



شبیه‌سازی شوری آب زیرزمینی با استفاده از شبکه عصبی مصنوعی، الگوریتم بهینه‌سازی تجمع ذرات و مدل SEAWAT (مطالعه موردی: مزارع کشت و صنعت نیشکر دعبل خزاعی)

*عاطفه صیادی‌شهرکی^۱، امیر سلطانی‌محمدی^۲، عبدالعلی ناصری^۳ و علی مختاران^۴

^۱دانشجوی کارشناسی‌ارشد گروه آبیاری و زهکشی، دانشگاه شهید چمران اهواز، استادیار گروه آبیاری و زهکشی، دانشگاه شهید چمران اهواز،

^۲استاد گروه آبیاری و زهکشی، دانشگاه شهید چمران اهواز، ^۳دکترای گروه آبیاری و زهکشی، دانشگاه شهید چمران اهواز

تاریخ دریافت: ۹۴/۹/۸؛ تاریخ پذیرش: ۹۵/۶/۲۴

چکیده

سابقه و هدف: شوری خاک عامل مهم در کاهش عملکرد مزارع نیشکر واقع در جنوب‌غربی ایران می‌باشد. بنابراین مطالعه و پایش این عامل در زمین‌های تحت کشت نیشکر، امری لازم و ضروری می‌باشد. استفاده از مدل‌های کامپیوتری با توجه به سرعت بالا و هزینه کم، به‌عنوان گزینه‌ای مناسب جهت پایش اراضی مذکور در نظر گرفته می‌شود. بنابراین پژوهش حاضر با هدف دستیابی به بهترین و مناسب‌ترین روش‌ها و مدل‌های تخمین میزان شوری خاک با استفاده از مدل‌های شبکه عصبی (شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی تجمع ذرات) و مدل SEAWAT، در مزرعه R9-11 از مزارع نیشکر دعبل خزاعی خوزستان صورت پذیرفت. ساعی و همکاران (۲۰۰۹)، از مدل شبکه عصبی برای پیش‌بینی شوری خاک استفاده کردند و کارایی خوب این مدل را در پیش‌بینی شوری خاک تایید نمودند.

مواد و روش‌ها: در این پژوهش از شبکه عصبی مصنوعی (ANN)، مدل شبکه عصبی تلفیقی با الگوریتم بهینه‌سازی تجمع ذرات (PSO+ANN) و مدل SEAWAT برای پیش‌بینی شوری آب زیرزمینی استفاده شده است. بدین‌منظور مزرعه R9-11 از مزارع نیشکر دعبل خزاعی خوزستان انتخاب و تعدادی پیزومتر در فواصل مختلف از جمع‌کننده زهاب در ۷ دسته که هر دسته شامل اعماق ۲/۲، ۳، ۴ و ۵ متری از سطح زمین می‌باشد، در لایه‌های مختلف از سطح خاک نصب گردید. تغییرات شوری آب زیرزمینی، حجم آب آبیاری، شوری آب آبیاری، شوری زهاب از آبان‌ماه سال ۱۳۹۲ تا مهرماه سال ۱۳۹۳ به‌صورت روزانه برداشت شد.

یافته‌ها: نتایج نشان داد که بالاترین دقت در پیش‌بینی شوری آب زیرزمینی مربوط به مدل شبکه عصبی با آموزش الگوریتم تجمع ذرات می‌باشد. به‌طوری‌که مقدار میانگین RMSE اعماق مختلف بین مقادیر اندازه‌گیری‌شده و شبیه‌سازی‌شده با مدل‌های شبکه عصبی مصنوعی، مدل شبکه عصبی تلفیقی با الگوریتم بهینه‌سازی تجمع ذرات و SEAWAT به‌ترتیب برابر ۰/۰۹۲، ۰/۰۱۷ و ۰/۷۴۵ به‌دست آمد.

نتیجه‌گیری: به‌طورکلی مقادیر RMSE و MAPE برای ارزیابی دقت مدل‌ها نشان از دقت بالای هر سه مدل (شبکه عصبی مصنوعی، مدل شبکه عصبی تلفیقی با الگوریتم بهینه‌سازی تجمع ذرات و مدل SEAWAT) در شبیه‌سازی شوری آب زیرزمینی می‌باشند که از علل اصلی آن می‌توان به اندازه‌گیری دقیق ورودی‌های مدل‌ها اشاره کرد.

واژه‌های کلیدی: شبیه‌سازی، شبکه عصبی، SEAWAT، شوری، متلب

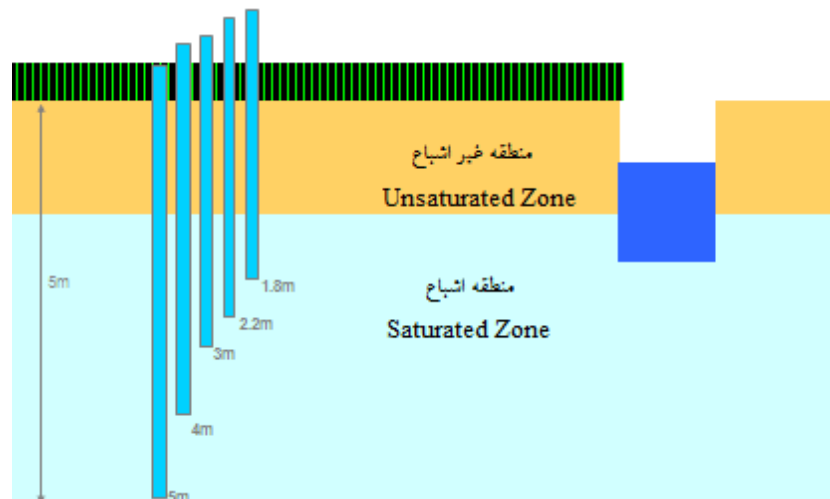
مقدمه

شوری خاک و بالا بودن سطح ایستابی از مهم‌ترین مشکلات محیطی می‌باشند که علاوه بر تأثیر منفی بر رشد و توسعه گیاه سبب تخریب اراضی نیز می‌شوند (۸). امروزه به دلیل کاهش ذخایر آب با کیفیت مناسب و نیاز روزافزون جمعیت در بخش‌های مختلف، استفاده از منابع آب شور برای آبیاری محصولاتی که از طریق کشاورزی آبی یا پمپاژ آب از آبخوان‌ها تولید می‌شوند، امری ضروری است (۷). شرکت توسعه نیشکر و صنایع جانبی در استان خوزستان با داشتن ۷ واحد کشت و صنعت نیشکر در مساحتی بالغ بر ۸۴۰۰۰ هکتار سهم عظیمی از اراضی کشاورزی استان خوزستان را به خود اختصاص داده است. اندازه‌گیری پارامترهای کیفی آب زیرزمینی مستلزم صرف هزینه‌های زیاد و زمان‌بر می‌باشد. مدل‌سازی در مناطق خشک برای مدیریت بهینه منابع آب از اهمیت ویژه‌ای برخوردار است. استفاده از شبکه‌های عصبی مصنوعی در مطالعات دهه اخیر، نشان می‌دهد این مدل توانایی بالایی در کشف رابطه بین داده‌ها و شناخت الگوها دارند (۵). از مدل‌های دیگر که برای شبیه‌سازی شوری آب زیرزمینی به کار می‌رود مدل SEAWAT می‌باشد. این مدل جریان ناپایدار سه‌بعدی آب زیرزمینی با جرم مخصوص ظاهری متغیر را در محیط متخلخل شبیه‌سازی می‌کند (۱۲). ساعی و همکاران (۲۰۰۹)، نیز از مدل شبکه عصبی برای پیش‌بینی شوری خاک استفاده کردند و کارایی خوب این مدل را در پیش‌بینی شوری خاک تأیید نمودند (۱۰). همچنین در پژوهشی دیگر صیام و همکاران (۲۰۱۱)، از مدل‌های شبکه عصبی برای پیش‌بینی شوری آب زیرزمینی نوار غزه استفاده کردند و به این نتیجه رسیدند که شوری آب زیرزمینی با

کاهش دبی، کاهش می‌یابد، همچنین پژوهشگران اعلام کردند که مدل‌های شبکه عصبی روشی مناسب برای پیش‌بینی پارامترهای کیفیت آب می‌باشد (۱۱). هدف از پژوهش حاضر شبیه‌سازی شوری آب زیرزمینی با استفاده از مدل شبکه عصبی مصنوعی با استفاده از نرم‌افزار متلب، الگوریتم بهینه‌سازی ذرات در محیط متلب و نرم‌افزار visual MODFLOW، مدل SEAWAT و در نهایت مقایسه نتایج هر سه مدل با مقادیر اندازه‌گیری شده در مزرعه می‌باشد.

مواد و روش‌ها

این پژوهش در مزرعه R9-11 از کشت و صنعت نیشکر دعبل خزاعی در سال ۹۳-۱۳۹۲ (فروردین ماه ۱۳۹۲ تا مهرماه ماه ۱۳۹۳) انجام گردید. مساحت ناخالص این واحد کشت و صنعت نیشکر ۱۲۰۰۰ هکتار می‌باشد و در ۳۰ کیلومتری جنوب شهرستان اهواز مرکز استان خوزستان و شرق رودخانه کارون قرار گرفته و در طول جغرافیایی ۴۸ درجه و ۳۵ دقیقه و عرض جغرافیایی ۳۱ درجه و ۸ دقیقه می‌باشد. در این پژوهش با توجه به هدف مورد مطالعه، هفت دسته پیزومتر که هر دسته شامل ۴ پیزومتر در اعماق مختلف ۲/۲، ۳، ۴ و ۵ متری در طول نصف مزرعه (۵۰۰ متری) در فاصله‌های مشخص از جمع‌کننده زهاب نصب گردید. به طوری که دسته اول در فاصله پنج متری، دسته دوم در فاصله ۳۰ متری، دسته سوم در فاصله ۵۰ متری، دسته چهارم در فاصله ۲۰۰ متری، دسته پنجم در فاصله ۲۵۰ متری، دسته ششم در فاصله ۳۰۰ متری و بالاخره دسته هفتم در فاصله ۴۰۰ متری از جمع‌کننده زهاب قرار گرفتند. شکل ۱ موقعیت لوله‌های پیزومتريک در مزرعه را نشان می‌دهد.



شکل ۱- شکل نمایی شماتیک از کارگذاری لوله‌های پیزومتریک در یک نقطه از زمین.

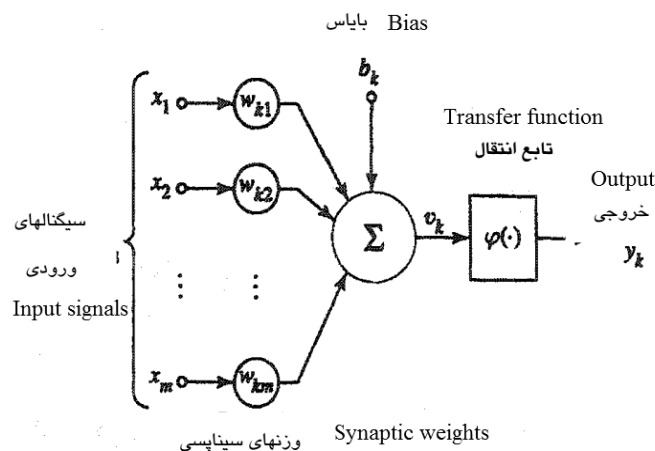
Figure 1. Schematic view of piezometric pipes placed in a spot of land.

یک از سیگنال‌های ورودی X در وزن مربوطه به سیناپس مربوط به آن سیگنال ورودی W را جمع می‌نماید و تابع محرکه φ خروجی را به گونه‌ای محدود می‌نماید که مقدار آن در بازه معینی قرار گیرد. بنابراین B_k یا بایاس یک آستانه خارجی است. بنابراین خروجی Y_k با معادله زیر بیان می‌شود.

$$Y_k = \varphi\left(\sum W_{kj} X_j - \theta_k\right) \quad (1)$$

مدل شبکه عصبی مصنوعی (Artificial Neural Network): عنصر کلیدی این الگو ساختار جدید سیستم پردازش اطلاعات آن می‌باشد و از تعداد زیادی عناصر (نرون) با ارتباطات قوی داخلی که هماهنگ با هم کار می‌کنند، تشکیل شده است. در حالت کلی یک شبکه عصبی از سه لایه ورودی، پنهان و خروجی تشکیل شده است:

نمایش ریاضی شبکه عصبی در شکل ۲ نشان داده شده است. در این شکل جمع‌کننده، حاصل ضرب هر



شکل ۲- مدل غیرخطی (۶).

Figure 2. Non-linear model (6).

D بعدی موقعیت به نام $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$ و سرعت هر ذره به وسیله یک بردار D بعدی سرعت به نام $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ نشان داده می‌شود. سرانجام جمعیت، با استفاده از روابط زیر و به صورت هدفمند به سمت نقطه بهینه حرکت می‌کند.

$$V_{id}^{n+1} = \chi(\omega \cdot v_{id}^n + c_1 r_1^n (p_{id}^n - x_{id}^n) + c_2 r_2^n (p_{pg}^n - x_{id}^n)) \quad (2)$$

$$x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1} \quad (3)$$

که در آن، X فاکتور انقباض، که از آن برای نرخ کارایی و سرعت همگرا شدن استفاده می‌شود، Γ_1 و Γ_2 اعداد تصادفی در بازه [0 1] با توزیع یکنواخت می‌باشد، N شماره تکرارها، c_1 مؤلفه شناختی، بهترین راه‌حلی که یک ذره به دست می‌آورد، c_2 مؤلفه اجتماعی، بهترین راه‌حلی که توسط کل گروه تشخیص داده می‌شود (۳).

انتخاب مقادیر مناسب برای مؤلفه شناختی و اجتماعی منجر به تسریع الگوریتم و جلوگیری از همگرایی زودرس در نقاط بهینه محلی می‌شود. در بهینه‌سازی با استفاده از PSO متغیرهای بهینه‌سازی در آموزش یک شبکه عصبی شامل وزن‌ها و بایاس‌های مربوط به شبکه می‌شوند. روند کار بدین ترتیب است که ابتدا N بردار موقعیت X_i که N برابر با تعداد اعضای دسته است، به صورت تصادفی تولید می‌گردد. شبکه عصبی به‌ازای پارامترهایی برابر با متغیرهای این بردارها اجرا شده و خطای به دست آمده از هر اجرا به‌عنوان میزان برازندگی بردار متغیر آن شبکه در نظر گرفته می‌شود. این روند آن قدر تکرار می‌شود تا همگرایی نهایی حاصل گردد. منظور از همگرایی نهایی رسیدن به بردار موقعیت بهینه (مقادیر وزن‌ها و بایاس‌های بهینه)، به نحوی است که خطای آموزش

با توجه به رابطه ۱ می‌توان گفت پردازش داخلی از دو بخش تشکیل می‌شود. در بخش اول یک مجموع از n مؤلفه بردار ورودی ایجاد شده و سپس یک مقدار بایاس به آن اضافه می‌شود. در بخش دوم یک پردازش غیرخطی صورت می‌پذیرد. این پردازش تابع محرکه Φ نامیده می‌شود. همه پارامترهای ورودی مدل مورد استفاده جهت پیش‌بینی، پارامترهای وابسته به شوری آب زیرزمینی یا پارامتر هدف می‌باشند.

از معضلاتی که در استفاده از شبکه عصبی وجود دارد، مسأله آموزش آن می‌باشد که به روش پس انتشار خطا آموزش داده می‌شود (۶).

الگوریتم بهینه‌سازی ذرات (Particle swarm optimization)

الگوریتم PSO: الگوریتم PSO با ایجاد یک جمعیت تصادفی شروع می‌شود. هر جزء در جمعیت مجموعه مختلف از متغیرهای تصمیم می‌باشند که مقدار بهینه آن‌ها باید تأمین شود و در واقع هر ذره یک بردار را در فضای حل مسأله نشان می‌دهد (۲). در این الگوریتم هر گونه کنش و واکنش در حرکت گروه تأثیر گذاشته و در نهایت هر یک از اعضای گروه می‌توانند از اکتشافات و مهارت‌های سایر اعضا بهره‌مند شوند. تفاوت اساسی این الگوریتم با سایر الگوریتم‌های بهینه‌سازی در این است که در این الگوریتم هر ذره علاوه بر داشتن بردار حرکت دارای یک بردار سرعت نیز می‌باشد که اعضای مجموعه را به تغییر موقعیت در فضای جستجو وادار می‌کند. این بردار سرعت خود برآیند دو بردار به نام‌های p و p_g می‌باشد. p بهترین موقعیتی است که یک ذره تاکنون به آن رسیده و p_g بهترین موقعیتی است که بهترین ذره در همسایگی آن ذره تاکنون به آن رسیده است. در این الگوریتم هر کدام از اعضای مجموعه در هر تکرار یک راه‌حل را ارائه می‌دهند. در جستجوی یک فضای d بعدی، مکان i امین ذره به‌وسیله یک بردار

به‌ازای آن کمینه گردد. بنابراین تابع هدفی که در این بهینه‌سازی باید مینیمم شود عبارتست از میزان خطای پیش‌بینی.

جهت انتخاب درصد داده‌ها جهت آموزش و تست، آنالیز حساسیت مدل نسبت به کمیت داده‌ها انجام شد و نتایج آن در جدول ۱ نشان داده شده است.

جدول ۱- نتایج آنالیز حساسیت مدل نسبت به کمیت داده‌ها.

Table 1. The results of sensitivity analysis of the quantity of data.

80	75	70	درصد داده‌های آموزش The percentage of training data
0.989	0.971	0.89	ضریب تبیین بین مقادیر اندازه‌گیری و شبیه‌سازی Determination coefficient between simulated and measured values

تخلخل مؤثر و کل، پراکندگی‌های افقی و عمودی، عمق کارگذاری و فاصله زهکش‌ها، عمق لایه محدودکننده، ضریب عکس‌العمل زهکش و شار تغذیه می‌باشد. خروجی مدل شامل تغییرات شوری آب زیرزمینی در لایه‌های مختلف می‌باشد. از فرضیاتی که برای اجرای مدل SEAWAT در نظر گرفته شد می‌توان به خطی بودن جریان و به تبع آن معتبر بودن قانون دارسی و قابل اجرا بودن ذخیره ویژه در سفره‌های آبی محدود اشاره کرد (۹).

به‌منظور واسنجی مدل در دو حالت پایدار و ناپایدار از اطلاعات ورودی مدل طی شش‌ماهه ۱۳۹۲/۷/۱۰ تا ۱۳۹۲/۱/۱۰ استفاده گردید. در حالت پایدار بیش‌ترین حساسیت مدل نسبت به کاهش هدایت هیدرولیکی در حالت غیرپایدار، مدل بیش‌ترین حساسیت نسبت به کاهش آبدهی ویژه مشاهده شد. دقت مدل‌سازی و صحت‌سنجی با توجه به ریشه میانگین مربعات خطا مقادیر محاسباتی و مشاهداتی سنجیده شد. میانگین واریانس واسنجی مدل کمی ۰/۵۱ و میانگین واریانس صحت‌سنجی ۰/۸۴ می‌باشد که نشان از دقت خوب واسنجی می‌باشد و با مطالعه چیت‌سازان و همکاران (۱۳۹۱) مطابقت دارد (۴).

با توجه به جدول بالا هرچه به درصد داده‌های آموزش افزوده می‌شود، دقت مدل در شبیه‌سازی بالاتر می‌شود؛ چراکه با افزایش حجم داده‌های آموزش و در اثر کاهش داده‌های آزمون، شبکه قادر به مشاهده حجم بیش‌تری از اطلاعات قبل از انجام شبیه‌سازی است.

بنابراین در این پژوهش ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای اعتبارسنجی مدل در نظر گرفته شدند.

مدل SEAWAT: مدل SEAWAT با روش اختلاف محدود در یک برنامه مجزا، معادلات جریان آب‌های زیرزمینی را براساس اختلاف چگالی با استفاده از مدل MT3DMS حل می‌کند. در این مدل چگالی سیال تنها تابع غلظت املاح بوده و اثر دما روی چگالی سیال مورد توجه نمی‌باشد. تغییرات زمانی و مکانی غلظت املاح در این مدل با استفاده از MT3DMS شبیه‌سازی می‌شود. سپس مدل SEAWAT از روش صریح یا ضمنی برای جفت کردن معادله‌های آب زیرزمینی و معادله‌های انتقال املاح استفاده می‌کند. در این پژوهش از مدل سه‌بعدی SEAWAT هم برای پیش‌بینی شوری آب زیرزمینی استفاده شده است. پارامترهای ورودی مدل شامل: بار هیدرولیکی، شوری آب زیرزمینی، هدایت هیدرولیکی افقی و عمودی، ضریب آبدهی و ذخیره،

شوری بین لایه‌های سطحی تا لایه محدودکننده را ایجاد کرده که منطقه بینابین آب شور و غیرشور را به وجود می‌آورد. با توجه به شکل ۳ مشاهده می‌شود که با فاصله گرفتن از جمع‌کننده زهاب و حرکت از دسته اول به بالادست مزرعه (دسته هفتم) یعنی کاهش عمق کارگذاری لوله‌های زهکشی میزان شوری در تمامی لایه‌ها کاهش می‌یابد. این میزان شوری در دسته اول نسبت به سایر دسته‌ها به‌خصوص در عمق ۵ متری به دلیل نزدیک بودن به جمع‌کننده زهاب و در دسته‌های پنجم و ششم در تمامی لایه‌ها به دلیل هم‌جوار بودن با لوله‌های زهکشی بسیار بالا می‌باشد. همچنین میزان شوری در هر عمق با فاصله گرفتن از جمع‌کننده زهاب کاهش می‌یابد. علت افزایش ناگهانی شوری در اعماق ۴ و ۵ متری در فواصل ۲۵۰ و ۳۰۰ متری از جمع‌کننده زهاب، به دلیل مجاور بودن پیزومترهای کارگذاری شده در دسته‌های پنجم و ششم در کنار لوله‌های زهکش و در نتیجه کوچک شدن جریان شعاعی آب به طرف زهکش‌ها در این اعماق می‌باشد.

معیارهای ارزیابی مدل: برای تعیین میزان دقت مدل‌ها از مقادیر ریشه میانگین مربعات خطا (RMSE) و میانگین درصد خطای مطلق (MAPE) استفاده شد:

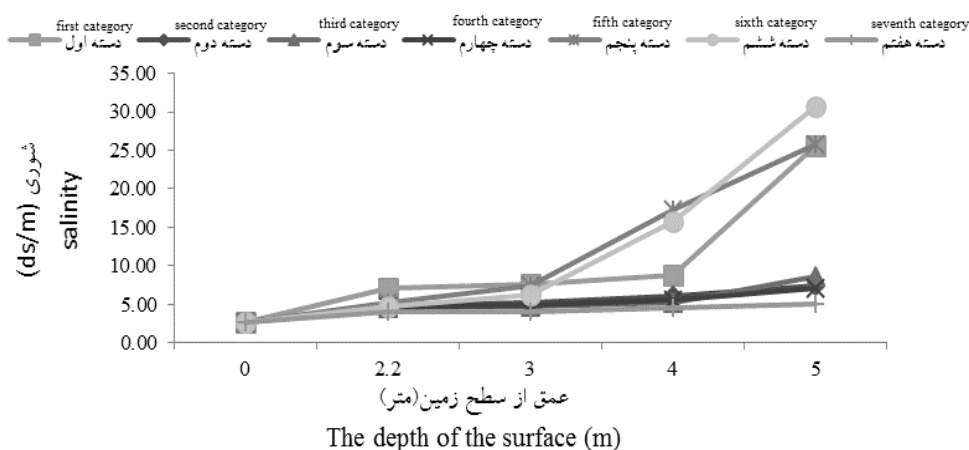
$$RMSE = \sqrt{\frac{1}{n} \sum (y_{observed} - y_{predicted})^2} \quad (4)$$

$$MAPE = 100 * \frac{1}{n} \sum \frac{|y_{observed} - y_{predicted}|}{y_{observed}} \quad (5)$$

که در آن‌ها، $y_{predicted}$ مقادیر پیش‌بینی شده $y_{observed}$ مقادیر مشاهداتی و n تعداد داده‌ها می‌باشد. هرچه مقادیر RMSE و MAPE به صفر نزدیک‌تر باشد، دقت مدل در پیش‌بینی بهتر است.

نتایج و بحث

نوسانات شوری آب زیرزمینی در لایه‌های مختلف از سطح زمین و در هفت تکرار در هر لایه مورد بررسی قرار گرفته است. در پژوهش حاضر شوری نسبت به عمق در تمامی دسته‌ها افزایش یافت. این اختلاف چگالی ناشی از تغییر غلظت، توزیع

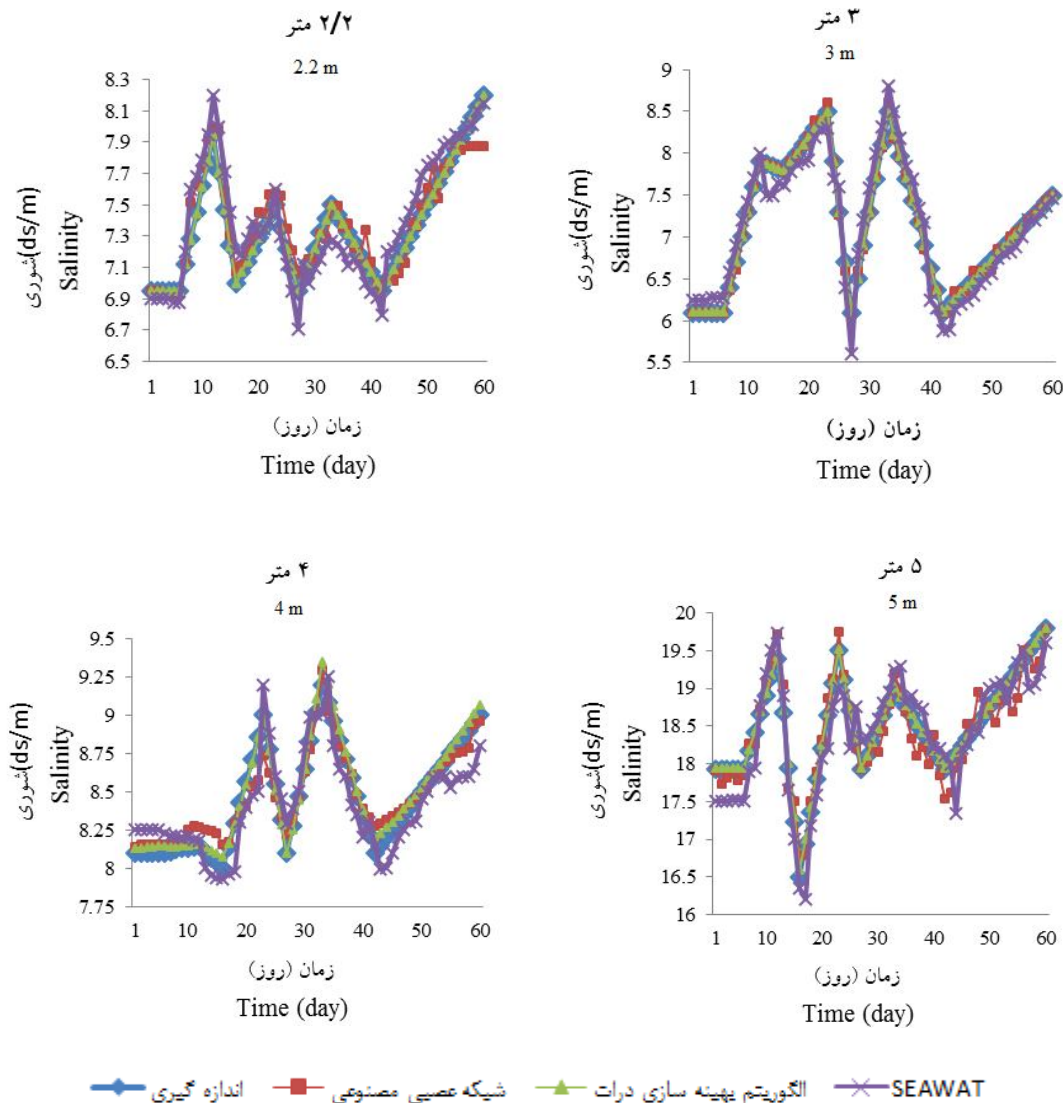


شکل ۳- تغییرات شوری در دسته‌های پیزومتری نسبت به عمق از سطح زمین.

Figure 3. Salinity changes in piezometric groups than to the depth of the surface.

در این مقاله برای پیش‌بینی شوری آب زیرزمینی مزرعه R9-11 از کشت و صنعت نیشکر دعبل خزاعی از دو مدل شبکه عصبی (شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی ذرات) با دو آموزش متفاوت و مدل SEAWAT استفاده شد. شکل ۴ مقایسه میانگین شبیه‌سازی شده در اعماق مختلف با استفاده از سه مدل به کار رفته را با مقادیر اندازه‌گیری شده در مزرعه نشان می‌دهد.

در این مقاله برای پیش‌بینی شوری آب زیرزمینی مزرعه R9-11 از کشت و صنعت نیشکر دعبل خزاعی از دو مدل شبکه عصبی (شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی ذرات) با دو آموزش متفاوت و مدل SEAWAT استفاده شد. شکل ۴ مقایسه میانگین شبیه‌سازی شده در اعماق مختلف با استفاده از سه مدل به کار رفته را با مقادیر اندازه‌گیری شده در مزرعه نشان می‌دهد.



شکل ۴- مقایسه شبیه‌سازی میانگین شوری آب زیرزمینی در اعماق مختلف.

Figure 4. Compare the simulated average groundwater salinity at different depths.

مقادیر اندازه‌گیری شده مربوط به مدل الگوریتم بهینه‌سازی ذرات و کم‌ترین همپوشانی مربوط به مدل SEAWAT می‌باشد. علت پیش‌بینی دقیق مدل

همان‌طور که در شکل ۴ مشاهده می‌شود، هر سه مدل به کار رفته در پیش‌بینی شوری آب زیرزمینی موفق عمل نموده‌اند ولی بیش‌ترین همپوشانی با

دستیابی به نتایج دقیق در شبیه‌سازی می‌شود. همان‌طور که گفته شد در مدل SEAWAT چگالی سیال تنها تابع غلظت املاح بوده و اثر دما روی چگالی سیال مورد توجه نمی‌باشد. تغییرات زمانی و مکانی غلظت املاح در این مدل با استفاده از MT3DMS شبیه‌سازی می‌شود. نتایج شبیه‌سازی مدل SEAWAT بیانگر آنست که این مدل دقت بالایی در پیش‌بینی شوری آب زیرزمینی دارد. اما از آنجایی که برای اجرا فرضیاتی در نظر گرفته می‌شود، به‌طور قطع نسبت به مدل‌های شبکه عصبی دقت کم‌تری دارد.

برای بهتر نشان دادن پیش‌بینی و دقت روش‌ها با مقادیر واقعی جدول ۲ تهیه و مقادیر میانگین RMSE و MAPE برای میانگین اعماق مختلف پیزومترها محاسبه شده است.

الگوریتم تجمع ذرات به مسأله آموزش آن برمی‌گردد. به این صورت که در روش شبکه عصبی مصنوعی برای آموزش از روش پس‌انتشار خطا استفاده می‌شود. این روش معمولاً برای پیش‌بینی نتایج نسبتاً خوبی در بر دارد اما اشکال آن گیر افتادن در بهینه محلی می‌باشد. مدلی دیگر از شبکه عصبی که برای آموزش از روش الگوریتم بهینه‌سازی ذرات استفاده می‌کند، بر اساس جست و جو عمل کرده و در این صورت می‌تواند تا حدودی برای هرچه بیش‌تر تصادفی شدن انتخاب نقاط تلاش کند. ذرات در این روش بر حسب موقعیت‌ها و سرعت‌هایشان تلاش می‌کنند بهینه‌ترین نقاط را در هر تکرار انتخاب و به روز کنند. با توجه به این‌که این الگوریتم یک روش بهینه‌سازی ساده، سریع و دارای پارامترهای تنظیم کم و غیردیفرانسیلی می‌باشد استفاده از این الگوریتم و ترکیب آن با شبکه عصبی به‌منظور آموزش بهینه شبکه عصبی منجر به

جدول ۲- میانگین RMSE و MAPE شوری آب زیرزمینی.

Table 2. Average RMSE and MAPE groundwater salinity.

SEAWAT		الگوریتم تجمع ذرات PSO		شبکه عصبی مصنوعی ANN		اعماق پیزومترها Depths of piezometers
میانگین MAPE Average MAPE	میانگین RMSE Average RMSE	میانگین MAPE Average MAPE	میانگین RMSE Average RMSE	میانگین MAPE Average MAPE	میانگین RMSE Average RMSE	
1.89	0.03	0.18	0.014	0.83	0.07	2.2
2.65	0.21	0.17	0.012	0.49	0.03	3
1.62	0.45	0.36	0.02	0.84	0.09	4
1.47	0.31	0.11	0.01	0.75	0.15	5

محاسبه شده و علت این امر هم اصلاح روش آموزش آن به روش ترکیبی می‌باشد.

نتیجه‌گیری

در این پژوهش از دو روش شبکه عصبی (شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی تجمع ذرات) و مدل SEAWAT برای پیش‌بینی شوری آب

جدول ۲ بیانگر این موضوع می‌باشد که استفاده از مدل‌های شبکه عصبی و SEAWAT برای پیش‌بینی شوری آب زیرزمینی بسیار موفق عمل نموده‌اند بطوری‌که مقادیر RMSE تقریباً نزدیک صفر هستند. همچنین با توجه به این اعداد، مقادیر خطا در هر عمق در روش الگوریتم بهینه‌سازی ذرات کم‌تر از روش شبکه عصبی مصنوعی و مدل SEAWAT

زیرزمینی در مزرعه R9-11 از مزارع نیشکر دعبل خزاعی خوزستان استفاده شد. با توجه به این که الگوریتم تجمع ذرات پتانسیل قابل توجهی در حل مسائل بهینه سازی دارد (۱)، نتایج نشان داد دقت پیش بینی الگوریتم بهینه سازی ذرات بالاتر از مدل شبکه عصبی مصنوعی و مدل SEAWAT می باشد. به طوری که مقدار میانگین RMSE اعماق مختلف مدل های شبکه عصبی مصنوعی، الگوریتم بهینه سازی تجمع ذرات و SEAWAT به ترتیب برابر ۰/۰۹۲، ۰/۰۱۷ و ۰/۷۴۵ می باشد.

منابع

1. Abido, M.A. 2002. Optimal power flow using particle swarm optimization. *Inter. J. Elec. Power Energy Syst.* 24: 7. 563-571.
2. Arumugam, M.S., and Rao, M.V.C. 2008. On the improved performances of the particle swarm optimization algorithms with adaptive parameters, cross-over operators and root mean square (RMS) variants for computing optimal control of a class of hybrid systems. *Appl. Soft Comp. J.* 8: 324-336.
3. Azarafra, H., Rezaei, H., Behmanesh, J., and Besharat, S. 2012. Results Comparison of Employin PSO, GA and SA Algorithms in Optimizing Reservoir Operation (Case study: Shaharchai Dam, Urmia, Iran). *J. Water Soil.* 26: 5. 1101-1108. (In Persian)
4. Chitsazan, M., Musavi, F., Mirzaie, Y., and Rastegar Zadeh, S. 2012. Qualitative and Quantitative Management the aquifer Ramhormoz by Using a mathematical model in MODFLOW and MD3DMS. *J. Adv. Appl. Geol.* 2: 5. 1-8. (In Persian)
5. Daliakopoulos, N.I., Coulibaly, P., and Tsanis, I.K. 2005. Ground water level forecasting using artificial neural networks. *J. Hydrol.* 309: 1. 229-240.
6. Emarati, M.R. 2014. Study of load and price forecasting methods in restructured electricity markets and offering new intelligence methods with more capabilities. M.Sc. Dissertation, University of Advanced Technology Faculty of Energy Department of Energy Management, Kerman. (In Persian)
7. Minhas, P.S., and Khosla, B.K. 1996. Solute displacement in a silt loam soil as affected by the method of water application under different evaporation rates. *Agricultural Water Management.* 12: 1. 63-74.
8. Moghaddam, P.R., and Koocheki, A. 2004. History of research on salt-affected lands of Iran: Present status and future prospects-halophytic ecosystems. P 83-95, In: F.K. Taha, S. Ismael and A. Jaradat (Eds.), In *Prospects of Saline Agriculture in the Arabian Peninsula: Proceedings of the International Seminar on Prospects of Saline Agriculture in the GCC Countries.* 18-20 March 2001, Dubai.
9. Mokhtaran, R. 2014. Dynamic study of freshwater and saltwater interface in irrigated lands of sugarcane. Ph.D. dissertation, University of Chamran, Ahvaz. (In Persian)
10. Saey, T., Van Meirvenne, M., and Vermeersch, H., Ameloot, N., and Cockx, L. 2009. A pedotransfer function to evaluate the soil profile textural heterogeneity using proximally sensed apparent electrical conductivity. *Geoderma.* 150: 389-395.
11. Seyam, M., and Mogheir, Y. 2011. Application of Artificial Neural Networks Model as Analytical Tool for Groundwater Salinity. *J. Environ. Prot.* 2: 1. 56-71.
12. Tahmasbi, H., Barani, Gh., and Zounemat, M. 2013. Modeling and analyzing how Elder Using software MODFLOW 4.2, SEAWAT model. *Proceedings of 7th Conference Iran Water Resources Management, Shahid Beheshti University, Tehran, Abstract.* (In Persian)



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 23(5), 2017
<http://jwsc.gau.ac.ir>

Short Technical Report

Simulation of groundwater salinity using Artificial Neural Network (ANN), Particle Swarm Optimization (PSO) and model SEAWAT (Case study: Debal khazaie sugarcane plantation)

*A. Sayadi Shahraki¹, A. Soltani Mohammadi², A.A. Naseri³ and A. Mokhtaran⁴

¹M.Sc. Student., Dept. of Irrigation and Drainage, Shahid Chamran University of Ahvaz,

²Assistant Prof., Dept. of Irrigation and Drainage, Shahid Chamran University of Ahvaz,

³Professor, Dept. of Irrigation and Drainage, Shahid Chamran University of Ahvaz,

⁴Ph.D., Dept. of Irrigation and Drainage, Shahid Chamran University of Ahvaz

Received: 11/29/2015; Accepted: 09/14/2016

Abstract

Background and Objectives: Soil salinity is the main factor which adversely affect the sugarcane yield in the southwest of Iran. Therefore, assessment and monitoring these factors are important issue in this area. Computer models can be considered as an appropriate approach for dealing with this problem. Therefore, this research was conducted to find a suitable model for simulation of soil salinity in sugarcane fields by using Neural Network models and SEAWAT model (Saey et al., 2009), neural network model (Artificial Neural Network, Particle swarm optimization) to predict soil used salinity and good performance of the model to predict soil salinity confirmed.

Materials and Methods: In this study, Artificial Neural Networks (ANN), Neural network model combined with Particle Swarm Optimization (PSO + ANN) and SEAWAT model is used to predict groundwater salinity For this purpose, field R9-11 of the Debal Khazaei sugarcane plantation is selected and a number of piezometers were installed in different depths and distance from collector. Piezometers were in 7 categories, each category includes depths of 2.2, 3, 4 and 5 meters above ground level, was installed in different layers of soil. The volume of irrigation water, salinity of irrigation water, salinity of groundwater and salinity drainage water in this period measurements from November 2013 to October 2014 on a daily basis.

Results: The results showed that the Neural network model combined with Particle Swarm Optimization method has a highest accuracy in predicting groundwater salinity. So that the average RMSE in different depths between measured and predicted with artificial neural network, Neural network model combined with Particle swarm optimization and SEAWAT obtained 0.092, 0.017 and 0.745, respectively.

Conclusion: Overall, the results of this study showed high accuracy of studied models (Artificial Neural Network, Particle swarm optimization and SEAWAT) for simulation of groundwater salinity that's because accurate measurement of input parameters.

Keywords: Salinity, SEAWAT, Simulation, Neural Network, Matlab

* Corresponding Author; Email: sayadi.atefeh@gmail.com