



Groundwater spring potential mapping using a novel hybrid of convolutional neural network with whale optimization algorithms (WOA) and bee colony (ABC)

Sotoude Dadkhah Bakhshayesh¹ | Aminreza Neshat^{2*} | Omid Tayari³

1. Department of Remote Sensing and Geographic Information System, Faculty of Natural Resources and Environment, Science, Science and Research Unit, Islamic Azad University, Tehran. iransotoude.bakhshayesh@gmail.com
2. Assistant Professor, Educational Department of Remote Sensing and Spatial Information Systems, Faculty of Environment and Energy, Islamic Azad University, Research Sciences Unit, Tehran, neshat.aminreza@srbiau.ac.ir
3. Assistant Professor, Department of Civil Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran, omiid.tayarii@yahoo.com

Article History

Received January 01, 2024

Revised February 06, 2024

Accepted March 16, 2024

Abstract

Limited groundwater resources and their overuse have become fundamental challenges for sustainable development worldwide. In this study, a combination of step-by-step weighted evaluation ratio analysis (SWARA), deep learning method of convolutional neural network (CNN), whale optimization (WOA) and bee colony algorithms (ABC) be applied, which approach provides an innovative method to produce the groundwater spring potential in Kermanshah province. In the first stage, a map containing 301 spring locations with a flow rate of more than 30 cubic meters per second and 304 points without springs was prepared. Thirteen parameters were created as independent variables. The SWARA method was used to determine the weight of the criteria, decision-making indicators and determine the relationship between the spring creation potential and the selected factors. Then, CNN-WOA hybrid model be applied to prepare the groundwater spring potential, and then it will be evaluated from the performance characteristic curve (ROC) and some other statistical evaluations. The validation of the training dataset illustrated that the success rate for SWARA-CNN-WOA, SWARA-CNN-ABC models is 86%, 91%, respectively. The results showed that the SWARA-CNN-ABC model performed better than other models with a small difference. In addition, the prediction rate evaluation revealed that the values under the ROC curve for SWARA-CNN-ABC, SWARA-CNN-WOA models are 87%, 88%, respectively. Based on the results, despite the excellent performance of all models, the SWARA-CNN-ABC model has made more accurate predictions. The hybrid models presented in this study can be used as an efficient and effective methodology to improve groundwater potential.

Keywords

Groundwater potential, CNN, VOA, ABC



پتانسیل یابی چشمه‌های آب زیرزمینی با استفاده از ترکیب جدید شبکه عصبی کانولوشنی با الگوریتم‌های بهینه‌سازی نهنگ (WOA) و کلونی زنبور عسل (ABC)

ستوده دادخواه بخشایش^۱ | امین رضا نشاط^۲ | امید طیاری^۳

۱. گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده منابع طبیعی و محیط زیست، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران. ایران. sotoude.bakhshayesh@gmail.com
۲. استادیار گروه آموزشی سنجش از دور و سیستم‌های اطلاعات مکانی، دانشکده محیط زیست و انرژی، دانشگاه آزاد اسلامی واحد علوم تحقیقات، تهران، neshat.aminreza@srbiau.ac.ir
۳. استادیار گروه مهندسی عمران، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. omiid.tayarii@yahoo.com

تاریخ‌های مقاله

تاریخ دریافت: ۱۴۰۲/۱۰/۱۱

تاریخ بازنگری: ۱۴۰۲/۱۱/۱۷

تاریخ پذیرش: ۱۴۰۲/۱۲/۲۶

چکیده

منابع آب زیرزمینی محدود و استفاده زیاد از آن‌ها به چالش‌های اساسی برای توسعه پایدار در سراسر جهان تبدیل شده است. در مطالعه حاضر از روش تجزیه و تحلیل نسبت ارزیابی گام به گام اوزان (SWARA)، روش یادگیری عمیق شبکه عصبی کانولوشن (CNN)، بهینه‌سازی نهنگ (WOA) و الگوریتم‌های کلونی زنبور عسل (ABC) استفاده شد و بارویکرد نوآورانه روش‌های ترکیبی به ارائه نقشه پتانسیل چشمه‌های آب زیرزمینی استان کرمانشاه پرداخت. در مرحله اول، یک نقشه شامل ۳۰۱ مکان چشمه بادبی بالای ۳۰ متر مکعب بر ثانیه و در ادامه سیزده پارامتر به عنوان متغیرهای مستقل ایجاد شدند. برای تعیین وزن معیارها، تعیین ارتباط بین پتانسیل ایجاد چشمه و عوامل انتخاب شده روش SWARA مورد استفاده قرار گرفت. سپس برای تهیه نقشه پتانسیل چشمه‌های آب زیرزمینی از مدل ترکیبی CNN-WOA استفاده شد. در انتها از منحنی مشخصه عملکرد (ROC) برای ارزیابی مدل‌ها استفاده شد. نتایج حاصل از اعتبارسنجی مجموعه داده آموزش برای مدل‌های SWARA-CNN-WOA، SWARA-CNN-ABC به ترتیب ۸۶ و ۹۱ درصد است. نتایج نشان داد با اختلاف کم، مدل SWARA-CNN-ABC عملکرد بهتری نسبت به مدل دیگر داشت. به علاوه، ارزیابی نرخ پیش‌بینی مشخص کرد که مقادیر زیرمنحنی ROC برای مدل‌های SWARA-CNN-ABC، SWARA-CNN-WOA به ترتیب ۸۷ و ۸۸ درصد است. بر اساس نتایج حاصل، هر دو مدل عملکرد مطلوبی داشتند، اما مدل SWARA-CNN-ABC پیش‌بینی دقیق‌تری را انجام داده است. مدل‌های ترکیبی ارائه شده در پژوهش حاضر می‌توانند به عنوان یک روش کارآمد و مؤثر برای بهبود پتانسیل یابی آب زیرزمینی مورد استفاده قرار گیرند.

کلیدواژگان

پتانسیل آب زیرزمینی، CNN، WOA، ABC

مقدمه

آب برای بقا و معیشت همه موجودات زنده روی کره زمین ضروری است. آب‌های زیرزمینی کارآمدترین و پایدارترین منبع آبی هستند که تحت تأثیر نوسانات اقلیمی یک منطقه خاص قرار نمی‌گیرند (۱). به دلیل اهمیت زیاد آب‌های زیرزمینی، پایش و ارزیابی منظم کمیت و کیفیت آن ضرورت بالایی به‌ویژه در مناطق خشک و نیمه خشک دارد (۲). بررسی کیفیت آب‌های زیرزمینی به منظور جلوگیری از تنش آبی طی سال‌های آینده و مدیریت صحیح آن اهمیت مسئله را دوچندان می‌کند (۳). به دلیل رشد جمعیت و رشد اقتصادی، پیش‌بینی می‌شود که تقاضا برای آب‌های زیرزمینی در آینده افزایش پیدا کند (۴).

سهم ایران از منابع آب شیرین جهان نسبت به مناطق دیگر در سطوح پایین‌تری قرار دارد. در سال‌های اخیر میانگین بارندگی ایران به صورت تقریبی ۶ درصد کمتر از میانگین بلندمدت است. روند نزولی سطح ایستابی منابع آب زیرزمینی تشدید شده و آب زیرزمینی کاهش پیدا کرده است (۵). طبق برآوردهای انجام شده، آب‌های زیرزمینی حدود ۶۵ درصد از آب‌های مصرفی را شامل می‌شود (۶). بهره‌برداری بی‌رویه از آب‌های زیرزمینی طی سال‌های اخیر موجب به هم زدن تعادل و افت سطح آب‌های زیرزمینی در بسیاری از آبخوان‌های کشور شده است (۷). از سوی دیگر، کشور ایران به دلیل قرارگیری در کمربند خشک و نیمه خشک جهان در ردیف کشورهای قرار می‌گیرد که با محدودیت منابع آبی مواجه هستند و بررسی آب زیرزمینی در نواحی خشک و نیمه خشک به عنوان منابع آبی بیشتر حائز اهمیت است (۸). بررسی وضعیت بارش در ایران در پنجاه سال گذشته حاکی از آن است که روند بلندمدت بارندگی نزولی بوده و حجم بارندگی در سال‌های اخیر نسبت به گذشته کاهش یافته است. کشاورزی از حیاتی‌ترین بخش‌های اقتصادی در ایران است و از این رو، آگاهی از وضعیت منابع آب زیرزمینی و پتانسیل آن به‌ویژه در مناطق کم‌آب می‌تواند برای غلبه بر این بحران مفید باشد (۹).

پتانسیل آب زیرزمینی احتمال وقوع یا وجود آب زیرزمینی در یک منطقه است (۱۰). با این حال، آب زیرزمینی یک منبع نامحدود نیست و از کارآمدترین روش‌ها برای حفاظت و مدیریت آب‌های زیرزمینی شناسایی بهینه‌بندی پتانسیل آب زیرزمینی است (۱۰).

روش‌های متعددی برای بهینه‌بندی پتانسیل آب‌های زیرزمینی و بهره‌برداری از آن‌ها وجود دارد. در سال‌های اخیر، تکنولوژی GIS و سنجش از دور به دلیل تواناییشان در مدیریت حجم عظیم داده‌های مکانی به ابزارهای مؤثری برای نقشه‌برداری پتانسیل آب‌های زیرزمینی تبدیل شده‌اند (۱۰). با پیشرفت علم و تکنولوژی انواع مدل‌های احتمالی برای تهیه نقشه پتانسیل یابی آب‌های زیرزمینی، مثل نسبت فراوانی، تصمیم‌گیری چندمعیاره، رگرسیون لجستیک، یادگیری ماشین و... به کمک کارشناسان آمده است. از سوی دیگر، روش‌های پرکاربرد اخیر مانند نقشه‌برداری پتانسیل آب زیرزمینی با استفاده از مدل‌های دومتغیره یا نظر خبرگان، Logistic، Frequency Ratio، Shannon Entropy و Regression، با وجود اینکه تفسیر آسانی دارند، اما به دلیل ساختار ساده‌شان، از قدرت پیش‌بینی قابل اعتمادی برخوردار نیستند (۱۱). همراه با افزایش تعداد و پیچیدگی داده‌ها در GIS، یک مدل قابل اعتماد برای کمک به حل این مشکلات مورد نیاز است. لذا در این مطالعه که با هدف پتانسیل یابی چشمه‌های آب زیرزمینی در استان کرمانشاه انجام شده است، برای بهبود دقت و رفع ضعف‌های تحقیقات پیشین، از SWARA برای وزن‌دهی لایه‌ها استفاده شد تا نوعی هماهنگی و همسانی در نظرات خبرگان ایجاد شود.

یادگیری ماشین روشی است که در آن اعتبارسنجی مدل و تفسیر نتایج پژوهش، از طریق علوم ریاضی و به‌ویژه آمار و احتمالات انجام می‌شود. در یادگیری ماشین، می‌توان به پردازش داده‌های عددی و انواع متنوع آن پرداخت

و همچنین، در طرح‌های پژوهشی جدید می‌توان از آن استفاده کرد. اما با وجود ازدیاد روزافزون داده‌ها و پیچیدگی موضوع، استخراج دانش و کشف الگو ناممکن به نظر می‌رسد. از این رو، نیاز به استفاده از رایانه‌ها در استخراج الگوی میان داده‌ها انکارناپذیر است. یادگیری عمیق یک روش یادگیری ماشینی الگوریتمی چندلایه است که از شبکه عصبی مغز انسان الهام گرفته شده است. کلمه «عمیق» به تعداد لایه‌هایی گفته می‌شود که از طریق آن‌ها داده‌ها طی فرایندهایی تبدیل می‌شوند. با استفاده از یادگیری عمیق، می‌توان کارهایی که معمولاً انسان‌ها انجام می‌دهند را به ماشین‌ها یاد داد (۱۲).

امروزه الگوریتم‌ها و مدل‌های مختلف پژوهش‌های مبتنی بر شبکه عصبی، جای خود را در میان طبقه‌بندی تصاویر به خوبی باز کرده‌اند. هدف اصلی این الگوریتم‌ها این است که در شبکه‌های مصنوعی، ماشین به شکلی آموزش ببیند که در نهایت تشخیصی نزدیک مغز انسان داشته باشد. افزایش استفاده از مدل‌های یادگیری عمیق، مانند CNN‌ها، برتری آن‌ها را نسبت به شبکه‌های عصبی سنتی برجسته کرده است (۱۳). هدف اصلی مطالعه پیشنهاد روش‌های ترکیبی جدید مبتنی بر روش‌های بهینه‌سازی است (۱۴). همچنین از شبکه عصبی عمیق کانولوشنی به عنوان یکی از روش‌های نوین برای پیش‌بینی ناشی از وزن‌های به دست آمده، استفاده خواهد شد. برای بهینه‌سازی و به دست آوردن نقشه‌های نهایی از الگوریتم WOA و ABC استفاده می‌شود که به این ترتیب با ترکیب دو روش ورودی اولیه و دو الگوریتم بهینه‌سازی نهایی انجام خواهد شد که خروجی حاصل این عمل، ۴ نقشه خواهد بود و ضرایب هر یک برای مشخص کردن بهترین نقشه، مورد محاسبه قرار خواهد گرفت. در این مقاله، بهره‌گیری از یادگیری عمیق در سنجش از راه دور را توسط سه استراتژی متفاوت ارزیابی و آنالیز می‌کنیم. در بسیاری از برنامه‌های کاربردی، مخصوصاً برنامه‌های سنجش از راه دور، به علت هزینه‌های محاسباتی و نیاز به مقادیر با داده‌های برجسب‌دار، امکان طراحی و آموزش شبکه‌های عصبی کانولوشن جدید وجود ندارد. آزمایش‌های این تحقیق با بهره‌بردن از مجموعه داده سنجش از راه دور و همچنین شبکه‌های عصبی کانولوشن معروف (-tuned fine) صورت می‌گیرد. نتایج نشان می‌دهد شبکه‌های عصبی کانولوشن به خوبی تنظیم شده، دارای بهترین عملکرد در بین استراتژی‌ها هستند. در حقیقت استفاده از ویژگی‌های شبکه‌های عصبی کانولوشن به خوبی تنظیم شده با SVM Linear بهترین نتیجه را می‌دهد. در حقیقت، با استفاده هم‌زمان از ویژگی‌های شبکه‌های عصبی کانولوشن به خوبی تنظیم شده به همراه SVM‌های خطی تنظیم شده، بهترین نتیجه به دست می‌آید. هدف اصلی این مقاله، ارزیابی استراتژی‌های مناسب برای بهره‌برداری بیشتر از توانایی‌های یادگیری عمیق جهت طبقه‌بندی صحنه‌های تصویری ماهواره‌ای و سنجش از راه دور است (۱۱).

بررسی پیشینه پژوهش

در مطالعه‌ای سه مدل آماری، یعنی نسبت فرکانس (FR)، شاخص آماری (SI) و وزن شواهد (WOE) را برای تهیه نقشه پتانسیل چشمه آب زیرزمینی در ایران مقایسه شدند. نتایج نشان داد دقت SI بالاترین (AUROC=0.854) بود، در حالی که دقت FR و WOE به ترتیب ۰/۸۳۷ و ۰/۷۶۳ بود (۱۵). در مطالعه‌ای جامع با هدف توسعه سه مدل جدید مبتنی بر GIS با ترکیب الگوریتم ژنتیک (GA)، بهینه‌سازی مبتنی بر جغرافیای زیستی (BBO) و تبرید شبیه‌سازی شده (SA) با رگرسیون بردار پشتیبان (SVR)، محققان به نقشه برداری پتانسیل آب زیرزمینی (GP) در استان تفی الله اردن پرداختند. دوازده عامل توپوگرافی، هیدرولوژیکی و زمین‌شناسی در نظر گرفته شد. فرایند نقشه برداری با و بدون انتخاب ویژگی (FS) با ادغام مدل SVR با الگوریتم‌های BBO، GA، و SA انجام شد. نتایج

نشان داد نقشه برداری با انتخاب ویژگی، مدل‌ها در داده‌های آزمایشی دقت بیشتری نسبت به داده‌های آموزشی دارند (۱۶). در مطالعه دیگری، یک رویکرد آماری جدید همراه با یک مدل مجموعه داده کاوی، از طریق اجرای تابع باور شواهد و الگوریتم‌های درخت رگرسیون تقویت شده (EBF-BRT) برای نقشه برداری پتانسیل آب زیرزمینی آبخوان لردگان در مرکز ایران معرفی شد. یافته‌های آزمون نشان داد مساحت زیرمنحنی‌های ROC برای مدل‌های EBF و EBF-BRT به ترتیب ۷۵ و ۸۲ درصد است (۱۷).


در پژوهشی از داده‌های سنجش از دور (IRS-LISS-III) و داده‌های مأموریت توپوگرافی رادار شاتل (SRTM) برای بررسی پتانسیل آب زیرزمینی در هند استفاده شد. روش عامل چندگانه (MIF) برای تخصیص وزن‌های نسبی به موارد مؤثر بر ذخیره آب زیرزمینی استفاده شد. سپس یک تحلیل همپوشانی وزنی (WOA) عوامل را ادغام کرد و به یک نقشه جامع منجر شد که شش GWPZ متمایز را نشان می‌داد. یافته‌ها توزیع پتانسیل آب زیرزمینی را در حوضه‌های مورد بررسی نشان می‌دهد که مناطقی در امتداد رودخانه مایوراکشی بالاترین پتانسیل را نشان می‌دهند (۱۸). در تحقیقی ارزیابی نواحی بالقوه آب زیرزمینی در حوضه ایفنی، واقع در محدوده غربی آنتی اطلس مراکش، بر اساس یک رویکرد تحلیلی چندمعیاره انجام شد که اثر مجموعه‌ای از عوامل ژئومورفولوژیکی مؤثر بر دسترس بودن آب زیرزمینی را ادغام کرد. این رویکرد شامل استفاده از سیستم‌های اطلاعات جغرافیایی (GIS) و مدل‌های فرایند تحلیل سلسله‌مراتبی (AHP) بود. یک نقشه پتانسیل آب زیرزمینی (GWPA) با مقایسه با داده‌های ۱۳۴ نقطه‌آبی موجود با استفاده از منحنی مشخصه عملکرد گیرنده (ROC) تأیید شد. AUC این تحقیق ۸۰ درصد محاسبه شد که نشان دهنده دقت پیش‌بینی خوب روش AHP است (۱۹).

معرفی منطقه مطالعاتی

اقلیم آب و هوایی استان کرمانشاه

استان کرمانشاه با مساحت ۲۴۶۲۲ کیلومتر مربع، در میانه باختری کشور و در محدوده جغرافیایی ۳۶ دقیقه و ۳۲ درجه تا ۱۵ دقیقه و ۳۵ درجه عرض شمالی و ۲۴ دقیقه و ۴۵ درجه تا ۳۰ دقیقه و ۴۸ درجه طول خاوری واقع است (ملکی، ۱۳۸۸). این استان از شمال به استان کردستان، از جنوب به استان لرستان و ایلام، از شرق به استان همدان و از غرب به استان‌های دیاله و حلبچه در کشور عراق محدود می‌شود.

استان کرمانشاه در معرض جبهه‌های مرطوب مدیترانه‌ای قرار دارد، برخورد این جبهه‌ها با ارتفاعات زاگرس موجب ریزش برف و باران می‌شود. متوسط میزان بارندگی در مناطق مختلف استان بین ۳۰۰ تا ۸۰۰ میلی‌متر در نوسان است و به طور کلی متوسط میزان بارندگی در سطح استان را ۴۰۰ تا ۵۰۰ میلی‌متر می‌توان در نظر گرفت.



شکل ۱. موقعیت محدوده مطالعه شده

جدول ۱. واحدهای سنگی و سازندهای زمین شناسی رخمون یافته در منطقه مطالعاتی

epoch	Era	Geology	Unit
CENOZOIC	Early.Eocene	Silty shale, sandstone, marl, sandy limestone, limestone and conglomerate	E1f
CENOZOIC	Eocene	Tine-bedded argillaceous limestone and calcareous shale (Kandavan Shale)	Ekn
CENOZOIC	Eocene-Miocene	Undivided Asmari and Shahbazan Formation	EMas-sb
MESOZOIC	Late.Jurassic	Basaltic volcanic	Jbv
MESOZOIC	Jurassic-Cretaceous	Crystalized limestone and calc-schist	JKI
MESOZOIC	Jurassic	Phyllite, slate and meta-sandstone (Hamadan Phyllites)	Jph
MESOZOIC	Late.Jurassic	Andesitic volcanic Tuff	JUavt
MESOZOIC	Late.Jurassic	Rhyolitic to rhyodacitic volcanics	JUdv
MESOZOIC	Late.Jurassic	Upper Jurassic granite to diorite intrusives	Jugr-di
MESOZOIC	Cretaceous	Undivided Bangestan Group, mainly limestone and shale, Albian to Campanian, comprising the following formations: Kazhdumi, Sarvak, Surgah and Ilam	Kbgp
MESOZOIC	Late.Cretaceous	Grey and brown, medium - bedded to massive fossiliferous limestone (KAZHDUMIFM)	KEpd-gu
MESOZOIC	Cretaceous	Grey, thick - bedded to massive o'olitic limestone	kkkk
MESOZOIC	Early.Cretaceous	Grey thick - bedded to massive orbitolina limestone	Klsol
MESOZOIC-CENOZOIC	Cretaceous-Paleocene	Dark olive - brown, low weathered siltstone and sandstone with local development of chert conglomerates and shelly limestone (AMIRANFM)	KPeam
MESOZOIC	Late.Cretaceous	Radiolarian chert and shale	Kur
CENOZOIC	Miocene	Anhydrite, salt, grey and red marl alternating with anhydrite, argillaceous limestone and limestone (GACHSARAN FM)	Mgs

CENOZOIC	Miocene	Cream to brown - weathering, feature - forming, well - jointed limestone with intercalations of shale (ASMARIFM)	OMas
CENOZOIC	Oligocene-Miocene	Massive to thick - bedded reefal limestone	OMql
CENOZOIC	Oligocene-Miocene	Red Beds composed of red conglomerate, sandstone, marl, gypsiferous marl and gypsum	OMrb
CENOZOIC	Paleocene-Eocene	Flysch turbidite, sandstone and calcareous mudstone	PeEf
CENOZOIC	Paleocene-Eocene	Grey and brown, medium - bedded to massive fossiliferous limestone (TALEHZANGFM)	PeEtz
CENOZOIC	Pliocene	Alternating hard of consolidated, massive, feature forming conglomerate and low - weathering cross - bedded sandstone (BAKHTYARIFM)	Plbk
CENOZOIC	Pliocene	Polymictic conglomerate and sandstone	Plc

ادامه جدول ۱. واحدهای سنگی و سازندهای زمین‌شناسی رخنمون یافته در منطقه مطالعاتی

epoch	Era	Geology	Unit
CENOZOIC	Quaternary	High level piedmont fan and vally terrace deposits	Qft1
CENOZOIC	Quaternary	Low level piedment fan and vally terrace deposits	Qft2
MESOZOIC	Triassic-Jurassic	Meta - volcanics, phyllites, slate and meta- limestone	TRJvm
MESOZOIC	Triassic	Thin to meddium - bedded, dark grey dolomite; thin - bedded dolomite, greenish shale and thin - bedded argillaceous limestone (KHAMEHKat and NEYRIZFM.)	TRkk-nz
MESOZOIC	Triassic-Cretaceous	Kuhe Bistoon limestone	TRKubl
MESOZOIC	Triassic-Cretaceous	Purple and red thin - bedded radiolarian chert with intercalations of neritic and pelagic limestone (Kerman and Neyzar Radiolarites)	TRKurl
MESOZOIC	Late.Cretaceous	Dark grey shale (Sanandaj shale) (Schist and phyllite)	Kussh

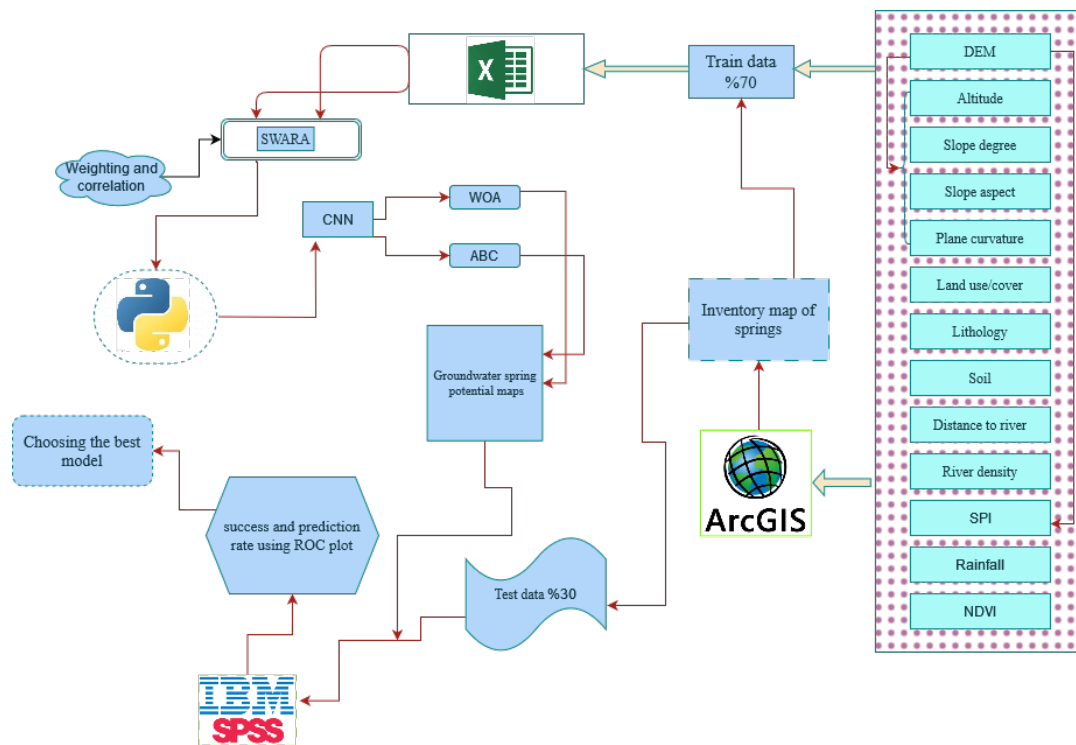
مواد و روش‌ها

داده‌های پژوهش

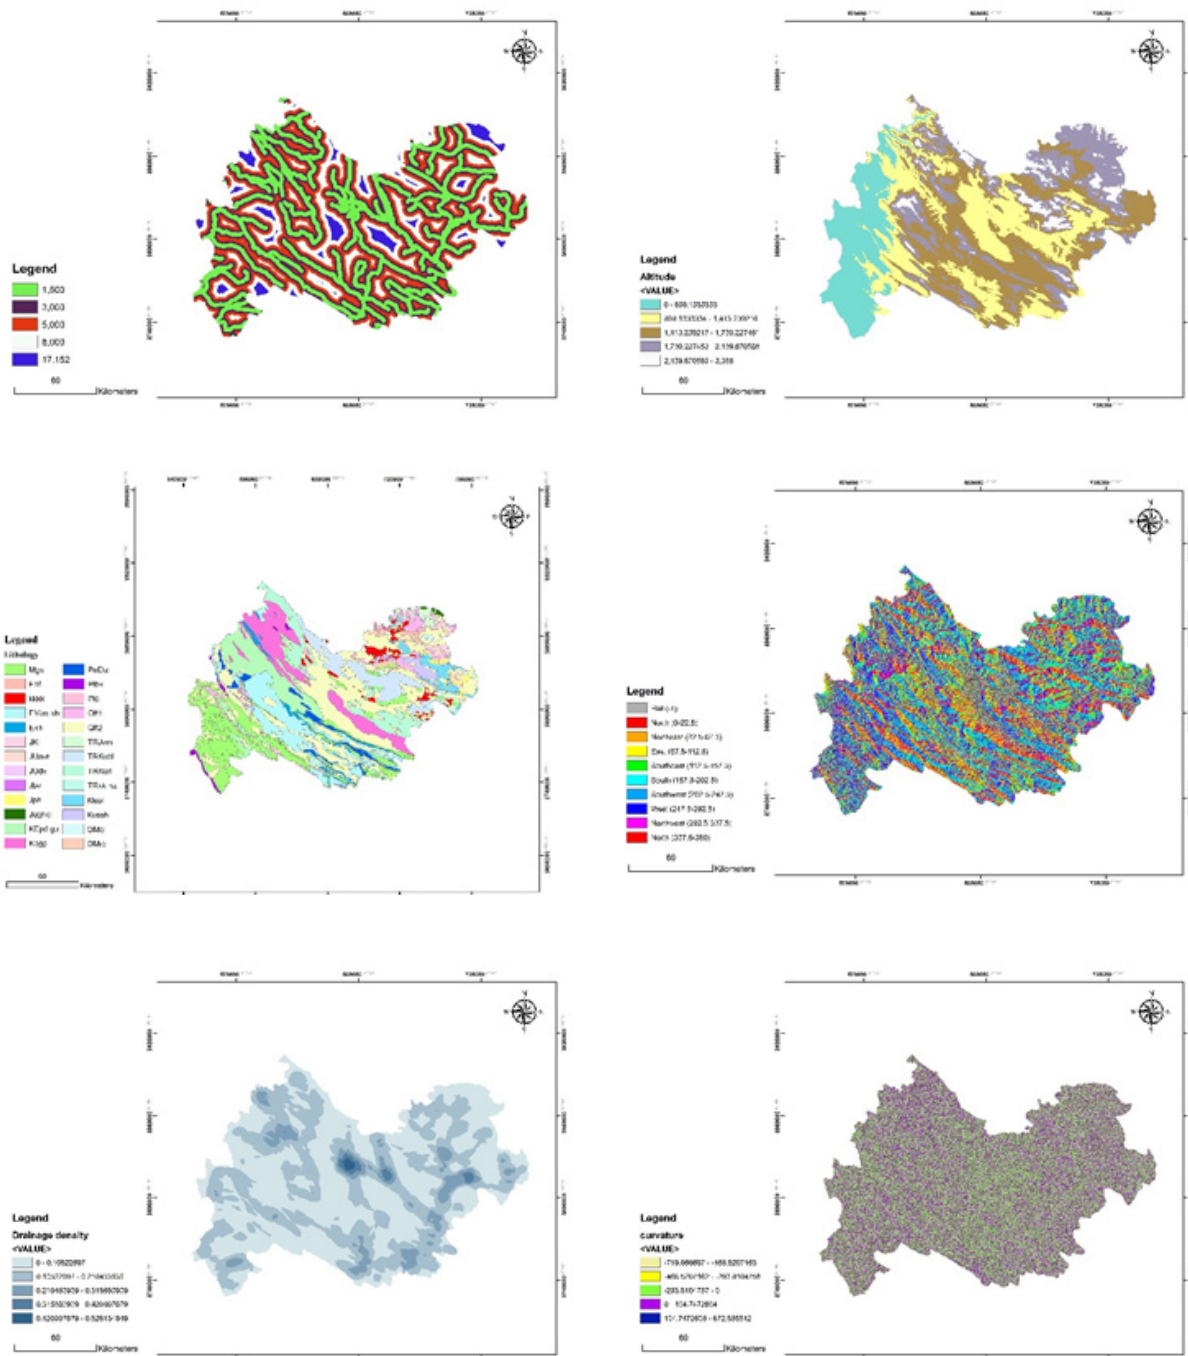
در مدل سازی مکانی آب‌های زیرزمینی، نشان دادن درجه همبستگی چشمه‌ها و عوامل مؤثر بر آن یک گام ضروری است و هر چه داده‌ها دقیق‌تر باشند، نتایج قابل اعتمادتر هستند (۹). برای این منظور در مرحله اول نقشه موقعیت محل چشمه‌ها و نقاط بدون چشمه باشد ترسیم شد که در آن محل چشمه‌های منطقه مورد مطالعه از سازمان مدیریت منابع آب ایران گردآوری شده است.

در مرحله دوم، بر اساس مطالعات قبلی و داده‌های موجود شامل داده‌های توپوگرافی و زمین‌شناسی و کاربری اراضی، ۱۳ متغیر از مهم‌ترین عوامل مؤثر بر پتانسیل یابی منابع آب زیرزمینی شامل ارتفاع، شیب، جهت شیب، انحنای پلان، کاربری/پوشش، خاک، سنگ‌شناسی، فاصله تا رودخانه، تراکم زهکشی، شاخص رطوبت توپوگرافی (TWI)، شاخص توان جریان (SPI)، بارندگی، و شاخص نرمال شده تفاوت پوشش گیاهی برای پتانسیل یابی چشمه‌های آب زیرزمینی تهیه شد (شکل ۳). درخور یادآوری است در این مطالعه فقط چاه‌ها و چشمه‌های بادبی ۳۰ مترمکعب بر ثانیه و بالاتر مورد بررسی قرار گرفت و نقاط غیر چشمه/چاه نیز به صورت تصادفی با نرم افزار ArcGis در روی نقشه ایجاد شده است. مراحل انجام پژوهش در شکل ۲ نشان داده شده است.

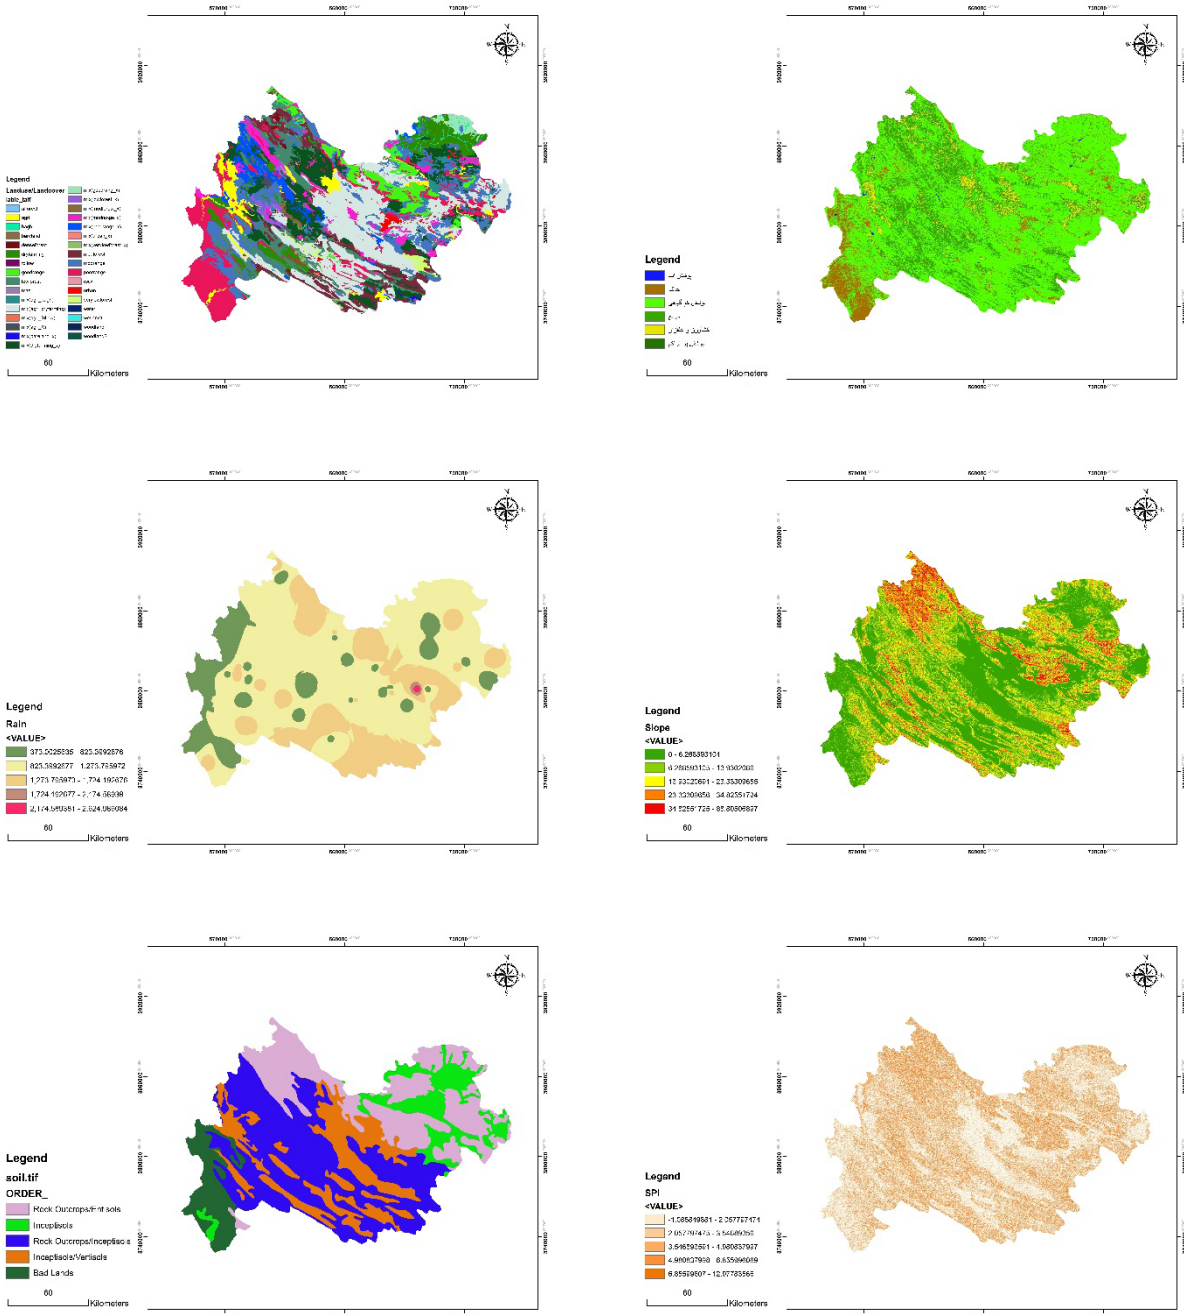
در این مطالعه، ۷۰ درصد از مجموعه داده (شامل ۲۱۰ نقطه چشمه با مقدار ۱ و ۲۱۰ نقطه غیر چشمه با مقدار ۰) به صورت تصادفی انتخاب شدند و برای آموزش مدل‌ها استفاده شدند. ۳۰ درصد باقی‌مانده (۹۱ نقطه) نیز برای اعتبارسنجی مدل‌ها و نقشه‌های تولیدی در نظر گرفته شد (۲، ۲۰).



شکل ۲. مراحل انجام پتانسیل یابی منابع آب زیرزمینی در منطقه مطالعاتی



شکل ۳. عوامل تأثیرگذار بر آب زیرزمینی



ادامه شکل ۳. عوامل تأثیرگذار بر آب زیرزمینی

روش های محاسبه وزن معیارهای ورودی

مدل تحلیل نسبت ارزیابی گام به گام اوزان (SWARA)

SWARA یکی از روش هایی است که برای تعیین وزن معیارها و زیرمعیارها در مسائل چند پارامتری استفاده می شود که نقش مهمی در فرایند تصمیم گیری دارد. به گفته Keršulienė et al (۲۰۱۰) و همکاران که این فرایند را توسعه داد، ویژگی اصلی این روش توانایی آن در ارزیابی نظرات خبرگان در مورد اهمیت نسبی معیارها در فرایند وزن دهی است. از این رو برای حل مسائل چندمعیاره بسیار مفید است. این روش شامل مراحل زیر است:

در مرحله اول، خبرگان معیارهای مسئله هدف را بر اساس اهمیت آن ها رتبه بندی می کنند.

در مرحله بعد تخمین زده می شود. مقدار نشان دهنده اهمیت نسبی هر معیار در مقایسه با معیار قبلی است. برای محاسبه داریم (رابطه ۱):

$$S_j = \frac{\sum_i^n A_i}{n} \quad (1)$$

که در آن و به ترتیب تعداد خبرگان و رتبه های پیشنهادی برای هر معیار را نشان می دهد. علاوه بر این، تعداد هر معیار است.

مرحله بعدی محاسبه (وزن اولیه) با استفاده از معادله ۲ است:

$$Q_j = \frac{X_j - 1}{K_j} \quad (2)$$

برای محاسبه داریم (رابطه ۳):

$$K_j = S_j + 1 \quad (3)$$

آخرین مرحله محاسبه وزن نسبی برای هر معیار است که با استفاده از رابطه ۴ محاسبه می شود:

$$W_j = \frac{Q_j}{\sum_{j=1}^m Q_j} \quad (4)$$

که در آن و به ترتیب تعداد هر معیار و تعداد کل معیارها را نشان می دهد. علاوه بر این، مقدار نرمال شده وزن استاندارد است.

شبکه عصبی کانولوشنی (CNN)

معماری شبکه کانولوشنی، مشابه الگوی اتصال نورون ها در مغز انسان است و از قشر دیداری الهام گرفته شده است. نورون ها تنها در یک ناحیه محدود از میدان دید به محرک ها پاسخ می دهند که به آن، میدان پذیرش گفته می شود. مجموعه ای از این میدان ها، با هم همپوشانی دارند تا کل ناحیه بینایی را پوشش دهند (۲۱).

یک شبکه نمونه معمولاً از لایه ورودی، لایه میانی (مخفی) و لایه خروجی تشکیل شده است. آخرین لایه یا لایه خروجی شامل مقادیر پیش بینی شده به وسیله شبکه است، بنابراین خروجی مدل را معرفی می کند. لایه های میانی یا مخفی که از گره های پردازشگر تشکیل شده اند، محل پردازش داده ها هستند (۲۱، ۲۲).

شمار لایه‌های مخفی و شمار گره‌ها در هر لایه مخفی به طور معمول به وسیله روش آزمون و خطا مشخص می‌شود. گره‌های هر لایه با لایه‌های مجاور در یک شبکه به طور کامل در ارتباط هستند. ورودی‌های هر گره ممکن است از متغیرهای ورودی یا از خروجی گره‌های دیگر حاصل شود. هر گره دارای یک تابع عملگر است که به آن تابع تبدیل گر گفته می‌شود (۲۲).

ورودی‌ها به شکل بردار هستند و هر ورودی توسط یک وزن به گره مربوط می‌شود. در نهایت، گروهی از وزن‌ها به شکل بردار وزنی به گره مورد نظر مرتبط می‌شوند. خروجی گره که نامیده می‌شود، طبق رابطه ۵ محاسبه می‌شود.

$$y = f(x \cdot w + b) \quad (5)$$

در این رابطه x داده‌های ورودی، w بردار وزن و b مقدار آستانه یا بایاس هستند. درون هر گره، پردازشگر تابع تبدیل گر، تولیدکننده خروجی‌های آن گره به شمار می‌رود. از مهم‌ترین و پرکاربردترین توابع تبدیل گر، تابع سیگموئید است که به صورت رابطه ۶ بیان می‌شود (۲۳).

$$f(t) = \frac{1}{1 + \exp(-tn)} \quad (6)$$

تعداد ورودی و لایه مخفی شبکه متغیر است و فقط به افق پیش‌بینی بستگی دارد. تعداد گره‌ها در لایه مخفی در راستای کمینه کردن خطا و بیشینه کردن دقت مدل بهینه‌سازی می‌شوند. با توجه به آنکه وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود، لذا در آموزش شبکه، نرمالیزه کردن داده‌ها قبل از اعمال شبکه بسیار مهم است. برای پیشگیری از چنین شرایطی و همچنین به لحاظ یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی داده‌ها مطابق رابطه ۷ انجام می‌شود (۲۳).

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

الگوریتم‌های بهینه‌سازی مدل کانولوشن

الگوریتم بهینه‌سازی نهنگ (WOA)

الگوریتم WOA یکی از الگوریتم‌های بهینه‌سازی الهام گرفته شده از طبیعت است که در زمینه‌های مختلف می‌توان از آن استفاده کرد. در حقیقت، نهنگ‌های گوژپشت می‌توانند مکان شکار را شناسایی کرده و آن‌ها را محاصره کنند. از آنجا که مکان طراحی بهینه در فضای جست‌وجو از راه قیاس شناخته نمی‌شود، الگوریتم WOA فرض می‌کند که بهترین راه حل نامزد حال حاضر، شکار هدف بوده و یا نزدیک به حالت مطلوب است. بعد از اینکه بهترین عامل جست‌وجو شناسایی شد، عوامل دیگر جست‌وجو سعی می‌کنند تا مکان خود را نسبت به بهترین عامل، جست‌وجو و به روزرسانی کنند. این رفتار از طریق معادله ۸ بیان شده است (۲۴):

$$\vec{D} = |\vec{C} \cdot \vec{X}(t) - \vec{X}(t)| \quad (8)$$

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot \vec{D}$$

که در آن t تکرار جاری را نشان می‌دهد، A و C بردارهای ضرایب، بردار مکان بهترین راه حل به دست آمده در حال

حاضر و X بردار مکان است. در خور یادآوری است که در صورت وجود راه حل بهتر، در هر تکرار باید به روز شود. بردار A و C به صورت رابطه ۹ محاسبه می شود (۲۴):

$$\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a}$$

$$\vec{C} = 2 \cdot \vec{r}$$
(۹)

که a به صورت خطی از مقدار ۲ تا ۰ و طی تکرارها کاهش می یابد (در هر دو فاز اکتشاف و استخراج) و بردار تصادفی در فاصله ۰ تا ۱ است.

الف) روش حمله حباب تور (فاز استخراج)

جهت مدل سازی ریاضی رفتار حباب تور نهنگ های گوژپشت، ۲ روش به صورت زیر طراحی شده است:

ب) مکانیزم محاصره انقباضی

این رفتار از طریق افزایش مقدار a حاصل می شود. به یاد داشته باشید که محدوده نوسان A به وسیله a کاهش می یابد. به بیان دیگر، A مقداری تصادفی در فاصله a تا -a است و a طی تکرارها، از مقدار ۲ تا ۰ کاهش می یابد. با انتخاب مقادیر تصادفی A در فاصله ۱ تا -۱، می توان مکان جدید عامل جست و جور در هر جابین مکان اصلی عامل و مکان بهترین عامل کنونی، تعریف کرد.

ج) مکان در حال بروزسانی ماریچی

این روش ابتدا فاصله بین نهنگ قرار گرفته در مختصات و طعمه موجود در و را محاسبه می کند. معادله ای ماریچی بین موقعیت نهنگ و طعمه ایجاد می شود تا حرکت حلزونی شکل نهنگ گوژپشت را تقلید کند (رابطه ۱۰):

$$\vec{X}(t+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t)$$
(۱۰)

در خور یادآوری است که نهنگ گوژپشت، حول طعمه در امتداد یک دایره انقباضی و هم زمان در مسیر ماریچی شکل به شنا درمی آید. برای مدل سازی این رفتار از مدل ریاضی زیر استفاده می شود (رابطه ۱۱):

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - \vec{A} \cdot \vec{D} & \text{if } p < 0.5 \\ \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) & \text{if } p \geq 0.5 \end{cases}$$
(۱۱)

که در آن P عددی تصادفی بین ۰ تا ۱ است. علاوه بر روش حباب تور، نهنگ های گوژپشت به صورت تصادفی به دنبال طعمه می گردند (۲۴).

الگوریتم کلونی زنبور عسل (ABC)

در یک کلونی زنبور عسل واقعی، وظایفی وجود دارد که توسط افراد متخصص انجام می شود. این زنبورهای متخصص تلاش می کنند تا میزان شهد ذخیره شده در کندورا با انجام تقسیم کار و خودسازماندهی مؤثر حداکثر کنند. مدل کمینه انتخاب جست و جوی غذا توسط گروه های هوشمند زنبور در یک کلونی زنبور عسل، که الگوریتم ABC اتخاذ کرده است، شامل سه نوع زنبور است: زنبورهای کارگر، زنبورهای ناظر، و زنبورهای پیشاهنگ (۲۵).

زنبورهای کارگر مسئول بهره برداری از منابع شهدی و اطلاعات دادن به سایر زنبورهای منتظر (زنبورهای ناظر) در کند و درباره کیفیت مکان مواد غذایی که در حال استخراج آن هستند. زنبورهای ناظر با اطلاعاتی که زنبورهای کارگر به اشتراک گذاشته اند درباره یک منبع غذایی برای بهره برداری تصمیم گیری می کنند. پیشاهنگ ها به صورت تصادفی محیط را برای یافتن یک منبع غذایی جدید براساس یک انگیزش درونی یا مدارک امکانی خارجی یا تصادفی جست و جو می کنند. مراحل اصلی الگوریتم ABC که این رفتار را شبیه سازی می کند در ادامه آورده می شود (۲۵):

۱. مقداردهی اولیه به موقعیت های منابع غذایی
 ۲. هر زنبور کارگر یک منبع غذایی جدید در مکان منبع غذایی خود تولید می کند و منبع بهتر را استخراج می کند.
 ۳. هر زنبور دیده و یک منبع را وابسته به کیفیت راه حله انتخاب می کند و یک منبع غذایی جدید را در مکان منبع غذایی انتخاب شده تولید می کند و منبع بهتر را استخراج می کند.
 ۴. تعیین منبعی که باید متروک شود و تخصیص زنبورهای کارگر آن به عنوان دیده و برای جست و جوی منابع غذایی جدید
 ۵. به خاطر سپردن بهترین منبع غذایی پیدا شده تا کنون.
 ۶. تکرار مرحله های ۲-۵ تا زمانی که معیار توقف مقتضی شود.
- در مرحله اول الگوریتم، راه حل ها به صورت تصادفی تولید می شوند که در آن تعداد منابع غذایی است. در مرحله دوم الگوریتم، برای هر زنبور کارگر، که تعداد کل آن ها برابر با نصف تعداد منابع غذایی است، یک منبع جدید به وسیله رابطه ۱۲ تولید می شود:

$$v_{ij} = x_{ij} + \phi_{ij} (x_{ij} - x_{kj}) \quad (12)$$

یک عدد تصادفی بطور یکنواخت توزیع شده در بازه $[-1, 1]$ است که تولید موقعیت منابع غذایی همسایه را در اطراف کنترل می کند، K شاخص راه حل است که به صورت تصادفی از کلونی انتخاب شده است (۲۵).
 D و ابعاد مسئله است. بعد از تولید این راه حل جدید با مقایسه می شود و زنبور کارگر منبع بهتر را استخراج می کند. در مرحله سوم الگوریتم، یک زنبور ناظر یک منبع غذایی را با احتمال رابطه ۱۳ انتخاب می کند و منبع جدیدی را در مکان منبع غذایی انتخاب شده توسط رابطه تولید می کند و به همان شکل روش زنبور کارگر، منبع بهتر برای استخراج شدن مورد تصمیم گیری قرار می گیرد (۲۵).

$$P_i = \frac{fit_i}{\sum_{n=1}^{SN} fit_n} \quad (13)$$

Fit_i میزان شایستگی راه حل x_i است.

بعد از آنکه تمام زنبورهای ناظر در منابع توزیع شدند، منابع مورد بررسی قرار می گیرند که آیا باید ترک شوند یا خیر. اگر تعداد چرخه هایی که یک منبع نمی تواند بهبود یابد، بزرگ تر از محدوده از قبل تعیین شده باشد آن منبع به عنوان منبع تمام شده در نظر گرفته می شود. زنبور کارگر مربوط به منبع تمام شده یک زنبور دیده و ور شده و یک جست و جوی تصادفی را از طریق رابطه ۱۴ در قلمروی مسئله به وجود می آورد (۲۵).

$$x_{ij} = x_{jmin} + (x_{jmax} - x_{jmin}) * rand \quad (14)$$

نتایج

بررسی ارتباط فضایی بین چشمه‌ها و عوامل تعیین‌کننده با استفاده از روش SWARA

مدل سازی پتانسیل آب زیرزمینی بدون مشخص کردن رابطه احتمالی بین کلاس‌های هر پارامتر و چشمه‌ها امکان پذیر نیست. به همین منظور، در این مطالعه روش تصمیم‌گیری چندمعیاره، SWARA و CNN استفاده شد، سپس شبکه عصبی با الگوریتم‌های WOA و ABC در پایتون نسخه ۳٫۱۲ نوشته و بهینه‌سازی شدند. هر چه مقادیر SWARA بزرگ‌تر باشند، احتمال حضور چشمه‌ها بیشتر است (جدول‌های ۲ و ۳).

در خصوص عامل ارتفاع، کلاس سوم بیشترین همبستگی را از خود نشان داد (به ترتیب ۰/۴۳ و ۰/۳۷۴ برای مدل SWARA). بررسی درجه شیب نشان داد کلاس ۰/۳۱۲ با مقادیر ۰/۴۸ و ۰/۳۱۲ به ترتیب بیشترین ظرفیت را دارد. این روند با افزایش شیب منطقه کاهش یافت. در خصوص جهت شیب، جهت غربی با وزن ۰/۴۵۶ بیشترین احتمال حضور چشمه را دارد. طبق جدول ۳، بیشترین وزن (۰/۴۵۵) برای منحنی پلان به کلاس flat تعلق دارد. نتایج کاربری اراضی نشان داد کلاس Rangeland بیشترین وزن را داشته است (۰/۳۵۲). بیشترین مقدار SWARA برای جنس خاک در کلاس Rock Outcrof/Entisols (با مقدار ۰/۳۹۱) مشاهده شد. در خصوص لیتولوژی، نتایج نشان داد kkk با وزن SWARA (۰/۳۸۰) بیشترین احتمال حضور چشمه‌های آب زیرزمینی را نسبت به واحدهای لیتولوژیکی دیگر دارد. با توجه به فاصله تا رودخانه، مشاهده می‌شود که کلاس ۱۵۰۰ متر بیشترین همبستگی را دارد. در خصوص چگالی رواناب، نتایج به دست آمده از مدل‌های SWARA نشان داد مقادیر ۰/۰۹ کیلومتر بر کیلومتر مربع بیشترین احتمال حضور چشمه را دارند. بررسی رابطه بین حضور چشمه‌های آب زیرزمینی و TWI نشان داد برای مدل، مقادیر بیشتر از ۱/۸ و کمتر از ۶/۳۴ بیشترین ظرفیت را دارند. برای SPI، کلاس ۰/۴۸/۶۶۰ با وزن SWARA ۰/۲۸۴ تأثیر بیشتری داشت. نتایج بارش نشان داد محدوده ۸۰۰-۹۰۰ میلی‌متر بیشترین تأثیر بر حضور چشمه داشت. در ارتباط با عامل NDVI، کلاس ۰/۱۵/۰۱ بیشترین احتمال را با مقدار ۰/۳۷۳ برای SWARA داشت.

پیاده‌سازی مدل‌های CNN-ABC و CNN-WOA

همان‌طور که در بخش آماده‌سازی داده ذکر شده است، در مرحله اول، ۷۰ درصد از مجموعه داده شامل ۲۱۰ نقطه با مقدار ۱ (چشمه) و ۲۱۰ نقطه با مقدار ۰ (غیر چشمه) با عوامل تعیین‌کننده تطبیق داده شدند تا مجموعه داده آموزش ایجاد شود. این امری با لایه‌های به دست آمده از مدل SWARA انجام شد. همین فرایند با ۳۰ درصد داده دیگر نیز برای تولید مجموعه داده اعتبارسنجی انجام شد. مدل‌های ترکیبی CNN-ABC و CNN-WOA سپس بر اساس وزن‌های به دست آمده از مراحل قبلی، برای هر یک از دسته‌های آموزش و آزمون، آموزش داده شدند؛ که نتیجه آن تولید دو مدل پتانسیل آب زیرزمینی با رویکردهای ترکیبی متفاوت در هر یک از فازهای آموزش و آزمون بوده است. در ادامه، مجموعه داده تولید شده (آموزش و آزمون) به ساختار برنامه وارد شد تا دقت پیش‌بینی هر یک از مدل‌ها مورد ارزیابی و تخمین قرار گیرد.

جدول ۲. مقادیر SWARA برای فاکتور زمین شناسی

Factors	SWARA	Factors	SWARA	Factors	SWARA
kkkk	0.38	Qft1	0.001	PeEf	0
Qft2	0.24	Kbgp	0.001	Ekn	0
EMas-sb	0.175	Mgs	0	TRJvm	0
TRKubl	0.094	Plbk	0	Jugr-di	0
KEpd-gu	0.049	Jph	0	Jbv	0
Kussh	0.028	OMrb	0	JKl	0
PeEtz	0.016	JUavt	0	OMql	0
KPeam	0.008	Kur	0	E1f	0
Klsol	0.004	OMas	0	Plc	0
TRKurl	0.002	TRkk-nz	0	JUdv	0

ادامه جدول ۲. مقادیر SWARA برای سایر فاکتورهای مؤثر

Factors	SWARA	Factors	SWARA
slope		Distance to river	
0-12.9	0.312491	1,500	0.374
12.9-21.9	0.243452	3,000	0.276
21.9-30.9	0.185024	5,000	0.173
30.9-41.7	0.148019	8,000	0.093
41.7>	0.111014	17,152	0.084
Altitude(m)		Drainage density	
1385-1703	0.430051	0.05-0.09	0.306
1070-1385	0.259452	0-0.05	0.203
1703-2068	0.141519	0.09-0.26	0.177
114-1070	0.084489	0.26-0.43	0.157
2068-3368	0.084489	0.43-0.53	0.157
Aspect		TWI	
West	0.45602	1.8-6.34	0.49
East	0.25244	9.93-13	0.247
South	0.137195	13-23.5	0.139
North	0.082317	6.34-7.96	0.077
Flat	0.072028	7.96-9.93	0.047
Plan curvature		Rainfall(mm)	
Flat	0.455165	800-900	0.424
Concave	0.359359	500-600	0.26
Convex	0.185476	400-500	0.15
Land use		700-800	
Rangeland	0.352489	600-700	0.058
Crops	0.256916	NDVI	
Built Area	0.143609	0.1-0.15	0.373
Trees	0.095739	0.15-0.23	0.219

Water	0.075623	0.23 - 0.32	0.147
Bare Ground	0.075623	0.32 - 0.42	0.13
		0.42 - 0.51	0.13
	Soil	SPI	
Rock Outcrops/Entisols	0.390981	0 - 48,664.14	0.284
Rock Outcrops/Inceptisols	0.238403	48,664.14001 - 227,099.33	0.268
Inceptisols/Vertisols	0.159895	227,099.3301 - 583,969.72	0.192
Inceptisols	0.109218	583,969.7201 - 1,330,153.27	0.128
Bad Lands	0.101503	1,330,153.271 - 10,402,553	0.128

جدول ۳. عملکرد مدل‌ها برای مجموعه داده آموزش

Training dataset	Models	
	SWARA-CNN-WOA	SWARA-CNN-ABC
True positive (TP)	78	116
True negative (TN)	224	158
False positive (FP)	24	52
False negative (FN)	15	15
Sensitivity	0.9	0.89
Specificity	0.83	0.75
Accuracy	0.85	0.8
RMSE	0.0052	0.00395
MAE	0.059707	
Kappa	0.7201	0.7
AUROC	0.86	0.91





جدول ۴. عملکرد مدل‌ها برای مجموعه داده تست

Testing dataset	Models	
	SWARA-CNN-WOA	SWARA-CNN-ABC
True positive (TP)	17	54
True negative (TN)	10	5
False positive (FP)	13	30
False negative (FN)	107	58
Sensitivity	0.89166	0.91525
Specificity	0.63	0.65909
Accuracy	0.74	0.78
RMSE	0.005722	0.00566
MAE	0.061502	
Kappa	0.6501	0.65
AUROC	0.87	0.88





اعتبارسنجی مدل‌ها و مقایسه آن‌ها

در این مرحله، با استفاده از شاخص RMSE عملکرد مدل‌ها در مجموعه داده‌های آموزش و آزمون ارزیابی شد. شکل‌های ۴ و ۵ نتایج مدل‌های SWARA-CNN-ABC و SWARA-CNN-WOA، در مراحل آموزش و آزمون را نشان می‌دهند.

نتایج نمونه‌های آموزش نشان داد مدل ترکیبی SWARA-CNN-ABC و SWARA-CNN-WOA به ترتیب مقادیر RMSE معادل ۰/۰۰۳۹ و ۰/۰۰۵۲ را دارند (جدول ۳). باید توجه داشت که محاسبه مقادیر RMSE برای داده‌های آزمون مهم‌تر است، زیرا قدرت پیش‌بینی مدل‌ها را مشخص می‌کند و با مقایسه آن‌ها می‌توان مدل بهینه‌تر را انتخاب کرد (۲۶). طبق جدول ۹، مدل‌های ترکیبی، SWARA-CNN-ABC و SWARA-CNN-WOA، دارای مقادیر RMSE برای داده‌های آزمون به ترتیب ۰/۰۰۵۶ و ۰/۰۰۵۷ هستند (جدول ۴). مدل SWARA-CNN-ABC، SWARA-CNN-WOA به ترتیب در رتبه اول و دوم قرار گرفته‌اند.



شکل ۴. اثربخشی مدل SWARA-CNN-ABC با استفاده از مجموعه داده‌های آموزش و آزمون: (بالا) مقادیر RMSE و MAE در مرحله آموزش (نمودار خطا) و نمودار توزیع خطا؛ (پایین) مقادیر RMSE و MAE در مرحله آزمون (نمودار خطا و نمودار توزیع خطا)



شکل ۵. اثربخشی مدل SWARA-CNN-WOA با استفاده از مجموعه داده‌های آموزش و آزمون: (بالا) مقادیر RMSE و MAE در مرحله آموزش (نمودار خطا و نمودار توزیع خطا)؛ (پایین) مقادیر RMSE و MAE در مرحله آزمون (نمودار خطا و نمودار توزیع خطا)


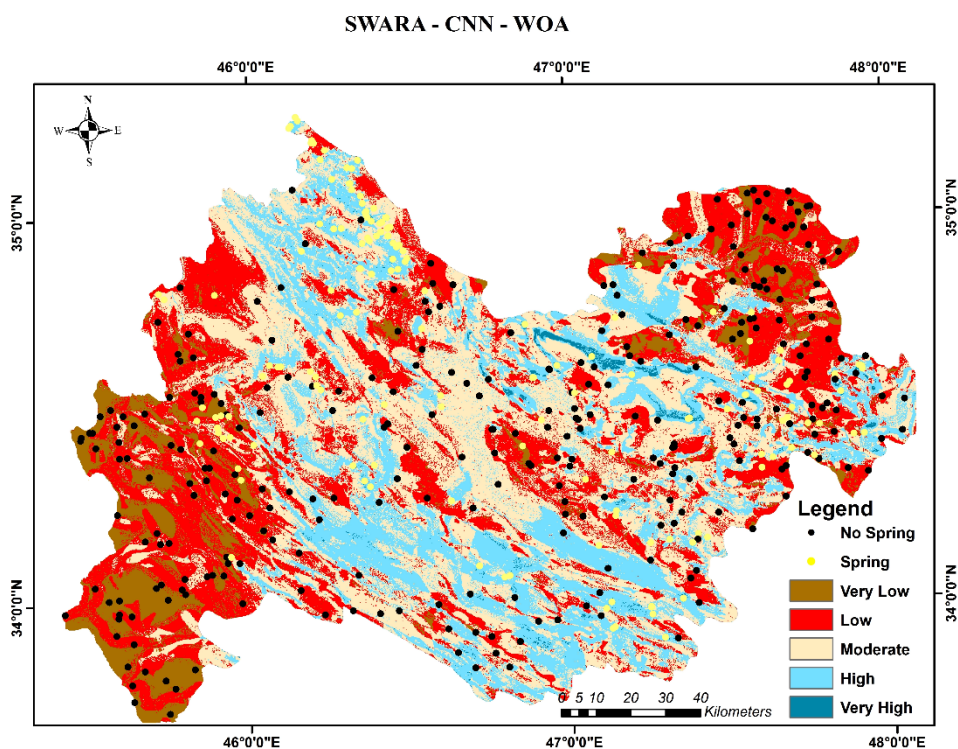
مدل سازی پتانسیل آب زیرزمینی

در مرحله بعد، مقادیر پیش بینی شده با استفاده از Python به پلتفرم ArcMap وارد شدند تا نقشه های پتانسیل آب زیرزمینی تولید شود (شکل ۶). روش های مختلف برای دسته بندی نقشه های احتمالی در مطالعات مختلف استفاده شده اند، در این مطالعه از روش کوانتایل (به دلیل تخمین مقدار میانگین متغیر پاسخ بر اساس مقدار متغیر) با پنج کلاس از بسیار پایین تا بسیار بالا انتخاب شد (۲۷) (جدول ۵).

جدول ۵. درصد کلاس های پتانسیل چشمه های آب زیرزمینی برای مدل های مختلف

Models	Percentage				
	Very low	Low	Moderate	High	Very high
SWARA-CNN-ABC		20.04	25.58	27.86	15.97
10.54					
SWARA-CNN-WOA	14.32	22.11	26.13	25.21	12.23

نتایج نشان داد برای بهترین مدل یعنی SWARA-CNN-WOA، درصد توزیع کلاس های بسیار پایین، پایین، متوسط، بالا و بسیار بالا به ترتیب ۱۴/۳۲، ۲۲/۱۱، ۲۶/۱۳، ۲۵/۲۱ و ۱۲/۲۳ درصد بود. نتایج همچنین نشان داد بیشترین درصد کلاس های بالا و بسیار بالا با مقادیر ۲۷/۸۶ و ۱۵/۹۷ درصد مربوط به مدل SWARA-CNN-ABC است.



شکل ۶. مدل‌های پتانسیل چشمه‌های آب زیرزمینی تولید شده به روش شبکه عصبی کانولوشن بهینه شده توسط الگوریتم نهنگ (بالا) و کلونی زنبور عسل (پایین)

ارزیابی و مقایسه مدل‌های پتانسیل چشمه‌های آب زیرزمینی

برای ارزیابی نقشه‌های تولید شده، در مرحله اول چگالی نقاط چشمه در هر کلاس از مدل‌های پتانسیل تولید شده محاسبه شد. طبق جدول ۶، چگالی چشمه‌ها یک روند افزایشی را از کلاس خیلی کم تا بسیار زیاد برای تمامی مدل‌ها

را نشان می دهد. برای تمام مدل ها، کلاس «خیلی پایین» کمترین چگالی و کلاس «خیلی زیاد» بیشترین درصد چگالی را داشت. کمترین چگالی (۲/۶۶ درصد) نیز مربوط به کلاس «خیلی پایین» مدل SWARA-CNN-ABC است.

جدول ۶. چگالی نقاط چشمه در هر کلاس از مدل های پتانسیل

Models	Very low	Low	Moderate	High	Very high
SWARA-CNN-ABC	2.66	6.38	19.15	34.04	37.77
SWARA-CNN-WOA	4.26	9.57	20.74	28.19	37.23

شاخص های آماری

استفاده از پارامترهای اعتبارسنجی مختلف از جمله حساسیت، خصوصیت، دقت، کاپا و AUC-ROC برای ارزیابی دقیق تر نقشه ها و مقایسه آن ها با یکدیگر انجام شد (۱). در جدول ۳ نتایج متدهای اعتبارسنجی برای مجموعه داده آموزش ارائه شده است. مدل SWARA-CNN-WOA (حساسیت = ۰/۹) و SWARA-CNN-ABC (حساسیت = ۰/۸۹) را دارد. علاوه بر این، در مورد دسته بندی صحیح پیکسل های غیر چشمه (خصوصیت)، SWARA-CNN-WOA (۰/۸۳) بهترین عملکرد را داشت، به دنبال آن مدل SWARA-CNN-ABC با مقدار ۰/۷۵ قرار دارد. طبق جدول ۸، کمترین مقدار برای دو پارامتر مهم دقت و کاپا متعلق به مدل SWARA-CNN-ABC بوده است (دقت = ۰/۸۵۴، کاپا = ۰/۷۰۷).

جدول ۴ نتایج متدهای اعتبارسنجی برای مجموعه داده آزمون را ارائه می دهد. مدل SWARA-CNN-ABC بالاترین حساسیت (۰/۹۱) عملکرد بهتری در دسته بندی پیکسل های خوب نسبت به سایر مدل ها ارائه داد، به دنبال آن مدل سایر مدل ها با میزان حساسیت ۰/۸۹ قرار گرفتند. همچنین در مورد دسته بندی صحیح پیکسل های غیر چشمه (خصوصیت)، SWARA-CNN-ABC بهترین عملکرد را داشت. طبق جدول ۹، مدل SWARA-CNN-WOA کمترین دقت (۰/۷۴) و کاپا (۰/۸۷) را نسبت به دیگری داشت.


تحلیل منحنی ROC

شکل ۷ مقادیر مساحت زیرمنحنی برای مدل های هیبریدی برای مجموعه داده های آموزش و آزمون نشان می دهد. نرخ موفقیت نشان داد مدل SWARA-CNN-ABC (۰/۹۱) و SWARA-CNN-WOA (۰/۸۶) به ترتیب در رتبه های اول و دوم قرار گرفته اند (شکل ۷).

علاوه بر آن (جدول ۵ و شکل ۷). جدول ۷ جزئیات بیشتری را در مورد منحنی ROC برای نرخ پیش بینی نشان می دهد.

جدول ۷. جزئیات تحلیل نمودار ROC

Test result variable(s)	Area	Std.error	Asymptotic sig.	Asymptotic 95% confidence interval	
				Lower bound	Upper bound
SWARA-CNN-ABC	0.881	0.0018	0	0.872	0.889
SWARA-CNN-WOA	0.87	0.0021	0	0.86	0.88



شکل ۷. نمودار ROC برای مدل‌های پتانسیل تولید شده (چپ) WOA و (راست) ABC

بحث

تأثیر کلاس‌های عوامل تعیین‌کننده بر مدل‌های پتانسیل چشمه‌های آب زیرزمینی

در این مطالعه عوامل تعیین‌کننده ابتدا با استفاده از تحقیقات گذشته و داده‌های موجود مشخص شدند، سپس وزن هر کلاس با استفاده از مدل‌های SWARA تعیین شد. بر اساس نتایج، ارتفاعات پایین و متوسط بیشترین تأثیر را نشان دادند، زیرا آب به سمت زمین در ارتفاعات پایین به دلیل شیب هیدرولیک حرکت می‌کند.

هر چه شیب کمتر باشد، زمان بیشتری برای نفوذ آب وجود دارد. در این مطالعه، کمترین درجه شیب (۱۲/۹۰) بیشترین ظرفیت را نشان داد. همچنین، در ارتباط با جهات شیب، کلاس‌های «مسطح» و «غرب» بیشترین احتمالات را داشتند. این مطالعه همچنین نشان داد کلاس «مسطح» از عامل منحنی طراحی و کلاس «مرتع» از عامل کاربری اراضی بیشترین ظرفیت آب زیرزمینی را داشتند. همانند آنچه در نتایج پژوهش Razavi Termeh و همکاران (۲۰۱۹) ارائه شده است [۱۱]، این پژوهش نیز به این نتیجه رسید که کلاس خاک «RockOutcrob/Entisols» بیشترین تأثیر را بر پتانسیل آب زیرزمینی دارد.

واحدهای لیتولوژی مختلف بستگی به ساختار زمین‌شناسی منطقه مطالعه شده، تأثیرات مختلفی در نفوذ آب دارند. در این مطالعه، kkkk و یا همان Grey, thick – bedded to massive o'olitic limestone بیشترین همبستگی با ظرفیت آب زیرزمینی را نشان داد. فاصله تا رودخانه‌ها در مناطق نیمه خشک به عنوان یک منبع مهم برای شارژ آب زیرزمینی تأثیر می‌گذارد. نتایج نشان داد ظرفیت آب زیرزمینی با افزایش فاصله از رودخانه نیز کاهش می‌یابد. در مورد چگالی زهکشی نیز مشاهده شد که چگالی به طور مستقیم با احتمال وقوع آب زیرزمینی مرتبط است. احتمال وقوع چشمه نیز با افزایش SPI افزایش می‌یابد. در این مطالعه نیز نشان داده شد که بیشترین احتمال شاخص SPI مربوط به کلاس ۴۸۶۶۴-۰ بوده است.

باران یک پارامتر است که به طور قابل توجهی بر شارژ آب زیرزمینی تأثیر می‌گذارد. هر چه باران بیشتر باشد، ظرفیت آب زیرزمینی نیز بیشتر است [۲۸]. نتایج این پژوهش نشان داد محدوده باران ۸۰۰-۹۰۰ میلی‌متر بیشترین تأثیر را داشته است. در مورد NDVI، نتایج این مطالعه نشان داد رابطه مستقیمی بین چگالی گیاهان و ظرفیت آب زیرزمینی وجود دارد. نقشه‌های تولید شده همچنین نشان داد برای هر چهار مدل هیبرید، مناطق شمال غربی تا جنوب شرقی و تا حدودی مرکز به سمت شمال شرق، بیشترین و مناطق شمال شرقی و جنوب غربی کمترین ظرفیت آب زیرزمینی را دارند.

مزایا و معایب مدل‌ها و ارزیابی عملکرد آن‌ها

با در نظر گرفتن تقسیم بندی پتانسیل آب زیرزمینی، محققان در مناطق مختلف از تکنیک‌های مختلف استفاده کرده‌اند و اغلب به این نتیجه رسیده‌اند که علاوه بر دقت داده‌ها، نوع مدل مورد استفاده برای دقت پیش‌بینی بسیار مؤثر است [۲۸] (لی و همکاران، ۲۰۱۷؛ آرورا و همکاران، ۲۰۱۹). علاوه بر این، در سال‌های اخیر با توسعه روش‌های داده‌کاوی در حوزه‌های مختلف مدل‌سازی فضایی، محققان اعلام کرده‌اند که استفاده از یادگیری ماشین و مدل‌های ترکیبی نتایج بهتری نسبت به سایر روش‌ها می‌تواند فراهم کند [۱۱]. نتایج این مطالعات نشان داده‌اند استفاده از مدل‌های مختلف برای یک مجموعه داده می‌تواند نتایج متفاوتی را ایجاد کند. با این حال باید توجه داشت که هیچ مدل یا الگوریتمی وجود ندارد که بتواند مسائل پیچیده مانند پتانسیل آب زیرزمینی را با دقت حداکثری پیش‌بینی کند. در این مطالعه، یک مدل ترکیبی جدید برای تولید نقشه پتانسیل آب زیرزمینی استفاده شد. در مرحله اول، روش تصمیم‌گیری چندمعیاره، SWARA، برای تولید داده‌های ورودی استفاده شد. در مرحله بعدی، روش CNN با دو الگوریتم ABC و WOA ترکیب شد تا دو مدل قدرتمند داده‌کاوی ایجاد کند. سپس نقشه‌های تولید شده در مرحله نهایی ارزیابی شدند و هر مرحله به صورت جداگانه تجزیه و تحلیل شد. بر اساس جدول ۶ و آنچه در بخش نتایج ذکر شد، مدل SWARA هم‌تناسبی یکسانی را بین کلاس هر عامل و چشمه‌ها نشان داد. به بیان دیگر، مقادیر خروجی نرمال بودند و بین ۰ تا ۱ قرار داشتند.

الگوریتم‌های یادگیری ماشین نظارت شده در حل مسائل غیرخطی عملکرد خوبی داشته‌اند. با این حال، همواره چالش بیش‌برازش در به‌کارگیری این روش‌ها وجود داشته است. گرچه روش یادگیری عمیق CNN در مطالعات مختلف نتایج موفق‌تری ارائه داده است، اما بیش‌برازش می‌تواند عملکرد پیش‌بینی مدل را ضعیف کند. برای کاهش یا جلوگیری از این مشکل، بسیاری از محققان از الگوریتم‌های متاهوریستیک برای بهینه‌سازی پارامترها استفاده کرده‌اند [۲۹]. یکی از مزایای این روش، قابلیت استخراج ویژگی‌های پیچیده از داده‌ها است. این روش با توانایی آموزش از پیش فرض‌های تصویری، می‌تواند الگوهای ناشناخته و مهم در پتانسیل یابی آب زیرزمینی را شناسایی کند. الگوریتم‌های متاهوریستیک از اطلاعات به دست آمده از محیط برای بهبود فرایند یادگیری استفاده می‌کنند و باعث افزایش کارایی و سرعت آن می‌شوند [۳۰]. ترکیب این الگوریتم‌ها با روش یادگیری CNN می‌تواند به طور مؤثر در مدیریت منابع آب زیرزمینی، تشخیص ناپیوستگی‌ها و پیش‌بینی میزان استفاده از این منابع در زمینه‌های مختلف از جمله کشاورزی و صنعتی مورد استفاده قرار گیرد، که این امر به بهبود کارایی و اقتصادی بخش‌های مختلف اجتماع کمک خواهد کرد. همان‌طور که پیش‌تر اشاره شد، تفاوت این مطالعه با سایر مطالعات در مدل‌سازی پتانسیل آب زیرزمینی در استفاده از الگوریتم‌های متاهوریستیک WOA و ABC و ترکیب آن با مدل جدید و قدرتمند CNN بوده است. بر اساس خروجی‌ها، هنگام استفاده از مدل SWARA برای تولید مجموعه داده ورودی، CNN-ABC عملکرد پیش‌بینی بهتری نسبت به CNN-WOA نشان داد (جدول ۵). در این تحقیق، به این نتیجه رسیدیم که حتی برای یک مجموعه داده، دو مدل هیبرید مختلف می‌توانند دقت متفاوتی داشته باشند.

به طور کلی، نتایج نشان داد با وجود عملکرد برجسته هر دو مدل، مدل SWARA-CNN-ABC کمی دقت بیشتری نسبت به مدل دیگر دارد. بر اساس آنچه گفته شد، بهترین راه برای بهبود دقت نتایج در مسائل مدل‌سازی فضایی، استفاده از الگوریتم‌های جدید و مقایسه آن‌ها با دیگر الگوریتم‌هاست. همچنین، به‌کارگیری مدل‌های ترکیبی که در این مطالعه استفاده شدند، برای مناطق دیگر تحت شرایط مختلف نیز توصیه می‌شوند. همچنین پیشنهاد می‌شود که در تحقیقات آتی، علاوه بر الگوریتم‌های جدید، نتایج روش‌های مختلف برای آموزش مدل‌های

ترکیبی استفاده شود.

نتیجه‌گیری

آزمایش‌های اکتشافی منابع آب زیرزمینی زمان‌بر و پرهزینه هستند، در نتیجه تهیه نقشه پتانسیل آب زیرزمینی با استفاده از روش‌های نوین یادگیری ماشینی با هدف مدیریت، حفاظت و بهره‌وری صحیح از منابع آب با توجه به نیاز آبی و غذایی کشور امری حیاتی است. با توجه به اهمیت روزافزون منابع آب زیرزمینی، استفاده از نقشه پتانسیل منابع آب زیرزمینی به عنوان یک ابزار بسیار مفید برای مدیریت این منبع ارزشمند و محدود افزایش پیدا کرده است. چارچوب ارائه شده در این مطالعه ترکیبی از روش‌ها و الگوریتم‌های نوین برای زون‌بندی درجه پتانسیل آب زیرزمینی در استان کرمانشاه، ایران است. برای این امر، ارتباط بین سیزده پارامتر مستقل و پارامتر وابسته (موقعیت چشمه‌ها) با استفاده از مدل SWARA تعیین شد. نتایج سپس وارد نرم‌افزار Python شدند تا مدل‌های داده‌کاوی CNN-ABC و CNN-WOA را آموزش دهند. نتایج نشان‌دهنده این موضوع بود که مدل ترکیبی SWARA-CNN-ABC دقت بهتری ارائه کرده و دارای عملکرد بهتری است.

منابع

- [1] Al-Abadi AM, Pourghasemi HR, Shahid S, Ghalib HB. Spatial Mapping of Groundwater Potential Using Entropy Weighted Linear Aggregate Novel Approach and GIS. Arab J Sci Eng. 2017;42(3):1185-99.
- [2] AlAyyash S, Al-Fugara Ak, Shatnawi R, Al-Shabeeb AR, Al-Adamat R, Al-Amoush H. Combination of Metaheuristic Optimization Algorithms and Machine Learning Methods for Groundwater Potential Mapping. Sustainability. 2023;15(3):2499.
- [3] Emami H, Emami S. Presentating a New Approach for Evaluating the Hydro-geochemical Quality of Groundwater using Swarm Intelligence Algorithms. Iranian journal of Ecohydrology. 2019;6(1):177-90 [Persian].
- [4] Erclin AE, Hoekstra AY. Water footprint scenarios for 2050: A global analysis. Environment International. 2014;64:71-82.
- [5] Moridi A. State of water resources in Iran. Int J Hydrol. 2017;1:111-4.
- [6] Rahmati O, Melesse AM. Application of Dempster-Shafer theory, spatial analysis and remote sensing for groundwater potentiality and nitrate pollution analysis in the semi-arid region of Khuzestan, Iran. Science of The Total Environment. 2016;568:1110-23.
- [7] Poursalehi F, KhasheiSiuki A, Hashemi SR. Investigating the performance of random forest algorithm in predicting water table fluctuations Compared with two models of decision tree and artificial neural network (Case study: unconfined aquifer of Birjand plain). Iranian journal of Ecohydrology. 2021;8(4):961-74 [Persian].
- [8] Najib M, Asghari Moghaddam A, Nadiri AA, Fijani E. Evaluating Quality Variation of Groundwater Resources in Marand Plain Using Unsupervised Combination Approach (GQI and GWQI Index). Iranian journal of Ecohydrology. 2021;8(4):1061-80 [Persian].
- [9] Rahmati O, Naghibi SA, Shahabi H, Bui DT, Pradhan B, Azareh A, et al. Groundwater spring potential modelling: Comprising the capability and robustness of three different modeling approaches. Journal of Hydrology. 2018;565:248-61.
- [10] Khosravi K, Panahi M, Tien Bui D. Spatial prediction of groundwater spring potential mapping based on an adaptive neuro-fuzzy inference system and metaheuristic optimization. Hydrology and Earth System Sciences. 2018;22(9):4771-92.
- [11] Razavi-Termeh SV, Khosravi K, Sadeghi-Niaraki A, Choi S-M, Singh VP. Improving groundwater potential mapping using metaheuristic approaches. Hydrological Sciences Journal. 2020;65(16):2729-49.
- [12] LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521(7553):436-44.
- [13] Pradhan B, Lee S, Dikshit A, Kim H. Spatial flood susceptibility mapping using an explainable artificial intelligence (XAI) model. Geoscience Frontiers. 2023;14(6):101625.
- [14] Paryani S, Bordbar M, Jun C, Panahi M, Bateni SM, Neale CMU, et al. Hybrid-based approaches for the flood susceptibility prediction of Kermanshah province, Iran. Nat Hazards. 2023;116(1):837-68.
- [15] Falah F, Ghorbani Nejad S, Rahmati O, Daneshfar M, Zeinivand H. Applicability of generalized additive model in groundwater potential modelling and comparison its performance by bivariate statistical methods. Geocarto International. 2017;32(10):1069-89.
- [16] Al-Fugara Ak, Ahmadlou M, Shatnawi R, AlAyyash S, Al-Adamat R, Al-Shabeeb AA-R, et al. Novel hybrid models combining meta-heuristic algorithms with support vector regression (SVR) for groundwater potential mapping. Geocarto International. 2022;37(9):2627-46.
- [17] Kordestani MD, Naghibi SA, Hashemi H, Ahmadi K, Kalantar B, Pradhan B. Groundwater potential mapping using a novel data-mining ensemble model. 2019.
- [18] Pande CB, Moharir KN, Singh SK, Varade AM. An integrated approach to delineate the groundwater potential zones in Devdari watershed area of Akola district, Maharashtra, Central India. Environ Dev Sustain. 2020;22(5):4867-87.
- [19] Ikirri M, Boutaleb S, Ibraheem IM, Abioui M, Echogdali FZ, Abdelrahman K, et al. Delineation of Groundwater

- Potential Area using an AHP, Remote Sensing, and GIS Techniques in the Ifni Basin, Western Anti-Atlas, Morocco. *Water*. 2023;15(7):1436.
- [20]Fashae OA, Tijani MN, Talabi AO, Adedeji OI. Delineation of groundwater potential zones in the crystalline basement terrain of SW-Nigeria: an integrated GIS and remote sensing approach. *Appl Water Sci*. 2014;4(1):19-38.
- [21]Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*. 2021;33(12):6999-7019.
- [22]Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, et al. Recent advances in convolutional neural networks. *Pattern Recognition*. 2018;77:354-77.
- [23]Albawi S, Mohammed T, Al-Zawi S. Understanding of a convolutional neural network. In 2017 international conference on engineering and technology (ICET) 2017 Aug 21 (pp. 1-6). Ieee.
- [24]Reddy K, Saha AK. A modified Whale Optimization Algorithm for exploitation capability and stability enhancement. *Heliyon*. 2022;8(10).
- [25]Karaboga D, Akay B. A comparative study of Artificial Bee Colony algorithm. *Applied Mathematics and Computation*. 2009;214(1):108-32.
- [26]Wang W, Lu Y. Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model. *IOP Conf Ser: Mater Sci Eng*. 2018;324(1):012049.
- [27]Waikar M, Nilawar AP. Identification of groundwater potential zone using remote sensing and GIS technique. *International Journal of Innovative Research in Science, Engineering and Technology*. 2014;3(5):12163-74.
- [28]Lee S, Hong S-M, Jung H-S. GIS-based groundwater potential mapping using artificial neural network and support vector machine models: the case of Boryeong city in Korea. *Geocarto International*. 2018;33(8):847-61.
- [29]Mallick J, Khan RA, Ahmed M, Alqadhi SD, Alsubih M, Falqi I, et al. Modeling Groundwater Potential Zone in a Semi-Arid Region of Aseer Using Fuzzy-AHP and Geoinformation Techniques. *Water*. 2019;11(12):2656.
- [30]Dokeroglu T, Sevinc E, Kucukyilmaz T, Cosar A. A survey on new generation metaheuristic algorithms. *Computers & Industrial Engineering*. 2019;137:106040.