۷	۰/۵۰	۴/۴	۱۸/۷	۱۳۸۵-۸۶
۲۲/۶۴	۰/۹۰	۲۰/۹	۲/۶۵	۲۰/۹۷	۰/۲۸	۶/۳	۲۰/۸	۱۳۸۶-۸۷
۲۷/۰۵	۲/۰۵	۲۰/۶۷	۲/۵۷	۲۸/۳۳	۰/۰۶	۳/۴	۲۲/۱	۱۳۸۷-۸۸
۲۰/۲۸	۱/۶۹	۲۰/۶۷	۲/۴۴	۲۰/۱۶	۰/۵۶	۴	۲۱/۹	۱۳۸۸-۸۹
۲۶/۵۰	۳/۵۳	۲۰/۶۷	۲/۸۶	۲۶/۵۸	۰/۴۱	۵/۹	۲۲/۲	۱۳۸۹-۹۰
۳۷/۷۶	۳/۵۰	۸/۶۷	۲/۸۸	۲۶/۹۴	۰/۱۱	۴/۲	۲۳/۱	۱۳۹۰-۹۱
۵۳/۱۶	۳/۴۱	۸/۶۷	۲/۵۱	۴۲/۲	۱/۰۹	۳/۵	۲۲/۵	۱۳۹۱-۹۲
۶۷/۱۵	۳/۳۱	۵/۶۷	۲/۵۸	۵۰/۴۸	۰/۹۷	۷/۳	۲۱/۵	۱۳۹۲-۹۳
۷۳/۴۸	۵/۱۵	۵/۶۷	۲/۸۳	۶۰/۷	۰/۲۷	۶/۲	۲۱/۵	۱۳۹۳-۹۴

زیرزمینی این دشت استفاده شده است. داده‌های استفاده‌شده شامل دو بازه زمانی تر و خشک است.


در این پژوهش، از ۴۶ نمونه داده سالانه آب زیرزمینی دشت عباس برای تخمین سطح آب

پیش‌بینی پاسخ‌های چندگانه از سامانه‌های غیرخطی پویا از شبکه‌های عصبی پس‌انتشار (BPNN) برای بسیاری از کارهای علمی انتخاب مناسبی به حساب می‌آید. در این نوع از شبکه‌های عصبی، بهینه‌سازی وزن‌ها به‌وسیله انتشار به عقب خطا در طول آموزش یا در فاز آموزش انجام می‌شود (Hajmeer و Basheer، ۲۰۰۰؛ Mukherjee و Routroy، ۲۰۱۲). در مطالعات اخیر، الگوریتم ژنتیک (GA)، بهینه‌سازی ازدحام ذرات (PSO)، الگوریتم رقابت استعماری (ICA) و بهینه‌سازی کلونی مورچه‌ها (ACOR) الگوریتم‌هایی هستند که برای آموزش مدل‌های شبکه‌های عصبی استفاده شده‌اند. در ادامه، این تکنیک‌های بهینه‌سازی به اختصار توضیح داده خواهند شد.

**الگوریتم ژنتیک (GA):** الگوریتم‌های ژنتیک، الگوریتم‌هایی هستند که برای تقلید اصول تکامل زیستی در سامانه ژنتیک طبیعی طراحی شده‌اند. GA به‌عنوان روش نمونه‌گیری تصادفی شناخته می‌شود. این الگوریتم می‌تواند به‌منظور شناسایی مسائل سخت در توابع هدف که دارای ویژگی‌های پیچیده مانند چندمنظوره بودن، غیرمداوم بودن، غیرقابل تشخیص و غیره به‌کار برده شود. این الگوریتم‌ها یک جمعیت راه‌حل را مدیریت و دست‌کاری می‌کنند و جستجوی خود را برای راه‌حل‌های عمده در مورد بقای تاکتیک‌های مناسب انجام می‌دهند. الگوریتم‌های ژنتیک مسائل خطی و غیرخطی را از طریق جستجوی همه نواحی فضای حالت و مناطق امیدبخش فعال از طریق متقاطع، جهش، تقاطع و انتخاب افراد در جمعیت حل می‌کند (Shen و همکاران، ۲۰۰۷). از سوی دیگر، در مورد انتخاب طبیعی و مکانیسم‌های ژنتیک، الگوریتم‌های ژنتیک به‌صورت تکراری جمعیت ترکیبات مصنوعی را از طریق عمل‌گرهای ژنتیکی بهبود می‌دهد. در فاز پردازش الگوریتم‌های ژنتیک، فقط به اطلاعات سازگار (به‌جای اطلاعات شیب) نیاز دارند (Kuo و همکاران، ۲۰۱۱). به‌طور کلی، پردازش الگوریتم ژنتیک به تعیین شش موضوع اساسی (۱) کروموزوم‌های نماینده، (۲) انتخاب تابع، (۳) عمل‌گرهای ژنتیک، (۴) ایجاد جمعیت اولیه، (۵) شرایط پایانی و (۶) تابع ارزیابی، نیاز دارد (Shen و همکاران، ۲۰۰۷).

برای صحت‌سنجی تخمین مدل داده‌ها به دو دسته تقسیم شده است. ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد داده‌ها برای آزمایش شبکه مورد استفاده قرار گرفته است.

**شبکه‌های عصبی مصنوعی:** شبکه‌های عصبی مصنوعی مدل محاسباتی الهام گرفته شده از مغز انسان هستند که شامل واحدهای منفرد مختلف به هم متصل (نورون) با ضرایبی (وزن‌ها) که ساختار شبکه را تشکیل داده‌اند، می‌باشند. نورون‌ها به‌عنوان واحدهای پردازش شناخته می‌شوند که اطلاعات را پردازش می‌کنند. سه نوع از نورون‌ها در شبکه‌های عصبی وجود دارد: (۱) نورون‌های خروجی، این نورون‌ها داده‌ها را به خارج از شبکه ارسال می‌کنند، (۲) نورون‌های ورودی که داده‌های خارجی را دریافت می‌کند و (۳) نورون‌های پنهان که نورون‌های لایه ورودی را به نورون‌های لایه خروجی متصل می‌کنند (Samani و همکاران، ۲۰۰۷؛ Zounemat-Kermani، ۲۰۱۲). هر کدام از نورون‌ها یک وزن ورودی، تابع انتقال و خروجی دارد، اساساً نورون‌ها بین ورودی‌ها و خروجی‌ها تعادل برقرار می‌کنند. طراحی‌های بسیار زیادی از شبکه‌های عصبی تا به حال وجود داشته است و هر ماه یک طراحی جدید کشف می‌شود. با این حال، همه شبکه‌های عصبی را می‌توان از طریق توابع انتقال نورونی، الگوریتم آموزش یا قوانین یادگیری و از طریق فرمول اتصالات آن‌ها شرح داد. در میان تمام ساختارهای شبکه‌های عصبی، پرسپترون چندلایه جלוوسو (FF-MLP) به‌طور مرسوم به‌عنوان یک تخمین‌گر سراسری شناخته می‌شود (Kisi و همکاران، ۲۰۱۵). شماتیک شبکه (FF-MLP) در شکل ۲ ارائه شده است. ورودی‌ها (سیگنال‌های دریافتی) وزن‌های اتصالات را ضرب می‌کنند و بعد از ترکیب اتصالات از یک تابع انتقال عبور می‌دهند تا خروجی برای نورون به‌دست آید. توابع فعال‌ساز بر روی مقادیر وزن‌دار شده جمعی عمل می‌کنند، معمولاً از توابع سیگموئیدی (منطقی) برای توابع انتقال استفاده می‌شود. قوانین یادگیری متفاوت زیادی برای شبکه‌های عصبی جלוوسو وجود دارد، اما اغلب از قوانین دلتا یا قوانین پس‌انتشار (BP) Kisi (۲۰۰۷) استفاده می‌شود. توانایی



شکل ۲- شماتیک شبکه عصبی پرسپترون چندلایه

گروه ذرات تولید می‌شود. سپس، هر کدام از ذرات در فضای جستجو حرکت می‌کند. سرعت به صورت برداری از موقعیت سابق خود به موقعیت فعلی تعریف می‌شود، در حالی که سرعت آغازین تمام ذرات برابر صفر در نظر گرفته شده است. سرعت جدید برای هر ذره بر طبق معادله زیر تعیین می‌شود:

$$\vec{v}_{new} = \vec{v} + r_1 c_1 \times (\vec{p}_{best} - \vec{p}) + r_2 c_2 \times (\vec{g}_{best} - \vec{p}) \quad (2)$$

که در آن،  $\vec{v}_{new}$ ،  $\vec{v}$  و  $\vec{p}$  به ترتیب سرعت جدید، سرعت کنونی و موقعیت کنونی ذره است.  $c_1$  و  $c_2$  ضرایب از پیش تعیین شده (ضرایب شتاب) هستند.  $r_1$  و  $r_2$  مقادیر تصادفی در محدوده (۰،۱) با توزیع یکنواخت هستند. قدم بعدی در این الگوریتم تولید موقعیت جدید ذرات است که به صورت  $\vec{p}_{new}$  شناخته می‌شود (معادله ۲). این رویه تا اتمام شرایط توقف ادامه دارد.

$$\vec{p}_{new} = \vec{p} + \vec{v}_{new} \quad (3)$$

الگوریتم PSO را می‌توان برای بهینه‌سازی مسائل در علوم مهندسی به کار برد. در مقایسه با دیگر الگوریتم‌های بهینه‌سازی، PSO توانایی اشغال فضای جستجو بهینه‌سازی بزرگتری با استفاده از ارتباطات ساده و تکمیل آسان دارا است.

**الگوریتم رقابت استعماری (ICA):** الگوریتم رقابت استعماری یک الگوریتم بهینه‌سازی مبتنی بر جمعیت است که از مزایای سیاست مانند مفاهیم اجتماعی و فرهنگی در فرایند بهینه‌سازی استفاده کرده است.

**بهینه‌سازی ازدحام ذرات (PSO):** الگوریتم PSO یک رویکرد بهینه‌سازی تصادفی مبتنی بر شبیه‌سازی رفتار اجتماعی دسته‌ای از پرندها در یک گروه است. PSO یک روش جستجوی مبتنی بر جمعیت است که هر کدام از افراد جمعیت به یک ذره اطلاق می‌شود، دسته‌ای از جمعیت یک گروه را تشکیل می‌دهد. هر ذره در گروه بیانگر یک جواب کاندید برای مسئله بهینه‌سازی است. این الگوریتم به وسیله Eberhart و Kennedy (۱۹۹۵) ارائه شد. بعدها به وسیله Shi و Eberhart (۱۹۹۸) توسعه داده شد. در الگوریتم PSO، ذرات در سرتاسر فضای جستجوی فرابعدی پراکنده می‌شوند. موقعیت ذره‌ها در فضای جستجو مبتنی بر گرایش اجتماعی و روانشناسی افراد برای تقلید از موفقیت افراد دیگر تغییر می‌کند (Clerc و Kennedy، ۲۰۰۲).

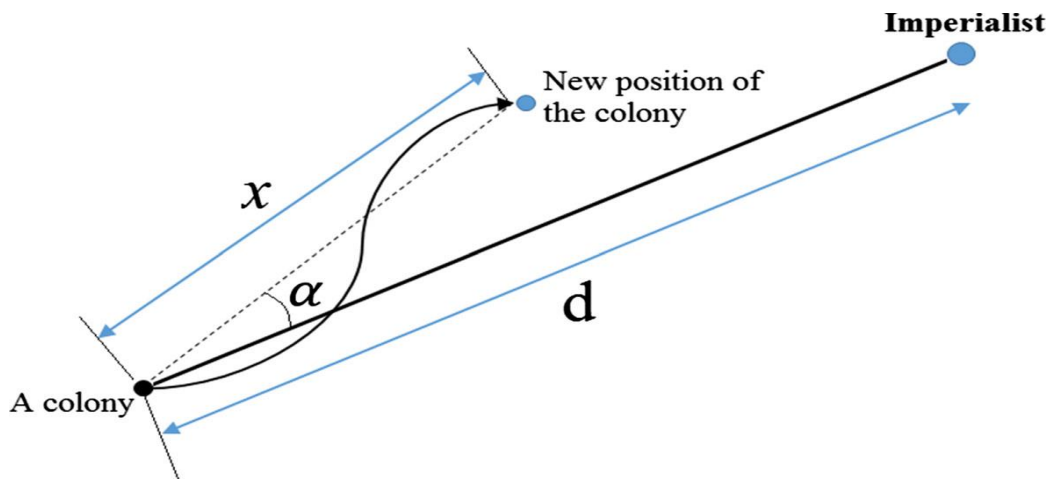
بنابراین، حرکت هر ذره در گروه با ترکیب برخی از جنبه‌های شخصی و آگاهی از حرکت همسایه‌هایش الهام گرفته است. بر طبق معادلات ریاضی، ذره‌ها در اطراف فضای جستجو برای پیدا کردن جواب بهینه در حرکت هستند. حرکات ذرات به وسیله خودشان هدایت می‌شود که به آن بهترین موقعیت شناخته شده خودشان ( $P_{best}$ ) می‌گویند و همچنین، بهترین موقعیت شناخته شده کل ذرات به بهترین ذره سراسری ( $G_{best}$ ) خوانده می‌شود. فرایند بهینه‌سازی الگوریتم PSO با مقداره‌ی اولیه پارامترها آغاز می‌شود. متعاقباً، اولین

در یک مسئله بهینه‌سازی دوبعدی است. با توجه به  $a > 1$  به‌عنوان ضرایب جذب (به‌عنوان مثال  $a=2$ )،  $x$  می‌تواند به‌صورت زیر تعریف شود (Ghaedi و همکاران، ۲۰۱۴؛ Amiri و همکاران، ۲۰۱۵).

$$x \sim U(0, \alpha xd); \alpha \sim U(-Y, Y) \quad (4)$$

$Y$  بیانگر پارامتر تصادفی است که مقدار انحراف از جهت اصلی را تنظیم می‌کند (مقدار اولیه  $Y$  برابر  $\pi/4$  فرض می‌شود) (Amiri و همکاران، ۲۰۱۵). در روش ICA، سیاست انقلاب در نظر گرفته شده است، به این صورت که تغییر ناگهانی در موقعیت کشورها به وجود می‌آید. استفاده از سیاست انقلاب قابلیت کشف رویکرد را افزایش داده و از هم‌گرایی زودهنگام کشورها و گیر کردن در کمینه محلی جلوگیری می‌کند (Nazari-Shirkouhi و همکاران، ۲۰۱۰). تئوری اصلی و اطلاعات جزئی درباره الگوریتم ICA را می‌توان در مقالات مربوطه بررسی کرد (Atashpaz Gargari و Lucas، ۲۰۰۷؛ Nazari-Shirkouhi و همکاران، ۲۰۱۰).

الگوریتم ICA در ابتدا به‌وسیله یک جمعیت اولیه، یعنی کشورهای امپریالیستی تنظیم شده است. هر کشور امپریالیستی شامل مستعمرات و کشورهای دیگر است (Atashpaz Gargari و Lucas، ۲۰۰۷؛ Abd-Elazim و Ali، ۲۰۱۶). کشورهای امپریالیستی با هم رقابت می‌کنند و سعی می‌کنند بر دیگر کشورها غلبه کنند و آن‌ها را به مستعمرات خود اضافه کنند. این رقابت هسته الگوریتم تکاملی رقابت استعماری را ایجاد می‌کند. در طول فرایند رقابت، امپراتوری‌های ضعیف‌تر سقوط می‌کنند و مستعمرات آن‌ها به‌وسیله امپراتوری قوی‌تر تصاحب می‌شود. این فرایند ادامه دارد تا یکی از امپراتوری‌ها با موقعیت مشخص مستعمرات آن باقی بماند. رویه اصلی الگوریتم رقابت استعماری به شرح زیر است: بعد از آغاز فرایند، هر مستعمره به سوی کشور امپریالیست مربوطه با توجه به سیاست جذب کشورهای امپریالیست در سراسر محورهای بهینه‌سازی مختلف حرکت می‌کند. شکل ۳، تصویر متحرک یک مستعمره به سمت امپریالیستی را با  $x$  نشان می‌دهد، که یک متغیر تصادفی توزیع شده



شکل ۳- نمایش حرکت مستعمره به‌سوی امپریالیست مربوطه

(۲۰۰۶). این روش به‌طور خاص تلاش می‌کند که رفتار تیمی کلونی مورچه‌ها برای پیدا کردن منبع غذا را تقلید کند. اگر منبع غذا به‌وسیله یکی از مورچه‌ها پیدا شود، سپس آن مورچه ارزیابی مختصری از اندازه منبع غذا انجام می‌دهد. سپس، مورچه بخشی از غذا را با خود به لانه می‌آورد، در حالی که مقداری فرمون در راه بازگشت رها می‌کند که به‌عنوان اثر فرمون شناخته

بهینه‌سازی کلونی مورچگان (ACO): بهینه‌سازی کلونی مورچگان (ACO) بر اساس رفتار تغذیه‌ای واقعی کلونی مورچه‌ها برای جستجوی غذا می‌باشد. ایده اصلی این روش، اولین بار به‌وسیله Dorigo و Gambardella (۱۹۹۷) ارائه شد و سپس این ایده به‌عنوان یک تکنیک بهینه‌سازی اصلاح و ارائه شد (Shen و همکاران، ۲۰۰۵؛ Dorigo و همکاران،

است.

تحلیل همبستگی برای تصمیم‌گیری در مورد ترکیب داده‌های بهینه استفاده شده است. خودهمبستگی، خودهمبستگی جزئی و همبستگی متقابل برای داده‌های سطح آب زیرزمینی، جریان ورودی زیرزمینی، نفوذ موثر از بارندگی، نفوذ موثر از جریان سطحی و سیلاب، نفوذ موثر از آب برگشتی کشاورزی، جریان خروجی زیرزمینی، برداشت از آبخوان برای کشاورزی و تبخیر از سطح آب زیرزمینی از تاخیر (۱۰-۰) و ۹۵ درصد محدوده اطمینان استفاده شده است (شکل ۴). با توجه به شکل ۴ قسمت A واضح است که داده سطح آب زیرزمینی همبستگی بالایی دارند. با مشاهده شکل ۴ قسمت B، تابع همبستگی نیمه‌خودکار نشان می‌دهد که همبستگی داده‌ها در تاخیرهای سه و شش اهمیت ندارد و در محدوده اطمینان قرار گرفته‌اند. الگوی کاهش سریع در قسمت B حاکمیت فرایند رگرسیون خودکار مربوط به فرایند میانگین حرکت را ثابت می‌کند. شکل ۴، قسمت‌های C، F، H و I نشان می‌دهد که جریان ورودی زیرزمینی، آب برگشتی از آبیاری زمین‌های کشاورزی، آب خروجی از چاه‌ها، چشمه‌ها، قنات‌ها و آب تبخیرشده از سفره آب زیرزمینی یک سال پیش با سطح آب زیرزمینی فعلی همبستگی بالایی دارند. شکل ۴، قسمت‌های D و E نشان می‌دهد که نفوذ از بارندگی و آب نفوذی از رواناب و سیلاب‌ها با تاخیر دو سال با سطح آب زیرزمینی فعلی همبستگی دارند. شکل ۴، قسمت G نشان می‌دهد که جریان خروجی آب زیرزمینی پنج سال قبل با سطح آب زیرزمینی فعلی همبستگی بالایی دارد. تجزیه و تحلیل داده‌ها به ما نشان می‌دهد که شرایط پیشین مقادیر سطح آب زیرزمینی، جریان ورودی زیرزمینی، نفوذ موثر از بارندگی، نفوذ موثر از جریان سطحی و سیلاب، نفوذ موثر از آب برگشتی کشاورزی، جریان خروجی زیرزمینی، برداشت از آبخوان برای کشاورزی و تبخیر از سطح آب زیرزمینی می‌توانند به‌عنوان ورودی برای مدل شبکه عصبی تکاملی کافی باشند.

قبل از استفاده از مدل‌های شبکه عصبی تکاملی،

می‌شود. این اثر فرمون به بقیه مورچه‌ها از دیگر لانه‌ها این شانس را می‌دهد که منبع غذای او را پیدا کنند. همه مورچه‌ها بعد از این که منبع غذایی را پیدا کردند، این عمل را تکرار می‌کنند. مقدار فرمون باقی‌مانده بر روی زمین به‌طور کلی به کیفیت و تعداد منبع کشف شده وابسته است (Socha و Dorigo، ۲۰۰۸). ماده اصلی فرمون قابل تبخیر است و مقدار آن در طول زمان کاهش می‌یابد. بنابراین، راه انتخاب شده به‌وسیله مورچه‌ها نشان‌دهنده مقدار اثر فرمون باقی‌مانده در مسیر است. بر طبق این روش، راه‌های کوتاه‌تر به‌علت اثر فرمون اولویت دارند و مورچه‌ها سعی می‌کنند، مسیرهای کوتاه‌تر ممکن را پیدا کنند. روش ACO بر اساس به‌روزرسانی اثر فرمون که بیان‌کننده راه‌حل خوب است، عمل می‌کند. تکنیک ACO دارای دو نسخه اصلی شامل روش پیوسته و گسسته است. ACO پیوسته (ACOR) برای مسائل بهینه‌سازی فضای جستجوی پیوسته به‌طور موفقیت‌آمیزی مورد استفاده قرار گرفته‌است (Toksari، ۲۰۰۷؛ Yu و همکاران، ۲۰۰۷).

**معیارهای ارزیابی و تحلیل داده‌ها:** در این مطالعه، سطح آب زیرزمینی با استفاده از چهار شبکه عصبی تکاملی متفاوت، ANN-GA، ANN-PSO، ANN-ICA و ANN-ACOR مدل شده است. مدل‌های استفاده‌شده با میانگین خطای نسبی (MRE)، میانگین مربع خطا (MSE) و ضریب تعیین ( $R^2$ ) ارزیابی شده‌اند.

$$MSE = \frac{1}{N} \sum_{i=1}^N (GWL_{i,a} - GWL_{i,e})^2 \quad (5)$$

که در آن،  $N$  تعداد داده‌ها،  $GWL_{i,a}$  سطح آب زیرزمینی مشاهده‌شده و  $GWL_{i,e}$  بیانگر تخمین مدل است.

$$R^2 = 1 - \frac{\sum_{i=1}^N (GWL_{i,a} - GWL_{i,e})^2}{\sum_{i=1}^N (GWL_{i,a} - \overline{GWL_{i,o}})^2} \quad (6)$$

که در آن،  $N$  تعداد داده‌ها،  $GWL_{i,a}$  سطح آب زیرزمینی مشاهده‌شده و  $GWL_{i,e}$  بیانگر تخمین مدل است.

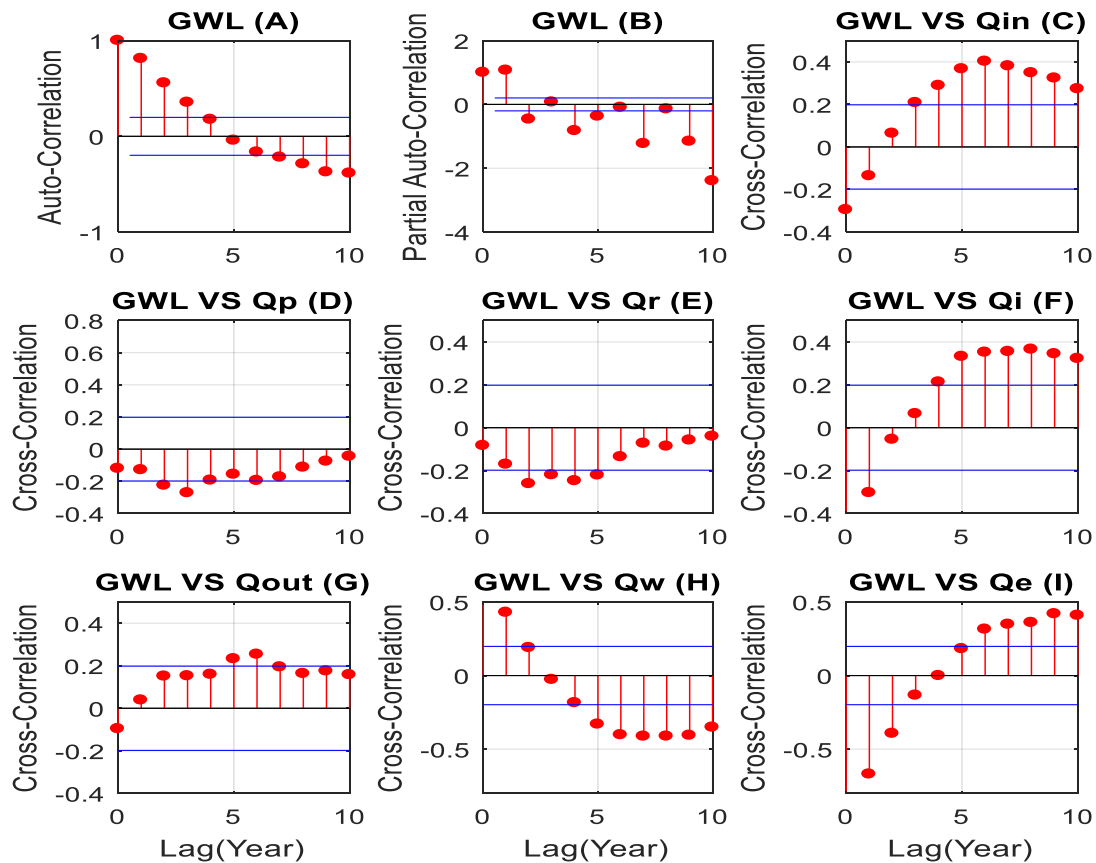
$$MRE = \frac{1}{N} \sum_{i=1}^N \left| \frac{GWL_{i,a} - GWL_{i,e}}{GWL_{i,a}} \right| \quad (7)$$

که در آن،  $N$  تعداد داده‌ها،  $GWL_{i,a}$  سطح آب زیرزمینی مشاهده‌شده و  $GWL_{i,e}$  بیانگر تخمین مدل



زیرزمینی، جریان ورودی زیرزمینی، نفوذ موثر از بارندگی، نفوذ موثر از جریان سطحی و سیلاب، نفوذ موثر از آب برگشتی کشاورزی، جریان خروجی زیرزمینی، برداشت از آبخوان برای کشاورزی و تبخیر از سطح آب زیرزمینی در زمان  $t$  به ترتیب به صورت  $GWL, Q_e, Q_w, Q_{out}, Q_i, Q_r, Q_p, Q_{in}$  بیان شوند.

داده‌های ورودی نرمالیزه شده به این ترتیب که مقادیر بیشینه و کمینه داده‌ها در محدوده (۰-۱۰) قرار می‌گیرند. بعد از اتمام مراحل تخمین به وسیله شبکه عصبی داده‌ها به حالت اولیه خود بازگردانده می‌شوند. نرمال‌سازی داده‌ها به واسطه برای آموزش مدل کمک می‌کند. اجازه دهید، مقادیر سطح آب



شکل ۴- تحلیل همبستگی داده‌های مورد استفاده: قسمت A) ضریب خودهمبستگی برای سطح آب زیرزمینی، قسمت B) خودهمبستگی جزئی برای سطح آب زیرزمینی، قسمت C) همبستگی متقابل بین جریان ورودی زیرزمینی و سطح آب زیرزمینی، قسمت D) همبستگی متقابل بین نفوذ از بارندگی و سطح آب زیرزمینی، قسمت E) همبستگی متقابل بین آب نفوذی از رواناب و سیلاب‌ها و سطح آب زیرزمینی، قسمت F) همبستگی متقابل بین آب برگشتی از آبیاری زمین‌های کشاورزی و سطح آب زیرزمینی، قسمت G) همبستگی متقابل بین جریان خروجی آب زیرزمینی و سطح آب زیرزمینی، قسمت H) همبستگی متقابل بین آب خروجی از چاه‌ها، چشمه‌ها، قنات‌ها و سطح آب زیرزمینی، قسمت I) همبستگی متقابل بین آب تبخیرشده از سفره آب زیرزمینی و سطح آب زیرزمینی

دارد، که آن سطح آب زیرزمینی،  $GWL_t$  است. برای هر مدل شبکه عصبی، تعداد نودهای لایه پنهان برابر  $2n$  بیانگر تعداد داده‌های ورودی) طبق پیشنهاد Wong (۱۹۹۱) و Bhattacharyya (۱۹۹۸) و تعداد دوره برابر ۲۰۰ برای آموزش شبکه در نظر گرفته شده است. بعد از این که فاز آموزش به پایان رسید، وزن‌های

در مطالعه کنونی، ترکیب ورودی‌های زیر به کار برده شده است: (۱)  $GWL_{t-1}$  و  $GWL_{t-2}$ ، (۲)  $GWL_{t-1}$ ،  $GWL_{t-2}$ ،  $Q_{i,t-1}$  و  $Q_{r,t-1}$ ، (۳)  $GWL_{t-1}$ ،  $GWL_{t-2}$ ،  $Q_{e,t-1}$  و  $Q_{w,t-1}$ ، (۴)  $GWL_{t-1}$  و  $GWL_{t-2}$ ،  $Q_{out,t-1}$ ،  $Q_{i,t-1}$ ،  $Q_{r,t-1}$ ،  $Q_{p,t-1}$ ،  $Q_{in,t}$  و  $Q_{e,t-1}$  در تمام موارد، لایه خروجی فقط یک نورون

تصادفی، مسابقه‌های و چرخ رولت، اندازه جمعیت و تقاطع به‌ترتیب برابر ۲۰۰ و ۰/۵ در نظر گرفته شده است. در جدول ۱، اعدادی که زیر آن‌ها خط کشیده شده است، نشان‌دهنده مقادیر کمینه MSE برای هر ترکیب ورودی و عدد رنگ‌شده نشان‌دهنده بهترین مدل ANN-GA برای تخمین سطح آب زیرزمینی با توجه به MSE است. با توجه به جدول، واضح است که محدوده MSE از ۰/۰۰۶۷ تا ۰/۰۱۳۸ برای آموزش و از ۰/۰۰۲۵ تا ۰/۰۲۱۷ برای آزمون به‌دست آمده است. بیشترین مقدار MSE برای مدل ANN-GA شامل ترکیب ورودی ۴ ( $Q_{r_t}, Q_{p_{t-1}}, Q_{in_t}, GWL_{t-2}, GWL_{t-1}$ )، ۱ ( $Q_{e_{t-1}}, Q_{w_{t-1}}, Q_{out_{t-1}}, Q_{i_{t-1}}$ )، در حالی که مدل با ترکیب ورودی ۳ ( $Q_{e_{t-1}}, GWL_{t-2}, GWL_{t-1}$ )، دارای بهترین دقت در فاز تست است. روش انتخاب چرخه رولت به‌طور کلی دارای دقت بالاتری در تخمین سطح آب زیرزمینی نسبت به روش انتخابی تورنمنت و تصادفی داشته است (با مشاهده ورودی ۱ و ۲).

شبکه ذخیره می‌شوند و برای صحت عملکرد شبکه برای داده‌های تست مورد استفاده قرار می‌گیرند. برای هر داده تست، MSE برای مدل شبکه عصبی محاسبه می‌شود.

### نتایج و بحث

**شبکه عصبی مصنوعی با الگوریتم ژنتیک:** اندازه‌های جمعیت متفاوت، روش انتخابی و تقاطع‌های متفاوت برای مدل ANN-GA امتحان شده است. در تقاطع، داده‌ها به گروه‌هایی تقسیم می‌شوند و با دیگر گروه‌ها مبادله می‌شوند و یک گروه جدید به‌طور تصادفی ایجاد می‌شود. دقت فازهای آموزش و تست برای مدل ANN-GA در جدول ۱ نشان داده شده است. برای اندازه جمعیت، از ۲۰۰، ۳۰۰ و ۴۰۰، برای تقاطع و انتخاب روش، از ۰/۵ و تصادفی به‌ترتیب استفاده شده است. برای تقاطع‌های ۰/۴، ۰/۵ و ۰/۶، اندازه جمعیت و انتخاب روش به‌ترتیب برابر ۲۰۰ و تصادفی استفاده شده است. برای روش‌های انتخاب،

جدول ۲- دقت MSE برای مدل‌های متفاوت ANN-GA در فاز آموزش و آزمون

ورودی‌ها	اندازه جمعیت			تقاطع			انتخاب روش	
	۲۰۰	۳۰۰	۴۰۰	۰/۴	۰/۵	۰/۶	تورنمنت	چرخه رولت
ورودی ۱								
آموزش	۰/۰۰۸۱	۰/۰۰۷۷	۰/۰۰۷۸	۰/۰۰۸۷	۰/۰۰۷۸	۰/۰۰۹۲	۰/۰۰۸۳	۰/۰۰۸۶
آزمایش	۰/۰۰۵۳	۰/۰۰۴۸	۰/۰۰۳۹	۰/۰۰۷۱	۰/۰۰۴۲	۰/۰۰۳۹	۰/۰۰۶۳	۰/۰۰۳۴
ورودی ۲								
آموزش	۰/۰۱۱۰	۰/۰۱۲۸	۰/۰۰۹۱	۰/۰۰۹۳	۰/۰۱۰۴	۰/۰۱۰۸	۰/۰۱۱۷	۰/۰۱۲۶
آزمایش	۰/۰۰۹۱	۰/۰۰۸۰	۰/۰۰۵۵	۰/۰۰۶۲	۰/۰۰۹۸	۰/۰۱۰۱	۰/۰۰۶۶	۰/۰۰۵۳
ورودی ۳								
آموزش	۰/۰۱۰۱	۰/۰۰۸۹	۰/۰۰۹۳	۰/۰۰۸۰	۰/۰۱۱۲	۰/۰۰۹۱	۰/۰۰۶۷	۰/۰۰۸۹
آزمایش	۰/۰۰۴۷	۰/۰۰۲۵	۰/۰۰۲۸	۰/۰۰۵۷	۰/۰۰۵۸	۰/۰۰۵۲	۰/۰۰۳۷	۰/۰۰۴۳
ورودی ۴								
آموزش	۰/۰۰۹۷	۰/۰۰۷۶	۰/۰۱۳۸	۰/۰۱۰۰	۰/۰۱۶۳	۰/۰۰۹۹	۰/۰۰۸۴	۰/۰۱۴۰
آزمایش	۰/۰۰۳۲	۰/۰۱۰۱	۰/۰۲۱۷	۰/۰۱۰۱	۰/۰۱۶۱	۰/۰۱۲۳	۰/۰۰۴۴	۰/۰۱۳۴

می‌دهد. برای اندازه‌های ازدحام ۲۰۰، ۳۰۰ و ۴۰۰، ضرایب سرعت اجتماعی و شناختی برابر ۲ تنظیم شده است. برای ضریب سرعت شناختی ۲، ۲/۵ و ۳، اندازه ازدحام و ضریب سرعت اجتماعی به‌ترتیب برابر ۲۰۰ و ۲ در نظر گرفته شده است. برای ضریب سرعت

**شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی ازدحام ذرات:** اندازه ازدحام متفاوت، ضرایب سرعت اجتماعی و شناختی متفاوتی برای مدل‌های ANN-PSO بررسی شده است. جدول ۲ میزان دقت فاز آموزش و تست برای مدل ANN-PSO را گزارش

ورودی ۲ ( $Q_{i-t}$  و  $Q_{r-t-1}$ ،  $Q_{p-t-1}$ ،  $Q_{in-t}$ ،  $GWL_{t-2}$ ،  $GWL_{t-1}$ ) و  $Q_{i-t}$  و  $Q_{r-t-1}$  و  $Q_{p-t-1}$  و  $Q_{in-t}$  و  $GWL_{t-2}$ ،  $GWL_{t-1}$ ) و  $Q_{w-t-1}$  و  $Q_{out-t-1}$ ،  $GWL_{t-2}$ ،  $GWL_{t-1}$ ) و  $Q_{e-t-1}$  (برای فاز آزمون به دست آمده است. این نشان می‌دهد که خطای مدل ANN-PSO برای داده‌های ورودی آبخوان نسبت به دیگر شرایط بیشتر می‌شود.

اجتماعی ۲، ۲/۵ و ۳، اندازه ازدحام و ضریب سرعت شناختی به ترتیب برابر ۲۰۰ و ۲ در نظر گرفته شده است. در جدول ۲، واضح است که محدوده MSE از ۰/۰۰۲۷ تا ۰/۰۰۹۶ برای آموزش و از ۰/۰۰۲۴ تا ۰/۰۰۹۷ برای تست به دست آمده است. مقادیر بیشینه و کمینه MSE برای مدل ANN-PSO به ترتیب برای

جدول ۳- دقت MSE برای مدل‌های متفاوت ANN-PSO برای فاز آموزش و آزمون

ورودی‌ها	اندازه ازدحام			ضریب شناختی		ضریب اجتماعی	
	۲۰۰	۳۰۰	۴۰۰	۲	۲/۵	۲	۲/۵
ورودی ۱							
آموزش	۰/۰۰۶۵	۰/۰۰۶۲	۰/۰۰۶۵	۰/۰۰۶۳	۰/۰۰۶۷	۰/۰۰۶۷	۰/۰۰۶۴
آزمایش	۰/۰۰۶۵	۰/۰۰۷۸	۰/۰۰۷۴	۰/۰۰۷۳	۰/۰۰۷۹	۰/۰۰۷۰	۰/۰۰۶۷
ورودی ۲							
آموزش	۰/۰۰۳۵	۰/۰۰۳۵	۰/۰۰۳۳	۰/۰۰۲۷	۰/۰۰۳۸	۰/۰۰۳۶	۰/۰۰۳۳
آزمایش	۰/۰۰۷۹	۰/۰۰۷۲	۰/۰۰۶۸	۰/۰۰۹۷	۰/۰۰۸۶	۰/۰۰۶۶	۰/۰۰۷۳
ورودی ۳							
آموزش	۰/۰۵۵	۰/۰۰۴۷	۰/۰۰۴۳	۰/۰۰۵۲	۰/۰۰۵۲	۰/۰۰۵۳	۰/۰۰۵۰
آزمایش	۰/۰۰۳۰	۰/۰۰۳۵	۰/۰۰۲۵	۰/۰۰۲۴	۰/۰۰۲۶	۰/۰۰۳۰	۰/۰۰۲۹
ورودی ۴							
آموزش	۰/۰۰۳۸	۰/۰۰۴۹	۰/۰۰۲۷	۰/۰۰۵۸	۰/۰۰۴۶	۰/۰۰۴۲	۰/۰۰۴۴
آزمایش	۰/۰۰۴۴	۰/۰۰۴۷	۰/۰۰۴۲	۰/۰۰۵۶	۰/۰۰۵۳	۰/۰۰۵۳	۰/۰۰۵۳

ورودی ۲ ( $Q_{i-t}$  و  $Q_{r-t-1}$ ،  $Q_{p-t-1}$ ،  $Q_{in-t}$ ،  $GWL_{t-2}$ ،  $GWL_{t-1}$ ) و  $Q_{i-t}$  و  $Q_{r-t-1}$  و  $Q_{p-t-1}$  و  $Q_{in-t}$  و  $GWL_{t-2}$ ،  $GWL_{t-1}$ ) و  $Q_{w-t-1}$  و  $Q_{out-t-1}$ ،  $GWL_{t-2}$ ،  $GWL_{t-1}$ ) و  $Q_{e-t-1}$  (برای فاز آزمون به دست آمده است. این نشان می‌دهد که خطای مدل ANN-PSO برای داده‌های ورودی آبخوان نسبت به دیگر شرایط بیشتر می‌شود.

۱) بهترین دقت در فاز آزمون را نشان می‌دهد.

**شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی کلونی مورچگان:** تعداد متفاوت جمعیت، عامل تشدید و نرخ انحراف برای مدل‌های ANN-ACOR آزمایش شده است. کارایی مدل‌های ANN-ACOR در فاز آموزش و آزمون در جدول ۴ نشان داده شده است. برای تعداد جمعیت‌های ۲۰۰، ۳۰۰ و ۴۰۰، عامل تشدید و نرخ انحراف به ترتیب برابر ۰/۵ و ۱ در نظر گرفته شده است. برای عامل تشدید ۰/۴، ۰/۵ و ۰/۶، تعداد جمعیت و نرخ انحراف به ترتیب برابر ۲۰۰ و ۱ انتخاب شده است. برای نرخ انحراف ۰/۸، ۰/۹ و ۱، تعداد جمعیت و عامل تشدید به ترتیب ۲۰۰ و ۰/۵ در نظر گرفته شده است. در جدول ۴، محدوده MSE از ۰/۰۰۷۱ تا ۰/۱۵۲۱ برای فاز آموزش و از ۰/۰۰۴۴ تا ۰/۱۴۱۲ برای آزمون مشاهده شده است. بیشینه مقدار MSE برای مدل ANN-ACOR برای ترکیب

**شبکه عصبی مصنوعی با الگوریتم رقابت استعماری:** تعداد متفاوت کشورها، ضریب جذب و نرخ انقلاب برای مدل‌های ANN-ICA آزمایش شده است. کارایی مدل‌های ANN-ICA در فاز آموزش و تست در جدول ۳ نشان داده شده است. برای تعداد کشورهای ۲۰۰، ۳۰۰ و ۴۰۰، ضریب جذب و نرخ انقلاب به ترتیب برابر ۲ و ۰/۳ در نظر گرفته شده است. برای ضریب جذب ۲، ۲/۵ و ۳، تعداد کشورها و نرخ انقلاب به ترتیب برابر ۲۰۰ و ۰/۳ انتخاب شده است. برای نرخ انقلاب ۰/۳، ۰/۴ و ۰/۵، تعداد کشورها و ضریب جذب به ترتیب ۲۰۰ و ۲ در نظر گرفته شده است. در جدول ۳، محدوده MSE از ۰/۰۰۲۳ تا ۰/۰۱۷۳ برای فاز آموزش و از ۰/۰۰۳۸ تا ۰/۰۲۹۸ برای آزمون مشاهده شده است. بیشینه مقدار MSE برای مدل ANN-ICA برای ترکیب ورودی ۴ ( $GWL_{t-1}$ ،  $Q_{i-t}$ ،  $Q_{r-t-1}$ ،  $Q_{p-t-1}$ ،  $Q_{in-t}$ ،  $GWL_{t-2}$ ،  $GWL_{t-1}$  و  $Q_{w-t-1}$ ،  $Q_{out-t-1}$ ،  $Q_{i-t}$ ،  $Q_{r-t-1}$ ،  $Q_{p-t-1}$ ،  $Q_{in-t}$ ،  $GWL_{t-2}$ ،  $GWL_{t-1}$ ) به دست آمده، در حالی که مدل با ترکیب

ورودی ۴  $(Q_{i,t-1}, Q_{r,t-1}, Q_{p,t-1}, Q_{in,t}, GWL_{t-2}, GWL_{t-1})$  مدل با ترکیب ورودی ۱  $(GWL_{t-2}, GWL_{t-1})$  دارای بهترین دقت در فاز آزمون را نشان می‌دهد.

جدول ۴- دقت MSE برای مدل‌های متفاوت ANN-ICA در فاز آموزش و آزمون

ورودی‌ها	تعداد کشورها			ضریب جذب		نرخ انقلاب		
	۲۰۰	۳۰۰	۴۰۰	۲/۵	۳	۰/۳	۰/۴	۰/۵
ورودی ۱								
آموزش	۰/۰۰۶۷	۰/۰۰۶۸	۰/۰۰۶۶	۰/۰۰۶۷	۰/۰۰۶۸	۰/۰۰۶۶	۰/۰۰۶۷	۰/۰۰۶۷
آزمایش	۰/۰۰۷۴	۰/۰۰۵۸	۰/۰۰۶۱	۰/۰۰۷۵	۰/۰۰۸۲	<u>۰/۰۰۵۳</u>	۰/۰۰۷۶	۰/۰۰۶۳
ورودی ۲								
آموزش	۰/۰۰۵۸	۰/۰۰۸۳	۰/۰۰۶۶	۰/۰۰۷۶	۰/۰۰۹۸	۰/۰۰۵۵	۰/۰۰۶۶	۰/۰۰۶۰
آزمایش	۰/۰۰۴۳	۰/۰۰۵۰	۰/۰۰۵۸	۰/۰۲۴۲	۰/۰۰۸۰	<u>۰/۰۰۳۸</u>	۰/۰۰۸۱	۰/۰۰۶۰
ورودی ۳								
آموزش	۰/۰۰۳۵	۰/۰۰۴۰	۰/۰۰۳۳	۰/۰۰۲۳	۰/۰۰۴۸	۰/۰۰۳۶	۰/۰۰۵۳	۰/۰۰۳۴
آزمایش	۰/۰۱۲۷	۰/۰۱۴۴	<u>۰/۰۰۸۹</u>	۰/۰۱۳۶	۰/۰۱۳۸	۰/۰۱۲۹	۰/۰۱۱۸	۰/۰۱۷۷
ورودی ۴								
آموزش	۰/۰۰۸۴	۰/۰۱۳۰	۰/۰۰۹۰	۰/۰۱۷۳	۰/۰۱۰۷	۰/۰۱۶۶	۰/۰۱۲۳	۰/۰۰۷۱
آزمایش	۰/۰۱۸۹	۰/۰۲۰۲	۰/۰۲۹۸	۰/۰۲۲۲	۰/۰۲۳۹	۰/۰۲۱۱	۰/۰۳۰۰	<u>۰/۰۱۱۰</u>

جدول ۵- دقت MSE برای مدل‌های متفاوت ANN-ACOR در فاز آموزش و تست

ورودی‌ها	اندازه جمعیت			عامل تشدید		نرخ انحراف		
	۲۰۰	۳۰۰	۴۰۰	۰/۴	۰/۵	۰/۶	۰/۸	۰/۹
ورودی ۱								
آموزش	۰/۰۰۷۱	۰/۰۰۹۴	۰/۰۰۹۰	۰/۰۰۸۶	۰/۰۱۰۰	۰/۰۰۹۷	۰/۰۱۰۸	۰/۰۰۹۳
آزمایش	<u>۰/۰۰۴۴</u>	۰/۰۰۶۳	۰/۰۰۵۸	۰/۰۰۶۹	۰/۰۰۷۷	۰/۰۰۷۶	۰/۰۰۶۴	۰/۰۰۸۱
ورودی ۲								
آموزش	۰/۰۱۷۶	۰/۰۳۲۵	۰/۰۳۷۷	۰/۰۳۸۳	۰/۰۳۰۰	۰/۰۱۹۵	۰/۰۳۳۹	۰/۰۲۲۳
آزمایش	۰/۰۳۲۶	۰/۰۳۱۰	۰/۰۵۱۱	۰/۰۷۱۱	۰/۰۲۹۵	<u>۰/۰۱۵۸</u>	۰/۰۲۹۷	۰/۰۴۳۴
ورودی ۳								
آموزش	۰/۰۳۲۳	۰/۰۲۷۰	۰/۰۱۷۲	۰/۰۱۴۳	۰/۰۳۴۹	۰/۰۲۱۴	۰/۰۲۵۴	۰/۰۱۴۳
آزمایش	۰/۰۲۹۰	۰/۰۱۹۱	۰/۰۲۸۲	۰/۰۱۹۰	۰/۰۴۸۰	<u>۰/۰۱۸۷</u>	۰/۰۳۰۰	۰/۰۲۰۰
ورودی ۴								
آموزش	۰/۰۸۸۸	۰/۰۷۴۰	۰/۰۶۷۶	۰/۱۵۲۱	۰/۰۵۱۴	۰/۱۲۶۹	۰/۰۵۷۱	۰/۰۸۴۷
آزمایش	۰/۰۹۶۰	۰/۰۵۷۰	۰/۰۶۹۵	۰/۱۷۸۷	<u>۰/۰۳۸۲</u>	۰/۰۴۲۳	۰/۰۴۷۸	۰/۰۹۳۴

مدل‌ها تخمین مناسبی برای داده‌های GWL داشته‌اند.

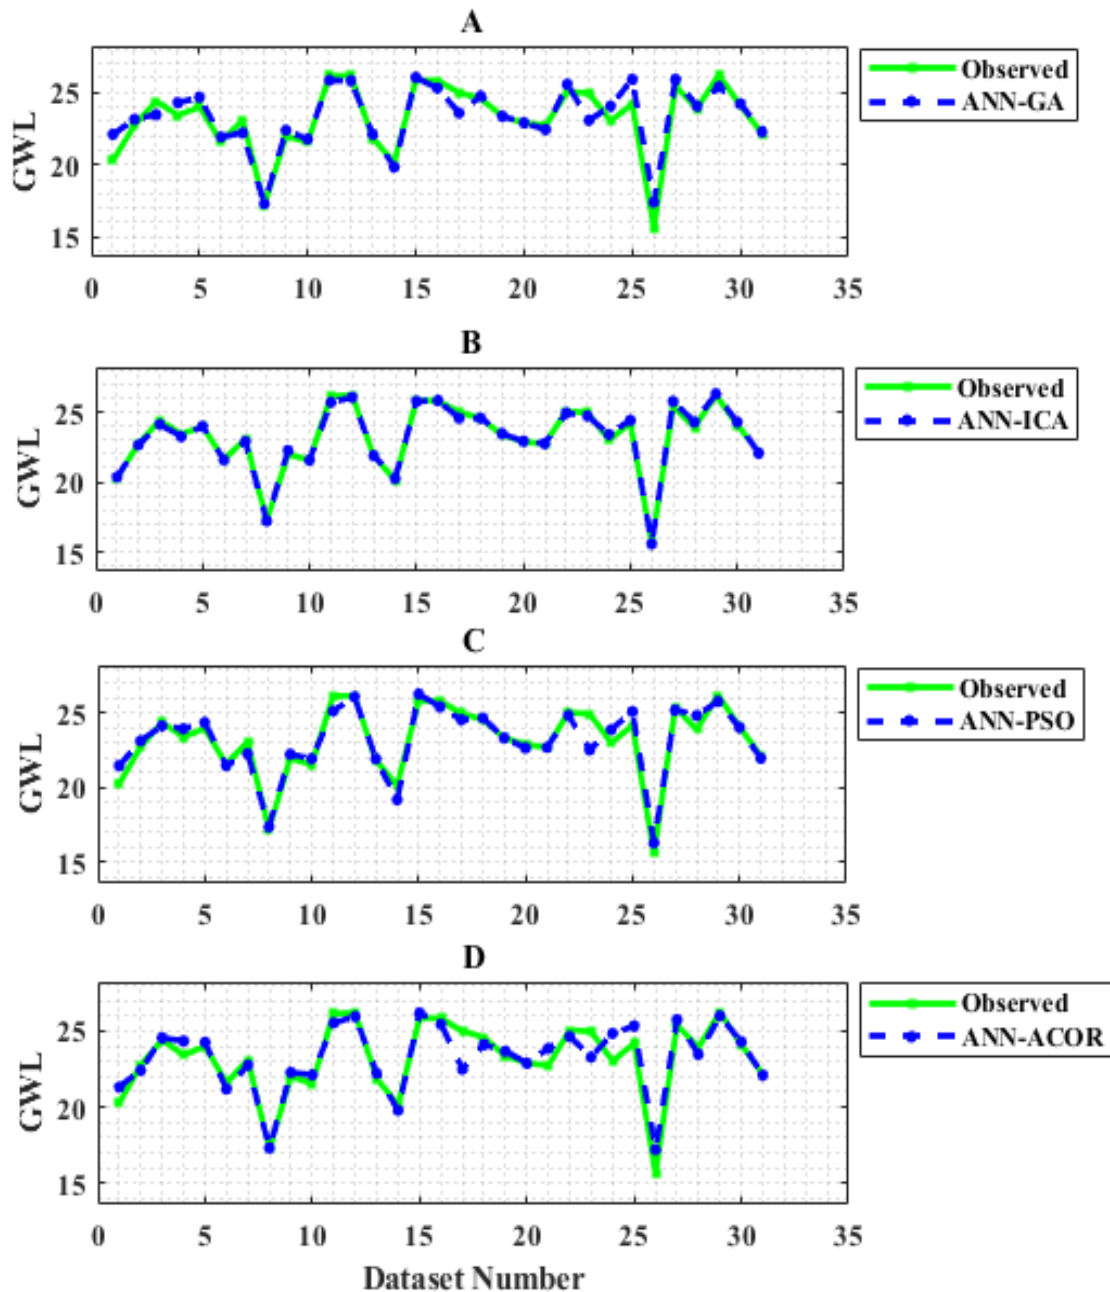
پراکندگی نقاط شبیه‌سازی شده در شکل ۶ نشان داده شده است. ضریب اطمینان برای مدل‌های ANN-GA، ANN-ICA، ANN-PSO و ANN-ACOR در فاز آموزش به ترتیب برابر ۰/۸۸۲۲۵، ۰/۹۹۳۰۸، ۰/۹۱۹۷۹ و ۰/۸۷۹۰۷ است. ضرایب اطمینان به دست آمده برای مدل‌ها نشان‌دهنده دقت بالای آن‌ها برای

در نهایت، ترکیب ورودی ۴  $(GWL_{t-2}, GWL_{t-1})$  مقایسه چهار روش به دلیل غنی‌تر بودن ترکیب آن انتخاب شده است. نمودارهای تناوب زمانی از مقادیر GWL مشاهده شده و شبیه‌سازی شده به وسیله مدل‌های ANN-PSO، ANN-ICA، ANN-GA و ANN-ACOR در دوره آموزش در شکل ۵ نشان داده شده است. با مشاهده شکل‌ها می‌توان دریافت همه

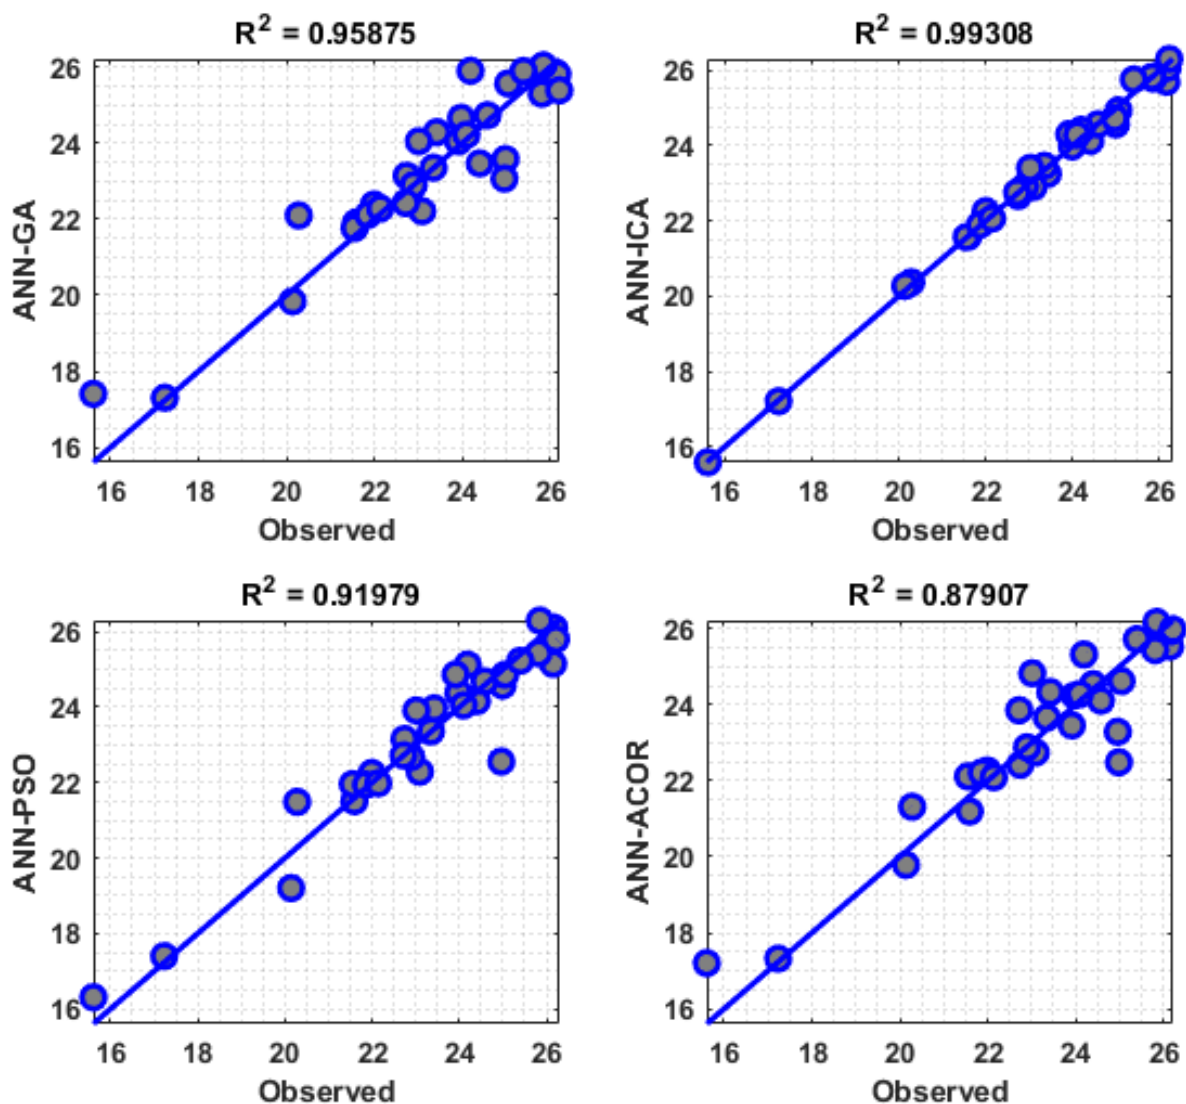
می‌دهد. اگرچه همه چهار مدل دارای تخمین مناسبی هستند، با این حال مدل ANN-GA عملکرد بهتری نسبت به مدل‌های ANN-PSO، ANN-ICA و ANN-ACOR در جذب بعضی از مقادیر قله‌ای داشته است.

تخمین تغییرات سطح آب زیرزمینی است. البته برای نتیجه‌گیری کلی از نتایج داده‌های آزمایش استفاده شد.

شکل ۷، تخمین مدل‌ها را در فاز آزمایش نشان



شکل ۵- نمودارهای تناوب زمانی از مقادیر GWL مشاهده‌شده و شبیه‌سازی شده بوسیله مدل‌های ANN-GA، ANN-ICA، ANN-PSO و ANN-ACOR در دوره آموزش



شکل ۶- پراکندگی نقاط شبیه‌سازی شده برای دوره آموزش

است. همچنین، درصد میانگین خطای نسبی مدل ANN-GA برابر ۳/۶۴۲۷ درصد است که خطای بسیار کمی را نشان می‌دهد.


مزایای الگوریتم ژنتیک عبارت‌اند از: (۱) ماهیت جستجوی تصادفی این الگوریتم در فضای مسئله، به نوعی یک جستجوی موازی محسوب می‌شود. زیرا هر کدام از کروموزوم‌های تصادفی تولیدشده به وسیله الگوریتم، یک نقطه شروع جدید برای جستجوی بخشی از فضای حالت مسئله به حساب آمده و جستجو در تمام آن‌ها به شکل هم‌زمان صورت می‌گیرد. (۲) به دلیل وسعت و پراکندگی نقاطی که مورد جستجو قرار می‌گیرند، در مسائلی که فضای جستجوی بزرگی داشته باشند، نتیجه مطلوبی کسب

تخمین‌های مدل‌های به کار برده شده در فاز آزمایش، در شکل ۸ به صورت پراکندگی نقاط نشان داده شده است. با مشاهده شکل می‌توان دریافت که مدل ANN-GA دارای ضریب تعیین بالاتری برابر ۹۳۸۷۹ درصد و عملکرد بهتری نسبت به دیگر مدل‌ها داشته است.


عملکرد چهار مدل شبکه عصبی تکاملی در تخمین سطح آب زیرزمینی در جدول ۶، مشخص شده است. با مشاهده نتایج می‌توان دریافت که مدل شبکه عصبی تکاملی با الگوریتم ژنتیک توانسته نماینده مناسبی برای تخمین سطح آب زیرزمینی باشد. میانگین مربعات خطا برای مدل ANN-GA برابر ۰/۶۹۴۸ در فاز آموزش و ۰/۸۷۳۹ در فاز آزمایش

از میان جمعیت، با احتمال بالایی به نقطه بهینه سراسری دست پیدا خواهد کرد. (۵) پیاده‌سازی آن ساده بوده و نیازی به روال‌های پیچیده حل مسئله ندارد. می‌توان گفت که این الگوریتم ممکن است یک کاندید خوب برای مدل‌سازی هیدرولوژیکی باشد.

می‌کند. (۳) نوعی جستجوی تصادفی هدفمند محسوب شده، از مسیرهای مختلف به جواب‌های متفاوتی خواهد رسید. علاوه بر آن، با هیچ محدودیتی در مسیر جستجو و انتخاب پاسخ‌های تصادفی روبرو نیست. (۴) به دلیل رقابت (تنازع بقاع) پاسخ‌ها و انتخاب بهترین‌ها



شکل ۷- نمودارهای تناوب زمانی از مقادیر GWL مشاهده‌شده و شبیه‌سازی شده به‌وسیله مدل‌های ANN-GA، ANN-ICA، ANN-PSO و ANN-ACOR در دوره آزمایش



شکل ۸- پراکندگی نقاط مشاهده‌شده و تخمین زده شده برای مدل‌ها در فاز آزمایش

جدول ۶- مقایسه عملکرد چهار مدل ارائه‌شده برای تخمین سطح آب زیرزمینی

مدل	ضریب تعیین ( $R^2$ )		میانگین مربعات خطا (MSE)		درصد میانگین خطای نسبی (MRE)	
	آموزش	آزمایش	آموزش	آزمایش	آموزش	آزمایش
ANN-GA	۰/۹۵۸۷	۰/۹۳۸۸	۰/۶۹۴۸	۰/۸۷۳۹	۲/۷۳۷۷	۳/۶۴۲۷
ANN-ICA	۰/۹۹۳۱	۰/۹۳۳۸	۰/۰۴۰۸	۰/۹۴۵۶	۰/۶۲۴۶	۴/۱۷۳۴
ANN-PSO	۰/۹۱۹۸	۰/۹۱۴۵	۰/۴۷۳۳	۱/۲۲۰۸	۲/۱۲۷۲	۴/۳۶۴۳
ANN-ACOR	۰/۸۷۹۱	۰/۸۷۵۹	۰/۷۱۳۵	۱/۷۷۲۰	۲/۷۰۴۵	۴/۸۹۶۴

### نتیجه‌گیری

این مطالعه به بررسی توانایی چهار روش شبکه عصبی تکاملی متفاوت در تخمین سطح آب زیرزمینی دشت عباس پرداخته است. داده‌های سطح آب زیرزمینی بر طبق جریان ورودی زیرزمینی، نفوذ موثر

از بارندگی، نفوذ موثر از جریان سطحی و سیلاب، نفوذ موثر از آب برگشتی کشاورزی، جریان خروجی زیرزمینی، برداشت از آبخوان برای کشاورزی، تبخیر از سطح آب زیرزمینی و داده‌های گذشته سطح آب زیرزمینی به‌عنوان ورودی مدل‌ها مورد استفاده قرار



تخمین تغییرات سطح آب زیرزمینی از جمله الگوریتم ژنتیک (Dash و همکاران، ۲۰۱۰؛ Jalakamali و Jalakamali، ۲۰۱۱)، الگوریتم رقابت استعماری (Tahershamsi و Sheikholeslami، ۲۰۱۱)، بهینه‌سازی ازدحام ذرات (Xi و همکاران، ۲۰۱۲؛ Gaur و همکاران، ۲۰۱۳) و مقایسه این روش‌ها با هم (Kisi و همکاران، ۲۰۱۷) استفاده کرده‌اند. در این پژوهش، علاوه بر مدل‌های فوق از مدل ANN-ACOR نیز استفاده شده است. مقایسه نتایج نشان می‌دهد که مدل ANN-GA عملکرد بهتری نسبت به سه مدل دیگر برای تخمین سطح آب زیرزمینی دارد که با نتایج Kisi (۲۰۱۷) و Gaur (۲۰۱۲) مغایرت داشته و با تحقیقات Jalakamali (۲۰۱۱) و Dash (۲۰۱۰) مطابقت دارد.

گرفته است. چهار ترکیب متفاوت ورودی بر طبق تحلیل همبستگی تعیین شده است. پارامترهای کنترلی متفاوتی برای مدل‌ها به کار برده شده است و آن‌ها را بر طبق میانگین مربع خطا، میانگین خطای نسبی و ضریب تعیین مورد مقایسه قرار داده‌ایم. همه چهار مدل، ANN-ICA، ANN-PSO، ANN-GA و ANN-ACOR، برای ترکیب ورودی  $(GWL_{t-1})$  و  $(Q_{e,t-1})$  بهترین دقت را نشان می‌دهند. برای آموزش مدل‌های شبکه عصبی برای تخمین سطح آب زیرزمینی از الگوریتم‌های متفاوتی استفاده شده است. بیشتر روش‌های مرسوم برای آموزش شبکه‌های عصبی از گرادیان نزولی با استفاده از انتشار به عقب برای محاسبه گرادیان واقعی استفاده می‌کنند. در سال‌های اخیر، برخی از محققین از تکنیک‌های تکاملی برای

#### منابع مورد استفاده

1. Abd-Elazim, S.M. and E.S. Ali. 2016. Imperialist competitive algorithm for optimal STATCOM design in a multimachine power system. *International Journal of Electrical Power and Energy Systems*, 76 pages.
2. Acharya, N., N.A. Shrivastava, B.K. Panigrahi and U.C. Mohanty. 2014. Development of an artificial neural network based multi-model ensemble to estimate the northeast monsoon rainfall over south peninsular India: an application of extreme learning machine. *Climate Dynamics*, 43(5-6): 1303-1310.
3. Adamowski, J. and H.F. Chan. 2011. A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(1-4): 28-40.
4. Affandi, A.K. and K. Watanabe. 2007. Daily groundwater level fluctuation forecasting using soft computing technique. *Nature and Science*, 5(2): 1-10.
5. Amiri, M., J. Ghiasi-Freez, B. Golkar and A. Hatampour. 2015. Improving water saturation estimation in a tight shaly sandstone reservoir using artificial neural network optimized by imperialist competitive algorithm, a case study. *Journal of Petroleum Science and Engineering*, 127: 347-358.
6. Atashpaz-Gargari, E. and C. Lucas. 2007. Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. In *Evolutionary Computation, CEC 2007, IEEE Congress on Evolutionary Computation*, pages 4661-4667.
7. Alizadeh, A. 2001. Principles of applied hydrology. Astan Quds Razavi, Mashhad, 808 pages (in Persian).
8. Basheer, I.A. and M. Hajmeer. 2000. Artificial neural networks: fundamentals, computing, design and application. *Journal of Microbiological Methods*, 43(1): 3-31.
9. Bhattacharyya, S. and P.C. Pendharkar. 1998. Inductive, evolutionary and neural computing techniques for discrimination: a comparative study. *Decision Sciences*, 29(4): 871-899.
10. Chau, K.W. 2006. Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River. *Journal of Hydrology*, 329(3-4): 363-367.
11. Daliakopoulos, I.N., P. Coulibaly and I.K. Tsanis. 2005. Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*, 309(1-4): 229-240.
12. Dash, N.B., S.N. Panda, R. Remesan and N. Sahoo. 2010. Hybrid neural modeling for groundwater level prediction. *Neural Computing and Applications*, 19(8): 1251-1263.
13. Dorigo, M. and L.M. Gambardella. 1997. Ant colony system: a cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, 1(1): 53-66.
14. Dorigo, M., M. Birattari and T. Stutzle. 2006. Artificial ants as a computational intelligence technique. *IEEE Computational Intelligence Magazine*, 1: 28-39.

15. Eberhart, R.C. and Y. Shi. 1998. Comparison between genetic algorithms and particle swarm optimization. In International Conference on Evolutionary Programming, Springer, Berlin, Heidelberg, pages 611-616.
16. Gaur, S., Ch.S.D. Graillot, B.R. Chahar and D.N. Kumar. 2013. Application of artificial neural networks and particle swarm optimization for the management of groundwater resources. *Water Resources Management*, 27(3): 927-941.
17. Ghaedi, M., A.M. Ghaedi, E. Negintaji, A. Ansari and F. Mohammadi. 2014. Artificial neural network-imperialist competitive algorithm based optimization for removal of sunset yellow using Zn(OH)<sub>2</sub> nanoparticles-activated carbon. *Journal of Industrial and Engineering Chemistry*, 20(6): 4332-4343
18. Hou, L., X.S. Wang, B.X. Hu, J. Shang and L. Wan. 2016. Experimental and numerical investigations of soil water balance at the hinterland of the Badain Jaran Desert for groundwater recharge estimation. *Journal of Hydrology*, 540: 386-396.
19. Iwalewa, T.M., A.S. Elamin and S.I. Kaka. 2016. A coupled model simulation assessment of shallow water-table rise in a Saudi Arabian coastal city. *Journal of Hydro-Environment Research*, 12: 46-58.
20. Jalalkamali, A. and N. Jalalkamali. 2011. Groundwater modeling using hybrid of artificial neural network with genetic algorithm. *African Journal of Agricultural Research*, 6(26): 5775-5784.
21. Khalil, B., S. Broda, J. Adamowski, B. Ozga-Zielinski and A. Donohoe. 2015. Short-term forecasting of groundwater levels under conditions of mine-tailings recharge using wavelet ensemble neural network models. *Hydrogeology Journal*, 23(1): 121-141.
22. Kişi, Ö. 2007. Streamflow forecasting using different artificial neural network algorithms. *Journal of Hydrologic Engineering*, 12(5): 532-539.
23. Kisi, O., H. Sanikhani, M. Zounemat-Kermani and F. Niazi. 2015. Long-term monthly evapotranspiration modeling by several data-driven methods without climatic data. *Computers and Electronics in Agriculture*, 115: 66-77.
24. Kisi, O., M. Tombul and M.Z. Kermani. 2015. Modeling soil temperatures at different depths by using three different neural computing techniques. *Theoretical and Applied Climatology*, 121(1-2): 377-387.
25. Kisi, O., M. Alizamir and M. Zounemat-Kermani. 2017. Modeling groundwater fluctuations by three different evolutionary neural network techniques using hydroclimatic data. *Natural Hazards*, 87(1): 367-381.
26. Kuo, R.J., C.H. Chen and Y.C. Hwang. 2001. An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network. *Fuzzy Sets and Systems*, 118(1): 21-45.
27. Mohanty, S., M.K. Jha, S.K. Raul, R.K. Panda and K.P. Sudheer. 2015. Using artificial neural network approach for simultaneous forecasting of weekly groundwater levels at multiple sites. *Water Resources Management*, 29(15): 5521-5532.
28. Mukherjee, I. and S. Routroy. 2012. Comparing the performance of neural networks developed by using Levenberg-Marquardt and Quasi-Newton with the gradient descent algorithm for modelling a multiple response grinding process. *Expert Systems with Applications*, 39(3): 2397-2407.
29. Nayak, P.C., K.P. Sudheer, D.M. Rangan and K.S. Ramasastri. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291(1-2): 52-66.
30. Nayak, P.C., Y.S. Rao and K.P. Sudheer. 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resources Management*, 20(1): 77-90.
31. Nazari-Shirkouhi, S., H. Eivazy, R. Ghodsi, K. Rezaie and E. Atashpaz-Gargari. 2010. Solving the integrated product mix-outsourcing problem using the imperialist competitive algorithm. *Expert Systems with Applications*, 37(12): 7615-7626.
32. Samani, N., M. Gohari-Moghadam and A.A. Safavi. 2007. A simple neural network model for the determination of aquifer parameters. *Journal of Hydrology*, 340(1-2): 1-11.
33. Shen, Q., J.H. Jiang, J.C. Tao, G.L. Shen and R.Q. Yu. 2005. Modified ant colony optimization algorithm for variable selection in QSAR modeling: QSAR studies of cyclooxygenase inhibitors. *Journal of Chemical Information and Modeling*, 45(4): 1024-1029.
34. Socha, K. and M. Dorigo. 2008. Ant colony optimization for continuous domains. *European Journal of Operational Research*, 185(3): 1155-1173.
35. Shen, C., L. Wang and Q. Li. 2007. Optimization of injection molding process parameters using combination of artificial neural network and genetic algorithm method. *Journal of Materials Processing Technology*, 183(2-3): 412-418.
36. Sun, Y., D. Wendi, D.E. Kim and S.Y. Liang. 2016. Application of artificial neural networks in groundwater table forecasting, a case study in a Singapore swamp forest. *Hydrology and Earth System Sciences*, 20(4): 1405-1412.

37. Toksarı, M.D. 2007. Ant colony optimization approach to estimate energy demand of Turkey. *Energy Policy*, 35(8): 3984-3990.
38. Tahershamsi, A. and R. Sheikholeslami. 2011. Optimization to identify Muskingum model parameters using imperialist competitive algorithm. *Iran University of Science and Technology*, 1(3): 475-484.
39. Wong, F.S. 1991. Time series forecasting using backpropagation neural networks. *Neurocomputing*, 2(4): 147-159.
40. Xi, Z., Y. Zhang and C. Zhu. 2012. Application of PSO-neural network model in prediction of groundwater level in Handan City. *International Journal on Advances in Information Sciences and Service Sciences*, 4(6): 177-183.
41. Yoon, H., S.C. Jun, Y. Hyun, G.O. Bae and K.K. Lee. 2011. A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, 396(1-2): 128-138.
42. Zeng, X., M. Ye, J. Burkardt, J. Wu, D. Wang and X. Zhu. 2016. Evaluating two sparse grid surrogates and two adaptation criteria for groundwater Bayesian uncertainty quantification. *Journal of Hydrology*, 535: 120-134.
43. Zounemat-Kermani, M. 2012. Hourly predictive Levenberg–Marquardt ANN and multi linear regression models for predicting of dew point temperature. *Meteorology and Atmospheric Physics*, 117(3-4): 181-192.
44. Zounemat-Kermani, M., O. Kisi and T. Rajaei. 2013. Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff. *Applied Soft Computing*, 13(12): 4633-4644.