

## تخمین نیترات آب زیرزمینی دشت همدان - بهار با استفاده از شبکه عصبی مصنوعی و اثر تفکیک داده‌ها بر دقت پیش‌بینی

حمید زارع ابیانه<sup>۱\*</sup>، مریم بیات ورکشی<sup>۲</sup>، سمیرا اخوان<sup>۳</sup>، محمد محمدی<sup>۴</sup>

۱-استادیار گروه مهندسی آب دانشکده کشاورزی، دانشگاه بوعلی سینا

۲-دانش آموخته کارشناسی ارشد آبیاری و زهکشی دانشکده کشاورزی، دانشگاه بوعلی سینا m.bayat.v@gmail.com

۳-استادیار گروه مهندسی آب دانشکده کشاورزی، دانشگاه بوعلی سینا S.Akhavan@basu.ac.ir

۴-کارشناس آبیاری، دانشگاه بوعلی سینا md\_mohamadi2020@yahoo.com

تاریخ دریافت: ۸۹/۱/۲۲ تاریخ پذیرش: ۸۹/۸/۲۲

### چکیده

کسب اطلاعات لازم در خصوص نیترات در منابع آب زیرزمینی مستلزم اندازه‌گیری‌های دقیق دوره‌ای است که با وجود اندازه‌گیری آن در برخی مناطق، به علت حساسیت‌های اجتماعی و سلامتی جامعه گزارش نمی‌شود. بنابراین مدل‌سازی آن به علت اطلاع از وضعیت کیفی آب هر منطقه ضروری به نظر می‌رسد. هدف این مطالعه استفاده از روش شبکه عصبی مصنوعی در برآورد نیترات و مقایسه آن با مقادیر اندازه‌گیری شده و بررسی تأثیرپذیری برآورد نیترات از تعداد و ماهیت اطلاعات ورودی به مدل شبکه عصبی بود. داده‌ها از آمار و اطلاعات کمی و کیفی ۵۳ حلقه چاه آب زیرزمینی دشت همدان - بهار در دو گروه اطلاعات پرهزینه و کم هزینه، طی سالهای ۱۳۸۲ تا ۱۳۸۷ اخذ شد. در گروه اطلاعات پرهزینه از ۱۳ متغیر مستقل شیمیایی به عنوان ورودی شبکه عصبی مصنوعی و در گروه کم هزینه از ۷ و ۸ متغیر به تفکیک برای مدل‌سازی نیترات استفاده شد. مقایسه نتایج آزمون هر سه آرایش، حاکی از توانایی بالای مدل شبکه عصبی در پیش‌بینی غلظت نیترات است. مقایسه میانگین خطاهای حاصل از هر سه مدل شبکه عصبی با آزمون t و آماره Z نشان داد که تفاوت معنی‌داری بین نتایج مدل‌ها وجود ندارد. بنابراین استفاده از اطلاعات گروه دوم در ورودی شبکه عصبی قابل توجه است. مشخصه‌های ورودی مدل پیشنهادی شامل خصوصیات ژئومورفولوژی عمق استاتیک، عمق چاه، مختصات جغرافیایی و اطلاعات کیفی دما، pH، هدایت الکتریکی نمونه‌های آب اندازه‌گیری شده است که موفق به پیش‌بینی غلظت نیترات با اطمینانی بیش از ۸۰ درصد شد که مؤید کارایی مناسب مدل در آبخوان دشت همدان - بهار است.

### کلید واژه

نیترات، پیش‌بینی، شبکه عصبی مصنوعی، همدان

### سر آغاز

افزایش عملکرد محصولات کشاورزی را به دنبال دارد. هر چند کاربرد نامناسب نیتروژن می‌تواند باعث کاهش عملکرد و یا آلوده شدن آب‌های زیرزمینی به نیترات شود (حسینی و همکاران، ۱۳۸۷). وجود مواد آلی در خاک، تجزیه آنها توسط جمعیت میکروبی و استفاده از کودهای شیمیایی، از منابع عمده نیتروژن خاک هستند. بررسی‌ها نشان داده در دهه‌های گذشته به دلیل افزایش عملکرد محصولات کشاورزی، هزینه کم کودهای شیمیایی و رشد صنایع و شهرنشینی، مصرف مواد نیتروژنه افزایش یافته است (جلالی و کلاهی، ۱۳۸۴؛ فلاح و همکاران، ۱۳۸۵). در این زمینه تمهیداتی برای کنترل آلودگی منابع آب با ایجاد شبکه‌های جمع‌آوری و

استان همدان یکی از مناطقی است که اقتصاد آن بر پایه تولید محصولات کشاورزی و باغی است. همدان منطقه‌ای نیمه سردسیر است که محصولات کشاورزی آن نسبت به مناطق معتدل کشور دیرتر به دست می‌آید و از نظر اقتصادی سود حاصل از فروش آن کم است. بنابراین کشاورزان برای کسب سود بیشتر، مایل به استفاده از کودهای شیمیایی و مواد مغذی افزودنی به خاک، به منظور افزایش حجم محصولات کشاورزی هستند. حفظ کیفیت آب به عنوان یکی از نهاده‌های اساسی ارزشمند از حیث آلودگی به دلیل سلامتی مصرف کنندگان لازم است. در بین عناصر غذایی، نیتروژن

همکاران، ۱۳۸۷). Kaluli و همکاران (1998) از شبکه عصبی با ساختار چهار لایه برای پیش‌بینی نیترات در خاک ناحیه ریشه استفاده کردند. آنان شبکه عصبی سه لایه با ۱۲ نرون اطلاعاتی در لایه ورودی، چهار نرون در لایه دوم و شش نرون در لایه سوم به کار بردند. Diamantopoulou و همکاران (2005) ورودی‌های متفاوتی را در ساختار شبکه عصبی برای پیش‌بینی نیترات رودخانه آکسیوس در شمال یونان استفاده کردند. آنان با استفاده از ۹ ورودی دبی، دما، هدایت الکتریکی، pH و مقادیر آمونیاک و کاتیون‌ها موفق به برآورد نیترات با ۱۹ درصد خطا شدند.

Ramasamy و همکاران (2003) نیترات را تابعی از یون‌های موجود در آب زیرزمینی دانسته و با مدل‌سازی به روش ANN و لحاظ ۶ مشخصه ورودی توانستند نیترات را پیش‌بینی کنند. در تحقیقی مشابه Ray and Klindworth (2000) نیز توانایی شبکه عصبی مصنوعی برای پیش‌بینی غلظت نیترات در چاه‌های آب را تأیید کردند. در مطالعه‌ای دیگر Almasri and Kaluarachchi (2005) از دو طریق سیستم اطلاعات جغرافیایی<sup>۲</sup> (GIS) و شبکه عصبی مصنوعی، موفق به برآورد نیترات آب زیرزمینی در آبخوان‌های منطقه واشنگتن شدند. Yesilnacar و همکاران (2008) غلظت نیترات موجود در چاه‌های آب زیرزمینی دشت هاران<sup>۳</sup> در ترکیه را بررسی و از تکنیک ANN با الگوریتم لونبرگ مارکوات، غلظت نیترات را با دقت بالا پیش‌بینی کردند.

با توجه به افزایش بی‌رویه جمعیت در سالهای اخیر، محدودیت منابع آبهای سطحی، خشکسالی‌های رخ داده و بهره‌برداری بی‌رویه از منابع آب زیرزمینی در کنار فعالیت‌های کشاورزی، صنعتی و شهری، آلاینده‌های مختلفی را به سفره‌های آب زیرزمینی تخلیه کرده است. برای جلوگیری از افت کیفی منابع آب موجود، مدیریت حفاظت از آب‌های زیرزمینی می‌باید به عنوان یک اصل در برنامه‌ریزی‌ها در نظر گرفته شود.

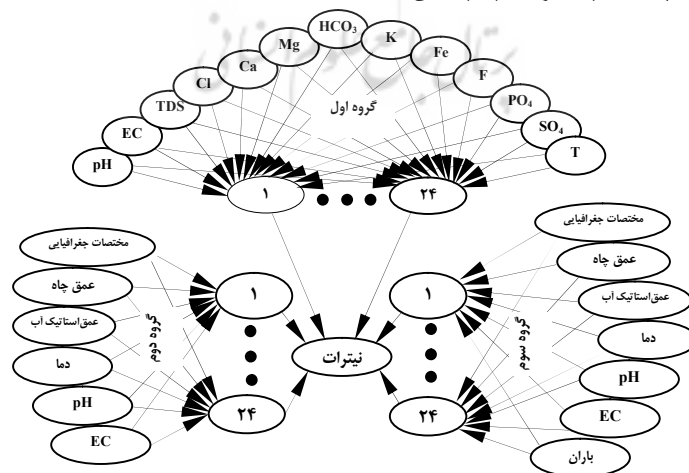
شهرستان همدان یکی از قطب‌های عمده تولید سیب‌زمینی، سیر، یونجه و گردوی کشور است که زیادی نیترات در آب و خاک منطقه علاوه بر جمعیت استانی برای جمعیت غیراستانی نیز خطرناک است. در این مقاله تلاش شد تا نقش کمیت و کیفیت داده‌های ورودی به مدل شبکه عصبی برای پیش‌بینی غلظت نیترات مورد ارزیابی قرار گیرد که در این خصوص منابع آب زیرزمینی شهرستان همدان با توجه به احتمال آلاینده‌گی آن در منطقه، به عنوان منطقه مطالعاتی در نظر گرفته شد.

تصفیه‌خانه‌های فاضلاب لحاظ شده است (تائبی و وشتانی، ۱۳۷۹). لیکن نیتروژن به دلیل تحرک زیاد و آبشویی آن از پروفیل خاک، نیروی بیشتری برای تخریب کیفیت آبهای زیرزمینی دارد (رهبری و همکاران، ۱۳۸۶). زیادی نیتروژن در منابع آب زیرزمینی، علاوه بر مشکلات اقتصادی و زیست محیطی (خسروی دهکردی و همکاران، ۱۳۸۴) از نظر سلامتی در کودکان، بیماری متهموگلوبینمیما، در بزرگسالان، ایجاد ترکیبات سرطانزا (یوسفی و نائیج، ۱۳۸۶) و در گیاهان، بی‌نظمی‌های فیزیولوژیک و رشد بی‌رویه گیاهان آبی (جلالی و کلاهچی، ۱۳۸۴) را به دنبال دارد. این درحالی است که در برخی مناطق کشور، از جمله همدان (جلالی و کلاهچی، ۱۳۸۴)، مشهد (لطیف، ۱۳۸۱)، بابل (محسنی، ۱۳۶۵)، آمل (یوسفی و نائیج، ۱۳۸۶)، اصفهان (جعفری ملک‌آبادی و همکاران، ۱۳۸۳) و زنجان (محمدیان فضلی و صادقی، ۱۳۸۲) وجود غلظت‌های بالای نیترات گزارش شده است. اگرچه اندازه‌گیری نیترات در تعدادی از آبخوانها انجام می‌شود، اما مهندسان معمولاً با شرایطی مواجهند که حجم اطلاعات موجود، کم و یا اندازه‌گیری‌ها به خاطر زمان‌بر بودن و هزینه زیاد تحت تأثیر مسائل اقتصادی قرار می‌گیرند. در حالی که نیترات یکی از آلاینده‌های مهم و قابل اندازه‌گیری در یک سفره آب زیرزمینی است که به خاطر مسائل اجتماعی و تبعات سلامتی ناشی از آن گزارش نمی‌شود. نیترات شاخص خوبی برای نشان دادن آلودگی از نظر بهداشت آب آشامیدنی است که به عنوان یک ماده مغذی بوجود آورنده یوتروفیکاسیون نیز حائز اهمیت است (تائبی و وشتانی، ۱۳۷۹). به همین منظور استفاده از راه‌حل‌های غیرمستقیم، برای تخمین یون نیترات از سایر یون‌های اندازه‌گیری شده به جهت عدم صرف هزینه مورد توجه است. به لحاظ غیرخطی بودن برخی فرآیندهای فیزیکی و عدم قطعیت در مشخصه‌های تأثیرگذار می‌توان از تکنیک مدل‌سازی جهت شبیه‌سازی و پیش‌بینی فرآیندهای غیرخطی و غیر قطعی، استفاده کرد (Nayak, et al., 2006 و صفوی، ۱۳۸۹). برخی مطالعات در خصوص شبیه‌سازی جابجایی نیترات با استفاده از نرم‌افزارهای DRAINMODE-N (نوری و همکاران، ۱۳۸۹؛ رهبری و همکاران، ۱۳۸۶) و LEACHN (رهبری و همکاران، ۱۳۸۶؛ بهمنی و همکاران، ۱۳۸۸) صورت گرفته است. پیشرفت‌های اخیر در استفاده از مدل‌های هوشمند شامل به‌کارگیری تکنیک شبکه‌های عصبی مصنوعی<sup>۱</sup> (ANN) با عملکرد مناسب‌تر نسبت به سایر مدل‌های آماری است (آذری و همکاران، ۱۳۸۷، نوری و

## مواد و روشها

( $Fe^{2+}$ ) بود. همچنین خصوصیات ژئومورفولوژی هر چاه مانند عمق چاه، عمق استاتیک آب و مختصات جغرافیایی (طول و عرض) آن از دفترچه مربوطه استخراج شد. نظر به اهمیت بارش و نقش آن در آیشویی آلاینده‌ها (یوسفی و نائیج، ۱۳۸۶)، مقادیر بارش روزانه در طول دوره آماری از گزارشات ایستگاه سینوپتیک اکباتان استخراج و به کار گرفته شد. عوامل pH، دما، بارش، عمق و هدایت الکتریکی به ترتیب دارای واحد استاندارد، درجه سلسیوس، میلیمتر بر روز، متر و دسی‌زیمنس بر متر و واحد بقیه مشخصه‌ها بر حسب میلی‌گرم در لیتر بود. در بررسی نیترات و مطالعات کیفی آب زیرزمینی ضمن حفظ کیفیت نمونه‌ها، باید نمونه‌گیری در زمانهای مختلف صورت گیرد. در حالی که برخی عوامل مانند خصوصیات ژئومورفولوژی با یک‌بار اندازه‌گیری در طول مدت بهره‌برداری و یا به صورت دوره‌ای برای هر چاه تعیین و عوامل شوری، قلیائیت و دمای آب نیز به صورت درجا<sup>۵</sup> (در محل) برای هر یک از نمونه‌های آب اندازه‌گیری می‌شوند. در چنین شرایطی مقرون به صرفه است که با استفاده از اطلاعات قابل دسترس کمی، اطلاعات قابل اندازه‌گیری در محل و ابزارهای پیش‌بینی به تخمین‌های دقیق و قابل قبولی از نیترات دست یافت. براین اساس متغیرهای پژوهش به دو دسته مستقل و وابسته تقسیم شد که متغیر وابسته، نیترات پیش‌بینی شده در نمونه آب چاهها و متغیرهای مستقل کلیه مشخصه‌های کیفی و کمی هر چاه بود. متغیرهای مستقل در این تحقیق به سه گروه تقسیم شدند که تعداد و نوع آنها در شکل شماره (۱) به نمایش گذاشته شده است.

آبخوان دشت همدان- بهار با وسعت ۲۴۷۵ کیلومترمربع در دامنه شمالی ارتفاعات الوند قرار دارد که در محدوده طول شرقی  $48^{\circ}17'$  تا  $48^{\circ}33'$  و عرض شمالی  $34^{\circ}49'$  تا  $35^{\circ}2'$  واقع است. این دشت یکی از دشت‌های اصلی تأمین‌کننده آب شرب و کشاورزی همدان است که به دلیل افت مداوم و کاهش ذخایر آن و روند افزایشی تخلیه فاضلابهای شهری و صنعتی، مواد زاید و جامد، کاربرد سموم و کودهای شیمیایی در محدوده آن مورد توجه است (احسانی و همکاران، ۱۳۸۶). اقلیم دشت نیمه خشک سرد با میانگین دمای حداقل و حداکثر  $2/8$  و  $19/2$  درجه سلسیوس و بارش بلند مدت سالانه  $312/3$  میلیمتر است (کازمی، ۱۳۸۵). در بررسی‌های صورت گرفته نیترات به عنوان مهم‌ترین آلاینده آب زیرزمینی در محدوده مورد مطالعه است (ناصری و ندافیان، ۱۳۸۷). بنابراین گزارش‌های آماری ۲۶ حلقه چاه آب شرب حفر شده در قسمت‌های مختلف سفره آب زیرزمینی شهر همدان طی دوره آماری ۱۳۸۲ تا ۱۳۸۷ جمع‌آوری شد (آب منطقه‌ای همدان، ۱۳۸۸). در مجموع از اطلاعات کمی و کیفی ۸۰۰ نمونه آب اندازه‌گیری شده توسط آب منطقه‌ای همدان در روزهای مشخص از ماههای مختلف دوره مورد مطالعه که موجود بود، استفاده شد. مشخصه‌های کیفی هر نمونه شامل نیترات ( $NO_3^-$ )، هدایت الکتریکی<sup>۴</sup> (EC)، pH، هاش (pH)، دمای آب، یون‌های بی‌کربنات ( $HCO_3^-$ )، کلرید ( $Cl^-$ )، سولفات ( $SO_4^{2-}$ )، کلسیم ( $Ca^{2+}$ )، منیزیم ( $Mg^{2+}$ )، سدیم ( $Na^+$ )، پتاسیم ( $K^+$ )، فسفات ( $PO_4^{3-}$ )، فلوراید ( $F^-$ )، آهن



شکل شماره (۱): ساختار شبکه عصبی مصنوعی مورد استفاده

شامل مختصات جغرافیایی، عمق چاه و عمق استاتیک آب و دما، pH و هدایت الکتریکی هر نمونه آب مدنظر قرار گرفت.

گروه اول به عنوان گروه پرهزینه شامل ۱۳ مشخصه شیمیایی آب و دمای آب بود. در گروه دوم خصوصیات ژئومورفولوژی چاهها

استفاده شود. از آنجایی که نرم‌افزار NeuroSolution قابلیت نرمال‌سازی داده‌ها را دارد بنابراین انجام این مرحله به صورت خودکار توسط نرم‌افزار انجام شد. در نهایت تمامی داده‌های موجود به صورت تصادفی به دو دسته آموزش<sup>۱۱</sup> (۷۰ درصد) و واسنجی<sup>۱۱</sup> (۳۰ درصد) تقسیم شد.

این تقسیم‌بندی براساس عرف معمول بوده و قاعده خاصی در این خصوص وجود ندارد (آذری و همکاران، ۱۳۸۷). اگرچه مطالعات مختلف نشان داده است که به جهت آموزش بهتر شبکه عصبی مصنوعی تعداد داده‌های آموزش می‌باید بیش از مرحله واسنجی باشد (Diamantopoulou, et al., 2003; Ramasamy, et al., 2003).

در این تحقیق برای انتخاب تعداد تکرار مناسب برای هر یک از سه آرایش پیشنهادی از کردار خطا برحسب تعداد تکرار<sup>۱۲</sup> استفاده شد. برای مقایسه برآوردهای شبکه عصبی مصنوعی، از شاخص‌های میانگین خطای مطلق (MAE)، مجذور میانگین مربعات خطا (RMSE)، میانگین درصد خطا (MPE) استفاده شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (۱)$$

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad (۲)$$

$$MPE = \sum_{i=1}^n \frac{|X_i - Y_i|}{Y_i} \times 100 \quad (۳)$$

همچنین از شاخص ضریب همبستگی (r) که تعیین کننده تناسب برازش مدل رگرسیون خطی به جفت داده‌های تخمینی و مشاهداتی است هم استفاده شد.

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (۴)$$

در این روابط،  $X_i$  و  $Y_i$  به ترتیب  $i$  امین داده نیترا برآوردی و اندازه‌گیری،  $\bar{X}$  و  $\bar{Y}$  به ترتیب متوسط داده‌های  $X_i$  و  $Y_i$ ، و  $n$  تعداد نمونه‌های مورد ارزیابی هستند. اختلاف بین نتایج هر سه گروه با در نظر گرفتن سطح معنی‌داری (p < ۰/۰۵) براساس آزمون تی‌استیودنت<sup>۱۳</sup> (t) و آماره Z صورت گرفت. بدین منظور با برازش

در گروه سوم نیز از تمامی اطلاعات گروه دوم و بارش به عنوان نماینده اقلیم منطقه و شاخصی از تغذیه آب زیرزمینی استفاده شد.

متغیرهای گروه دوم و سوم از لحاظ هزینه دستیابی، کم هزینه‌تر، از لحاظ زمان دستیابی، سریع‌تر و از لحاظ خطای اندازه‌گیری، خطای کمتری نسبت به متغیرهای گروه اول دارند (زارع ایبانه و همکاران، ۲۰۰۵). زیرا برای متغیرهای گروه اول، حفظ شرایط کیفی نمونه‌ها و سطح مهارت متصدی آزمایش‌ها به دلیل ضرورت اندازه‌گیری‌های منظم در دقت کار تأثیر دارد. ضمن آن‌که متغیرهای گروه اول در مقایسه با متغیرهای گروه دوم و سوم از تغییرپذیری بیشتری نسبت به زمان برخوردارند.

قابل ذکر است که از تمامی متغیرهای در نظر گرفته شده، بویژه متغیرهای گروه اول به‌طور گسترده‌ای در دیگر مطالعات مشابه استفاده شده است، (Diamantopoulou, et al., 2005; Yesilnacar, et al., 2008). لیکن به صورت دسته‌بندی شده براساس ماهیت آنها کمتر مورد توجه بوده است. برای مدل‌سازی شبکه عصبی مصنوعی از نرم‌افزار NeuroSolution استفاده شد.

این نرم‌افزار، یک مدل شبکه عصبی از نوع پرسپترون چند لایه<sup>۶</sup> (MLP) با الگوریتم آموزش پس‌انتشار پیش‌خور<sup>۷</sup> (FFBP) بر داده‌ها برازش می‌دهد. این شبکه، یکی از مهم‌ترین شبکه‌های عصبی در مدل‌سازی سیستم‌های دینامیکی است که کاربرد فراوان در حل مسائل پیچیده غیرخطی دارد (میرسپاهی و همکاران، ۱۳۸۵; Ardicioglu, et al., 2007; Adineh, et al., 2008). مدل فوق دارای یک لایه ورودی، یک لایه پنهان و یک لایه خروجی بود. تعداد نرون‌های ورودی‌ها برای هر مدل مطابق شکل شماره (۱) معادل ۱۳، ۷ و ۸ نرون اطلاعاتی بود.

همچنین از ۱ تا ۲۴ نرون نیز در لایه میانی به روش تکرار و آزمون استفاده شد. برای آموزش شبکه طراحی شده از الگوریتم آموزش انتشار خطا به عقب، لونیبرگ مارکوات<sup>۸</sup> استفاده شد.

این الگوریتم، روشی غیرخطی، سریع و دقیق در یافتن نقاط حداقل به عنوان جوابهای مطلوب است. در اجرای هر یک از مدل‌های شبکه عصبی، تابع فعال‌سازی سیگموئیدی<sup>۹</sup> به دلیل سادگی مشتق آن به کار گرفته شد که موجب سادگی حل روشهای پس انتشار خطا می‌شود (Zhang, et al., 1998).

همچنین به منظور افزایش دقت و سرعت اجرای شبکه‌های عصبی مصنوعی بایستی از داده‌های نرمال شده در محدوده [۰ و ۱]

نیترات تمامی عوامل بر میانگین مقدار حداقل، مقدار حداکثر و ضریب تغییرات در جدول شماره (۱) ارایه شده است. همان طور که نتایج آمار توصیفی نشان می‌دهد، تمامی عوامل به جز pH تغییرپذیری نسبتاً زیادی را دارند. جدول شماره (۱) نشان می‌دهد دامنه تغییرات نیترات بین ۳ تا حداکثر ۵۱/۷ میلی گرم در لیتر است. اگرچه میانگین غلظت نیترات منطقه، کمتر از حد مجاز این آلاینده (۵۰ میلی گرم در لیتر) است، اما گزارشاتی مبنی بر بالا بودن غلظت نیترات در برخی نقاط منطقه نیز وجود دارد (جلالی و کلاه‌چی، ۱۳۸۴) که لزوم مطالعه بیشتر را می‌رساند.

براساس جدول شماره (۱) ضریب تغییرات نیترات ۳۸ درصد است که زیادی آن نشان‌دهنده تأثیر آلودگی‌های زیست محیطی در منابع آب مورد مطالعه است.

آلودگی منابع آب به نیترات و ترکیب‌های مختلف نیتروژن آن می‌تواند به دلیل موقعیت چاهها نسبت به منابع آلاینده بویژه فاضلابهای شهری باشد. هر چند افزایش مصرف کودهای نیتروژنی به واسطه رشد فعالیت‌های کشاورزی در منطقه و تأثیر بارش و زه‌آبهای ناشی از آبیاری بر جابه‌جایی و نشت به چاهها نیز بی‌تأثیر نیست.

مدل رگرسیون خطی بر مقادیر پیش‌بینی و اندازه‌گیری، اقدام به اعمال آزمون  $t$  بر شیب خط برازشی (رابطه ۵) و آماره  $Z$  بر ضریب همبستگی (رابطه ۶) به صورت جفتی شد. به عبارت دیگر معنی‌داری تفاوت در شیب هر یک از مدل‌ها در مقایسه با آماره  $t$  جدول و ضریب همبستگی براساس مقدار  $Z > 1/96$  در سطح  $0/05$  به‌منظور انتخاب مدل شبکه عصبی مناسب صورت گرفت.

$$t = \frac{|\beta_i - \beta_{(i+1)}|}{\sqrt{sp^2 \left( \frac{1}{SS_{xi}} + \frac{1}{SS_{x(i+1)}} \right)}}, sp = \frac{SS_{ei} + SS_{e(i+1)}}{n_i + n_{(i+1)} - 4} \quad (5)$$

$$Z = \frac{|Z'_i - Z'_{(i+1)}|}{\sqrt{\frac{1}{n_i - 3} + \frac{1}{n_{(i+1)} - 3}}}, Z' = \frac{1}{2} \ln \frac{1+r}{1-r} \quad (6)$$

در روابط فوق،  $\beta_i$  و  $\beta_{(i+1)}$  شیب خطوط برازشی بین دو گروه  $i$  و  $(i+1)$ ،  $SS_e$  مجموع مربعات خطا،  $SS_x$  مجموع مربعات متغیر مستقل،  $n_i$  و  $n_{(i+1)}$  تعداد نمونه‌ها در دو گروه  $i$  و  $(i+1)$  است.

## نتایج و بحث


نتایج آمار توصیفی مؤلفه‌های کیفی مورد استفاده در پیش‌بینی

جدول شماره (۱): شاخص‌های آماری مشخصه‌های مورد استفاده


مشخصه	واحد	میانگین	حداکثر	حداقل	ضریب تغییرات
T	$^{\circ}\text{C}$	۱۶/۵۸	۲۶/۵۰	۴	۰/۲۵
EC	$\mu\text{Sm}^{-1}$	۷۸۶/۵۶	۱۴۴۱	۸/۲۰	۰/۳۱
pH	-	۷/۴۶	۸/۵۳	۶/۸۱	۰/۰۳
$\text{Fe}^{2+}$	$\text{MgL}^{-1}$	۰/۰۲	۰/۵۷	۰	۱/۸۵
$\text{K}^{+}$	$\text{MgL}^{-1}$	۱/۹۵	۴	۰/۰۱	۰/۳۴
$\text{Na}^{+}$	$\text{MgL}^{-1}$	۳۵/۲۶	۱۱۷/۲۰	۰/۶۰	۰/۶۰
$\text{Mg}^{2+}$	$\text{MgL}^{-1}$	۲۵/۷۴	۷۹/۷۰	۱/۹۰	۰/۴۲
$\text{Ca}^{2+}$	$\text{MgL}^{-1}$	۸۴/۱۰	۱۶۱/۶۰	۲۱/۶۰	۰/۳۳
$\text{PO}_4^{3-}$	$\text{MgL}^{-1}$	۰/۳۰	۰/۹۲	۰	۰/۵۳
$\text{HCO}_3^{-}$	$\text{MgL}^{-1}$	۲۵۸/۰۶	۴۲۱/۶۰	۱۳۱/۲۰	۰/۱۸
$\text{SO}_4^{2-}$	$\text{MgL}^{-1}$	۸۰/۳۰	۳۳۲	۰/۱۵	۰/۸۴
$\text{Cl}^{-}$	$\text{MgL}^{-1}$	۵۶/۵۰	۲۰۷/۳۰	۵/۷۰	۰/۵۱
$\text{F}^{-}$	$\text{MgL}^{-1}$	۰/۳۳	۱/۰۵	۰	۰/۵۲
$\text{NO}_3^{-}$	$\text{MgL}^{-1}$	۲۳/۸۸	۵۱/۷۰	۳	۰/۳۸

آب دارد. بدین منظور کردار ستونی میانگین غلظت نیترات تجمع یافته در آب زیرزمینی به تفکیک سالهای مورد مطالعه در شکل شماره (۲) به نمایش گذاشته شده است.

چنانچه خسروی دهکردی و همکاران (۱۳۸۴) و جعفری ملک آبادی و همکاران (۱۳۸۳) عنوان کردند حجم نیتروژن تخلیه شده بر اراضی و آبشویی آن بیشترین تأثیر را روی مقدار نیترات محلول در




نیترات مشاهده شده (میلی گرم در لیتر)



نیترات مشاهده شده (میلی گرم در لیتر)

### شکل شماره (۳): تغییرات مقادیر نیترات مشاهده شده

#### نسبت به مقادیر پیش‌بینی شده در آرایش اول




تکرار محاسباتی

### شکل شماره (۴): روند تغییرات خطای شبکه عصبی مصنوعی

#### (RMSE) برحسب تکرار محاسبات در آرایش اول

#### از نرم‌افزار NeuroSolution

از شکل شماره (۴) این گونه استنباط می‌شود که با افزایش تکرار محاسباتی خطای پیش‌بینی کاهش می‌یابد، اما در تکرار ۵۳ شبکه به حالت پایا رسیده و پس از آن هیچ تغییر خاصی در خطای قابل مشاهده نیست. بنابراین می‌توان ۵۳ تکرار را به عنوان مناسب‌ترین تکرار آموزشی شبکه در شبیه‌سازی غلظت نیترات در آرایش اول دانست. مهاجر و همکاران (۱۳۸۸) عنوان کردند که کاهش خطا با افزایش تعداد تکرارهای آموزشی و سپس ثابت شدن مقدار آن به منزله اتمام کار مدل‌سازی است و ادامه افزایش تعداد تکرارها بهبودی خاصی را در نتیجه ایجاد نمی‌کند. در شکل شماره (۵) برآورد غلظت نیترات نشان از اطلاعات آرایش نرون‌های اطلاعاتی در لایه ورودی داده شده است. برای اجرای این آرایش از



### شکل شماره (۲): روند تغییرات غلظت نیترات طی

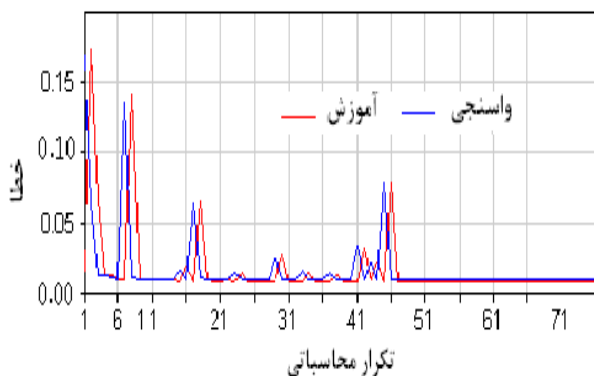
#### دوره مورد مطالعه

همان‌طور که از شکل فوق مشاهده می‌شود میانگین غلظت نیترات در آبخوان منطقه مورد بررسی از ۱۳/۱۷ میلی‌گرم در لیتر در سال ۱۳۸۲ (حداقل ۳ و حداکثر ۳۲) به ۲۶/۵۷ میلی‌گرم در لیتر در سال ۱۳۸۷ (حداقل ۱۳/۲ و حداکثر ۴۹/۸) افزایش یافته است کردار شماره (۲) نشان می‌دهد که ادامه شرایط موجود می‌تواند افزایش بیشتر غلظت نیترات را در پی داشته باشد که لازم است با مدیریت صحیح مصرف مواد نیتروژنه نظیر کودهای کشاورزی از ادامه آن جلوگیری شود.

نتایج فوق کاملاً هماهنگ با یافته‌های محققان قبلی از جمله (Jalali, 2005) و ناصری و ندافیان (۱۳۸۷) در خصوص آلودگی نیترات سفره آب زیرزمینی دشت بهار است. بنابراین مدل‌سازی و پیش‌بینی نیترات با توجه به اهمیت شناخت آن ضروری به نظر می‌رسد.


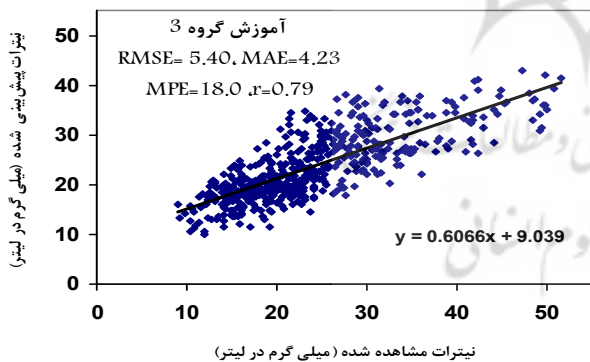
در شکل شماره (۳) نتایج اجرای مدل تدوینی برای آرایش گروه اول شبکه عصبی بر مبنای مجموعه اطلاعات آموزش و واسنجی با ۱۳ عنصر پردازش‌گر در لایه ورودی آمده است. در این شکل، مقادیر نیترات در محور عمودی با استفاده از الگوی پرسپترون و قانون یادگیری لوبنبرگ مارکوات با اجرای شبکه عصبی مصنوعی برآورد شد.

همان‌طور که در شکل شماره (۳) ملاحظه می‌شود، حداقل میانگین مربعات خطای حاصل از اجرای آرایش ۱ در مرحله نهایی (واسنجی) ۴/۹۳ میلی‌گرم در لیتر است که در حالت نرمال شده این مقدار خطا در تکرار ۵۳ به میزان ۰/۰۰۹ میلی‌گرم در لیتر از نرم‌افزار NeuroSolution به دست آمد (شکل شماره ۴).



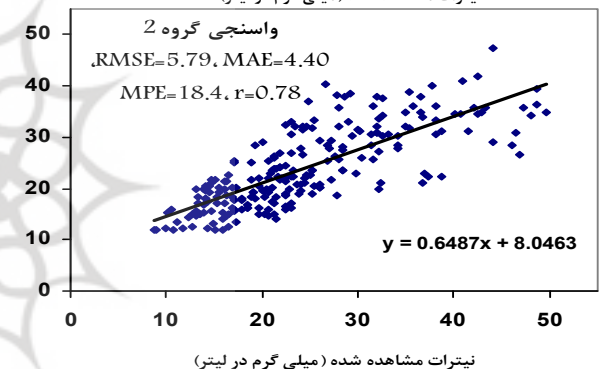

شکل شماره (۶): روند تغییرات خطای شبکه عصبی مصنوعی در تخمین نیترات نسبت به تکرار محاسبات در آرایش اول از نرم افزار NeuroSolution

در شکل شماره (۶) هم ملاحظه می شود افزایش تعداد تکرارهای محاسباتی در کاهش خطای پیش بینی نقش دارد. به طوری که حداقل خطا در ۴۷ تکرار محاسباتی حاصل شد. تعداد تکرارهای این آرایش در مقایسه با آرایش ۱ (شکل شماره ۴) کاهش داشته است لیکن شبکه موفق به کاهش خطای بیشتری در مقایسه با آرایش ۱ نشده است. نتایج اجرای آرایش ۳ شبکه عصبی با هفت ورودی در قالب خط رگرسیون برای دو گروه از داده های واسنجی و آموزش در شکل شماره (۷) ذکر شده است



شکل شماره (۷): تغییرات مقادیر نیترات مشاهده شده نسبت به مقادیر پیش بینی شده در آرایش سوم

مدل شبکه عصبی پرسپترون سه لایه و قانون یادگیری لونیگ-مارکوات با هفت ورودی در لایه اول استفاده شد. در این قسمت نیز با انجام تحلیل رگرسیون خطی بر روی مقادیر نیترات، رابطه بین نیترات پیش بینی و نیترات مشاهده شده همراه ضریب همبستگی و خطای مدل به دست آمد.



شکل شماره (۸): تغییرات مقادیر نیترات مشاهده شده نسبت به مقادیر پیش بینی شده در آرایش دوم

بر اساس شکل شماره (۸)، ضریب همبستگی در این حالت ۰/۷۸ به دست آمد که نشان دهنده ارتباط مناسب مقادیر پیش بینی شده از مدل شبکه عصبی مصنوعی و مشاهداتی از اندازه گیری هاست. به نظر می رسد تغییر ماهیت داده های ورودی و کاهش تعداد آنها در لایه اول شبکه عصبی منجر به افزایش خطای پیش بینی و عدم بهبود خطای شبکه شده است. مقایسه کردار شماره (۵) با کردار شماره (۳) نشان می دهد که در حد بسیار جزیی پراکنش مقادیر نیترات در شکل شماره (۵)، در هر دو گروه اطلاعات آموزش و واسنجی بیشتر است. این گونه استنباط می شود که شبکه عصبی طراحی شده در آرایش شماره ۱ رابطه بین ورودی ها و مقادیر نیترات خروجی را بهتر و با خطای کمتری یاد گرفته است (Piggott, 2003). شکل شماره (۶) نیز مشابه شکل شماره (۴) روند خطای مراحل آموزش و واسنجی پس از اجرای شبکه عصبی با آرایش شماره ۲ را در محیط نرم افزار NeuroSolution نشان می دهد.

جدول برای شیب خط برازشی و آماره  $Z$  برای ضریب همبستگی در جدول شماره (۲) ذکر شده است.


### جدول شماره (۲): نتایج تجزیه و تحلیل آماره‌های مربوط به

#### پیش‌بینی نیترات از سه گروه

معیار	شماره آرایش		
	۳ و ۲	۳ و ۱	۲ و ۱
$Z$	۰/۵۶ ns	۰/۶۱ ns	۱/۱۸ ns
$t$	۰/۷۹ ns	۰/۳۹ ns	۰/۲۹ ns

ns: عدم معنی‌داری در سطح ۰/۰۵

مقایسه مقادیر  $t$  و  $Z$  نشان می‌دهد که بین نرون‌های اطلاعاتی لایه اول از نظر تعداد و ماهیت آنها (پیر هزینه و کم هزینه) تفاوت معنی‌دار وجود ندارد ( $p > 0.05$ ). بنابراین می‌توان اطلاعات مدل دوم، مشتمل بر مشخصات ژئومورفولوژی چاهها، دما، pH و EC را به عنوان ورودی مناسب در شبیه‌سازی نیترات پیشنهاد کرد. برای تشخیص میزان تأثیر عامل بارش در مقابل عوامل غیربارشی بر میزان غلظت نیترات در آب زیرزمینی با ترسیم مقادیر غلظت نیترات مشاهداتی به صورت متناظر با بارش‌های حادث شده و برآورد ضریب تعیین (شکل شماره ۹) مشخص شد تأثیرپذیری نیترات از بارش به دلیل کم بودن ضریب تعیین (۰/۱۳۹)  $R^2 =$  چندان زیاد نیست. کم بودن ضریب تعیین می‌تواند دلیل بر تأثیرگذاری عوامل غیربارشی بر نیترات باشد.



شکل شماره (۹): همبستگی بین بارش سالانه و غلظت نیترات

مشابه چنین نتیجه‌ای از سوی ناصری و همکاران (۱۳۸۵) در بررسی عوامل مؤثر در تغییرات غلظت نیترات آبهای زیرزمینی حوضه قره‌سو در استان گلستان گزارش شده است. از این رو انتخاب ورودی‌های مدل ۲ که تأثیر عامل بارش را حذف می‌کند، مناسب به نظر می‌رسد. بنابراین روند رو به افزایش غلظت نیترات طی سالهای

در مدل طراحی شده برای این حالت (شکل شماره ۷) مشخصه بارش به دلیل تأثیرگذاری بر آبشویی نیترات (جعفری ملک آبادی و همکاران، ۱۳۸۳) به مجموعه نرون‌های آرایش ۲ اضافه شد. به نظر می‌رسد اضافه کردن بارش به منظور بهبود نتایج، مؤثر بوده به طوری که میزان خطای مطلق (MAE)، میانگین درصد خطا (MPE) و مجذور میانگین مربعات خطا (RMSE) شبکه در حالت واسنجی نسبت به آرایش ۲ به ترتیب ۱/۸۲، ۲/۷۲، ۱ و ۲ درصد کاهش و ضریب همبستگی نیز ۲/۶ درصد افزایش داشته است. در بررسی عملکرد آرایش ۳، کردار تعداد تکرارهای محاسباتی برای رسیدن به پایداری در جواب، به تفکیک داده‌های آموزش و واسنجی در شکل شماره (۸) رسم شد. این شکل روند خطا به همراه تعداد تکرارهای محاسباتی را نمایش می‌دهد.



شکل شماره (۸): روند تغییرات خطای شبکه عصبی مصنوعی در

#### تخمین نیترات نسبت به تکرار محاسبات در آرایش اول

##### از نرم‌افزار NeuroSolution

براساس شکل شماره (۸) حداقل خطای نرمال در آرایش ۳ شبکه عصبی ۰/۰۰۹۵ است که در حدود ۱۹ بار تکرار محاسباتی روند خطای آموزش و واسنجی در کمترین مقدار خود همگرا شده است. مقایسه اشکال ۸، ۶ و ۴ نشان می‌دهد که مدل ۱ میانگین خطای کمتری نسبت به دو مدل دیگر دارد. براساس شکل شماره (۸) حداقل خطا ۰/۰۰۹۵ میلی‌گرم در لیتر در مقایسه با مدل یک با ۰/۰۰۹ میلی‌گرم در لیتر و مدل دو با ۰/۰۱ میلی‌گرم در لیتر است. ضمن آن که مدل ۳ در یادگیری الگوهای آموزشی نسبت به دو مدل دیگر موفق‌تر بوده و توانسته است با کاهش حجم عملیات از نظر تعداد تکرار آموزشی، در زمان کوتاه‌تر به جوابهای همگرا دست یابد. با توجه به عدم اختلاف قابل توجه نتایج هر یک از مدل‌های عصبی و به منظور بررسی دقیق‌تر آن به دلیل پیشنهاد آرایش مناسب، سطح معنی‌داری اختلاف‌ها از طریق آزمون  $t$  و آماره  $Z$  مورد بررسی قرار گرفت. نتایج مقادیر  $t$  جفتی محاسبه شده با مقادیر  $t$



که اطلاعات گروه اول زمان بر و هزینه بر هستند. به عبارت دیگر در آرایش ۲ و ۳، ورودی‌ها نسبت به ورودی آرایش ۱ دقیق‌تر و کم هزینه‌تر است و برخی از اطلاعات مانند عمق چاه، ارتفاع استاتیک چاه و مختصات جغرافیایی نسبت به زمان، مقادیر ثابتی محسوب می‌شوند.

۳) مقایسه نتایج این مطالعه نسبت به مطالعات مشابه نظیر (Ramasamy, et al., 2003) با ضریب همبستگی ۰/۷۴ و (Almasri and Kaluarachchi, 2005) با ضریب همبستگی ۰/۷۱ نشان‌دهنده انتخاب مناسب ورودی‌های مدل پیشنهادی بود.

۴) با توجه به نتایج حاصل می‌توان استفاده از شبکه عصبی سه لایه را در تخمین غلظت یون نیترات توصیه کرد. ۵) همان‌طور که محققینی نظیر (Zhang, et al., 1998)، کریمی گوغری و اسلامی (۱۳۸۷) و زارع ایبانه و همکاران (۱۳۸۸) نیز به لحاظ نظری، توانایی تقریب هر تابع پیوسته‌ای را به کمک یک شبکه سه لایه با تعداد کافی نرون گزارش کرده‌اند.

#### یادداشت‌ها

- 1- Artificial Neural Network
- 2- Geograph Information System
- 3- Harran
- 4- Electrical conductivity
- 5- in-situ
- 6- Multi layer perceptron
- 7- Feed-Forward Back Propagation
- 8- Levenberg Marquette
- 9- Sigmoid
- 10- Training
- 11- Testing
- 12- Epoch
- 13- T student

مورد مطالعه می‌تواند ناشی از عوامل دیگر نظیر فاضلابهای شهری و پساب فعالیت‌های کشاورزی باشد. به اعتقاد زارع ایبانه و همکاران (۱۳۸۹) تغذیه نامتعارف منابع آب زیرزمینی دشت از طریق تخلیه فاضلابهای مسکونی شهر همدان در مناطق شهرک فرهنگیان، جورقان و مریانج در جنوب شرق دشت، در افزایش غلظت آلاینده‌ها نقش بسزایی دارد.

کلیه نتایج حاصل برای آبخوان مورد مطالعه صادق است و با توجه به تفاوت شرایط هر آبخوان لازم است برای مناطق دیگر، مدل‌های مورد استفاده کالیبره شوند.

#### نتیجه‌گیری

نتایج به‌دست آمده در آبخوان مورد مطالعه نشان داد مقادیر پیش‌بینی شده برای تمامی مدل‌های عصبی کمتر از ۴/۵ درصد است. این مقدار خطا با دقت در اندازه‌گیری مشخصه‌های ورودی برای شبکه و اجرا در محیط نرم‌افزارهای مختلف عصبی می‌تواند کاهش یابد. میزان تغییرات خطای متوسط فرآیند شبیه‌سازی نیترات حاصل از مدل‌های عصبی، در نوسان بود. به‌طور کلی کمترین میزان خطا مربوط به مدل اول شبکه عصبی به میزان  $RMSE=4/93$  میلی‌گرم در لیتر و بیشترین میزان خطا مربوط به مدل دوم شبکه عصبی به میزان  $RMSE=5/79$  میلی‌گرم در لیتر بود. لازم به ذکر است نتایج فوق در خصوص آبخوان مورد مطالعه صادق است و برای دیگر مناطق مدل نیاز به کالیبراسیون دارد.

۱) در مدل سوم شبکه عصبی، اضافه شدن بارش در ورودی مدل به میزان ۲/۶ درصد خطای مدل را بهبود بخشید.

۲) مقایسه میانگین خطاهای حاصل از هر سه مدل شبکه عصبی با آزمون تی‌استیودنت نشان داد که تعداد و ماهیت داده‌های ورودی در سطح ۰/۰۵ درصد آماری معنی‌دار نیست. بنابراین استفاده از اطلاعات گروه دوم در ورودی شبکه عصبی قابل توجیه است. چرا

#### منابع مورد استفاده

آذری، ۱. و همکاران، ۱۳۸۷. برآورد میزان بار گاز مصرفی شهر تهران با استفاده از فناوری شبکه‌های عصبی. نشریه دانشکده فنی. جلد ۴۲، شماره ۸ صص ۹۶۱ تا ۹۶۸.

احسانی، ح.ر. و همکاران، ۱۳۸۶. بررسی روند تغییرات نیترات و کل جامدات محلول در آبهای شرب زیرزمینی دشت همدان - بهار با استفاده از سیستم اطلاعات جغرافیایی (GIS). مجموعه مقالات دهمین همایش کشوری بهداشت محیط.

امور آب استان همدان، ۱۳۸۸. گزارش مطالعات آبهای زیرزمینی چهار دشت همدان در سال آبی ۱۳۸۵-۱۳۸۴، دفتر مطالعات منابع آب استان همدان، امور آب استان همدان.

بهمنی، ا. و همکاران. ۱۳۸۸. بررسی نیروی شستشوی نیترات و آمونیوم در پروفیل خاک تحت تأثیر کم آبیاری. مجله آبیاری و زهکشی ایران. جلد ۳، شماره ۱ صص ۳۷ تا ۴۴.

تائبی، ا. و وشتانی، م. ۱۳۷۹. پیش‌بینی کیفیت رواناب شهری: بررسی روشها و ارائه مدل منتخب. نشریه دانشکده فنی، جلد ۳۴، شماره ۴ صص ۴۱ تا ۴۸.

جلالی، م. و کلاهچی، ز. ۱۳۸۴. غلظت نیترات در آبهای زیرزمینی منطقه بهار همدان. مجله علوم خاک و آب. جلد ۱۹، شماره ۲ صص ۱۹۴ تا ۲۰۲.

جعفری ملک آبادی، ع. و همکاران. ۱۳۸۳. بررسی غلظت نیترات در آبهای زیرزمینی استان اصفهان. علوم و فنون کشاورزی و منابع طبیعی، سال هشتم، شماره سوم صص ۶۹-۸۲.

حسینی، ی. و همکاران. ۱۳۸۷. مدل سازی واکنش کلزا به تنش‌های توامان شوری و کمبود نیتروژن. علوم و فنون کشاورزی و منابع طبیعی. جلد ۱۲، شماره ۴۶، (ب) صص ۷۲۱ تا ۷۳۵.

خسروی دهکردی، ا. افیونی، م. و موسوی، س.ف. ۱۳۸۴. بررسی تغییرات غلظت نیترات آبهای زیرزمینی حاشیه زاینده‌رود در استان اصفهان. مجله محیط شناسی، شماره ۳۹، صص ۳۳ تا ۴۰.

رهبری، پ. و همکاران. ۱۳۸۶. شبیه‌سازی انتقال نیترات به آبهای زیرزمینی. مجله علوم کشاورزی ایران، جلد ۳۸ صص ۴۷ تا ۵۶.

زارع ایبانه، ح. و همکاران. ۱۳۸۸. ارزیابی کارایی دو نرم‌افزار شبکه عصبی مصنوعی در پیش‌بینی تبخیر-تعرق گیاه مرجع. مجله دانش آب و خاک. جلد ۱۹/۱، شماره ۲ صص ۱۵۱ تا ۱۶۳.

زارع ایبانه، ح.، عبدالصالحی، ا. و کاظمی، آ. ۱۳۸۹. مطالعه خوردگی و رسوب گذاری آبهای زیرزمینی دشت همدان-بهار. علوم و تکنولوژی محیط زیست. دوره دوازدهم، شماره ۲ صص ۸۹ تا ۱۰۳.

صفوی، ح.ر. ۱۳۸۹. پیش بینی کیفی رودخانه‌ها با استفاده از سیستم استنتاج فازی-عصبی تطبیقی. محیط شناسی. سال ۳۶، شماره ۵۳ صص ۱ تا ۱۰.

فلاح، س.ح. و همکاران. ۱۳۸۵. بررسی میزان نیتريت و نیترات در منابع آب آشامیدنی شهر سمنان در سال ۱۳۸۱. مجله دانشکده پزشکی دانشگاه علوم پزشکی گیلان دوره پانزدهم شماره ۶۰، صص ۱ تا ۶.

کاظمی، آ. ۱۳۸۵. ارزیابی شاخص‌های خشکی و خشکسالی در شرایط اقلیمی استان همدان. پایان‌نامه کارشناسی ارشد آبیاری و زهکشی. دانشگاه بوعلیه سینا. به راهنمایی دکتر علی اکبر سبزی‌پرور و دکتر صفر معروفی.

کریمی گوغری، ش. و اسلامی، ا. ۱۳۸۷. پیش‌بینی بارندگی سالانه در استان کرمان با استفاده از شبکه‌های عصبی مصنوعی. مجله آبیاری و زهکشی ایران. جلد ۲، شماره ۲ صص ۱۲۳ تا ۱۳۲.

لطیف، م. ۱۳۸۱. بررسی آلودگی نیترات و منشأیابی آن در آبهای زیرزمینی دشت مشهد. پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه صنعتی اصفهان.

محسنی، ا. ۱۳۶۵. بررسی وضع آلودگی آبهای زیرزمینی به یون نیترات در اثر کاربرد کودهای ازته در شهرستان بابل. پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی، دانشگاه تربیت مدرس.

محمدیان فضل‌ی، م. و صادقی، غ.ر. ۱۳۸۲. بررسی آلودگی منابع تأمین آب آشامیدنی شهر زنجان طی سالهای ۸۰-۷۹. مجله علمی دانشگاه علوم پزشکی و خدمات بهداشتی درمانی زنجان، شماره ۴۳ صص ۴۹ تا ۵۴.

مهاجر، ر.، صالحی، م.ح.، بیگیهرچگانی، ح. ۱۳۸۸. تخمین ظرفیت تبادل کاتیونی خاک با استفاده از رگرسیون و شبکه عصبی. اثر تفکیک داده‌ها بر دقت و صحت توابع. مجله علوم آب و خاک (علوم و فنون کشاورزی و منابع طبیعی). جلد ۱۳، شماره ۴۹ صص ۸۳ تا ۹۸.

میرسپاهی، ع.، حامد موسویان، م.ت. و محمدظاهری، م. ۱۳۸۵. شبیه‌سازی خشک کن بستر سیال غیر مداوم به روش مدل‌سازی عصبی سری‌های زمانی. نشریه دانشکده مهندسی. جلد ۱۸. شماره ۲ صص ۵۷ تا ۶۷.

ناصری، ح. و همکاران. ۱۳۸۵. بررسی عوامل مؤثر در تغییرات مکانی غلظت نیترات آبهای زیرزمینی حوضه آبخیز قره سو، استان گلستان. مجله علوم کشاورزی و منابع طبیعی، جلد ۱۳، شماره ۱ صص ۱۰۸ تا ۱۱۶.

ناصری، ح.ر. و ندفیان، ح. ۱۳۸۷. مدل‌سازی انتقال آلاینده نیترات آبهای زیرزمینی در محدوده چاههای آب شرب. فصل‌نامه زمین‌شناسی ایران، سال دوم، شماره ششم صص ۸۷ تا ۹۸.

نوری، ر.، اشرفی، خ. و اژدرپور، ا. ۱۳۸۷. مقایسه کاربرد روشهای شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره براساس تحلیل مؤلفه‌های اصلی برای پیش بینی غلظت میانگین روزانه کربن مونوکسید: بررسی موردی شهر تهران. مجله فیزیک زمین و فضا، دوره ۳۴، شماره ۱ صص ۱۳۵ تا ۱۵۲.

نوری، ح. و همکاران. ۱۳۸۹. شبیه‌سازی تغییرات سطح ایستابی و غلظت نیترات در اراضی شالیزاری با مدل DRAINMOD-N (مطالعه موردی: کاپیک). مجله دانش کشاورزی (آب و خاک). جلد ۲۰/۱، شماره ۱ صص ۱ تا ۱۱.

یوسفی، ذ. و نائیج، ا. ۱۳۸۶. بررسی و تعیین میزان نیترات منابع آب آشامیدنی روستایی آمل. مجله دانشگاه علوم پزشکی مازندران دوره هفدهم شماره ۶۱ صص ۱۶۱ تا ۱۶۵.

Adineh, V.R., et al. 2008. Optimization of the operational parameters in a fast axial flow CW CO2 laser using artificial neural networks and genetic algorithms. *Optics & Laser Technology*. 40: 1000–1007.

Almasri, M.N. and J.J., Kaluarachchi. 2005. Modular neural networks to predict the nitrate distribution in ground water using the on-ground nitrogen loading and recharge data. *Environmental Modelling & Software* 20: 851-871.

Ardiclioglu, M., O., Kisi, and T., Haktanin. 2007. Suspended sediment prediction by using two different feed-forward backpropagation algorithms. *Can J. Civil Eng.* 34(1): 1–6.

Diamantopoulou, M.J., V.Z., Antonopoulos and D.M., Papamichail. 2005. The use of a neural network technique for the prediction of water quality parameters of Axios River in Northern Greece. *European Water*. 11/12: 55-62.

Jalali, M. 2005. Groundwater geochemistry in the Alisadr, Hamadan, western Iran. *Environ Monit Assess* DOI 10.1007/s10661-009-1007-5.

Kaluli, J.W. C.A., Madramootoo, and Y., Djebbar. 1998. Modeling nitrate leaching using neural networks. *Water Science Technology*. 38(7): 127-134.

Nayak, P.C., Y.R.S., Rao and K.P., Sudheer. 2006. Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water Resources Management* 20: 77-90.

Piggott, J. 2003. Advantical Ltd, Accurate Load Forecasting. You cannot be serious.

Ramasamy,N., et al .2003. Modeling Nitrate Concentration in Ground Water Using Regression and Neural Networks. FREC Research Reports. Department of Food and Resource Economics University of Delaware.

Ray,C. and K.K.,Klindworth .2000. Neural Networks for Agrichemical Vulnerability Assessment of Rural Private Wells. Journal of Hydrologic Engineering, 5 (2): 162-171.

Yesilnacar,M.I., et al .2008. Neural network prediction of nitrate in groundwater of Harran Plain, Turkey. Environ Geol: 56:19–25.DOI 10.1007/s00254-007-1136-5.

Zhang,G., B.E.,Patuwo and M.y.,Hu. 1998. Forecasting with artificial neural networks: the state of the art. International Journal of forecasting. 14: 35-65.

