

## ارزیابی عملکرد مدل بهینه‌سازی شبکه پایش آب زیرزمینی بر پایه شبکه عصبی و جستجوی گرگ خاکستری (GNM) (مطالعه موردی: دشت بیرجند)

احمد جعفرزاده<sup>۱</sup>، عباس خاشعی سیوکی<sup>۲\*</sup>

تاریخ ارسال: ۱۳۹۶/۰۳/۱۴

تاریخ پذیرش: ۱۳۹۶/۱۱/۱۱

### چکیده

پایش کمی آب زیرزمینی، با هدف بررسی و تعیین عوامل مؤثر در رفتار آبخوان‌ها نقش به‌سزایی در مدیریت آب زیرزمینی هر منطقه دارد. بنابراین برای مطالعه تغییرات زمانی و مکانی سطح آب زیرزمینی، شبکه پایش کمی آب زیرزمینی مورد نیاز است. این مطالعه در نظر دارد تا به منظور پایش کمی آبخوان دشت بیرجند و تعیین نقاط بهینه پیژومترها یک روش جدید تحت عنوان Gray wolf and Neural network Monitoring (GNM) را پیشنهاد دهد. در روش پیشنهاد شده از ۲ مدل شبکه عصبی و جستجوی گرگ خاکستری به عنوان مدل شبیه‌ساز سطح آب زیرزمینی و مکان‌یابی موقعیت پیژومتر استفاده شده است. سطح آب زیرزمینی با تأخیرهای ۱ تا ۳ ماهه، ارتفاع توپوگرافی، تخلیه از آبخوان و مختصات به عنوان ورودی تخمین‌گر سطح آب زیرزمینی مدل GNM تعیین گردید. مقادیر مشاهداتی کلیه مؤلفه‌های ورودی با استفاده از ابزار درون‌یابی در محیط GIS برای کل سطح آبخوان بدست آمد. همچنین شاخص‌های RMSE و  $R^2$  به عنوان مقدار تابع هدف در این قسمت از مطالعه در نظر گرفته شد. تابع هدف در قسمت مکان‌یابی، مقدار نمائی خطا بین سطح آب زیرزمینی مشاهداتی و شبیه‌سازی شده در نظر گرفته شد. همچنین به منظور افزایش دقت و کشف نقاط بهینه جدید برنامه از روش Polytope به عنوان مدل کمکی استفاده گردید. نتایج نشان داد با توجه به مقادیر شاخص‌های ارزیابی در قسمت شبیه‌سازی سطح آب زیرزمینی مدل GNM که با استفاده از شبکه عصبی انجام شد، مدل پیشنهاد شده از کارایی مناسبی در این زمینه برخوردار است. مقدار شاخص‌های RMSE و  $R^2$  در مرحله صحت‌سنجی به ترتیب ۰/۱ و ۰/۹۹ متر بدست آمد. همچنین ارزیابی نتایج مقایسه سطح آب زیرزمینی مشاهداتی و شبیه‌سازی شده نشان داد که مدل GNM در تعیین نقاط بهینه جدید نیز از قابلیت خوبی برخوردار می‌باشد. به طوری که مقدار تابع هدف تا سقف ۰/۰۰۰۷ متر کاهش نشان داد. در نهایت موقعیت ۱۰ پیژومتر جدید در آبخوان بیرجند با استفاده از مدل GNM تعیین شد. همچنین نتایج کاربرد روش Polytope نشان داد که این روش می‌تواند تا حد قابل قبولی در کشف نقاط بهینه جدید کارایی داشته باشد. به نحوی که پیاده‌سازی این روش باعث شد که مقدار تابع هدف تا سقف ۰/۰۰۰۱ کاهش پیدا کند. دقت تخمین سطح آب زیرزمینی در شبکه پیژومتری پیشنهاد شده توسط مدل GNM برای برآورد سطح آب زیرزمینی حدفواصل سال‌های ۱۳۹۰ تا ۱۳۹۲ بررسی شد. مقدار شاخص‌های ارزیابی برای هر کدام از پیژومترهای انتخاب شده تعیین گردید. نتایج نشان داد که شبکه پیژومتری پیشنهاد شده تا حد قابل قبولی سطح آب زیرزمینی را به درستی تخمین رده است.

واژه‌های کلیدی: مکان‌یابی پیژومتر، شبکه عصبی، گرگ خاکستری، Polytope.

<sup>۱</sup> دانشجوی دکتری مهندسی منابع آب، گروه علوم و مهندسی آب، دانشگاه بیرجند، ۰۹۳۶۲۹۴۰۳۷۷، mnt.jafarzadeh@chmail.ir

<sup>۲</sup> دانشیار گروه علوم و مهندسی آب، دانشگاه بیرجند، ۰۵۶۳۲۲۵۴۰۴۱، abbaskhashei@birjand.ac.ir

## مقدمه

منابع آب زیرزمینی به عنوان یک منبع قابل توجه در مناطق خشک و نیمه خشک نظیر استان خراسان جنوبی می‌باشد. ویژگی‌های این مناطق به صورت کلی درجه حرارت بالا، بارندگی فصلی کم، تبخیر بالا و منابع آب سطحی غیر قابل اعتماد می‌باشد. در دشت بیرجند نیز همانند اکثر نقاط خشک و نیمه‌خشک، روند کاهش بارندگی و افزایش تراکم جمعیت، عملکرد پایین مصرف آب در بخش کشاورزی و وقوع خشکسالی باعث شده است تا بیشترین تمرکز برای تأمین آب مورد نیاز معطوف به آب‌های زیرزمینی گردد. در چنین شرایطی که منابع آب زیرزمینی از جایگاه بسیار مهمی برخوردار می‌باشد، لازم است تا توجه ویژه‌ای به حراست و نگهداری کمی و کیفی آبخوان صورت پذیرد (محمدی و معماریان، ۱۳۹۵).

پایش منابع آب زیرزمینی از جمله مسائل چالش برانگیز است که در آن مهندسان باید یک تصمیم مؤثر و کارا بین سازوکارهای نظام اجرایی حاکم بگیرند؛ خطرات انسانی و محیطی را نشان دهند؛ هزینه‌ها را کاهش دهند و به منافع ذینفعان توجه لازم داشته باشند (Kollat and Reed, 2005). امروزه پایش ابزاری مهم در مدیریت آب‌های سطحی و زیرزمینی محسوب می‌شود. در صورت فقدان برنامه‌ریزی پایش مناسب، امکان قضاوت علمی و مستند در مورد مدیریت منابع آب وجود نخواهد داشت (میرزائی ندوشن و همکاران، ۱۳۹۵). یکی از مؤلفه‌هایی که در پایش کمی آب زیرزمینی از اهمیت ویژه‌ای برخوردار است، سطح آب زیرزمینی می‌باشد. لذا باید این کمیت را تا حد امکان با دقت بالایی تخمین زد. (خرمدل و همکاران، ۱۳۹۴). روش‌های تجربی و فیزیکی هر دو برای تخمین سطح آب زیرزمینی دارای محدودیت‌هایی می‌باشند. روش‌های تجربی از آنجا که مبتنی بر روابط خطی بین بارش و سطح آب زیرزمینی می‌باشند، زمانی که آبخوان دارای تغییرات زیادی باشد دقت کافی را برای تخمین ندارند. همچنین روش‌های فیزیکی به دلیل وابستگی بسیار زیاد به داده‌های آب زیرزمینی عمدتاً روش‌های گران و کم کاربرد در مناطق خشک

خواهند بود (Coulibaly et al, 2001). از این رو بهره‌گیری از روش‌های پیشرفته در این امر، می‌تواند کمک شایانی را در جهت بهبود شناخت سامانه-های آب زیرزمینی داشته باشد. همچنین در بیشتر موارد تصمیم گیرندگان نیاز چندانی به رسیدن به جواب بهینه مطلق در یک مسئله دنیای واقعی ندارند و تنها با یک جواب خوب قادر به تصمیم‌گیری می‌باشند، از این رو استفاده از روش‌های تقریبی در حل مسائل بهینه‌سازی به طور چشم‌گیری افزایش یافته است (بزرگ حداد، ۱۳۸۴). در این میان استفاده از روش‌های فراکاشی و تکاملی به عنوان یک ابزار سودمند، در بهینه‌سازی شبکه پایش آب‌های زیرزمینی توسعه داشته است. به دلیل اهداف متنوعی که در پایش آب‌های زیرزمینی وجود دارد، مطالعات بهینه‌سازی شبکه پایش به صورت تک و یا چند هدفه انجام می‌شود. همچنین می‌توان مطالعات پایش آب‌های زیرزمینی را در دو دسته کمی و کیفی تقسیم‌بندی نمود که در ادامه به بیان روش کار و یافته‌های بعضی از این مطالعات اشاره می‌شود. به عنوان مثال در یک پژوهش، (Cieniawski et al, 1995) با اسفاده از الگوریتم ژنتیک اقدام به تعیین محل چاه‌های پایش آب زیرزمینی نمودند تا اهداف حداکثر اعتمادپذیری و حداقل نواحی آلوده شده در تشخیص اولیه را مورد بررسی قرار دهند. در این مطالعه تعداد ۱۶۲ موقعیت برای انتخاب چاه‌های پایش در نظر گرفته شد و در نهایت مقادیر جبهه پارتو برای تعداد ۴ و ۵ چاه پایش ارزیابی شد. نتایج مطالعه آن‌ها نشان داد که متناسب با شرایط در نظر گرفته شده، مقدار اعتمادپذیری بین ۴۸ تا ۹۰ درصد و سطوح آلوده به آلاینده‌ها بین ۳/۵ تا ۱۴/۵ هکتار متغیر می‌باشد. در مطالعه Kollat and Reed, (2005) کاربرد الگوریتم NSGAI<sup>1</sup> را در پایش کیفی آب زیرزمینی مورد بررسی قرار دادند. در این مطالعه که به صورت آزمایشگاهی در آزمایشگاه ملی لورنس لیورمور ایالت کالیفرنیا کشور آمریکا<sup>2</sup> انجام شده است، آلاینده PCE<sup>3</sup> از تانک زیرزمینی نشت پیدا

1 non-dominated sorted genetic algorithm-II

2 Lawrence Livermore National Laboratory, California State, US

3 perchloroethylene

انتقال آلودگی MT3D مبادرت به مکان‌یابی محل چاه‌های پایش آب‌های زیرزمینی نمودند. هدف مطالعه مذکور تشخیص به موقع نشت آلودگی از محل توزیع سوخت گازولین در سایت گرانجر ایالت ایندیانا<sup>4</sup> در کشور آمریکا می‌باشد. در نهایت تعداد ۳۲ محل بهینه برای حفر چاه پایش پیشنهاد گردید که مقدار تابع هدف در جبهه پرتو نرخ هزینه بین ۱۰ تا ۶۵ درصد و تابع هدف خطای جرم آلاینده بین صفر تا ۳۰ درصد متغیر است. همچنین نتایج نشان داد مادامی که گزینه‌های با هزینه کم انتخاب شود، مقدار خطای برآورد جرم آلاینده زیاد خواهد بود. میرزائی ندوشن و همکاران (۱۳۹۵) با استفاده از الگوریتم NSGII اقدام به مکان‌یابی چاه‌های پیژومترهای نمودند. توابع هدف در این مطالعه حداقل‌سازی تعداد چاه‌های پیژومتری و حداقل نمودن خطای تخمین می‌باشد. تعداد ۳۱۱ نقطه در آبخوان اشتهاارد به عنوان نقاط پتانسیل به الگوریتم NSGII معرفی شد. همچنین مقدار سطح آب زیرزمینی مشاهداتی با استفاده پیژومترهای واقعی و ابزار درون‌یابی در محیط GIS برای نقاط پتانسیل درون‌یابی شد. مکان‌یابی با استفاده از الگوریتم NSGII شد و متغیر تصمیم تعداد چاه‌های پیژومتری در نظر گرفته شد.

بررسی منابع نشان می‌دهد که در بعضی از پژوهش‌های انجام شده در حوضه منابع آب، به دلیل پیچیدگی محاسبات، حجم زیاد داده‌های مورد نیازمند و زمان‌بر بودن پیاده‌سازی مدل‌های مفهومی، عددی و تحلیلی، سعی بر این شده است تا با استفاده از روش‌های جانشین (نظیر روش‌های داده‌محور)، فرآیند بهینه‌سازی بهبود یابد. استفاده از روش‌های جانشین (کمکی) می‌تواند باعث افزایش سرعت همگرایی و کشف نقاط جدید برای مدل بهینه‌ساز در تکرارهای بالا گردد (Guyaguler et al 2002). همچنین کاربرد این روش‌های در کنار مدل‌های عددی موجب کاهش زمان محاسبات می‌شود. چراکه در این حالت بخشی از فرآیند شبیه‌سازی بر عهده روش کمکی می‌باشد

نموده است، و هدف الگوریتم NSGAI کاهش هزینه، کاهش خطای برآورد غلظت آلاینده و کاهش خطای تخمین بار آلودگی می‌باشد. تعداد ۲۹ چاه در مسیر جریان وجود دارد که جبهه پارتو<sup>۱</sup> برای حالات ۱۸ تا ۲۵ چاه پایش به دست آمده است. نتایج مطالعه آن‌ها نشان داد که الگوریتم NSGAI در تمامی حالات در نظر گرفته شده می‌تواند متناسب با توابع هدف، گزینه‌های مختلفی را برای محل چاه‌های پایش ارائه دهد. همچنین نتایج نشان داد که با افزایش تعداد متغیر تصمیم (تعداد چاه‌های پایش)، محاسبات و زمان به صورت فزاینده‌ای افزایش می‌یابند. عملکرد الگوریتم‌های  $GA^2$ ,  $SA^3$ , TABU, Polytope توسط Lee and Ellis, (1996) در یک مسأله بهینه سازی غیرخطی صحیح مورد مقایسه قرار گرفته و نتیجه گردید که الگوریتم‌های ابتکاری برای حل مسایل طراحی شبکه پایش آب زیرزمینی رضایت بخش می‌باشند. در مطالعه‌ای Li and Hilton, (2005) از روش بهینه‌سازی جامعه مورچگان برای حل مسأله بهینه‌سازی طراحی شبکه پایش آب زیرزمینی استفاده نمودند. در این تحقیق نیز ضمن بررسی غلظت یک آلاینده در شبکه پایش کیفی، به بهینه‌سازی مکانی شبکه اکتفا شده است. مقایسه عملکرد الگوریتم‌های فراابتکاری در بهینه‌سازی شبکه پایش آب‌های زیرزمینی توسط Kollat and Reed, (2005) انجام شد. بررسی توانمندی الگوریتم NSGAI در ارضا نمودن توابع هدف حداقل نمودن هزینه نمونه‌برداری، حداکثر نمودن دقت نقشه‌برداری و حداقل نمودن خطای تخمین جرم آلاینده در این مطالعه خود انجام شده است. عملکرد الگوریتم براساس معیارهای ارزیابی همگرایی، تنوع جواب‌ها و انحراف جبهه پرتو مورد ارزیابی قرار گرفت. نتایج مطالعه آن‌ها بر اعتمادپذیری و عملکرد بالای این الگوریتم در پیدا نمودن چاه‌های پایش آب زیرزمینی دلالت دارد. در مطالعه‌ای دیگر Luo et al, (2016) با استفاده از الگوریتم ژنتیک چند هدفه و مدل جریان

1 Pareto

2 Genetic Algorithms (GA)

3 Simulated Annealing (SA)

4 Granger, Indiana State of US

## مواد و روش‌ها

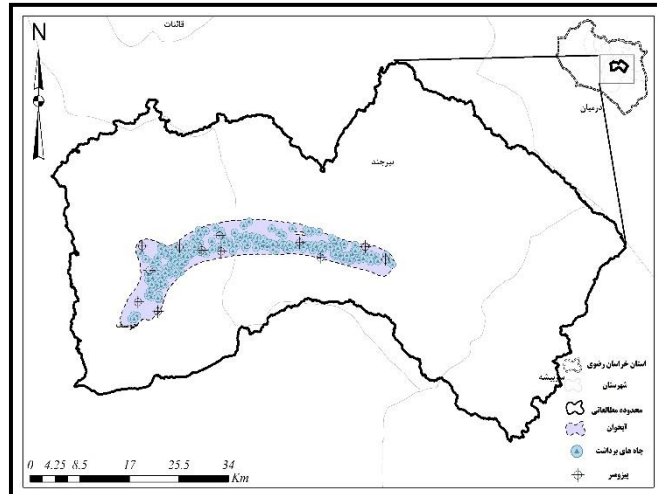
### معرفی منطقه مورد مطالعه

شهرستان بیرجند مرکز استان خراسان جنوبی در شمال رشته کوه‌های باقران و در محدوده‌ی ۵۹ درجه و ۱۳ ثانیه طول جغرافیایی و با ۳۲ درجه و ۵۳ ثانیه عرض جغرافیایی قرار گرفته است. وسعت این شهر ۴۲/۷ کیلومتر مربع، دارای ۲ بخش و ۱۰ دهستان می‌باشد. میانگین حداقل و حداکثر دمای سالیانه بیرجند به ترتیب ۸ و ۲۴ درجه سانتی‌گراد است. بارش سالانه ۱۵۲ میلی‌متر و ارتفاع از سطح دریا ۱۴۹۱ متر می‌باشد. میزان تبخیر پتانسیل دشت بیرجند ۱۷۴۵/۳۸ میلی‌متر برآورد شده است (جعفرزاده و همکاران، ۱۳۹۵). شکل (۱) جزئیات بهتری از موقعیت دشت بیرجند را ارائه می‌دهد.

( Koziel and Leifsson 2013; Razavi et al, )  
(2012).

استفاده از مدل‌های جانشین در بعضی از مطالعات مکان‌یابی که با هدف پایش آب زیرزمینی انجام شده‌اند نیز وجود دارد. به عنوان مثال بهینه‌سازی مکان‌یابی حفر چاه تغذیه جهت افزایش نرخ پمپاژ چاه‌های نفت موضوع مطالعه Guyaguler et al, (2002) می‌باشد. آن‌ها در این پژوهش میدانی جهت تعیین مکان بهینه حفر چاه تغذیه در خلیج مکزیک<sup>۱</sup> از الگوریتم ژنتیک بهره گرفته‌اند. همچنین مدل‌سازی جریان آب زیرزمینی با توجه به موقعیت چاه‌های تغذیه‌ای پیشنهادی توسط مدل MODFLOW عملی شده است. به دلیل زیاد بودن حجم محاسبات و تعداد جمعیت الگوریتم و همچنین کمک به کشف نقاط جدید از ۲ روش کمکی شبکه عصبی و درون‌یابی کریجینگ در کنار مدل جریان آب زیرزمینی بهره گرفته شد. در مطالعه‌ای دیگر Johnson & Rogers, (2000) کیفیت نتایج بدست آمده برای مسئله اصلاح آبخوان را در دو حالت حل تحلیلی و ترکیب آن با شبکه عصبی و تقریب‌های خطی بررسی نمودند. نتایج مطالعه آن‌ها نشان داد که کیفیت جواب‌های بدست آمده از حالت دوم بسیار بهتر از حالت اول می‌باشد.

مطالعه پیش‌رو در نظر دارد تا با هدف صرفه‌جویی اقتصادی اقدام به مکان‌یابی محل پیژومترهای جدید برای آبخوان دشت بیرجند نماید. بررسی منابع ارائه شده در فوق نشان می‌دهد که مطالعات زیادی بر روی عملکرد الگوریتم‌های جدید فراابتکاری در مقوله مکان‌یابی انجام نشده است. همچنین با توجه به کاربرد مدل‌های کمکی در حل مسائل بهینه‌سازی، کمتر مطالعه‌ای در داخل کشور اقدام به استفاده از روش Polytope به عنوان مدل جانشین نموده است. مطالعه پیش‌رو جهت تخمین مناسب سطح آب زیرزمینی و مکان‌یابی محل پیژومترها مدل GNM را پیشنهاد نموده است. در این مدل مکان‌یابی محل پیژومترها با استفاده از الگوریتم گرگ خاکستری و تخمین سطح آب با استفاده از شبکه عصبی انجام می‌شود.



شکل (۱): موقعیت محدوده مطالعاتی بیرجند


## آماده‌سازی داده‌ها

به منظور بررسی تغییرات سطح آب زیرزمینی، از آمار مشاهداتی سطح آب زیرزمینی تعداد ۱۲ پیزومتر در آبخوان دشت بیرجند حدفصل سال‌های ۱۳۹۰ تا ۱۳۹۳ استفاده شد (جدول ۱). موقعیت این پیزومترها بر روی شکل (۱) نیز مشخص شده است.

از آنجا که هدف مکان‌یابی پیزومترهای جدید در آبخوان می‌باشد، در ابتدا سطح آبخوان به شبکه‌هایی با فواصل عمودی و افقی ۵۰۰ در ۵۰۰ تقسیم‌بندی شد. حسب این تقسیم‌بندی تعداد ۱۰۵۴ نقطه پتانسیل در مرکز این شبکه‌ها و در سطح آبخوان ایجاد گردید. در این پژوهش و با استناد به نتایج مطالعه محتشم و همکاران (۱۳۸۹) میزان تخلیه و سطح آب زیرزمینی به عنوان ورودی‌های به مدل شبکه عصبی تعیین گردید. همچنین به منظور در نظر گرفتن وضعیت توپوگرافی منطقه، ارتفاع نقاط نیز به عنوان یکی از ورودی‌ها به مدل شبکه عصبی در نظر گرفته شد. در نهایت سعی شد تا مقدار متغیرهای ورودی به شبکه عصبی با استفاده از ابزار درون‌یابی در محیط GIS برای نقاط شبکه‌بندی شده آبخوان (شکل ۲) بدست آید. به بیان دیگر مقادیر مشاهداتی سطح آب زیرزمینی مهر، شهریور، مرداد و تیر ماه سال آبی ۱۳۹۳ به همراه تخلیه از آبخوان (بر اساس چاه‌های برداشت) و ارتفاع توپوگرافی برای هر کدام از نقاط شکل (۲) به دست آمد و به عنوان بانک داده برای ورود به شبکه عصبی تعیین گردید.

جدول (۱): پیزومترهای انتخابی در آبخوان دشت بیرجند

محل پیزومترها	UTMX	UTMY	TARAZ (m)	درصد پوشش
تقاب	۶۸۰۹۴۹	۳۶۳۸۲۲۷	۱۳۱۰/۸۱	۸/۴۸
جنوب	۷۰۱۵۳۴	۳۶۳۸۹۷۰	۱۳۶۳/۸۴	۱۷/۴۷
خوسف	۶۷۷۲۳۰	۳۶۲۷۸۳۶	۱۲۹۸/۹	۴/۰۵
راه سیوجان	۶۸۴۷۷۳	۳۶۳۷۶۹۵	۱۳۵۲	۶/۳۷
راه شهنة	۶۷۵۷۹۵	۳۶۳۴۵۲۸	۱۳۴۴	۱۰/۴۳
شمال	۶۷۴۴۹۹	۳۶۳۸۳۸۳	۱۳۰۸/۰۵	۴/۰۵
شمال	۶۸۷۷۹۰	۳۶۴۰۱۱۹	۱۳۷۸/۷۱	۱۱/۸۳
شوکت‌آباد	۷۱۲۸۰۰	۳۶۳۸۳۰۰	۱۴۹۶/۹۵	۷/۸۰
غرب بجد	۷۶۱۲۵۶	۳۶۳۶۲۳۹	۱۵۴۳	۵/۲۸
غرب	۶۸۸۰۵۸	۳۶۳۷۵۴۲	۱۳۸۶	۷/۳۳
کنار سپاه	۷۰۵۱۰۶	۳۶۳۶۵۴۸	۱۵۳۷	۷/۷۶
نصرآباد،	۶۷۳۸۰۲	۳۶۲۹۳۶۱	۱۲۹۱/۰۱	۹/۱۵



شکل (۲): مجموعه نقاط شبکه آبخوان

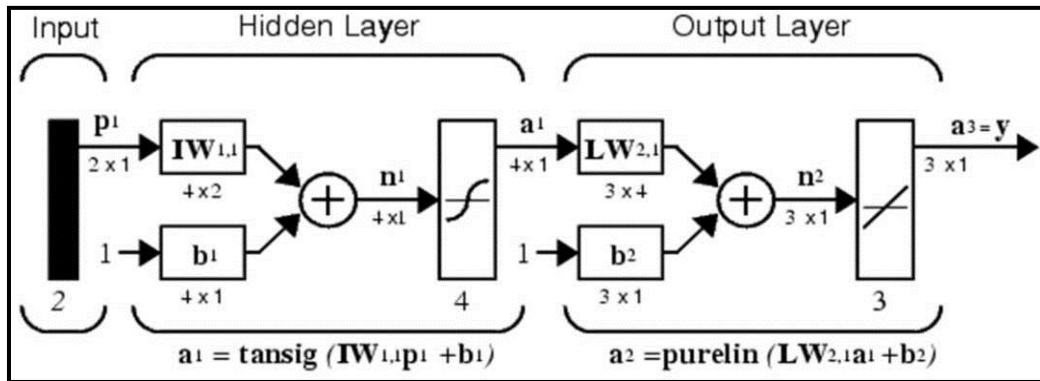
جمع می‌کند و حاصل به تابع محرکه انتقال داده می‌شود تا به این وسیله به نرون‌های لایه بعد انتقال داده شود. این عمل در نرون‌های همه لایه‌های شبکه انجام می‌شود تا در نهایت خروجی شبکه به دست آید.

#### شبکه پرسپترون چند لایه

در شبکه عصبی پرسپترون چند لایه با الگوریتم پس انتشار خطا، مدل شبکه عصبی در لایه پنهان از تابع محرکه تانژانت سیگموئید (tansig) و در لایه خروجی از تابع محرکه خطی (purelin) استفاده می‌نماید و تابع یادگیری وزن‌ها تابع لونیبرگ-مارکوارت (trainlm) می‌باشد. در این شبکه‌ها اطلاعات ورودی توسط نرون‌های ورودی دریافت شده، سپس به نرون‌های لایه پنهان فرستاده می‌شود و پردازش مورد نظر روی آن‌ها انجام می‌گیرد و نتیجه به نرون‌های لایه خروجی فرستاده شده تا به عنوان خروجی شبکه نمایش داده شوند. شکل (۳) نمونه‌ای از یک شبکه پرسپترون چندلایه را نشان می‌دهد.

#### شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی، برای اولین بار در سال ۱۹۴۳ توسط مک کولاک و پیتس معرفی شد (McCulloch and Pitts, 1943)، اما این روش برای مدت‌های طولانی بدون استفاده بود که بعدها با توسعه رایانه‌ها و همچنین ظهور الگوریتم آموزش پس انتشار خطا (Rumelhart et al, 1986) استفاده از آن‌ها وارد مرحله تازه‌ای گردید. شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده است و مانند مغز انسان به پردازش اطلاعات می‌پردازد. این سیستم از عناصر زیادی به نام نرون تشکیل شده است که برای حل یک مسئله به صورت هماهنگ عمل می‌کنند. یک نرون کوچکترین واحد پردازش‌گر اطلاعات است، که اساس عملکرد شبکه عصبی را تشکیل می‌دهد. هر شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی تشکیل شده است. هر لایه توسط وزن‌ها به نرون‌های لایه بعد متصل می‌شود. هر نرون مقادیر ورودی را در وزن خود ضرب کرده و با انحراف



شکل (۳): ساختار شبکه عصبی پرسپترون چندلایه

شبکه عصبی داده‌های موجود در نقاط شبکه‌بندی شده آبخوان (۱۰۵۴ نقطه شبکه آبخوان) به ۳ قسمت آموزش، صحت‌سنجی و آزمایش با نسبت ۷۰، ۱۵ و ۱۵ درصد تقسیم شد. همچنین ۴ مؤلفه مختصات، ارتفاع توپوگرافی، تخلیه و سطح آب زیرزمینی سه ماه قبل بر روی نقاط شبکه‌بندی سطح آبخوان (شکل ۲) به عنوان ورودی و سطح آب زیرزمینی برای انتهای سال آبی ۱۳۹۳ به عنوان خروجی شبکه عصبی در نظر گرفته شد. از آنجا که وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود، لازم است تا به منظور یکسان کردن ارزش داده‌ها برای شبکه عصبی، عمل نرمال‌سازی داده‌ها صورت پذیرد. این کار مانع کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نرون‌ها می‌گردد (Zhang and Sun, 2009).

$$X_n = 0.8 \times \left( \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \right) + 0.1 \quad (1)$$

که در این رابطه  $X_n$  مقدار داده نرمال شده،  $X_i$  مقدار داده مشاهده‌ای،  $X_{\max}$  و  $X_{\min}$  به ترتیب معرف مقادیر حداکثر و حداقل در داده‌های مشاهداتی می‌باشند. همچنین توابع لونبرگ-مارکوورت (trainlm) و محرکه تانژانت سیگموئید (tansig) به ترتیب به عنوان توابع یادگیری و آموزش لایه پنهان در کنار الگوریتم پس انتشار خطا در این مطالعه استفاده شد. بعد از نرمال‌سازی و جداسازی داده‌ها به آموزش، صحت‌سنجی و آزمایش، کد برنامه شبکه عصبی برای ۵۰ بار اجرا می‌شود تا در نهایت براساس شاخص‌های

### انتخاب بهترین آرایش شبکه

اساس آموزش شبکه‌های عصبی بر مبنای آزمون و خطا می‌باشد تا بهترین آرایش شبکه با تغییر ساختار آموزشی جهت تخمین خروجی مورد نظر حاصل گردد (ایزدی و همکاران، ۱۳۸۶). در این مقوله معیار ارزیابی برای انتخاب شبکه عصبی برتر، توانمندی شبکه در برآورد نمودن معیارهای ارزیابی می‌باشد.


پژوهش‌های انجام شده نشان می‌دهند که شبکه عصبی توانایی قابل قبولی برای مدل‌سازی آب‌های زیرزمینی دارا می‌باشد. در نخستین کاربردهای شبکه عصبی در مدل‌سازی آب‌های زیرزمینی پژوهشگران کاربرد آن را در تعیین نقشه‌های هدایت هیدرولیکی (Ranjithan et al., 1995)، پیش‌بینی آب محبوس در سازندها (Schaap and Bouten, 1996) و تخمین مؤلفه‌های آبخوان (Lebron et al., 1999) بررسی نمودند. مطالعه Coulibaly et al, 2001 از جمله نخستین پژوهش‌های ارزیابی کاربرد شبکه عصبی در تخمین سطح آب زیرزمینی به شمار می‌رود. در سال‌های اخیر مطالعات گسترده‌ای ارزیابی عملکرد شبکه عصبی مصنوعی را در پیش‌بینی و شبیه‌سازی سطح آب زیرزمینی بررسی نموده‌اند که اکثر این مطالعات به موفقیت و قابلیت خوب شبکه عصبی در مدل‌سازی سطح آب زیرزمینی اشاره نموده‌اند (Taormina 2012; Shiri et al, 2013; Rezaeianzadeh et al, 2015).

در این پژوهش به منظور تخمین سطح آب زیرزمینی در آبخوان دشت بیرجند از مدل شبکه عصبی استفاده شد. در این مطالعه به منظور اجرای

گرفت. در ادامه مراحل اصلی این الگوریتم مورد بحث قرار می‌گیرد.

### الگوریتم بهینه‌سازی GWO

به دلیل اینکه در طبیعت حیات وحش شکارچی طبیعی برای گرگ خاکستری (Gray Wolf) وجود ندارد، این حیوانات به عنوان بالاترین سطح شکارچیان حیات وحش در نظر گرفته می‌شوند. سلسله مراتب اجتماعی دسته گرگ‌ها در شکل (۴) نشان داده شده است. رهبران که به عنوان آلفا شناخته می‌شوند وظیفه تصمیم‌گیری در مورد شکار، محل استراحت، زمان ادامه حرکت و سایر مسائل را دارا می‌باشند. گرگ‌های آلفا بهترین گرگ از نظر مدیریت گروه می‌باشند. دومین گروه از سلسله مراتب گرگ‌های خاکستری، مربوط به بتا می‌باشد. این گرگ‌ها در تصمیم‌گیری به کمک گرگ‌های آلفا می‌آیند. گرگ‌های امگا پایین مرتبه در سلسله مراتب گرگ‌ها را دارا می‌باشند و ناگزیرند که در صورت نیاز به دسته‌های بالاتر ملحق شوند. گرگ‌هایی که در دسته سوم از این مراتب هستند، جزء دسته دلتا می‌باشند (Mirjalili et al, 2016).



شکل (۴): سلسله مراتب موجود در جمعیت گرگ‌های خاکستری

گرگ‌های اول تا سوم از حیث ارزش‌مندی مکان طعمه، به ترتیب به عنوان آلفا، بتا و دلتا نامیده می‌شوند. مابقی اعضای جمعیت گرگ‌های خاکستری در نقش گرگ‌های عادی ظاهر می‌شوند. لازم است تا در گام بعدی الگوریتم کل اعضای جمعیت تغییر مکان پیدا

ارزیابی بهترین شبکه عصبی ساخته شده برای تخمین ارتفاع سطح آب زیرزمینی تعیین گردد. روابط (۲) و (۵) شاخص‌های ارزیابی مورد استفاده برای بررسی عملکرد شبکه عصبی را نشان می‌دهند.


$$RMSE = \sqrt{\frac{\sum_i^n (S_i - O_i)^2}{n}} \quad (2)$$

$$R^2 = \frac{\sum_i^n (O_i - \bar{O}) \times \sum_i^n (S_i - \bar{S})}{\sum_i^n (O_i - \bar{O})^2 \times \sum_i^n (S_i - \bar{S})^2} \quad (3)$$

$$MAE = \frac{\sum_i^n (S_i - O_i)}{n} \quad (4)$$

$$Pbias = \frac{\sum_i^n (S_i - O_i)}{\sum_i^n O_i} \quad (5)$$

که در آن  $S_i$  و  $O_i$  به ترتیب سطح آب زیرزمینی (بر حسب متر) شبیه‌سازی شده (توسط شبکه عصبی) و مشاهداتی را نشان می‌دهند. پس از آماده‌سازی شبکه عصبی به عنوان تخمین‌گر سطح آب زیرزمینی، در اقدام بعدی پیاده‌سازی الگوریتم GWO به منظور مکان‌یابی محل پیزومترهای جدید در دستور کار قرار



این الگوریتم نیز همانند سایر الگوریتم‌های فراابتکاری با تولید جمعیت اولیه در فضای تصمیم شروع می‌شود. بعد از تشکیل اعضای جمعیت و مکان‌یابی اولیه آن‌ها لازم است تا ارزش هر کدام از گرگ‌ها (متناسب با مکان انتخاب شده) تعیین گردد.



مؤلفه‌های ورودی به مدل شبکه عصبی در کنار مختصات مشخص شده است. به منظور تخمین سطح آب زیرزمینی برای انتهای سال آبی ۱۳۹۳ (مهر ماه)، مدل GNM، شبکه عصبی ساخته شده را فراخوانی نموده تا سطح آب زیرزمینی را برای ۱۰ پیرومتر انتخاب شده (توسط هر کدام از اعضای جمعیت گرگ‌ها) برآورد نماید. پس از برآورد سطح آب زیرزمینی برای پیرومترهای هر عضو از جمعیت (و محاسبه مقدار میانگین آن‌ها)، لازم است تا در گام بعدی مقدار تابع هدف اعضای جمعیت گرگ‌ها طبق معادله (۹) تعیین شود:

$$E = \text{absolute}(\text{observe} - \text{simulate}) \quad (9)$$

$$\text{Fitness} = 1 - \exp(-E)$$

در معادله فوق *observe* و *simulate* به ترتیب میانگین سطح آب زیرزمینی مشاهداتی (مهرماه ۱۳۹۳) و شبیه‌سازی شده می‌باشند. سطح آب زیرزمینی مشاهداتی با استفاده از میانگین وزنی سطح آب پیرومترهای فعلی آبخوان (جدول ۱) بدست آمد. همچنین وزن هر کدام از پیرومترهای فعلی آبخوان با استفاده از تیسس بندی و در محیط GIS بدست آمد. همچنین *E* و *Fitness* به ترتیب خطای تخمین و مقدار تابع هدف هر کدام از اعضای الگوریتم می‌باشند. در مطالعات Luo et al, (1995) و Cieniawski et al, (2016) نیز از خطای تخمین به عنوان تابع هدف استفاده شده است. بازه تغییرات تابع هدف انتخاب شده بین صفر و ۱ تغییر می‌کند و خطای (*E*) بیشتر از ۲/۳ متر باعث می‌شود تا مقدار تابع هدف (*Fitness*) به سمت ۱ میل کند. اعمال این تابع هدف مخصوصاً برای تخمین سطح آب زیرزمینی باعث می‌شود تا الگوریتم با سخت‌گیری بسیار بالایی نسبت به جستجو و کشف نقاط بهینه اقدام نماید. گام بعدی مدل GNM طبق الگوریتم جستجوی گرگ، تعیین ذرات برتر آلفا، بتا و دلتا می‌باشد. با تعیین این ذرات الگوریتم گرگ وارد حلقه اصلی خود شده و متناسب با روابط جهش (معادلات ۶ الی ۸) طی چندین تکرار به دنبال بهترین مکان پیرومتر خواهد بود. بدین ترتیب دقت شبکه پیرومتری هر کدام از ذرات جمعیت الگوریتم تعیین

نمایند. از تغییر مکان در الگوریتم‌ها تحت عنوان جهش یاد می‌شود. تغییر مکان در گرگ‌های عادی متناسب با مکان‌های گرگ‌های دسته بالاتر صورت می‌پذیرد. معادلات (۶) الی (۸) چگونگی این تغییر مکان را نشان می‌دهد (Mirjalili et al, 2016).

$$\begin{cases} \overrightarrow{D_\alpha} = |C_1 \times X_\alpha - X| \\ \overrightarrow{D_\beta} = |C_2 \times X_\beta - X| \Rightarrow C_t = 2 \times r_1 \\ \overrightarrow{D_\delta} = |C_3 \times X_\delta - X| \end{cases} \quad (6)$$

$$\begin{cases} X_1 = X_\alpha - A_1 \times \overrightarrow{D_\alpha} \\ X_2 = X_\beta - A_2 \times \overrightarrow{D_\beta} \Rightarrow A_t = 2 \times a \times r_2 - a \\ X_3 = X_\delta - A_3 \times \overrightarrow{D_\delta} \end{cases} \quad (7)$$

$$X_{t+1} = \text{mean}(X_1, X_2, X_3) \quad (8)$$

در روابط فوق  $C_t$  و  $A_t$  به ترتیب متغیرهای بردارهای جهش به سمت مکان‌های بهتر می‌باشند. ضرایب  $r_1$  و  $r_2$  به ترتیب اعداد تصادفی بین صفر و ۱،  $a$  ضریب کاهش تأثیر در هر تکرار،  $X$  مکان متغیر در وضعیت فعلی،  $X_{t+1}$  مکان متغیر در وضعیت بعدی،  $X_\alpha$ ،  $X_\beta$  و  $X_\delta$  به ترتیب موقعیت گرگ‌های آلفا، بتا و دلتا می‌باشد. بعد از اینکه کلیه اعضای جمعیت گرگ‌ها تغییر مکان دهند لازم است تا موقعیت سه گرگ برتر به روز شود (معادله ۸). در پایان این گام موقعیت ذره آلفا به عنوان بهترین جواب تعیین می‌گردد. لازم است تا محقق شدن شرایط خاتمه الگوریتم در طی چندین تکرار سعی نماید تا کلیه نقاط موجود در فضای تصمیم را پوشش دهد.

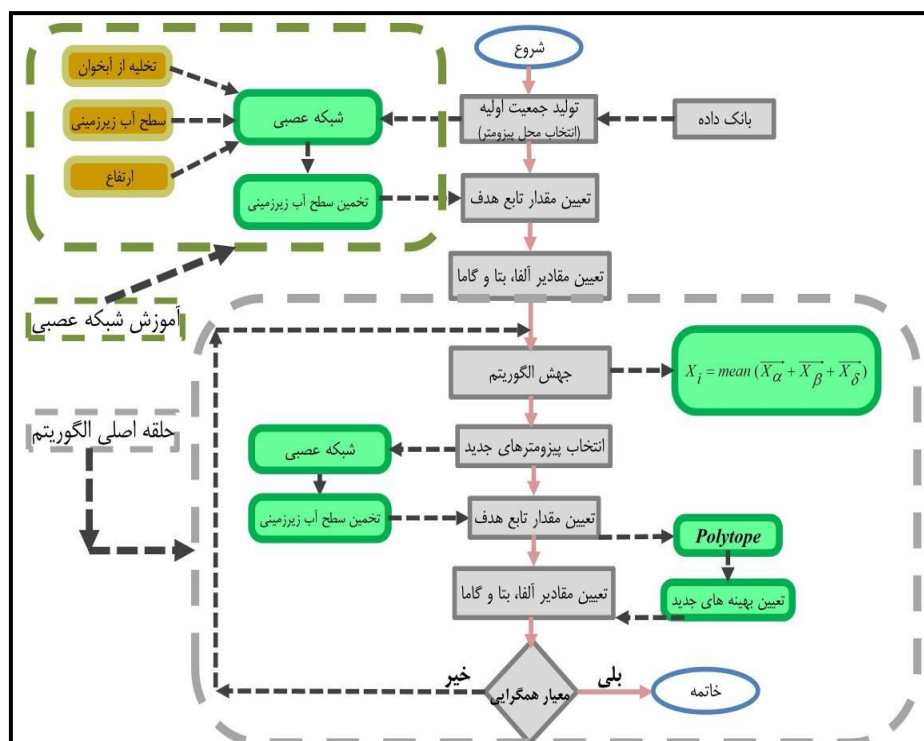
## مدل GNM

به منظور شروع بهینه‌سازی در مدل GNM ابتدا مدل شبکه عصبی فراخوانی شده و سپس الگوریتم جستجوی گرگ خاکستری شروع به کار می‌کند. بدین منظور هر کدام از اعضای جمعیت موقیعت‌های ۱۰ پیرومتر را از بانک نقاط شبکه‌بندی سطح آبخوان (شکل ۲) به صورت تصادفی انتخاب می‌کنند تا جمعیت اولیه شکل گیرد. در هر کدام از این نقاط

## اعمال شرایط خاتمه

از آنجا که ممکن است مدل GNM در پیدا کردن جواب بهینه به سمت یک بهینه موضعی متمایل شود و تا آخرین تکرار بهترین جواب ترقی پیدا نکند، از شرایط خاتمه استفاده شده است. شرایط خاتمه استفاده شده در این مطالعه بدین شرح است که اگر بهترین جواب مدل GNM در ۱۰۰ تکرار اخیر بهبودی پیدا نکرد، مدل مذکور از حلقه اصلی خود خارج شده و بهینه‌سازی پایان می‌یابد. شکل (۵) راهنمای مراحل اجرای مدل GNM را نشان می‌دهد.

می‌شود و معیار انتخاب بهترین مکان برای پیرومترها، کمترین خطا در برآورد سطح آب زیرزمینی مشاهداتی مهرماه ۱۳۹۳ می‌باشد. لازم به ذکر است که تعداد تکرار و اعضای جمعیت در الگوریتم گرگ خاکستری به ترتیب ۱۰۰ و ۱۰۰۰ فرض شد.




شکل (۵): مراحل اجرای الگوریتم GNM

عنوان مرکز ثقل مشخص شده و یک مسیر در امتداد بدترین عضو نخبه و مرکز ثقل تعیین می‌گردد. متناسب با رابطه (۱۰) و در انعکاس این مسیر نقطه‌ای به صورت تصادفی تعیین می‌شود (نام این نقطه انعکاس<sup>۱</sup> می‌باشد). مقدار تابع هدف برای نقطه انعکاس تعیین می‌شود و متناسب با حالات پیش‌رو تصمیم لازم گرفته می‌شود.

## روش کمکی Polytope

الگوریتم Polytope یا بسط چندقله‌ای مربوط به چگونگی جستجوی ذرات در فضای تصمیم می‌شود. کاربرد این الگوریتم، کشف جهت دستیابی ذرات الگوریتم به بهینه‌های سراسری است و اصولاً به منظور رهایی از همگرایی‌های محلی استفاده می‌شود. چگونگی کارکرد این الگوریتم بدین شرح است که ابتدا تعدادی از بهترین اعضای جمعیت الگوریتم تعیین می‌شوند (اعضای نخبه). میانگین مکان‌های اعضای نخبه تحت

1 Reflection



شکل (۶): تغییر جهت جستجوی ذرات در الگوریتم Polytope

## نتایج و بحث

در ابتدا نتایج مربوط به آماده‌سازی شبکه عصبی ارائه شده است. بهترین جوآب‌های بدست آمده (پس از ۵۰ بار اجرای شبکه عصبی) برای مقادیر شاخص‌های ارزیابی  $RMSE$ ،  $MAE$ ،  $Pbias$  و  $R^2$  برای دوره آزمایش، به ترتیب برابر است با ۰/۱، ۰/۰۱، ۰/۱۵ متر و ۰/۹۹ بدست آمد. از این‌رو می‌توان بیان نمود که استفاده از شبکه‌های عصبی پرسپترون دارای کارایی مناسب می‌باشد. شکل (۷) مقادیر شاخص‌های ارزیابی دقت شبکه عصبی را برای دوره‌های آموزش، صحت‌سنجی و آزمایش نشان می‌دهد. از این‌جا نتایج یافته‌های پژوهش با نتایج مطالعه Daliakopoulos et al, (2005) و محتشم و همکاران، (۱۳۸۹) یکسان می‌باشد. در مطالعه محتشم و همکاران (۱۳۸۹) که با استفاده از شبکه عصبی اقدام به تخمین سطح آب زیرزمینی دشت بیرجند نموده بود، مقدار شاخص‌های ارزیابی  $R^2$  و  $RMSE$  به ترتیب ۰/۹۹ و ۰/۰۳ متر بدست آمد. به منظور ارزیابی بیشتر عملکرد شبکه عصبی، اقدام به ترسیم سطح آب زیرزمینی شبیه‌سازی شده در مقابل مقادیر مشاهداتی شد (شکل ۸). همانطور که در این شکل مشخص شده است، در هیچ کدام از دوره‌های آزمایش و صحت‌سنجی، شبیه‌سازی-های شبکه عصبی با کم یا بیش تخمینی خاصی همراه نبوده است.

حالت اول) چنانچه این نقطه از حیث مقدار تابع هدف، بین بدترین و بهترین عضو نخبه قرار داشت با بدترین عضو نخبه جایگزین می‌گردد. حالت دوم) چنانچه این ذره از بهترین عضو نخبه بهتر باشد، باید مسیر انعکاس بسط یابد. از این‌رو در همین امتداد و متناسب با رابطه (۱۱) نقطه جدید دیگری تعیین می‌گردد (نام این نقطه انبساط<sup>۱</sup> می‌باشد). در این گام چنانچه تابع هدف نقطه انبساط از بدترین عضو نخبگان بهتر باشد جایگزین آن می‌شود. حالت سوم) چنانچه مقدار تابع هدف نقطه انعکاس از بدترین عضو نخبگان بدتر باشد لازم است تا در خلاف جهت انعکاس، بسطی صورت پذیرد و نقطه‌ای جدید در راستای عکس انعکاس و متناسب با رابطه (۱۲) تعیین گردد (نام این نقطه انقباض<sup>۲</sup> می‌باشد). چنانچه مقدار تابع هدف نقطه انقباض از بدترین عضو نخبگان بهتر باشد جایگزین آن می‌شود. در صورتی که مقدار تابع هدف نقطه انقباض از بدترین عضو نخبگان بهتر نباشد، تصمیم خاصی گرفته نمی‌شود و الگوریتم به مسیر طبیعی خود ادامه می‌دهد.

$$(10) X_R = C + \alpha(C - Particle_{worst}), \alpha > 0$$


$$(11) X_E = C + \beta(X_r - C), \beta > 1$$

$$(12) X_C = C + \gamma(X_r - C), 0 < \gamma < 1$$

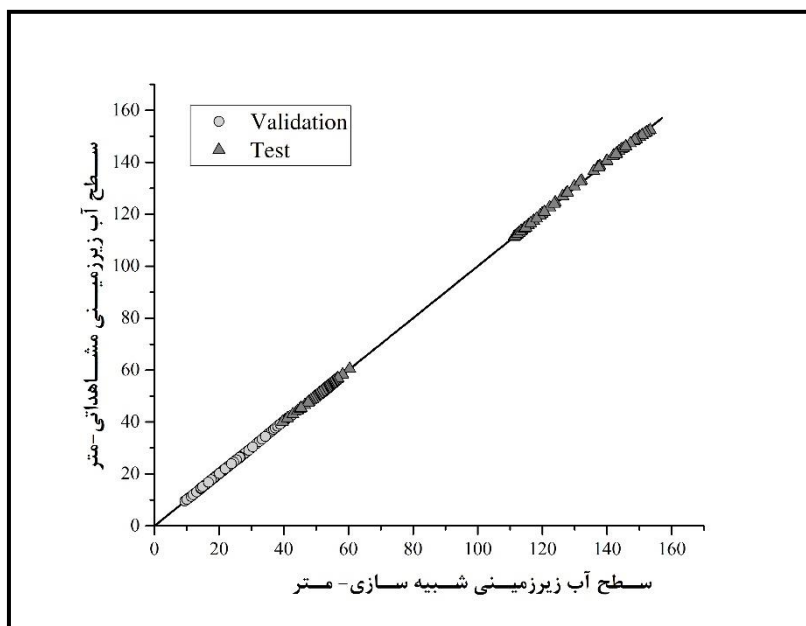
در روابط فوق  $X_C$  و  $X_E$  و  $X_R$  به ترتیب نقاط انعکاس، انبساط و انقباض می‌باشند. ضریب  $C$  مرکز ثقل و  $Particle_{worst}$  بدترین عضو نخبگان به شمار می‌رود. ضرایب  $\alpha$  و  $\beta$  مقادیر ثابت می‌باشند که به ترتیب معادل ۱ و ۲ در نظر گرفته شده‌اند (Güyağüler et al, 2002). همچنین مقدار  $\gamma$  یک عدد تصادفی بین صفر و یک می‌باشد. مقدار ضرایب  $\alpha$  و  $\beta$  با استفاده از ۱۰ بار اجرای برنامه و سعی و خطا برآورد شدند. شکل (۶) توصیفی از روش Polytope را به صورت نمایشی ارائه می‌نماید.

1 Expansion

2 Contraction



شکل (۷): شاخص‌های ارزیابی شبکه عصبی



شکل (۸): مقایسه مقادیر مشاهداتی و شبیه‌سازی در شبکه عصبی

جواب بهینه مشخص شد و در جدول (۲) ارائه گردید. مدل بهینه‌سازی GWO با اعمال شرایط خاتمه طی ۲۸۳ تکرار و پس از طی زمانی در حدود ۱۲۰۰ ثانیه از حلقه اصلی خود خارج شد. شکل (۸) نمودار همگرایی ۳ عضو برتر الگوریتم را نشان می‌دهد. شیب نمودار همگرایی نشان دهنده سرعت در پیدا نمودن جواب بهینه می‌باشد. همچنین فاصله بهترین جواب الگوریتم در آخرین تکرار تا بهینه مطلق (معادل کمترین خطای


پس از حصول نتایج مناسب در خصوص کارایی شبکه عصبی در تخمین سطح آب زیرزمینی در انتهای سال آبی ۱۳۹۳، اقدام به اجرای مدل GNM شد. به دلیل ماهیت سعی و خطا در فرآیند بهینه‌سازی الگوریتم GNM، ممکن است که اجراهای متوالی جواب‌های متفاوت را ارائه دهند. از این رو به منظور دستیابی به بهترین جواب مدل، ۲۰ اجرای پیاپی مدل مورد بررسی قرار گرفت و بهترین نتایج آن به عنوان

روش Polytope نیز در جدول (۱) ارائه شده است. با استناد به نتایج مندرج در این جدول مشخص می‌شود که استفاده از این روش موجب بهبود مقدار تابع هدف تا سقف  $0/0001$  شده است (بیش از ۸۵ درصد بهبود در مقدار تابع هدف). عملکرد خوب الگوریتم Polytope نشان می‌دهد که به کارگیری آن ضمن فراهم نمودن امکان کشف نقاط جدید با ارزش بیشتر برای الگوریتم، می‌تواند عملکرد فرآیند بهینه‌سازی را نیز بهبود بخشد (Nelder and Mead, 2000). مطالعه Guyaguler et al, (2000) در نتایج خود صراحتاً به بهبود عملکرد الگوریتم ژنتیک در بهینه‌یابی تعیین مکان‌های چاه‌های تغذیه در اثر استفاده از الگوریتم Polytope اشاره نمودند.

ممکن یعنی صفر) نشان دهنده دقت جواب می‌باشد. ذره آلفا که بهترین عضو الگوریتم جستجوی گرگ می‌باشد در بین ۳ ذره برتر دارای سرعت و دقت بهتری در جهت پیدا نمودن جواب بهینه می‌باشد. همچنین موقعیت پیژومترهای انتخاب شده و شبکه پیژومترهای قدیم آبخوان در شکل (۹) مشخص گردیده است. بر اساس مقایسه میانگین سطح آب زیرزمینی در پیژومترهای منتخب مدل GWO با سطح آب زیرزمینی مهرماه سال ۱۳۹۳، مقدار تابع هدف تا  $0/0001$  متر کاهش پیدا کرد. از این رو می‌توان بیان نمود که مدل پیشنهاد شده دارای دقت خوبی برای تخمین سطح آب زیرزمینی دارد. این درحالی است که در مدل GWO تعداد پیژومترها نسبت به وضعیت فعلی کاهش پیدا کرده است. نتایج عملکرد استفاده از

جدول (۲): عملکرد الگوریتم بهینه‌سازی

تعداد تکرار	زمان اجرا (ثانیه)	تعداد فراخوانی تابع هدف	مقدار تابع هدف (متر)
۲۸۳	۱۱۸۳/۲۳	۲۹۰۵۱	$0/000117$
۱۷۶	۷۰۹/۷۶۹	۱۷۸۰۰	$0/0007$



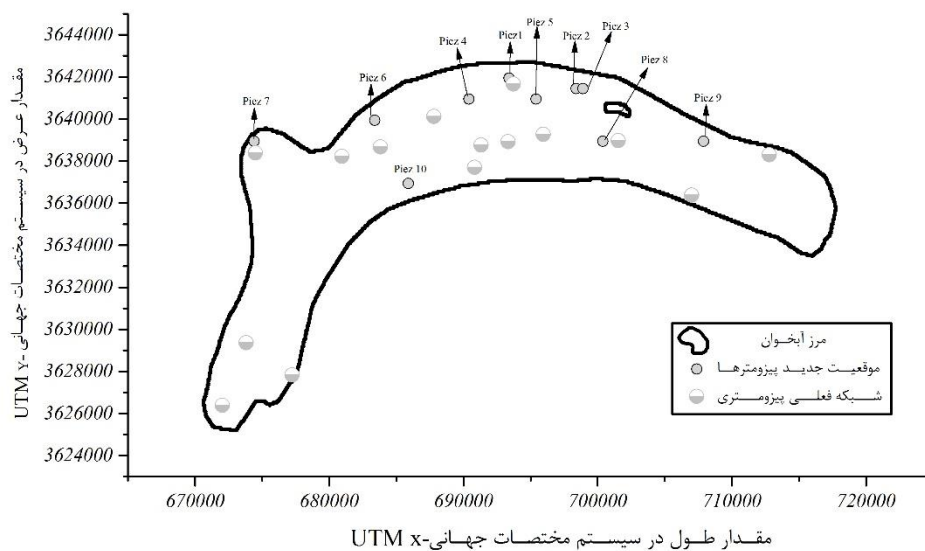
شکل (۸): نمودار همگرایی الگوریتم پیشنهاد شده

استناد به وضعیت فیزیوگرافی آبخوان بیرجند (لایه سنگ کف، جهت جریان و سطح آب زیرزمینی) و شکل (۹) مشخص می‌شود که الگوریتم به دنبال تعیین شبکه

شکل (۹) شبکه پیژومترهای بهینه و قدیمی را نشان می‌دهد. به منظور تحلیل بیشتر موقعیت پیژومترهای انتخاب شده توسط مدل GNM و با

بعد از اینکه نتایج مربوط به کارایی مدل GNM در مکان‌یابی محل بهینه پیزومترهای جدید در مهر ماه ۱۳۹۳ مورد ارزیابی قرار گرفت، سعی شد تا دقت شبکه جدید پیزومترها برای سایر مقادیر مشاهداتی مورد ارزیابی قرار گیرد. از این‌رو با استفاده از پیزومترهای فعلی آبخوان، اقدام به تعیین سطح آب زیرزمینی برای موقعیت‌های جدید و حذف‌های سال‌های ۱۳۹۰ تا ۱۳۹۲ شد. فلذا سطح آب زیرزمینی در شبکه پیزومتری جدید و با استفاده از تخمین‌گر سطح آب زیرزمینی مدل GNM، برآورد شده و مقایسه سطح آب مشاهداتی و خروجی مدل GNM برای محل پیزومترهای جدید انجام گردید. مقادیر شاخص‌های ارزیابی  $RMSE$ ،  $MAE$ ،  $Pbias$  و  $R^2$  برای این مقایسه و هر کدام از موقعیت‌های جدید بدست آمد و در جدول (۳) ارائه شد.

بهینه پیزومتر در قسمت‌های مرکزی آبخوان می‌باشد. می‌توان بیان نمود که به دلیل اینکه در قسمت‌های غربی ضخامت آبخوان به تدریج کاهش می‌یابد (جعفرزاده و همکاران، ۱۳۹۴) و عمدتاً سطح آب زیرزمینی در این قسمت‌های آبخوان ثابت می‌باشد، الگوریتم این نقاط را کنار گذاشته و بیشتر به دنبال نقاطی است که تغییر در آن‌ها موجب بهبود خطای پیش‌بینی شود می‌باشد. مطالعه محتشم و همکاران (۱۳۸۹) نیز به این نتیجه اذعان داشته‌اند. آن‌ها در مطالعه خود بیان داشته‌اند که اطلاعات پمپاژ از چاه‌های برداشت در نواحی مرکزی آبخوان دارای دقت بالاتری نسبت به سایر نواحی می‌باشد. در نهایت باید توجه لازم به این موضوع داشت که ثبت اطلاعات، نگهداری و حفاظت از شبکه پیزومترهای یک آبخوان نیازمند هزینه و صرف وقت می‌باشد. از این‌رو تعیین مکان‌های بهینه پیزومترها می‌تواند موجبات صرفه‌جویی اقتصادی و مدیریت بهتر زمان را فراهم نماید.




شکل (۹): موقعیت شبکه بهینه پیزومترهای آبخوان دشت بیرجند

جدول (۳): مقدار شاخص‌های ارزیابی برای مقایسه سطح آب مشاهداتی و شبیه‌سازی در محل پیزومترهای جدید


نام پیزومتر	RMSE	MAE	Pbias	$R^2$
Piez1	۰/۲۲	۰/۱۵	-۰/۰۹	۰/۸۲
Piez2	۰/۳۹	۰/۲۶	۰/۰۴	۰/۳۷
Piez3	۰/۳۹	۰/۲۷	۰/۰۶	۰/۳۷
Piez4	۰/۲۱	۰/۱۵	-۰/۱۶	۰/۸۵
Piez5	۰/۳	۰/۱۸	-۰/۰۳	۰/۶۳
Piez6	۰/۳	۰/۲۲	-۰/۱۷	۰/۷۲
Piez7	۱/۱۱	۱/۰۵	۰/۷۳	۰/۲۱
Piez8	۰/۳۹	۰/۲۸	۰/۰۹	۰/۳۷
Piez9	۰/۹	۰/۹	۰/۷۴	۰/۹
Piez10	۰/۲۷	۰/۲۷	۰/۷۴	۰/۹

تغییرات سطح آب زیرزمینی مشاهداتی و شبیه‌سازی شده توسط مدل GNM در شکل (۱۰-الف و ب) به تصویر درآمده است.

مقادیر تمامی شاخص‌های ارزیابی برای محل‌های جدید گویای توانمندی خوب مدل GNM در مکان‌یابی و تخمین مناسب می‌باشد، لکن مقدار شاخص  $R^2$  برای پیزومترهایی که در پاییز سال ۱۳۹۲ همراه با کم تخمینی می‌باشند کمتر از سایر پیزومترها می‌باشد.



الف



ب

شکل (۱۰): سطح آب زیرزمینی مشاهداتی و شبیه‌سازی مدل GNM در پیزومترهای جدید

نتایج تخمین سطح آب زیرزمینی مدل GNM

نشان داد که شبکه عصبی متناسب با ورودی‌های در نظر گرفته شده، تا حد قابل قبولی توانمندی بالایی در این مقوله دارد. همچنین بررسی مقدار تابع هدف در مکان‌یابی نشان داد که مدل پیشنهاد شده در این بخش نیز از عملکرد قابل توجهی برخوردار است. همچنین مقایسه سطح آب زیرزمینی در ماه‌های مختلف نشان داد که دقت تخمین در مکان‌های جدید پیزومترها قابل قبول می‌باشد. با توجه به توانمندی مناسب مدل GNM و کاهش تعداد پیزومترها در خروجی ارائه شده توسط این مدل، می‌توان بیان نمود که شبکه پیزومتری جدید موجبات صرفه‌جویی اقتصادی و مدیریت بهتر زمان را فراهم خواهد نمود.

### نتیجه‌گیری

این مطالعه یک روش جدید مبتنی بر شبکه عصبی مصنوعی و جستجوی گرگ خاکستری تحت عنوان GNM برای پایش آب‌های زیرزمینی و تعیین مکان‌های پیزومترهای جدید در آبخوان بیرجند با هدف کاهش تعداد پیزومترها و افزایش دقت، ارائه نموده است. میزان تخلیه از آبخوان، سطح آب زیرزمینی و ارتفاع توپوگرافی به عنوان ورودی به شبکه عصبی در نظر گرفت شد و مقادیر آن‌ها برای نقاط شبکه‌بندی آبخوان بدست آمد. ابتدا مدل مذکور برای یک ماه مشخص (مهرماه ۱۳۹۳) اقدام به مکان‌یابی مکان پیزومترهای جدید نمود و پس از تأیید عملکرد آن، اقدام به تخمین سطح آب زیرزمین در محل‌های جدید و حدفواصل سال‌های ۱۳۹۰ تا ۱۳۹۲ نمود.



## منابع

- بزرگ حداد، ا. ۱۳۸۴. بهینه‌سازی هیدروسستم‌ها با استفاده از الگوریتم بهینه‌یابی جفت‌گیری زنبورهای عسل (HBMO). رساله دکتری. دانشگاه علم و صنعت.
- جعفرزاده، ا. ع. خاشعی سیوکی، ع. شهیدی. ۱۳۹۴. بررسی اثرات طرح تجمع و تصفیه فاضلاب شهری بر تراز هیدرولیکی آبخوان تحت شرایط تغییر اقلیم در دوره ۲۰۱۴-۲۰۲۰ میلادی (مطالعه موردی: دشت بیرجند). نشریه آبیاری زهکشی ایران، ۳(۹): ۴۹۰-۴۹۹.
- محمدی گیوشاد، ف.، ه. معماریان. ۱۳۹۵. بحران آب دشت بیرجند، عوامل، پیامدها و راهکارها، دومین همایش ملی مدیریت پایدار منابع خاک و محیط زیست (کیفیت، سلامت و امنیت خاک)، کرمان، گروه علوم و مهندسی خاک دانشگاه شهید باهنر کرمان، [https://www.civilica.com/Paper-SMSER02-SMSER02\\_055.html](https://www.civilica.com/Paper-SMSER02-SMSER02_055.html)
- میرزائی ندوشن، ف.، ا. بزرگ‌حداد، م. خیاطی خلقی. ۱۳۹۵. طراحی دو هدفه شبکه پایش سطح آب زیرزمینی با NSGII در دشت اشتهارد. مجله تحقیقات آب و خاک ایران، دوره ۴۷، شماره ۲، ۳۴۵-۳۵۴.
- Coulibaly, P., Anctil, F., Aravena, R., & Bobée, B. (2001). Artificial neural network modeling of water table depth fluctuations. *Water resources research*, 37(4), 885-896.
- Cieniawski, S. E., Eheart, J. W., & Ranjithan, S. (1995). Using genetic algorithms to solve a multiobjective groundwater monitoring problem. *Water Resources Research*, 31(2), 399-409.
- Dadaser-Celik, F., & Cengiz, E. (2013). A neural network model for simulation of water levels at Daliakopoulos, I. N., Coulibaly, P., & Tsanis, I. K. (2005). Groundwater level forecasting using artificial neural networks. *Journal of Hydrology*, 309(1), 229-240.
- Guyaguler, B., Horne, R. N., Rogers, L., & Rosenzweig, J. J. (2000, January). Optimization of well placement in a Gulf of Mexico waterflooding project. In SPE annual technical conference and exhibition. Society of Petroleum Engineers.
- Kollat, J. B., & Reed, P. M. (2005). Comparison of multi-objective evolutionary algorithms for long-term monitoring design. In *Impacts of Global Climate Change* (pp. 1-11).
- Koziel, S., & Leifsson, L. (2013). Surrogate-based modeling and optimization. *Applications in Engineering*.
- Li, Y., & Hilton, A. B. C. (2005). Reducing spatial sampling in long-term groundwater monitoring networks using ant colony optimization. *International Journal of Computational Intelligence Research*, 1(1), 9-28.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Mirjalili, S., Saremi, S., Mirjalili, S. M., & Coelho, L. D. S. (2016). Multi-objective grey wolf optimizer: a novel algorithm for multi-criterion optimization. *Expert Systems with Applications*, 47, 106-119.
- Nelder, J.A., and Mead, R.: (2000) "A Simplex Method for Function Minimization," *Computer Journal*, 7:308-313.
- Ranjithan, S., Eheart, J. W., & Garrett, J. H. (1995). Application of neural network in groundwater remediation under conditions of uncertainty. *New uncertainty concepts in hydrology and water resources*, 133-140.
- Razavi, S., Tolson, B. A., & Burn, D. H. (2012). Review of surrogate modeling in water resources. *Water Resources Research*, 48(7).
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1985). Learning internal representations by error propagation (No. ICS-8506). California Univ San Diego La Jolla Inst for Cognitive Science.
- Schaap, M. G., & Bouten, W. (1996). Modeling water retention curves of sandy soils using neural networks. *Water Resources Research*, 32(10), 3033-3040.
- Shiri, J., Kisi, O., Yoon, H., Lee, K. K., & Nazemi, A. H. (2013). Predicting groundwater level fluctuations with meteorological effect implications—A comparative study among soft computing techniques. *Computers & Geosciences*, 56, 32-44.

Taormina, R., Chau, K. W., & Sethi, R. (2012). Artificial neural network simulation of hourly groundwater levels in a coastal aquifer system of the Venice lagoon. *Engineering Applications of Artificial Intelligence*, 25(8), 1670-1676.

Zhang, Q., & Sun, S. (2009, December). Weighted data normalization based on eigenvalues for artificial neural network classification. In *International Conference on Neural Information Processing* (pp. 349-356). Springer Berlin Heidelberg.

## Performance examination of optimization model of groundwater monitoring network based on Gray wolf and Neural network (GNM) (Case study: Birjand plain)

Ahmad Jafarzadeh<sup>1</sup>, Abbas Khashei-Siuki<sup>2</sup>

### Abstract

Quantity monitoring of groundwater with assessment and detection of main origins of the aquifer regime, has important role in management of groundwater in any region. Hence monitoring network of groundwater is importance for spacial and temporal variations of water table. This study proposes a new method named Gray wolf and Neural network Monitoring (GNM) to quantity monitoring of Birjand plain and detection of optimal location of piezometers. In this proposed method used of neural network and Gray Wolf Algorithm (GWA) to estimate of water table and placement of piezometer location respectively. Water table with one to three month delay lag, topographic elevation, aquifer discharge and coordinate were considered as input of water table estimator (Neural Network) of GNM. The observation values of input components were interpolated on Birjand aquifer using of Geostatistical Analysis in GIS. Also  $R^2$  and RMSE indices were used to skill evaluation of Neural Network. Exponential error between observed and simulated water table was assumed as fitness function in placement of piezometer location. Also used of Polytope algorithm to rise of accuracy and exploration of new optimal points. Results indicated that estimator of groundwater table of GNM has a noticeable performance. The value of  $R^2$  and RMSE indices in validation section achieved 0.1 and 0.9 m respectively. Also examine of comparison results of observation and simulation groundwater table showed that GNM has well skill in placement of piezometers location. So that the value of fitness function was decreased to 0.0007 m. The location of 10 new piezometers ultimately was recognized using of GNM. Also results of Polytope algorithm application indicated that this method can to have high capable to new optimal pints. So that using of this method could to reduce fitness function to 0.0001 m. Estimation skill of groundwater table in proposed piezometer network by GNM examined with comparison of observation and simulated groundwater table between 1390 to 1392. The values of  $R^2$  and RMSE indices were evaluated for any piezometer of new piezometer network. Results showed that proposed piezometer network has noticeable accuracy in estimation of water table.

**Keywords:** Gray Wolf, Piezometer placement, Neural Network, Polytope.

<sup>1</sup> PhD Student of Water Resource Engineering, Dept. of Science and Water Engineering, University Of Birjand. [mnt.jafarzadeh@chmail.ir](mailto:mnt.jafarzadeh@chmail.ir)

<sup>2</sup> Associated Professor of Dept. of Science and Water Engineering, University Of Birjand. [abbaskhashei@birjand.ac.ir](mailto:abbaskhashei@birjand.ac.ir)