

تخمین تغییرات آب زیرزمینی با استفاده از چهار تکنیک متفاوت شبکه عصبی تکاملی و داده‌های آب و هواشناسی (مطالعه موردی دشت عباس، استان ایلام)

شهلا پایمذد^۱، محمد رضا رضایی^۲، محمد جواد رضایی^۳، جعفر رضایی^۴

تاریخ پذیرش: ۱۳۹۷/۱۱/۱

تاریخ دریافت: ۱۳۹۷/۶/۲۴

چکیده

در نواحی خشک و نیمه‌خشک، به دلیل کمبود جریان‌های سطحی، فشار عمدۀ بر آب‌های زیرزمینی وارد می‌شود. سطح منابع آب زیرزمینی محدوده مورد مطالعه (دشت عباس) نیز به دلیل استفاده‌بی‌رویه، دچار افت شدید شده و بیش از ۳۰ سال است که به عنوان دشت ممنوعه اعلام گردیده است. در این تحقیق، از چهار مدل متفاوت شبکه عصبی تکاملی شامل شبکه عصبی پرسپترون چندلایه با الگوریتم ژنتیک (ANN-GA)، بهینه‌سازی ازدحام ذرات (ANN-PSO)، الگوریتم رقابت استعماری (ANN-ICA) و بهینه‌سازی کلونی مورچگان (ANN-ACOR) برای تخمین سطح آب زیرزمینی استفاده شده است. داده‌های مورد استفاده شامل بارش، تبخیر، متوسط دمای سالانه، نفوذ مؤثر و داده‌های گذشته سطح آب زیرزمینی برای یک دوره ۲۲ ساله است. 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 مدل‌های ارائه شده برای ANN-PSO، ANN-ICA و ANN-GA به ترتیب 33% ، 39% و 44% به دست آمده است. دقت میانگین مربع خطای مدل‌های ANN-ACOR و ANN-GWL_{t-1} به ترتیب 0.0039 و 0.0044 و برای مدل ANN-GA 0.0030 به دست آمده است. روند تغییرات سطح آب زیرزمینی دشت در مقطع زمانی ۷۲ تا ۸۴ روند کاهشی و از سال ۸۵ تا ۹۴ با ورود آب سد کرخه، روند افزایشی داشته و بیلان آب دشت مثبت شده 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: آب زیرزمینی، ازدحام ذرات، الگوریتم ژنتیک، رقابت استعماری، شبکه‌های عصبی، کلونی مورچگان.

۱. استادیار گروه مهندسی آب، دانشگاه اراک، نویسنده مسئول؛ paimozd.ar@hotmail.com

۲. کارشناس ارشد گروه مهندسی آب، دانشگاه اراک

۳. کارشناس ارشد گروه مهندسی کامپیوتر دانشگاه آزاد کرمانشاه

۴. عضو هیئت‌علمی مرکز تحقیقات کشاورزی و منابع طبیعی استان ایلام

مقدمه

تطبیقی و... است (زنگ^۵ و همکاران، ۲۰۱۶). امتیاز قابل توجه تکنیک‌های محاسبات نرم در مدل‌سازی سیستم‌ها این است که نیازی به یک رابطهٔ فیزیکی خوش‌تعریف برای تبدیل یک ورودی به یک خروجی ندارند (نایاک و همکاران، ۲۰۰۴). در بین انواع مختلف رویکردهای محاسبات نرم، از مدل‌های شبکهٔ عصبی مصنوعی به طور مطلوب برای شبیه‌سازی هیدرولوژی غیرخطی از قبیل بارندگی (آچاریا^۶ و همکاران، ۲۰۱۴)، تبخیر تعرق (کیسی^۷ و همکاران، ۲۰۱۵^a) استفاده شده است.

تا به امروز، برخی از محققان، از شبکهٔ عصبی برای مدل‌سازی تغییرات آب زیرزمینی استفاده کردند (دالیاکوپولوس و همکاران، ۲۰۰۵؛ داش و همکاران، ۲۰۱۰؛ آداماووسکی و چان^۸، ۲۰۱۱؛ طاهرشمسی و شیخ‌الاسلامی، ۲۰۱۱؛ خلیلی و همکاران، ۲۰۱۵). بیشتر این مطالعات اشاره کردند که شبکهٔ عصبی مصنوعی (به عنوان مدل غیرخطی) ساده‌تر و سریع‌تر برای توسعه بوده 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 کوتاه‌مدت قابل اطمینان باشند. در مطالعهٔ دیگر، موهنتی و همکاران (۲۰۱۵) نشان دادند که مدل شبکهٔ عصبی نتایج بهتری در زمان‌های کوتاه‌مدت نسبت به زمان‌های بلندمدت ارائه می‌دهد.

برای آموزش مدل‌های شبکهٔ عصبی برای پیش‌بینی سطح آب زیرزمینی، از الگوریتم‌های متفاوتی می‌توان استفاده کرد. بیشتر روش‌های مرسوم برای آموزش شبکه‌های عصبی از گرادیان نزولی با استفاده از انتشار به عقب برای محاسبه گرادیان واقعی استفاده می‌شود (دالیاکوپولوس، ۲۰۰۵). در سال‌های اخیر، برخی از محققان از تکنیک‌های تکاملی برای مدل‌سازی تغییرات سطح آب زیرزمینی از جمله الگوریتم ژنتیک (داش و همکاران، ۲۰۱۰؛ جلال‌کمالی، ۲۰۱۱)، الگوریتم رقابت استعماری (طاهرشمسی و شیخ‌الاسلامی، ۲۰۱۱)، بهینه‌سازی از دحام (گور^۹ و همکاران، ۲۰۱۳؛ ری^{۱۰} و همکاران، ۲۰۱۲) و مقایسه این روش‌ها با هم (کیسی و همکاران، ۲۰۱۷) استفاده کرده‌اند.

یکی از منابع اصلی تأمین آب شرب کشاورزی و صنعتی، آب زیرزمینی است. شایان ذکر است که آب‌های زیرزمینی در برخی مناطق به عنوان منابع ذخیره در نظر گرفته می‌شوند، درحالی که در مناطق دیگر ممکن است از آن‌ها برای تأمین آب شرب به علت دسترس‌پذیری آن‌ها استفاده شود (نایاک^۱ و همکاران، ۲۰۰۶؛ دالیاکوپولوس^۲ و همکاران، ۲۰۰۵) تجزیه و تحلیل سطح آب زیرزمینی، عامل ضروری برای حفظ دسترسی آن است. مدل‌سازی و پیش‌بینی سطح آب زیرزمینی برای حفاظت از محیط‌زیست، حفظ کردن تعادل سیستم آب زیرزمینی، کنترل تغییرات سطح آب زیرزمینی و محافظت از تشدید نشت زمین اهمیت دارد. تکنیک‌ها و راه حل‌های مدیریت آب‌های زیرزمینی و اقدامات کنترلی توسط پژوهشگران و متخصصان برای مقابله با مشکلات درازمدت نشت زمین و حفاظت منابع آب زیرزمینی ارائه شده است (موهنتی^۳ و همکاران، ۲۰۱۵؛ افندي و واتانابي^۴، ۲۰۰۷). علاوه بر این، بعضی موضوعات از قبیل تخلیه منابع آب زیرزمینی، تناقض بین استفاده از آب‌های زیرزمینی و آب‌های سطحی و پتانسیل آبودگی آب‌های زیرزمینی می‌توانند به عنوان برخی نگرانی‌ها دسته‌بندی شوند که به مسائل مهمی تبدیل شده و در سطح حوضهٔ آبخوان گسترش پیدا کنند. 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 (نایاک و همکاران، ۲۰۰۶).

روش دیگر جایگزین برای شبیه‌سازی و پیش‌بینی تغییرات سطح آب زیرزمینی بر اساس تکنیک‌های مدل‌سازی سری‌زمانی (شامل مدل‌های خطی و غیرخطی) است. این تکنیک‌ها به داده‌های سری‌زمانی تغییرات سطح آب زیرزمینی (به طور معمول برای یک دوره طولانی) و احتمالاً برخی از متغیرهای ورودی مرتبط (مانند بارش) اشاره دارند. از روش‌های داده‌محور غیرخطی محبوب برای شبیه‌سازی آب زیرزمینی، رویکرد محاسبات نرم است که شامل شبکه‌های عصبی مصنوعی (ANNs)، شبکه‌های موجی، سیستم‌های استنتاج تطبیقی نورو فازی، رگرسیون بردار پشتیبان، روش همبستگی تصادفی شبکه

5. Zeng

6. Acharya

7. Kisi

8. Adamowski & Chan

9. Gaur

10. Xi

1. Nayak

2. Daliakopoulos

3. Mohanty

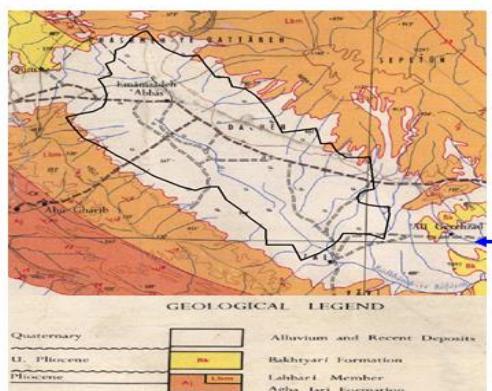
4. Affandi, Watanabe

زیرزمینی، بارش، تبخیر، متوسط دمای سالانه و نفوذ مؤثر بین سال‌های ۱۳۷۲ تا ۱۳۹۴ است. میانگین بارش این دشت در حدود ۲۵۲ میلی‌متر است که عمدتاً در فصل پاییز و زمستان رخ می‌دهد. از سال ۱۳۸۵۵ این دشت به وسیله کانال انتقال آب از سد کرخه به میزان ۳۰۰ میلیون مترمکعب در سال تغذیه می‌شود. شکل (۱) موقعیت مکانی دشت عباس را در ایران 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 توسط مدیران برای ارزیابی شرایط آب زیرزمینی فعلی و بلندمدت در دشت عباس مورد نیاز است.

با توجه به مطالعات انجام شده، مقاله مرتبط با مقایسه چهار شبکه عصبی تکاملی ANN-PSO، ANN-ICA، ANN-GA و ANN-ACOR برای تخمین سطح آب زیرزمینی انتشار نیافته است. هدف اصلی این مطالعه بررسی دقیق مدل‌های تخمین ماهانه سطح آب زیرزمینی با استفاده از بارش، تبخیر و داده‌های گذشته سطح آب زیرزمینی است.

مطالعه موردي

دشت عباس در استان ایلام در بخش جنوب غربی ایران در عرض جغرافیایی ۳۲° و طول جغرافیایی ۴۷° قرار گرفته است؛ مساحت این دشت با مقیاس ۱:۵۰۰۰۰ برابر ۳۸۲,۷۵ کیلومتر مربع است. داده‌های استفاده شده در این مطالعه، سطح آب



شکل (۱): موقعیت مکانی منطقه مورد مطالعه

Figure (1): Location of the studied area

۱. خروجی که داده‌ها را به خارج از شبکه ارسال می‌کنند؛
۲. نورون‌های ورودی که داده‌های خارجی را دریافت می‌کنند؛
۳. نورون‌های پنهان که نورون‌های لایه ورودی را به نورون‌های لایه خروجی متصل می‌کنند (سامانی و همکاران ۲۰۰۷؛ کرمانی و همکاران، ۲۰۱۲). هریک از نورون‌ها یک وزن ورودی، تابع انتقال و خروجی دارد. اساساً نورون‌ها بین ورودی‌ها و خروجی‌ها تعادل برقرار می‌کنند. در میان تمام ساختارهای شبکه‌های عصبی، پرسپترون چندلایه جلوسو

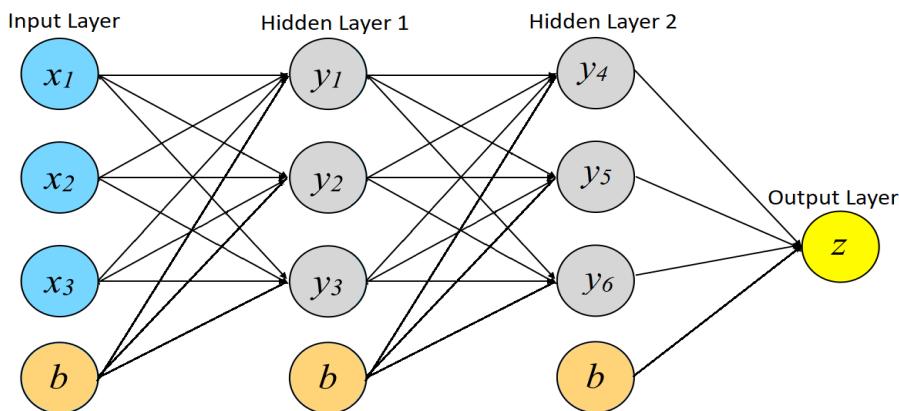
مواد و روش‌ها

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی مدل محاسباتی الهام‌گرفته شده از مغز انسان هستند که شامل واحدهای منفرد مختلف به هم متصل (نورون) با ضرایبی (وزن‌ها) که ساختار شبکه را تشکیل می‌دهند. نورون‌ها به عنوان واحدهای پردازش شناخته می‌شوند که اطلاعات را پردازش می‌کنند. سه نوع از نورون‌ها در شبکه‌های عصبی وجود دارد: ۱. نورون‌های

ژنتیک (GA)، بهینه‌سازی ازدحام ذرات (PSO)، الگوریتم رغابت 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.

(FF-MLP) به طور مرسوم به عنوان یک تخمین‌گر سراسری شناخته می‌شود (کیسی و همکاران، ۲۰۱۵b). شماتیک شبکه (FF-MLP) در شکل (۲) ارائه شده است. قوانین یادگیری متفاوت زیادی برای شبکه‌های عصبی جلوسو وجود دارد، اما اغلب از قوانین دلتا یا قوانین پس انتشار (BP) (کیسی و همکاران، ۲۰۰۷) پیروی می‌کنند. در مطالعات اخیر، الگوریتم



شکل (۲): شماتیک شبکه عصبی پرسپترون چندلایه

Figure (2): Multiple Layer Perceptron Neural Network Schematic

هریک 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. بر طبق معادلات ریاضی، ذره‌ها در اطراف فضای جستجو برای پیدا کردن جواب بهینه در حرکت‌اند. حرکات ذرات توسط خودشان هدایت می‌شوند که به آن بهترین موقعیت شناخته‌شده خودشان (P_{best}) می‌گویند و همچنین بهترین موقعیت شناخته‌شده کل ذرات بهترین ذره سراسری (g_{best}) خوانده می‌شود.

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 بیشتری را با استفاده از ارتباطات ساده و تکمیل آسان دارد.

الگوریتم رقابت استعماری (ICA)

الگوریتم رقابت استعماری الگوریتم بهینه‌سازی مبتنی بر جمعیت است که از مزایای سیاست مانند مفاهیم اجتماعی و فرهنگی در فرایند بهینه‌سازی استفاده کرده است. الگوریتم

الگوریتم‌های ژنتیک، الگوریتم‌هایی هستند که برای تقلید اصول تکامل زیستی در سیستم ژنتیک طبیعی طراحی شده‌اند. GA روش نمونه‌گیری تصادفی شناخته می‌شود. این الگوریتم می‌تواند به منظور شناسایی مسائل سخت در توابع هدف که ویژگی‌های پیچیده مانند چندمنظوره بودن، غیرمداوم بودن، غیرقابل تشخیص و... دارند، به کار برد. این الگوریتم‌ها یک جمعیت راه حل را مدیریت و دستکاری می‌کنند و جستجوی خود را برای راه حل‌های عملده در مورد «بقاء تاکتیک‌های مناسب» انجام می‌دهند. به طور کلی، پردازش الگوریتم ژنتیک به تعیین شش موضوع اساسی نیاز دارد: ۱. کروموزوم‌های نماینده؛ ۲. انتخاب تابع؛ ۳. عمل‌گرهای ژنتیک؛ ۴. ایجاد جمعیت اولیه؛ ۵. شرایط پایانی؛ ۶. تابع ارزیابی.

بهینه‌سازی ازدحام ذرات (PSO)

الگوریتم PSO رویکرد بهینه‌سازی تصادفی مبتنی بر شبیه‌سازی رفتار اجتماعی دسته‌ای از پرنده‌ها در یک گروه است. PSO روش جستجوی مبتنی بر جمعیت است که

$$MSE = \frac{1}{N} \sum_{i=1}^N (GWL_{i,0} - GWL_{i,e})^2 \quad (4)$$

N تعداد داده‌ها، $GWL_{i,0}$ سطح آب زیرزمینی مشاهده شده و $GWL_{i,e}$ بیانگر تخمین مدل است.

$$R^2 = 1 - \frac{\sum_{i=1}^N (GWL_{i,0} - GWL_{i,e})^2}{\sum_{i=1}^N (GWL_{i,0} - \bar{GWL}_{i,0})^2} \quad (5)$$

N تعداد داده‌ها، $GWL_{i,0}$ سطح آب زیرزمینی مشاهده شده و $GWL_{i,e}$ بیانگر تخمین مدل است.

قبل از استفاده از مدل‌های شبکه عصبی تکاملی، داده‌های ورودی نرمال‌سازی می‌شود. به این ترتیب که مقادیر بیشینه و کمینه داده‌ها در محدوده ۱-۰ قرار می‌گیرند. این نرمال‌سازی به واسنجی داده‌ها برای آموزش مدل کمک می‌کند. مقادیر سطح آب زیرزمینی، بارش، تبخیر، دمای متوسط سالانه و T_t , E_t , P_t , Pen_t بیان شده است. ترکیب ورودی‌های مختلف در جدول (۱) ذکر شده است. برای هر مدل شبکه عصبی، طبق پیشنهاد ونگ^۱ (۱۹۹۱) و باهاتاچاریا و پندارکر^۲ (۱۹۹۸) تعداد نودهای لایه پنهان برابر $2n$ (بیانگر تعداد داده‌های ورودی) و تعداد مراحل آموزش ۲۰۰ انتخاب شده است.

جدول (۱): ترکیب ورودی‌ها

Table (1): Combine inputs

ورودی	ترکیب
۱	$GWL_t = (GWL_{t-1}, GWL_{t-2})$
۲	$GWL_t = (GWL_{t-1}, GWL_{t-2}, P_t)$
۳	$GWL_t = (GWL_{t-1}, GWL_{t-2}, E_{t-4})$
۴	$GWL_t = (GWL_{t-1}, GWL_{t-2}, P_t, E_{t-4})$
۵	$GWL_t = (GWL_{t-1}, GWL_{t-2}, P_{t-1})$
۶	$GWL_t = (GWL_{t-1}, GWL_{t-2}, P_t, E_{t-4}, T_t, PEN_t)$

نتایج

آنالیز داده‌ها

آنالیز همبستگی برای تصمیم‌گیری درباره ترکیب داده‌های بهینه استفاده شده است. خودههمبستگی، خودههمبستگی جزئی و همبستگی متقابل برای داده سطح آب زیرزمینی، بارش، تبخیر، دمای متوسط سالانه و نفوذ مؤثر از تأخیر (۰-۱۰) و درصد محدوده اطمینان استفاده شده است

ICA در ابتدا توسط یک جمعیت اولیه، یعنی کشورهای امپریالیستی تنظیم شده است. هر کشور امپریالیستی شامل مستعمرات و کشورهای دیگر است (آتشپز گرگری و لوکاس^۳، عبدالعظیم، 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 هسته‌الگوریتم تکاملی، رقابت استعماری را ایجاد می‌کند. در طول فرایند رقابت، امپراتوری‌های ضعیف‌تر سقوط می‌کنند و مستعمرات آن‌ها توسط امپراتوری قوی‌تر تصاحب می‌شود. این فرایند ادامه دارد تا یکی از امپراتوری‌ها با موقعیت مشخص، مستعمرات آن باقی بماند.

تئوری اصلی و اطلاعات جزئی درباره الگوریتم ICA می‌توان در مقالات مربوط بررسی کرد (آتشپز گرگری و لوکاس، ۲۰۰۷؛ نظری شیرکوهی و همکاران، ۲۰۱۱).

بهینه‌سازی کلونی مورچگان (ACO)

بهینه‌سازی کلونی مورچگان (ACO) بر اساس رفتار تغذیه‌ای واقعی کلونی مورچه‌ها برای جست‌وجوی غذاست. ایده اصلی این روش اولین بار توسط (دریگو و گامباردلا^۴، ۱۹۹۷) ارائه شد. این روش به‌طور خاص تلاش می‌کند که رفتار تیمی کلونی مورچه‌ها را برای پیدا کردن منع غذا تقلید کند. تکنیک ACO دارای دو نسخه اصلی شامل روش پیوسته و گسسته است. ACO پیوسته (ACOR) برای مسائل بهینه‌سازی فضای جست‌وجوی پیوسته، به‌طور موفقیت‌آمیزی مورد استفاده قرار گرفته است (توکسار^۵، ۲۰۰۷؛ یو^۶ و همکاران، ۲۰۰۷).

معیارهای ارزیابی و تنظیمات شبکه

در این مطالعه، سطح آب زیرزمینی با استفاده از چهار شبکه عصبی تکاملی متفاوت، ANN-ICA، ANN-PSO، ANN-GA و ANN-ACOR مدل شده است. مدل‌های استفاده شده با میانگین مربع خطأ (MSE) و ضریب تعیین (R^2) ارزیابی شده‌اند.

1. Atashpaz gargari & Lucas

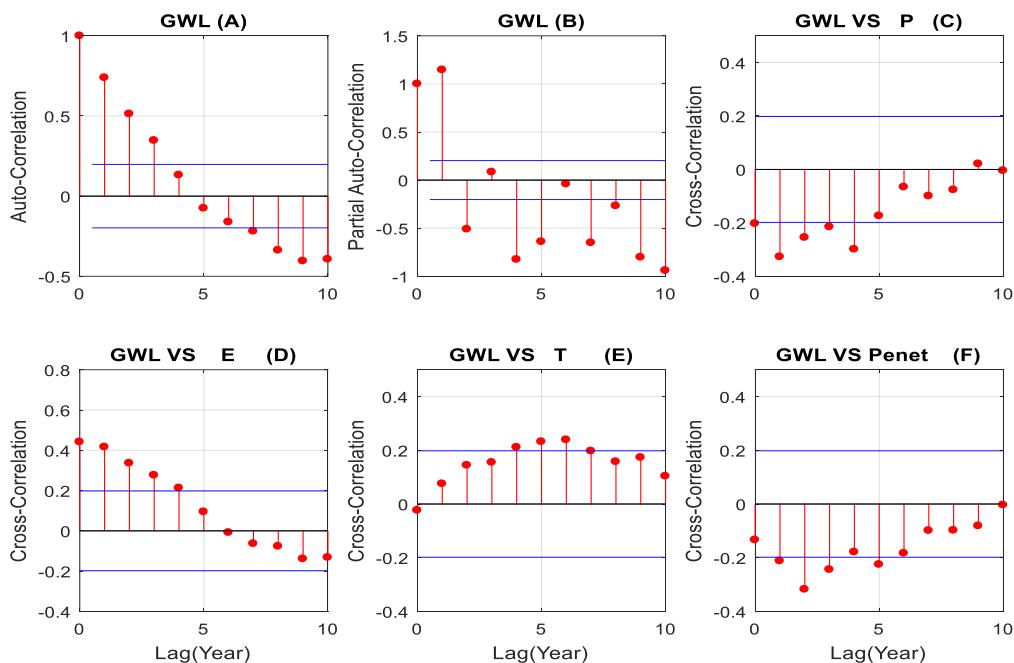
2. Dorigo & Gambardella

3. Toksar

4. Yu

همبستگی بالایی دارند. شکل (۴) قسمت E نشان می‌دهد که دمای متوسط سالانه با تأخیر ۴ با سطح آب زیرزمینی فعلی همبستگی دارد. شکل (۴) قسمت F نشان می‌دهد که نفوذ مؤثر یک سال قبل با سطح آب زیرزمینی فعلی همبستگی بالایی دارد. تجزیه و تحلیل داده‌ها به ما نشان می‌دهد که شرایط پیشین مقادیر بارش، تبخیر، دمای متوسط سالانه، نفوذ مؤثر و سطح آب زیرزمینی می‌توانند به عنوان ورودی برای مدل شبکه عصبی تکاملی کافی باشند.

(شکل ۴). با توجه به شکل (۴) قسمت A واضح است که داده سطح آب زیرزمینی در تأخیرهای ۴، ۵، ۶ همبستگی مناسبی ندارد ولی در بقیه تأخیرها همبستگی بالایی دارد. با مشاهده شکل (۴) قسمت B تابع خودهمبستگی نشان می‌دهد همبستگی داده‌ها در تأخیر ۴ و ۷ اهمیت ندارد و در حداوده اطمینان قرار دارد. الگوی کاهش سریع در قسمت B حاکمیت فرایند رگرسیون خودکار مربوط به فرایند میانگین حرکت را ثابت می‌کند. شکل (۴) قسمت C و D نشان می‌دهد که بارش و تبخیر فعلی با سطح آب زیرزمینی فعلی



شکل (۴): آنالیز همبستگی داده‌های مورد استفاده: شکل (A) ضریب خودهمبستگی برای سطح آب زیرزمینی، شکل (B) خودهمبستگی جزئی برای سطح آب زیرزمینی، شکل (C) همبستگی متقابل بین بارش و سطح آب زیرزمینی، شکل (D) همبستگی متقابل بین تبخیر و سطح آب زیرزمینی، شکل (E) همبستگی متقابل بین متوسط دمای سالانه و سطح آب زیرزمینی، شکل (F) همبستگی متقابل بین نفوذ مؤثر و سطح آب زیرزمینی

Figure (4): Correlations analysis of the data used: Figure (A) Correlation coefficient for groundwater level, Figure (B) Partial correlation for groundwater level, Figure (C) Interaction correlation between precipitation and groundwater level, Figure (D) Interaction correlation between Evaporation and Groundwater Level, Figure (E) Interaction between annual average temperature and groundwater level, Figure (F) The correlation between effective penetration and groundwater level

شبکه عصبی مصنوعی با الگوریتم ژنتیک

می‌شوند و یک گروه جدید به طور تصادفی ایجاد می‌شود. دقت فازهای آموزش و آزمایش برای مدل ANN-GA در جدول (۲) نشان داده شده است. برای اندازه جمعیت از

اندازه‌های متفاوت جمعیت، روش انتخابی و تقاطع‌های متفاوت برای مدل ANN-GA امتحان شده است. در تقاطع، داده‌ها به گروههایی تقسیم می‌شوند و با دیگر گروه‌ها مبادله

زیرزمینی با توجه به MSE است. با توجه به جدول، واضح است که محدوده MSE از $0/0056$ تا $0/0087$ برای آموزش و از $0/0030$ تا $0/0154$ برای آزمایش به دست آمده است. بیشترین مقدار MSE برای مدل ANN-GA شامل ترکیب ورودی ۶ است، درحالی‌که مدل با ترکیب ورودی ۲ بهترین دقت در فاز آزمایش را دارد. روش انتخاب چرخه رولت به‌طور کلی، دقت بیشتری در تخمین ماهانه سطح آب زیرزمینی نسبت به روش انتخابی تورنمنت و تصادفی داشته است (با مشاهده ورودی ۲، ۳ و ۶).

۲۰۰، ۳۰۰ و ۴۰۰، برای تقاطع و انتخاب روش از $0/5$ و تصادفی به‌ترتیب استفاده شد. برای تقاطع‌های $0/4$ ، $0/5$ و $0/6$ ، اندازه جمعیت و انتخاب روش به‌ترتیب برابر 200 و تصادفی استفاده شده است. برای روش‌های انتخاب، تصادفی، مسابقه‌ای و چرخ رولت، اندازه جمعیت و تقاطع به‌ترتیب برابر 200 و $0/5$ در نظر گرفته شده است. در جدول (۲) اعدادی که زیر آن‌ها خط کشیده شده، نشان‌دهنده مقادیر کمینه MSE برای هر ترکیب ورودی و عدد رنگ شده نشان‌دهنده بهترین مدل ANN-GA برای تخمین سطح آب

جدول (۲): دقت MSE برای مدل‌های متفاوت ANN-GA در فاز آموزش و آزمایش

Table (2): MSE accuracy for different models of ANN-GA in the training and testing phase

ورودی‌ها	اندازه جمعیت	تقاطع						انتخاب روش		
		۳۰۰	۲۰۰	۰/۴	۰/۵	۰/۶	تورنمنت	تصادفی	چرخه رولت	
آموزش ۱										
آزمایش ۱										
آموزش ۲										
آزمایش ۲										
آموزش ۳										
آزمایش ۳										
آموزش ۴										
آزمایش ۴										
آموزش ۵										
آزمایش ۵										
آموزش ۶										
آزمایش ۶										

و ۲ در نظر گرفته شده است. برای ضریب سرعت اجتماعی $2/5$ و ۳ اندازه ازدحام و ضریب سرعت شناختی به‌ترتیب برابر 200 و ۲ در نظر گرفته شده است. در جدول (۳) واضح است که محدوده MSE از $0/0031$ تا $0/0096$ برای آموزش و از $0/0039$ تا $0/0157$ برای آزمایش به دست آمده است. مقادیر بیشینه و کمینه MSE برای مدل ANN-PSO به‌ترتیب برای ورودی ۶ و ورودی ۲ برای فاز آزمایش به دست آمده است. این نشان می‌دهد که با افزایش پیجیدگی ورودی خطای مدل ANN-PSO بیشتر می‌شود.

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 (۳) میزان دقت فاز آموزش و آزمایش برای مدل ANN-PSO را گزارش می‌دهد. برای اندازه‌های ازدحام 200 ، 300 و 400 ، ضرایب سرعت اجتماعی و شناختی برابر 2 تنظیم شده است. برای ضریب سرعت شناختی $2/5$ و ۳ اندازه ازدحام و ضریب سرعت اجتماعی به‌ترتیب برابر 200

جدول (۳): دقیقیت MSE برای مدل‌های مختلف ANN-PSO در فاز آموزش و آزمایش

Table (3): MSE accuracy for different models of ANN-PSO for training and testing phase

ورودی‌ها	اندازه ازدحام						ضریب شناختی			ضریب اجتماعی		
	۳	۲/۵	۲	۳	۲/۵	۲	۴۰۰	۳۰۰	۲۰۰	۳	۲/۵	۲
آموزش ۱	۰/۰۰۶۴	۰/۰۰۶۷	۰/۰۰۶۷	۰/۰۰۹۶	۰/۰۰۶۷	۰/۰۰۶۳	۰/۰۰۶۵	۰/۰۰۶۲	۰/۰۰۶۵	۰/۰۰۶۴	۰/۰۰۶۷	۰/۰۰۶۷
آزمایش ۱	۰/۰۰۶۷	۰/۰۰۷۵	۰/۰۰۷۰	۰/۰۰۴۷	۰/۰۰۷۹	۰/۰۰۷۳	۰/۰۰۷۴	۰/۰۰۷۸	۰/۰۰۶۵	۰/۰۰۶۷	۰/۰۰۶۷	۰/۰۰۷۵
آموزش ۲	۰/۰۰۴۴	۰/۰۰۴۵	۰/۰۰۴۷	۰/۰۰۷۱	۰/۰۰۴۳	۰/۰۰۴۱	۰/۰۰۳۷	۰/۰۰۴۲	۰/۰۰۴۵	۰/۰۰۴۵	۰/۰۰۴۵	۰/۰۰۴۵
آزمایش ۲	۰/۰۰۴۵	۰/۰۰۴۷	۰/۰۰۵۲	۰/۰۰۴۹	۰/۰۰۵۰	۰/۰۰۵۵	۰/۰۰۶۰	۰/۰۰۴۹	۰/۰۰۳۹	۰/۰۰۴۵	۰/۰۰۴۵	۰/۰۰۴۵
آموزش ۳	۰/۰۰۵۹	۰/۰۰۵۵	۰/۰۰۵۲	۰/۰۰۶۶	۰/۰۰۵۹	۰/۰۰۵۰	۰/۰۰۵۹	۰/۰۰۵۳	۰/۰۰۵۳	۰/۰۰۵۹	۰/۰۰۵۹	۰/۰۰۵۹
آزمایش ۳	۰/۰۰۷۶	۰/۰۰۷۷	۰/۰۰۸۰	۰/۰۰۷۵	۰/۰۰۷۹	۰/۰۰۸۲	۰/۰۰۷۹	۰/۰۰۸۳	۰/۰۰۷۸	۰/۰۰۷۸	۰/۰۰۷۶	۰/۰۰۷۷
آموزش ۴	۰/۰۰۴۳	۰/۰۰۴۶	۰/۰۰۵۱	۰/۰۰۷۰	۰/۰۰۴۱	۰/۰۰۵۱	۰/۰۰۳۸	۰/۰۰۴۰	۰/۰۰۳۹	۰/۰۰۴۳	۰/۰۰۴۳	۰/۰۰۴۳
آزمایش ۴	۰/۰۰۶۰	۰/۰۰۵۹	۰/۰۰۵۷	۰/۰۰۵۴	۰/۰۰۵۴	۰/۰۰۵۶	۰/۰۰۶۱	۰/۰۰۵۹	۰/۰۰۵۱	۰/۰۰۵۱	۰/۰۰۶۰	۰/۰۰۵۹
آموزش ۵	۰/۰۰۷۳	۰/۰۰۷۲	۰/۰۰۷۱	۰/۰۰۸۲	۰/۰۰۷۱	۰/۰۰۷۰	۰/۰۰۷۳	۰/۰۰۶۹	۰/۰۰۷۱	۰/۰۰۷۳	۰/۰۰۷۲	۰/۰۰۷۲
آزمایش ۵	۰/۰۰۴۴	۰/۰۰۴۶	۰/۰۰۴۵	۰/۰۰۴۲	۰/۰۰۴۴	۰/۰۰۴۵	۰/۰۰۴۲	۰/۰۰۴۵	۰/۰۰۴۳	۰/۰۰۴۳	۰/۰۰۴۴	۰/۰۰۴۴
آموزش ۵	۰/۰۰۴۵	۰/۰۰۴۳	۰/۰۰۴۵	۰/۰۰۵۸	۰/۰۰۴۳	۰/۰۰۳۸	۰/۰۰۳۱	۰/۰۰۳۸	۰/۰۰۴۳	۰/۰۰۴۳	۰/۰۰۴۵	۰/۰۰۴۵
آزمایش ۵	۰/۰۰۹۴	۰/۰۱۰۸	۰/۰۱۰۷	۰/۰۱۵۷	۰/۰۰۸۶	۰/۰۱۰۰	۰/۰۱۰۵	۰/۰۰۸۸	۰/۰۰۹۶	۰/۰۰۹۶	۰/۰۱۰۸	۰/۰۱۰۷

است. برای نرخ انقلاب $0/۰۳$ ، $۰/۰۴$ و $۰/۰۵$ ، تعداد کشورها و ضریب جذب به ترتیب ۲۰۰ و ۲ در نظر گرفته شده است. در جدول (۴) محدوده MSE از $۰/۰۰۵۰$ تا $۰/۰۱۰۸$ برای فاز آموزش و از $۰/۰۰۲۲$ تا $۰/۰۱۶۹$ برای آزمایش مشاهده شده است. بیشینه مقدار MSE برای مدل ANN-ICA برای ترکیب ورودی ۶ به دست آمده، در حالی که مدل با ترکیب ورودی ۲ ، بهترین دقیقیت در فاز آزمایش را نشان می‌دهد.

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 آزمایش در جدول (۴) نشان داده شده است. برای تعداد کشورهای ۲۰۰ ، ۳۰۰ و ۴۰۰ ضریب جذب و نرخ انقلاب به ترتیب برابر ۲ و ۳ و ۴ در نظر گرفته شده است. برای ضریب جذب ۲ و ۳ ، تعداد کشورها و نرخ انقلاب به ترتیب برابر ۲۰۰ و $۰/۰۳$ انتخاب شده

جدول (۴): دقیقیت MSE برای مدل‌های مختلف ANN-ICA در فاز آموزش و آزمایش

Table (4): MSE accuracy for different models of ANN-ICA in the training and testing phase

ورودی‌ها	تعداد کشورها						ضریب جذب			نرخ انقلاب		
	۴۰۰	۳۰۰	۲۰۰	۲	۳	۲/۵	۳	۲/۵	۰/۴	۰/۳	۰/۰	
آموزش ۱	۰/۰۰۵۶	۰/۰۰۵۵	۰/۰۰۵۶	۰/۰۰۵۵	۰/۰۰۵۰	۰/۰۰۵۰	۰/۰۰۵۶	۰/۰۰۵۷	۰/۰۰۵۵	۰/۰۰۵۶	۰/۰۰۵۲	۰/۰۰۵۵
آزمایش ۱	۰/۰۰۸۹	۰/۰۰۹۲	۰/۰۰۹۱	۰/۰۰۸۵	۰/۰۰۸۸	۰/۰۰۹۱	۰/۰۰۹۳	۰/۰۰۸۳	۰/۰۰۸۹	۰/۰۰۸۹	۰/۰۰۸۹	۰/۰۰۹۲
آموزش ۲	۰/۰۰۵۳	۰/۰۰۵۷	۰/۰۰۵۳	۰/۰۰۶۳	۰/۰۰۵۷	۰/۰۰۵۷	۰/۰۰۵۳	۰/۰۰۵۴	۰/۰۰۵۳	۰/۰۰۵۴	۰/۰۰۵۰	۰/۰۰۵۹
آزمایش ۲	۰/۰۰۳۰	۰/۰۰۳۱	۰/۰۰۲۴	۰/۰۰۲۷	۰/۰۰۲۷	۰/۰۰۲۴	۰/۰۰۳۱	۰/۰۰۳۰	۰/۰۰۳۰	۰/۰۰۳۰	۰/۰۰۲۷	۰/۰۰۲۲
آموزش ۳	۰/۰۰۷۱	۰/۰۰۶۶	۰/۰۰۷۱	۰/۰۰۶۸	۰/۰۰۷۳	۰/۰۰۷۳	۰/۰۰۶۸	۰/۰۰۶۶	۰/۰۰۷۱	۰/۰۰۷۱	۰/۰۰۷۳	۰/۰۰۷۲
آزمایش ۳	۰/۰۰۵۱	۰/۰۰۵۴	۰/۰۰۷۳	۰/۰۰۶۸	۰/۰۰۶۸	۰/۰۰۶۸	۰/۰۰۶۷	۰/۰۰۶۵	۰/۰۰۵۱	۰/۰۰۵۳	۰/۰۰۵۰	۰/۰۰۵۰
آموزش ۴	۰/۰۰۶۵	۰/۰۰۶۳	۰/۰۰۵۷	۰/۰۰۶۸	۰/۰۰۷۵	۰/۰۰۵۶	۰/۰۰۵۸	۰/۰۰۶۵	۰/۰۰۶۵	۰/۰۰۶۵	۰/۰۰۵۹	۰/۰۰۵۹
آزمایش ۴	۰/۰۰۳۲	۰/۰۰۳۶	۰/۰۰۳۶	۰/۰۰۳۱	۰/۰۰۳۸	۰/۰۰۳۸	۰/۰۰۳۱	۰/۰۰۳۲	۰/۰۰۳۲	۰/۰۰۳۲	۰/۰۰۳۹	۰/۰۰۳۹
آموزش ۵	۰/۰۰۷۱	۰/۰۰۶۱	۰/۰۰۷۱	۰/۰۰۶۷	۰/۰۰۶۵	۰/۰۰۶۵	۰/۰۰۶۱	۰/۰۰۷۱	۰/۰۰۷۱	۰/۰۰۷۱	۰/۰۰۷۳	۰/۰۰۷۲
آزمایش ۵	۰/۰۰۶۳	۰/۰۰۸۰	۰/۰۰۷۴	۰/۰۰۶۹	۰/۰۰۷۷	۰/۰۰۷۷	۰/۰۰۷۷	۰/۰۰۸۰	۰/۰۰۸۰	۰/۰۰۸۰	۰/۰۰۸۷	۰/۰۰۸۶
آموزش ۶	۰/۰۱۰۶	۰/۰۰۶۰	۰/۰۰۷۰	۰/۰۱۰۶	۰/۰۰۷۰	۰/۰۰۷۰	۰/۰۰۶۰	۰/۰۱۰۶	۰/۰۱۰۶	۰/۰۱۰۶	۰/۰۱۰۸	۰/۰۰۹۱
آزمایش ۶	۰/۰۰۷۶	۰/۰۰۸۰	۰/۰۰۸۴	۰/۰۰۹۰	۰/۰۰۸۹	۰/۰۰۷۵	۰/۰۰۸۰	۰/۰۰۷۶	۰/۰۰۷۶	۰/۰۰۷۶	۰/۰۱۲۳	۰/۰۱۷۹

جمعیت و نرخ انحراف به ترتیب برابر ۲۰۰ و ۱ انتخاب شده است. برای نرخ انحراف $0/8$ ، $0/9$ و 1 ، تعداد جمعیت و فاکتور تشدید به ترتیب 200 و $0/5$ در نظر گرفته شده است. در جدول (۴) محدوده MSE از $0/0054$ تا $0/0707$ برای فاز آموزش و از $0/0024$ تا $0/0500$ برای آزمایش مشاهده شده است. پیشینه مقدار MSE برای مدل ANN-ACOR برای ترکیب ورودی 6 به دست آمده، در حالی که مدل با ترکیب ورودی 2 بهترین دقت در فاز آزمایش 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 آزمایش در جدول (۵) نشان داده شده است. برای تعداد جمعیت‌های 200 ، 300 و 400 ، فاکتور تشدید و نرخ انحراف به ترتیب برابر $0/5$ و $0/6$ ، تعداد

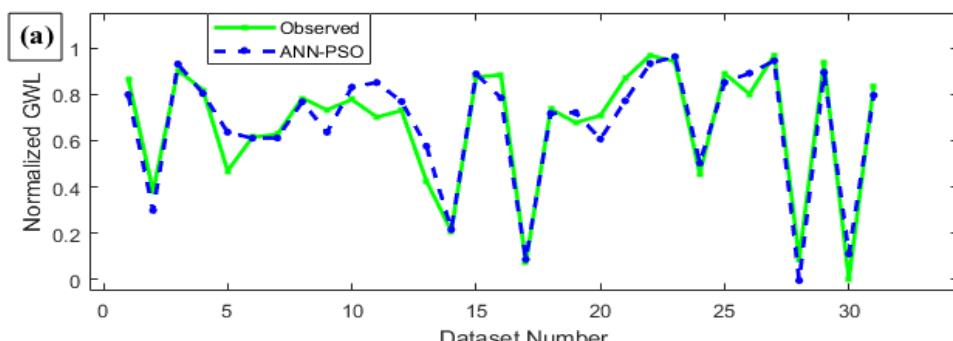
جدول (۵): دقت MSE برای مدل‌های متفاوت ANN-ACOR در فاز آموزش و آزمایش

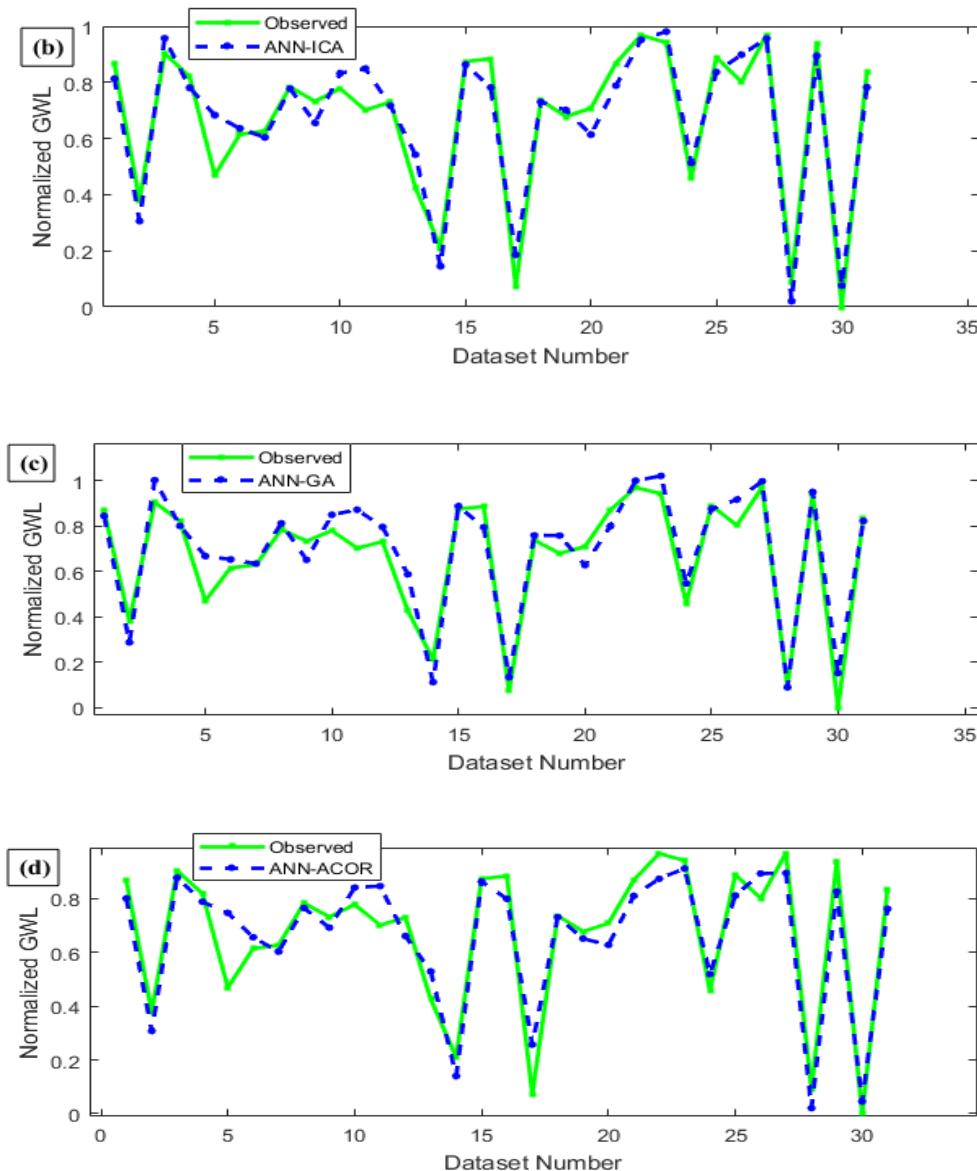
Table (5): MSE accuracy for different models of ANN-ACOR in the training and testing phase

ورودی‌ها	اندازه جمعیت											
	نرخ انحراف			فاکتور تشدید								
۱	$0/9$	$0/8$	$0/6$	$0/5$	$0/4$	400	300	200				
آموزش	<u>۱</u>	<u>$0/0091$</u>	<u>$0/0093$</u>	<u>$0/0108$</u>	<u>$0/0097$</u>	<u>$0/0100$</u>	<u>$0/0086$</u>	<u>$0/0090$</u>	<u>$0/0094$</u>	<u>$0/0071$</u>		
آزمایش	<u>۱</u>	<u>$0/0050$</u>	<u>$0/0081$</u>	<u>$0/0064$</u>	<u>$0/0076$</u>	<u>$0/0077$</u>	<u>$0/0069$</u>	<u>$0/0058$</u>	<u>$0/0063$</u>	<u>$0/0044$</u>		
آموزش	<u>۲</u>	<u>$0/0089$</u>	<u>$0/0054$</u>	<u>$0/0074$</u>	<u>$0/0112$</u>	<u>$0/0122$</u>	<u>$0/0068$</u>	<u>$0/0099$</u>	<u>$0/0070$</u>	<u>$0/0101$</u>		
آزمایش	<u>۲</u>	<u>$0/0139$</u>	<u>$0/0150$</u>	<u>$0/0101$</u>	<u>$0/0087$</u>	<u>$0/0078$</u>	<u>$0/0081$</u>	<u>$0/0052$</u>	<u>$0/0053$</u>	<u>$0/0024$</u>		
آموزش	<u>۳</u>	<u>$0/0079$</u>	<u>$0/0063$</u>	<u>$0/0104$</u>	<u>$0/0090$</u>	<u>$0/0104$</u>	<u>$0/0101$</u>	<u>$0/0085$</u>	<u>$0/0083$</u>	<u>$0/0065$</u>		
آزمایش	<u>۳</u>	<u>$0/0090$</u>	<u>$0/0116$</u>	<u>$0/0122$</u>	<u>$0/0170$</u>	<u>$0/0165$</u>	<u>$0/0118$</u>	<u>$0/0132$</u>	<u>$0/0094$</u>	<u>$0/0169$</u>		
آموزش	<u>۴</u>	<u>$0/0247$</u>	<u>$0/0099$</u>	<u>$0/0160$</u>	<u>$0/0164$</u>	<u>$0/0168$</u>	<u>$0/0218$</u>	<u>$0/0176$</u>	<u>$0/0073$</u>	<u>$0/0147$</u>		
آزمایش	<u>۴</u>	<u>$0/0069$</u>	<u>$0/0059$</u>	<u>$0/0102$</u>	<u>$0/0096$</u>	<u>$0/0105$</u>	<u>$0/0050$</u>	<u>$0/0150$</u>	<u>$0/0099$</u>	<u>$0/0145$</u>		
آموزش	<u>۵</u>	<u>$0/0069$</u>	<u>$0/0083$</u>	<u>$0/0161$</u>	<u>$0/0093$</u>	<u>$0/0111$</u>	<u>$0/0107$</u>	<u>$0/0072$</u>	<u>$0/0115$</u>	<u>$0/0059$</u>		
آزمایش	<u>۵</u>	<u>$0/0176$</u>	<u>$0/0199$</u>	<u>$0/0161$</u>	<u>$0/0151$</u>	<u>$0/0224$</u>	<u>$0/0084$</u>	<u>$0/0139$</u>	<u>$0/0126$</u>	<u>$0/0213$</u>		
آموزش	<u>۶</u>	<u>$0/0707$</u>	<u>$0/0314$</u>	<u>$0/0331$</u>	<u>$0/0439$</u>	<u>$0/0220$</u>	<u>$0/0355$</u>	<u>$0/0426$</u>	<u>$0/0390$</u>	<u>$0/0297$</u>		
آزمایش	<u>۶</u>	<u>$0/0485$</u>	<u>$0/0211$</u>	<u>$0/0320$</u>	<u>$0/0500$</u>	<u>$0/0214$</u>	<u>$0/0256$</u>	<u>$0/0333$</u>	<u>$0/0279$</u>	<u>$0/0199$</u>		

ANN-ACOR در دوره آموزش در شکل (۵) نشان داده شده است. با مشاهده شکل‌ها می‌توان دریافت همه مدل‌ها تخمین مناسبی برای داده‌های GWL داشته‌اند.

در نهایت، ترکیب ورودی 2 برای مقایسه روش‌ها به دلیل دارا بودن نرخ خطای کمتر انتخاب شده است. نمودارهای تنابع زمانی برای مقادیر GWL مشاهده شده و شبیه‌سازی شده توسط مدل‌های ANN-GA، ANN-ICA، ANN-PSO و ANN-PSO



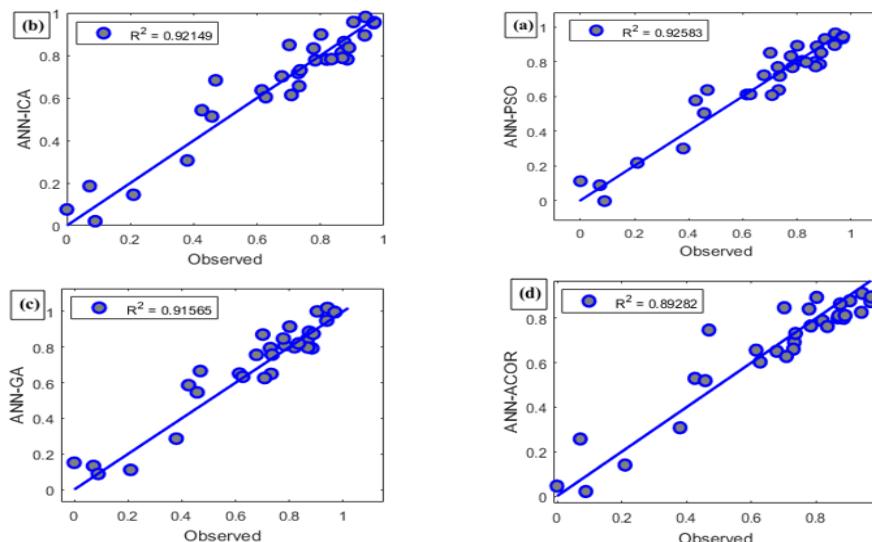


شکل (۵): نمودارهای تناوب زمانی برای مقادیر GWL مشاهده شده و شبیه سازی شده توسط مدل های ANN-PSO و ANN-GA ANN-ICA ANN-PSO در دوره آموزش ANN-ACOR

Figure (5): Time-space graphs for GWL values observed and simulated by ANN-PSO, ANN-ICA, ANN-GA and ANN-ACOR models during training

نشان می دهد که این روش ها توانایی بالایی در تنظیم وزن های شبکه دارند. دلیل کارایی این روش ها، توازن مناسب در بررسی فضای مسئله (اکتشاف) و بهره برداری از جواب های به دست آمده (استخراج) است.

پراکندگی نقاط شبیه سازی شده در فاز آموزش در شکل (۶) نشان داده شده است. با مشاهده این شکل می توان دریافت که توزیع انتخاب داده های آموزش مناسب بوده است؛ زیرا پراکندگی نقاط در تمام محدوده قرار دارد. عملکرد آموزش روش های تکاملی برای شبکه عصبی پرسپترون چند لایه با توجه به ضرایب اطمینان قابل توجه



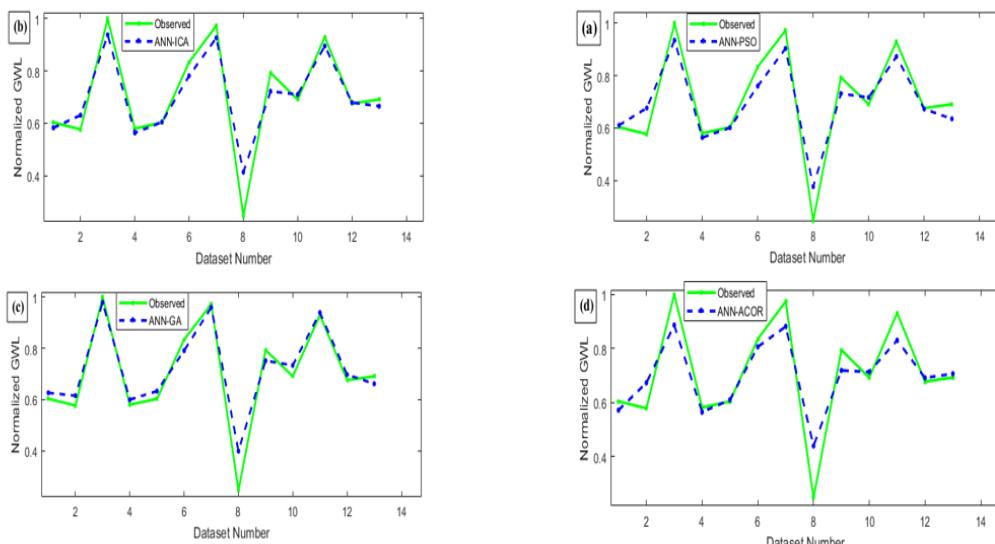
شکل (۶): نمودار پراکندگی یک به یک نقاط شبیه‌سازی شده در فاز آموزش

Figure 6: The dispersion diagram of one-to-one simulated points in the training phase

و ANN-ACOR در جذب بعضی از مقادیر قلهای داشته

است.

شکل (۷) تخمین مدل‌ها را در فاز آزمایش نشان می‌دهد. اگرچه همه سه مدل تخمین مناسبی دارند، مدل ANN-GA عملکرد بهتری نسبت به مدل‌های ANN-ICA، ANN-PSO



شکل (۷): نمودارهای تناوب زمانی برای مقادیر GWL مشاهده شده و شبیه‌سازی شده توسط مدل‌های ANN-GA، ANN-ICA، ANN-PSO و ANN-ACOR در دوره آزمایش

Figure 7: Chronometric graphs for GWL values observed and simulated by ANN-PSO, ANN-ICA, ANN-GA and ANN-ACOR models during the test period

تخمین‌های مدل‌های به کار برد شده در فاز آزمایش در شکل (۸) به صورت پراکندگی نقاط نشان داده شده است. با مشاهده شکل واضح است که مدل ANN-GA تخمین پراکندگی کمتری و عملکرد بهتری نسبت به دیگر مدل‌ها داشته است.

برای ارزیابی مدل‌ها باید به بخش آزمایش آن‌ها توجه کرد؛ زیرا در بخش آموزش خروجی‌های مشاهده شده به شبکه ارائه شده‌اند. نتایج بخش آموزش و آزمایش در جدول (۶) ذکر شده است. با توجه به نتایج بدست آمده، میانگین مربعات خطای مدل‌ها در بخش آزمایش به ترتیب 0.0039 ، 0.0032 ، 0.0040 و 0.0030 است؛ که در این بخش عملکرد مدل شبکه عصبی با الگوریتم ژنتیک بهتر از بقیه روش‌های تکاملی است. همچنین ضریب تعیین در بخش آزمایش به ترتیب 0.95525 ، 0.94928 ، 0.94928 و 0.95729 به دست آمده است. نتایج ضریب تعیین برای الگوریتم ژنتیک اطمینان بیشتری برای تخمین سطح آب زیرزمینی را نشان می‌دهد.

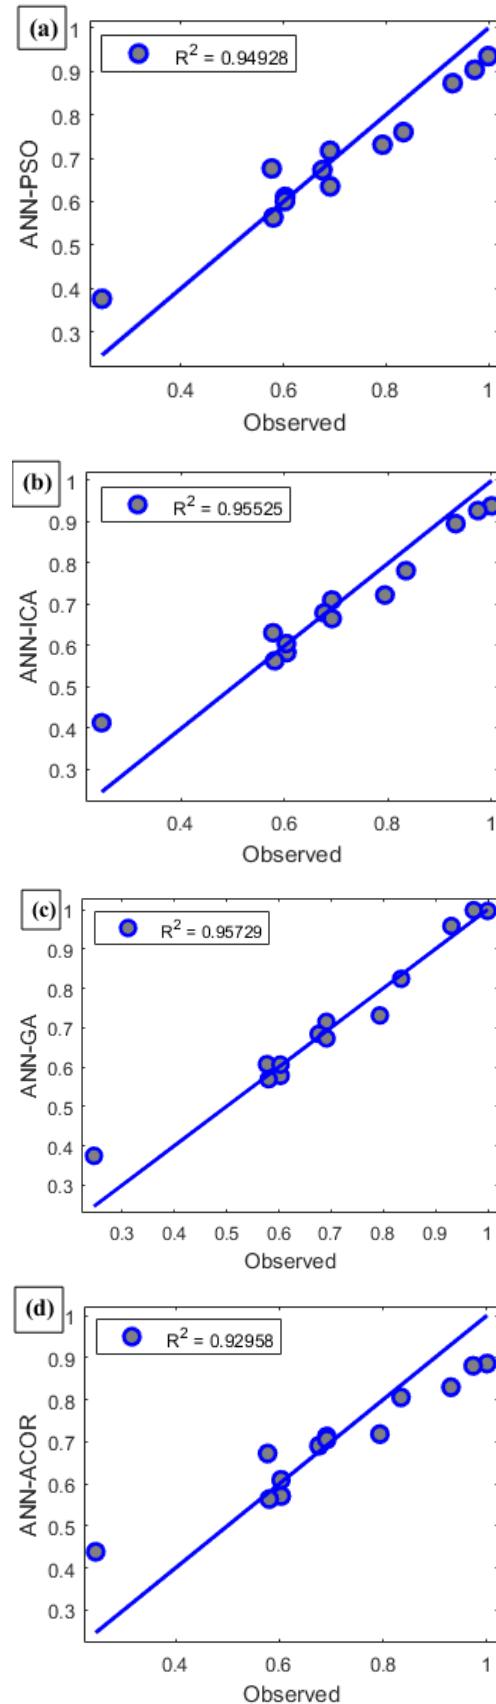
جدول (۶): مقایسه عملکرد چهار مدل ارائه شده برای تخمین سطح آب زیرزمینی

Table (6): Comparison of the performance of the four models presented for estimation of groundwater level

ضریب تعیین	میانگین مربعات خطأ			مدل‌ها
	آموزش	آزمایش	آموزش	
0.95729	0.91565	0.0030	0.0075	ANN-GA
0.95525	0.92149	0.0032	0.0061	ANN-ICA
0.94928	0.92583	0.0039	0.0045	ANN-PSO
0.92958	0.89282	0.0040	0.0101	ANN-ACOR

با توجه به نتایج داده‌ها در فاز آزمایش، عملکرد GA نسبت به الگوریتم‌های ICA، PSO و ACOR در مدل‌سازی تغییرات آب زیرزمینی بهتر بوده است.

مزایای الگوریتم ژنتیک عبارت‌اند از: ۱. ماهیت جست‌وجوی تصادفی این الگوریتم در فضای مسئله، به نوعی یک جست‌وجوی موازی محسوب می‌شود؛ زیرا هریک از کروموزوم‌های تصادفی تولید شده به وسیله الگوریتم، یک نقطه شروع جدید برای جست‌وجوی بخشی از فضای حالت مسئله به حساب آمده و جست‌وجو در تمام آن‌ها به شکل همزمان صورت می‌گیرد. ۲. بدلیل وسعت و پراکندگی نقاطی که مورد جست‌وجو قرار می‌گیرند، در مسائلی که فضای جست‌وجوی بزرگی داشته باشند، نتیجه مطلوبی کسب می‌کند. ۳. نوعی جست‌وجوی تصادفی هدفمند محسوب شده و از مسیرهای مختلف به جواب‌های متفاوتی خواهد رسید. علاوه بر آن، با هیچ محدودیتی در مسیر جست‌وجو و انتخاب پاسخ‌های



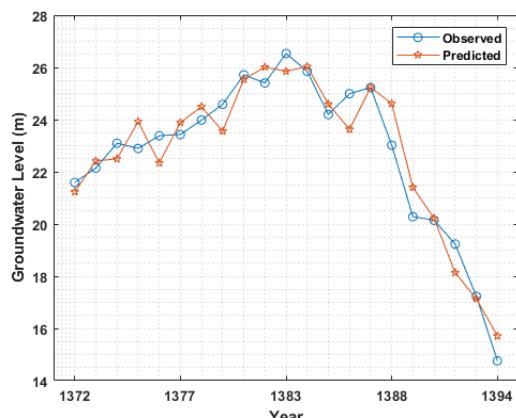
شکل (۸): نمودار پراکندگی یک‌به‌یک نقاط شبیه‌سازی شده در فاز آزمایش

Figure (8): The dispersion diagram of one-to-one simulated points in the testing phase

است. بررسی روند تغییرات سطح آب زیرزمینی دشت در یک دوره ۲۲ ساله نشان می‌دهد که از سال ۱۳۷۲ تا ۱۳۸۵ به علت برداشت بیش از حد و خشکسالی‌های پی‌درپی، سطح ایستابی با یک شیب تند پایین آمده است. از این تاریخ به بعد با ورود آب سد کرخه و کاهش برداشت از سفره آب زیرزمینی، سطح ایستابی دشت بالا آمده و در سال ۱۳۹۴ به ۱۴ متر رسیده است. داده‌های سطح آب زیرزمینی قبلی، تبخیر، بارش، دمای متوسط سالانه و نفوذ مؤثر به عنوان ورودی مدل‌ها مورد استفاده قرار گرفته است. شش ترکیب متفاوت ورودی بر طبق آنالیز همبستگی تعیین شده است. پارامترهای کنترلی متفاوتی برای مدل‌ها به کار برده شده و بر طبق میانگین مریع خطا و ضریب تعیین با همدیگر مقایسه شده است. همه چهار مدل ANN-ICA، ANN-PSO، ANN-GA و ANN-ACOR، برای ترکیب ورودی ۲ بهترین دقت را نشان می‌دهند. مقایسه نتایج نشان می‌دهد که مدل ANN-GA عملکرد بهتری نسبت به سه مدل دیگر برای تخمین سطح آب زیرزمینی دارد. 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 محققان از تکنیک‌های تکاملی برای تخمین تغییرات سطح آب زیرزمینی از جمله الگوریتم ژنتیک (داش، ۲۰۱۰؛ جلال‌کمالی و همکاران، ۲۰۱۱)، الگوریتم رقابت استعماری (ظاهرشمسی و شیخ‌الاسلامی، ۲۰۱۱)، بهینه‌سازی ازدحام ذرات (ژی^۱ و همکاران، ۲۰۱۲؛ گوور^۲ و همکاران، ۲۰۱۳) و مقایسه این روش‌ها با هم (کیسی و همکاران، ۲۰۱۷) استفاده کرده‌اند. در این تحقیق علاوه بر مدل‌های فوق از مدل ANN-ACOR نیز استفاده شده است. مقایسه نتایج نشان می‌دهد که مدل ANN-GA عملکرد بهتری نسبت به ۳ مدل دیگر برای تخمین سطح آب زیرزمینی دارد که با نتایج ژی^۱ و همکاران (۲۰۱۲) و گوور^۲ و همکاران (۲۰۱۳) مغایرت، ولی با تحقیقات داش و همکاران (۲۰۱۰) و جلال‌کمالی و همکاران (۲۰۱۱) مطابقت دارد.

تصادفی رو به رو نیست. ۴. به دلیل رقابت (تنازع بقاع) پاسخ‌ها و انتخاب بهترین‌ها 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.

با توجه به اندازه‌گیری‌های انجام‌شده در چاههای پیزومتری، سطح ایستابی دشت به علت خشکسالی و برداشت بیش از حد آب‌های زیرزمینی در سال ۱۳۷۲، ۲۱ متر گزارش شده و تا سال ۱۳۸۵ سطح ایستابی به ۲۶ متر رسیده است. در سال ۱۳۸۵ با ورود آب سد کرخه، سطح ایستابی چاههای پیزومتری دشت نسبت به سطح زمین روند کاهشی داشته و تا سال ۱۳۹۴ به کمترین مقدار خود یعنی ۱۴ متر رسیده، که نشان‌دهنده بالا آمدن سطح آب ایستابی در دشت مطالعه است. در شکل (۹) روند تغییرات سطح آب ایستابی مشاهده شده در پیزومترها با روش شبکه عصبی مصنوعی با الگوریتم ژنتیک نشان داده شده است. با توجه به شکل می‌توان دریافت که شبکه عصبی مصنوعی به خوبی روند افزایش و کاهش تغییرات سطح آب را تخمین زده است.



شکل (۹): مقایسه تخمین تغییرات سطح آب زیرزمینی مشاهده شده و پیش‌بینی شده

Figure (9): Comparison of estimated and observed changes in groundwater level

نتیجه‌گیری

این مطالعه به بررسی توانایی چهار روش شبکه عصبی تکاملی متفاوت در تخمین سطح آب زیرزمینی دشت عباس پرداخته

منابع

1. Abd-Elazim, SM., Ali, ES., 2016. Imperialist competitive algorithm for optimal STATCOM design in a multimachine power system. *Electri Power Energy Syst* 76: 136–146.
2. Acharya, N., Shrivastava, NA., Panigrahi, BK., Mohanty, UC., 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. *Clim Dyn* 43(5): 1303–1310.
3. Adamowski, J., Chan, HF., 2011. a wavelet neural network conjunction model for groundwater level forecasting. *J Hydrol* 407(1–4): 28–40.
4. Affandi, AK., Watanabe, K., 2007. Daily groundwater level fluctuation forecasting using soft computing technique. *Nat Sci* 5(2): 1–10.
5. Atashpaz Gargari, E., Lucas, C., 2007. Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. *IEEE Congress on Evolutionary Computation*, Singapore.
6. Bhattacharyya, S., Pendharkar, PC., 1998. Inductive, evolutionary and neural techniques for discrimination: a comparative study. *Decis Sci* 29(4): 871–899.
7. Daliakopoulos, IN., Coulibaly, P., Tsanis, IK., 2005. Groundwater level forecasting using artificial neural networks. *J Hydrol* 309(1–4): 229–240.
8. Dash, NB., Panda, SN., Remesan, R., Sahoo, N., 2010. Hybrid neural modeling for groundwater level prediction. *Neural Comput Appl* 19(8): 1251–1263.
9. Dorigo, M., Gambardella, L.M., 1997. Ant colony system: a cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation* 1(1), 53–66.
10. Gaur, S., Sudheer, Ch., Graillot, D., Chahar, BR., Kumar, DN., 2013. Application of artificial neural networks and particle swarm optimization for the management of groundwater resources. *Water Resour Manage* 27(3): 927–941.
11. Jalalkamali, A., Jalalkamali, N., 2011. Groundwater modeling using hybrid of artificial neural network with genetic algorithm. *Afr J Agric Res* 6(26): 5775–5784.
12. Khalil, B., Broda, S., Adamowski, J., Ozga-Zielinski, B., Donohoe, A., 2015. Short-term forecasting of groundwater levels under conditions of mine-tailings recharge using wavelet ensemble neural network models. *Hydrogeol J* 23(1): 121–141.
13. Kisi, O., 2007. Streamflow forecasting using different artificial neural network algorithms. *J. Hydrologic Engineering*. 12(5): 532–539.
14. Kisi, O., Sanikhani, H., Zounemat-Kermani, M., Niazi, F., 2015a. Long-term monthly evapotranspiration modeling by several data-driven methods without climatic data. *Comput Electron Agric* 115:66–77.
15. Kisi, O., Tombul, M., Zounemat-Kermani, M., 2015b. Modeling soil temperatures at different depths by using three different neural computing techniques. *Theoret Appl Climatol* 121(1): 377–387.
16. Kisi, O., Alizamir, M., Zounemat-Kermani, M., 2017. Modeling groundwater fluctuations by three different evolutionary neural network techniques using hydroclimatic data. *Natural Hazards*, 87(1), 367–381.
17. Mohanty, S., Jha, MK., Raul, SK., Panda, RK., Sudheer, KP., 2015. Using artificial neural network approach for simultaneous forecasting of weekly groundwater levels at multiple sites. *Water Resour Manage* 29(15): 5521–5532.
18. Nayak, PC., Sudheer, KP., Rangan, DM., Ramasatri, KS., 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *J Hydrol* 291: 52–66.
19. Nayak, PC., Rao, YRS., Sudheer, KP., 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resour Manage* 20: 77–90.
20. Nazari-Shirkouhi, S., Eivazy, H., Ghodsi, R., Rezaie, K., Atashpaz-Gargari, E., 2010. Solving the integrated product mix-outsourcing problem using the imperialist competitive algorithm. *Expert Syst Appl* 37: 7615–7626.
21. Samani, N., Gohari-Moghadam, M., Safavi, AA., 2007. A simple neural network model for the determination of aquifer parameters. *J Hydrol* 340(1–2): 1–11.
22. Toksarı, M.D., 2007. Ant colony optimization approach to estimate energy demand of turkey. *Energy Policy*35 (8), 3984–3990.
23. Tahershamsi, A., Sheikholeslami, R., 2011. Optimization to identify Muskingum model parameters using imperialist competitive algorithm. *Int J Optim Civil Eng* 3: 473–482.

24. Wong, FS., 1991. Time series forecasting using backpropagation neural networks. *Neurocomputing* 2(4): 147–159.
25. Xi, Z., Zhang, Y., Zhu, C., 2012. Application of PSO-neural network model in prediction of groundwater level in Handan City. *Adv Infor Sci Ser Sci* 4(6): 177–183.
26. Yu, L., Liu, K., Li, K., 2007. Ant colony optimization in continuous problem. *Frontiers of Mechanical Engineering in China* 2(4), 459–462.
27. Zeng, XK., Ye, M., Burkardt, J., Wu, JC., Wang, D., Zhu, XB., 2016. Evaluating two sparse grid surrogates and two adaptation criteria for groundwater Bayesian uncertainty quantification. *J Hydrol* 535:120–134.
28. Zounemat-Kermani, M., 2012. Hourly predictive Levenberg–Marquardt ANN and multi linear regression models for predicting of dew point temperature. *Meteorol Atmos Phys* 117(3–4): 181–192.
29. Zounemat-Kermani, M., Kisi, O., Rajaee, T., 2013. Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff. *Appl Soft Compute* 13(12): 4633–4644.

Modeling Groundwater Changes Using Four Different Techniques of Evolutionary Neural Network and climatic data (Case Study of Dasht-Abbas Plain, Ilam Province)

Shahla Paimozd^{*1}, Mohamad Reza Rezaei[†], Mohamad Javad Rezaei³, Jafar Rezaei⁴

Received: 15/09/2018

Accepted: 21/01/2019

Extended Abstract

Introduction: Groundwater is one of the main sources of drinking water, agriculture and industry. It is worth noting that groundwater is considered as reserve resources in some areas, while in other areas it may be used for supplying potable water due to their availability (Daliakopoulos et al., 2005; Nayak et al., 2006). Groundwater analysis is an essential factor in maintaining its access. Modeling and predicting the groundwater level for environmental protection, maintaining the balance of the groundwater system, controlling changes in groundwater levels and protecting the escalation of land subsidence are important. Groundwater management techniques and solutions, and control measurements by researchers and operators to address the long-term problems of land subsidence and groundwater conservation (Affandi and Watanabe 2007; Mohanty et al., 2015). The main aim of this study is to evaluate the accuracy of evolutionary neural network models in the monthly groundwater level estimation.

Materials and methods: In this study groundwater level, precipitation, evaporation, annual average temperature and effective influence between 1993 and 2016 were used. The purpose of this study is applying neural networks to estimate the groundwater level. To use the neural network, we must optimize the weights and biases of the network. In this research, weights and network biases were obtained using optimization algorithms such as genetic algorithm, particle swarm algorithm, Imperialist Competitive algorithm and ant colony algorithm.

1. Faculty member of Arak University of Agriculture and Natural Resources, Arak University; paimozd.ar@hotmail.com
 2. MSc Graduated, Irrigation and Drainage, Arak University
 3. Department of Computer, Islamic Azad University, Kermanshah Branch
 4. Faculty member, Economic, Social and Extension Research Department Ilam Agricultural and Natural Resources Research and Education Center, Agricultural Research, Education and Extension Organization (AREEO), Ilam
 DOI: 10.22052/deej.2018.7.22.25

Results: Different control parameters have been used for models, and they are compared with each other based on the mean square error and the coefficient of determination. All four models showed the best accuracy for input combinations. Comparison of the results shows that the ANN-GA model has a better performance than the other three models for groundwater level estimation. The advantages of GA are: 1) The nature of the random search of this algorithm in the problem space is in some way a parallel search. Because each of the random-generated chromosomes generated by the algorithm is considered as a new starting point to search for part of the problem-space and searches in all of them simultaneously. 2) Due to the breadth and dispersion of the points to be searched, it yields a satisfactory result in issues of great search space. 3) A kind of random search is targeted and will come from different paths to different answers. In addition, there is no limit to the search and selection of random answers. 4) Because of the competition, the answers and the selection of the best among the population, with a high probability, will reach the optimal level. 5) Its implementation is simple and does not require complex problem-solving procedures. It can be said that this algorithm may be a good candidate for hydrological modeling. Investigating the trend of groundwater level changes in the plain over a period of 22 years shows that from 1993 to 2006, due to excessive withdrawal and droughts, the level of stagnation with a steep slope has fallen. Since then, with the arrival of the water of the Karkheh Dam and the reduction of withdrawal, the groundwater level of the plain table has risen and reaches 14 meters in 2015.

Discussion & conclusion: Most commonly used methods for training neural networks from descending gradients using back propagation are to calculate real gradients. In recent years, some researchers have developed evolutionary techniques for estimating groundwater level changes, including genetic algorithms (Dash et al. 2010, Jalakamali and Jalakamali 2011), Imperialist competition algorithm (Tahershamsi and Sheikholeslami 2011), particle swarm optimization (Xi et al. 2012, Gaur et al. 2013) and comparing these methods with each other (Kisi et al., 2017). In addition to the above-mentioned models, the ANN-ACOR model was also used. Comparison of the results shows that the ANN-GA model has a better performance than the other three models for estimating groundwater level, which contradicts the results of (Xi, 2012) and (Gaur, 2013), and matches with the research (Jalalkamali, 2011) and (Dash, 2010).

Keywords: Groundwater Changes, Evolutionary Neural Networks, Genetic Algorithm, Particle Swarm Optimization, Imperialism Competition Algorithm, Ant Colony Optimization, Modeling.