

## بهینه‌سازی مدل دراستیک با استفاده از ماشین بردار پشتیبان و شبکه عصبی مصنوعی به منظور ارزیابی آسیب‌پذیری ذاتی آبخوان دشت اردبیل

مریم قره‌خانی<sup>۱</sup>، عطاالله ندیری<sup>۲\*</sup>، اصغر اصغری مقدم<sup>۳</sup>، فریبا صادقی اقدام<sup>۴</sup>

۱. دانشجوی کارشناسی ارشد هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز

۲. استادیار گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز

۳. استاد گروه علوم زمین، دانشکده علوم طبیعی، دانشگاه تبریز

۴. دانشجوی دکتری هیدروژئولوژی، دانشکده علوم طبیعی، دانشگاه تبریز

(تاریخ دریافت: ۱۳۹۴/۰۷/۱۰ - تاریخ تصویب: ۱۳۹۴/۰۹/۱۰)

### چکیده

با توجه به افزایش جمعیت و توسعه کشاورزی در دشت اردبیل، ارزیابی آسیب‌پذیری آبخوان این دشت برای مدیریت منابع آب زیرزمینی و جلوگیری از آلودگی آب‌های زیرزمینی ضروری است. در این پژوهش آسیب‌پذیری آبخوان دشت اردبیل در برابر آلودگی با استفاده از روش دراستیک بررسی شد. در مدل دراستیک هفت پارامتر مؤثر در آسیب‌پذیری شامل عمق آب زیرزمینی، تغذیه خالص، محیط آبخوان، محیط خاک، توپوگرافی، محیط غیراشباع و هدایت هیدرولیکی، به صورت هفت لایه رستری با مقیاس ۳۰۰۰۰:۱ تهیه شد و بعد از رتبه‌دهی و وزن‌دهی شاخص دراستیک محاسبه شد که برای دشت اردبیل بین ۸۲ تا ۱۵۱ به دست آمد. سپس به منظور بهینه‌سازی مدل دراستیک از مدل ماشین بردار پشتیبان، شبکه عصبی پیشرو و شبکه عصبی برگشتی استفاده شد تا بدین طریق بتوان به نتایج دقیق‌تری از ارزیابی آسیب‌پذیری دست یافت. به این منظور پارامترهای دراستیک به عنوان ورودی مدل و شاخص دراستیک به عنوان خروجی مدل تعریف شدند و مقادیر نیترا ت مربوطه به ۲ دسته آموزش و آزمون تقسیم شد. شاخص دراستیک مربوط به مرحله آموزش با مقادیر نیترا ت مربوط تصحیح شد و بعد از آموزش مدل، در مرحله آزمون نتایج مدل‌ها با استفاده از مقادیر نیترا ت ارزیابی شد. نتایج نشان داد که هر سه مدل هوش مصنوعی توانایی زیادی در ارزیابی آسیب‌پذیری آبخوان دارند، اما در این بین، مدل ماشین بردار پشتیبان در مرحله آزمون برای هر سه قسمت شرقی، غربی و جنوبی دشت با کمترین مقدار RMSE به ترتیب ۶/۷۴، ۳/۹۳ و ۳/۷۸ و بیشترین مقدار  $R^2$  به ترتیب ۰/۷۳، ۰/۷۹ و ۰/۷۲ نتایج بهتری را در برداشت. براساس این مدل، قسمت‌های شمالی و غربی دشت پتانسیل آلودگی بالایی دارد و باید محافظت بیشتری از این مناطق صورت گیرد.

**کلیدواژگان:** آسیب‌پذیری آبخوان، دشت اردبیل، ماشین بردار پشتیبان، مدل دراستیک، هوش مصنوعی.

## مقدمه

در طول چند دهه گذشته، آلودگی آب‌های زیرزمینی به یکی از مشکلات جدی زیست‌محیطی در نتیجه افزایش فعالیت‌های صنعتی و کشاورزی تبدیل شده است. بازسازی سفره‌های آب زیرزمینی آلوده شده برای بازگرداندن به کیفیت اصلی بسیار مشکل و حتی غیرممکن است. این در حالی است که آب‌های زیرزمینی به دلیل حجم ذخیره‌سازی زیاد و حساسیت نسبتاً کم آن به آلودگی در مقایسه با آب‌های سطحی به طور فزاینده‌ای به منبع مهم تأمین آب تبدیل شده است [۹]. به‌عنوان یک قاعده کلی، محافظت از آب‌های زیرزمینی در برابر آلودگی به مراتب آسان‌تر و عاقلانه‌تر از حذف آلودگی بعد از آلوده شدن آن است. گام نخست و ضروری برای جلوگیری از آلودگی آب‌های زیرزمینی شناسایی مناطق در معرض خطر آلودگی بیشتر است [۲۶]. مفهوم آسیب‌پذیری برای اولین بار در اواخر سال ۱۹۶۰ میلادی در فرانسه برای آگاهی بخشی درباره آلودگی آب زیرزمینی ارائه شده است [۳۶]. آسیب‌پذیری را می‌توان به‌عنوان امکان نفوذ و پخش آلاینده‌ها از سطح زمین به سیستم آب زیرزمینی تعریف کرد. آسیب‌پذیری آبخوان، نیروی آن را برای نفوذ و پخش آلاینده‌ها از سطح زمین به سیستم آب زیرزمینی نشان می‌دهد، به طوری که آلودگی تولیدشده در سطح زمین بتواند به آب زیرزمینی برسد و در آن پراکنده شود [۹]. آسیب‌پذیری نوعی خصوصیت نسبی، بدون بعد و غیرقابل اندازه‌گیری است و به ویژگی‌های آبخوان، محیط زمین‌شناسی و هیدروژئولوژی بستگی دارد [۶]. ارزیابی آسیب‌پذیری برای آلودگی آب‌های زیرزمینی بخشی از مدیریت آب‌های زیرزمینی در بسیاری از مناطق جهان به‌شمار می‌رود.

تا کنون روش‌های مختلفی برای ارزیابی آسیب‌پذیری ارائه شده است و در تمامی روش‌ها آسیب‌پذیری آبخوان براساس انتقال آلودگی از سطح زمین به لایه آبدار برآورد شده است. روش دراستیک یکی از روش‌های متداول استفاده شده برای ارزیابی آسیب‌پذیری آب زیرزمینی است [۴]. مدل دراستیک براساس هفت پارامتر هیدروژئولوژیکی مؤثر در آسیب‌پذیری از جمله، عمق آب زیرزمینی، تغذیه خالص، محیط آبخوان، محیط خاک، توپوگرافی، تأثیر ناحیه غیراشباع و هدایت هیدرولیکی است. از مزایای مدل دراستیک می‌توان به هزینه اندک و تعداد داده‌های کم

اشاره کرد، اما ضعف عمده این مدل، اعمال نظرهای کارشناسی برای تعیین وزن و رتبه‌دهی پارامترهای به‌کاررفته در آن است [۲۳].

به‌منظور بهبود مدل دراستیک تا کنون روش‌های مختلفی ارائه شده است از جمله پاناکاپولوس و همکاران به‌منظور بهینه‌سازی مدل دراستیک از روش‌های آماری استفاده کرده‌اند [۲۹]. در بعضی از مطالعات نیز از پارامترهای اضافی مانند کاربری اراضی و نوع و شدت آبیاری برای بهبود مدل دراستیک استفاده شده است [۲۵، ۳۱]. اخیراً از روش‌های هوش مصنوعی به‌طور گسترده‌ای در بسیاری از مطالعات در علوم مختلف استفاده شده است [۱۳، ۲۸، ۳۵]. از جمله مطالعات انجام‌شده در زمینه ارزیابی آسیب‌پذیری آب زیرزمینی با استفاده از هوش مصنوعی می‌توان به موارد زیر اشاره کرد:

دیکسون در سال ۲۰۰۵ به‌منظور پیش‌بینی آسیب‌پذیری آب زیرزمینی برای زیرحوضه انتخاب‌شده از حوضه رودخانه ایلینویس<sup>۱</sup> در شمال غرب آرکانزاس، از روش نروفازی استفاده کرده و حساسیت مدل نروفازی را با تلفیق روش‌های GIS و نروفازی بررسی کرده است [۱۷]. فرج‌زاده اصل و محمدی در پژوهشی به‌منظور پهنه‌بندی آسیب‌پذیری آب‌های زیرزمینی از الگوریتم‌های فازی عصبی استفاده کردند [۱]. مطالعه‌ای در زمینه بهینه‌سازی مدل دراستیک توسط فیجانی و همکاران در سال ۲۰۱۳ انجام شده است که به‌منظور ارزیابی آسیب‌پذیری آب زیرزمینی آبخوان دشت مراغه- بناب، بهینه‌سازی مدل دراستیک را با استفاده از هوش مصنوعی مرکب نظارت‌شده انجام داده‌اند [۲۰]. ماشین بردار پشتیبان<sup>۲</sup> (SVM)، یک ابزار رگرسیون و طبقه‌بندی است و برخلاف ANN که سعی می‌کند به تعریف پیچیدگی توابع از فضای ورودی بپردازد، SVM داده‌های غیرخطی را به فضایی با ابعاد بیشتر می‌برد، سپس از توابع خطی ساده برای ایجاد مرزهای جداکننده خطی در فضای جدید استفاده می‌کند. یکی دیگر از ویژگی‌های SVM این است که فرمولاسیون رگرسیون آن به جای حداقل کردن ریسک تجربی، براساس حداقل کردن ریسک ساختاری است به طوری که عملکرد بهتری داشته باشد [۱۲]. اولین کاربرد روش

1. Illinois

2. Support Vector Machine

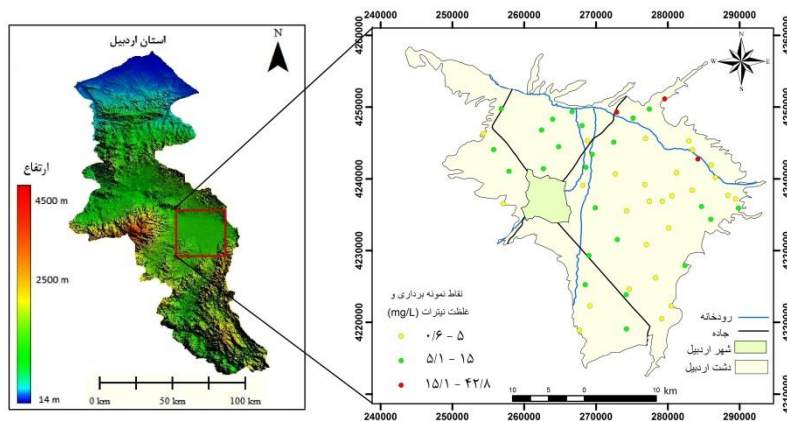
کارایی آن با شبکه عصبی (ANN) مقایسه شد. یکی از مزیت‌های استفاده از مدل‌های هوش مصنوعی علاوه بر آسیب‌پذیری ذاتی، ارائه تخمینی از آسیب‌پذیری ویژه در منطقه نیز است که در این پژوهش ارائه شده و قابل استفاده برای مناطق مطالعاتی دیگر نیز است.

### منطقه مطالعاتی

محدوده مطالعاتی مد نظر در این تحقیق، آبخوان دشت اردبیل است. همان‌طور که در شکل ۱ مشاهده می‌شود دشت اردبیل در شمال غرب ایران و در استان اردبیل قرار دارد. این دشت وسعتی حدود ۹۹۰ کیلومترمربع دارد. حوضه آبریز دشت اردبیل در محدوده طول شرقی  $48^{\circ}40' - 48^{\circ}00'$  و عرض شمالی  $38^{\circ}30' - 38^{\circ}00'$  قرار گرفته است. دشت اردبیل دشتی نسبتاً هموار است که از اطراف توسط کوه‌های بزقوش، تالش و سبلان احاطه شده و تنها خروجی منابع آبی دشت در دورترین نقطه شمال غربی آن واقع شده است. این دشت دارای سه رودخانه اصلی قره‌سو، بالخلوچای و قوری‌چای است. نوران‌چای، هیرچای و شهریورچای نیز از دیگر رودهای این دشت هستند. از نظر زمین‌شناسی ارتفاعات اطراف دشت اردبیل بخشی از رشته‌کوه البرز هستند. در قسمت‌های مرکزی و شرق رشته‌کوه البرز، رخساره‌های توف سبز با سن ائوسن در ارتباط با سنگ‌های آتشفشانی هستند، در حالی که در منطقه اردبیل سنگ‌های آتشفشانی غالب و توف‌های سبز کمتر هستند. در این منطقه سازندهای سنوزوئیک اغلب چین خورده‌اند و سازندهای قدیمی‌تر تنها در بخش‌های شمالی یافت می‌شوند [۲].

ماشین بردار پشتیبان (SVM) در مسائل آب توسط دیباک و همکاران با مدل‌سازی بارش- رواناب ارائه شد [۱۶]. همچنین در پژوهشی به‌منظور پیش‌بینی سطح آب زیرزمینی از SVM و ANN استفاده شده است و نتایج این دو روش با هم مقایسه شده است. نتایج بیانگر کارایی بهتر SVM در آموزش، واسنجی و اعتبارسنجی در مقایسه با ANN بود [۱۱].

دشت اردبیل به‌عنوان یکی از مناطق فعال کشاورزی، دامداری و صنعت است که در آن از کودهای کشاورزی زیاد استفاده می‌شود و در شمال غرب کشور از دشت‌های مهم به‌شمار می‌آید. در این دشت علاوه بر کودهای استفاده‌شده، پساب‌ها و فاضلاب‌های حاصل از منطقه می‌تواند آب‌های زیرزمینی را آلوده سازند، بنابراین ارزیابی آسیب‌پذیری آبخوان دشت اردبیل ضرورت دارد تا بتوان با شناسایی مناطق آسیب‌پذیر این دشت از آلوده‌شدن آب‌های زیرزمینی این منطقه تا حدی جلوگیری کرد. بنابراین، در این پژوهش از مدل دراستیک برای بررسی آسیب‌پذیری ذاتی دشت یادشده استفاده شد. سپس برای دستیابی به نتایج دقیق‌تر از آسیب‌پذیری آبخوان و شناسایی مناطق دارای پتانسیل آلودگی زیاد از مدل‌های هوش مصنوعی استفاده شد. یکی از مزیت‌های هوش مصنوعی در زمینه ارزیابی آسیب‌پذیری نسبت به روش دراستیک این است که وزن‌هایی که در روش دراستیک با نظر کارشناس اعمال می‌شود را به‌صورت بهینه و بدون نیاز به نظر کارشناس انجام می‌دهد. بنابراین، برای بهینه‌سازی و بهبود مدل دراستیک، ماشین بردار پشتیبان (SVM) که تا کنون برای این منظور استفاده نشده، به کار گرفته شد و



شکل ۱. منطقه مطالعه‌شده و موقعیت نقاط نمونه‌برداری برای غلظت‌های نیترات

## روش پژوهش

در این پژوهش از روش DRASTIC برای ارزیابی آسیب‌پذیری آبخوان دشت اردبیل استفاده شده است. سپس به منظور بهینه‌سازی این روش از مدل‌های هوش مصنوعی از جمله ماشین بردار پشتیبان و شبکه عصبی استفاده شد. در این پژوهش منابع اطلاعاتی گوناگونی از جمله داده‌های عمق آب زیرزمینی، لاگ چاه‌های مشاهده‌ای، نتایج آزمایش پمپاژ، نقشه بافت خاک منطقه و نقشه توپوگرافی برای تهیه پارامترهای مدل دراستیک به کار گرفته شد. با تجزیه و تحلیل این اطلاعات در محیط نرم‌افزار Arc GIS نقشه پهنه‌بندی آسیب‌پذیری آبخوان دشت اردبیل تهیه شد (توضیحات کامل در خصوص چگونگی ارزیابی پارامترهای دراستیک و تهیه نقشه آسیب‌پذیری در بخش بحث و نتایج ارائه شده است). در مرحله بعد به منظور اجرای مدل‌های هوش مصنوعی، هفت پارامتر دراستیک به عنوان ورودی مدل‌ها و شاخص دراستیک تصحیح شده با نیترا به عنوان خروجی مدل‌ها انتخاب شد. همچنین برای صحت‌سنجی مدل‌ها نیز از مقادیر اندازه‌گیری شده غلظت نیترا در منطقه استفاده شد.

## مدل دراستیک (DRASTIC)

مدل دراستیک توسط آژانس حفاظت محیط زیست آمریکا (US - EPA) به منظور تعیین پتانسیل آلودگی آب‌های زیرزمینی توسعه یافته است [۵]. این مدل، پتانسیل آلودگی یک ناحیه را با جمع کردن عوامل کلیدی مؤثر بر انتقال مواد آلاینده محلول ارزیابی می‌کند. مدل دراستیک براساس هفت پارامتر هیدروژئولوژیکی است که شامل عمق آب زیرزمینی<sup>۱</sup>، تغذیه<sup>۲</sup>، محیط آبخوان<sup>۳</sup>، محیط خاک<sup>۴</sup>، توپوگرافی<sup>۵</sup>، تأثیر ناحیه غیراشباع<sup>۶</sup> و ضریب هدایت هیدرولیکی<sup>۷</sup> است. اطلاعات حاصل از این پارامترها به صورت تلفیقی تجزیه و تحلیل و سپس توسط سامانه اطلاعات جغرافیایی (GIS) پردازش می‌شوند. در روش دراستیک به هر پارامتر یک رتبه و یک وزن (از ۱ تا ۵) برحسب اهمیت پارامتر اختصاص داده می‌شود. رتبه پارامترهای دراستیک بین ۱ تا ۱۰ متغیر است، به طوری که

۱ به معنای کمترین و ۱۰ به معنای بیشترین خطر برای آلودگی آب زیرزمینی در نظر گرفته می‌شود [۹]. از این رو شاخص دراستیک براساس وزن‌دهی به مجموع هفت پارامتر با فرمول ۱ محاسبه می‌شود [۵].

$$DI = DrDw + RrRw + ArAw + SrSw + TrTw + IrIw + CrCw \quad (1)$$

در رابطه بالا، DI شاخص آسیب‌پذیری دراستیک و حروف بزرگ نشان‌دهنده پارامترهای هفت‌گانه و r نرخ ارزش (رتبه) و w وزنی است که به هر پارامتر تخصیص داده می‌شود.

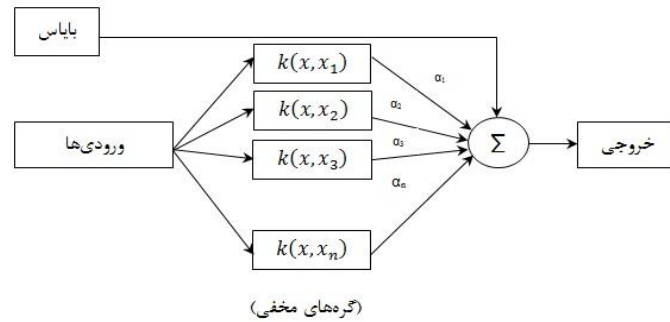
## ماشین بردار پشتیبان (SVM)

اساس روش ماشین‌های بردار پشتیبان (SVM) توسط کورتز و وپنیک در سال ۱۹۹۵ ارائه شد [۱۴]. ماشین بردار پشتیبان یک سیستم یادگیری کارآمد است که از اصل استقرایی کمینه‌سازی خطای ساختاری بهره می‌جوید و به یک جواب بهینه کلی منجر می‌شود [۱۵]. شکل ۲ تصویر شماتیکی از ماشین بردار پشتیبان را نشان می‌دهد. مهم‌ترین کاربردهای ماشین بردار پشتیبان در طبقه‌بندی و خطی‌سازی داده‌هاست. ویژگی مهم ماشین بردار پشتیبان این است که برخلاف الگوریتم‌های کلاسیک و رگرسیون‌های خطی که به وسیله حدافل کردن قدر مطلق خطا یا توان دوم خطا عمل می‌کنند، آن‌ها ریسک عملیاتی را به حدافل می‌رسانند. SVM ریسک نبود طبقه‌بندی صحیح را به صورت یک سری عددی بیان می‌کند و بعد مقدار کمینه آن را حساب می‌کند، اما شبکه عصبی MLP هر موقع که خطای تقسیم‌بندی (تفکیک) کم باشد آن را به عنوان یک راه حل ارائه می‌دهد. ماشین بردار پشتیبان برخلاف شبکه‌های عصبی با مشکل گیر افتادن در مینیمم‌های محلی تابع خطا مواجه نیست [۲۲، ۲۷]. مراحل حل مسئله در الگوریتم ماشین‌های بردار پشتیبان همانند الگوریتم شبکه‌های عصبی به دو مرحله آموزش و آزمایش تقسیم می‌شود.

انواع مدل‌های ماشین بردار پشتیبان عبارت‌اند از طبقه‌بندی بردار پشتیبان<sup>۸</sup>، رگرسیون بردار پشتیبان<sup>۹</sup>، حدافل مربعات ماشین‌های بردار پشتیبان<sup>۱۰</sup>، برنامه‌ریزی خطی ماشین‌های بردار پشتیبان<sup>۱۱</sup> و Nu ماشین‌های بردار پشتیبان<sup>۱۲</sup> [۳۰].

8. Support vector classification  
9. Support vector regression  
10. Least-squares support vector machines  
11. Linear programming support vector machines  
12. Nu-support vector machines

1. Depth of groundwater  
2. Recharge  
3. Aquifer media  
4. Soil media  
5. Topography (surface slope)  
6. Impact of the vadose zone media  
7. Conductivity



شکل ۲. تصویر شماتیکی از SVM

استفاده می‌شود، مسئله بهینه‌سازی به وسیله حداقل کردن تابع معین زیر فرموله می‌شود [۳۴]:

$$\min R(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 \quad (3)$$

$\gamma$  پارامتر تنظیم‌کننده خطا و  $e$  میزان خطا را نشان می‌دهد.

براساس این محدودیت:

$$y(x) = w^T \varphi(x_i) + b + e_i, \quad i = 1, 2, \dots, n \quad (4)$$

برای حل این مسئله بهینه‌سازی از تابع لاگرانژ استفاده شده است:

$$L(w, b, e, \alpha) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 - \quad (5)$$

$$\sum_{i=1}^n \alpha_i \{ w^T \varphi(x_i) + b + e_i - y_i \}$$

$\alpha_i$  ضریب لاگرانژ است.

حل معادله ۵ را می‌توان با مشتق جزئی  $w$ ,  $b$ ,  $e_i$  و  $\alpha_i$  به‌دست آورد.

$$\left\{ \begin{aligned} \frac{\partial L}{\partial w} = 0 &\rightarrow w = \sum_{i=1}^n \alpha_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 &\rightarrow \sum_{i=1}^n \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 &\rightarrow \alpha_i = \gamma e_i \\ \frac{\partial L}{\partial \alpha_i} = 0 &\rightarrow w^T \varphi(x_i) + b + e_i - y_i = 0 \end{aligned} \right. \quad (6)$$

با استفاده از شرایط KKT، مدل حداقل مربعات ماشین بردار پشتیبان به‌منظور تخمین تابع به‌صورت رابطه ۷ نتیجه می‌شود:

در این پژوهش از حداقل مربعات ماشین بردار پشتیبان استفاده شده است. حداقل مربعات ماشین بردار پشتیبان (LS-SVM) یک مدل SVM اصلاح‌شده است که توسط سویکنس<sup>۱</sup> و همکاران در سال ۲۰۰۲ ارائه شده است و یک روش یادگیری ماشین است که قابل اجرا برای طبقه‌بندی و رگرسیون است [۳۴]. راه حل LS-SVM به جای مسئله برنامه‌نویسی درجه دوم SVM<sup>۲</sup> از معادلات KKT<sup>۳</sup> خطی استفاده می‌کند. اشکال عمده LS-SVM این است که از یک تابع تلفات درجه دوم بدون هیچ قانونی استفاده می‌کند که به تخمین ضعیف‌تری منجر می‌شود. از این‌رو به‌منظور جلوگیری از این، LS-SVM وزن‌دار اقتباس شد و در مواردی که وزن‌های کوچک به داده‌ها اختصاص داده شود، روش آموزشی دومرحله‌ای ارائه می‌شود. این مدل به‌دلیل استفاده از معادلات خطی در حل مسائل، دقت محاسباتی بیشتری نسبت به ماشین بردار پشتیبان کلاسیک دارد [۳۲، ۳۳].

یک مجموعه آموزشی از  $N$  داده  $\{x_i, y_i\}_{i=1}^N$  در نظر گرفته می‌شود که  $x_i \in R^d$  داده ورودی  $y_i \in R$  داده خروجی است. مدل‌های رگرسیون LS-SVM در فضای ویژگی به‌صورت زیر است:

$$y(x) = w^T \varphi(x) + b \quad (2)$$

$w$  و  $b$  به ترتیب مقادیر وزن‌ها و بایاس تابع رگرسیون هستند.  $\varphi(x)$  ترسیم غیرخطی ورودی‌ها در فضای ویژگی با ابعاد بالاست. زمانی که LS-SVM برای تخمین تابع

1. Suykens  
2. Quadratic programming problem  
3. Karush-Kuhn-Tucker equations

می‌شوند. در شبکه‌های عصبی پیشرو گره‌های پردازشگر در لایه‌های مخفی قرار دارند و هر شبکه می‌تواند چندین لایه مخفی و هر لایه مخفی می‌تواند یک یا بیش از یک گره داشته باشد. در شبکه‌های پیشرو (FFN) اطلاعات از ورودی به سمت خروجی حرکت می‌کند. گره‌های یک لایه با گره‌های لایه دیگر ارتباط دارند، اما با گره‌های موجود در همان لایه مرتبط نیستند. بنابراین، خروجی هر گره در یک لایه فقط به ورودی‌های دریافتی از لایه‌های قبلی و وزن‌های مربوط وابسته است. در شبکه‌های عصبی برگشتی (RNN) اطلاعات بین گره‌ها در دو جهت، از ورودی به سمت خروجی و به عکس جریان می‌یابند. این نوع شبکه از خروجی‌ها به عنوان ورودی‌های جدید استفاده می‌کند، بنابراین به داده‌ها اجازه برگشت به ورودی را می‌دهد [۷].

ساختار عمومی یک شبکه عصبی مصنوعی معمولاً از لایه ورودی، لایه‌های میانی (مخفی) و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه خروجی شامل مقادیر پیش‌بینی شده به وسیله شبکه است و خروجی مدل را معرفی می‌کند. لایه‌های میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌هاست. هر گره یک تابع تبدیلگر دارد (شکل ۳) که این تابع تبدیلگر، تولیدکننده خروجی‌های آن گره به شمار می‌رود. تعداد لایه‌های مخفی و تعداد گره‌ها در هر لایه مخفی معمولاً با استفاده از روش آزمون و خطا تعیین می‌شود. گره‌های لایه‌های مجاور به‌طور کامل با هم در ارتباطند [۳]. شکل ۳ ساختار یک شبکه عصبی مصنوعی را نشان می‌دهد که از هفت گره در لایه ورودی، دو گره در لایه میانی و یک گره در لایه خروجی تشکیل شده است.

$$y(x) = \sum_{i=1}^n \alpha_i K(x_i, x) + b \quad (7)$$

$K(x_i, x)$  تابع کرنل نامیده می‌شود. انواع مختلفی از توابع کرنل وجود دارد از جمله خطی، چندجمله‌ای، تابع پایه شعاعی (RBF) و سیگموئیدی [۳۲] که در این پژوهش از تابع کرنل RBF استفاده شده است (معادله ۸).

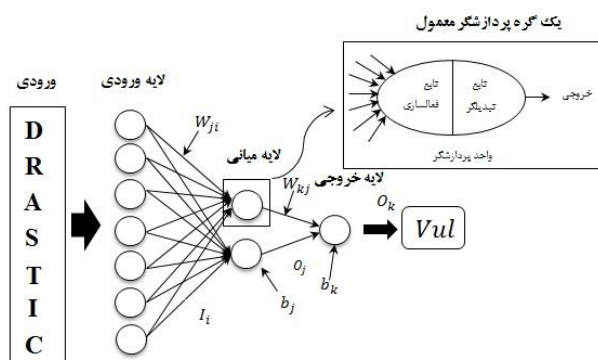
$$K(x_i, x_j) = \exp(-x_i - x_j^2 / \sigma^2) \quad (8)$$

$\sigma$  پارامتر تابع کرنل است. در مدل‌سازی با حداقل مربعات ماشین بردار پشتیبان، انتخاب مقادیر مناسب دو پارامتر  $\gamma$  (در معادله ۳) و  $\sigma$  (در معادله ۸) اهمیت بسیار زیاد دارد که مقادیر این دو پارامتر با آزمون و خطا تعیین می‌شود.

### شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی به عنوان یک مدل تجربی برای اولین بار از فرموله کردن توانایی‌های مغز انسان ارائه شد [۲۴]. شبکه‌های عصبی مصنوعی یک سیستم پردازش اطلاعات توده‌ای است که به صورت موازی قرار گرفته‌اند و ویژگی‌های عملکردی خاص شبیه شبکه‌های عصبی بیولوژیکی مغز انسان دارد [۲۱].

یک شبکه عصبی به وسیله الگوی ارتباطی بین گره‌ها، روش تعیین وزن‌های ارتباطی و تابع فعال‌سازی مشخص می‌شود [۱۹]. یک شبکه عصبی به‌طور معمول شامل تعدادی از گره‌هاست که با آرایش خاصی قرار گرفته‌اند. یکی از روش‌های طبقه‌بندی شبکه‌های عصبی براساس تعداد لایه‌هاست که به سه نوع تک‌لایه‌ای، دو لایه‌ای و چندلایه‌ای تقسیم می‌شود. شبکه‌های عصبی مصنوعی همچنین براساس جهت جریان و پردازش اطلاعات به دو دسته شبکه‌های پیشرو و شبکه‌های برگشتی تقسیم



شکل ۳. ساختار شبکه عصبی مصنوعی (ANN) و یک گره پردازشگر

غیراشباع بخش غربی دشت بیشتر از رسوبات آبرفتی دانه‌درشت و بخش‌های شرقی و جنوبی از رسوبات دانه‌ریز تشکیل شده‌اند، از نظر عمق آب زیرزمینی قسمت جنوبی دشت عمق زیاد و قسمت غربی کمترین عمق آب زیرزمینی را دارد و همچنین بیشترین تراوایی و میزان تغذیه مربوط به بخش غربی دشت و کمترین آن مربوط به بخش جنوبی است. بنابراین، برای افزایش دقت مدل‌ها، منطقه مطالعاتی به سه قسمت شرقی، غربی، و جنوبی تقسیم (شکل ۴) و برای هر قسمت مدل هوش مصنوعی با خصوصیات متفاوت تهیه شد.

به‌منظور اجرای مدل دراستیک، نقشه‌های مربوط به هر یک از پارامترهای مدل دراستیک در محیط نرم‌افزار GIS تهیه شد و سپس رتبه‌دهی و وزن‌دهی و درنهایت تلفیق لایه‌های مختلف اطلاعاتی انجام گرفت که چگونگی تهیه لایه‌های اطلاعاتی به‌طور مختصر در زیر ارائه شده است. پارامتر عمق آب زیرزمینی تعیین‌کننده عمقی است که آلوده‌کننده باید طی کند تا به سطح ایستابی برسد. هرچه عمق سطح ایستابی بیشتر باشد، زمان بیشتری طول می‌کشد تا این مواد به آبخوان برسد و امکان پخش شدن، رقیق شدن و جذب مواد آلاینده در خاک وجود خواهد داشت. بنابراین، برای عمق‌های کمتر، بیشترین رتبه (۱۰) و برای عمق‌های بیشتر، کمترین رتبه (۱) اختصاص داده می‌شود. برای تهیه نقشه عمق آب زیرزمینی، ابتدا موقعیت و عمق سطح ایستابی چاه‌های موجود در منطقه به محیط اکسل وارد و سپس به فرمت قابل قبول برای نرم‌افزار ARC GIS تبدیل شد. سپس با روش کریجینگ معمولی (Ordinary Kriging) درون‌یابی انجام گرفت و به‌منظور تلفیق با لایه‌های دیگر به حالت رستری تبدیل شد و درنهایت رتبه‌دهی انجام گرفت و لایه عمق آب زیرزمینی تهیه شد.

تغذیه خالص مقدار آبی است که از سطح زمین نفوذ می‌کند و به سطح ایستابی می‌رسد. تغذیه آب موجب می‌شود تا آلوده‌کننده به‌صورت عمودی انتقال یابد و به سطح ایستابی برسد. برای ایجاد این لایه از بیلان آب زیرزمینی استفاده و میزان تغذیه محاسبه شد و بعد از درون‌یابی و رتبه‌دهی نقشه تغذیه آب زیرزمینی حاصل شد. برای تهیه نقشه محیط آبخوان و محیط غیراشباع با استفاده از لاگ چاه‌های منطقه جنس مواد تشکیل‌دهنده

### معیارهای ارزیابی دقت مدل‌های هوش مصنوعی

در این پژوهش به‌منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیش‌بینی دقیق از ۴ معیار جذر میانگین مربع خطا (RMSE) میانگین خطای مطلق (MAE)، ضریب تبیین ( $R^2$ ) و ضریب همبستگی ( $r$ ) استفاده شده است. این ۴ معیار به‌صورت زیر محاسبه می‌شوند:

$$MAE = \frac{\sum_{i=1}^n |(Vul_i - \bar{Vul}_i)|}{n} \quad (9)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Vul_i - \bar{Vul}_i)^2}{n}} \quad (10)$$

$$r = \frac{\sum_{i=1}^n (Vul_i - \bar{Vul}_i)(N_i - \bar{N})}{\sqrt{\sum_{i=1}^n (Vul_i - \bar{Vul}_i)^2} \sqrt{\sum_{i=1}^n (N_i - \bar{N})^2}} \quad (11)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Vul_i - \bar{Vul}_i)^2}{\sum_{i=1}^n (Vul_i - \bar{Vul}_i)^2} \quad (12)$$

در روابط یادشده:  $Vul_i$  نتایج آسیب‌پذیری مشاهداتی،  $\bar{Vul}_i$  نتایج آسیب‌پذیری محاسباتی به‌وسیله مدل هوش مصنوعی،  $\bar{Vul}$  میانگین مشاهداتی،  $Vul$  میانگین محاسباتی،  $n$  تعداد کل مشاهداتی،  $N_i$  غلظت نیترات و  $\bar{N}$  میانگین غلظت نیترات را نشان می‌دهد. MAE و RMSE میزان خطای بین مقادیر مشاهداتی و محاسباتی را نشان می‌دهد و  $R^2$  و  $r$  نشانگر میزان بازده شبکه است. هر چقدر MAE و RMSE به صفر و  $R^2$  و  $r$  به یک میل کنند، یعنی مقادیر مشاهداتی و محاسباتی بسیار نزدیک به هم است و نتایج مدل کمترین مقدار خطا و بیشترین دقت را دارد.

### بحث و نتایج

در این مطالعه به‌منظور صحت‌سنجی و مقایسه پیش‌بینی مدل‌ها از غلظت نیترات اندازه‌گیری شده در منطقه مطالعه شده استفاده شد. شکل ۴ توزیع نیترات را در منطقه نشان می‌دهد که با استفاده از روش IDW پهنه‌بندی شده است که بیشترین غلظت نیترات در آب زیرزمینی را در قسمت غربی و بخشی از شمال دشت و کمترین مقدار را در جنوب دشت نشان می‌دهد.

دشت اردبیل ناهمگنی‌های فراوانی از نظر زمین‌شناسی و هیدروژئولوژیکی دارد، از جمله اینکه رسوبات زون

پس از تهیه مشخصه‌های مورد نیاز برای ارزیابی آسیب‌پذیری به روش دراستیک به صورت هفت لایه رستری که در شکل ۵ نشان داده شده‌اند وزن‌دهی پارامترها مطابق جدول ۱ انجام گرفت و بعد از تلفیق آن‌ها براساس رابطه ۱ شاخص آسیب‌پذیری محاسبه شد.

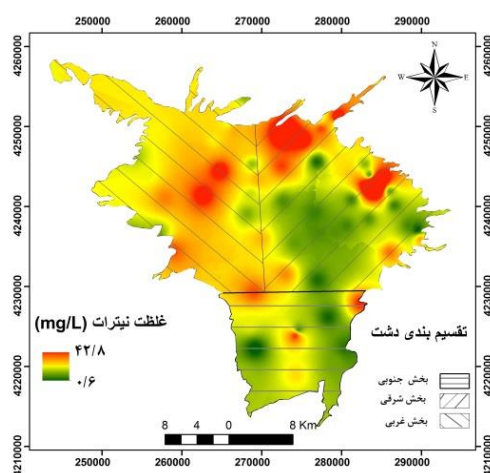
جدول ۱. وزن‌دهی پارامترهای مدل DRASTIC

وزن	پارامتر
۵	عمق آب زیرزمینی
۴	تغذیه خالص
۳	محیط آبخوان
۲	محیط خاک
۱	توپوگرافی
۵	محیط غیراشباع
۳	هدایت هیدرولیکی

شاخص آسیب‌پذیری دراستیک برای دشت اردبیل بین ۸۲ تا ۱۵۱ به دست آمد که با توجه به طبقه‌بندی آلر و همکاران [۵] آسیب‌پذیری دشت اردبیل در دو گروه آسیب‌پذیری کم (۸۲-۱۲۰) و متوسط (۱۲۱-۱۵۱) قرار می‌گیرد. بیشترین آسیب‌پذیری آب‌های زیرزمینی مربوط به آسیب‌پذیری متوسط است که ۵۵/۶۴ درصد از منطقه مطالعه شده را پوشش می‌دهد، این رده بخش‌هایی در نواحی شمالی و غربی را به خود اختصاص داده است. شرق و قسمتی از جنوب دشت در محدوده آسیب‌پذیری کم قرار دارد که ۴۴/۳۶ درصد از منطقه را شامل می‌شود.

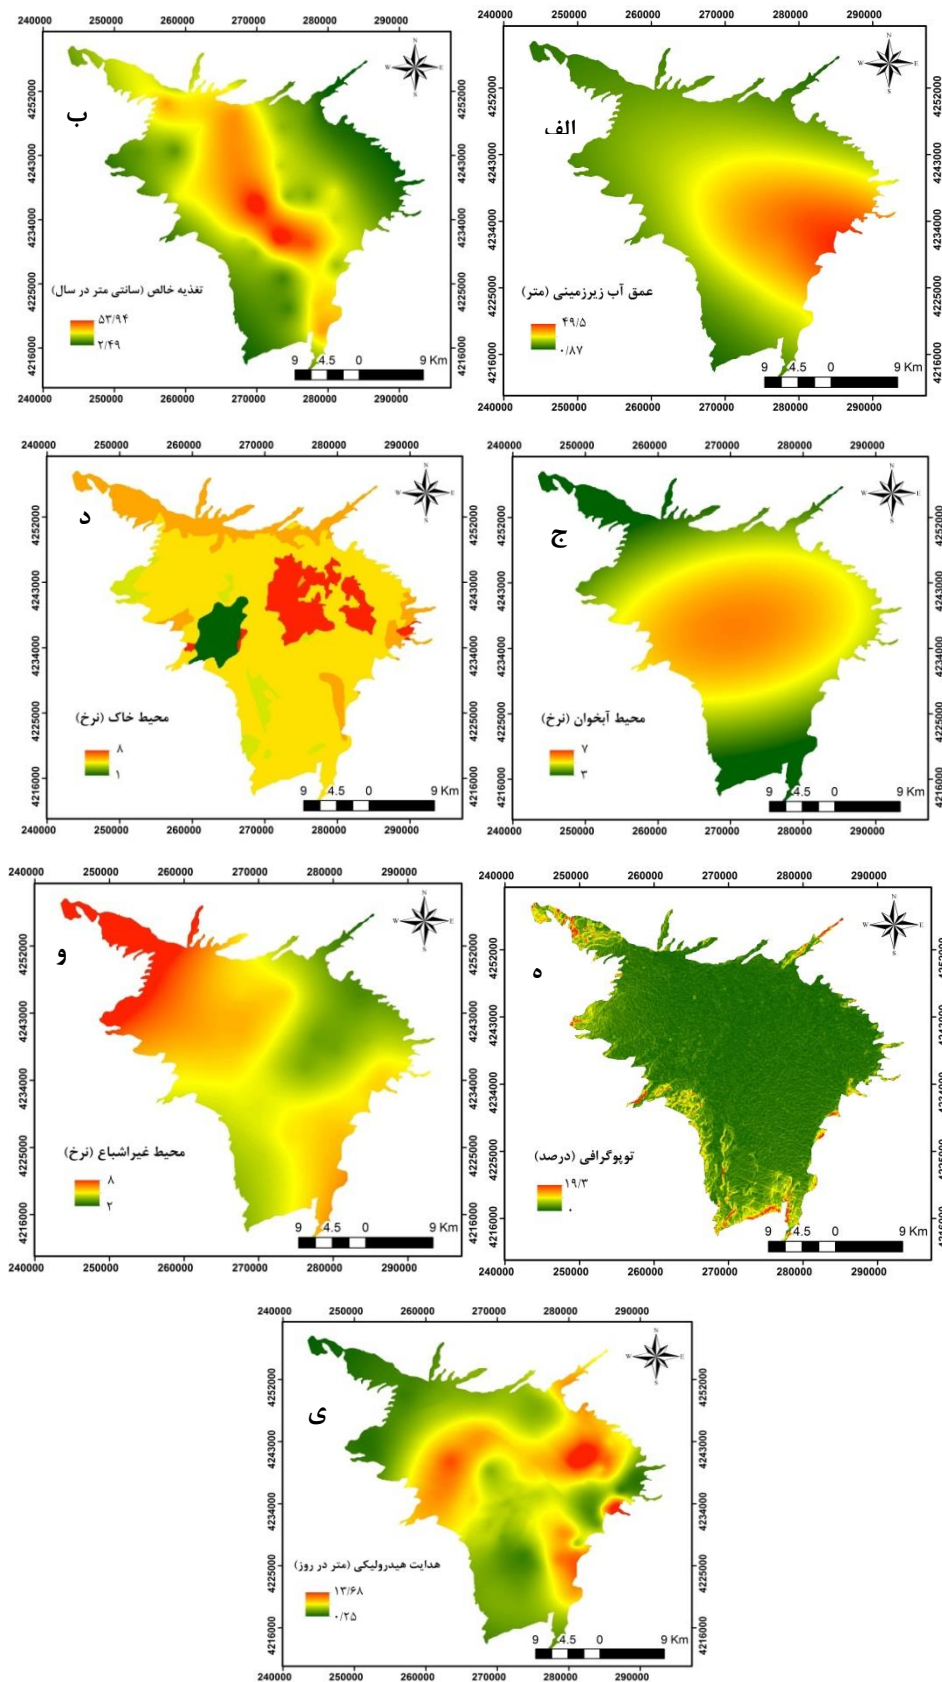
آبخوان و محیط غیراشباع مشخص شد. سپس با اعمال رتبه‌دهی و درون‌یابی لایه محیط آبخوان و محیط غیراشباع به دست آمد.

محیط خاک تأثیر مهمی در چگونگی تغذیه و متعاقب آن بر چگونگی حرکت آلاینده دارد. وجود مواد با بافت دانه‌درشت، نفوذپذیری خاک و در نتیجه قابلیت انتقال آلاینده‌ها به سیستم آب زیرزمینی را افزایش می‌دهند. برای تهیه این لایه، نقشه خاک منطقه رقومی و نقشه محیط خاک تهیه شد. لایه توپوگرافی به تغییرات شیب سطح زمین مربوط می‌شود. به طوری که افزایش شیب توپوگرافی موجب کاهش ماندگاری آب روی سطح زمین و کاهش نرخ نفوذ می‌شود. پس ناحیه با شیب کمتر، رتبه بیشتری در مدل خواهد داشت. برای تهیه این لایه از مدل ارتفاعی رقومی منطقه استفاده شد و سپس نقشه شیب از مدل ارتفاعی رقومی استخراج و رتبه‌دهی انجام شد. لایه هدایت هیدرولیکی مربوط به نفوذپذیری سفره یا توانایی مواد سفره به منظور انتقال آب یا مواد محلول است. بنابراین، هرچه هدایت هیدرولیکی آبخوان بیشتر باشد، امکان جریان یافتن آلاینده‌ها در آبخوان بیشتر خواهد بود. برای تهیه این لایه ابتدا به منظور محاسبه هدایت هیدرولیکی آبخوان از اطلاعات موجود در منطقه از جمله داده‌های قابلیت انتقال و ضخامت اشباع آبخوان استفاده شد و میزان هدایت هیدرولیکی به دست آمد. بدین ترتیب این اطلاعات به محیط اکسل وارد و سپس در نرم‌افزار ARC GIS با استفاده از روش Kriging درون‌یابی شد و رتبه‌دهی انجام گرفت و نقشه هدایت هیدرولیکی تهیه شد.



شکل ۴. توزیع مکانی غلظت نیترات در آب زیرزمینی منطقه مطالعاتی





شکل ۵. نقشه بهینه‌بندی پارامترهای مدل دراستیک: الف) عمق آب زیرزمینی؛ ب) تغذیه خالص؛ ج) محیط آبخوان؛ د) محیط خاک؛ ه) توپوگرافی؛ و) محیط غیراشباع؛ ز) هدایت هیدرولیکی

سیگموئید تانژانتی و در لایه چهارم خطی است. برای بخش شرقی تعداد دوره‌های آموزش ۵۶۶ و مقادیر  $R^2$  و RMSE برای مرحله آموزش به ترتیب ۰/۶۸ و ۱۱/۵۴ و برای بخش جنوبی با ۴۲۴ دوره آموزش مقادیر  $R^2$  و RMSE به ترتیب ۰/۷۳ و ۷/۶۴ به دست آمد. شبکه عصبی برگشتی برای بخش شرقی و جنوبی به ترتیب با دوره‌های آموزش ۱۱ و ۳۹ اجرا شد و مقادیر  $R^2$  و RMSE مرحله آموزش برای بخش شرقی ۰/۸۱ و ۹/۹۳ و برای بخش جنوبی ۰/۹۴ و ۳/۶۲ به دست آمد. براساس نتایج به دست آمده از این دو مدل که در جدول ۲ ارائه شده است، برای بخش غربی شبکه عصبی پیشرو و برای بخش‌های شرقی و جنوبی شبکه عصبی برگشتی نتایج بهتری ارائه دادند.

نتایج حاصل از مدل‌سازی با استفاده از ماشین بردار

#### پشتیبان

همان‌گونه که در بخش قبلی اشاره شد، مقادیر  $\gamma$  و  $\sigma$  از مهم‌ترین پارامترهای تعیین‌کننده ساختار یک مدل LS-SVM است. مقدار این دو پارامتر از طریق آزمون و خطا تعیین می‌شود که مقدار بهینه این دو پارامتر به گونه‌ای تعیین می‌شود که نتایج به دست آمده بیشترین ضریب همبستگی ( $r$ ) و کمترین مقدار خطا (RMSE) را داشته باشد.

در این مطالعه، ورودی‌ها و خروجی‌های ماشین بردار پشتیبان همانند شبکه عصبی به کار برده شد. همچنین ورودی‌ها و خروجی‌ها در مدل ماشین بردار پشتیبان برخلاف شبکه عصبی نیازی به نرمالیزه کردن داده‌ها ندارد. ماشین بردار پشتیبان برای هر سه بخش از دشت (شرقی، غربی و جنوبی) اجرا شد و مقادیر پارامترهای  $\gamma$  و  $\sigma$  به دست آمد که در جدول ۲ ارائه شده است. پس از اجرای مدل، مقادیر آسیب‌پذیری پیش‌بینی شده به وسیله مدل LS-SVM با مقادیر آسیب‌پذیری مشاهده شده مقایسه شد و  $R^2$  و RMSE محاسبه شد (جدول ۳).

جدول ۲. نتایج اجرای LS-SVM

پارامتر $\sigma$	پارامتر $\gamma$	
۳۲/۹	۱۹۸۹/۹	بخش غربی
۱/۱	۱۳۳/۶	بخش شرقی
۱/۵	۳۳۴/۱	بخش جنوبی

نتایج مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی در این پژوهش برای اجرای مدل‌های هوش مصنوعی به منظور ارزیابی آسیب‌پذیری به علت وسعت زیاد دشت و همچنین ناهمگنی موجود، دشت مطالعه شده به سه بخش (شرقی، غربی و جنوبی) تقسیم شد (شکل ۴) و برای هر بخش به طور جداگانه مدل‌های هوش مصنوعی استفاده شد. در روش‌های شبکه‌های عصبی پیشرو و برگشتی، هفت پارامتر مدل دراستیک به عنوان ورودی‌های مدل و شاخص آسیب‌پذیری به عنوان خروجی مدل انتخاب شد. برای اجرای مدل‌های هوش مصنوعی، ابتدا در مرحله آموزش طبق رابطه ۱۳ اقدام به تصحیح مقادیر آسیب‌پذیری (شاخص دراستیک) شد و سپس در مرحله آزمون با استفاده از مقادیر نیترا نتایج مدل‌ها ارزیابی شد [۲۰].

$$\frac{Vul_{max}}{(NO_r)_{max}} \times (NO_r)_i \quad (13)$$

در رابطه یادشده،  $Vul_{max}$  حداکثر بیشترین مقدار شاخص دراستیک،  $(NO_r)_{max}$  بیشترین غلظت نیترا و  $(NO_r)_i$  غلظت نیترا را نشان می‌دهد.

برای بخش غربی به منظور اجرای شبکه عصبی پیشرو از شبکه سه‌لایه با الگوریتم لئونبرگ-مارکوارت<sup>۱</sup> (LM) استفاده شد. براساس آزمون و خطا تعداد گره‌ها در لایه میانی ۲ و گره خروجی هم برابر ۱ انتخاب شد که منطبق بر تعداد پارامتر خروجی بود. تابع تبدیلگر در لایه دوم از نوع سیگموئید تانژانتی (Tansig) و در لایه سوم خطی (Purlin) است. تعداد دوره‌های آموزش ۱۰۰ بوده و مقادیر ضریب تبیین ( $R^2$ ) و RMSE برای مرحله آموزش به ترتیب ۰/۸۴ و ۴/۰۲ به دست آمد. برای مرحله آزمون، ضریب تبیین و RMSE به ترتیب برابر با ۰/۸۲ و ۷/۴۴ به دست آمد. در شبکه عصبی برگشتی با ۱۲۳ دوره آموزش مقادیر  $R^2$  و RMSE برای مرحله آموزش به ترتیب ۰/۹۶ و ۱/۷۶ و مقدار  $R^2$  و RMSE برای مرحله آزمون به ترتیب ۰/۶ و ۸/۱۳ به دست آمد.

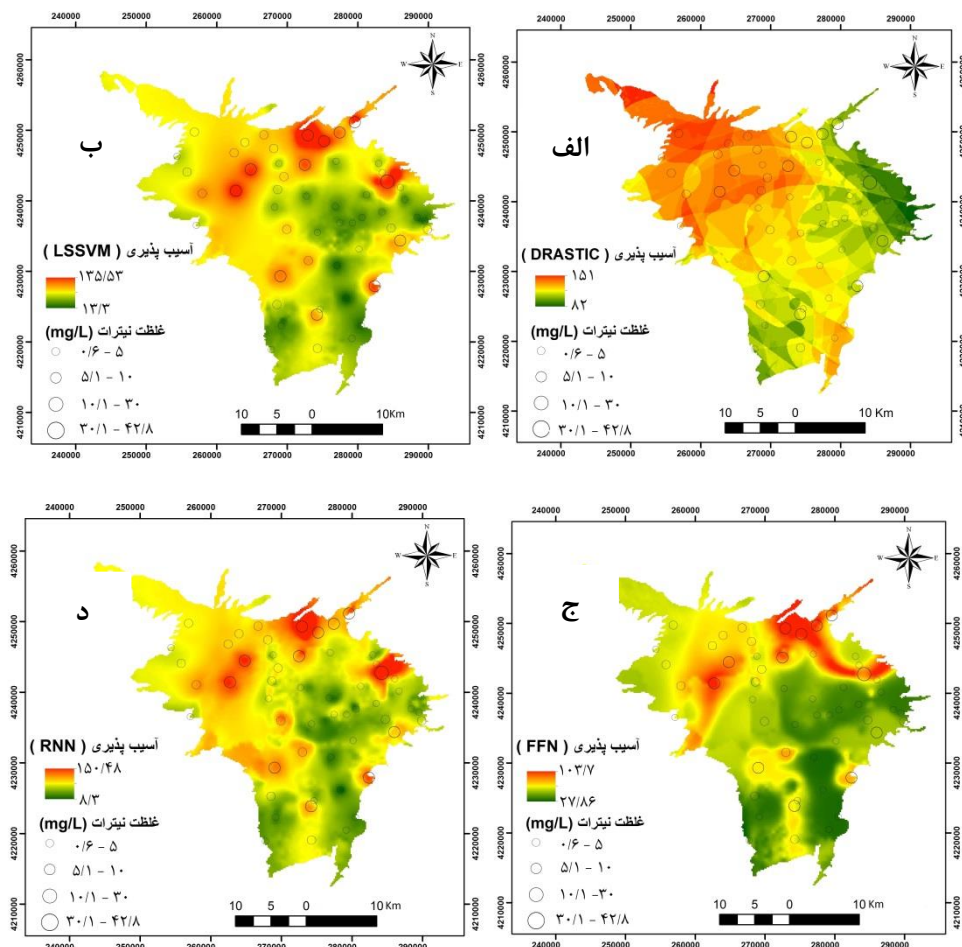
برای بخش شرقی و جنوبی نیز براساس روش آزمون و خطا مدل شبکه عصبی پیشرو با یک شبکه ۴ لایه انتخاب شد به طوری که تعداد گره‌ها در لایه‌های دوم و سوم و چهارم به ترتیب ۲ و ۲ و ۱ بود. تابع تبدیلگر در لایه دوم و سوم

جدول ۳. نتایج به‌دست‌آمده از مدل‌های مختلف هوش مصنوعی در مراحل آموزش و آزمون

نوع مدل			معیار ارزیابی	مراحل
LS-SVM	RNN	FFN		
۰/۲۳	۱/۷۶	۴/۰۲	RMSE	مرحله آموزش
۰/۱۳	۱/۳	۳/۰۶	MAE	
۰/۹۹	۰/۹۸	۰/۹۲	r	
۰/۹۸	۰/۹۶	۰/۸۴	R <sup>2</sup>	
۳/۹۳	۸/۱۳	۷/۴۴	RMSE	بخش غربی
۲/۵۴	۶/۱۲	۶/۸۴	MAE	
۰/۸۹	۰/۷۸	۰/۹۱	r	مرحله آزمون
۰/۷۹	۰/۶	۰/۸۲	R <sup>2</sup>	
۲/۳	۹/۹۳	۱۱/۵۴	RMSE	مرحله آموزش
۱/۳۵	۷/۷۱	۸/۵۸	MAE	
۰/۹۸	۰/۹	۰/۸۳	r	
۰/۹۶	۰/۸۱	۰/۶۸	R <sup>2</sup>	
۶/۷۴	۸/۹۱	۷/۲۸	RMSE	بخش شرقی
۵/۱۶	۷/۳۰	۶/۱۵	MAE	
۰/۸۶	۰/۸۳	۰/۷	r	مرحله آزمون
۰/۷۳	۰/۶۸	۰/۴۹	R <sup>2</sup>	
۱/۹۸	۳/۶۲	۷/۶۴	RMSE	مرحله آموزش
۱/۱	۲/۶۰	۶/۰۹	MAE	
۰/۹۸	۰/۹۷	۰/۸۶	r	
۰/۹۶	۰/۹۴	۰/۷۳	R <sup>2</sup>	
۳/۷۸	۴/۸۱	۵/۹۲	RMSE	بخش جنوبی
۳/۲۱	۴/۰۱	۴/۸۶	MAE	
۰/۸۵	۰/۸۵	۰/۸	r	مرحله آزمون
۰/۷۲	۰/۷۲	۰/۶۴	R <sup>2</sup>	

آلودگی بیشتر قرار گرفته‌اند، اما این انطباق در نقشه آسب‌پذیری حاصل از مدل LS-SVM نسبت به سایر روش‌ها بیشتر است و هیچ چاه آبی با غلظت نیترات زیاد در منطقه با خطر آلودگی کم قرار ندارد، بلکه در محدوده با خطر آلودگی بیشتر قرار دارند. ضریب تبیین ( $R^2$ ) برای مدل‌های حداقل مربعات ماشین بردار پشتیبان، شبکه عصبی پیشرو و برگشتی برای کل دشت اردبیل به ترتیب ۰/۹۷، ۰/۷۶ و ۰/۸۶ به‌دست آمد. با توجه به جدول ۳، مدل حداقل مربعات ماشین بردار پشتیبان بیشترین ضریب تبیین و همچنین کمترین RMSE را نسبت به سایر روش‌ها دارد. بنابراین، نتایج نشان داد که مدل LS-SVM کارایی بیشتری در تخمین آسب‌پذیری آبخوان دشت اردبیل دارد. براساس این مدل، حدود ۵۵ درصد منطقه مطالعاتی در دسته آسب‌پذیری خیلی کم، ۳۶/۳ درصد و ۸/۷ درصد به ترتیب در دسته آسب‌پذیری کم و متوسط قرار می‌گیرند.

نتایج به‌دست‌آمده از مدل‌های مختلف هوش مصنوعی که در جدول ۳ ارائه شده است، نشان می‌دهد که همه مدل‌های هوش مصنوعی به‌کار برده‌شده در این پژوهش به‌منظور ارزیابی آسب‌پذیری قابل‌کاربرد هستند. از بین ۳ مدل ارائه‌شده برای بهینه‌سازی مدل دراستیک، مدل حداقل مربعات ماشین بردار پشتیبان (LS-SVM) کمترین خطا (RMSE) را دارد که این به‌علت دقت محاسباتی زیاد این روش است که به خطای کمتر منجر می‌شود. نقشه‌های آسب‌پذیری تهیه‌شده با استفاده از مدل‌های دراستیک اصلی و اصلاح‌شده به همراه غلظت نیترات چاه‌های اندازه‌گیری شده در شکل ۶ نشان داده شده است. دایره‌های توخالی موقعیت و غلظت نیترات را در منطقه نشان می‌دهد که برای صحت‌سنجی استفاده شده است. با انطباق مقادیر یون نیترات بر روی هر یک از نقشه‌های آسب‌پذیری مشاهده شد که در همه روش‌ها بیشتر نقاط با نیترات زیاد در محدوده با خطر



شکل ۶. نقشه آسیب‌پذیری آب زیرزمینی: الف) مدل DRASTIC؛ ب) مدل LSSVM؛ ج) مدل FFN؛ د) مدل RNN

### نتیجه‌گیری

هدف از انجام این پژوهش، تعیین آسیب‌پذیری ذاتی آبخوان دشت اردبیل با استفاده از مدل دراستیک و سپس بهینه‌سازی آن با استفاده از مدل هوش مصنوعی بوده است. دشت اردبیل از مناطق فعال کشاورزی است که در آن از کودهای کشاورزی زیاد استفاده می‌شود این مواد به همراه پساب‌ها و فاضلاب‌های حاصل از منطقه، آب‌های زیرزمینی را بیشتر در معرض خطر آلودگی قرار می‌دهد. بنابراین، ارزیابی آسیب‌پذیری آبخوان این دشت و تعیین مناطق با پتانسیل زیاد آلودگی ضرورت دارد. در همین راستا هفت پارامتر مؤثر در آسیب‌پذیری آب زیرزمینی به‌صورت هفت لایه رستری تهیه شد و شاخص آسیب‌پذیری برای منطقه بین ۸۲ تا ۱۵۱ محاسبه شد. سپس بهینه‌سازی مدل دراستیک با استفاده از مدل‌های شبکه عصبی پیش‌رو، شبکه عصبی برگشتی و حداقل مربعات ماشین بردار پشتیبان انجام گرفت. برای این

منظور، به‌علت وسعت زیاد دشت اردبیل و همچنین ناهمگنی موجود، این دشت به سه بخش تقسیم شد و برای هر یک مدل‌های هوش مصنوعی اجرا شد، که در مطالعات مشابه [۱۰، ۲۰] به این مورد توجه نشده بود در حالی که اجرای مدل برای بخش‌های مختلف دشت نسبت به اجرای مدل برای کل دشت نتایج بهتری داشت. نتایج حاصل از این مطالعه نشان داد که هر یک از مدل‌های هوش مصنوعی به‌تنهایی بهتر از مدل دراستیک، آسیب‌پذیری منطقه را پیش‌بینی کرده و همبستگی زیادی با مقادیر نیترات دارند، اما از بین این مدل‌ها، مدل LS-SVM بیشترین ضریب همبستگی و کمترین خطا را دارد، که این خطای کم به‌علت برتری محاسباتی این روش نسبت به سایر روش‌هاست. نتایج مطالعه انجام‌شده توسط دیکسون در سال ۲۰۰۹ به‌منظور شناسایی چاه‌های آلوده‌شده با نیترات با استفاده از ANN و SVM بیانگر عملکرد بهتر روش SVM نسبت به روش ANN است

- [8]. Asefa, Tirusew; Kemplowski, Mariush; McKee, Mac; Khalil, Abedalrazq; 2006, Multi-time scale stream flow predictions: The support vector machines approach, *Journal of Hydrology*, 318, pp. 7–16.
- [9]. Babiker, Insaf, S; Mohamed, Mohamed, A.A; Tetsuya, Hiyama; and Kikuo, Kato; 2005, A GIS-based DRASTIC model for assessing aquifer vulnerability in Kakamigahara Heights, Gifu Prefecture, central Japan, *Sci Total Environ*, vol 354, pp. 127–140.
- [10]. Barzegar, Rahim; Asghari Moghaddam, Asghar; Baghban, Hamed; 2015, A supervised committee machine artificial intelligent for improving DRASTIC method to assess groundwater contamination risk: a case study from Tabriz plain aquifer, Iran, *Stoch Environ Res Risk Assess*.
- [11]. Behzad, Mohsen; Asghari, Keyvan; and Coppola, Jr, Emery, A.; 2010, Comparative Study of SVMs and ANNs in Aquifer Water Level Prediction. *J. Comput. Civ. Eng.*, vol 24, pp. 408-413.
- [12]. Chen, Bo. Juen; Chang, Ming. Wei; and Lin, Chih. Jen; 2004, Load forecasting using Support Vector Machines: A study on EUNITE Competition 2001, *IEEE Transactions on Power Systems*, 19(4). pp. 1821–1830.
- [13]. Chitsazan, Nima ; Nadiri, Ata Allah; Tsai, Frank, T-C, 2015, Prediction and structural uncertainty analyses of artificial neural networks using hierarchical Bayesian model averaging, *Journal of Hydrology*, 528, pp. 52-62.
- [14]. Cortes, Corinna; and Vapnik, Vladimir; 1995, Support-vector networks. *Machine learning*, 20: 3, pp. 273-297.
- [15]. Cristianini, Nello; and Shawe-Taylor, John; 2000, *An Introduction to Support Vector Machines*. Cambridge University Press, New York, USA.
- [16]. Dibike, Yonas, B; Velickov, Slavco; Solomatine, Dimitri; and Abbot, Michael, B; 2001, Model Induction with Support Vector Machines-Introduction and Applications. *J. Comp. Civil Engin.* ASCE, vol 15, pp. 208-216.
- [17]. Dixon, Barnali; 2005a, Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a GIS-based sensitivity analysis, *Journal of Hydrology*, vol 309, pp. 17-38.
- [18]. Dixon, Barnali; 2009, A case study using support vector machines, neural networks and logistic regression in a GIS to identify wells contaminated with nitrate-N, *Hydrogeology Journal*, vol 17, pp. 1507–1520.
- [۱۸]. همچنین سایر مطالعات انجام شده در زمینه هیدرولوژی و هیدروژئولوژی کاربری زیاد ماشین‌های بردار پشتیبان را نسبت به سایر روش‌های هوش مصنوعی نشان می‌دهد که در راستای نتایج پژوهش حاضر است [۸، ۱۱، ۲۷، ۳۳]. بنابراین، LS-SVM به‌عنوان بهترین مدل برای بهینه‌سازی مدل دراستیک به‌منظور ارزیابی آسیب‌پذیری آبخوان دشت اردبیل معرفی شد. براساس این مدل بیشتر قسمت‌های شمال و غرب دشت اردبیل دارای پتانسیل آلودگی بیشتری نسبت به سایر مناطق است و باید محافظت بیشتری از این مناطق صورت گیرد.

### منابع

- [۱]. فرج‌زاده اصل، منوچهر؛ محمدی، عثمان؛ ۱۳۹۰، «پهنه‌بندی آسیب‌پذیری آب‌های زیرزمینی با کمک الگوریتم‌های فازی عصبی (مطالعه موردی: استان زنجان)»، *سنجش از دور و GIS ایران*، سال سوم، شماره اول، ص ۱-۱۸.
- [۲]. کرد، مهدی؛ ۱۳۹۳، «مدل‌سازی عددی آبخوان دشت اردبیل و مدیریت آن با استفاده از بهینه‌سازی برداشت آن»، رساله دکتری، دانشگاه تبریز.
- [۳]. ندیری، عطاالله؛ ۱۳۹۲، «مقایسه کارایی مدل‌های عددی و هوش مصنوعی در مدیریت آبخوان‌ها (مطالعه موردی: دشت تسوج)»، رساله دکتری، دانشگاه تبریز.
- [4]. Al-Abadi, Alaa M; Al-Shamma'a, Ayser M; Aljabbari, Mukdad H; 2014, A GIS-based DRASTIC model for assessing intrinsic groundwater vulnerability in northeastern Missan governorate, southern Iraq, *Appl Water Sci*.
- [5]. Aller, Linda; Bennett, Truman; Lehr, Jay.H; Petty, Rebecca.; and Hackett, Glen; 1987, DRASTIC: A Standardized System for Evaluating Ground Water Pollution Potential Using Hydrogeologic Settings, EPA 600/2-87-035. U.S. Environmental Protection Agency, Ada, Oklahoma.
- [6]. Antonakos, Andreas.K; and Lambrakis, Nikolaos. I; 2007, Development and testing of three hybrid methods for the assessment of aquifer vulnerability to nitrates based on the drastic model, an example from NE Korinthia, Greece, *Journal of Hydrology*, pp. 288– 304.
- [7]. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000, *Artificial neural network in hydrology*, part I and II. *J. Hydrol. Eng.*, 5(2), pp. 115-137.

- [19]. Fausett, Laurene; 1994, Fundamentals of neural network. Prentice Hall, Englewood Cliffs, N. J. 461 Pages.
- [20]. Fijani, Elham; Nadiri, Ata. Allah; Asghari, Moghaddam, Asghar; Tsai, Frank, T-C; and Dixon, Barnali; 2013, Optimization of DRASTIC Method by Supervised Committee Machine Artificial Intelligence to Assess Groundwater Vulnerability for Maragheh-Bonab Plain Aquifer, Iran, Journal of hydrology, vol 530, pp. 89-100.
- [21]. Haykin, Simon; 1994, Neural networks: a comprehensive foundation, Macmillan College Publishing, New York.
- [22]. Hong, Wei, Chiang; 2011, Traffic flow forecasting by seasonal SVR with chaotic simulated annealing algorithm, Neurocomputing, Vol 74, pp. 2096-2107.
- [23]. Jovanovic, N. Z; Adams S; Thomas A; Fey M; Beekman H. E; Campbell R; Saayman I; Conrad J; 2006, Improved DRASTIC method for assessment of groundwater vulnerability to generic aqueous phase contaminants, WIT Transactions on Ecology and the Environment, Vol 92, waste Management and the Environment III, pp. 393-402.
- [24]. McCulloch, Warren, S; Pitts, Walter; 1943, A logic calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, vol 5, pp. 115-133.
- [25]. McLay, C.D.A., Dragten, R., Sparling, G., and Selvarajah, N., 2001, Predicting groundwater nitrate concentrations in a region of mixed agricultural land use: a comparison of three approaches, Environmental Pollutants, vol 115, pp. 191-204.
- [26]. Mohammadi, Kourosh; Niknam, Ramin; and Majd, Vahid, Johari; 2009, Aquifer vulnerability assessment using GIS and fuzzy system: a case study in Tehran-Karaj aquifer, Iran, Environ Geol, vol 58, pp. 437-446.
- [27]. Mousavi, S.F. Amiri, M.J. Gohari, A.R. and Afyuni, M. 2011, Estimation of Nitrate Concentration Using Fuzzy Regression Method and Support Vector Machines, World Applied Sciences Journal, 12 (6), pp. 774-782.
- [28]. Nadiri, Ata Allah; Fijani, Elham; Asghari Moghaddam, Asghar; 2013, Supervised committee machine with artificial intelligence for prediction of fluoride concentration, IWA Publishing.
- [29]. Panagopoulos, George; Antonakos, Andreas; and Lambrakis, Nicolaos; 2005, Optimization of DRASTIC model for groundwater vulnerability assessment, by the use of simple statistical methods and GIS, Hydrogeology Journal.
- [30]. Raghavendra, Sujay; and Chandra, Deka, Pares; 2014, Support vector machine applications in the field of hydrology: A review, Elsevier, Applied Soft Computing, vol 19, pp. 372-386.
- [31]. Secunda, S., Collin, M.L., and Melloul, A.J., 1998, Groundwater vulnerability assessment using a composite model combining DRASTIC with extensive agricultural land use in Israel's Sharon region, Journal of Environmental Management, vol 54, pp. 39-57.
- [32]. Seifi, Akram; 2010, Developing of expert system to prediction of daily evapotranspiration by support vector machine and compare results to ANN, ANFIS and experimental method. M.Sc. Thesis, Department of Water Engineering, Tarbiat Modarres University, Tehran, Iran (In Persian).
- [33]. Shabri, Ani; and Suhartono; 2012, Streamflow forecasting using least-squares support vector machines, Hydrological Sciences journal, 57(7), pp. 1275-1293.
- [34]. Suykens, Johan, A, K; Van, Gestel, Tony; Brabanter, Jos, De; De, Moor, Bart; Vandewalle, Joos; 2002, in: Least Squares Support Vector Machines, World Scientific Publishing, Singapore.
- [35]. Tayfur, Gokmen; Nadiri, Ata Allah; Asghari Moghaddam, Asghar; 2014, Supervised intelligent committee machine method for hydraulic conductivity estimation, Water resources management, 28 (4), pp. 1173-1184.
- [36]. Vrba, Jiri; and Zoporozec, Alexander; 1994, Guidebook on mapping groundwater vulnerability, International Contributions to Hydrogeology, Verlag Heinz Heise GmbH and Co, KG.
- [37]. Yin, Jiajian; 2011, LogP prediction for blocked tripeptides with amino acids descriptors (HMLP) by multiple linear regression and support vector regression, Procedia Environmental Sciences, vol 8, pp. 173-178.