

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

حمید زارع ابیانه^{۱*}، مریم بیات ورکشی^۲، سمیرا اخوان^۳، محمد محمدی^۴

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

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

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

md_mohamadi2020@yahoo.com ۴- کارشناس آبیاری، دانشگاه بولنی سینا

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 مدل سازی 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 پژوهشی و کم هزینه، طی سالهای ۱۳۸۲ تا ۱۳۸۷ آخذ شد. در گروه اطلاعات پژوهشی از ۱۳ متغیر مستقل شیمیایی به عنوان ورودی شبکه عصبی مصنوعی و در گروه کم هزینه از ۷ و ۸ متغیر به تفکیک برای مدل سازی 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 توجیه است. مشخصه‌های ورودی مدل پیشنهادی شامل خصوصیات ژئومرفولوژی عمیق 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

سرآغاز

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 عمدۀ 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 نیتروژنی افزایش یافته است (جالی و کلاهچی، ۱۳۸۴؛ فلاح و همکاران، ۱۳۸۵). در این زمینه تمهداتی 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 باگی 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 نهادهای اساسی ارزشمند از حیث آلودگی به دلیل سلامتی مصرف کنندگان لازم است. در بین عناصر غذایی، نیتروژن

همکاران، ۱۳۸۷) و همکاران (۱۹۹۸) 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 (۲۰۰۵) 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 آنیون‌ها و کاتیون‌ها موفق به برآورد نیترات با ۱۹ درصد خطا شدند.

Ramasamy و همکاران (۲۰۰۳) 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 (۲۰۰۰) نیز توانایی شبکه عصبی مصنوعی برای پیش‌بینی غلظت نیترات در چاههای آب را تأیید کردند. در مطالعه‌ای دیگر Almasri and Kaluarachchi (۲۰۰۵) از دو طریق سیستم اطلاعات جغرافیایی (GIS) و شبکه عصبی مصنوعی، موفق به برآورد نیترات آب زیرزمینی در آبخوأنهای منطقه واشنگتن شدند. Yesilnacar و همکاران (۲۰۰۸) غلظت نیترات موجود در چاههای آب زیرزمینی دشت هاران^۳ 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 رخداده و بهره برداری 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.

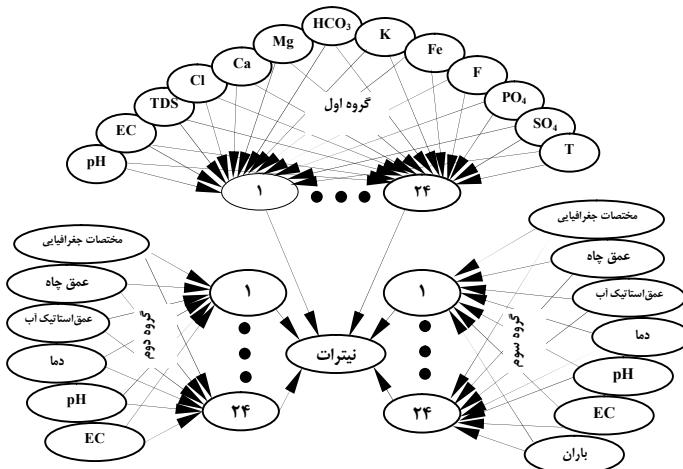
شهرستان همدان یکی از قطب‌های عمده تولید سیب‌زمینی، سیر، یونجه و گردوب کشور است که زیادی نیترات در آب و خاک منطقه علاوه بر جمعیت استانی برای جمعیت غیراستانی نیز خطروناک است. در این مقاله تلاش شد تا نقش کمیت و کیفیت داده‌های ورودی به مدل شبکه عصبی برای پیش‌بینی غلظت نیترات مورد ارزیابی قرار گیرد که در 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 (تابی 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 متهماً گلوبینمیا، در بزرگسالان، ایجاد ترکیبات سرطان‌زا (یوسفی و نائج، ۱۳۸۶) و در گیاهان، بی‌نظمی‌های فیزیولوژیک و رشد بی‌رویه گیاهان آبری (جلالی و کلاهچی، ۱۳۸۴) را به دنبال دارد. این در حالی است که در برخی مناطق کشور، از جمله همدان (جلالی و کلاهچی، ۱۳۸۴)، مشهد (لطیف، ۱۳۸۱)، بابل (محسنی، ۱۳۶۵)، آمل (یوسفی و نائج، 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 زمان بر 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 یوتروپیکاسیون نیز حائز اهمیت است (تابی و وشتانی، ۱۳۷۹). به همین منظور استفاده از راه حل‌های 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 به کارگیری تکنیک شبکه‌های عصبی مصنوعی^۱ (ANN) با عملکرد مناسب‌تر نسبت به سایر مدل‌های آماری است (آذری و همکاران، ۱۳۸۷، نوری و

(Fe^{2+}) بود. همچنین خصوصیات ژئومرفولوژی 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 آبیابی آلاینده‌ها (بوسفی و نائیج، ۱۳۸۶)، مقدار 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 سیلیسیوس، 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 ژئومرفولوژی 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^۵ (در محل) برای هر یک از نمونه‌های آب اندازه‌گیری می‌شوند. در چنین شرایطی مقرر 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 ووابسته 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.

مداد و روشهای

آبخوان دشت همدان- بهار با وسعت ۲۴۷۵ کیلومتر مربع در دامنه شمالی ارتفاعات الوند قرار دارد که در محدوده طول شرقی ۱۷° تا ۴۸° و عرض شمالی ۳۹° تا ۳۴° واقع است. این دشت یکی از دشت‌های اصلی تأمین کننده آب شرب و کشاورزی همدان است که به‌دلیل 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 حداً کثیر $2/8$ و $19/2$ درجه سیلسیوس و بارش بلند مدت سالانه $312/3$ میلیمتر است (کاظمی، 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^۴ (EC)، pH، HCO_3^- ، Cl^- ، سولفات (SO_4^{2-}), کلسیم (Ca^{2+}), مینیزیم (Mg^{2+}), سدیم (Na^+), پتاسیم (K^+), فسفات (PO_4^{3-}), فلوراید (F^-), آهن



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

pH و هدایت الکتریکی هر نمونه آب مدنظر قرار گرفت.

گروه اول به عنوان گروه پژوهیenne شامل ۱۳ مشخصه شیمیایی آب و دمای آب بود. در گروه دوم خصوصیات ژئومرفولوژی چاهه‌ها

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^{۱۰} (۷۰ درصد) و واسنجی^{۱۱} (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 Diamantopoulou, et al., 2003 ; Ramasamy, et al., 2005 باشد ().

در این تحقیق برای انتخاب تعداد تکرار مناسب برای هر یک از سه آرایش پیشنهادی از کردار خطای برحسب تعداد تکرار^{۱۲} استفاده شد. برای مقایسه برآوردهای شبکه عصبی مصنوعی، از شاخص‌های میانگین خطای مطلق (MAE)، مبنور میانگین مربعات خطای میانگین (RMSE)، میانگین درصد خطای (MPE) استفاده شد.

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

$$MAE = \frac{\sum_{i=1}^n |X_i - Y_i|}{n} \quad (2)$$

$$MPE = \frac{\sum_{i=1}^n \left| \frac{X_i - Y_i}{Y_i} \right| \times 100}{n} \quad (3)$$

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

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2(Y_i - \bar{Y})^2}} \quad (4)$$

در این روابط، X_i و Y_i به ترتیب i امین داده نیترات برآورده 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 ($p < 0.05$) براساس آزمون تی استیومنت^{۱۳} (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 تعذیه 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 اوّل دارند (زارع ایانه و همکاران، ۲۰۰۵) زیرا برای متغیرهای گروه اوّل، حفظ شرایط کیفی نمونه‌ها و سطح مهارت متصدی آزمایش‌ها به دلیل ضرورت اندازه‌گیری‌های منظم در دقت کار تأثیر دارد. ضمن آن که متغیرهای گروه اوّل در مقایسه با متغیرهای گروه دوم و سوم از تعییرپذیری بیشتری نسبت به زمان برخوردارند.

قابل ذکر است که از تمامی متغیرهای در نظر گرفته شده، بویژه متغیرهای گروه اوّل به طور گسترده‌ای در دیگر مطالعات مشابه استفاده شده است، Diamantopoulou, et al., 2005 ; Yesilnacar, et al., 2008 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^{۱۴} (MLP) با الگوریتم آموزش پس انتشار پیش‌خور^{۱۵} (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 ; Ardiclioglu, 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 خطای عقب، لونبرگ مارکوات^{۱۶} استفاده شد.

این الگوریتم، روشنی غیرخطی، سریع و دقیق در یافتن نقاط حداقل به عنوان جوابهای مطلوب است. در اجرای هر یک از مدل‌های شبکه عصبی، تابع فعال‌سازی سیگموئیدی^{۱۷} به دلیل سادگی مشتق آن به کار گرفته شد که موجب سادگی حل روش‌های پس انتشار خطای می‌شود (Zhang, et al., 1998).

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

نیترات تمامی عوامل بر میانگین مقدار حداقل، مقدار حداکثر و ضریب تغییرات در جدول شماره (۱) ارایه شده است. همان‌طور که pH نتایج آمار توصیفی نشان می‌دهد، تمامی عوامل به جز 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 (۰/۵ میلی گرم در لیتر) است، اما گزارشاتی مبنی بر بالا بودن غلظت نیترات در برخی نقاط منطقه نیز وجود دارد (جالی 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 زدهای 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 $Z > ۱/۹۶$ در سطح ۰/۰۵ به منظور 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، β_i و $\beta_{(i+1)}$ شیب خطوط برازشی بین دو گروه i و $(i+1)$ ، SS_e مجموع مربعات خطأ، 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

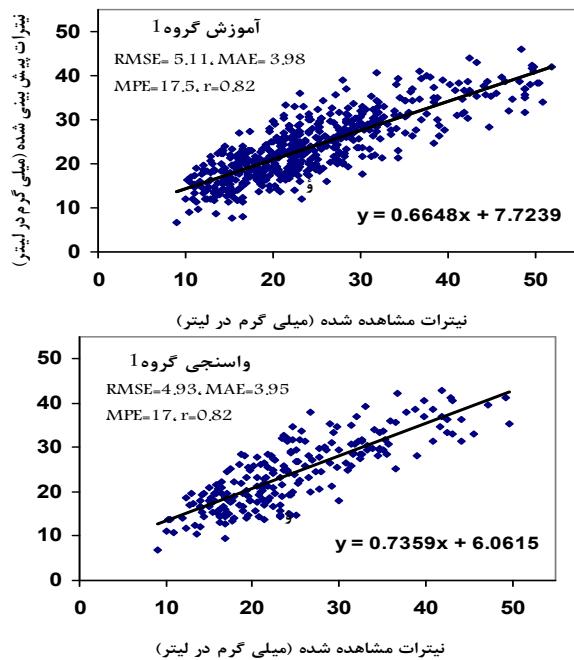
نتایج آمار توصیفی مؤلفه‌های کیفی مورد استفاده در پیش‌بینی

جدول شماره (۱): شاخص‌های آماری مشخصه‌های مورد استفاده

ضریب تغییرات	حداقل	حداکثر	میانگین	واحد	مشخصه
۰/۲۵	۴	۲۶/۵۰	۱۶/۵۸	^0C	T
۰/۳۱	۸/۲۰	۱۴۴۱	۷۸۶/۵۶	$\mu \text{ Sm}^{-1}$	EC
۰/۰۳	۶/۸۱	۸/۵۳	۷/۴۶	-	pH
۱/۸۵	.	۰/۰۷	۰/۰۲	MgL^{-1}	Fe^{2+}
۰/۳۴	۰/۰۱	۴	۱/۹۵	MgL^{-1}	K^+
۰/۶۰	۰/۶۰	۱۱۷/۲۰	۳۵/۲۶	MgL^{-1}	Na^+
۰/۴۲	۱/۹۰	۷۹/۷۰	۲۵/۷۴	MgL^{-1}	Mg^{2+}
۰/۳۳	۲۱/۶۰	۱۶۱/۶۰	۸۴/۱۰	MgL^{-1}	Ca^{2+}
۰/۵۳	.	۰/۹۲	۰/۳۰	MgL^{-1}	PO_4^{3-}
۰/۱۸	۱۳۱/۲۰	۴۲۱/۶۰	۲۵۸/۰۶	MgL^{-1}	HCO_3^-
۰/۸۴	۰/۱۵	۳۳۲	۸۰/۳۰	MgL^{-1}	SO_4^{2-}
۰/۵۱	۵/۷۰	۲۰۷/۳۰	۵۶/۵۰	MgL^{-1}	Cl^-
۰/۵۲	.	۱/۰۵	۰/۳۳	MgL^{-1}	F ⁻
۰/۳۸	۳	۵۱/۷۰	۲۳/۸۸	MgL^{-1}	NO_3^-

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



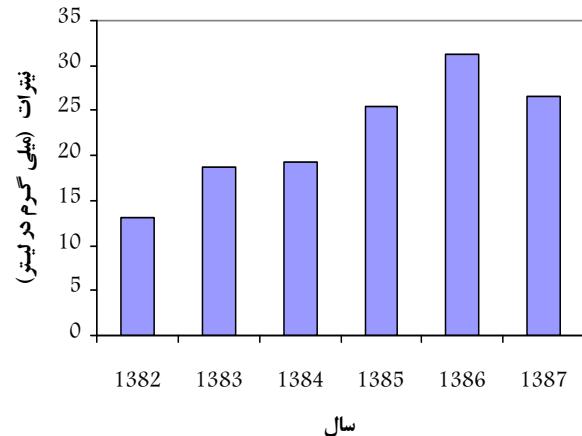
شکل شماره (۳): تغییرات مقادیر نیترات مشاهده شده نسبت به مقادیر پیش‌بینی شده در آرایش اول



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



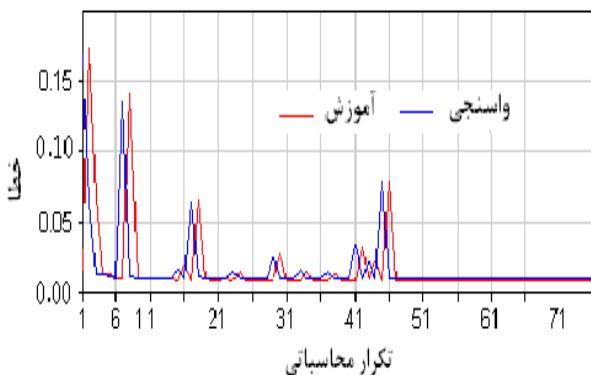
شکل شماره (۲): روند تغییرات غلظت نیترات طی دوره مورد مطالعه

همان طور 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 که دارای 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 نیتروژن نظیر کودهای کشاورزی از ادامه آن جلوگیری شود.

نتایج فوق کاملاً همانگ 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.

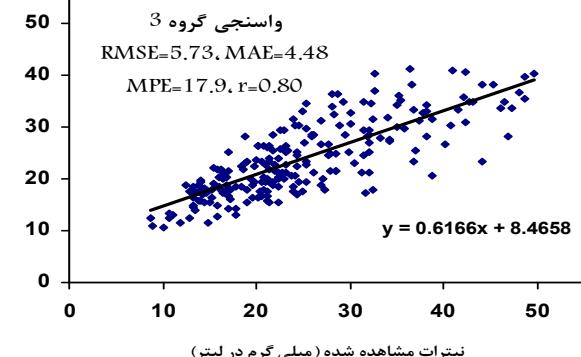
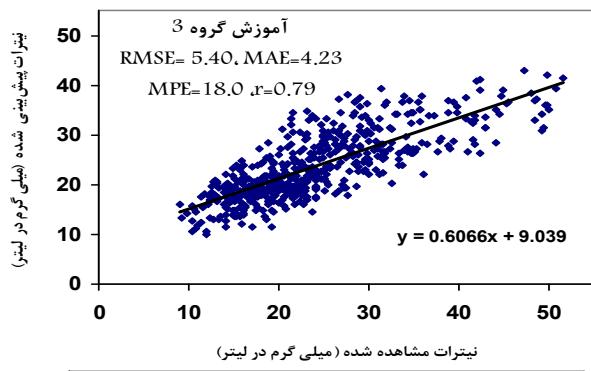
در شکل شماره (۳) نتایج اجرای مدل تدوینی برای آرایش گروه اول شبکه عصبی برمبنای مجموعه اطلاعات آموزش و واسنجی با ۱۳ عنصر پردازش گر در لایه ورودی آمده است. در این شکل، مقادیر نیترات در محور عمودی با استفاده از الگوی پرسپترون و قانون یادگیری لوبنبرگ مارکوات با اجرای شبکه عصبی مصنوعی برآورد شد.

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



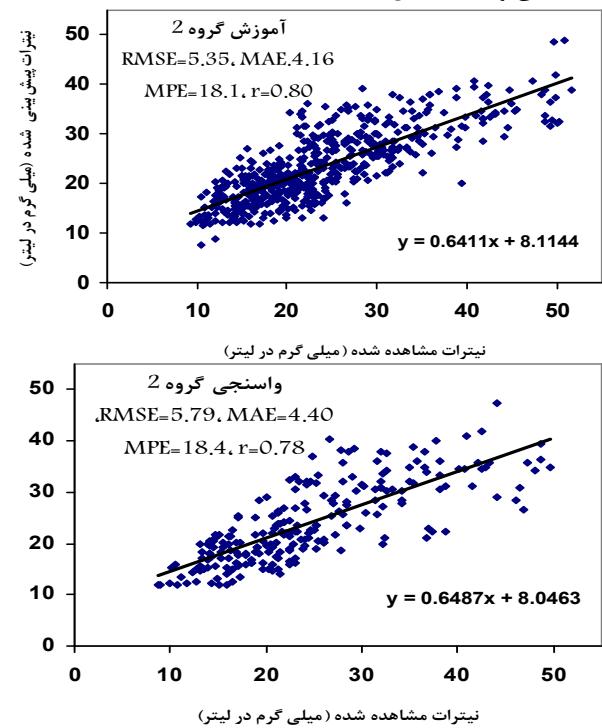
شکل شماره (۶) : روند تغییرات خطای شبکه عصبی مصنوعی در تخمین نیترات نسبت به تکرار محاسبات در آرایش اول از نرم افزار NeuroSolution

در شکل شماره (۶) هم ملاحظه می شود افزایش تعداد تکرارهای محاسباتی در کاهش خطای پیش‌بینی 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 داده‌های واسنجی و آموزش در شکل شماره (۷) ذکر شده است



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

مدل شبکه عصبی پرسپترون سه لایه و قانون یادگیری لوبرگ‌مارکوات با هفت ورودی در لایه اول استفاده شد. در این قسمت نیز با انجام تحلیل رگرسیون خطی بر روی مقادیر نیترات، رابطه بین نیترات پیش‌بینی و نیترات مشاهداتی به همراه ضریب همبستگی و خطای مدل بدست آمد.



شکل شماره (۵) : تغییرات مقادیر نیترات مشاهده شده نسبت به مقادیر پیش‌بینی شده در آرایش دوم

براساس شکل شماره (۵)، ضریب همبستگی در این حالت ۰/۷۸ به دست آمد که نشان‌دهنده ارتباط مناسب مقادیر پیش‌بینی شده از مدل شبکه عصبی مصنوعی و مشاهداتی از اندازه‌گیری‌هاست. به نظر می‌رسد تغییر ماهیت داده‌های ورودی و کاهش تعداد آنها در لایه اول شبکه عصبی منجر به افزایش خطای پیش‌بینی و عدم بهبود خطای شبکه شده است. مقایسه کردار شماره (۵) با کردار شماره (۳) نشان می‌دهد 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 می‌شود که شبکه عصبی طراحی شده در آرایش شماره ۱ رابطه بین ورودی‌ها و مقادیر نیترات (Piggott, 2003). شکل شماره (۶) نیز مشابه شکل شماره (۴) روند خطای مرحله آموزش و واسنجی پس از اجرای شبکه عصبی با آرایش شماره ۲ را در محیط نرم‌افزار NeuroSolution نشان می‌دهد.

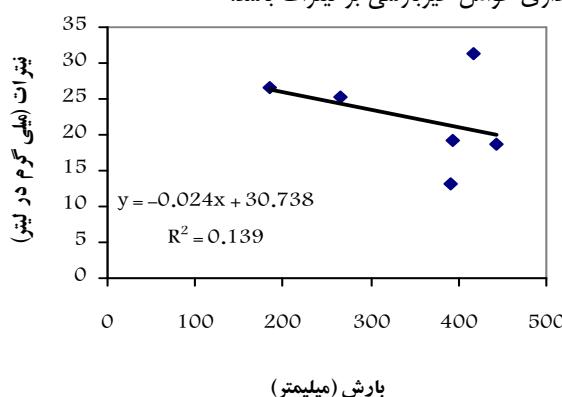
جدول برای شبیه‌سازی و آماره Z برای ضریب همبستگی در جدول شماره (۲) ذکر شده است.

جدول شماره (۲): نتایج تجزیه و تحلیل آماره‌های مربوط به پیش‌بینی نیترات از سه گروه

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

ns: عدم معنی‌داری در سطح ۰/۰۵

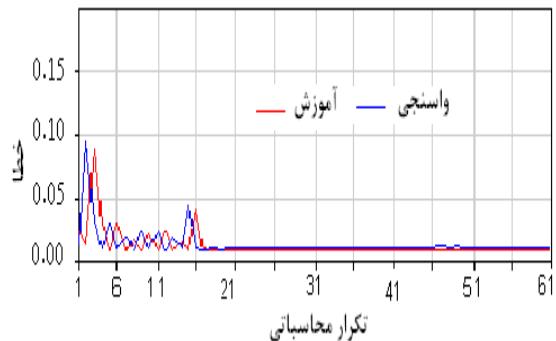
مقایسه مقادیر t و Z نشان می‌دهد که بین نرون‌های اطلاعاتی لایه اول از نظر تعداد و ماهیت آنها (پر هزینه و کم هزینه) تفاوت معنی‌دار وجود ندارد ($p > 0/05$). بنابراین می‌توان اطلاعات مدل دوم، مشتمل بر مشخصات ژئومرفولوژی چاهها، دما، pH و EC را به عنوان ورودی مناسب در شبیه‌سازی نیترات پیشنهاد کرد. برای تشخیص 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 ($R^2 = 0/139$) 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 نتیجه‌های 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 (جغرافی ملک آبادی و همکاران، ۱۳۸۳) به مجموعه نرون‌های آرایش ۲ اضافه شد. به‌نظر می‌رسد اضافه کردن بارش به منظور بهبود نتایج، مؤثر بوده به‌طوری که میزان خطای مطلق (MAE)، میانگین درصد خطای (MPE) و محدود میانگین مربعات خطای (RMSE) شبکه در حالت واسنجی نسبت به آرایش ۲ به ترتیب $۱/۸۲$ ، $۲/۷۲$ و ۱ 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 خطای 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 فرم افزار NeuroSolution

براساس شکل شماره (۸) حداقل خطای نرمال در آرایش ۳ شبکه عصبی مصنوعی در حدود $۰/۰۰۹۵$ 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 خطای $۰/۰۰۹۵$ 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، ورودی ها نسبت به ورودی آرایش ۱ دقیق تر و کم هزینه تر است و برخی از اطلاعات مانند عمق چاه، ارتفاع استاتیک چاه و مختصات جغرافیایی نسبت به زمان، مقادیر ثابتی محسوب می شوند.

(۳) مقایسه نتایج این مطالعه نسبت به مطالعات مشابه نظری (Ramasamy, et al., 2003) با ضریب همبستگی 0.74 و (Almasri and Kaluarachchi, 2005) با ضریب همبستگی 0.71 نشان دهنده انتخاب مناسب ورودی های مدل پیشنهادی بود.

(۴) با توجه به نتایج حاصل می توان استفاده از شبکه عصبی سه لایه را در تخمین غلظت یون نیترات توصیه کرد.

(۵) همان طور که محققین نظری (Zhang , et al., 1998) کریمی گوغری و اسلامی (۱۳۸۷) و زارع ابیانه و همکاران (۱۳۸۸) نیز به لحاظ نظری، توانایی تقریب هرتابع پیوسته ای را به کمک یک شبکه سه لایه با تعداد کافی نرون گزارش کرده اند.

داداشتها

- 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 می تواند ناشی از عوامل دیگر نظری فاضلابهای شهری و پساب فعالیتهای کشاورزی باشد. به اعتقاد زارع ابیانه و همکاران (۱۳۸۹) تقذیه نامتعارف منابع آب زیرزمینی دشت از طریق تخلیه فاضلابهای مسکونی شهر همدان در مناطق شهرک فرهنگیان، جورقان و مریانچ در جنوب شرق دشت، در افزایش غلظت آلاینده ها 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، مدل های مورد استفاده کالیبره شوند.

نتیجه گیری

نتایج بدست آمده در آبخوان مورد مطالعه نشان داد مقادیر پیش بینی شده برای تمامی مدل های عصبی کمتر از $4/5$ درصد است. این مقدار خطا با دقت در اندازه گیری مشخصه های ورودی برای شبکه و اجرا در محیط نرم افزارهای مختلف عصبی می تواند کاهش یابد. میزان تغییرات خطای متوسط فرآیند شبیه سازی نیترات حاصل از مدل های عصبی، در نوسان بود. به طور کلی کمترین میزان خطای مربوط به مدل اول شبکه عصبی به میزان $4/93$ میلی گرم در لیتر و بیشترین میزان خطای مربوط به مدل دوم شبکه عصبی به میزان $5/79$ میلی گرم 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 $2/6$ درصد خطای مدل را بهبود بخشد.

(۲) مقایسه میانگین خطاهای حاصل از هر سه مدل شبکه عصبی با آزمون تی استیوونت نشان داد که تعداد و ماهیت داده های ورودی در سطح $0/05$ درصد آماری معنی دار نیست. بنابراین استفاده از اطلاعات گروه دوم در ورودی شبکه عصبی قابل توجیه است. چرا

منابع مورد استفاده

آذری، ا. و همکاران. ۱۳۸۷. برآورد میزان بارگاز مصرفی شهر تهران با استفاده از فناوری شبکه های عصبی. نشریه دانشکده فنی. جلد ۴۲، شماره ۸ صص ۹۶۸ تا ۶۵.

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 ۱۳۸۴-۱۳۸۵، 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.

تائی، 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.

جالالی، 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. مدل‌سازی واکنش کلزا به تنש‌های 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 ایانه، ح.و همکاران. ۱۳۸۸. ارزیابی کارآیی 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 ایانه، 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. پیش‌بینی کیفی رودخانه‌ها با استفاده از سیستم استنتاج فازی- عصبی تطبیقی. محیط شناسی، سال ۳۶، شماره ۵۳ صص ۱ تا ۱۰.

فالاح، س.ح.و همکاران. ۱۳۸۵. بررسی میزان نیتریت 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 شخص‌های خشکی و خشکسالی در شرایط اقلیمی استان همدان. پایان نامه کارشناسی ارشد آبیاری و زهکشی، دانشگاه بوعلی‌سینا، به راهنمایی دکتر علی اکبر سبزیه‌پرور 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. پایان نامه 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. پایان نامه 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 ۷۹-۸۰. 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 نداییان، 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 پیش‌بینی غلظت میانگین وزانه کربن مونوکسید نیتروز شهر تهران. مجله فیزیک زمین و فضا، دوره ۳۴، شماره ۱ صص ۱۳۵ تا ۱۵۲.

نوری، ح.و همکاران. ۱۳۸۹. شبیه‌سازی تغییرات سطح ایستایی 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. مجلة دانشگاه علوم پزشکی مازندران دوره هفدهم شماره ۶۱ صص ۱۶۱ تا ۱۶۵.

Adineh,V.R., et al .2008. Optimization of the operational arameters 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 backpropogation 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 de 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 artifical neural networks: the state of the art. International Journal of forecasting. 14: 35-65.