



مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی فارس

پژوهش‌های آبخیزداری

شاپا: ۲۰۳۸-۲۹۸۱



مركز تحقيقات، آموزش و پژوهش کشاورزی

مدل سازی توان منابع آب زیرزمینی با استفاده از مدل‌های یادگیری ماشینی

احمد سلامت^۱، مجتبی اردستانی^{۲*}، بهرام ملک‌محمدی^۳

۱ - دانشجوی دکتری مهندسی محیط‌زیست گرایش منابع آب، پردیس بین‌المللی کیش، دانشگاه تهران

۲ - استاد، دانشکده‌ی محیط‌زیست، دانشگاه تهران

۳ - دانشیار، دانشکده‌ی محیط‌زیست، دانشگاه تهران

چکیده‌ی مبسوط

مقدمه و هدف

توان‌یابی منابع آب زیرزمینی یکی از اصل‌های پایه در مدیریت منابع آب است. هدف این پژوهش توان‌یابی آب زیرزمینی با استفاده از مدل‌های یادگیری ماشین بردار پشتیبان (SVM) و همچنین دستورالعمل‌های فراکاوشی (مدل ترکیبی (هیبریدی) ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی زنبور عسل (SVM-BA) و مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی ازدحام ذرات (SVM-PSO) است.

مواد و روش‌ها

در این پژوهش در منطقه‌ی بجنورد عامل‌های بلندی، شیب، جهت، شاخص رطوبت پستی‌بلندی، فاصله از آبراهه، تراکم زهکشی، فاصله از گسل، سنگ‌شناسی، شاخص موقعیت پستی‌بلندی، شاخص ناهمواری زمین، موقعیت شیب نسبی و شاخص همگرایی جریان انتخاب شدند. از شرکت آب منطقه‌ای اطلاعات موقعیت ۳۵۹ چشمه دریافت شد. دستورالعمل تقسیم‌بندی تصادفی برای تقسیم نقطه‌های آموزشی (۷۰٪) و نقطه‌های اعتبارسنجی (۳۰٪) استفاده شد. براساس تحلیل حساسیت حذفی، اندازه‌ی اهمیت و مشارکت متغیرهای ورودی در توان‌یابی آب زیرزمینی مشخص شد. ارزیابی دقت مدل‌ها در دو مرحله‌ی آموزش و اعتبارسنجی براساس روش منحنی مشخصه عامل گیرنده (ROC) انجام شد.

نوع مقاله: پژوهشی

*مسئول مکاتبات، پست الکترونیکی: Ardestan@ut.ac.it

استناد: سلامت، ا.، اردستانی، م.، ملک‌محمدی، ب. ۱۴۰۲. مدل‌سازی پتانسیل منابع آب زیرزمینی با استفاده از مدل‌های یادگیری ماشینی. پژوهش‌های آبخیزداری، ۳۶ (۴): ۱۳۲-۱۱۴.

شناسه‌ی دیجیتال: 10.22092/WMRJ.2023.360675.1506

تاریخ دریافت: ۱۴۰۱/۰۹/۰۲، تاریخ بازنگری: ۱۴۰۱/۱۱/۰۱، تاریخ پذیرش: ۱۴۰۱/۱۲/۲۸، تاریخ انتشار: ۱۴۰۲/۱۰/۰۱
پژوهش‌های آبخیزداری، سال ۱۴۰۲، دوره‌ی ۳۶، شماره‌ی ۴، شماره‌ی پیاپی ۱۴۱، زمستان ۱۴۰۲، صفحه‌های ۱۱۴ تا ۱۳۲.

© نویسندگان

ناشر: مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی استان فارس



نتایج

ارزیابی دقت مدل‌ها براساس معیار ارزیابی مساحت زیرمنحنی عامل گیرنده (AUC) نشان داد که دقت پیش‌بینی مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی ازدحام ذرات (SVM-PSO) ۰/۹۴۵ بیشتر از دیگر مدل‌ها (SVM: 0.918 و SVM-BA: 0.932) بود. براساس نتایج مدل برتر در این پژوهش ۷۵٪ از سطح منطقه طبقه‌ی توان زیاد و ۳۸/۶۶٪ از سطح منطقه طبقه‌ی توان خیلی زیاد را کسب کردند. از میان عامل‌های، موقعیت شیب نسبی (۱۴/۵٪)، فاصله از گسل (۱۳/۴٪) و سنگ‌شناسی (۱۲/۳٪) در پیش‌بینی توان آب زیرزمینی بیشترین اهمیت را داشتند.

بحث و نتیجه‌گیری

براساس نتایج این پژوهش، عملکرد مدل ماشین بردار پشتیبان زیاد بود و دو دستورالعمل بهینه‌سازی فراکاوشی زنیورسل و فراکاوشی ازدحام ذرات موجب تقویت قدرت پیش‌بینی مدل شدند. همچنین مدل‌های یادگیری ماشینی می‌توانند ارتباط میان عامل‌های محیطی و آب‌دهی چشمه‌ها را شناسایی کنند و با به‌کارگیری داده‌های موجود، نقش آن‌ها را تعیین کنند. عامل موقعیت شیب نسبی به‌عنوان مهم‌ترین متغیر و عامل فاصله از گسل نیز به‌عنوان دومین متغیر مهم در این پژوهش مشخص شدند. نتایج پژوهش نشان داد که در تغذیه‌ی بخش‌های زیرسطحی، ذخیره و جریان آب زیرزمینی، گسل‌های منطقه نقش مهمی داشتند. با کاربرد مدل در شناسایی وضعیت توان آب زیرزمینی عامل سنگ‌شناسی نیز به‌عنوان سومین متغیر مهم معرفی شد. در این پژوهش، با پیشنهاد نقشه‌ی توان آب زیرزمینی، امکان برنامه‌ریزی و تدقیق آمایش سرزمین برای آبخیز بجنورد فراهم شد.

واژگان کلیدی: آب زیرزمینی، بجنورد، ماشین بردار پشتیبان، یادگیری ماشینی

مقدمه

را ایجاد کند و هم اینکه هزینه‌ی حفاری و بهره‌برداری آب زیرزمینی را کاهش دهد (دی‌سانتا و همکاران ۲۰۰۷؛ شنگا و همکاران ۲۰۱۸). روش‌های مختلفی برای تعیین توان آب زیرزمینی وجود دارد که از جمله آن‌ها روش ژئوالکتریک، استفاده از موج‌های صوتی، حفر چاه گمانه را می‌توان نام برد. از طرفی این روش‌ها با داشتن دقت زیاد، نیاز به مهارت، تخصص و صرف هزینه و زمان زیاد دارند. امروزه ادغام سنجش‌ازدور و فن‌های سامانه‌ی اطلاعات جغرافیایی می‌تواند به کشف منطقه‌های توان آب زیرزمینی و غلبه بر برخی از مانع‌های مزبور کمک کند. فناوری سامانه‌ی اطلاعات جغرافیایی در کم‌ترین زمان ممکن و هزینه اندک، در منطقه‌های بزرگ و غیرقابل دسترسی، به ابزاری بسیار مفید برای دسترسی، نظارت و حفظ منابع آب زیرزمینی تبدیل شده است (گینتومو و همکاران ۲۰۱۵؛ جاوهر و همکاران ۲۰۱۸) همچنین این امکان را فراهم می‌سازد که با کم‌ترین تلاش ممکن بتوان ناحیه‌هایی که احتمال وجود چشمه را دارند شناسایی کرده و در مواقع خشک‌سالی از آن بهره‌برداری کرد (کورسینی و همکاران ۲۰۰۹). نتایج پژوهش داوودی‌مقدم و همکاران (۲۰۱۳)، بر تأثیر

شناخت اصولی منابع آب زیرزمینی یک اصل کلیدی مدیریت منابع آب به‌شمار می‌آید. با توجه به افزایش نیاز کشور ایران به آب و همچنین به‌دلیل توان زیاد آلودگی منابع آب‌های سطحی زمین، توزیع نامتعادل مکانی و زمانی این منابع، پرداختن به موضوع‌های مربوط به آب‌های زیرزمینی، امری ضروری و اجتناب‌ناپذیر است. افزایش جمعیت و افزایش تقاضا برای آب و غذا موجب افزایش تنش در کمیت و کیفیت منابع آب زیرزمینی و کاهش منابع با ارزش آب زیرزمینی شده است (تایت و همکاران ۲۰۰۸). بنابراین جلوگیری از افزایش این مشکلات با مدیریت و بهره‌برداری متناسب با توان آب زیرزمینی یکی از رویکردهای مهم در این زمینه است. در سال‌های اخیر به‌دلیل برداشت بی‌رویه از منابع آب به‌ویژه چاه‌ها به‌دلیل‌های گوناگون مانند توسعه‌ی صنعتی، رشد بی‌رویه جمعیت، کاهش بارش‌های جوی، خشک‌سالی‌ها و غیره، مسئله‌ی کم‌آبی حادث شده است. در نتیجه ضرورت پژوهش‌های دقیق و راهبردی ممنوعیت بهره‌برداری برای جلوگیری از ایجاد تنش در آبخوان‌های آبرفتی اجتناب‌ناپذیر است. شناخت منطقه‌های مستعد استخراج آب زیرزمینی هم می‌تواند زمینه فراهم شدن آب بیشتر و با کیفیت بهتر

عملکرد بهتری داشت. نقشه‌ی تولیدشده براساس مدل برتر نشان داد که برای تولید آب‌های زیرزمینی ۲۰/۲٪ از مساحت منطقه در طبقه‌ی توان بسیار زیاد بودند. کمبود داده‌های لازم در شناسایی توان منابع آب زیرزمینی در سازندهای سخت (محدوده‌های خارج از آبخوان) یکی از مهم‌ترین مسائلی است که غالباً هنگام اجرای مدل‌سازی آبی، پژوهشگران با آن روبرو هستند. بنابراین، بررسی وضعیت توان منابع آب زیرزمینی در سازندهای سخت یکی از مسائل مهم در مدیریت منابع آب پایدار است. از این رو استفاده از مدل‌سازی مکانی برای تعیین توان ذخیره و بهره‌برداری آب زیرزمینی گامی رو به جلو در زمینه‌ی مدیریت منابع آب زیرزمینی می‌باشد. استان خراسان شمالی در زمره‌ی استان‌های رو به رشد کشور است که با پدیده‌ی افزایش جمعیت و به تبع آن چالش تأمین نیاز آبی در بخش شرب، کشاورزی و صنعت روبرو می‌باشد. در سال‌های اخیر در این استان وضعیت منابع آب سطحی و زیرزمینی خوب نبوده است به‌طوری‌که وزارت نیرو توسعه‌ی بهره‌برداری از منابع آب بسیاری از دشت‌های خراسان شمالی را ممنوع کرده است. به دنبال افزایش مشکلات اجتماعی-اقتصادی در استان، ضرورت توجه به منابع آب زیرزمینی بیشتر شده است. از آنجایی که تعیین وضعیت توان منابع آب زیرزمینی با استفاده از مدل‌های آبی و عددی نیازمند اطلاعات دقیق و زیاد هستند، استفاده از آن‌ها در بسیاری از محدوده‌های پژوهشی امکان‌پذیر نیست. در این پژوهش سعی بر آن است که یک روش نوین برای حل این مشکل پیشنهاد شود تا براساس اطلاعات موجود از وضعیت آب‌دهی چشمه‌ها و نقشه‌های عامل‌های محیطی بتوان از وضعیت توان آب زیرزمینی منطقه پیش‌بینی صحیحی انجام داد. هدف از این پژوهش مقایسه‌ی عملکرد مدل‌های ترکیبی در پیش‌بینی توان منابع آب زیرزمینی، تهیه‌ی نقشه‌ی پهنه‌بندی توان آب زیرزمینی براساس بهترین مدل و تعیین اندازه‌ی مشارکت متغیرهای محیطی در وضعیت توان منابع آب زیرزمینی می‌باشد. علت انتخاب محدوده‌ی پژوهشی بجنورد در استان خراسان شمالی این است که وضعیت توان آب زیرزمینی آن به دلیل نبود اطلاعات آبی و چاه‌های اندازه‌گیری، کاملاً نامشخص است. بنابراین، برای رفع این مشکل استفاده از مدل‌های آبی و عددی محدودیت زیادی دارند. بخش زیادی از آب آشامیدنی شهر بجنورد و روستاهای منطقه که در این محدوده‌ی پژوهشی هستند، از آب زیرزمینی تهیه می‌شود. این موضوع، اهمیت بررسی توان آب زیرزمینی با استفاده از رویکردهای نوین را دوچندان می‌کند. لازم به ذکر است که دستورالعمل‌های فراکاوشی موجب


اندازه‌ی نمونه (۱۰۰٪، ۷۵٪، ۵۰٪ و ۲۵٪ داده‌ها) در مدل‌سازی توان آب زیرزمینی در آبخوان‌های سازند سخت کوهستانی با استفاده از مدل‌های یادگیری ماشینی شامل سامانه‌ی استنتاجی عصبی-فازی سازگار یافته (ANFIS)، سامانه‌ی استنتاجی عصبی فازی سازگار یافته - دستورالعمل رقابتی امپریالیستی (ANFIS-ICA)، درخت تصمیم‌گیری تناوبی (ADT) و جنگل تصادفی (RF) نشان داد که اندازه‌ی نمونه بر عملکرد چهار دستورالعمل یادگیری ماشینی مؤثر بود و مدل جنگل تصادفی نسبت به کاهش اندازه‌ی نمونه‌ها حساسیت کمتری داشت. افزون بر این نتایج اعتبارسنجی ثابت کرد که مدل جنگل تصادفی (AUCROC=96.32%) در بین چهار مجموعه داده بهترین عملکرد را داشت. همچنین موقعیت شیب نسبی، سنگ شناسی و فاصله از گسل به عنوان اصلی ترین عامل‌های مؤثر در توزیع چشمه‌ها در مدل‌سازی توان آب زیرزمینی انتخاب شدند. نتایج پژوهش موسوی و همکاران (۲۰۲۱) نشان داد که توان آب زیرزمینی مدل‌های Bagging (یعنی RF و Bagged CART) عملکرد بیشتری در مقایسه با مدل‌های Boosting داشتند. به طور کلی، مدل RF عملکرد بهتری در مقایسه با مدل‌های دیگر داشت (با دقت = ۰/۸۶، کاپا = ۰/۶۷، صحت = ۰/۸۵). همچنین، متغیرهای شاخص موقعیت پستی بلندی، ژرفای دره، تراکم زهکشی، بلندی و فاصله از جریان در روند مدل‌سازی بیشترین سهم را داشتند. فام و همکاران (۲۰۱۹) در منطقه‌ی گوجارات هند برای توان‌یابی منابع آب زیرزمینی از مدل‌های ترکیبی مختلف هوش مصنوعی استفاده کردند. در پژوهش آن‌ها عامل‌های پستی بلندی، بارندگی، شاخص رطوبت پستی بلندی، سنگ‌شناسی و کاربری زمین به عنوان متغیرهای مستقل پیش‌بینی کننده در نظر گرفته شدند. نتایج پژوهش آن‌ها نشان داد که مدل ترکیبی جنگل چرخشی و تقویتی چندگانه کارایی بیشتری داشت و در شرایطی که تعداد داده‌های اندازه‌گیری آب‌دهی چشمه‌ها و چاه‌ها محدود باشد، این مدل قادر به پیش‌بینی توان آب زیرزمینی در سطح گسترده است. ساچدوا و کومار (۲۰۲۱) برای تهیه‌ی نقشه‌ی آب‌های زیرزمینی نهفته در دهلیپور هند، مدل‌های درختان تصمیم‌گیری پیشرفته و جنگل تصادفی را با یکدیگر مقایسه کردند. در این پژوهش ۱۴ عامل تأثیرگذار بر آب زیرزمینی برای منطقه بررسی شده در نظر گرفته شد. با استفاده از ویژگی‌های عملکرد گیرنده (ROC)، عملکرد پیش‌بینی این مدل‌ها با هم مقایسه شد. نتایج این پژوهش نشان داد مدل درخت تصمیم‌گیری تقویتی شده در مقایسه با مدل جنگل تصادفی

اندازه‌ی بارندگی سالانه حدود ۲۷۲ میلی‌متر است و حداقل و حداکثر دمای منطقه به ترتیب ۶/۸ تا $19/7^{\circ}\text{C}$ است. موقعیت منطقه‌ی بررسی‌شده در شکل ۱ نشان داده شده است. گسل‌ها و شکستگی‌های زیادی در منطقه‌ی بررسی‌شده وجود دارد که نقش مهمی در گسترش چشمه‌ها دارند. لازم به ذکر است که منابع آب زیرزمینی ۸۸٪ از منابع آب استان خراسان را تأمین می‌کند. روندنمای مرحله‌های انجام پژوهش در شکل ۲ نشان داده شده است.

بهینه‌سازی مدل‌های یادگیری ماشینی شده و در نهایت دقت پیش‌بینی مدل یادگیری ماشینی افزایش می‌یابد.


مواد و روش‌ها

این پژوهش در منطقه‌ی بجنورد در استان خراسان شمالی که میان عرض‌های جغرافیایی $37^{\circ} 10'$ و $37^{\circ} 30'$ شمالی و طول‌های جغرافیایی $57^{\circ} 00'$ و $57^{\circ} 40'$ شرقی است، انجام شد. بلندی منطقه‌ی بجنورد از ۸۷۵ تا ۲۹۶۸ متر متغیر است.



شکل ۱- موقعیت منطقه و چشمه‌های بررسی‌شده در پژوهش.

Figure 1- The area study and the location of the springs in the current research.



شکل ۲- روندنمای مرحله‌های انجام پژوهش.

Figure 2- Flowchart of the research.

سطح زمین است تا بتواند در آن نفوذ کند (داوودی‌مقدم و همکاران ۲۰۱۳). منطقه‌هایی که شیب کمتری دارند، برای مدت طولانی آب را حفظ می‌کنند که این امر امکان نفوذ و تغذیه آبخوان را بیشتر می‌کند و یک عامل مؤثر بر رواناب سطحی، تراکم زهکشی و رطوبت خاک است (گروی ۲۰۱۱). جهت شیب قرار گرفتن در معرض نور خورشید را تعیین می‌کند و به دنبال آن آثار تبخیر نیز به عنوان یک عامل پیش‌بینی در نظر گرفته می‌شود (دای و همکاران ۲۰۰۱). تغییرات جهت شیب منجر می‌شود که اندازه‌ی انرژی خورشیدی دریافت‌شده به وسیله‌ی سطح زمین متفاوت باشد. همچنین این تغییرات بر اندازه‌ی رطوبت خاک، نوع، اندازه، توزیع تاج پوشش و در نهایت بر تبخیر و تعرق تأثیرگذار است (رحمتی و ملسه ۲۰۱۶؛ نقیبی و همکاران ۲۰۱۸). شاخص رطوبت پستی‌بلندی (TWI) تأثیر پستی‌بلندی بر برخی از خصوصیات آب‌شناختی را کاهش می‌دهد. این شاخص روند جمع‌آوری آب در مکان‌های مختلف و تأثیر گرانش بر نفوذ آب به سمت پایین به یک سفره‌ی آبخوان را توصیف می‌کند (قربانی‌نژاد و همکاران ۲۰۱۷). افزایش فاصله از رودها، به‌ویژه رودهایی با جریان دائمی یا رودهایی که جریان بیشتری دارند، می‌تواند تأثیر منفی بر توان آب زیرزمینی داشته باشند (دیپا و همکاران ۲۰۱۶). برای تهیه‌ی لایه‌ی فاصله از رودها، از تابع فاصله‌ی اقلیدسی در نرم‌افزار ArcGIS 10.5 استفاده شد. عامل‌های ساختمانی و زمین‌ساختی (تکتونیکی) نظیر گسل‌ها به عنوان نقطه‌های ضعف واحدهای زمین‌شناسی به شمار

از بخش‌های مهم هر پژوهش جمع‌آوری داده‌ها و ساخت یک پایگاه داده مکانی است (پورقاسمی و همکاران ۲۰۱۳). براساس بررسی‌های مشاهده‌ای پرشمار و اسناد شرکت آب منطقه‌ای استان خراسان شمالی اطلاعات مربوط به موقعیت ۳۵۹ چشمه جمع‌آوری شد. در هنگام اجرای مدل‌های داده‌کاوی باید نقطه‌های استفاده‌شده برای آموزش مدل از نقطه‌های اعتبارسنجی متفاوت باشند (لی و همکاران ۲۰۱۷). از چشمه‌های آموزشی در تحلیل‌ها استفاده می‌شود و اعتبارسنجی نقشه‌ی نهایی با استفاده از چشمه‌های اعتبارسنجی انجام می‌شود (قوش و کارانزا ۲۰۱۰؛ اوزدمیر ۲۰۱۱). بنابراین از دستورالعمل تقسیم‌بندی تصادفی (رحمتی و ملسه ۲۰۱۶؛ نمپاک و همکاران ۲۰۱۴) برای تقسیم نقطه‌های آموزشی و نقطه‌های اعتبارسنجی استفاده شد. برای آموزش مدل از ۷۰٪ چشمه‌ها (۲۵۱ چشمه) و برای اعتبارسنجی مدل از ۳۰٪ چشمه‌ها (۱۰۸ چشمه) استفاده شد.

طبقه‌های بلندی از مهم‌ترین عامل‌های محیطی مؤثر در توان آب زیرزمینی می‌باشد که نقش مهمی در تغییرات مکانی شرایط آب‌شناختی مانند جریان آب زیرزمینی، رطوبت خاک، اندازه‌ی نفوذپذیری و ضریب رواناب دارد (پورقاسمی و بهشتی‌راد ۲۰۱۵). این عامل در شیب آبی و جهت حرکت آب زیرزمینی و محل تشکیل آبخوان نقش اساسی دارد (نقیبی و همکاران ۲۰۱۶). عامل شیب یکی از سنجه‌های ضروری زمین‌ریخت‌سنجی است. این عامل در تعیین توان آب‌های زیرزمینی اهمیت زیادی دارد. نقش عامل شیب توانایی نگهداری آب به اندازه‌ی کافی روی

CI به‌دست می‌آید و سپس از ۹۰ درجه کم می‌شود. اندازه‌های CI مثبت نشان‌دهنده‌ی منطقه‌ی واگرا و اندازه‌های CI منفی نشان‌دهنده‌ی منطقه‌ی همگرا است. بنابراین اندازه‌ی CI کمتر نشان‌دهنده‌ی اندازه‌ی توان آب زیرزمینی بیشتر و تجمع آب‌های زیرزمینی است (لیو و همکاران ۲۰۱۵).

مدل ماشین بردار پشتیبان (SVM)

مدل ماشین بردار پشتیبان به‌دلیل اینکه بر پایه‌ی نظریه‌ی یادگیری و نظریه‌ی ابعادی آماری است، از این رو نوعی سامانه‌ی طبقه‌بندی نظارت‌شده به‌شمار می‌آید. از آنجایی که مدل SVM قابلیت استفاده مشترک برای دو عملیات طبقه‌بندی و وایزای را دارد، از این رو، در سال‌های اخیر به‌وسیله‌ی پژوهشگران بسیاری از رشته‌های مختلف استفاده‌شده است (کلانتری و همکاران ۲۰۱۷). این مدل مجموعه‌ای از تابع‌های طبقه‌بندی است که قابلیت ارزیابی خطا و تعمیم مناسب اطلاعات را دارد و با به‌کارگیری اطلاعات لایه‌های عامل‌های مستقل و تکرار فرآیند مدل‌سازی، پیچیدگی را کاهش می‌دهد. اگر داده‌های ورودی (متغیرهای مستقل و وابسته) به‌شکل خطی مجزا از هم باشند، می‌توان با کاربرد این مدل ماشین‌های خطی برای تولید یک سطح بهینه را پیشنهاد داد و سپس تفکیک داده‌ها با خطای کم و ایجاد حداکثر فاصله میان صفح و نزدیک‌ترین نقطه‌های آموزشی (بردارهای پشتیبان) را انجام داد (پورقاسمی و همکاران ۲۰۱۳). براساس نظریه‌ی یادگیری آماری، کرانه‌ی ارزش یادگیری ماشین برای داده‌های طبقه‌بندی نشده، به‌عنوان ارزش خطای تعمیم‌یافته در نظر گرفته می‌شود که در قالب تابعی از مجموعه ارزش خطاهای آموزشی نسبت به نمایش اندازه‌ی پیچیدگی طبقه‌بندی‌کننده‌ها اعمال می‌شود (یاعو و همکاران ۲۰۰۸). از این رو، به‌منظور به حداقل رساندن نرخ خطاهای تعمیم‌یافته باید نرخ خطای آموزش و پیچیدگی را کاهش داد که این کار با استفاده از صفحه جدایش که وظیفه افزایش حاشیه بین طبقه‌ها را بر عهده دارد انجام می‌شود. بردارهای پشتیبان، داده‌های نقطه‌ای نزدیک به این صفحه هستند که بخشی از اعضای کلیدی داده‌های آموزشی به‌شمار می‌آیند (پورقاسمی و همکاران ۲۰۱۳). افزایش پایداری مدل نسبت به اختلال، وابسته به بزرگ‌تر بودن صفحه‌ی جدایش است. هدف اصلی دستورالعمل‌های مدل SVM، حل مسئله‌های بهینه‌سازی درجه‌ی دوم است. در فرآیند مدل‌سازی، مدل SVM سلول‌های آموزشی را به‌شکل مجموعه‌ای مجزا و خطی انتخاب می‌کند (رابطه‌ی ۱).

می‌روند و راهی برای عبور آسان آب و محلی برای تجمع آب به‌شکل آبگیرهای زیرزمینی می‌باشند. گسل‌های منطقه‌ی بررسی‌شده از نقشه‌های زمین‌شناسی با مقیاس ۱:۱۰۰۰۰۰ که به‌وسیله‌ی اداره‌ی مطالعات زمین‌شناسی ایران (۱۹۹۷) تولید شده بود، شناسایی شدند. نوع سنگ و ویژگی‌های وابسته به آن نظیر بافت و درجه‌ی خلوص سنگ‌ها روی ویژگی‌های مختلف یک آبخوان، به‌ویژه تخلخل و نفوذپذیری آن و در نهایت تمرکز جریان آب زیرزمینی در داخل سنگ‌ها تأثیرگذار است. این دو ویژگی نیز بر وجود و حرکت آب‌های زیرزمینی تأثیرگذار است (اوزدمیر ۲۰۱۱). سفره‌های زیرزمینی مناسب معمولاً در نهشته‌های آبرفتی سازندهای کواترنر گزارش شده است (رحمتی و ملسه ۲۰۱۶). پژوهش‌ها نشان‌گر آن است که شکل و تراکم زهکشی هر منطقه به‌وسیله‌ی پستی‌بلندی، واحدهای زمین‌شناسی، سنگ‌شناسی، نوع خاک، نفوذ، ظرفیت جذب آب در خاک، تاج پوشش، آب و هوا و ساختارهای زمین‌ساختی و زمین‌شناسی منطقه مهار می‌شود. آبراهه‌ها نقش انتقال رواناب را دارند و با نفوذپذیری زمین رابطه‌ی معکوس دارند. سطح زهکشی زیاد نفوذ را کاهش می‌دهد و رواناب را افزایش می‌دهد. بنابراین، منطقه‌هایی با تراکم زهکشی کم برای گسترش آب زیرزمینی مناسب هستند (مناپ و همکاران ۲۰۱۴). شاخص موقعیت پستی‌بلندی (TPI) به‌شکل تفاوت میان پیکسل مرکزی و میانگین سلول‌های پیرامون آن تعریف شده است و موقعیت مربوط به هر پیکسل را نشان می‌دهد. شاخص زبری سطح یا ناهمواری زمین (TRI) معیاری است که به‌وسیله‌ی رایلی و همکاران (۱۹۹۹) برای بیان تفاوت بلندی میان یک سلول و میانگین ماتریس هشت سلولی سلول‌های پیرامون تعریف شده است. شاخص TRI دامنه‌های محدب و مقعر را نشان می‌دهد (کلانتری و همکاران ۲۰۱۷). موقعیت شیب نسبی (RSP) یکی دیگر از شاخص‌هایی است که از روی مدل رقومی ارتفاعی با استفاده از نرم‌افزار SAGA تهیه شده است. این شاخص، صفات پستی‌بلندی منطقه‌ی پژوهش (مانند قله‌ها، دره‌ها، سطح‌های مسطح، دامنه‌های میانی، پایین و بالا) را نشان می‌دهد (رحمتی و همکاران ۲۰۱۸). از شاخص همگرایی جریان (CI) برای تشخیص ناحیه‌ی همگرا از ناحیه‌ی واگرای جریان استفاده می‌شود (تومرت ۲۰۰۹)، بنابراین می‌توان برای مدل‌سازی توان آب زیرزمینی از آن استفاده کرد (لیو و همکاران ۲۰۱۵). شاخص CI می‌تواند براساس نقشه‌ی جهت شیب محاسبه شود. با محاسبه‌ی میانگین زاویه میان جهت سلول‌های مجاور به سمت سلول مرکزی

هستند. ارزیابی برازندگی به شروع حلقه و ارزیابی شایستگی زنبور پیشاهنگ مربوط است. زنبورهای پیشاهنگ با برازندگی زیاد به‌عنوان زنبورهای برگزیده انتخاب می‌شوند و مکان‌هایی که به‌وسیله آن‌ها بازدید شده‌اند به‌عنوان مجاورت جستجو انتخاب می‌شوند. دستورالعمل جستجوها در مجاورت مکان‌های انتخاب‌شده متمرکز می‌شود و به‌منظور پای‌کوبی در نزدیکی مکان‌های انتخاب‌شده زنبورهای بیشتری را به خدمت می‌گیرد. زنبورهای به خدمت گمارده‌شده مطابق با برازندگی مرتبط با مکان‌های ویژه پای‌کوبی قادر به انتخاب مستقیم هستند (رابطه ۶).

(۶)

$$X_{id}(t+1) = X_{id}(t) * (Rand - 0.5) * 2 + X_{id}(t)$$

X_i : به‌عنوان آمین X_i, i : برابر با یک تا n, d : بعدی در X_i, d : برابر با یک تا D, t : تکرار، $X_{id}(t+1)$: آمین بعد در X در تکرار d , $Rand$: تعداد واقعی با توزیع تصادفی و یکنواخت در محدوده صفر تا یک، n : تعداد زنبورهای پیشاهنگ است. زنبورهای نخبه به‌عنوان شکل‌دهنده‌ی اولین تمرکز در جستجوی راه حل بهینه‌ی محلی و تمرکز نهایی متفاوت هستند. اندازه‌های برازندگی پیوسته به‌منظور تعیین بهترین زنبورها و زنبورهای نخبه انتخابی استفاده شد. زنبورهای باقی‌مانده به‌شکل تصادفی در پیرامون فضای جستجوی پیشاهنگ به‌منظور راه‌حل‌های توان جدید به‌کارگرفته شدند. دستورالعمل زنبورعسل به جستجوی تصادفی وابسته است که به‌طور نسبی در جستجوی فعالیت‌های محلی است. همچنین، دستورالعمل BA قابلیت جستجوی رکوردهای گذشته به‌وسیله‌ی دستورالعمل بهینه‌سازی ازدحام ذرات (PSO) را نداشت.

مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکوشی ازدحام ذرات ($SVM-PSO$) دستورالعمل بهینه‌سازی برای ازدحام ذرات نوعی دستورالعمل بهینه‌سازی است که الهام گرفته از رفتار تغذیه‌ای پرندگان برای یافتن راه‌حل بهینه است. در دستورالعمل PSO ، جمعیتی از ذرات در یک فضای جستجو با هدف یافتن مطلوب‌ترین، با دنبال کردن ذرات بهینه‌ی فعلی و تغییر موقعیت آن‌ها شروع به حرکت می‌کنند. موقعیت یک ذره به یک راه حل ممکن به عملکرد بهینه‌سازی اشاره دارد. ارزیابی عملکرد با توجه به موقعیت ذرات، شایستگی آن راه حل را فراهم می‌کند. در هر تکرار، هر ذره با دنبال کردن بهترین راه حل به‌دست‌آمده از ذره‌ی کنونی (بهترین محل) و

$$(X_i(i = 1, 2, \dots, n)) \quad (۱)$$

سلول‌های آموزشی دو طبقه و به‌شکل رابطه‌ی ۲ است.

$$Y_i = \pm 1 \quad (۲)$$

هدف اصلی مدل SVM شناسایی یک صفحه‌ی جدایش n بعدی است که بتواند بیشترین شکاف و فاصله بین دو طبقه ایجاد کند و درنهایت منجر به کاهش متغیر $\|w\|$ شود. بیان ریاضی مطلب مزبور به‌شکل رابطه‌های ۳ و ۴ نشان‌دهنده است (یاعو و همکاران ۲۰۰۸).

$$1/2 \|w\|^2 \quad (۳)$$

$$W \cdot X_i + b_i \geq 1 \quad (۴)$$

$\|w\|$ قدر مطلق صفحه‌ی جدایش بهنجار، b : پایه (مبنایی) عددی است.

برای حل مسئله‌ی مزبور از یک رابطه‌ی لاگرانژی شامل ضریب افزایشنده با نام λ_i استفاده می‌شود که با کاهش ضریب‌های W و b و افزایش λ_i اندازه‌ی L لاگرانژی کاهش یابد. درنهایت شکل کلی معادله در رابطه‌ی ۵ نشان‌دهنده شده است.

(۵)

$$L = \frac{1}{2}(w)^2 - \sum_{i=1}^n \lambda_i(Y_i((W \cdot X_i) + b) - 1)$$

مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکوشی زنبورعسل ($SVM-BA$) دستورالعمل زنبورعسل (BA) یک دستورالعمل بهینه‌سازی است که با الهام از رفتار تغذیه‌ای طبیعی زنبورهای عسل اجرا می‌شود. تنظیم سنج‌های دستورالعمل زنبورعسل به شرح زیر انجام شد (فام و همکاران ۲۰۰۶):

- ۱- تعداد زنبورهای پیشاهنگ (n)
- ۲- تعداد مکان‌های برگزیده از n پایگاه بازدیدشده (e)
- ۳- تعداد بهترین پایگاه‌ها از n پایگاه بازدیدشده (b)
- ۴- تعداد زنبورهای به‌کار گرفته‌شده برای مکان‌های برگزیده الکترونیکی ($n1$)
- ۵- تعداد زنبورهای به‌کار گرفته‌شده برای بهترین مکان‌های ($n2$) b
- ۶- تعداد زنبورهای به‌کار گرفته‌شده برای دیگر مکان‌های بازدیدشده (r)
- ۷- معیار جستجو و توقف پای‌کوبی زنبورهای همسایه (ngh).

دستورالعمل زنبورعسل با n تعداد زنبور پیشاهنگ شروع می‌شود که در فضای جستجو به‌شکل تصادفی

مشارکت متغیرهای ورودی در توان یابی آب زیرزمینی مشخص شد. در این آزمون در مرحله اول مدل سازی با کل متغیرها انجام شد. سپس با استفاده از روش حذفی، در هر مرحله یکی از متغیرهای مستقل حذف شد و مدل سازی بدون آن متغیر انجام شد؛ سپس اندازه افت دقت نقشه ی نهایی در ازای حذف آن متغیر محاسبه شد. متغیری که با حذف آن بیشترین افت دقت رخ داد در پیش بینی و مدل سازی سهم زیادی داشت (رحمتی و ملسه ۲۰۱۶).

ارزیابی نتایج مدل سازی

ارزیابی دقت مدل ها در دو مرحله آموزش (یادگیری) و اعتبارسنجی (آزمایش) براساس روش منحنی مشخصه عامل گیرنده (ROC) انجام شد. منحنی ROC یکی از مفیدترین و کارآمدترین و جامع ترین روش ها در شناسایی احتمال و پیش بینی سامانه ها است که اندازه ی دقت مدل را به طور کمی برآورد می کند و به شکل گسترده به منظور آزمون مدل حساسیت پذیری خطرهای طبیعی استفاده شده است (پورقاسمی و همکاران ۲۰۱۳). منحنی ROC یک نمایش گرافیکی از موازنه بین ارزش خطای منفی و مثبت برای هر اندازه ی احتمالی از برش ها^۱ است. محور X درصد اختصاصیت^۲ (احتمال تشخیص صحیح نقطه های شبه نبودن رخداد) و محور Y حساسیت^۳ (احتمال تشخیص صحیح نقطه های رخداد) را نشان می دهد. سطح زیر نمودار (AUC) به دست آمده به عنوان معیاری از قدرت تفکیک مدل در تشخیص نقطه های وجود رخداد از نبودن رخداد است. چنانچه مدلی نتواند حضور چشمه را بهتر از دیدگاه احتمالی (تصادفی) برآورد کند اندازه ی AUC آن ۰/۵ است و زمانی که منحنی ROC، سطح زیر منحنی برابر با یک داشته باشد بیان گر بهترین دقت از نقشه ی حساسیت پذیری تهیه شده، است. همبستگی کیفی - کمی سطح زیر منحنی و ارزیابی برآورد به شکل زیر است (دوکوتا و همکاران ۲۰۱۳):

(۰/۹ - ۰/۹، عالی؛ ۰/۸ - ۰/۹، خیلی خوب؛ ۰/۷ - ۰/۸، خوب؛ ۰/۶ - ۰/۷، متوسط؛ ۰/۵ - ۰/۶، ضعیف).

نتایج

عامل های زمین - محیطی

براساس نقشه ی بلندی کمترین و بیشترین بلندی منطقه به ترتیب ۸۷۷ و ۲۹۶۷ متر بود. بخش های بلند در قسمت جنوبی، جنوب شرقی و جنوب غربی بودند. بخش های با بلندی کم در قسمت های میانی،

بهترین جمعیت (بهترین جهان) به روزرسانی می شود. زمانی که یک ذره بخشی از جمعیت همسایگان مکان شناسی (توپولوژیک) را در برمی گیرد، بهترین اندازه به عنوان بهترین محل در نظر گرفته می شود. ذرات مایل به حرکت به سوی منطقه های خوبی که در فضای جستجو و در پاسخ به گستردگی اطلاعات از راه ازدحام هستند، می باشند. حرکت های یک ذره به سوی موقعیت جدید از راه سرعت به روز شده در هر زمان از مرحله t با استفاده از رابطه ی ۷ محاسبه شد. سپس با استفاده از رابطه ی ۳ سرعت جدید به عنوان موقعیت و سرعت قبلی محاسبه شد.

$$X_{id}(t+1) = X_{id}(t) + v_{id}(t+1) \quad (7)$$

x_i : آامین X ، i : از یک تا n ، V_i : آامین V ، d : بعدی در x_i یا V ، d : از یک تا D ، t : تکرار، $X_{id}(t)$: آامین بعد در آامین x در t تکرار، $V_{id}(t+1)$: آامین بعد در آامین V در $t+1$ تکرار، $X_{id}(t+1)$: آامین بعد در آامین x در $t+1$ تکرار، n : تعداد ذرات است.

(۸)

$$v_{id}(t+1) = W * v_{id}(t) + C_1 * Rand * [P_{id}(t) - X_{id}(t)] + C_2 * Rand * [G_d(t) - x_{id}(t)]$$

$V_{id}(t)$: آامین بعد در آامین V در t تکرار، w : وزن تکرار و مهارکننده مغناطیس سرعت گذشته $V_{id}(t)$ در محاسبه های سرعت جدید، $P_{id}(t)$: آامین بعد در آامین برترین ذره ی محلی در t تکرار، $G_d(t)$: آامین بعد جهانی بهترین ذره در t تکرار، C_1 و C_2 : تعیین کننده ی معنی داری $P_{id}(t)$ و $G_d(t)$: تعداد واقعی توزیع شده به شکل تصادفی و یکنواخت در محدوده ی صفر تا یک است. V_{id} در هر مرحله ی زمانی از دستورالعمل به وسیله ی سنجه های V_{min} و V_{max} محدود می شود. ازدحام در دستورالعمل PSO، در فضای جستجو با اختصاص هر ذره به یک موقعیت یکنواخت که به طور تصادفی انتخاب شده آغاز می شود. سرعت ها به شکل تصادفی در محدوده ی V_{min} و V_{max} آغاز می شود. سرعت ذرات در هر بعد به سرعت حداکثر V_{max} بند می شود. چنانچه سرعت آن بعد فراتر از V_{max} یا V_{min} باشد (سنجه های مشخص شده به وسیله ی کاربر)، سرعت آن بعد به V_{max} یا V_{min} محدود می شود.

تعیین اهمیت نسبی و اندازه ی مشارکت متغیرهای

زمین - محیطی پیش بینی کننده


براساس تحلیل حساسیت حذفی، اندازه ی اهمیت و

1 - Trade off
2 - Specificity
3 - Sensitivity

۳۲۷۷ متر متغیر بود. براساس موقعیت مکانی گسل‌ها، بخش‌های میانی، شرقی و غربی بیشترین تراکم گسل را داشتند. تنوع خصوصیات واحدهای سنگ‌شناسی و زمان تشکیل آنها باعث شده است که فرایندهای آب‌شناختی و آب‌زمین‌شناختی (هیدروژئولوژیکی) گسترده و عمیقی در این آبخیز رخ دهد. بیشترین سطح آبخیز از واحدهای سنگ‌شناسی زمان ژوراسیک کرتاسه با مساحت $۳۵/۵۷\%$ و واحدهای سنگ‌شناسی زمان کرتاسه زیرین با مساحت $۳۴/۲\%$ است. اندازه‌ی شاخص موقعیت پستی‌بلندی از ۱۳۶- تا ۱۳۰ متغیر بود. بیشترین اندازه‌های شاخص موقعیت پستی‌بلندی در بخش‌های شمال‌شرقی، غربی، جنوبی و شرقی مشاهده شد. در حالی که این شاخص در قسمت‌های میانی آبخیز متوسط و خیلی کم بود. اندازه‌ی شاخص ناهم‌واری زمین در این آبخیز از صفر تا $۱۷۴/۷$ متغیر بود، به‌گونه‌ای که اندازه‌های هموار در قسمت‌های شمال‌شرقی و لکه‌هایی در شرق و جنوب آبخیز بود. قسمت‌های ناهم‌وار نیز در بخش‌های جنوبی، جنوب‌غربی، شرق و شمال بودند. اندازه‌ی شاخص موقعیت شیب نسبی در منطقه‌ی مطالعه‌شده از صفر تا یک متغیر بود. با کاربرد این شاخص، هر دامنه از لحاظ موقعیت شیب نسبی به طبقه‌های مختلف تقسیم شد. شاخص موقعیت شیب نسبی در بخش‌های زیاد بود. این شاخص در بخش‌های پای دامنه و خط‌القصه‌ها کمترین اندازه را داشت.

شاخص همگرایی جریان نشان‌دهنده‌ی وضعیت همگرایی جریان‌های سطحی و زیرسطحی است که اندازه‌ی آن در آبخیز مطالعه‌شده از $۹۹/۶۲۵$ - تا $۹۹/۶۲۵$ متغیر بود. این نقشه نشان داد که اندازه‌ی شاخص همگرایی جریان در آبراهه‌ها زیاد است. افزون بر این همگرایی جریان در بخش‌هایی از شمال‌غرب، شرق و جنوب منطقه بسیار ضعیف بود (شکل ۳).

شمالی و شمال‌شرقی مشاهده شد. براساس نقشه‌ی شیب زمین، کمترین و بیشترین اندازه‌ی شیب به‌ترتیب صفر و ۷۳۵% محاسبه شد. بخش‌های کم شیب غالباً در قسمت‌های میانی آبخیز بودند. بخش‌های دیگری از آبخیز از جمله شرق، جنوب، شمال و غرب زمین‌های هموار داشتند. لکه‌های زیادی از منطقه مخصوصاً در قسمت‌های جنوبی، غربی و شرقی شیب زیاد داشتند. تنوع جهت شیب در این آبخیز زیاد بود و طبقه‌های جهت شیب نیز توزیع فراوانی نسبتاً مشابهی داشت. فراوانی طبقه‌ی بدون جهت کمتر از یک درصد بود. اندازه‌ی شاخص رطوبت پستی‌بلندی آبخیز مطالعه‌شده از $۰/۴۲$ تا $۲۱/۲$ متغیر بود. بخش‌های شمال‌شرقی و میانی بیشترین اندازه‌ی شاخص رطوبت پستی‌بلندی را داشتند و منطقه‌های بلند در قسمت‌های شرقی، غربی و جنوبی کمترین اندازه‌ی شاخص رطوبت پستی‌بلندی را کسب کردند. از آنجایی که آبراهه‌ها شریان‌های یک آبخیز هستند، فاصله از آنها یک معیار مهم در شرایط بوم‌شناختی و آب‌شناختی به‌شمار می‌آید. اندازه‌ی فاصله از آبراهه در این آبخیز از صفر تا ۲۳۲۴ متر متغیر بود. اندازه‌ی تراکم زهکشی بخش‌های مختلف آبخیز از صفر تا $۲/۸۱$ کیلومتر بر کیلومتر مربع متغیر بود. بیشترین اندازه‌ی تراکم زهکشی در بخش‌های شمال‌غربی، میانی، جنوب‌غربی و لکه‌هایی از شرق منطقه بود. قسمت‌های مرکزی و حاشیه‌ای آبخیز مطالعه‌شده اندازه‌ی تراکم زهکشی کم تا متوسط داشتند. تمرکز جریان آب سطحی آبخیز عموماً در منطقه‌هایی با تراکم زهکشی زیاد شکل گرفته است. این آبخیز گسل‌های زیادی داشت که زمین‌شناسی ساختمانی آن را پیچیده بود و به نوبه‌ی خود بر وضعیت نفوذ جریان‌های سطحی و همچنین ظهور چشمه و خروجی جریان زیرسطحی تأثیر زیادی داشت. اندازه‌ی فاصله از گسل در این آبخیز از صفر تا




شکل ۳- نقشه‌ی عامل‌های استفاده‌شده در پژوهش.
Figure 3- Map of the factors in the research.

و جنوب‌شرق بودند. افزون بر آن، بخش‌های کوچکی از منطقه در شمال‌غربی و شرق توان آب زیرزمینی زیادی داشتند. این در حالی است که بخش‌هایی که توان آب زیرزمینی کمی داشتند عموماً در شمال و میانه‌ی آب‌خیز بودند. اندازه‌ی توان آب زیرزمینی براساس مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی ازدحام ذرات از $0/001$ تا یک متغیر بود (شکل ۴). براساس نتایج این مدل ترکیبی، اندازه‌ی توان آب زیرزمینی در سراسر منطقه متغیر بود و در بخش‌های مختلف منطقه امکان دسترسی به منابع آب زیرزمینی وجود داشت.

نقشه‌ی توان آب زیرزمینی

اندازه‌ی توان آب زیرزمینی براساس مدل ماشین بردار پشتیبان از $0/02$ تا یک متغیر بود (شکل ۴). براساس خروجی مدل ماشین بردار پشتیبان، منطقه‌های با توان آب زیرزمینی زیاد در اکثر نقطه‌های منطقه‌ی مطالعه‌شده پراکنده بود و امکان دسترسی و بهره‌برداری آب زیرزمینی در بخش‌های مختلف وجود داشت. اندازه‌ی توان آب زیرزمینی براساس مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی زنبورعسل از $0/001$ تا یک متغیر بود (شکل ۴). براساس نتایج این مدل ترکیبی، منطقه‌هایی که توان آب زیرزمینی زیادی داشتند غالباً در قسمت‌های جنوب‌غرب، جنوب




شکل ۴- نقشه‌ی توان آب زیرزمینی براساس مدل‌های استفاده‌شده (SVM, SVM-PSO, SVM-BA) در پژوهش.

Figure 4- Groundwater potential map based on the models used (SVM, SVM-PSO, SVM-BA) in the research.

زیادی از منطقه قابل مشاهده است. توزیع مکانی به‌دست‌آمده (جدول ۱) نشان دهنده وضعیت پیچیده جریان و ذخیره آب زیرزمینی در سازندهای منطقه است که بر اساس نتایج به‌دست‌آمده می‌توان شناخت کامل‌تری از توان آب زیرزمینی برای مصارف و برنامه‌های مختلف پیدا نمود.

نقشه کلاس توان آب زیرزمینی حاصل از مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی ازدحام ذرات به‌عنوان مدل برتر در شکل ۵ نشان داده شده است. بر اساس نتایج این مدل، کلاس توان آب زیرزمینی خیلی زیاد در سراسر آب‌خیز پراکنده شده و درعین حال کلاس توان آب زیرزمینی خیلی پایین نیز در بخش‌های



شکل ۵- طبقه بندی توان آب زیرزمینی با استفاده از مدل SVM_PSO.

Figure 5- Classification of Groundwater potential using SVM_PSO model.

جدول ۱- مساحت طبقه های توان آب زیرزمینی براساس مدل برتر.

Table 1- Area of groundwater potential classes based on the best model.

model	Groundwater potential class	Area (ha)	Area (%)
Support vector machine and optimization algorithm of particle swarm optimization (SVM-PSO)	Very low	50984.73	39.85
	Low	10427	8.15
	Moderate	7160.14	5.59
	High	9909.18	7.75
	Very High	49471.29	38.66

می توان گفت که مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه سازی فراکاوشی ازدحام ذرات (SVM-PSO) در پیش بینی توان آب زیرزمینی بیشترین دقت و عملکرد (۰/۹۴۵٪) را داشت. شایان ذکر است از آنجایی که معیار مساحت زیرمنحنی راک برای هر سه مدل بیش از ۰/۹۰٪ بود، هر سه مدل در عملکرد در طبقه های مطلوب بودند. بر پایه نتایج این پژوهش دستورالعمل های بهینه سازی فراکاوشی زنبور عسل و ازدحام ذرات موجب افزایش کارایی و بهبود عملکرد مدل در تحلیل داده ها و پیش بینی شد.

ارزیابی عملکرد مدل ها

اعتبارسنجی و ارزیابی دقت پیش بینی مدل براساس داده های گروه اعتبارسنجی (۳۰٪ کل چشمه ها) انجام شد. معیار ارزیابی مساحت زیرمنحنی عامل گیرنده (AUC) که به عنوان معتبرترین مؤلفه تعیین کارایی مدل شناخته شده است، نشان داد که دقت پیش بینی مدل ماشین بردار پشتیبان (SVM) ۰/۹۱۸، مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه سازی فراکاوشی زنبور عسل (SVM-BA) ۰/۹۳۲ و مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه سازی فراکاوشی ازدحام ذرات (SVM-PSO) ۰/۹۴۵ است (جدول ۲). بنابراین،

جدول ۲- دقت پیش‌بینی مدل‌ها براساس معیارهای ارزیابی عملکرد در مرحله اعتبارسنجی.


Table 2- Prediction accuracy of models based on performance evaluation criteria in the test.

Model	Area under the curve (AUC)
Support vector machine	0.918
Support vector machine and the bee metaheuristic optimization algorithm	0.932
Support vector machine and optimization algorithm of particle swarm optimization (SVM-PSO)	0.945

اندازه‌ی اهمیت عامل‌های زمین-محیطی

اندازه‌ی اهمیت عامل‌های محیطی براساس نتایج مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی ازدحام ذرات (مدل برتر) در شکل ۶ نشان داده شده است. براساس پردازش اطلاعات مکانی، این مدل نشان داد که از میان عامل‌های محیطی مختلف، موقعیت شیب نسبی (۱۴/۵٪)، فاصله از گسل (۱۳/۴٪) و سنگ‌شناسی (۱۲/۳٪) بیشترین اهمیت را داشتند. عامل‌های تراکم زهکشی (۱/۲٪)، فاصله از جریان (۹/۱٪)، شاخص رطوبت پستی‌بلندی (۸/۶٪)، شاخص

موقعیت پستی‌بلندی (۶/۷٪)، بلندی زمین (۶/۱٪) و جهت شیب (۵/۴٪) اهمیت متوسطی داشتند. براساس نتایج این پژوهش، شاخص همگرایی (۵/۱٪)، شیب زمین (۴/۵٪) و شاخص ناهمواری پستی‌بلندی (۴/۱٪) کمترین وزن و اهمیت را کسب کردند. ذکر این نکته ضروری است که توان آب زیرزمینی بسیار پیچیده بود و پیش‌بینی آن تنها با در نظر گرفتن طیف گسترده‌ای از عامل‌های محیطی امکان‌پذیر بود. بنابراین، اگرچه اهمیت برخی از عامل‌ها کم‌تر به‌دست آمد، اما به‌کارگیری آن‌ها می‌تواند اطلاعات مکانی ارزشمندی را در اختیار مدل قرار دهد.



شکل ۶- اندازه‌ی اهمیت عامل‌های محیطی براساس مدل SVM-PSO.

Figure 6- The importance of environmental factors based on the SVM-PSO model.

بحث و نتیجه‌گیری

مدل‌سازی توان آب زیرزمینی به‌عنوان یکی از موضوع‌های مهم در پژوهش‌های منابع آب است. از آنجایی که در پژوهش‌های آب زیرزمینی داده‌های زیادی از متغیرهای پرشمار استفاده می‌شود، غالباً برای انجام بررسی‌های دقیق میدانی به نیروی انسانی و صرف هزینه بسیار زیاد نیاز است. در سال‌های اخیر، بیشتر به مدل‌سازی مبتنی بر رویکرد هوش مصنوعی توجه شده است. در این پژوهش، از مدل ماشین بردار پشتیبان برای پیش‌بینی

مکانی توان آب زیرزمینی در سازندهای سخت استفاده شد. از سویی دیگر، از دستورالعمل‌های بهینه‌سازی برای بهبود عملکرد مدل استفاده شد. براساس نتایج این پژوهش، عملکرد مدل ماشین بردار پشتیبان زیاد بود. دو دستورالعمل بهینه‌سازی فراکاوشی زنبورعسل و فراکاوشی ازدحام ذرات موجب تقویت قدرت پیش‌بینی مدل شدند. در پژوهشی رحمتی و همکاران (۲۰۱۸) برای برآورد وضعیت توان آب زیرزمینی در آبخیز بجنورد از مدل هوش مصنوعی وایازی درختی استفاده

می‌توان شرایط پستی‌بلندی سطح زمین، سطح آب زیرزمینی و احتمال انقطاع آن‌ها را برای ایجاد چشمه توصیف کرد، زیرا چشمه‌ها عموماً از تلاقی پستی‌بلندی سطح زمین و تراز آب زیرزمینی پدیدار می‌شوند. این یافته‌ی مهم با نتایج پژوهش رحمتی و همکاران (۲۰۱۸) که در همین آبخیز توان آب زیرزمینی با استفاده از مدل یادگیری ماشینی درخت وایازی لجستیک (LMT) را بررسی کردند، مطابقت دارد. در این پژوهش عامل فاصله از گسل نیز به‌عنوان دومین متغیر مهم تعیین شد. نتایج پژوهش نشان داد که گسل‌های منطقه‌ی مطالعه‌شده نقش مهمی در تغذیه‌ی بخش‌های زیرسطحی، ذخیره و جریان آب زیرزمینی داشتند. افزون بر نتایج مدل‌سازی، تحلیل‌های فضایی ارتباط بین لایه‌ی فاصله از گسل‌ها و توان آب زیرزمینی تأیید کرد که بخش‌هایی که در مجاورت گسل‌ها هستند، توان آب زیرزمینی بیشتری داشتند. در این پژوهش عامل سنگ‌شناسی به‌عنوان سومین متغیر مهم در شناسایی وضعیت توان آب زیرزمینی شناسایی شد. از آنجایی که خصوصیات واحدهای سنگ‌شناسی از مؤلفه‌های مهم در نفوذ، جریان و ذخیره آب زیرزمینی هستند، وجود این عامل در میان سه متغیر محیطی مهم کاملاً منطقی است. در این آبخیز تنوع واحدهای سنگ‌شناسی موجب پیچیدگی وضعیت توان آب زیرزمینی شد. ارتباط میان توان آب زیرزمینی و خصوصیات محیطی هر آبخیز اختصاصی است و باید براساس مدل‌سازی انجام شده در هر آبخیز وضعیت توان آب زیرزمینی آن آبخیز را بررسی کرد.

منابع آب زیرزمینی از اصلی‌ترین منابع آب قابل تکیه در منطقه‌های خشک و نیمه‌خشک است. مدل‌سازی توان آب زیرزمینی در سازندهای سخت مقرون به‌صرفه است و براساس اطلاعات آبدهی چشمه‌ها و لایه‌های رقیومی مربوط به عامل‌های محیطی می‌توان اطلاعات مفیدی برای مدیریت منابع آب فراهم ساخت. در سال‌های اخیر به استفاده از دستورالعمل‌های هوش مصنوعی در پیش‌بینی توان آب زیرزمینی بسیار توجه شده است (فنگ و همکاران ۲۰۲۱). بدون بهره‌گیری از رویکرد مدل‌سازی، کارشناسان مجبور هستند برای تعیین توان آب زیرزمینی از روش حفاری و گمانه‌زنی استفاده کنند که بسیار هزینه‌بر و زمان‌بر است. براساس نقشه‌ی توان آب زیرزمینی به‌دست‌آمده از مدل‌سازی، برنامه‌ریزی آمایش سرزمین دقیق‌تر خواهد شد و موقعیت قرارگیری صنعت، کشاورزی و CI انسانی در یک آبخیز با کارایی بیشتری از لحاظ تأمین آب امکان‌پذیر خواهد بود. در این پژوهش، با پیشنهاد نقشه‌ی توان آب زیرزمینی، امکان برنامه‌ریزی و تدقیق آمایش سرزمین برای آبخیز بجنورد فراهم شد.

کردند. این پژوهشگران براساس معیار ارزیابی مساحت زیر منحنی راک، دقت پیش‌بینی مدل استفاده شده را $90/4\%$ گزارش کردند. نتایج این پژوهش نشان داد که دقت مدل انفرادی ماشین بردار پشتیبان و دو مدل ترکیبی ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی زنبورعسل (SVM-BA) و ماشین بردار پشتیبان و دستورالعمل بهینه‌سازی فراکاوشی ازدحام ذرات (SVM-PSO) در مقایسه با مدل استفاده‌شده در پژوهش رحمتی و همکاران (۲۰۱۸) بیشتر بود. در پژوهش دیگری که چوبین و ملکیان (۲۰۱۷) در آبخیز بجنورد انجام دادند، دقت مدل طبقه‌بندی و وایازی درختی در پیش‌بینی توان آب زیرزمینی 88% تعیین شد. در پژوهش بین‌المللی که به‌وسیله‌ی ناهو و همکاران (۲۰۲۰) در آبخیز بجنورد انجام شد از سه مدل آماری عامل قطعیت، وایازی پشتیبانی و مدل ترکیبی عامل قطعیت-وایازی پشتیبانی (عامل قطعیت-وایازی پشتیبانی) برای تهیه‌ی نقشه‌ی توان آب زیرزمینی استفاده شد. نتایج این پژوهشگران نشان داد که دقت مدل‌های عامل قطعیت، وایازی پشتیبانی و مدل ترکیبی عامل قطعیت-وایازی پشتیبانی به‌ترتیب $78/4\%$ ، $84/6\%$ و $78/4\%$ بود. از این رو، می‌توان گفت که قابلیت پیش‌بینی کنندگی مدل ماشین بردار پشتیبان و همچنین مدل‌های ترکیبی آن براساس دستورالعمل‌های فراکاوشی ازدحام ذرات و زنبورعسل از مدل‌های آماری مزبور به مراتب بیشتر است.

در رویکرد مدل‌های یادگیری ماشینی، نقش هر عامل محیطی براساس تحلیل‌های مدل‌سازی تعیین‌شده است و کارشناس در تعیین اندازه‌ی اهمیت آن نقشی ندارد. به‌عبارت دیگر، در یک مدل، ارتباط میان عامل‌های محیطی (متغیرهای مستقل) و چشمه‌های آب زیرزمینی (متغیر وابسته) براساس داده‌های ورودی مدل تعیین می‌شود و فرایند شکل‌گیری و رخداد یک پدیده مانند آب زیرزمینی بررسی می‌شود. در این پژوهش، چگونگی ارتباط بین عامل‌های محیطی و چشمه‌های آب زیرزمینی براساس مدل‌های یادگیری ماشینی و فنون هوش مصنوعی بررسی شد. نتایج به‌دست‌آمده بدون دخالت نظر کارشناسی بود. براساس نتایج این پژوهش، می‌توان با کاربرد مدل‌های یادگیری ماشینی ارتباط میان عامل‌های محیطی و آبدهی چشمه‌ها را شناسایی کرد. همچنین، می‌توان نقش داده‌های به‌کار برده‌شده را نیز تعیین کرد. براساس نتایج به‌دست‌آمده، عامل موقعیت شیب نسبی به‌عنوان مهم‌ترین متغیر در وضعیت توان آب زیرزمینی شناسایی شد. این عامل نشان می‌دهد که هر پیکسل در چه موقعیتی از شیب یک دامنه (یال، قسمت فوقانی دامنه، وسط دامنه، قسمت تحتانی دامنه، یا انتهای دامنه) است. بنابراین، با استفاده از این متغیر

فهرست منابع

- Choubin B, Malekian A. 2017. Combined gamma and M-test based ANN and ARIMA models for groundwater fluctuation forecasting in semiarid regions. *Environmental Earth Sciences*, 76:538. <https://doi.org/10.1007/s12665-017-6870-8>.
- Corsini A, Cervi F, Ronchetti F. 2009. Weight of evidence and artificial neural networks for potential groundwater spring mapping: An application to the Mt. Modino area (Northern Apennines, Italy). *Geomorphology*. 111(1-2): 79-87.
- Dai FC, Lee CF, Li J, Xu ZW. 2001. Assessment of landslide susceptibility on the natural terrain of Lantau Island, Hong Kong. *Environment Geology*. 40(3): 381-391
- Davoodi Moghaddam D, Rezaei M, Pourghasemi HR, Pourtaghie ZS, Pradhan B. 2013. Groundwater spring potential mapping using bivariate statistical model and GIS in the Taleghan Watershed, Iran. *Arabian Journal Geoscience*. 8: 913-929. <https://doi.org/10.1007/s12517-013-1161-5>.
- De Santa Olalla FM, Dominguez A, Ortega F, Artigao A, Fabeiro C. 2007. Bayesian networks in planning a large aquifer in Eastern Mancha, Spain. *Environmental Modelling and Software*. 22(8):1089-1100.
- Deepa S, Venkateswaran S, Ayyandurai R. 2016. Groundwater recharges potential zones mapping in upper Manimuktha Sub basin Vellar River Tamil Nadu India using GIS and remote sensing techniques. *Modeling Earth Systems and Environment*, 2: 137. <https://doi.org/10.1007/s40808-016-0192-9>.
- Devkota KC, Regmi AD, Pourghasemi HR, Yoshida K, Pradhan B, Ryu IC. 2013. Landslide susceptibility mapping using certainty factor, index of entropy and logistic regression models in GIS and their comparison at Mugling-Narayanghat road section in Nepal Himalaya. *Natural Hazards*. 65(1):135-165.
- Geroy IJ, Gribb MM, Marshall HP, Chandler DG, Benner SG, McNamara JP. 2011. Aspect influences on soil water retention and storage. *Hydrology Processes*. 25: 3836-3842.
- Ghorbani Nejad S, Falah F, Daneshfar M, Haghizadeh A, Rahmati O. 2017. Delineation of groundwater potential zones using remote sensing and GIS-based data-driven models. *Geocarto International*. 32(2):167-187
- Ghosh, S, Carranza EJM. 2010. Spatial analysis of mutual fault/fracture and slope controls on rock sliding in Darjeeling Himalaya, India. *Geomorphology*. 122: 1- 24.
- Javhar A, Chen X, Jovid A, Yunus M, Jamshed A, Eldiir D, Zulfyior B. 2018. Evaluation of remote sensing techniques for lithological mapping in the southeastern pamir using landsat 8 OLI Data. *International Journal of Geoinformatics*. 14(1): 1-10.
- Kalantar B, Pradhan B, Naghibi SA, Motevalli A, Mansor S. 2017. Assessment of the effects of training data selection on the landslide susceptibility mapping: A comparison between support vector machine (SVM), logistic regression (LR) and artificial neural networks (ANN). *Geomatics, Natural Hazards and Risk*. 9:(1):49-69. DOI:- 10.1080/19475705.2017.1407368.
- Lee S, Kim JC, Jung HS, Lee MJ, Lee S. 2017. Spatial prediction of flood susceptibility using random-forest and boosted-tree models in Seoul metropolitan city, Korea. *Geomatics, Natural Hazards and Risk*. pp. 1-19.
- Liu T, Yan H, Zhai L. 2015. Extract relevant features from DEM for groundwater potential mapping. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 40(7): 113-119.
- Manap MA, Nampak H, Pradhan B, Lee S, Sulaiman WNA, Ramli MF. 2014. Application

- of probabilistic-based frequency ratio model in groundwater potential mapping using remote sensing data and GIS. *Arabian Journal Geoscience*. 7(2):711–724.
- Mosavi A, Hosseini FS, Choubin B, Goodarzi M, Dineva AA, Sardooi ER. 2021. Ensemble boosting and bagging based machine learning models for groundwater potential prediction. *Water Resources Management*. 35(1):23–37.
- Naghibi SA, Moghaddam DD, Kalantar B, Pradhan B, Kisi O. 2017. A comparative assessment of GIS-based data mining models and a novel ensemble model in groundwater well potential mapping. *Journal of Hydrology*. 548:471–483
- Naghibi SA, Pourghasemi HR, Abbaspour K. 2018. A comparison between ten advanced and soft computing models for groundwater qanat potential assessment in Iran using R and GIS. *Theor Appl Climatol*. 131(3–4):967–984
- Naghibi SA, Pourghasemi HR, Dixon B. 2016. GIS-based groundwater potential mapping using boosted regression tree, classification and regression tree, and random forest machine learning models in Iran. *Environmental Monitoring and Assessment*. 188(1): 44. <https://doi.org/10.1007/s10661-015-5049-6>.
- Nampak H, Pradhan B, Manap MA. 2014. Application of GIS based data driven evidential belief function model to predict groundwater potential zonation. *Journal of Hydrology*. 513: 283–300.
- Nhu V, Rahmati O, Falah F, Shojaei S, Ansari N, Shahabi H, Shirzadi A, Gorski K, Nguyen H, Ahmad B. 2020. Mapping of groundwater spring potential in karst aquifer system using novel ensemble bivariate and multivariate models. *Water*, 12(4):985; <https://doi.org/10.3390/w12040985>.
- Ozdemir A. 2011. Using a binary logistic regression method and GIS for evaluating and mapping the groundwater spring potential in the Sultan Mountains (Aksehir, Turkey). *Journal of Hydrology*. 405(1–2):123–136.
- Pham BT, Jaafari A, Prakash I, Singh SK, Quoc NK, Bui DT. 2019. Hybrid computational intelligence models for groundwater potential mapping. *Catena*. 182 p. <https://doi.org/10.1016/j.catena.2019.104101>.
- Pham DT, Ghanbarzadeh A, Koç E, Otri S, Rahim S, Zaidi M. 2006. The bees algorithm—a novel tool for complex optimization problems. In *Intelligent production machines and systems. Intelligent Production Machines and Systems*. 2nd I*PROMS Virtual International Conference 3–14 July 2006. pp. 454–459.
- Phong T, Pham B, Trinh P, Ly H, Vu Q, Ho L, Phong L, Le H, Avand M, Prakash I. 2021. Groundwater potential mapping using GIS-based hybrid artificial intelligence methods. *Groundwater*. 59(5):745–760.
- Pourghasemi HR, Moradi HR, Fatemi Aghda SM, Gokceoglu C, Pradhan B. 2013. GIS-based landslide susceptibility mapping with probabilistic likelihood ratio and spatial multi-criteria evaluation models (North of Tehran, Iran). *Arabian Journal Geoscience*. 7: 1857–1878. doi:10.1007/s12517-012-0825-x.
- Pourghasemi HR, Beheshtirad M. 2015. Assessment of a data-driven evidential belief function model and GIS for groundwater potential mapping in the Koohrang Watershed, Iran. *Geocarto International*. 30(6):662–685.
- Rahmati O, Melesse AM. 2016. Application of Dempster–Shafer theory, spatial analysis and remote sensing for groundwater potentiality and nitrate pollution analysis in the semi-arid region of Khuzeestan, Iran. *Science of Total Environment*. 568: 1110–1123.
- Rahmati O, Naghibi SA, Shahabi H, Bui DT, Pradhan B, Azareh A, Rafiei-Sardooi E, Samani AN, Melesse AM. 2018. Groundwater spring potential modelling: Comparing the capability and robustness of three different

- modeling approaches. *Journal of Hydrology*. 565:248-261.
- Sachdeva S, Kumar B. 2021. Comparison of gradient boosted decision trees and random forest for groundwater potential mapping in Dholpur (Rajasthan), India. *Stochastic Environmental Research and Risk Assessment*. 35(2):287-306.
- Shenga ZD, Baroková D, Šoltész A. 2018. Numerical modeling of groundwater to assess the impact of proposed rail way construction on groundwater regime. *Pollack Periodica*. 13(3): 187–196.
- Tait NG, Davison RM, Leharne SA, Lerner DN. 2008. Borehole Optimization System (BOS): A case study assessing options for abstraction of urban groundwater in Nottingham, UK. *Journal Environmental Modelling and Software*. 23(5):611–621.
- Thapa R, Gupta S, Guin S, Kaur H. 2017. Assessment of groundwater potential zones using multi-influencing factor (MIF) and GIS: a case study from Birbhum district, West Bengal. *Applied Water Science*. 7(7):4117-4131.
- Thommeret N, Bailly JS, Puech C. 2009. Robust extraction of Thalwegs networks from DTMs for topological characterisation: a case study on badlands. *Proceedings of Geomorphometry*. 31: 218-223.
- Yao X, Tham LG, Dai FC. 2008. Landslide susceptibility mapping based on support vector machine: A case study on natural slopes of Hong Kong, China. *Geomorphology*. 101(4):572-582.



Fars Agricultural and Natural Resources
Research and Education Center



Agricultural Research, Education
and Extension Organization

Modeling Groundwater Potential Using Machine Learning Models

Ahmad Salamat¹, Mojtaba Ardestani^{*2}, Bahram Malekmohammadi³

1- Ph.D. Student in Environmental Engineering, Water resources, Kish International Campus, University of Tehran

2- Professor, Faculty of Environment, University of Tehran

3- Associate Professor, Faculty of Environment, University of Tehran

Extended Abstract

Introduction

Finding the potential of groundwater resources is one of the basic principles in water resources management. The aim of this research is to determine the potential of groundwater using support vector machine learning (SVM) models as well as metaheuristic algorithms (hybrid support vector machine model and the bee metaheuristic optimization algorithm (SVM-BA) and hybrid model of the support vector machine and particle swarm optimization algorithm (SVM-PSO).

Materials and methods

The factors of elevation, slope, aspect, topographic humidity index, distance from stream, drainage density, distance from fault, lithology, topographic position index, land roughness index, relative slope position and flow convergence index were selected in Bojnurd region. Information on the location of 359 springs was received from the regional water company. Random division algorithm was used to divide training points (70%) and validation points (30%). Based on the removal sensitivity analysis, the importance and contribution of the input variables in determining the groundwater potential were

Article Type: Research Article

***Corresponding Author E-mail:** Ardestan@ut.ac.it

Citation: Salamat, A., Ardestani, M., Malekmohammadi, B. 2023. Modeling Groundwater potential using machine learning models. Watershed Management Research. 36(4): 114-132.

DOI: 10.22092/WMRJ.2023.360675.1506

Received: 23 November 2022, **Received in revised form:** 21 January 2023, **Accepted:** 19 March 2023,

Published online: 22 December 2023

Watershed Management Research, VOL. 36, No.4, Ser. No: 141, Winter 2024, pp. 114-132.

Publisher: Fars Agricultural and Natural Resources Research and Education Center

©Author(s)



determined. The accuracy of the models was evaluated in two stages of training and validation based on the receiver operating characteristic (ROC) curve method.

Results

The evaluation of the accuracy of the models based on the evaluation criteria of the area under curve (AUC) showed that the prediction accuracy of the hybrid model of the support vector machine and the particle swarm optimization algorithm (SVM-PSO) is 0.945 more than other models (SVM: 0.918 and SVM-BA: 0.932). Based on the results of the superior model, the high potential class and the very high potential class accounted for 7.75% and 38.66% of the area respectively. Among the factors, relative slope position with 14.5%, distance from the fault with 13.4% and lithology with 12.3% were the most important in predicting groundwater potential.

Discussion and Conclusion

Based on the results of this research, the support vector machine model has a high performance, and two optimization algorithms, the bee metaheuristic and particle swarm optimization algorithm, strengthen the predictive power of the model. Also machine learning models can identify the relationship between the environmental factors and the water supply of the springs and determine their role by using the available data. The relative slope position factor was identified as the most important variable and the distance from the fault factor was considered as the second most important variable in the present study. The results of the research showed that the faults in the region play an important role in aquifer recharge, storage and flow of groundwater. The lithological factor was also introduced by the model as the third important variable in identifying the state of groundwater potential. In this research, by presenting the groundwater potential map, it is possible to plan and verify land use planning for the Bojnurd watershed.

Key Words: Bojnurd, groundwater, machine learning, support vector machine