

مدل سازی کیفی منابع آب زیرزمینی با استفاده از شبکه عصبی مصنوعی و الگوریتم بهینه سازی گرگ خاکستری: مورد مطالعه دشت کبودرآهنگ، همدان، ایران

مهدی پیرزاد^۱، سهیل سبحان اردکانی^{۲*}

^۱ کارشناس ارشد مهندسی محیط زیست، گروه مهندسی محیط زیست، دانشکده فنی و مهندسی، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران
^۲ دکترای تخصصی علوم محیط زیست، استاد گروه محیط زیست، دانشکده علوم پایه، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

تاریخ دریافت مقاله: ۱۴۰۲/۰۸/۱۱، تاریخ پذیرش: ۱۴۰۲/۰۹/۱۲

چکیده

زمینه و هدف: امروزه با توجه به تغییرات اقلیمی و کاهش نزولات جوی در سطح کشور و به خصوص استان همدان، نرخ دسترسی به منابع آب سطحی کاهش یافته و لذا، میزان برداشت از منابع آب زیرزمینی به شدت افزایش یافته است که این موضوع موجب تغییر در کیفیت این منابع برای مصارف گوناگون شده است. در نتیجه، لزوم پایش کیفی منابع آب زیرزمینی نیز اهمیت دوچندانی یافته است. از این رو، در این پژوهش با استفاده از مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم فراابتکاری گرگ خاکستری نسبت به مدل سازی کیفی منابع آب زیرزمینی دشت کبودرآهنگ واقع در شمال غربی استان همدان در سال ۱۴۰۱ اقدام شد.

مواد و روش ها: در این پژوهش، داده های کیفی منابع آب زیرزمینی مربوط به چاه های دشت کبودرآهنگ به سه بخش آموزش (۷۰٪)، اعتبارسنجی (۱۵٪) و آزمون (۱۵٪) تقسیم و با استفاده از مدل ترکیبی شبکه عصبی مصنوعی و الگوریتم فراابتکاری گرگ خاکستری مدل سازی کیفی منابع آب زیرزمینی دشت کبودرآهنگ انجام شد.

یافته ها: نتایج نشان داد که مدل ارائه شده قابلیت بالایی در پیش بینی کیفیت آب زیرزمینی بر اساس سه متغیر pH، EC و TDS داشته است. مقدار $R = 0.9975$ نشان دهنده پیشگویی بالای متغیرها بود. نتایج حاصل از پیاده سازی شبکه عصبی مصنوعی بیان گر صحت بالا و همچنین قابلیت بالای پیش بینی و خطای اندک مدل بود که این خطا با کمک الگوریتم گرگ خاکستری کاهش یافت. بنابراین، می توان اذعان داشت علی رغم این که الگوریتم شبکه عصبی مصنوعی تا حد بالایی قادر به پیش بینی کیفیت آب زیرزمینی در منطقه مورد مطالعه بود، الگوریتم گرگ خاکستری با کاهش خطای پیش بینی، این عملکرد را تکمیل و مقدار بهینگی مدل را افزایش داد.

نتیجه گیری: الگوریتم های شبکه عصبی مصنوعی و بهینه سازی گرگ خاکستری مکمل هم بوده و عملکرد خوبی برای پیش بینی تغییرات کیفی منابع آب زیرزمینی از خود نشان می دهند.

واژه های کلیدی: کیفیت آب زیرزمینی، مدل سازی هوشمند داده ها، شبکه عصبی مصنوعی، الگوریتم گرگ خاکستری، دشت کبودرآهنگ.

مقدمه

هرچند منابع آب در بین سایر منابع طبیعی جایگاه ویژه‌ای را به‌خود اختصاص داده‌اند و به‌طور تقریبی یک سوم جمعیت جهان به‌خصوص در مناطق خشک و نیم خشک، برای تامین آب آشامیدنی به منابع آب زیرزمینی وابسته هستند^{۱-۳}. این در حالی است که تغییرات اقلیمی، افزایش جمعیت و آلودگی‌های انسان‌ساخت فشار مضاعفی بر این منابع وارد کرده است^۴. در این میان، بهره‌برداری بیش‌تر از حد، افزایش شوری و نفوذ و اختلاط آلاینده‌ها، می‌تواند منجر به بحران افت کیفی منابع آب زیرزمینی شود که توجه فوری مدیران این حوزه را می‌طلبد^{۵،۶}.

به‌منظور مدیریت منابع آب زیرزمینی، باید ابتدا داده‌های آنالیز شیمیایی آب زیرزمینی محدوده مطالعاتی را جمع‌آوری کرد^۷ و سپس، تغییرات کمی و کیفی این منابع در فصول مختلف با استفاده از انجام یک سری تحقیقات طولانی مدت برای هر منطقه خاص پیش‌بینی شوند، که این فرایندها امری هزینه‌بر و نیازمند نیروی انسانی و دقت بالا است^۸. این در حالی است که با ابزاری مانند شبیه‌سازها و یا مدل‌ها می‌توان با شبیه‌سازی شرایط محیط طبیعی، نتایج قابل قبولی به‌دست آورد^{۹،۱۰}.

امروزه، استفاده از الگوریتم‌های هوش مصنوعی (Artificial Intelligence, AI) به‌عنوان جایگزینی بالقوه برای رویکردهای سنتی‌تر برای تخمین و پیش‌بینی کیفیت آب متداول شده است^{۱۱،۱۲}. از جمله روش‌های کاربردی هوش مصنوعی، مدل شبکه عصبی مصنوعی (Artificial Neural Network, ANN) است که الهام گرفته از مغز انسان و چگونگی پردازش اطلاعات، آموزش و یادگیری روند آن‌ها است^{۱۳،۱۴}. با توجه به کارایی پیش‌بینی بهتر در مقایسه با سایر مدل‌های مرسوم، ANN به‌طور گسترده برای حل مسائل در زمینه‌های مختلف مهندسی استفاده شده است^{۱۵}. بررسی

مطالعات نشان‌دهنده آن است که ANN ابزاری کارآمد و دقیق در مدیریت کیفیت منابع آب زیرزمینی است و می‌تواند در طراحی و برنامه‌ریزی مدیریت این منابع و راهبردهای پیشگیری از آلودگی مفید باشد^{۱۶}.

از چالش‌های مرتبط با ارزیابی کیفی آب، می‌توان به تعداد بالای پارامترهای کیفی برای ارزیابی منابع آب زیرزمینی و نیاز به ترکیب چندین الگوریتم یا مدل یادگیری ماشینی در پیش‌بینی کیفیت آب اشاره کرد^{۱۷}. از آن‌جا که الگوریتم‌های هیبریدی بهبود قابل توجهی در ارزیابی کیفی آب در مقایسه با الگوریتم‌های مستقل دارند^{۱۸}، برای مقابله با نقاط ضعف مدل شبکه عصبی، الگوریتم‌های بهینه‌سازی فراابتکاری پیشرفته، مانند الگوریتم گرگ خاکستری (Grey Wolf Optimizer, GWO) که یک الگوریتم مدرن الهام گرفته از طبیعت است که به‌طور معمول برای بهبود مدل‌های ANN استفاده می‌شود، مورد نیاز است^{۱۹}.

در پژوهش‌های مشابه، مدل پرسپترون چندلایه (Multilayer Perceptron, MLP) به‌عنوان ابزاری قوی برای پیش‌بینی غلظت عناصر بالقوه سمی در منابع آب زیرزمینی گزارش شد^۹. در پژوهشی با استفاده از تحلیل عاملی و خوشه‌ای نسبت به ارزیابی کیفی منابع آب زیرزمینی دشت کبودآهنگ همدان اقدام و چهار پارامتر EC، pH، TH و Mg به‌عنوان مهم‌ترین عوامل موثر بر کیفیت آب گزارش شدند^{۲۰}. امامی و همکاران (۲۰۱۸) با تحلیل منابع آب زیرزمینی دشت جلفا نتیجه گرفتند که مقدار ضریب همبستگی زیاد بین مقادیر مشاهداتی و پیش‌بینی شده، قابلیت بالای الگوریتم GWO را برای پیش‌بینی کیفیت آب زیرزمینی نشان می‌دهد^{۲۱}. در پژوهشی دیگر، ساداتی‌نژاد و همکاران (۲۰۱۸) با بازطراحی شبکه پایش آب زیرزمینی آبخوان کوه‌دشت گزارش کردند که تغییرات تدریجی کمی و کیفی منابع آب را نمی‌توان با نمونه‌برداری‌های نامنظم و پراکنده پیش‌بینی کرد و بدین منظور، به شبکه‌های برداشت پیوسته و پردازش داده‌های

زنبورهای مصنوعی (ABC) از دقت و قابلیت بیش‌تر برخوردار بوده است.^{۲۷}

با توجه به تغییرات آب و هوایی، خشکسالی سنوات اخیر، برداشت‌های بی‌رویه از منابع آب زیرزمینی منطقه مورد مطالعه، کاهش کیفیت و لزوم مدیریت منابع مذکور، این پژوهش با هدف ارزیابی کیفی منابع آب زیرزمینی دشت کبودرآهنگ همدان با استفاده از یک مدل داده-هوشمند ترکیبی مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری و شبکه عصبی مصنوعی انجام یافت.

مواد و روش

معرفی منطقه مورد مطالعه


شهرستان کبودرآهنگ در گستره‌ای به مساحت ۳۴۴۸ کیلومترمربع معادل ۱۹/۶٪ از مساحت استان همدان را تشکیل می‌دهد. این شهرستان با موقعیت جغرافیایی ۴۸ درجه و ۲۷ دقیقه طول شرقی و ۳۴ درجه و ۳۳ دقیقه عرض شمالی، از شمال به استان زنجان و از جنوب به شهرستان همدان، از شرق به شهرستان رزن و از غرب به استان کردستان محدود شده است.^{۲۸} موقعیت استقرار دشت کبودرآهنگ در شکل ۱ آورده شده است.

گردآوری داده‌ها


در این پژوهش، برای ارزیابی کیفی منابع آب زیرزمینی دشت کبودرآهنگ از داده‌های شرکت آب منطقه‌ای همدان مربوط به ۳۰ حلقه چاه برای دوره ۱۰ ساله (۱۳۹۱-۱۴۰۱) استفاده شد. نقشه موقعیت استقرار چاه‌های نمونه‌برداری در شکل ۲ نشان داده شده است.

مربوط به آن‌ها نیاز است.^{۲۲} به علاوه، نتایج پژوهشی نشان داد که الگوریتم گرگ خاکستری با میانگین مقادیر ضریب همبستگی به ترتیب برابر با ۰/۹۶، ۰/۹۵ و ۰/۹۵۵ برای مقادیر مشاهداتی و پیش‌بینی شده پارامترهای TDS، EC و SAR، در مقایسه با سایر الگوریتم‌های ارزیابی کیفیت هیدروژئوشیمیایی منابع آب زیرزمینی به عنوان مدلی برتر قابل معرفی است.^{۲۳} بهرامی و آگدرنژاد (۲۰۲۳) نیز با مقایسه مدل‌های ANN و کریجینگ برای پیش‌بینی پارامترهای کیفی آب زیرزمینی دشت دزفول شامل SAR، TDS و EC، گزارش کردند که تلفیق مدل‌های شبکه عصبی مصنوعی با الگوریتم‌های بهینه‌سازی ابزاری مفید برای شبیه‌سازی پارامترهای کیفی آب زیرزمینی بوده است.^{۲۴} نتایج پژوهشی دیگر نشان داد که مدل ANN-GWO در مقایسه با مدل‌های ANN-DE و ANN-PSO از پایداری و رفتار همگرایی بهتر برای اصلاح آب‌های زیرزمینی برخوردار بوده است.^{۲۵} از طرفی، تیخامارین و همکاران (۲۰۲۰) گزارش کردند که تلفیق هوش مصنوعی با GWO در مقایسه با روش‌های استاندارد هوش مصنوعی برای پیش‌بینی ماهانه جریان منابع آب زیرزمینی عملکرد بهتری داشته است.^{۲۶} نتایج پژوهشی نشان داد که عملکردهای هیدرولوژیکی و وضعیت سیستم‌های آب زیرزمینی پیچیده بوده و تفسیر آن‌ها بدون کمک مدل‌سازی هوش مصنوعی دشوار است.^{۱۶} قبادی و همکاران (۲۰۲۲) از یک مدل داده-هوش ترکیبی جدید مبتنی بر ANN و GWO پرسپترون چند لایه (GWO-MLPANN) برای مدل‌سازی کیفیت منابع آب زیرزمینی بهره برده و گزارش کردند که این مدل ترکیبی یک ابزار سودمند برای پیش‌بینی کیفیت منابع آب زیرزمینی بوده است.^{۱۷} علاوه بر این، موئدی و همکاران (۲۰۲۳) گزارش کردند که مدل ترکیبی شبکه عصبی مصنوعی به همراه الگوریتم فراابتکاری گرگ خاکستری (GWO-ANN) در شبیه‌سازی و ارزیابی کیفیت منابع آب زیرزمینی در مقایسه با بهینه‌سازی هریس هاکس (HHO) و کلونی

مدلسازی کیفی منابع آب زیرزمینی با استفاده از شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی گرگ خاکستری: مورد مطالعه دشت کبودرآهنگ، همدان، ایران



شکل ۱. موقعیت استقرار دشت کبودرآهنگ



شکل ۲. موقعیت استقرار چاه‌های نمونه‌برداری از آب زیرزمینی

(۱) گرگ رهبر یا آلفا، (۲) گرگ بتا، (۳) گرگ دلتا و (۴) گرگ امگا

گرگ‌های آلفا به هدایت سایر گرگ‌ها می‌پردازند، و لذا در الگوریتم نقش اساسی ایفا می‌کنند. اما گرگ‌های بتا و دلتا نقش دستیار گرگ آلفا را داشته و گرگ‌های امگا نیز فقط پیرو گرگ رهبر و دستیاران وی هستند^{۳۲}. مدل ریاضی مرحله اول، یعنی محاصره طعمه، به صورت ذیل است (روابط ۱ تا ۴):

$$X(t+1) = X_p(t) - AD \quad (۱)$$

پارامتر D در رابطه ۱ با استفاده از رابطه ۲ محاسبه شد:

$$D = |CX_p(t) - X(t)| \quad (۲)$$

در رابطه‌های ۱ و ۲:

$X_p(t)$ نشان‌دهنده موقعیت شکار در لحظه t: $X(t)$ بیان‌گر موقعیت گرگ در لحظه t و D نیز نشان‌دهنده فاصله گرگ تا شکار است. A و C بردارهای نیز ضریب هستند که به منظور محاسبه آن‌ها از رابطه‌های ۳ و ۴ استفاده شد.

$$A = 2a r1 - a \quad (۳)$$

$$C = 2r2 \quad (۴)$$

در روابط ۳ و ۴: R1 و R2 مقادیر تصادفی بوده و

a پارامتری است که مقدار آن به صورت خطی از عدد ۲ تا صفر کاهش می‌یابد.

در زمان شکار، فرایند حمله توسط گرگ آلفا هدایت می‌شود. از آن‌جا که در الگوریتم گرگ خاکستری فرض بر این است که گرگ‌های آلفا، بتا و دلتا از مکان بالقوه طعمه بیش‌تر آگاهی دارند، لذا، گرگ‌های بتا و دلتا نیز امکان دارد در فرایند حمله گرگ آلفا به شکار مشارکت کنند. در الگوریتم گرگ خاکستری

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (شکل ۳) یک مدل محاسباتی است که از مغز انسان الهام گرفته است. این مدل از نورون‌ها برای پردازش اطلاعات استفاده می‌کند و از قابلیت تعمیم خوب و مقاومت در برابر داده‌های مفقود برخوردار است^{۲۹}. الگوریتم نشر به عقب (Back Propagation, BP) یکی از رویه‌های پرکاربرد برای آموزش شبکه‌های چند لایه است. این الگوریتم با محاسبه خطای خروجی و انتشار آن به سمت لایه‌های ورودی، وزن‌های شبکه را به گونه‌ای تنظیم می‌کند که خطای خروجی کاهش یابد^{۳۰}. مشخصه‌های الگوریتم BP، نشر رو به جلوی سیگنال و نشر معکوس خطا است. در فرایند نشر رو به جلو، سیگنال ورودی از لایه ورودی به لایه مخفی نشر می‌یابد. پس از کنش تابع تحریک خروجی، لایه مخفی به لایه خروجی منتقل می‌شود. نتیجه خروجی به وسیله تاثیر تابع تحریک لایه خروجی حاصل می‌شود. اگر مقدار خروجی مطلوب حاصل نشود فرایند نشر به عقب باید طی شود. خطای بین مقدار واقعی و مقدار خروجی در مسیر متصل شده باز می‌گردد. با شناخت اوزان اتصال هر لایه از نورون‌ها خطا کاهش می‌یابد و سپس فرایند نشر به جلو منتقل می‌شود. از طریق تکرار مراحل فوق تا زمانی که خطا کمتر از یک مقدار آستانه تعیین شده باشد^{۳۱}.

الگوریتم گرگ خاکستری

الگوریتم گرگ خاکستری یکی از الگوریتم‌های مهم الهام گرفته شده از طبیعت و نشأت گرفته از رفتار گرگ‌های خاکستری است. مراحل این الگوریتم به شرح ذیل هستند:

(۱) مشاهده شکار، ردیابی و تعقیب آن

(۲) نزدیک شدن، احاطه کردن و گمراه کردن شکار

(۳) حمله به شکار

در الگوریتم گرگ خاکستری چهار نوع گرگ به شرح ذیل

وجود دارند:

مدل‌سازی کیفی منابع آب زیرزمینی با استفاده از شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی گرگ خاکستری: مورد مطالعه دشت کبودرآهنگ، همدان، ایران

به‌منظور تبدیل فرایند شکار به یک رابطه یا مدل ریاضی از روابط ۵ تا ۱۱ استفاده می‌شود.^{۳۲}

$$D_a = |C_1 X_a - X| \quad (5)$$

$$D_B = |C_1 X_B - X| \quad (6)$$

$$D_\delta = |C_1 X_\delta - X| \quad (7)$$


$$X_1 = X_a - A_1 D_a \quad (8)$$

$$X_2 = X_B - A_2 D_B \quad (9)$$


$$X_3 = X_\delta - A_3 D_\delta \quad (10)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (11)$$

شماتیک مراحل الگوریتم گرگ خاکستری در شکل ۴ نشان داده شده است.



شکل ۳. شبکه عصبی سه لایه با یک ورودی



شکل ۴. مراحل الگوریتم گرگ خاکستری

نحوه ورود داده‌ها در مدل

در تحقیق حاضر، برای پیش‌بینی مقادیر پارامترهای pH، هدایت الکتریکی (EC) و TDS به اطلاعات پارامترهای کلسیم، منیزیم، کلراید، سولفات، سدیم و کدورت به‌عنوان متغیر ورودی نیاز بود. بنابراین، سه متغیر TDS، EC و pH

نقش متغیرهای خروجی یا وابسته را ایفا کرده و ۶ متغیر مارالذکر نقش متغیرهای اثرگذار یا مستقل یا ورودی را ایفا می‌کنند. در ادامه، برای پیش‌بینی هر یک از متغیرهای خروجی از روابط ۱۲ تا ۱۴ استفاده شد:

(۱۲)

$$TDS = C_1 Ca + C_2 Mg + C_3 Cl + C_4 SO_4 + C_5 Turb + C_6 Na$$

(۱۳)

$$EC = C_1 Ca + C_2 Mg + C_3 Cl + C_4 SO_4 + C_5 Turb + C_6 Na$$

(۱۴)

$$pH = C_1 Ca + C_2 Mg + C_3 Cl + C_4 SO_4 + C_5 Turb + C_6 Na$$

از طرفی، توابع هدف یا برازندگی (Fitness) با استفاده از روابط ۱۵ تا ۱۷ محاسبه شدند:

$$MSE_{TDS} = \sum_{i=1}^N \frac{1}{N} (TDS_i - \overline{TDS})^2 \quad (15)$$

$$MSE_{EC} = \sum_{i=1}^N \frac{1}{N} (EC_i - \overline{EC})^2 \quad (16)$$


$$MSE_{pH} = \sum_{i=1}^N \frac{1}{N} (pH_i - \overline{pH})^2 \quad (17)$$

یافته ها

نتایج تشریح مدل

نتایج بررسی ارتباط بین ۶ متغیر ورودی کلسیم، منیزیم، کلراید، سولفات، کدورت و سدیم و سه متغیر خروجی TDS، EC و pH منابع آب با استفاده از شبکه عصبی مصنوعی در شکل های ۵ تا ۱۱ آورده شده است.


در رابطه های ۱۲ تا ۱۷: C1, C2, C3, C4, C5, C6 نشان دهنده ضرائب وزنی برای شش متغیر ورودی هستند. در الگوریتم گرگ خاکستری، میانگین توان دوم خطاها (MSE) برای متغیرهای هدایت الکتریکی، pH و TDS بر اساس تفاضل هر مقدار از مقدار پیش بینی شده و با استفاده از شبکه عصبی به تفکیک هر متغیر خروجی با استفاده از نسخه 2021 نرم افزار متلب محاسبه شد.



شکل ۵. نمودار نتایج عملکرد شبکه عصبی مصنوعی


نتایج مندرج در شکل ۵ نشان دهنده نزولی شدن نمودار آموزش و همچنین حداقل شدن نمودار اعتبارسنجی است که این خود بیانگر عملکرد درست شبکه عصبی و از طرفی تحقق بهینه سازی در تکرار چهارم است.

در اولین گام و با توجه به شکل ۵ می توان دریافت که عملکرد شبکه عصبی به بهینه سازی رسیده است یا خیر. به عبارت دیگر، حداقل سازی داده های اعتبارسنجی و همچنین نزولی شدن نمودار آموزش داده ها محقق گردیده یا خیر.




شکل ۶. نمودار نتایج شیب شبکه عصبی

نتایج مندرج در شکل ۶ نیز به شکل دقیق تر نشان دهنده روند نزولی داده های آموزش در شبکه عصبی بوده که دلالت بر عملکرد صحیح شبکه عصبی دارد.



شکل ۷. نمودار نتایج مطلوبیت نهایی (Marginal Utility, MU)


شکل ۷ (نمودار MU) نشان دهنده آن است که در هنگام بهینه سازی، مقدار مطلوبیت نهایی به حداکثر خود رسیده و در همین میزان باقی مانده است. این در حالی است که از تکرار چهارم به بعد، مقدار MU به بیشینه مقادیر خود رسیده و دیگر افت نکرده است.



شکل ۸. نمودار نتایج بررسی اعتبارسنجی


در شکل ۸ مشاهده می شود که پس از تحقق بهینه سازی در تکرار چهارم، از این تکرار به بعد، نقاط اعتبارسنجی ماهیت صعودی یافته و به پیک خود رسیده اند که این نیز دلیل دیگری بر عملکرد صحیح شبکه عصبی در بخش داده های اعتبارسنجی است.


مدل‌سازی کیفی منابع آب زیرزمینی با استفاده از شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی گرگ خاکستری: مورد مطالعه دشت کبودرآهنگ، همدان، ایران



شکل ۹. هیستوگرام‌های خطا

نتایج مربوط به هیستوگرام خطا در شکل ۹ نشان داده شده است. با استناد به یافته‌ها می‌توان اذعان داشت که عبارات خطا از توزیع نرمال برخوردار بوده و همچنین از توزیع اولیه داده‌های اعتبارسنجی آزمون و آموزش تبعیت کرده است. از این‌رو، بر اساس نرمال بودن توزیع عبارات خطا می‌توان اعتبار مدل شبکه عصبی در تحقیق حاضر را مورد تأیید قرار داد. شکل ۱۰. نمودار رگرسیون، (الف) آموزش، (ب) آزمون، (ج) اعتبارسنجی و (د) کل داده‌ها






بالایی می‌توانند تبیین کننده متغیرهای خروجی تحقیق در بخش داده‌های آموزش باشند. خلاصه نتایج حاصل از شبکه عصبی مصنوعی شامل مشخصه‌های کل داده‌ها و همچنین داده‌های آموزش، اعتبارسنجی و آزمون در جدول ۱ آورده شده است.

نتایج رگرسیون آموزش، آزمون، اعتبارسنجی و کل داده‌ها در شکل ۱۰ (الف تا د) آورده شده است. همان‌طور که در شکل ۱۰ الف مشاهده می‌شود، رگرسیون داده‌های آموزش با $R = 0.99746$ توزیع بسیار بالای متغیرهای ورودی را نشان می‌دهد. به عبارت دیگر، می‌توان اذعان داشت که متغیرهای ورودی تا حد بسیار


جدول ۱. خلاصه نتایج شبکه عصبی

R	MSE	مشاهدات	مجموعه داده‌ها
۰/۹۹۷۵	۰/۰۰۱۷	۶۹۷	آموزش
۰/۹۹۶۵	۰/۰۰۲۳	۱۴۹	اعتبارسنجی
۰/۹۹۵۷	۰/۰۰۲۸	۱۴۹	آزمون
۰/۹۹۷۰۵	۰/۰۰۱۵	۹۹۶	کل داده‌ها

نتایج مقایسه مقادیر MSE بین داده‌ها و به‌علاوه، نتایج مقایسه مقادیر R بین داده‌ها به‌ترتیب در شکل‌های ۱۱ و ۱۲ آورده شده‌اند.



شکل ۱۱. نتایج مقایسه مقادیر MSE بین داده‌ها




شکل ۱۲. نتایج مقایسه مقادیر R بین داده‌ها

نتایج کاهش خطای پیش‌بینی با الگوریتم گرگ خاکستری

نتایج مربوط به کاهش خطای پیش‌بینی به تفکیک عبارات خطای MSE در شکل ۱۳ آورده شده است.

نتایج مقایسه مقادیر MSE بین داده‌ها (شکل ۱۱) نشان داد که مقدار خطای کل داده‌ها نسبت به سه نوع دیگر از داده‌ها کم‌تر بوده است. از طرفی، نتایج مقایسه مقادیر R بین داده‌ها نیز بیان‌گر آن بود که مقدار R داده‌های آموزش بیش‌تر از سایر داده‌ها بوده است (شکل ۱۲).



شکل ۱۳. نتایج کاهش مقدار MSE با استفاده از الگوریتم گرگ خاکستری

همان‌طور که مشاهده می‌شود، الگوریتم گرگ خاکستری منجر به کاهش خطای MSE و حداقل‌سازی "خطای پیش‌بینی" شده است. به بیان دیگر، خطای پیش‌بینی بدست آمده با استفاده از شبکه عصبی با کمک الگوریتم گرگ خاکستری بهینه شده است.



شکل ۱۴. نتایج مقایسه مقدار MSE پیش از پیاده‌سازی الگوریتم گرگ خاکستری و پس از آن

نتایج مقایسه مقدار MSE پیش و پس از پیاده‌سازی الگوریتم گرگ خاکستری در شکل ۱۴ نشان داده شده است. با استناد به نتایج، مشاهده می‌شود که در ۱۰ تکرار انجام یافته برای مقایسه الگوریتم‌های شبکه عصبی مصنوعی و گرگ خاکستری، GWO منجر به کاهش "خطای پیش‌بینی" شده است.

بحث

این پژوهش با هدف مدل‌سازی کیفیت منابع آب زیرزمینی دشت کبودرآهنگ همدان با استفاده از مدل داده هوشمند جدید مبتنی بر الگوریتم بهینه‌سازی گرگ خاکستری انجام یافت یافته‌های حاصل از پیاده‌سازی شبکه عصبی مصنوعی نشان داد که ANN موفق به پیش‌بینی کیفیت آب شده است. با توجه به وجود ۶ متغیر کلسیم، منیزیم، کلراید، سولفات، کدورت و سدیم به عنوان متغیرهای ورودی و پارامترهای EC، TDS و pH به عنوان متغیرهای خروجی، نتایج شبکه عصبی نشان داد که بیش‌تر از ۹۹ درصد تغییرات کیفی آب و از طرفی مقادیر سه متغیر خروجی تحت تاثیر ۶ متغیر ورودی بوده است. علاوه بر این، با استناد به نمودار عملکرد شبکه عصبی (شکل ۵)، نزولی شدن نمودار آموزش و همچنین حداقل شدن نمودار اعتبارسنجی و تحقق بهینه‌سازی توسط این الگوریتم و همچنین، هیستوگرام‌های خطا که از توزیع نرمال تبعیت کردند (شکل ۹)، می‌توان صحت و عملکرد شبکه عصبی پیاده‌سازی شده در تحقیق حاضر را تأیید کرد. از طرف دیگر، نمودار شیب شبکه عصبی (شکل ۶) شیب نزولی و نمودارهای MU و اعتبارسنجی (شکل‌های ۷ و ۸) نیز روند صعودی را در تکرار چهارم پس از تحقق بهینه‌سازی نشان دادند که همه این موارد عملکرد درست و مناسب شبکه عصبی را تأیید می‌کنند.

خط پراکنش یا رگرسیون شبکه عصبی (شکل ۱۰) نیز نشان داد که تا حد ممکن خط ترسیم شده نزدیک به نقاط داده

بوده و بنابراین، بیشینه نزدیکی را به همه داده‌های آموزش، اعتبارسنجی و آزمون داشته است. علاوه بر این، مقادیر R به ترتیب برابر با ۰/۹۹۷۴۶، ۰/۹۹۵۷۴، ۰/۹۹۶۴۵ و ۰/۹۹۷۰۵ برای نتایج رگرسیون آموزش، آزمون، اعتبارسنجی و کل داده‌ها نشان‌دهنده تناسب بسیار بالای مدل است. به این مفهوم که تغییر در سه متغیر EC، TDS و pH تا حد بسیار زیاد توسط شش متغیر ورودی پیش‌بینی می‌شوند. به بیان دیگر، این شش متغیر توانایی بالایی در تبیین سه متغیر خروجی داشته‌اند و همچنین میزان خطای اندکی توسط آن‌ها حاصل شده است. از سوی دیگر، مقدار خطای شبکه عصبی یعنی MSE در سطح پائین و قابل قبولی قرار داشت که می‌تواند ملاک مقایسه با سایر روش‌های مشابه برای پیش‌بینی قرار گیرد. در مجموع، می‌توان اذعان داشت که الگوریتم شبکه عصبی روش مناسبی برای پیش‌بینی کیفیت آب با توجه به متغیرهای ورودی بوده است.

نتایج، نشان‌دهنده حداقل سازی خطای پیش‌بینی پس از ترکیب ANN و GWO است. به‌طوری‌که میانگین کاهش خطای پیش‌بینی توسط GWO از ۰/۰۰۰۸ تا ۰/۰۰۱ متغیر بود و از این‌رو، می‌توان اذعان داشت که در مجموع این الگوریتم موفق به بهینه‌سازی عملکرد شبکه عصبی شده است. همان‌طور که در شکل ۱۳ مشاهده می‌شود، منحنی آبی که نشان‌دهنده میانگین عبارات خطا است، ماهیت نزولی یافته و در ادامه همگرایی دو منحنی قرمز و آبی مشاهده می‌شود که خود بیان‌گر همگرایی بیش‌تر اصلاحات اعمال شده برای کاهش میزان خطا و به حداقل رساندن آن به شکل بهینه است. با استناد به نتایج مقایسه مقدار MSE پیش و پس از پیاده‌سازی الگوریتم گرگ خاکستری (شکل ۱۴)، مشاهده شد که در تکرارهای انجام یافته، GWO منجر به کاهش "خطای پیش‌بینی" شده است. بدین مفهوم که در همه تکرارها بین دو الگوریتم خطوط آبی و نارنجی تفاوت معنی‌دار مشاهده می‌شود. نتایج مقایسه "خطای پیش‌بینی" برای چهار مجموعه داده "آموزش"، "آزمون"، "اعتبارسنجی" و "کل داده‌ها" نشان

قابلیت الگوریتم شبکه عصبی مصنوعی در پیش‌بینی کیفی منابع آب زیرزمینی، گزارش کردند که مقادیر R و MSE حاصل در مقایسه با پژوهش حاضر از دقت کم‌تری برخوردار بوده است.

نتیجه‌گیری

نتایج نشان دادند که الگوریتم شبکه عصبی مصنوعی از قابلیت مناسب پیش‌بینی کیفی منابع آب زیرزمینی بر اساس سه متغیر pH ، EC و TDS برخوردار بوده است. به بیان دیگر، مشخص شد که متغیرهای انتخابی شامل کلسیم، منیزیم، کلراید، سولفات، کدورت و سدیم تا حد زیادی قادر به پیش‌بینی و در واقع اثرگذاری بر پارامترهای TDS ، EC و pH بوده‌اند. در این خصوص، می‌توان به مقدار $R = 0.9975$ که نشان‌دهنده پیشگویی بالای این متغیرها در ارزیابی کیفی منابع آب زیرزمینی است، اشاره کرد. به‌طور کلی، نتایج پیاده‌سازی الگوریتم شبکه عصبی مصنوعی نشان‌دهنده صحت و همچنین قابلیت بالای پیش‌بینی و خطای اندک مدل بود که این خطای اندک نیز با استفاده از الگوریتم گرگ خاکستری کاهش یافت. بنابراین، می‌توان اذعان داشت علی‌رغم این‌که مدل شبکه عصبی مصنوعی تا حد زیادی قادر به پیش‌بینی کیفیت منابع آب زیرزمینی در منطقه مورد مطالعه بود، الگوریتم گرگ خاکستری با کاهش خطای پیش‌بینی، این عملکرد را تکمیل کرده و بهینگی مدل را افزایش داد. از این‌رو، از آنجا که الگوریتم‌های ANN و GWO مکمل یکدیگر بوده و عملکرد خوبی را برای پیش‌بینی نشان دادند، استفاده از آن‌ها برای پیش‌بینی تغییرات کیفی منابع آب زیرزمینی در سایر مناطق هم پیشنهاد می‌شود.

داد که در همه موارد، الگوریتم گرگ خاکستری موفق به کاهش میزان "خطای پیش‌بینی" شده است. برای مثال در تکرار اول، خطای پیش‌بینی برابر با 0.017 بوده است که بعد از پیاده‌سازی الگوریتم گرگ خاکستری مقدار آن به 0.0007 تنزل یافته است. یا در خصوص کل داده‌ها، در تکرار اول مقدار خطای پیش‌بینی برابر با 0.015 بوده است که بعد از پیاده‌سازی GWO به 0.0008 تنزل یافته است، که این خود نشان‌دهنده کاهش چشمگیر خطای پیش‌بینی در هر دو مورد است. بنابراین، می‌توان اذعان داشت که الگوریتم گرگ خاکستری در بهبود پیش‌بینی کیفیت منابع آب عملکرد موفق‌تری داشته و می‌تواند در سایر پژوهش‌های مشابه نیز مورد استفاده قرار گیرد.

قبادی و همکاران (۲۰۲۲) در پژوهشی قابلیت مدل ترکیبی شبکه عصبی و الگوریتم گرگ خاکستری را در پیش‌بینی کیفیت منابع آب زیرزمینی دشت اسداباد همدان تایید کردند که نتایج تحقیق حاضر را تایید می‌کند^{۳۷}. جعفرزاده و خاشعی سیوکی (۲۰۱۸) نیز کارایی تلفیق الگوریتم‌های ANN و GWO در پیش‌بینی تغییرات مقادیر کمی در منابع آب زیرزمینی دشت بیرجند را مورد تایید قرار دادند^{۳۳}. در پژوهشی دیگر، از ترکیب الگوریتم شبکه عصبی و الگوریتم ازدحام ذرات برای پیش‌بینی تغییرات کیفی پارامترهای TDS ، EC و SAR در منابع آب زیرزمینی دشت بهبهان استفاده و مشخص شد که نتایج حاصل از دقت کم‌تری در مقایسه با پژوهش حاضر برخوردار بوده است^{۳۴}. نتایج مطالعه امامی و امامی (۲۰۱۹) نیز دقت الگوریتم گرگ خاکستری برای ارزیابی کیفیت هیدروژن‌نوشیمیایی آب زیرزمینی را مورد تایید قرار دادند^{۳۳}. العادیل و همکاران (۲۰۲۲) نیز ضمن تایید

تقدیر و تشکر

این مقاله برگرفته از پایان‌نامه کارشناسی ارشد مهندسی محیط‌زیست مصوب واحد همدان دانشگاه آزاد اسلامی با کد ۱۷۱۴۲۹۷۰۰۶۹۰۷۶۴۲۱۵۰۱۹۱۶۲۶۳۲۰۲۷ است که بدین‌وسیله نویسندگان از حوزه معاونت پژوهش و فن‌آوری دانشگاه برای فراهم کردن امکانات اجرای مطالعه سپاسگزاری می‌کنند.

References

1. Shiklomanov IA. Appraisal and assessment of world water resources. *Water Int* 2000; 25(1): 11-32.
2. Sobhanardakani S, Maanijou M, Asadi H. Investigation of Pb, Cd, Cu and Mg concentrations in groundwater resources of Razan Plain. *Sci J Hamadan Univ Med Sci* 2015; 21(4): 319-29 (In Persian).
3. Sobhanardakan S, Taghavi L, Shahmoradi B, et al. Groundwater quality assessment using the water quality pollution indices in Toyserkan Plain. *Environ Health Eng Manage J* 2017; 4(1): 21-7.
4. Makarigakis AK, Jimenez-Cisneros BE. UNESCO's contribution to face global water challenges. *Water* 2019; 11(2): 388.
5. Yari AR, Sobhanardakan S. Water quality assessment of groundwater resources in Qaleeh Shahin Plain based on Cd and HEI. *Int Arch Health Sci* 2016; 3(3): 101-06.
6. Sobhanardakani S. Evaluation of the water quality pollution indices for groundwater resources of Ghahavand Plain, Hamedan Province, western Iran. *Iran J Toxicol* 2016; 10(3): 35-40.
7. Sabzevari Y, Zeinivand H. Evaluation of groundwater quality for different uses, case study: Delfan plain. *J Geogr Space* 2022; 22(78): 55-71 (In Persian).
8. Askari J, Egdernezhad A. Groundwater modeling using artificial intelligence methods (Case study: Dezful-Andimeshk plain). 2022; 8(2): 160-71 (In Persian).
9. Alizamir M, Sobhanardakani S. An artificial neural network - particle swarm optimization (ANN- PSO) approach to predict heavy metals contamination in groundwater resources. *Jundishapur J Health Sci* 2018; 10(2): e67544.
10. Aldhyani THH, Al-Yaari M, Alkahtani H, et al. Water quality prediction using artificial intelligence algorithms. *Appl Bionic Biomechanic* 2020; 2020: 6659314.
11. Alizamir M, Sobhanardakani S. A comparison of performance of artificial neural networks for prediction of heavy metals concentration in groundwater resources of Toyserkan Plain. *Avicenna J Environ Health Eng* 2017; 4(1): e11792.
12. Al-Adhaileh MH, Aldhyani THH, Alsaade FW, et al. Groundwater quality: The application of artificial intelligence. *J Environ Publ Health* 2022; 2022: 8425798.
13. Rajaei T, Pouraslan F. Temporal and spatial forecast of Davarzan plain groundwater level. *Hydrogeomorphology* 2015; 2(4): 1-19 (In Persian).
14. Alizamir M, Sobhanardakani S, Hasanaliipour Shahrabadi A. Prediction of heavy metals concentration in the groundwater resources in Razan Plain: Extreme learning machine vs. artificial neural network and multivariate adaptive regression spline. *Annal Mil Health Sci Res* 2019; 17(4): e98554.
15. Farooq MU, Zafar AM, Raheem W, et al. Assessment of algorithm performance on predicting total dissolved solids using artificial neural network and multiple linear regression for the groundwater data. *Water*, 2022; 14(13): 2002.
16. Che Nordin NF, Mohd NS, Koting S, et al. Groundwater quality forecasting modelling using artificial intelligence: A review. *Groundwater Sustain Dev* 2021; 14: 100643.
17. Ghobadi A, Cheraghi M, Sobhanardakani S, et al. Groundwater quality modeling using a novel hybrid data-intelligence model based on gray wolf optimization algorithm and multi-layer perceptron artificial neural network: a case study in Asadabad Plain, Hamedan, Iran. *Environ Sci Pollut Res* 2022; 29(6): 8716-30.
18. Bui DT, Khosravi K, Tiefenbacher J, et al. Improving prediction of water quality indices using novel hybrid machine-learning algorithms. *Sci Total Environ* 2020; 721: 137612.
19. Alizamir M, Kazemi Z, Kazemi Z, et al. Investigating landfill leachate and groundwater quality prediction using a Robust Integrated Artificial Intelligence Model: Grey Wolf Metaheuristic Optimization Algorithm and Extreme Learning Machine. *Water* 2023; 15(13): 2453.
20. Abbasi Teshnizi F, Nouri Emamzadehei MM. Assessment of groundwater quality in Kaboudarahang Plain using factor and cluster analysis. *Environ Water Eng* 2017; 3(3): 272-9 (In Persian).
21. Emami S, Noruzi-Sarkarabad R, Choopan Y. Use of artificial neural network and imperialist competitive algorithm to evaluate the groundwater quality of Jolfa Plain for various uses. 2021; 53(1): 313-30 (In Persian).
22. Sadatinejadi, SJ, Ghasemi L, Yousefi H. Redesign of groundwater monitoring network Kuhdasht Aquifer. *Ecohydrology* 2019; 5(4): 1255-66 (In Persian).
23. Emami H, Emami S. Presentating a New Approach for evaluating the hydro-geochemical quality of groundwater using Swarm Intelligence Algorithms. 2019; 6(1): 177-90 (In Persian).
24. Bahrami F, Egdernezhad A. Comparison of Artificial Neural Network and Kriging models in predicting

- groundwater quality parameters (SAR, TDS and EC) of Dezful Andimeshk plain. J Res Environ Health 2023; 8(4): 365-77 (In Persian).
25. Majumder P, Eldho TI. Artificial Neural Network and Grey Wolf Optimizer based Surrogate Simulation-Optimization Model for groundwater remediation. Water Res Manage 2020; 34(2): 763-83.
 26. Tikhamarine Y, Souag-Gamane D, Najah Ahmed A, et al. Improving artificial intelligence models accuracy for monthly streamflow forecasting using grey Wolf optimization (GWO) algorithm. J Hydrol 2020; 582, 124435.
 27. Moayedi H, Salari M, Dehrashid AA, et al. Groundwater quality evaluation using hybrid model of the multi-layer perceptron combined with neural-evolutionary regression techniques: case study of Shiraz plain. Stoch Environ Res Risk Assess 2023; 37(8): 2961-76.
 28. Bahmani O, Zali A. Investigation and determination of the spatial distribution of nitrate and electrical conductivity in groundwater by geostatistical method (Case study: Kabudrahng Plain). J Environ Sci Technol 2021; 23(5): 143-57 (In Persian).
 29. Göçken M, Özçalıcı M, Boru A, et al. Integrating metaheuristics and Artificial Neural Networks for improved stock price prediction. Expert Sys Appl 2016; 44: 320-31.
 30. Wang J, Wang J. Forecasting stock market indexes using principle component analysis and stochastic time effective neural networks. Neurocomputing 2015; 156: 68-78.
 31. Chi T. Understanding Chinese consumer adoption of apparel mobile commerce: An extended TAM approach. J Retail Consum Serv 2018; 44, 274-84.
 32. Mirjalili S, Mirjalili SM, Lewis A. Grey wolf optimizer. Adv Eng softw 2014; 69: 46-61.
 33. Jafarzadeh A, Khashei Siuki A. Performance examination of optimization model of groundwater monitoring network based on Gray wolf and Neural network (GNM) (Case study: Birjand plain). J Irrig Water Eng 2018; 8(3): 121-39 (In Persian).
 34. Ahaninjan K, Egdernezhad A. Modeling qualitative parameters of SAR, EC, and TDS in groundwater using optimized artificial neural network model (Case study: Behbahan Plain). 2020; 6(2): 161-72 (In Persian).

Qualitative modeling of groundwater resources using Artificial Neural Network and Gray Wolf Optimizer algorithm (Case Study: Kabudarahang Plain, Hamedan Province, Iran)

Mahdi Pirzad¹, Soheil Sobhanardakani^{2*}

1. M.Sc. in Environmental Engineering, Department of Environmental Engineering, College of Engineering, Hamedan Branch, Islamic Azad University, Hamedan, Iran.

2. Ph.D. in Environmental Science, Professor in Environmental Science, Department of the Environment, College of Basic Sciences, Hamedan Branch, Islamic Azad University, Hamedan, Iran.

Email: : s_sobhan@iauh.ac.ir

Received: 2 November 2023 , Accepted: 3 December 2023

ABSTRACT

Background: Climate change and declining rainfall have significantly reduced access to surface water in Iran, particularly in Hamedan Province. This has led to increased reliance on groundwater resources, consequently altering their quality for various uses. Therefore, this study was conducted to develop a qualitative model for assess of groundwater resources in Kabudarahang Plain, Hamedan Province, using an Artificial Neural Network (ANN) and the Gray Wolf Optimizer (GWO) algorithm.

Methods: Qualitative data of groundwater resources in Kabudarahang Plain were collected and analyzed over a decade (2012-2022). ANN modeling was employed to predict groundwater quality changes. Additionally, the GWO algorithm was integrated to enhance prediction accuracy. The model utilized three output or dependent variables (TDS, EC, and pH) and six input or independent variables (calcium, magnesium, chloride, sulfate, sodium, and turbidity).

Results: : The ANN model demonstrated that over 99% of water quality variations can be attributed to the six input variables. Moreover, the GWO algorithm effectively reduced average prediction errors from 0.0015 to 0.0008.

Conclusion: The ANN algorithm exhibited high prediction accuracy, low prediction error, and model optimality, which were further enhanced by the GWO algorithm. This suggests that while the ANN model successfully predicted groundwater quality changes in the study area, the GWO algorithm refined the predictions, and improving the model's overall performance. Considering the complementary nature and effectiveness of ANN and GWO algorithms for prediction, their application to predict qualitative changes in groundwater resources in other regions is recommended.

Keywords: Groundwater quality, Intelligent data modeling, Artificial neural network, Gray wolf algorithm, Kabudarahang Plain.