

# استفاده از مدل هوش مصنوعی مرکب نظارت شده برای بهبود مدل دراستیک (مطالعه موردی: آبخوان دشت اردبیل)

مریم قره‌خانی<sup>۱</sup>، عطاالله ندیری<sup>۲\*</sup> و اصغر اصغری مقدم<sup>۳</sup>

<sup>۱</sup>دانشجوی دکترا، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

<sup>۲</sup>استادیار، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

<sup>۳</sup>استاد، دانشکده علوم طبیعی، دانشگاه تبریز، تبریز، ایران

تاریخ دریافت: ۱۳۹۵/۰۲/۱۱ تاریخ پذیرش: ۱۳۹۵/۰۵/۲۵

## چکیده

آلودگی منابع آب زیرزمینی به علت نفوذ آلاینده‌ها از سطح زمین به سامانه آب زیرزمینی به‌ویژه در مناطق خشک و نیمه‌خشک که با کمبود کمی و کیفی منابع آب روبه‌رو هستند؛ یکی از معضلات جدی به شمار می‌آید. بنابراین ارزیابی آسیب‌پذیری آب زیرزمینی به منظور شناسایی مناطق دارای پتانسیل بالای آلودگی برای مدیریت منابع آب زیرزمینی ضروری است. در این پژوهش آسیب‌پذیری آبخوان دشت اردبیل در برابر آلودگی با استفاده از روش دراستیک مورد بررسی قرار گرفت. در مدل دراستیک هفت متغیر مؤثر در آسیب‌پذیری که شامل ژرفای آب زیرزمینی، تغذیه خالص، محیط آبخوان، محیط خاک، توپوگرافی، محیط غیر اشباع و هدایت هیدرولیکی است؛ به‌صورت هفت لایه رستری تهیه شد و پس از رتبه‌دهی و وزن‌دهی شاخص دراستیک به دست آمد که برای دشت اردبیل شاخص دراستیک میان ۸۲ تا ۱۵۱ به دست آمد. اما از آنجایی که مشکل اصلی این مدل اعمال‌نظرهای کارشناسی برای رتبه‌دهی و وزن‌دهی متغیرهای به کار رفته در آن است؛ بنابراین هدف اصلی این پژوهش بهبود مدل دراستیک با استفاده از ۵ روش هوش مصنوعی از جمله شبکه عصبی پیشرو، شبکه عصبی برگشتی، فازی ساجنو، فازی ممدانی و مدل مرکب است. تا بدین روش بتوان به نتایج دقیق‌تری از ارزیابی آسیب‌پذیری دست یافت. با توجه به ناهمگنی موجود در دشت اردبیل این دشت به سه بخش خاوری، باختری و جنوبی تقسیم و مدل‌های هوش مصنوعی به‌طور جداگانه برای هر بخش اجرا شد. به این منظور متغیرهای دراستیک به عنوان ورودی مدل و شاخص دراستیک به عنوان خروجی مدل تعریف شدند و مقادیر نیترا مربوطه به ۲ دسته آموزش و آزمایش تقسیم شد. شاخص دراستیک مربوط به مرحله آموزش با مقادیر نیترا مربوطه تصحیح و پس از آموزش مدل، در مرحله آزمایش نتایج مدل‌ها با استفاده از مقادیر نیترا ارزیابی شد. نتایج نشان داد که همه روش‌های هوش مصنوعی توانایی بالایی در بهبود مدل دراستیک دارند؛ اما در این میان، مدل هوش مصنوعی مرکب (SCMAI) نتایج بهتری را دربر داشت. بر پایه این مدل، بخش‌های باختری و شمالی دشت پتانسیل آلودگی بالایی دارد و باید محافظت بیشتری از این مناطق صورت گیرد.

**کلیدواژه‌ها:** آسیب‌پذیری، دشت اردبیل، دراستیک، هوش مصنوعی، مدل SCMAI

**\*نویسنده مسئول:** عطاالله ندیری

E-mail: nadiri@tabrizu.ac.ir

## ۱- پیش‌نوشتار

زیرزمینی بخشی از مدیریت آب‌های زیرزمینی در بسیاری از مناطق جهان به شمار می‌رود.

تاکنون روش‌های مختلفی برای ارزیابی آسیب‌پذیری ارائه و در همه روش‌ها آسیب‌پذیری آبخوان بر پایه انتقال آلودگی از سطح زمین به لایه آبدار برآورد شده است. روش دراستیک یکی از متداول‌ترین روش‌های مورد استفاده برای ارزیابی آسیب‌پذیری آب زیرزمینی است (Aller et al., 1987). مدل دراستیک بر پایه هفت متغیر آب‌زمن‌شناختی مؤثر در آسیب‌پذیری از جمله ژرفای آب زیرزمینی، تغذیه خالص، محیط آبخوان، محیط خاک، توپوگرافی، تأثیر ناحیه غیراشباع و هدایت هیدرولیکی است. از مزایای مدل دراستیک می‌توان به هزینه و تعداد داده‌های کم اشاره کرد. اما ضعف اصلی این مدل، اعمال نظرهای کارشناسی برای وزن و رتبه‌دهی متغیرهای به کار رفته در آن است.

به منظور بهبود مدل دراستیک تاکنون روش‌های مختلفی ارائه شده است؛ از جمله Panagopoulos et al. (2005) به منظور بهینه‌سازی مدل دراستیک از روش‌های آماری استفاده کرده‌اند. در برخی از مطالعات نیز از متغیرهای اضافی مانند کاربری زمین‌ها و نوع و شدت آبیاری برای بهبود مدل دراستیک استفاده شده است (Dixon (2005), Secunda et al., 1998; McLay et al., 2001). به منظور پیش‌بینی آسیب‌پذیری آب زیرزمینی برای زیرحوضه انتخاب شده از حوضه رودخانه Illinois در شمال باختری آرکانزاس، از روش نروفازی استفاده و حساسیت مدل نروفازی را با تلفیق روش‌های GIS و نروفازی بررسی کرد. همچنین در پژوهش دیگری، با استفاده از روش‌های منطق فازی آسیب‌پذیری آبخوان نسبت به آلودگی در مقیاس منطقه‌ای پیش‌بینی شد (Dixon et al., 2002). نیک‌نام و همکاران (۱۳۸۶)

در سال‌های اخیر افزایش مصرف آب و پرهزینه بودن گسترش منابع آب سطحی، منجر به فشارهای مضاعفی به منابع آب زیرزمینی شده است. در شرایط کنونی بخش قابل ملاحظه‌ای از مصارف آب به‌ویژه در بخش آشامیدنی، توسط منابع آب زیرزمینی تأمین می‌شود که بیشتر از آبخوان‌های آزاد است. این در حالی است که این آبخوان‌ها آسیب‌پذیری و حساسیت بیشتری در برابر آلاینده‌های ناشی از فعالیت‌های کشاورزی، صنعتی و شهری دارند. در بسیاری از موارد آلودگی آب زیرزمینی پس از آلوده شدن چاه‌های آب آشامیدنی شناسایی می‌شود. در صورت آلوده شدن آب زیرزمینی، رفع آلودگی بسیار پرهزینه و فرایندی طولانی است. بنابراین با توجه به بالا بودن هزینه‌های پالایش آب‌های آلوده و محدودیت‌های موجود بهترین راه حل، جلوگیری از آلودگی منابع آب زیرزمینی است که این امر با شناسایی مناطق آسیب‌پذیر آبخوان مقدور است.

مفهوم آسیب‌پذیری برای اولین بار در اواخر سال ۱۹۶۰ میلادی در فرانسه برای آگاهی‌بخشی در مورد آلودگی آب زیرزمینی ارائه شده است (Vrba and Zopozec, 1994). آسیب‌پذیری را می‌توان به عنوان امکان نفوذ و پخش آلاینده‌ها از سطح زمین به سامانه آب زیرزمینی تعریف کرد. آسیب‌پذیری آبخوان، نیروی آن را برای نفوذ و پخش آلاینده‌ها از سطح زمین به سامانه آب زیرزمینی نشان می‌دهد؛ به‌گونه‌ای که آلودگی تولید شده در سطح زمین بتواند به آب زیرزمینی برسد و در آن پراکنده شود (Babiker et al., 2005). آسیب‌پذیری نوعی ویژگی نسبی بدون بعد و غیر قابل اندازه‌گیری است و به ویژگی‌های آبخوان محیط زمین‌شناختی و آب‌زمن‌شناختی (هیدروژئولوژیک) بستگی دارد (Antonakos and Lambrakis, 2007). ارزیابی آسیب‌پذیری برای آلودگی آب‌های

در رابطه بالا،  $DI$  شاخص آسیب پذیری دراستیک و حروف بزرگ نشان دهنده متغیرهای هفت گانه و  $T$  نرخ ارزش (رتبه) و  $W$  وزنی است که به هر متغیر تخصیص داده می شود.

### ۳-۲. شبکه های عصبی مصنوعی (ANN)

شبکه های عصبی مصنوعی یک سامانه پردازش اطلاعات توده ای هستند که به صورت موازی قرار گرفته اند و ویژگی های عملکردی خاص شبیه شبکه های عصبی زیستی مغز انسان دارند (Haykin, 1994). شبکه های عصبی مصنوعی بر پایه قوانین زیر گسترش یافته اند:

- ۱) پردازش اطلاعات در واحدهای منفردی به نام گره صورت می گیرد؛
- ۲) سیگنال های میان گره ها از راه خطوط ارتباطی انتقال می یابند؛
- ۳) هر خط ارتباطی یک وزنی نسبت داده شده که نشان دهنده قدرت ارتباطی آن خط است؛
- ۴) هر گره به طور معمول دارای توابع فعال سازی و تبدیل گر به منظور تعیین سیگنال های خروجی از داده های ورودی شبکه است (ندیری و همکاران، ۱۳۹۲).

یک شبکه عصبی به وسیله الگوی ارتباطی میان گره ها، روش تعیین وزن های ارتباطی و تابع فعال سازی مشخص می شود (Fausett, 1994). یک شبکه عصبی به طور معمول شامل شماری از گره ها است که با آرایش خاصی قرار گرفته اند. یکی از روش های رده بندی شبکه های عصبی بر پایه شمار لایه ها است که به سه نوع تک لایه ای، دو لایه ای و چند لایه ای تقسیم می شوند. شبکه های عصبی مصنوعی همچنین بر پایه سوی جریان و پردازش اطلاعات به دو دسته، شبکه های پیشرو و شبکه های برگشتی تقسیم می شوند. در شبکه های عصبی پیشرو گره های پردازش گر در لایه های مخفی قرار دارند و هر شبکه می تواند چندین لایه مخفی و هر لایه مخفی می تواند یک یا بیش از یک گره داشته باشد. در شبکه های پیشرو اطلاعات از ورودی به سوی خروجی حرکت می کند. گره های یک لایه با گره های لایه دیگر در ارتباط هستند؛ اما با گره های موجود در همان لایه ارتباط ندارند. بنابراین خروجی هر گره در یک لایه تنها به ورودی های دریافتی از لایه های پیش و وزن های مربوطه وابسته است. در شبکه های عصبی برگشتی اطلاعات میان گره ها در دو سو، از ورودی به سوی خروجی و وارون جریان می یابند. این نوع شبکه از خروجی ها به عنوان ورودی های جدید استفاده می کند؛ بنابراین به داده ها اجازه برگشت به ورودی را می دهد (ASCE, 2000).

ساختار عادی یک شبکه عصبی مصنوعی معمولاً از لایه ورودی، لایه های میانی (مخفی) و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله ای برای تهیه کردن داده ها است. آخرین لایه یا لایه خروجی شامل مقادیر پیش بینی شده به وسیله شبکه است و خروجی مدل را معرفی می کند. لایه های میانی یا مخفی که از گره های پردازشگر تشکیل شده اند، محل پردازش داده ها هستند. شمار لایه های مخفی و شمار گره ها در هر لایه مخفی معمولاً با استفاده از روش آزمون و خطا تعیین می شود. گره های لایه های مجاور به طور کامل با هم در ارتباط هستند (ندیری، ۱۳۸۶). شکل ۲ ساختار یک شبکه عصبی مصنوعی را نشان می دهد که از ۷ گره در لایه ورودی، ۲ گره در لایه میانی و ۱ گره در لایه خروجی تشکیل شده است.

### ۳-۳. منطق فازی (FL)

تئوری فازی برای اولین بار توسط Zadeh (1965) در مقاله ای با عنوان مجموعه های فازی ارائه شد. تئوری فازی، شامل همه تئوری هایی است که از مفاهیم بنیادین مجموعه های فازی یا توابع عضویت استفاده می کند. منطق فازی به عنوان جایگزینی برای توضیح عدم قطعیت مورد استفاده قرار گرفته است. مجموعه های فازی مرزهایی مبهم و تدریجی میان مرزهای تعریف شده دارند؛ که برای برابری با ماهیت عدم قطعیت در سامانه و خطاهای انسانی مناسب هستند (Pulido Calvo and Gutiérrez-Estrada, 2009; Tayfur et al., 2014).

در همه روش های ارزیابی آسیب پذیری، عدم قطعیت امری ذاتی است که این عدم قطعیت ها به علت خطای اطلاعاتی و متغیر بودن متغیرهای آب زمین شناختی نسبت به

آسیب پذیری سفره آب زیرزمینی تهران - کرج را با استفاده از روش های دراستیک و منطق فازی بررسی کردند. مطالعه ای نیز در زمینه بهینه سازی مدل دراستیک توسط Fijani et al., (2013) انجام شده است که به منظور ارزیابی آسیب پذیری آب زیرزمینی آبخوان دشت مراغه - بناب بهینه سازی مدل دراستیک را با استفاده از هوش مصنوعی مرکب نظارت شده انجام داده اند.

در این پژوهش نیز برای بهبود مدل دراستیک از ترکیب جدیدی از مدل های هوش مصنوعی استفاده شده است که با پژوهش های پیشین متفاوت بوده و تا حال به کار گرفته نشده است. منطقه مطالعاتی در این پژوهش، دشت اردبیل است که از مناطق فعال کشاورزی، دامداری و صنعت است که در آن از کودهای کشاورزی زیاد استفاده می شود. این مواد به همراه پساب ها و فاضلاب های حاصل از منطقه می توانند آب های زیرزمینی را آلوده سازند؛ بنابراین ارزیابی آسیب پذیری آبخوان این دشت ضرورت دارد.

### ۲- منطقه مورد مطالعه

محدوده مطالعاتی مورد نظر آبخوان دشت اردبیل است. همان گونه که در شکل ۱ دیده می شود؛ دشت اردبیل در شمال باختر ایران و در استان اردبیل قرار دارد. این دشت توسط ارتفاعات که بخشی از رشته کوه البرز هستند، دربر گرفته شده است و گسترشی در حدود ۹۹۰ کیلومتر مربع دارد. تقریباً ۵۶۴۰۰۰ نفر در دشت اردبیل زندگی می کنند که در دو شهر و ۸۸ روستا ساکن هستند. حوضه آبریز دشت اردبیل در محدوده طول خاوری ۴۸° ۴۰' تا ۴۸° ۰۰' و عرض شمالی ۳۸° ۳۰' تا ۳۸° ۰۰' قرار گرفته است. دشت اردبیل دشتی به نسبت هموار است که از پیرامون توسط کوه های بزقوش، تالش و سبلان دربر گرفته شده است و تنها خروجی منابع آبی دشت در منتهی الیه شمال باختری آن قرار دارد. بیشترین ارتفاع مربوط به قله سبلان با ارتفاع ۴۸۱۰ متر از سطح دریا و کمترین ارتفاع مربوط به ناحیه خروجی در شمال باختری دشت با ارتفاع ۱۱۷۰ متر از سطح دریاست. این دشت دارای سه رودخانه اصلی قره سو، بالخلوچای و قوری چای است. نوران چای، هیرچای و شهریورچای نیز از دیگر رودهای این دشت هستند. بر پایه داده های حاصل از ایستگاه سینوپتیک اردبیل در بازه زمانی ۱۳۵۵-۱۳۸۵، بیشترین بارش در محدوده مطالعاتی در اردیبهشت ماه و کمترین آن مربوط به مرداد ماه و متوسط بارش سالانه در منطقه ۳۰۳/۱ میلی متر است. بیشترین و کمترین دما به ترتیب ۳۹/۸ و ۳۳/۸- درجه سانتی گراد و میانگین دمای سالانه ۹/۰ درجه سانتی گراد بوده است (کرد، ۱۳۹۳).

### ۳- روش شناسی

#### ۳-۱. مدل دراستیک

مدل دراستیک یک مدل کمی است که برای برآورد پتانسیل آلودگی سامانه آب زیرزمینی در یک مقیاس ناحیه ای طراحی شده است. بر پایه آن متغیرهای مختلف آب زمین شناختی تأثیر گذار در انتقال آلودگی با یک ضریب وزنی و یک ضریب ارزش با یکدیگر جمع می شوند و در پایان نقشه آسیب پذیری ارائه می شود (اصغری مقدم و همکاران، ۱۳۸۸). این مدل بر پایه ۷ متغیر آب زمین شناختی است که شامل ژرفای آب زیرزمینی (D)، تغذیه (R)، محیط آبخوان (A)، محیط خاک (S)، توپوگرافی (T)، تأثیر ناحیه غیر اشباع (I) و ضریب هدایت هیدرولیکی (C) است. اطلاعات حاصل از این متغیرها به صورت تلفیقی تجزیه و تحلیل و سپس توسط سامانه اطلاعات جغرافیایی (GIS) پردازش می شوند. در روش دراستیک به هر متغیر یک رتبه و یک وزن (از ۱ تا ۵) برحسب اهمیت متغیر اختصاص داده می شود. رتبه متغیرهای دراستیک میان ۱ تا ۱۰ است؛ به گونه ای که ۱ به معنای کمترین و ۱۰ بیشترین خطر برای آلودگی آب زیرزمینی در نظر گرفته می شود (Panagopoulos et al., 2005). از این رو شاخص دراستیک بر پایه وزنی به مجموع ۷ متغیر با فرمول ۱ به دست می آید (Aller et al., 1987).

$$DI = D_r D_w + R_r R_w + A_r A_w + S_r S_w + T_r T_w + I_r I_w + C_r C_w \quad (1)$$

توابع فعال‌سازی برای  $f_1$  از نوع سیگموئید تاژناتی (tansig) و برای  $f_2$  از نوع خطی (purelin) هستند؛  $O_k$  یا  $Vul_{SCMAI}$  خروجی مدل SCMAI است (Fijani et al., 2013). در مرحله آموزش شبکه عصبی (ANN)، الگوریتم لونیبرگ-مارکوارت (LM) به عنوان یک الگوریتم یادگیری برای برآورد وزن‌ها ( $W_{kj}$  و  $W_{ji}$ ) و بایاس‌ها انتخاب شده است (ASCE, 2000).

### ۳-۵. معیارهای ارزیابی دقت مدل‌های هوش مصنوعی

در این پژوهش به منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیش‌بینی دقیق از ۵ معیار جذر میانگین مربع نسبی خطا (RRMSE)، جذر میانگین مربع خطا (RMSE) میانگین خطای مطلق (MAE)، ضریب تبیین ( $R^2$ ) و ضریب همبستگی ( $r$ ) استفاده شده است. این ۵ معیار به صورت زیر به دست می‌آیند:

$$RRMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{vul_i - \widehat{vul}_i}{vul_i} \right)^2} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (vul_i - \widehat{vul}_i)^2}{n}} \quad (6)$$

$$MAE = \frac{\sum_{i=1}^n |vul_i - \widehat{vul}_i|}{n} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (vul_i - \widehat{vul}_i)^2}{\sum_{i=1}^n (vul_i - \bar{vul})^2} \quad (8)$$

$$r = \frac{\sum_{i=1}^n (vul_i - \bar{vul})(N_i - \bar{N})}{\sqrt{\sum_{i=1}^n (vul_i - \bar{vul})^2} \sqrt{\sum_{i=1}^n (N_i - \bar{N})^2}} \quad (9)$$

روابط بالا،  $\widehat{vul}_i$  نتایج آسیب‌پذیری مشاهداتی،  $\bar{vul}_i$  نتایج آسیب‌پذیری محاسباتی به وسیله مدل هوش مصنوعی،  $\bar{vul}$  میانگین مشاهداتی،  $n$  تعداد کل مشاهداتی،  $N_i$  غلظت نیترات و  $\bar{N}$  میانگین غلظت نیترات را نشان می‌دهد. RRMSE، RMSE و MAE میزان خطای میان مقادیر مشاهداتی و محاسباتی را نشان می‌دهد و  $R^2$  و  $r$  نشانگر میزان بازده شبکه هستند. هر چقدر RRMSE، RMSE و MAE به صفر و  $R^2$  و  $r$  به یک میل کنند بهترین جواب برای مدل ایجاد خواهد شد.

### ۴- بحث و نتایج

در این مطالعه به منظور درستی‌سنجی و مقایسه پیش‌بینی مدل‌های مختلف از غلظت نیترات ۶۵ نمونه در منطقه مورد مطالعه استفاده شد که توسط کرد در سال ۱۳۹۰ اندازه‌گیری شده گرفته بود (کرد، ۱۳۹۳). 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 بخش باختری و بخشی از شمال دشت و کمترین مقدار را در جنوب دشت نشان می‌دهد.

دشت اردبیل ناهمگنی‌های فراوانی از دید زمین‌شناسی و آب‌زمین‌شناختی دارد؛ از جمله اینکه رسوبات محیط غیراشباع بخش باختری دشت بیشتر از رسوبات آبرفتی دانه‌درشت و بخش‌های خاوری و جنوبی از رسوبات دانه‌ریز تشکیل شده‌اند. از دید ژرفای آب زیرزمینی بخش جنوبی دشت دارای ژرفای زیاد، بخش باختری دارای کمترین ژرفا و بخش خاوری دارای ژرفای میانگین است و همچنین بیشترین تراوایی و میزان تغذیه مربوط به بخش باختری دشت و کمترین آن مربوط به بخش جنوبی است. بنابراین برای افزایش دقت مدل‌ها، منطقه مطالعاتی با در نظر گرفتن این ویژگی‌های آب‌زمین‌شناختی و زمین‌شناسی بیان شده و نیز بر پایه نظر کارشناسی به سه بخش خاوری، باختری، و جنوبی تقسیم شد (شکل ۴) و برای هر بخش، مدل‌های هوش مصنوعی به‌طور جداگانه و با ویژگی‌های متفاوت اجرا شد.

به منظور اجرای مدل دراستیک، نقشه‌های مربوط به هر کدام از متغیرهای مدل دراستیک در محیط نرم‌افزار Arc GIS تهیه شد و سپس رتبه‌دهی و وزن‌دهی و

زمان و مکان است (به نقل از ناصری و صارمی‌نژاد، ۱۳۹۰). بنابراین ارائه مدلی که توانایی پاسخگویی در شرایط عدم قطعیت را داشته باشد، یک ابزار مدیریتی مناسب برای ارزیابی آسیب‌پذیری آب زیرزمینی است. در ارزیابی آسیب‌پذیری دسته‌بندی اطلاعات و تعیین مرز میان دسته‌ها اهمیت خاصی دارد؛ بنابراین منطق فازی روش مناسبی برای ارزیابی آسیب‌پذیری آب زیرزمینی است (Dixon et al., 2002).

هر مجموعه فازی به وسیله یک تابع عضویت نشان داده می‌شود. تابع عضویت اشکال مختلفی مانند گوسی، مثلثی، دوزنقه‌ای، سیگموئید و غیره دارد. هر سامانه فازی شامل سه بخش اصلی است: (۱) فازی‌سازی داده‌ها؛ (۲) سامانه استنتاج فازی (قوانین فازی)؛ (۳) غیرفازی‌سازی داده‌ها. در فازی‌سازی، ورودی‌ها از راه تابع عضویت مربوط، به مجموعه فازی مناسب تغییر می‌یابند و نتایج فازی‌سازی شده با سامانه استنتاج فازی به دست می‌آید. در مرحله آخر از اجتماع خروجی‌ها و غیرفازی‌سازی آنها نتایج پایانی به دست می‌آید. بر پایه نوع تابع عضویت، مدل فازی به دو نوع ممدانی و ساجنو تقسیم می‌شود. در روش ممدانی توابع عضویت خروجی، مجموعه‌های فازی هستند؛ اما در مدل ساجنو خروجی به صورت ثابت یا خطی است که توسط روش دسته‌بندی به دست می‌آید (Nadiri et al., 2013).

### ۳-۴. مدل هوش مصنوعی مرکب (SCMAI)

یک مدل هوش مصنوعی مرکب از گروهی از مدل‌های هوش مصنوعی تشکیل شده که خروجی‌های مدل‌های منفرد را ترکیب می‌کند و با توجه به اینکه هر یک از مدل‌های هوش مصنوعی مزایای ویژه‌ای دارد؛ بنابراین مدل هوش مصنوعی مرکب از مزایای همه این مدل‌ها استفاده می‌کند و نتایج بهتری نسبت به هر یک از مدل‌های منفرد ارائه می‌دهد (ندیری، ۱۳۹۲). از جمله روش‌های ترکیب مدل‌ها می‌توان به روش میانگین‌گیری ساده و میانگین‌گیری وزنی اشاره کرد (Chen and Lin, 2006; Labani et al., 2010). در این مطالعه، یک مدل هوش مصنوعی مرکب نظارت شده (SCMAI) برای ارزیابی آسیب‌پذیری ارائه شده است؛ در این روش یک مدل هوش مصنوعی (AI) به عنوان یک ترکیب کننده نظارت شده غیرخطی به کار گرفته شده که جایگزین روش میانگین‌گیری ساده و وزنی است (Nadiri et al., 2013).

در این پژوهش برای استفاده همزمان از کارایی مدل‌های شبکه عصبی پیشرو، شبکه عصبی برگشتی، فازی ساجنو و فازی ممدانی از مدل هوش مصنوعی مرکب نظارت شده (SCMAI) استفاده شده است. آسیب‌پذیری به دست آمده به وسیله این ۴ مدل منفرد هوش مصنوعی ورودی‌های مدل SCMAI را تشکیل می‌دهند. شکل ۳ تصویر نمادین از مدل هوش مصنوعی ارائه شده در این پژوهش را نشان می‌دهد.

مدل هوش مصنوعی مرکب شامل ۴ مدل هوش مصنوعی است که در طی دو مرحله اصلی ایجاد می‌شود. در مرحله اول، آسیب‌پذیری آب زیرزمینی از داده‌های آب‌زمین‌شناختی (متغیرهای دراستیک) با استفاده از مدل‌های هوش مصنوعی شامل شبکه عصبی پیشرو (FFN)، شبکه عصبی برگشتی (RNN)، فازی ساجنو (SFL) و فازی ممدانی (MFL) پیش‌بینی شده است و در مرحله دوم، از یک شبکه عصبی مصنوعی به عنوان یک ترکیب کننده غیر خطی نظارت شده برای ترکیب مدل‌ها استفاده می‌شود. عبارت ریاضی مدل SCMAI به صورت زیر است:

$$vul_i = AI_i(D, R, A, S, T, I, C) \quad (2)$$

$$O_j = f_1(b_j + \sum_i W_{ji} Vul_i) \quad (3)$$

$$O_k = Vul_{SCMAI} = f_2(b_k + \sum_j W_{kj} O_j) \quad (4)$$

$Vul_i$  خروجی هر یک از مدل‌های هوش مصنوعی (شبکه عصبی پیشرو، شبکه عصبی برگشتی، فازی ساجنو و فازی ممدانی) است که در مدل مرکب به عنوان ورودی استفاده شده‌اند.  $f_1$  و  $f_2$  توابع فعال‌سازی به ترتیب برای لایه پنهان و لایه خروجی هستند،  $O_j$ ،  $O_k$ ،  $W_{kj}$  و  $W_{ji}$  گره‌ها در لایه پنهان،  $W_{kj}$  و  $W_{ji}$  وزن‌هایی که قدرت ارتباطی میان دو لایه را کنترل می‌کنند و  $b_j$  و  $b_k$  بایاس‌ها هستند که به ترتیب برای تنظیم مقدار میانگین در لایه پنهان و لایه خروجی استفاده شده‌اند. انواع

درصد از منطقه مورد مطالعه را پوشش می‌دهد. این رده بخش‌هایی در نواحی شمالی و باختری را به خود اختصاص داده است. خاور و بخشی از جنوب دشت در محدوده آسیب‌پذیری کم قرار دارد که ۴۴/۳۶ درصد از منطقه را شامل می‌شود.

#### ۴-۱. نتایج حاصل از مدل‌سازی توسط شبکه‌های عصبی مصنوعی

در این پروژه برای اجرای مدل‌های هوش مصنوعی به منظور ارزیابی آسیب‌پذیری به علت گسترش زیاد دشت و همچنین ناهمگنی موجود، دشت مورد مطالعه به سه بخش (خاوری، باختری و جنوبی) تقسیم (شکل ۴) و برای هر بخش به‌طور جداگانه مدل‌های هوش مصنوعی اجرا شد. در همه این مدل‌های هوش مصنوعی ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای مرحله آزمایش به کار برده شد. در روش‌های شبکه عصبی پیشرو و برگشتی، ۷ متغیر مدل دراستیک به عنوان ورودی‌های مدل و شاخص دراستیک تصحیح شده با نیترا به عنوان خروجی مدل به کار گرفته شد. برای اجرای مدل‌های هوش مصنوعی ابتدا در مرحله آموزش طبق رابطه ۱۰ مقادیر آسیب‌پذیری (شاخص دراستیک) تصحیح و سپس در مرحله آزمایش با استفاده از مقادیر نیترا نتایج مدل‌ها ارزیابی شد.

$$(10) \quad \text{شاخص دراستیک تصحیح شده} = \frac{Vul_{max}}{(NO_3)_{max}} \times (NO_3)_i$$

در رابطه بالا،  $Vul_{max}$  بیشترین مقدار شاخص دراستیک،  $(NO_3)_{max}$  بیشترین غلظت نیترا و  $(NO_3)_i$  غلظت نیترا را نشان می‌دهد.

برای بخش باختری به منظور اجرای شبکه عصبی پیشرو از شبکه سه لایه با الگوریتم لوبنرگ-مارکوارت (LM) استفاده شد. بر پایه آزمون و خطا تعداد گره‌ها در لایه میانی ۲ و گره خروجی هم برابر ۱ به دست آمد که منطبق بر تعداد متغیر خروجی است. تابع تبدیل‌گر در لایه دوم از نوع سیگموئید تانژانتی (Tansig) و در لایه سوم خطی (Purlin) است. پس از ۱۰۰ دوره آموزش مقادیر ضریب تعیینی ( $R^2$ ) و RMSE برای مرحله آموزش به ترتیب ۰/۸۵ و ۴/۰۲ حاصل شد. پس از آموزش، مدل برای مرحله آزمایش اجرا شد و ضریب تعیینی آسیب‌پذیری پیش‌بینی شده توسط مدل با مقادیر نیترا برابر ۰/۸۳ به دست آمد. در شبکه عصبی برگشتی با ۱۲۳ دوره آموزش مقادیر  $R^2$  و RMSE برای مرحله آموزش به ترتیب ۰/۹۷ و ۱/۷۶ و مقدار  $R^2$  برای مرحله آزمایش ۰/۶۲ به دست آمد.

برای بخش خاوری و جنوبی نیز بر پایه روش آزمون و خطا، مدل شبکه عصبی پیشرو با یک شبکه ۴ لایه انتخاب شد؛ به گونه‌ای که تعداد گره‌ها در لایه دوم و سوم و چهارم به ترتیب ۲ و ۲ و ۱ بود. تابع تبدیل‌گر در لایه دوم و سوم سیگموئید تانژانتی و در لایه چهارم خطی است. برای بخش خاوری دوره‌های آموزش ۵۶۶ و مقادیر  $R^2$  و RMSE برای مرحله آموزش به ترتیب ۰/۷ و ۱۱/۵۴ و برای بخش جنوبی با ۴۲۴ دوره آموزش مقادیر  $R^2$  و RMSE به ترتیب ۰/۷۵ و ۷/۶۴ به دست آمد. شبکه عصبی برگشتی برای بخش خاوری و جنوبی به ترتیب با دوره‌های آموزش ۱۱ و ۳۹ اجرا شد و مقادیر  $R^2$  و RMSE مرحله آموزش برای بخش خاوری ۰/۸۱ و ۹/۹۳ و برای بخش جنوبی ۰/۹۵ و ۳/۶۲ به دست آمد. بر پایه نتایج حاصل از این دو مدل که در جدول ۲ ارائه شده است، برای بخش باختری شبکه عصبی پیشرو و برای بخش‌های خاوری و جنوبی شبکه عصبی برگشتی نتایج بهتری ارائه دادند.

#### ۴-۲. نتایج حاصل از مدل‌سازی توسط منطق فازی

در این پژوهش از دو روش منطق فازی (ساجنو و ممدانی) به منظور تعیین میزان آسیب‌پذیری استفاده شده است. در این روش ورودی‌ها و خروجی‌ها همان ورودی‌ها و خروجی‌های مدل شبکه عصبی مصنوعی هستند که در بخش پیشین اشاره شد. اولین گام در روش‌های فازی، تعیین توابع عضویت و دسته‌بندی داده‌هاست. به منظور دسته‌بندی داده‌ها و تعیین تابع عضویت در مدل ساجنو از روش کاهشی (Subtractive) و در مدل ممدانی از روش FCM استفاده شد. متغیر اصلی در مدل ساجنو برای تعیین دسته‌ها و قوانین اگر-آنگاه، شعاع دسته‌بندی و مقدار آن میان صفر و یک است (Hongxing et al., 2000). برای بخش خاوری دشت مدل ساجنو

در پایان تلفیق لایه‌های مختلف اطلاعاتی انجام گرفت؛ که چگونگی تهیه لایه‌های اطلاعاتی به‌طور مختصر در زیر آورده شده است. فاصله میان سطح زمین و سطح آب زیرزمینی، ژرفای برخورد را مشخص می‌کند. این متغیر تعیین‌کننده ژرفایی است که آلوده‌کننده باید طی کند تا به سطح ایستایی برسد. هر چه ژرفای سطح ایستایی 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 ژرفاهای کمتر، بیشترین رتبه (۱۰) و برای ژرفای‌های بیشتر، کمترین رتبه (۱) اختصاص داده می‌شود. برای تهیه نقشه ژرفای آب زیرزمینی، ابتدا موقعیت و ژرفای سطح ایستایی 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 به منظور تلفیق با لایه‌های دیگر به حالت رستری تبدیل شد و در پایان رتبه‌دهی انجام و لایه ژرفای آب زیرزمینی تهیه شد.

تغذیه خالص مقدار آبی است که از سطح زمین نفوذ کرده و به سطح ایستایی می‌رسد. تغذیه آب موجب می‌شود تا آلوده‌کننده به‌صورت عمودی انتقال یابد، به سطح ایستایی برسد و به‌صورت افقی در آبخوان حرکت کند. برای ایجاد این لایه از بیلان آب زیرزمینی استفاده شد و میزان تغذیه به دست آمد و پس 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 آبخوان (بخش اشباع زیر سطح ایستایی) و محیط غیراشباع (بخش غیر اشباع بالای سطح ایستایی) مشخص شد و به هر کدام از آنها نرخی اختصاص یافت. سپس با اعمال درونیابی، لایه محیط آبخوان و محیط غیراشباع به دست آمد.

محیط خاک تأثیر مهمی در چگونگی تغذیه و در پی آن چگونگی حرکت آلاینده دارد. وجود مواد با بافت ریزدانه مانند سیلت و رس، تراوایی خاک را کاهش می‌دهد و بر عکس مواد دانه‌درشت‌تر مانند شن، نفوذپذیری خاک و در نتیجه قابلیت انتقال آلاینده‌ها به سامانه آب زیرزمینی را افزایش می‌دهند. برای تهیه این لایه، نقشه خاک منطقه رقومی شده 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. کاهش شیب نیز موجب افزایش نرخ نفوذ می‌شود و پتانسیل آلودگی بیشتری را ایجاد می‌کند. پس ناحیه با شیب کمتر، رتبه بیشتری در مدل خواهد داشت. برای تهیه این لایه از مدل ارتفاعی رقومی منطقه استفاده و سپس نقشه شیب از مدل ارتفاعی رقومی استخراج شد و رتبه‌دهی انجام گرفت. لایه هدایت هیدرولیکی مربوط به نفوذپذیری سفره یا توانایی مواد سفره به منظور انتقال آب یا مواد محلول است. بنابراین هر چه 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 ستبری اشباع آبخوان استفاده شد و میزان هدایت هیدرولیکی به دست آمد. بدین ترتیب این اطلاعات به محیط اکسل وارد و به فرمت قابل قبول برای نرم‌افزار ARC GIS تبدیل شد. سپس با استفاده از روش Kriging درونیابی، رتبه‌دهی انجام و نقشه هدایت هیدرولیکی تهیه شد. پس از تهیه ویژگی‌های مورد نیاز برای ارزیابی آسیب‌پذیری به روش دراستیک به‌صورت هفت لایه رستری که در شکل ۵ نشان داده شده‌اند. وزن‌دهی متغیرها مطابق جدول ۱ و طبق وزن‌دهی (Aller et al., 1987) انجام شد و پس از تلفیق آنها بر پایه رابطه ۱ شاخص آسیب‌پذیری به دست آمد.

شاخص آسیب‌پذیری دراستیک برای دشت اردبیل میان ۸۲ تا ۱۵۱ به دست آمد که با توجه به رده‌بندی (Aller et al., 1987) آسیب‌پذیری دشت اردبیل در دو گروه آسیب‌پذیری کم (۱۲۰ - ۸۲) و متوسط (۱۵۱ - ۱۲۱) قرار می‌گیرد. بیشترین آسیب‌پذیری آب‌های زیرزمینی مربوط به آسیب‌پذیری متوسط است که ۵۵/۶۴

#### ۴-۴. مقایسه نتایج حاصل از مدل‌های مختلف برای پیش‌بینی آسیب‌پذیری آب زیرزمینی

نقشه‌های آسیب‌پذیری تهیه شده با استفاده از مدل‌های دراستیک اصلی و اصلاح شده به همراه غلظت نترات چاه‌های اندازه‌گیری شده در شکل ۶ نشان داده شده است. دایره‌های تو خالی موقعیت و غلظت نترات را در منطقه نشان می‌دهد که برای درستی سنجی استفاده شده است. با انطباق مقادیر یون نترات روی هر کدام از نقشه‌های آسیب‌پذیری دیده شد که در همه روش‌ها بیشتر نقاط با نترات بالا در محدوده با خطر آلودگی بیشتر قرار گرفته‌اند؛ اما این انطباق در نقشه آسیب‌پذیری حاصل از مدل SCMAI نسبت به دیگر روش‌ها بیشتر است و هیچ چاه آبی با غلظت نترات بالا در منطقه با خطر آلودگی کم قرار ندارد؛ بلکه در محدوده با خطر آلودگی بیشتر قرار دارند.

در همین راستا برای بررسی دقیق‌تر و همچنین مقایسه مدل‌های آسیب‌پذیری با هم، از روش محاسبه شاخص همبستگی (CI) (Fijani et al. (2013) میان مدل‌های مختلف آسیب‌پذیری و داده‌های نترات استفاده شد. برای محاسبه شاخص همبستگی، مقادیر نترات به چهار گروه نترات خیلی کم، کم، متوسط و زیاد تقسیم‌بندی می‌شود؛ سپس تعداد چاه‌هایی که مقادیر نترات آنها دارای ارزش یکسانی با نقشه‌های آسیب‌پذیری است و در یک گروه قرار دارند؛ در ۴ ضرب می‌شوند. آن تعداد از چاه‌هایی که مقادیر نترات و گروه آسیب‌پذیری آن به مقدار ۱، ۲، ۳ و ۴ اختلاف دارند به ترتیب در ۳، ۲ و ۱ ضرب می‌شوند. سپس مقادیر حاصل با هم جمع بسته می‌شود و شاخص همبستگی (CI) به دست می‌آید؛ که این می‌تواند همبستگی میان مدل‌های آسیب‌پذیری و مقادیر نترات را نشان دهد. CI بالاتر به معنی همبستگی بیشتر است (Fijani et al., 2013).

انطباق چاه‌های با چهار سطح آلودگی نترات و دسته‌های آسیب‌پذیری پیش‌بینی شده به وسیله مدل‌های SFL، MFL، RNN، FFFN، DRASTIC و SCMAI در جدول ۳ ارائه شده است. برای نمونه برای به دست آوردن شاخص همبستگی برای پیش‌بینی مدل SFL، چاه در گروه آسیب‌پذیری و سطح آلودگی نترات یکسانی قرار دارند و ۲۲ چاه دارای اختلاف ۱ و ۴ چاه دارای اختلاف ۲ هستند. ضرایب این گروه از چاه‌ها به ترتیب ۴، ۳ و ۲ است. سپس شاخص همبستگی این چنین به دست می‌آید:

$$CI = 28 \times 4 + 22 \times 3 + 4 \times 2 + 0 \times 1 = 186$$

بر پایه نتایج حاصل از مدل‌های آسیب‌پذیری در جدول ۳، مدل‌های هوش مصنوعی نتایج بهتری نسبت به مدل دراستیک ارائه دادند و شاخص همبستگی (CI) بیشتری دارند. از میان مدل‌های هوش مصنوعی، مدل SCMAI بیشترین شاخص همبستگی (CI) و همچنین با توجه به جدول ۲ پایین‌ترین خطا و بالاترین ضریب همبستگی را دارد. این نتایج نشان داد که مدل SCMAI با ترکیب غیر خطی، کارایی بالایی در برآورد آسیب‌پذیری آبخوان دشت اردبیل دارد. بر پایه مدل SCMAI، ۳۴/۴ درصد از منطقه در معرض خطر آلودگی خیلی کم، ۵۵/۷ درصد در معرض خطر آلودگی کم و ۹/۹ درصد در خطر آلودگی متوسط قرار دارد.

#### ۵- نتیجه‌گیری

هدف 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 بالای آلودگی ضرورت دارد. در همین راستا ۷ متغیر مؤثر در آسیب‌پذیری آب زیرزمینی به صورت ۷ لایه رستری تهیه شد و شاخص آسیب‌پذیری برای منطقه میان ۸۲ تا ۱۵۱ به دست آمد. سپس بهینه‌سازی مدل دراستیک با استفاده از مدل‌های شبکه عصبی پیشرو، شبکه عصبی برگشتی، فازی ساجنو، فازی ممدانی و مدل مرکب انجام شد که ترکیبی

بر پایه کمترین مقدار RMSE، شعاع دسته‌بندی بهینه ۰/۶ انتخاب و ۴ قانون تولید شد. تابع عضویت استفاده شده برای داده‌های ورودی تابع گوسی بود و تابع عضویت خروجی مدل از نوع خطی است که بر پایه داده‌های ورودی ساخته می‌شود. برای بخش باختری و جنوبی با استفاده از تابع عضویت گوسی مقدار شعاع دسته‌بندی ۰/۸ انتخاب و ۳ قانون نیز تولید شد. مقادیر  $r$  و RRMSE مربوط به مراحل آموزش و آزمایش در جدول ۲ ارائه شده است.

همان‌طور که پیش‌تر اشاره شد، از روش دسته‌بندی FCM برای تهیه مدل فازی ممدانی استفاده شد. در مدل ممدانی همانند مدل ساجنو به منظور دسته‌بندی داده‌ها، تعداد دسته‌های بهینه بر پایه کمترین مقدار RMSE انتخاب شد و تابع عضویت ورودی و خروجی از نوع گوسی است. تعداد دسته‌ها و قوانین برای بخش‌های باختری، خاوری و جنوبی به ترتیب ۲۸، ۳۶ و ۳۷ به دست آمد و مقادیر ضریب تعیینی آسیب‌پذیری مشاهداتی و محاسباتی برای مرحله آموزش به ترتیب ۰/۸، ۰/۷۵ و ۰/۸ و ضریب تعیینی نتایج این مدل با مقادیر نترات به ترتیب ۰/۵۸، ۰/۶۷ و ۰/۶ به دست آمد. نتایج به دست آمده (جدول ۲) نشان داد که از میان دو مدل منطق فازی، برای بخش باختری دشت مدل ساجنو و برای بخش‌های خاوری و جنوبی مدل ممدانی نتایج بهتری نشان دادند.

بر پایه نتایج حاصل از ۴ مدل هوش مصنوعی یعنی مدل‌های شبکه عصبی پیشرو، شبکه عصبی برگشتی، فازی ساجنو و فازی ممدانی که در جدول ۲ ارائه شده است؛ با وجود اینکه هر ۴ مدل نتایج قابل قبولی را ارائه دادند؛ اما هر یک از مدل‌ها در بخشی از منطقه مطالعاتی نتایج بهتری دارند. مثلاً بر پایه بالاترین ضریب همبستگی میان مقادیر محاسباتی و نترات برای بخش باختری دشت مدل شبکه عصبی پیشرو با ضریب همبستگی ۰/۹۱ و برای بخش خاوری و جنوبی دشت شبکه عصبی برگشتی با ضریب همبستگی ۰/۸۳ و ۰/۸۵ ارائه شد. با توجه به اینکه هر کدام از این ۴ مدل هوش مصنوعی برتری‌های خاص خود را دارد؛ بنابراین برای استفاده همزمان از مزایای همه آنها از مدل هوش مصنوعی مرکب استفاده شد.

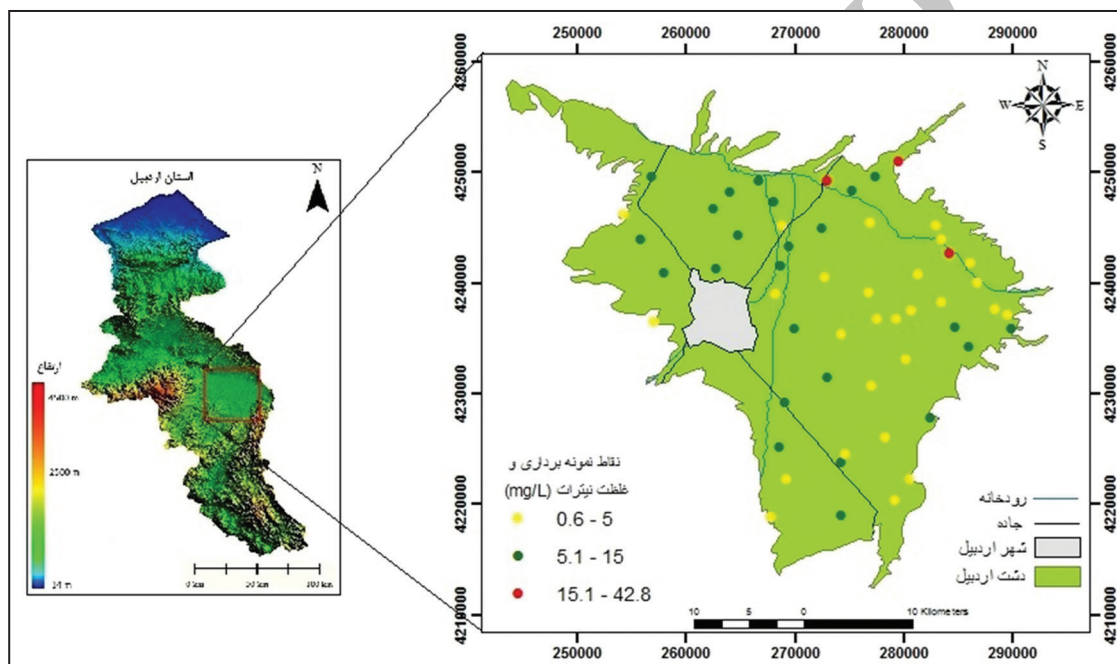
#### ۴-۳. نتایج حاصل از مدل هوش مصنوعی مرکب (SCMAI)

در این پژوهش برای ایجاد مدل مرکب از یک شبکه عصبی سه لایه پرسپترون با الگوریتم LM برای ترکیب مدل‌های شبکه عصبی پیشرو، برگشتی، فازی ساجنو و فازی ممدانی استفاده شد.


روش SCMAI همان‌گونه که در شکل ۳ نشان داده شده است؛ از یک شبکه عصبی مصنوعی (بخش) برای ترکیب برآورد مقادیر آسیب‌پذیری با استفاده از FFFN، RNN، SFL و MFL در مرحله آموزش استفاده می‌کند. در این مدل مقادیر آسیب‌پذیری محاسباتی توسط ۴ مدل، ورودی‌های مدل و آسیب‌پذیری مشاهداتی خروجی مدل را تشکیل می‌دهد. برای مدل ANN استفاده شده در مدل SCMAI، ساختار MLP-LM بر پایه معادلات ۲ و ۳ به کار گرفته شده است. برای هر سه بخش از دشت از مدل ANN سه لایه‌ای و با الگوریتم LM برای بهینه‌سازی وزن‌ها و بایاس‌ها استفاده شد. تابع تبدیل‌گر برای لایه پنهان از نوع Tansig و برای لایه خروجی از نوع Purelin است. در مدل SCMAI اجرا شده برای بخش باختری دشت، مدل ANN دارای ۴ گره در لایه ورودی، ۲ گره در لایه میانی (پنهان) و یک گره در لایه خروجی است. پس از ۵۰ دوره آموزش مقدار RMSE، ۱/۹۲ به دست آمد. سپس مدل SCMAI توسط داده‌های نترات درستی سنجی شد و ضریب همبستگی (f)، ۰/۹۶ به دست آمد. برای مدل اجرا شده در بخش خاوری و جنوبی دشت، شمار گره‌های لایه میانی به ترتیب ۸ و ۳ است و مقدار RMSE برای بخش خاوری پس از ۱۰۰ دوره آموزش، ۵/۶۴ و برای بخش جنوبی پس از ۵۷ دوره آموزش، ۲/۷۴ به دست آمد. جدول ۲ نتایج حاصل از ۴ مدل منفرد شبکه عصبی و مدل مرکب را نشان می‌دهد. همان‌گونه که ملاحظه می‌شود مدل SCMAI کمترین خطای نسبی (RRMSE) و بیشترین ضریب همبستگی را نسبت به چهار مدل دیگر هوش مصنوعی دارد.

را در ارزیابی آسیب‌پذیری نشان داد. نتایج حاصل از دیگر مطالعات انجام شده در پیش‌بینی و برآورد متغیرهای آب‌زمین‌شناختی و آب‌شناختی نیز نشانگر عملکرد بهتر مدل‌های مرکب غیر خطی نسبت به دیگر مدل‌های هوش مصنوعی بوده است (Nadiri et al., 2013; Nadiri et al., 2014; Asadi et al., 2014; Tayfure et al., 2014). بر پایه مدل مرکب (SCMAI) بخش‌های باختری و شمال دشت اردبیل پتانسیل آلودگی بیشتری نسبت به دیگر مناطق دارد و باید محافظت بیشتری از این مناطق صورت گیرد. مدل مرکب غیرخطی ارائه شده نیز با وجود توانایی بالای خود مانند همه مدل‌ها عدم قطعیت دارد و بنابراین بررسی عدم قطعیت این مدل می‌تواند موضوعی برای پژوهش‌های بعدی باشد. همچنین با توجه به اینکه تقسیم‌بندی دشت در این پژوهش بر پایه نظر کارشناسی انجام گرفته است؛ پیشنهاد می‌شود که در مطالعات بعدی برای تقسیم‌بندی دقیق‌تر از روش‌های دسته‌بندی هوش مصنوعی از جمله SOM و LVQ استفاده شود.

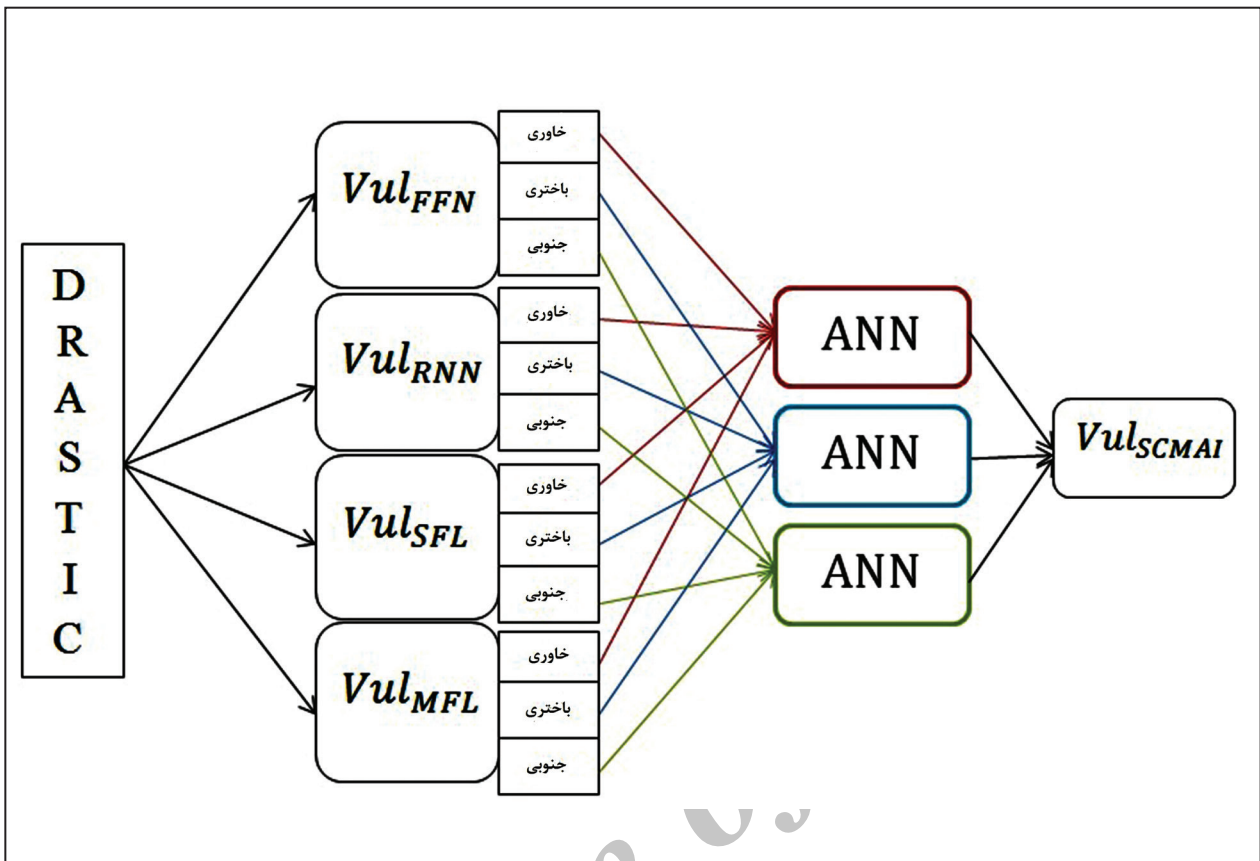
از این چهار مدل است. برای اجرای این مدل‌ها به علت گسترش زیاد دشت و همچنین ناهمگنی موجود، دشت اردبیل به سه بخش تقسیم و برای هر کدام مدل‌های هوش مصنوعی اجرا شد. نتایج نشان داد که هر یک از مدل‌های هوش مصنوعی به تنهایی بهتر از مدل دراستیک آسیب‌پذیری منطقه را پیش‌بینی می‌کند و همبستگی بالایی با مقادیر نیترات دارند. اما با توجه به توانایی ذاتی و متفاوت هر یک از مدل‌های هوش مصنوعی برای به دست آوردن نتایج بهتر این مدل‌ها ترکیب غیر خطی شدند. از میان مدل‌های هوش مصنوعی، مدل مرکب بالاترین شاخص همبستگی (CI) را داشت. این به دلیل آن است که مدل هوش مصنوعی مرکب با ترکیب نتایج حاصل از این مدل‌های منفرد به‌طور همزمان از مزایای همه این روش‌ها استفاده می‌کند و نتایج بهتری را نسبت به دیگر روش‌ها ارائه می‌دهد. نتایج مطالعات مشابه انجام شده در زمینه ارزیابی آسیب‌پذیری با استفاده از هوش مصنوعی توسط (Fijani et al. (2013، توانایی بالای مدل‌های هوش مصنوعی مرکب غیرخطی



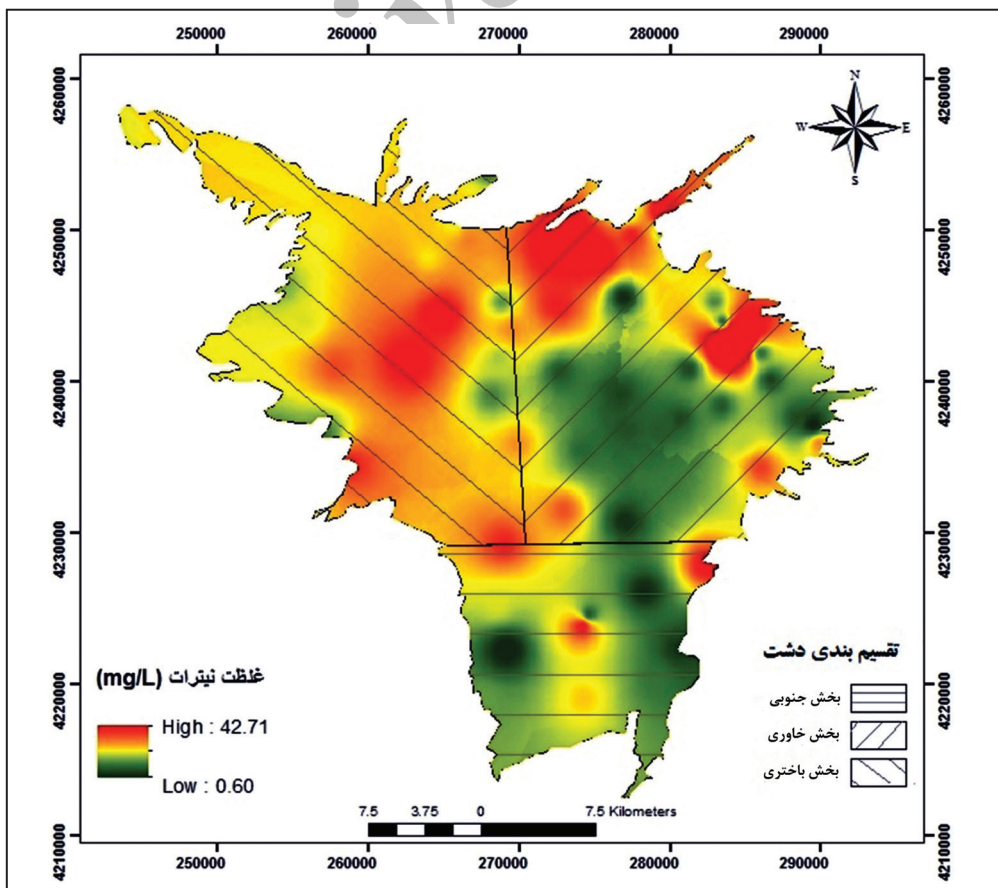
شکل ۱- منطقه مورد مطالعه و موقعیت نقاط نمونه‌برداری برای غلظت‌های نیترات.



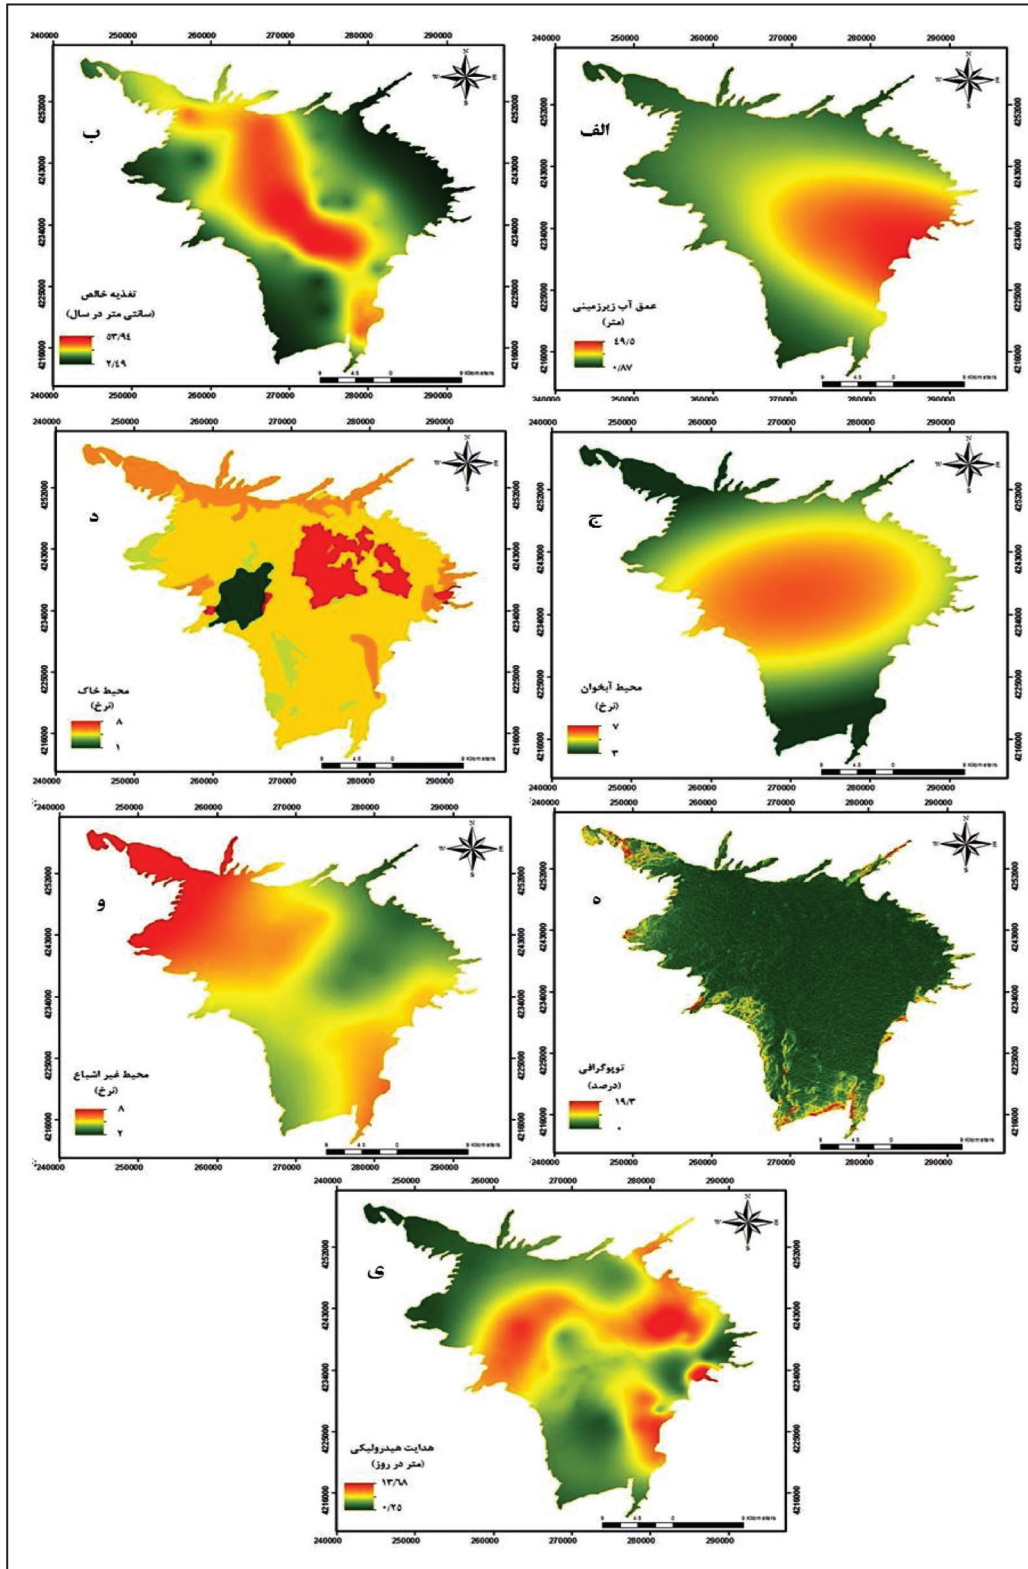
شکل ۲- ساختار شبکه عصبی مصنوعی (ANN).



شکل ۳- تصویر نمادین از مدل SCMAI.

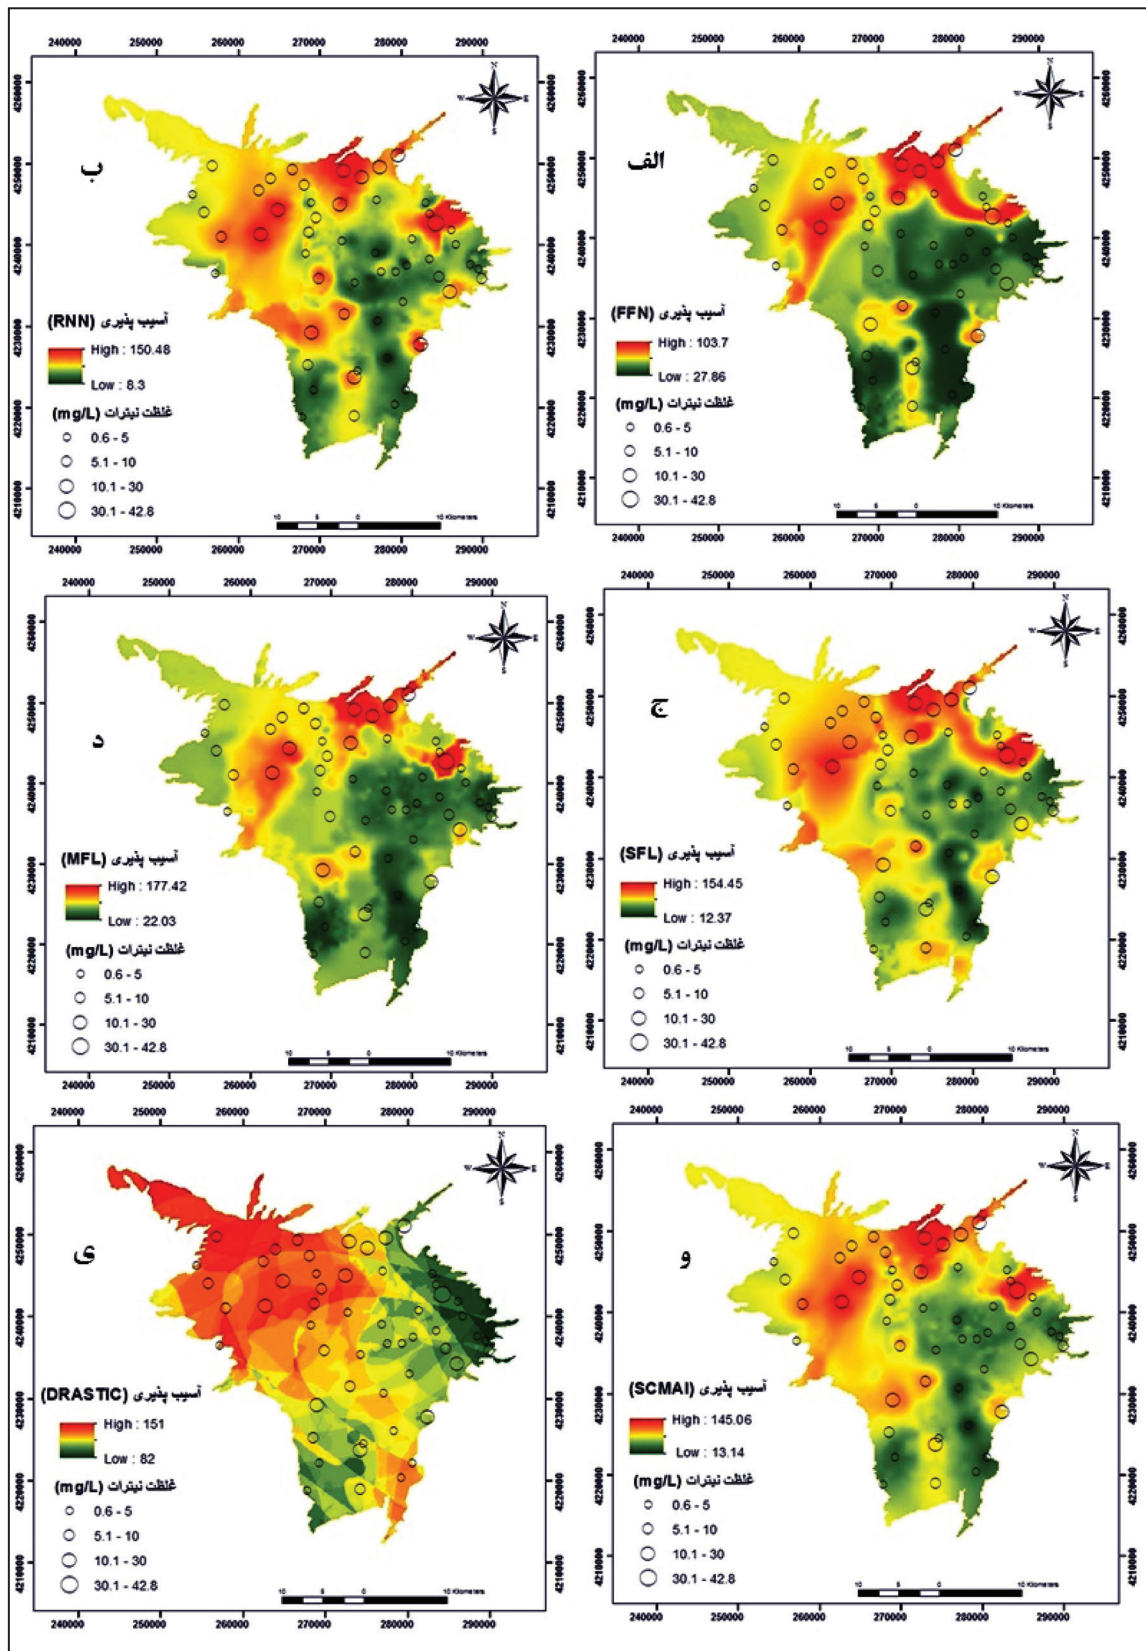


شکل ۴- توزیع مکانی غلظت نیترات در آب زیرزمینی منطقه.



شکل ۵- نقشه پهنه بندی متغیرهای مدل دراستیک. الف) ژرفای آب زیرزمینی؛ ب) تغذیه خالص؛ ج) محیط آبخوان؛ د) محیط خاک؛ ه) توپوگرافی؛ و) محیط غیر اشباع؛ ی) هدایت هیدرولیکی.





شکل ۶- نقشه آسوب پذیری آب زیرزمینی. الف) مدل FFN؛ ب) مدل RNN؛ ج) مدل SFL؛ د) مدل MFL؛ و) مدل SCMAI؛ ه) مدل DRASTIC.

جدول ۱- وزن‌دهی متغیرهای مدل

DRASTIC

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

جدول ۲- نتایج به دست آمده از مدل‌های مختلف هوش مصنوعی در مراحل آموزش و آزمایش.

نوع مدل					معیار ارزیابی	مراحل	
SCMAI	MFL	SFL	RNN	FFN			
۰/۰۱	۰/۰۷	۰/۰۶	۰/۰۳	۰/۰۶	RRMSE	مرحله آموزش	بخش باختری
۱	۳/۲۶	۳/۰۶	۱/۳	۳/۰۶	MAE		
۰/۹۹	۰/۸۹	۰/۹۱	۰/۹۸	۰/۹۲	r		
۰/۰۲	۰/۰۷	۰/۱۹	۰/۱۴	۰/۱۲	RRMSE	مرحله آزمایش	
۱/۱۳	۴/۵۴	۵/۶۴	۶/۱۲	۶/۸۴	MAE		
۰/۹۷	۰/۷۶	۰/۷۷	۰/۷۸	۰/۹۱	r		
۰/۱۱	۰/۲۶	۰/۲۶	۰/۲۳	۰/۲۵	RRMSE	مرحله آموزش	بخش خاوری
۳/۷۶	۹/۳۵	۸/۷۱	۷/۷۱	۸/۵۸	MAE		
۰/۹۲	۰/۸۶	۰/۸۶	۰/۹	۰/۸۳	r		
۰/۰۹	۰/۱۳	۰/۱۳	۰/۱۹	۰/۱۵	RRMSE	مرحله آزمایش	
۵/۵۴	۵/۲۰	۵/۳۸	۷/۳۰	۶/۱۵	MAE		
۰/۹۲	۰/۸۱	۰/۷۷	۰/۸۳	۰/۷	r		
۰/۰۵	۰/۱۸	۰/۱۷	۰/۱	۰/۲۲	RRMSE	مرحله آموزش	بخش جنوبی
۱/۸۱	۵/۱۷	۵/۷۹	۲/۶۰	۶/۰۹	MAE		
۰/۹۸	۰/۸۹	۰/۸۶	۰/۹۷	۰/۸۶	r		
۰/۰۷	۰/۰۸	۰/۱۱	۰/۱۱	۰/۱۳	RRMSE	مرحله آزمایش	
۲/۳۸	۳/۲۷	۴/۲۷	۴/۰۱	۴/۸۶	MAE		
۰/۹۷	۰/۷۸	۰/۷۴	۰/۸۵	۰/۸	r		

جدول ۳- انطباق چاه‌های اندازه‌گیری نترات در چهار سطح آلودگی با نقشه‌های آسیب‌پذیری تهیه شده با روش‌های مختلف.

	غلظت نترات								
	خیلی کم	کم	متوسط	زیاد		خیلی کم	کم	متوسط	زیاد
DRASTIC				CI=۱۵۵	FFN				CI=۱۸۴
کم	۱۰	۲	۲	۱	خیلی کم	۲۵	۱۴	۳	۰
متوسط	۱۷	۱۳	۹	۰	کم	۲	۱	۸	۱
SFL				CI=۱۸۶	MFL				CI=۱۹۰
خیلی کم	۲۵	۱۳	۴	۰	خیلی کم	۲۷	۱۴	۲	۰
کم	۲	۲	۶	۰	کم	۰	۱	۷	۰
متوسط	۰	۰	۱	۱	متوسط	۰	۰	۱	۰
					زیاد	۰	۰	۱	۱
RNN				CI=۱۹۱	SCMAI				CI=۱۹۵
خیلی کم	۲۶	۱۲	۱	۰	خیلی کم	۲۷	۱۰	۲	۰
کم	۱	۳	۹	۰	کم	۰	۵	۶	۰
متوسط	۰	۰	۱	۱	متوسط	۰	۰	۳	۱

## کتابنگاری

- اصغری مقدم، ا.، فیجانی، ا. و ندیری، ع.، ۱۳۸۸- ارزیابی آسیب‌پذیری آب زیرزمینی دشت‌های بازرگان و پلدشت با استفاده از مدل دراستیک بر اساس GIS. مجله محیط‌شناسی، شماره ۵۲، ص. ۵۵ تا ۶۴.
- کرد، م.، ۱۳۹۳- مدل‌سازی عددی آبخوان دشت اردبیل و مدیریت آن با استفاده از بهینه‌سازی برداشت آن، رساله دکترا، دانشکده علوم طبیعی، دانشگاه تبریز، ۱۹۰ ص.
- ناصری، ح. و صارمی‌نژاد، ف.، ۱۳۹۰- مقایسه ارزیابی آسیب‌پذیری آبخوان به روش‌های DRASTIC و منطق فازی، مطالعه موردی: دشت گل‌گیر مسجد سلیمان. فصل‌نامه جغرافیای طبیعی، سال چهارم، شماره ۱۱، صص. ۱۷ تا ۳۴.
- ندیری، ع.، ۱۳۸۶- پیش‌بینی سطح آب‌های زیرزمینی با استفاده از مدل شبکه‌های عصبی مصنوعی در محدوده مترو شهر تبریز، پایان‌نامه کارشناسی ارشد، دانشکده علوم طبیعی، دانشگاه تبریز، ۱۷۸ ص.
- ندیری، ع.، ۱۳۹۲- مقایسه کارایی مدل‌های عددی و هوش مصنوعی در مدیریت آبخوان‌ها (مطالعه موردی: دشت تسوج)، رساله دکترا، دانشکده علوم طبیعی، دانشگاه تبریز، ۲۳۰ ص.
- ندیری، ع.، اصغری مقدم، ا.، عبقری، ه. و فیجانی، ا.، ۱۳۹۲- توسعه مدل‌های هوش مصنوعی مرکب در برآورد قابلیت انتقال آبخوان، مطالعه موردی: دشت تسوج. تحقیقات منابع آب ایران، سال نهم، شماره ۱، ص. ۱ تا ۱۴.
- نیک‌نام، ر.، محمدی، ک. و جوهری مجد، و.، ۱۳۸۶- ارزیابی آسیب‌پذیری سفره آب زیرزمینی تهران-کرج با روش DRASTIC و منطق فازی، مجله تحقیقات منابع آب ایران، سال سوم، شماره ۲، ص. ۳۹ تا ۴۷.

## References

- Aller, L., Bennett, T., Lehr, J. H., Petty, R. J. and Hackett, G., 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.
- Antonakos, A. K. and Lambrakis, N. 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, 288– 304.
- Asadi, S., Hassan, M. and Nadiri, A., 2014- Artificial intelligence modeling to evaluate field performance of photocatalytic asphalt pavement for ambient air purification. Environ Sci Pollut Res, 21, 8847-8857.
- 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), 115-137.

- Babiker, I. S., Mohamed, M. A. A., Hiyama, T. and Kato, K., 2005- A GIS-based DRASTIC model for assessing aquifer vulnerability in Kakamigahara Heights, Gifu Prefecture, central Japan. *Science of the Total Environment*, 345(1-3), 127-140.
- Chen, C. H. and Lin, Z. S., 2006- A committee machine with empirical formulas for permeability prediction. *Computer and Geoscience*, 32 (4), 485-496.
- Dixon, B., 2005- Applicability of neuro-fuzzy techniques in predicting ground-water vulnerability: a GIS-based sensitivity analysis. *Journal of Hydrology*, 309, 17-38.
- Dixon, B., Scott, H. D., Dixon, J. C. and Steele, K. F., 2002- Prediction of aquifer vulnerability to pesticides using fuzzy rule-based models at the regional scale. *Physical geography*, 23, 130-153.
- Fausett, L., 1994- Fundamentals of neural network. Prentice Hall, Englewood Cliffs, N. J., p. 461.
- Fijani, E., Nadiri, A. A., Asghari Moghaddam, A., Tsai, F. and Dixon, B., 2013- Optimization of DRASTIC Method by Supervised Committee Machine Artificial Intelligence to Assess Groundwater Vulnerability for Maragheh-Bonab Plain Aquifer, Iran. *Journal of hydrology*, 530, 89-100.
- Haykin, S., 1994- Neural networks: a comprehensive foundation. Macmillan College Publishing, New York.
- Hongxing, L., Chen, P. C. P. and Huang, H. P., 2000- Fuzzy Neural Intelligent System, Mathematical Foundation and the Application in Engineering. CRC Press, p. 392.
- Labani, M. M., Kadkhodaie-Ilkhechi, A. and Salahshoor, K., 2010- Estimation of NMR log parameters from conventional well log data using a committee machine with intelligent systems: a case study from the Iranian part of the South Pars gas field, Persian Gulf Basin. *Journal of Petroleum Science and Engineering*, 72, 175-185.
- 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*, 115, 191-204.
- Nadiri, A. A., Chitsazan, N., Tsai, F. T. C. and Moghaddam, A. A., 2014- Bayesian Artificial Intelligence Model Averaging for Hydraulic Conductivity Estimation, *Journal of Hydrologic Engineering*, 19, 520-532.
- Nadiri, A. A., Fijani, E., Tsai, F. T. C. and Moghaddam, A. A., 2013- Supervised committee machine with artificial intelligence for prediction of fluoride concentration. *Journal of Hydroinformatics* 15: 1474-1490.
- Panagopoulos, G., Antonakos, A. and Lambrakis, N., 2005- Optimization of DRASTIC model for groundwater vulnerability assessment, by the use of simple statistical methods and GIS. *Hydrogeology Journal*.
- Pulido-Calvo, I. and Gutiérrez-Estrada, J. C., 2009- Improved irrigation water demand forecasting using a soft-computing hybrid model. *Biosystems Engineering* 102(2), pp 202-218.
- 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*, 54, 39-57.
- Tayfur, G., Nadiri, A. A. and Moghaddam, A. A., 2014- Supervised Intelligent Committee Machine Method for Hydraulic Conductivity Estimation. *Water Resour Manage*, 28: 1173-1184.
- Vrba, J. and Zoporozec, A., 1994- Guidebook on mapping groundwater vulnerability. International Contributions to Hydrogeology, Verlag Heinz Heise GmbH and Co, KG.
- Zadeh, L. A., 1965- Fuzzy sets. *Information and Control*, 8 (3), pp 338-353.

# Using supervised committee machine artificial intelligent model for improving DRASTIC model (case study: Ardabil plain aquifer)

M. Gharekhani<sup>1</sup>, A. A. Nadiri<sup>2\*</sup> and A. Asghari Moghaddam<sup>3</sup>

<sup>1</sup>Ph.D. Student, Faculty of Natural Science, University of Tabriz, Tabriz, Iran

<sup>2</sup>Assistant Professor, Faculty of Natural Science, University of Tabriz, Tabriz, Iran

<sup>3</sup>Professor, Faculty of Natural Science, University of Tabriz, Tabriz, Iran

Received: 2016 April 30

Accepted: 2016 August 15

## Abstract

Due to the infiltration of contaminants from surface to underground water systems, groundwater pollution is one of the serious problems, especially in arid and semi-arid areas that encounter with lack of quality and quantity of water resources. Therefore, groundwater vulnerability evaluation is necessary to manage the ground water resources by identifying areas with high potential of contamination. In this study, ground water vulnerability in Ardabil plain aquifer was evaluated by applying DRASTIC model. DRASTIC model was prepared by seven effective parameters on vulnerability, including groundwater depth, net recharge, aquifer media, soil media, topography, impact of vadose zone, and hydraulic conductivity. These parameters were prepared as seven raster layers, then DRASTIC index was then calculated after ranking and weighting. The DRASTIC index value was obtained between 82 to 151 for the Ardabil plain. The main problem of this model is the subjectivity in determining rates and weights of the parameters. Therefore, the purpose of this study is to improve DRASTIC model using the 5 methods of artificial intelligence (AI), such as Feedforward network (FFN), Recurrent neural network (RNN), Sugeno fuzzy logic (SFL), Mamdani fuzzy logic (MFL), and Committee machine (CM) to obtain the most accurate results of vulnerability evaluation. With respect to Ardabil plain heterogeneity, It is, divided into 3 sections including west, east and north, and each section needs an individual model. For this purpose, the DRASTIC parameters and the vulnerability index were defined as inputs data and output data respectively for models, and nitrate concentration data were divided into two categories for training and test steps. The output of model in training step was corrected by the related nitrate concentration, and after model training, the output of model in test step was verified by the nitrate concentration. The results show that all of the artificial intelligence methods are able to improve the DRASTIC model, but the supervised committee machine artificial intelligence (SCMAI) model had the best results. According to this model, the most of high pollution potential areas located in western and northern parts of the plain, and where need more protection.

**Keywords:** Groundwater Vulnerability, Ardabil Plain, DRASTIC, Artificial Intelligence, SCMAI model.

For Persian Version see pages 113 to 124

\*Corresponding author: A. A. Nadiri; E-mail: nadiri@tabrizu.ac.ir