

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 پایمزد^{۱*}، محمدرضا رضایی^۲، محمد جواد رضایی^۳، جعفر رضایی^۴

تاریخ دریافت: ۱۳۹۷/۶/۲۴

تاریخ پذیرش: ۱۳۹۷/۱۱/۱

چکیده

در نواحی خشک و نیمه‌خشک، به دلیل کمبود جریان‌های سطحی، فشار عمده بر آب‌های زیرزمینی وارد می‌شود. سطح منابع آب زیرزمینی محدوده مورد مطالعه (دشت عباس) نیز به دلیل استفاده بی‌رویه، دچار افت شدید شده و بیش از ۳۰ سال است که به‌عنوان 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 بین مدل‌های ارائه شده برای ورودی $(P_1 \text{ و } GWL_{t-2}, GWL_{t-1})$ به دست آمده است. دقت میانگین مربع خطا برای مدل‌های ANN-PSO، ANN-ICA، ANN-ACOR به ترتیب ۰/۰۰۳۳، ۰/۰۰۳۹ و ۰/۰۰۴۴ و برای مدل ANN-GA ۰/۰۰۳۰ 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 هیئت علمی مرکز تحقیقات کشاورزی و منابع طبیعی استان ایلام

مقدمه

یکی از منابع اصلی تأمین آب شرب کشاورزی و صنعتی، آب زیرزمینی است. شایان ذکر است که آب‌های زیرزمینی در برخی مناطق به‌عنوان منابع ذخیره در نظر گرفته می‌شوند، درحالی‌که در مناطق دیگر ممکن است از آن‌ها برای تأمین آب شرب به‌علت دسترس پذیری 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 نشست زمین اهمیت دارد. تکنیک‌ها و راه‌حل‌های مدیریت آب‌های زیرزمینی و اقدامات کنترلی توسط پژوهشگران و متصدیان برای مقابله با مشکلات درازمدت نشست زمین و حفاظت منابع آب زیرزمینی ارائه شده است (موهنتی^۳ و همکاران، ۲۰۱۵؛ افندی و واتانابی^۴، ۲۰۰۷). 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 به مسائل مهمی تبدیل شده و در سطح حوضه 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 (به‌طور 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

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

تا به امروز، برخی از محققان، از شبکه عصبی برای مدل‌سازی تغییرات آب زیرزمینی استفاده کرده‌اند (دالیاکوپولوس و همکاران، ۲۰۰۵؛ داش و همکاران، ۲۰۱۰؛ آداموسکی و چان^۸، ۲۰۱۱، طاهرشمسی و شیخ‌الاسلامی، ۲۰۱۱؛ خلیلی و همکاران، ۲۰۱۵). بیشتر این مطالعات اشاره کرده‌اند که شبکه عصبی مصنوعی (به‌عنوان 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 مطالعه دیگر، موهنتی و همکاران (۲۰۱۵) نشان داده‌اند که مدل شبکه عصبی نتایج بهتری در زمان‌های کوتاه‌مدت نسبت به زمان‌های بلندمدت ارائه می‌دهد.

برای آموزش مدل‌های شبکه 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 ازدحام (گور^۹ و همکاران، ۲۰۱۳؛ ژی^{۱۰} و همکاران، ۲۰۱۲) و مقایسه این روش‌ها با هم (کیسی و همکاران، ۲۰۱۷) استفاده کرده‌اند.

5. Zeng

6. Acharya

7. Kisi

8. Adamowski & Chan

9. Gaur

10. Xi

1. Nayak

2. Daliakopoulos

3. Mohanty

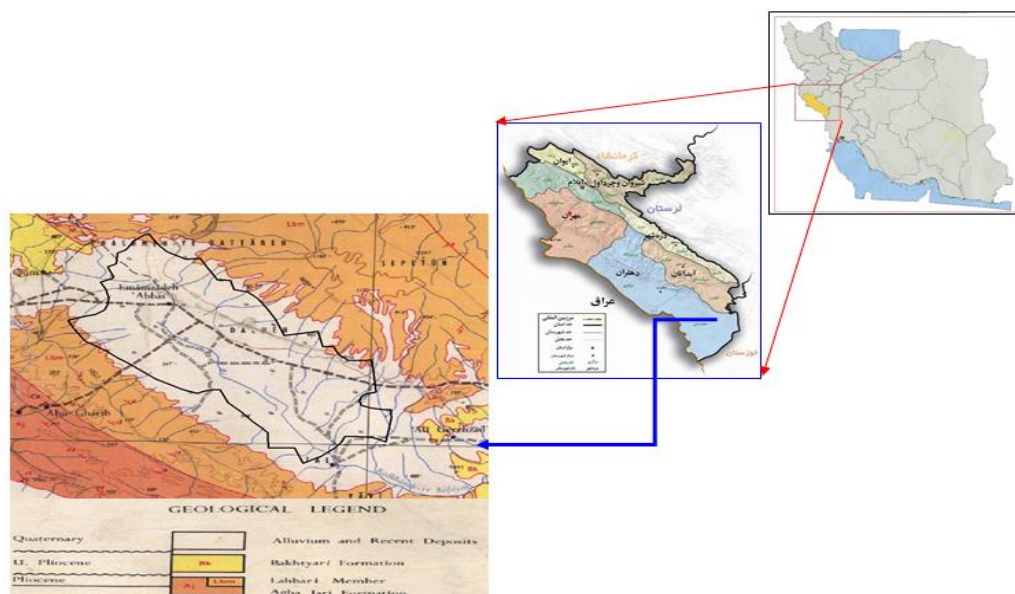
4. Affandi, Watanabe

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 ۱۳۸۵ این دشت به‌وسیله 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. به‌دلیل 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 انجام‌شده، مقاله مرتبگی 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 دقت مدل‌های ANN-PSO، ANN-ICA، ANN-GA و ANN-ACOR در تخمین ماهانه سطح آب زیرزمینی با استفاده از بارش، تبخیر و داده‌های گذشته سطح آب زیرزمینی است.

مطالعه موردی

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 استفاده‌شده در این مطالعه، سطح آب



شکل (۱): موقعیت مکانی منطقه مورد مطالعه

Figure (1): Location of the studied area

خروجی که داده‌ها را به خارج از شبکه ارسال می‌کنند؛
۲. نوروں‌های ورودی که داده‌های خارجی را دریافت می‌کنند؛
۳. نوروں‌های پنهان که نوروں‌های لایه ورودی را به نوروں‌های لایه خروجی متصل می‌کنند (سامانی و همکاران، ۲۰۰۷؛ کرمانی و همکاران، ۲۰۱۲). هر یک از نوروں‌ها یک وزن ورودی، تابع انتقال و خروجی دارد. اساساً نوروں‌ها 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 الهام‌گرفته‌شده از مغز انسان هستند که شامل واحدهای منفرد مختلف به هم متصل (نوروں) با ضرایبی (وزن‌ها) که ساختار شبکه را تشکیل می‌دهند. نوروں‌ها به‌عنوان واحدهای پردازش شناخته می‌شوند که اطلاعات را پردازش می‌کنند. سه نوع از نوروں‌ها در شبکه‌های عصبی وجود دارد: ۱. نوروں‌های

ژنتیک (GA)، بهینه‌سازی ازدحام ذرات (PSO)، الگوریتم رغبت 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 جست‌وجو 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 جست‌وجو 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

الگوریتم ژنتیک (GA)

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 برده شود. این الگوریتم‌ها یک جمعیت راه‌حل را مدیریت و دستکاری می‌کنند و جست‌وجوی خود را برای راه‌حل‌های عمده در مورد «بقای 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 پرندگان در یک گروه است. PSO روش جست‌وجوی مبتنی بر جمعیت است که

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

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

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

N تعداد داده‌ها، $GWL_{i,o}$ 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 ۰-۱ قرار می‌گیرند. این نرمال‌سازی به واسطه داده‌ها برای آموزش مدل کمک می‌کند. مقادیر سطح آب زیرزمینی، بارش، تبخیر، دمای متوسط سالانه و نفوذ مؤثر در زمان t به ترتیب به صورت GWL_t ، E_t ، P_t و Pen_t بیان شده است. ترکیب ورودی‌های مختلف در جدول (۱) ذکر شده است. برای هر مدل شبکه عصبی، طبق پیشنهاد ونگ^۵ (۱۹۹۱) و باها تاچاریا و پندارکر^۶ (۱۹۹۸) تعداد نودهای لایه پنهان برابر $2n$ (n بیانگر تعداد داده‌های ورودی) و تعداد مراحل آموزش ۲۰۰ انتخاب شده است.

جدول (۱): ترکیب ورودی‌ها

Table (1): Combine inputs

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

نتایج

آنالیز داده‌ها

آنالیز همبستگی برای تصمیم‌گیری درباره ترکیب داده‌های بهینه استفاده شده است. خودهمبستگی، خودهمبستگی جزئی و همبستگی متقابل برای داده سطح آب زیرزمینی، بارش، تبخیر، دمای متوسط سالانه و نفوذ مؤثر از تأخیر (۰-۱) و ۹۵ 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 (آتشیپز گرگری و لوکاس^۱، ۲۰۰۷؛ 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 هسته الگوریتم 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 را می‌توان در مقالات مربوط بررسی کرد (آتشیپز 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، ۱۹۹۷) ارائه شد. این روش به‌طور خاص تلاش می‌کند که رفتار تیمی کلونی مورچه‌ها را برای پیدا کردن منبع 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^۳، ۲۰۰۷؛ یو^۴ و همکاران، ۲۰۰۷).

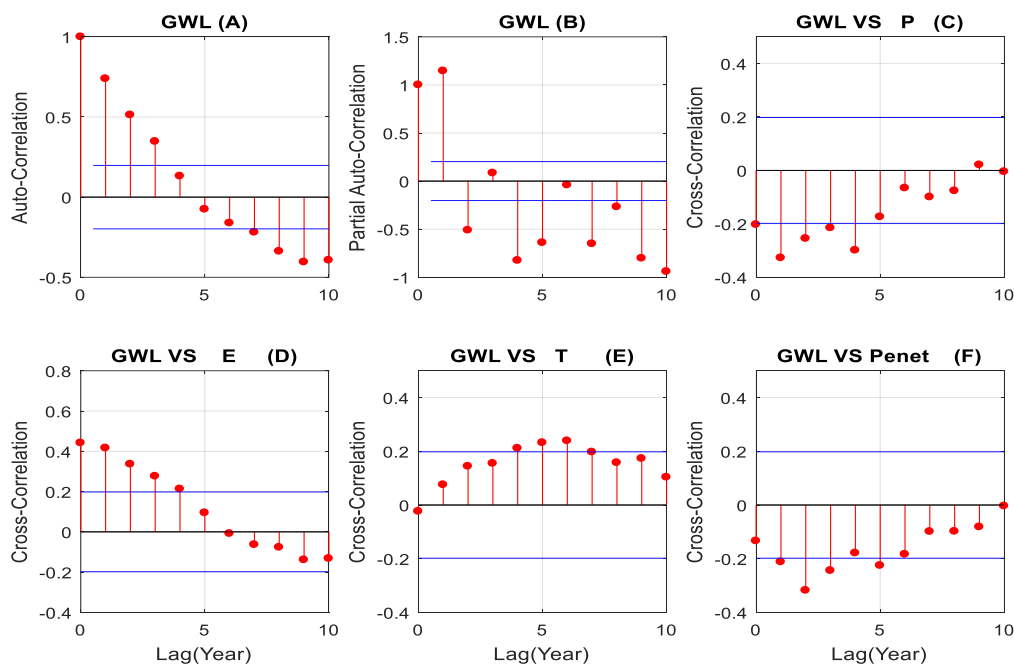
معیارهای ارزیابی و تنظیمات شبکه

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 خطا (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 به‌عنوان 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 محدوده 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 دمای متوسط 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 به‌طور 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 ۰/۰۰۵۶ تا ۰/۰۱۸۷ برای آموزش و از ۰/۰۰۳۰ تا ۰/۰۱۵۴ برای آزمایش به دست آمده است. بیشترین مقدار MSE برای مدل ANN-GA شامل ترکیب ورودی ۶ است، درحالی که مدل با ترکیب ورودی ۲ بهترین دقت در فاز آزمایش را دارد. روش انتخاب چرخه رولت به طور 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 ۰/۵ و تصادفی به ترتیب استفاده شد. برای تقاطع های ۰/۴، ۰/۵ و ۰/۶، اندازه جمعیت و انتخاب روش به ترتیب برابر ۲۰۰ و تصادفی استفاده شده است. برای روش های انتخاب، تصادفی، مسابقه ای و چرخ رولت، اندازه جمعیت و تقاطع به ترتیب برابر ۲۰۰ و ۰/۵ در نظر گرفته شده است. در جدول (۲) اعدادی که زیر آنها خط کشیده شده، نشان دهنده مقادیر کمینه MSE برای هر ترکیب ورودی و عدد رنگ شده نشان دهنده بهترین مدل ANN-GA برای تخمین سطح آب

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

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

ورودی ها	اندازه جمعیت			تقاطع			انتخاب روش		
	۲۰۰	۳۰۰	۴۰۰	۰/۴	۰/۵	۰/۶	تصادفی	تورنمنت	چرخه رولت
آموزش ۱	۰/۰۰۶۸	۰/۰۰۷۱	۰/۰۰۸۲	۰/۰۰۹۸	۰/۰۰۸۳	۰/۰۰۶۳	۰/۰۰۹۵	۰/۰۰۷۰	۰/۰۰۵۸
آزمایش ۱	۰/۰۰۸۵	۰/۰۰۹۶	۰/۰۰۶۹	۰/۰۰۶۹	۰/۰۰۸۵	۰/۰۱۰۴	۰/۰۰۵۴	۰/۰۰۶۶	۰/۰۱۵۴
آموزش ۲	۰/۰۱۰۳	۰/۰۰۶۷	۰/۰۰۷۷	۰/۰۰۷۵	۰/۰۰۷۴	۰/۰۰۷۴	۰/۰۰۹۲	۰/۰۰۷۲	۰/۰۰۷۸
آزمایش ۲	۰/۰۰۵۹	۰/۰۰۴۴	۰/۰۰۶۱	۰/۰۰۳۰	۰/۰۰۴۳	۰/۰۰۴۹	۰/۰۰۷۵	۰/۰۰۳۸	۰/۰۰۳۴
آموزش ۳	۰/۰۱۰۲	۰/۰۱۰۳	۰/۰۱۱۱	۰/۰۱۲۲	۰/۰۱۱۸	۰/۰۹۸۰	۰/۰۰۷۹	۰/۰۰۸۹	۰/۰۱۲۳
آزمایش ۳	۰/۰۰۸۴	۰/۰۰۳۵	۰/۰۰۵۰	۰/۰۰۵۰	۰/۰۰۵۱	۰/۰۰۴۵	۰/۰۰۵۲	۰/۰۰۵۰	۰/۰۰۴۳
آموزش ۴	۰/۰۰۶۲	۰/۰۰۶۱	۰/۰۱۱۳	۰/۰۰۹۵	۰/۰۰۹۵	۰/۰۰۹۵	۰/۰۰۸۱	۰/۰۰۵۶	۰/۰۰۸۶
آزمایش ۴	۰/۰۰۸۹	۰/۰۰۷۳	۰/۰۰۹۰	۰/۰۰۸۱	۰/۰۱۳۸	۰/۰۰۷۳	۰/۰۰۷۸	۰/۰۰۶۹	۰/۰۰۹۳
آموزش ۵	۰/۰۰۸۰	۰/۰۰۹۶	۰/۰۰۶۹	۰/۰۰۹۰	۰/۰۰۷۰	۰/۰۱۰۴	۰/۰۰۹۸	۰/۰۰۷۷	۰/۰۰۸۶
آزمایش ۵	۰/۰۰۸۷	۰/۰۰۷۰	۰/۰۱۱۴	۰/۰۱۰۱	۰/۰۰۶۶	۰/۰۱۰۸	۰/۰۰۷۶	۰/۰۰۹۳	۰/۰۰۸۲
آموزش ۶	۰/۰۱۸۷	۰/۰۱۲۹	۰/۰۱۲۸	۰/۰۱۷۱	۰/۰۱۳۰	۰/۰۱۳۸	۰/۰۱۴۶	۰/۰۱۴۷	۰/۰۰۹۶
آزمایش ۶	۰/۰۱۳۹	۰/۰۰۹۷	۰/۰۰۴۹	۰/۰۰۵۶	۰/۰۰۹۶	۰/۰۱۳۴	۰/۰۱۰۱	۰/۰۰۸۶	۰/۰۰۸۳

و ۲ در نظر گرفته شده است. برای ضریب سرعت اجتماعی ۲، ۳ و ۵، اندازه ازدحام و ضریب سرعت شناختی به ترتیب برابر ۲۰۰ و ۲ در نظر گرفته شده است. در جدول (۳) واضح است که محدوده MSE از ۰/۰۰۳۱ تا ۰/۰۰۹۶ برای آموزش و از ۰/۰۰۳۹ تا ۰/۰۱۵۷ برای آزمایش به دست آمده است. مقادیر بیشینه و کمینه MSE برای مدل ANN-PSO به ترتیب برای ورودی ۶ و ورودی ۲ برای فاز آزمایش به دست آمده است. این نشان می دهد که با افزایش پیچیدگی ورودی خطای مدل ANN-PSO بیشتر می شود.

شبکه عصبی مصنوعی با الگوریتم بهینه سازی ازدحام

ذرات

اندازه ازدحام متفاوت، ضرایب سرعت اجتماعی و شناختی متفاوتی برای مدل های ANN-PSO بررسی شده است. جدول (۳) میزان دقت فاز آموزش و آزمایش برای مدل ANN-PSO را گزارش می دهد. برای اندازه های ازدحام ۲۰۰، ۳۰۰ و ۴۰۰، ضرایب سرعت اجتماعی و شناختی برابر ۲ تنظیم شده است. برای ضریب سرعت شناختی ۲، ۳ و ۵، اندازه ازدحام و ضریب سرعت اجتماعی به ترتیب برابر ۲۰۰

جدول (۳): دقت MSE برای مدل‌های متفاوت ANN-PSO برای فاز آموزش و آزمایش

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

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

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 (۴) محدودهٔ MSE از ۰/۰۰۵۰ تا ۰/۰۱۰۸ برای فاز آموزش و از ۰/۰۰۲۲ تا ۰/۰۱۶۹ برای آزمایش مشاهده شده است. بیشینهٔ مقدار MSE برای مدل ANN-ICA برای ترکیب ورودی ۶ به دست آمده، درحالی‌که مدل با ترکیب ورودی ۲، بهترین دقت در فاز آموزش را نشان می‌دهد.

شبکهٔ 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 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

جدول (۴): دقت MSE برای مدل‌های متفاوت 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	
	۲۰۰	۳۰۰	۴۰۰	۲	۲/۵	۳	۰/۵
آموزش ۱	۰/۰۰۵۶	۰/۰۰۵۵	۰/۰۰۵۰	۰/۰۰۵۵	۰/۰۰۵۶	۰/۰۰۵۸	۰/۰۰۵۲
آزمایش ۱	۰/۰۰۸۹	۰/۰۰۸۳	۰/۰۰۹۳	۰/۰۰۹۱	۰/۰۰۸۸	۰/۰۰۸۵	۰/۰۰۸۹
آموزش ۲	۰/۰۰۵۴	۰/۰۰۵۳	۰/۰۰۵۷	۰/۰۰۶۳	۰/۰۰۶۱	۰/۰۰۵۹	۰/۰۰۶۰
آزمایش ۲	۰/۰۰۳۰	۰/۰۰۳۱	۰/۰۰۲۴	۰/۰۰۲۷	۰/۰۰۲۲	۰/۰۰۲۳	۰/۰۰۲۷
آموزش ۳	۰/۰۰۷۱	۰/۰۰۶۶	۰/۰۰۶۸	۰/۰۰۷۳	۰/۰۰۷۳	۰/۰۰۶۹	۰/۰۰۷۳
آزمایش ۳	۰/۰۰۵۱	۰/۰۰۶۵	۰/۰۰۶۷	۰/۰۰۶۸	۰/۰۰۴۶	۰/۰۰۷۳	۰/۰۰۵۰
آموزش ۴	۰/۰۰۶۵	۰/۰۰۵۸	۰/۰۰۵۶	۰/۰۰۷۵	۰/۰۰۶۸	۰/۰۰۵۷	۰/۰۰۷۰
آزمایش ۴	۰/۰۰۳۲	۰/۰۰۳۶	۰/۰۰۵۱	۰/۰۰۴۸	۰/۰۰۳۴	۰/۰۰۴۷	۰/۰۰۲۷
آموزش ۵	۰/۰۰۷۱	۰/۰۰۶۱	۰/۰۰۶۵	۰/۰۰۶۷	۰/۰۰۷۰	۰/۰۰۶۵	۰/۰۰۶۸
آزمایش ۵	۰/۰۰۶۳	۰/۰۰۸۰	۰/۰۰۸۵	۰/۰۰۷۷	۰/۰۰۶۹	۰/۰۰۷۴	۰/۰۰۸۷
آموزش ۶	۰/۰۱۰۶	۰/۰۰۶۰	۰/۰۰۷۰	۰/۰۱۰۶	۰/۰۰۷۱	۰/۰۰۷۸	۰/۰۱۰۸
آزمایش ۶	۰/۰۰۷۶	۰/۰۰۸۵	۰/۰۰۷۵	۰/۰۰۸۹	۰/۰۰۹۵	۰/۰۰۸۴	۰/۰۱۲۳

شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی کلونی مورچگان

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 فاکتور تشدید به ترتیب ۲۰۰ و ۰/۵ در نظر گرفته شده است. در جدول (۴) محدوده MSE از ۰/۰۰۵۴ تا ۰/۰۷۰۷ برای فاز آموزش و از ۰/۰۰۲۴ تا ۰/۰۵۰۰ برای آزمایش مشاهده شده است. بیشینه مقدار MSE برای مدل ANN-ACOR برای ترکیب ورودی ۶ به دست آمده، درحالی‌که مدل با ترکیب ورودی ۲ بهترین دقت در فاز آزمایش را نشان می‌دهد.

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 ۲۰۰، ۳۰۰ و ۴۰۰، فاکتور تشدید و نرخ انحراف به ترتیب برابر ۰/۵ و ۱ در نظر گرفته شده است. برای فاکتور تشدید ۰/۴، ۰/۵ و ۰/۶، تعداد


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

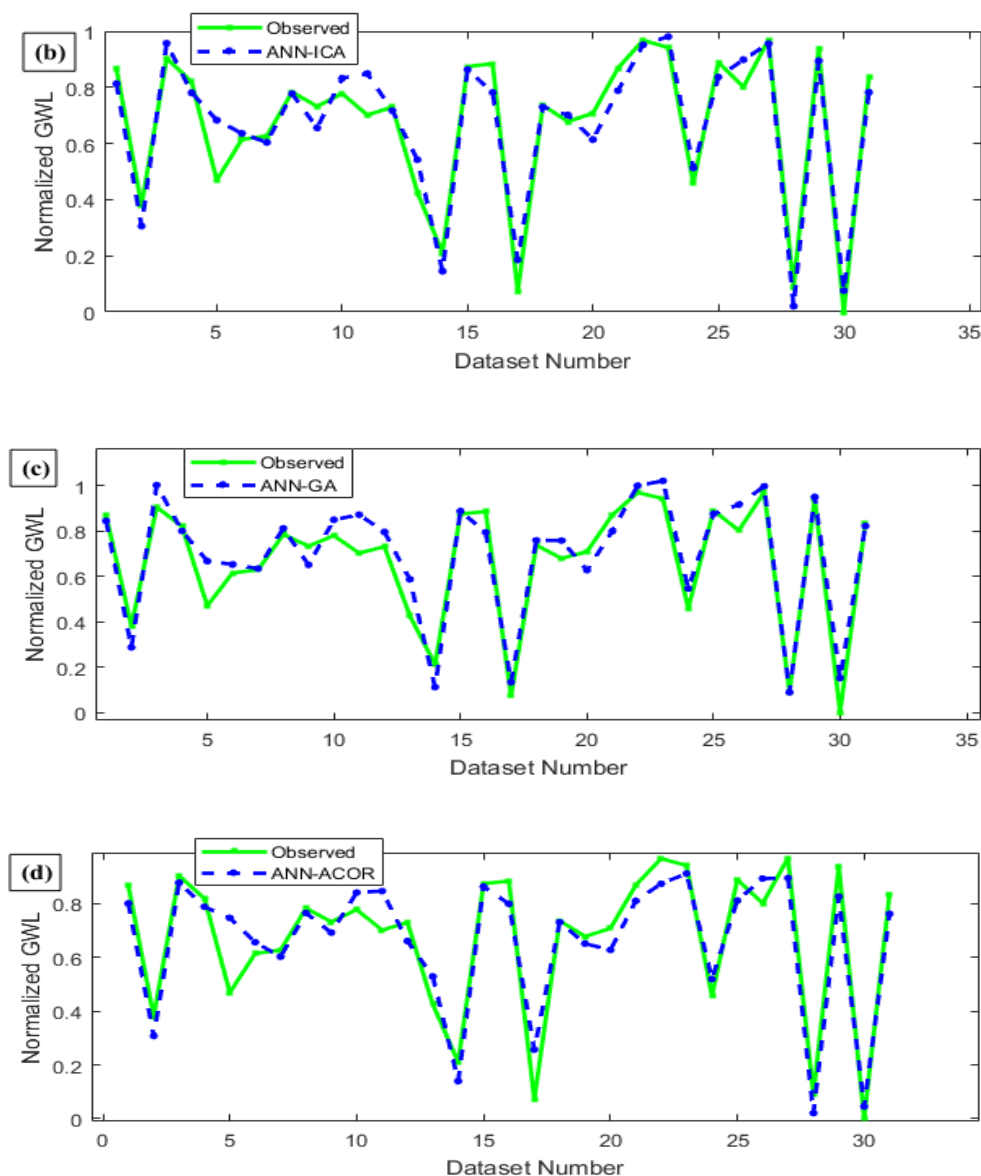
Table (5): MSE accuracy for different models of ANN-ACOR in the training and testing phase

ورودی‌ها	اندازه جمعیت			فاکتور تشدید			نرخ انحراف		
	۲۰۰	۳۰۰	۴۰۰	۰/۴	۰/۵	۰/۶	۰/۸	۰/۹	۱
آموزش ۱	۰/۰۰۷۱	۰/۰۰۹۴	۰/۰۰۹۰	۰/۰۰۸۶	۰/۰۱۰۰	۰/۰۰۹۷	۰/۰۱۰۸	۰/۰۰۹۳	۰/۰۰۹۱
آزمایش ۱	۰/۰۰۴۴	۰/۰۰۶۳	۰/۰۰۵۸	۰/۰۰۶۹	۰/۰۰۷۷	۰/۰۰۷۶	۰/۰۰۶۴	۰/۰۰۸۱	۰/۰۰۵۰
آموزش ۲	۰/۰۱۰۱	۰/۰۰۷۰	۰/۰۰۹۹	۰/۰۰۶۸	۰/۰۱۲۲	۰/۰۱۱۲	۰/۰۰۷۴	۰/۰۰۵۴	۰/۰۰۸۹
آزمایش ۲	۰/۰۰۲۴	۰/۰۰۵۳	۰/۰۰۵۲	۰/۰۰۸۱	۰/۰۰۷۸	۰/۰۰۸۷	۰/۰۱۰۱	۰/۰۱۵۰	۰/۰۱۳۹
آموزش ۳	۰/۰۰۶۵	۰/۰۰۸۳	۰/۰۰۸۵	۰/۰۱۰۱	۰/۰۱۰۴	۰/۰۰۹۰	۰/۰۱۰۴	۰/۰۰۶۳	۰/۰۰۷۹
آزمایش ۳	۰/۰۱۶۹	۰/۰۰۹۴	۰/۰۱۳۲	۰/۰۱۱۸	۰/۰۱۶۵	۰/۰۱۷۰	۰/۰۱۲۲	۰/۰۱۱۶	۰/۰۰۹۰
آموزش ۴	۰/۰۱۴۷	۰/۰۰۷۳	۰/۰۱۷۶	۰/۰۲۱۸	۰/۰۱۶۸	۰/۰۱۶۴	۰/۰۱۶۵	۰/۰۰۹۹	۰/۰۲۴۷
آزمایش ۴	۰/۰۱۴۵	۰/۰۰۹۹	۰/۰۱۵۰	۰/۰۰۵۰	۰/۰۱۰۵	۰/۰۰۹۶	۰/۰۱۰۲	۰/۰۰۵۹	۰/۰۰۶۹
آموزش ۵	۰/۰۰۵۹	۰/۰۱۱۵	۰/۰۰۷۲	۰/۰۱۵۷	۰/۰۱۱۱	۰/۰۰۹۳	۰/۰۱۶۱	۰/۰۰۸۳	۰/۰۰۶۹
آزمایش ۵	۰/۰۲۱۳	۰/۰۱۲۶	۰/۰۱۳۹	۰/۰۰۸۴	۰/۰۲۲۴	۰/۰۱۵۱	۰/۰۱۶۱	۰/۰۱۹۹	۰/۰۱۷۶
آموزش ۶	۰/۰۲۹۷	۰/۰۳۹۰	۰/۰۴۲۶	۰/۰۳۵۵	۰/۰۲۲۰	۰/۰۴۳۹	۰/۰۳۳۱	۰/۰۳۱۴	۰/۰۷۰۷
آزمایش ۶	۰/۰۱۹۹	۰/۰۲۷۹	۰/۰۳۳۳	۰/۰۲۵۶	۰/۰۲۱۴	۰/۰۵۰۰	۰/۰۳۲۰	۰/۰۲۱۱	۰/۰۴۸۵

در نهایت، ترکیب ورودی ۲ برای مقایسه روش‌ها به دلیل دارا بودن نرخ خطای کمتر انتخاب شده است. نمودارهای تناوب زمانی برای مقادیر مشاهده شده و شبیه‌سازی شده توسط مدل‌های ANN-GA، ANN-ICA، ANN-PSO و

در نهایت، ترکیب ورودی ۲ برای مقایسه روش‌ها به دلیل دارا بودن نرخ خطای کمتر انتخاب شده است. نمودارهای تناوب زمانی برای مقادیر مشاهده شده و شبیه‌سازی شده توسط مدل‌های ANN-GA، ANN-ICA، ANN-PSO و



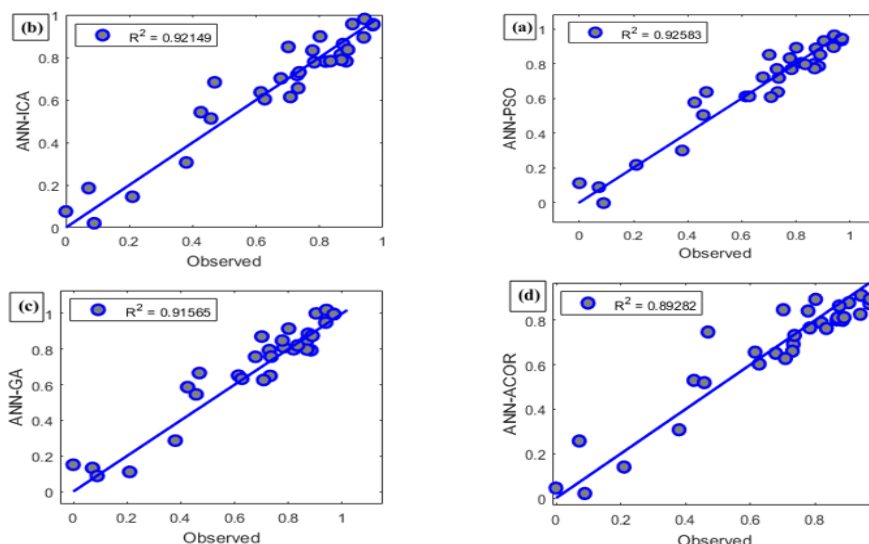


شکل (۵): نمودارهای تناوب زمانی برای مقادیر GWL مشاهده شده و شبیه‌سازی شده توسط مدل‌های ANN-PSO، ANN-ICA، ANN-GA و ANN-ACOR در دوره آموزش

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

نشان می‌دهد که این روش‌ها توانایی بالایی در تنظیم وزن‌های شبکه دارند. دلیل کارایی این روش‌ها، توازن مناسب در بررسی فضای مسئله (اکتشاف) و بهره‌برداری از جواب‌های به‌دست‌آمده (استخراج) است.

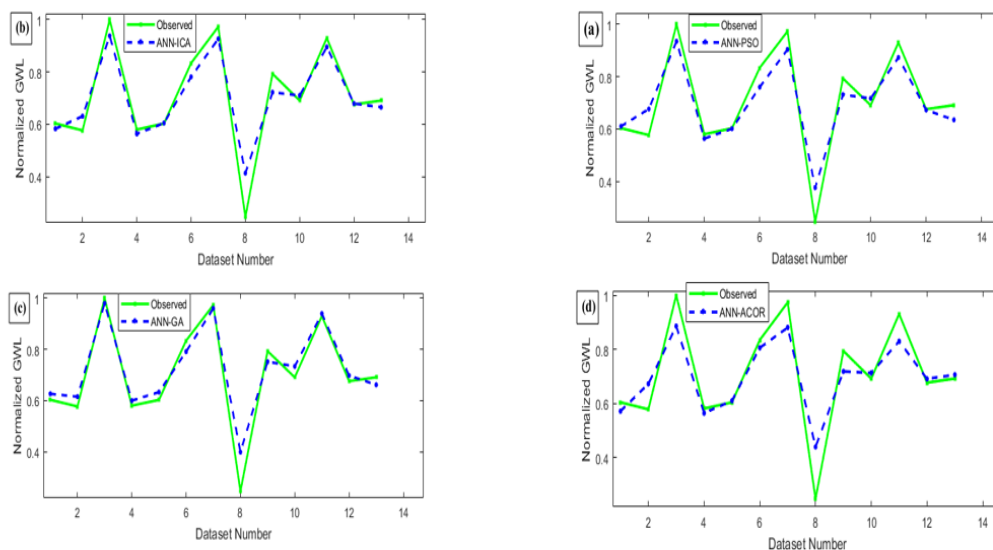
پراکنندگی نقاط شبیه‌سازی شده در فاز آموزش در شکل (۶) نشان داده شده است. با مشاهده این شکل می‌توان دریافت که توزیع انتخاب داده‌های آموزش مناسب بوده است؛ زیرا پراکنندگی نقاط در تمام محدوده قرار دارد. عملکرد آموزش روش‌های تکاملی برای شبکه عصبی پرسپترون چندلایه با توجه به ضرایب اطمینان قابل توجه



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

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

شکل (۷) تخمین مدل‌ها را در فاز آزمایش نشان می‌دهد. و ANN-ACOR در جذب بعضی از مقادیر قله‌ای داشته اگرچه همه سه مدل تخمین مناسبی دارند، مدل ANN-GA عملکرد بهتری نسبت به مدل‌های ANN-PSO، ANN-ICA عملکرد بهتری نسبت به مدل‌های ANN-PSO، ANN-ICA، ANN-PSO



شکل (۷): نمودارهای تناوب زمانی برای مقادیر GWL مشاهده شده و شبیه‌سازی شده توسط مدل‌های ANN-PSO، ANN-ICA، ANN-GA 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 برده شده در فاز آزمایش در شکل (۸) به صورت پراکنندگی نقاط نشان داده شده است. با مشاهده شکل واضح است که مدل ANN-GA تخمین پراکنندگی 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 به دست آمده، میانگین مربعات خطای مدل‌ها در بخش آزمایش به ترتیب ۰/۰۰۳۹، ۰/۰۰۳۲، ۰/۰۰۴۰ و ۰/۰۰۳۰ 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 ۰/۹۵۵۲۵، ۰/۹۴۹۲۸، ۰/۹۲۹۵۸ و ۰/۹۵۷۲۹ 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

مدل‌ها	میانگین مربعات خطا		ضریب تعیین	
	آموزش	آزمایش	آموزش	آزمایش
ANN-GA	۰/۰۰۷۵	۰/۰۰۳۰	۰/۹۱۵۶۵	۰/۹۵۷۲۹
ANN-ICA	۰/۰۰۶۱	۰/۰۰۳۲	۰/۹۲۱۴۹	۰/۹۵۵۲۵
ANN-PSO	۰/۰۰۴۵	۰/۰۰۳۹	۰/۹۲۵۸۳	۰/۹۴۹۲۸
ANN-ACOR	۰/۰۱۰۱	۰/۰۰۴۰	۰/۸۹۲۸۲	۰/۹۲۹۵۸

با توجه به نتایج داده‌ها در فاز آزمایش، عملکرد GA نسبت به الگوریتم‌های PSO، ICA 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 هر یک 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. به دلیل 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 یک به یک 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 به‌علت 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 به‌عنوان 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 مربع خطا و ضریب تعیین با همدیگر مقایسه شده است. همه چهار مدل ANN-ICA، ANN-PSO، ANN-GA، ANN-ACOR 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 (دش، ۲۰۱۰؛ جلال‌کمالی و همکاران، ۲۰۱۱)، الگوریتم رقابت استعماری (طاهرشمسی 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 ژئی و همکاران (۲۰۱۲) و گوور و همکاران (۲۰۱۳) مغایرت، ولی با تحقیقات داش و همکاران (۲۰۱۰) و جلال‌کمالی و همکاران (۲۰۱۱) مطابقت دارد.

تصادفی روبه‌رو 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 پیژومتری، سطح ایستابی دشت به‌علت خشک‌سالی و برداشت بیش از حد آب‌های زیرزمینی در سال ۱۳۷۲، ۲۱ متر گزارش شده و تا سال ۱۳۸۵ سطح ایستابی به ۲۴ متر رسیده است. در سال ۱۳۸۵ با ورود آب سد کرخه، سطح ایستابی چاه‌های پیژومتری 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 مورد مطالعه است. در شکل (۹) روند تغییرات سطح آب ایستابی مشاهده‌شده در پیژومترها با روش شبکه عصبی مصنوعی با الگوریتم ژنتیک نشان داده شده است. با توجه به شکل می‌توان دریافت که شبکه عصبی مصنوعی به‌خوبی روند افزایش و کاهش تغییرات سطح آب را تخمین زده است.



شکل (۹): مقایسه تخمین تغییرات سطح آب زیرزمینی مشاهده‌شده 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 inspires 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 Transactionson 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., Rajaei, 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 Rezaei², 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.