

تخمین شوری نیمرخ خاک در شبکه آبیاری و زهکشی دشت تبریز با استفاده از مدل‌های SaltMod و شبکه عصبی مصنوعی

امیر حق وردی^{۱*} - کورش محمدی^۲ - سید اسدالله محسنی موحد^۳ - بیژن قهرمان^۴ - محمد افشار^۵

تاریخ دریافت: ۸۹/۳/۲۰

تاریخ پذیرش: ۸۹/۸/۳۰

چکیده

شوری خاک در منطقه توسعه ریشه از مهم‌ترین مشکلاتی است که در اراضی کشاورزی باعث کاهش محصول می‌شود. در این پژوهش شوری نیمرخ خاک در شبکه آبیاری و زهکشی دشت تبریز با استفاده از مدل‌های شبکه عصبی و SaltMod شبیه‌سازی شد. بر اساس توزیع مکانی اولیه شوری، منطقه مورد مطالعه به چهار گروه مختلف آب و خاک تقسیم شد و شوری برای دو فصل در یک سال پیش‌بینی شد. مدل SaltMod واسنجی گردید و برای تولید ۲۴۰۰ سری داده برای آموزش شبکه‌های عصبی مصنوعی به کار گرفته شد. تعدادی از عوامل ورودی SaltMod از جمله داده‌های عمق آب آبیاری، تبخیر-تعرق، عمق سطح ایستابی، بارندگی و شوری اولیه نیمرخ خاک در شبکه‌های عصبی استفاده شدند. همچنین کارایی الگوریتم ژنتیک در فرآیند آموزش شبکه‌های عصبی مورد بررسی قرار گرفت. میانگین ضریب تعیین (R^2) و میزان خطای شوری برآورد شده (RMSE) انتهای سال در تمامی گروه‌ها با استفاده از شبکه‌های عصبی به ترتیب برابر ۰/۸ و ۰/۰۳۲ بود. در مجموع می‌توان گفت شبکه‌های عصبی مصنوعی به خوبی توانایی مدل‌سازی و پیش‌بینی شوری خاک منطقه ریشه را دارند و می‌توانند جایگزین خوبی برای SaltMod باشند. همچنین نتایج نشان داد که به طور کلی کارکرد شبکه‌های عصبی با به کارگیری الگوریتم ژنتیک بهبود می‌یابد.

واژه‌های کلیدی: دشت تبریز، شوری نیمرخ خاک، الگوریتم ژنتیک، شبکه‌های عصبی مصنوعی، SaltMod

مقدمه

علاقه‌مندی به مدل‌سازی رفتارهای طبیعی و استفاده از مدل‌های رایانه‌ای موجود روز به روز افزایش می‌یابد. به طوری که امروزه تعداد بسیار زیادی مدل در علوم آب مانند DrainMod (۲۳ و ۲۳)، SaltMod (۱۵)، LEACHM (۲۵) و SWAP (۲۴) در مناطق گوناگون جهان گسترش یافته‌اند و مقاله‌های متعددی نیز از کار با آن‌ها گزارش می‌گردد. این مدل‌ها در ارزیابی سیستم‌های زهکشی بسیار مؤثر هستند (۱۰). SaltMod (www.waterlog.info) یک برنامه رایانه‌ای برای پیش‌بینی شوری رطوبت خاک، آب زیرزمینی و آب زهکشی، عمق سطح ایستابی و خروجی زهکش در زمین‌های کشاورزی است، که قادر به بررسی حالت‌های مختلف هیدرولوژیک و گزینه‌های متنوع مدیریت آب می‌باشد (۱۵).

کاربردهای متعددی از مدل SaltMod در سطح جهان گزارش شده است. سینگ و همکاران (۲۱) با استفاده از مدل SaltMod به شبیه‌سازی شوری خاک در منطقه ریشه، کمیت و کیفیت آب زهکشی و عمق سطح ایستابی در مناطقی از کشور هندوستان پرداختند. نتایج نشان داد که SaltMod می‌تواند با اطمینان برای ارزیابی کارایی

در حدود ۶۰۰۰ سال قبل، تمدن قدیمی بین‌النهرین در جلگه دجله و فرات شکوفا شد و سپس به دلیل شور شدن خاک در اثر عملیات آبیاری بدون زهکشی از بین رفت (۷). ماندابی و شور شدن خاک از عوامل نامطلوب زراعت به شمار می‌رود. خاک‌های شور که امروزه تشکیل می‌شود بیشتر به علت شوری آب‌های زیرزمینی و یا تبخیر-تعرق از اراضی کشاورزی است (۲). با توجه به لزوم بررسی عوامل مختلف آب و خاک و شبیه‌سازی و پیش‌بینی آن‌ها،

۱ و ۴- دانشجوی دکتری و استاد گروه مهندسی آب، دانشکده کشاورزی، دانشگاه فردوسی مشهد

*- نویسنده مسئول: (Email: amirhaghverdii@gmail.com)

۲- دانشیار گروه آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه تربیت مدرس تهران

۳- استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه اراک

۵- کارشناس مهندسی مشاور یکم

می‌تواند وزن‌ها و اریب‌ها را به رسیدن به کمینه مطلق تنظیم کند و این امر خود موجب افزایش دقت پیش‌بینی در شبکه عصبی می‌شود (۱۷).

هسو و همکاران (۱۲) با استفاده از روش کمترین مجذورات خطی^۳ سرعت همگرایی را برای دستیابی به مقادیر بهینه وزن‌ها و اریب‌ها در یک مدل بارندگی - رواناب بالا بردند. آن‌ها پیشنهاد کردند که کارایی مدل‌های شبکه عصبی می‌تواند با استفاده از الگوریتم‌های مانند بهینه‌سازی کلی تصادفی^۴ و الگوریتم ژنتیک بهبود یابد. جین و سرینیواسولو (۱۳) در تحقیقی مشابه عنوان کردند که شبکه‌هایی که با الگوریتم ژنتیک آموزش می‌بینند دقت بیشتری نسبت به شبکه‌هایی دارند که با الگوریتم پس انتشار خطا آموزش می‌بینند.

در واقعیت کار با مدل‌های تخصصی برآورد شوری مانند SaltMod از چند جهت مشکل می‌باشد. نخست آنکه این مدل‌ها نیاز به عوامل ورودی زیادی دارند که استحصال آن‌ها از لحاظ زمان، هزینه و امکانات کار آسانی نمی‌باشد. دوم آنکه اجرای این مدل‌ها نیاز به در دسترس بودن تمامی عوامل ورودی دارد و در صورت ناقص یا مبهم بودن داده‌ها یا به کلی از کار می‌افتند و یا اینکه جواب‌های قابل اعتمادی ارائه نمی‌دهند. از طرفی اجرای مجزای مدل‌های شبکه عصبی نیز در این موارد خالی از اشکال نیست. زیرا این مدل‌ها برای دستیابی به عملکردی مطلوب نیاز به تعداد قابل ملاحظه‌ای عامل ورودی و خروجی دارند که بایستی در حد امکان تمامی محدوده‌های تغییرات واقعی را پوشانند و گرنه بطور لزوم نتایج خوبی از کار با این مدل‌ها عاید نمی‌گردد. این دو نقیصه باعث شد که تلاش‌هایی برای استفاده توأم از مدل‌های SaltMod و شبکه عصبی صورت پذیرد. سرنگی و همکاران (۱۹) در پژوهشی با استفاده از شبکه‌های عصبی و SaltMod شوری نیمرخ خاک و خروجی زهکش‌ها را در یک منطقه آزمایشی در هندوستان پیش‌بینی کردند. نتایج نشان داد که SaltMod شوری خاک منطقه ریشه را بهتر پیش‌بینی کرد و شبکه عصبی در پیش‌بینی شوری خروجی زهکش‌ها بهتر عمل نمود.

دشت تبریز در مجاورت رودخانه آجی چای واقع است که به علت عبور از خاک‌های شور و تماس آب با زیر لایه‌های خاک شور از شوری زیادی برخوردار است. در نتیجه مشکلات شوری و ماندابی باعث عدم کارایی مناسب از منابع خاک و آب در دسترس گردیده است. از این رو این شرایط منتج به کشاورزی با رویکرد محیط زیست پایدار نگردیده و کاهش تولید محصولات کشاورزی را به همراه دارد. بنابراین لزوم بهبود شرایط منابع خاک و آب جهت دستیابی به محیط زیست و کشاورزی پایدار و بهبود کشت آبی در دشت احساس می‌شود

فاصله‌های متفاوت زهکش‌ها در سامانه زهکشی زیرسطحی استفاده شود. اوستربان و ابوسینا (۱۶) در پژوهشی در مصر با استفاده از SaltMod گزارش کردند که افت سطح ایستابی تا حدود ۰/۸ متری سطح زمین در هر فصل می‌تواند تا حد کافی شوری خاک را کنترل کند.

انتخاب یک روش و رویکرد مناسب برای مدل‌سازی یک سامانه، کاملاً به میزان پیچیدگی آن سامانه بستگی داشته و پیچیدگی نیز ارتباط معکوس با میزان دانش و شناخت ما از آن سامانه دارد. سامانه‌هایی را که پیچیدگی آن‌ها زیاد باشد به شرط وجود داده‌های کافی می‌توان با استفاده از روش‌های مدل آزاد نظیر شبکه‌های عصبی مصنوعی (ANN) مدل‌سازی نمود (۶). شبکه عصبی پردازنده‌ای است که دانشی را که از راه تجربه کسب نموده است برای استفاده‌های بعدی ذخیره می‌کند (۱۱). پیاده‌سازی ساختارهای محاسباتی سیستم بیولوژیک می‌تواند منجر به ایجاد الگوهای محاسباتی بهتری برای گروه‌های معینی از مسائل شود. از آن جمله به گروهی از مسائل که با داده‌های ناقص، کم، متناقض، مبهم یا احتمالی مورد بررسی قرار می‌گیرند، می‌توان اشاره کرد (۳). با توجه به توانمندی‌های زیاد مدل‌های شبکه عصبی در علوم مختلف از جمله علوم آب، این مدل‌ها در سال‌های اخیر در گستره وسیعی به کار گرفته شده‌اند. همچنین این مدل‌ها به خوبی و با دقت بسیار بالایی ویژگی‌های هیدرولوژیک خاک را پیش‌بینی می‌کنند (۸ و ۲۰).

الگوریتم‌های پس انتشار خطا بیش‌ترین کاربرد را برای آموزش شبکه‌های عصبی دارند (۹). موفقیت یا عدم موفقیت یک الگوریتم پس انتشار خطا بر اساس نقطه آغاز جستجوی الگوریتم برای یافتن جواب بهینه تعیین می‌شود. اگر نقطه آغاز جستجو نزدیک به یک کمینه محلی^۱ قابل توجه باشد این جستجو ممکن است در دام آن کمینه محلی گرفتار شود. برای جلوگیری از این امر راه کارهای متعددی پیشنهاد شده‌است. یکی از جدیدترین این روش‌ها استفاده توأم از الگوریتم ژنتیک^۲ و شبکه‌های عصبی در قالب یک (GA-ANN) می‌باشد. الگوریتم ژنتیک عملگرهای جهش، تقاطع و انتخابی را با هدف پیدا کردن بهترین راه حل برای یک مسئله ترکیب می‌کند. جستجوی آن برای این راه حل بهینه تا زمان دستیابی به معیار مشخص شده ادامه می‌یابد. در کاربرد توأم مدل‌های شبکه عصبی و الگوریتم ژنتیک این معیارها بر اساس کمترین خطای حاصله در طول فرایند آموزش مشخص می‌شود (۱۸). در یک الگوریتم ژنتیک، جستجو بر اساس یک جمعیت از نقاط جستجوگر در فضای جستجو آغاز می‌شود. این جستجوی راهبردی چندگانه به چیره شدن بر مسئله کمینه محلی کمک می‌کند. از این رو الگوریتم ژنتیک بهتر

3-Linear Least Squares

4-Stochastic Global Optimization

1-Local Minimum

2-Genetic Algorithm

(۵).

است. بر اساس توزیع اولیه شوری، منطقه مورد مطالعه به گروه‌های یک ($S_0 \leq 4$ dS/m و $S_1 = 4-8$ dS/m)، دو ($S_2 = 8-16$ dS/m)، سه ($S_3 = 16-32$ dS/m) و چهار ($S_4 > 32$ dS/m) برای مدل‌سازی تقسیم شد.

مدل‌سازی SaltMod

روش محاسباتی SaltMod بر پایه بیان فصلی آب در زمین‌های کشاورزی می‌باشد. حداکثر چهار فصل (دوره زمانی) می‌تواند در یک سال زراعی موجود باشد و تعداد ماه‌های هر فصل با توجه به نظر کاربر و حسب شرایط منطقه‌ای معین می‌گردد. بدیهی است هر چه تعداد فصل‌ها بیشتر باشد به تعداد بیش‌تری عامل ورودی نیاز می‌باشد. مدت هر فصل بر اساس تعداد ماه‌های آن در مدل مشخص می‌شود و تعداد ماه‌ها در کل فصول بایستی ۱۲ ماه یعنی معادل یک سال کامل باشد. منطقه مورد مطالعه می‌تواند بسته به نظر کاربر به سه زیر منطقه (A، B و U) تقسیم شود. مناطق A و B می‌توانند از نظر الگوی کشت و نوع آبیاری (سبک و سنگین) تفکیک گردند. در این حالت منطقه U می‌تواند به اراضی اختصاص یابد که آبیاری نمی‌شوند. خروجی‌های SaltMod برای هر فصل از سال و به تعداد سال‌هایی که عوامل ورودی آن‌ها مشخص شده‌است بدست می‌آید. داده‌های خروجی شامل حالت‌های هیدرولوژیک و شوری می‌باشد. بیان آب و نمک بر پایه بیان آب و با استفاده از غلظت نمک در آب ورودی و خروجی برای نواحی مختلف در نیمرخ خاک تعیین می‌شود (۱۷).


داده‌های مورد نیاز برای انجام این پژوهش (شوری نیمرخ خاک و سطح ایستایی) از مطالعات پیشین انجام شده توسط مهندسی مشاور یکم در دشت تبریز اخذ گردید. با توجه به محدودیت‌های مدل SaltMod و شرایط منطقه‌ای (از جمله توزیع شوری و الگوی کشت)، داده‌های ورودی در چهار گروه مطالعاتی (حسب شوری اولیه در ناحیه توسعه ریشه - جدول ۱) طبقه‌بندی شد. در داده‌های ورودی مدل، هر سال به دو فصل (دوره زمانی) مساوی ۶ ماهه تقسیم گردید. شبیه‌سازی برای یک سال انجام گردید و شوری نیمرخ خاک در انتهای فصل اول و در انتهای سال بدست آمد. تأثیر عوامل مختلف در هر چهار گروه روی شوری نیمرخ خاک منطقه ریشه در پایان فصل اول و دوم سال بررسی شد. برخی از عوامل ورودی مدل SaltMod در جدول ۱ آورده شده‌است. واسنجی مدل با تخمین میزان زهکشی طبیعی (G_n) و کسر آبشویی (F_{ir}) در هر یک از مناطق انجام شد. بدین منظور مقادیر مختلف ضریب آبشویی و زهکشی طبیعی در ورودی‌های مدل در نظر گرفته شد و خروجی‌های مدل با مقادیر اندازه‌گیری شده واقعی برای انتخاب بهترین مقدار مقایسه گردید.

در مجموع نتایج پژوهش‌های پیشین این نکته مهم را نشان می‌دهند که در شرایط مساوی استفاده از داده‌های استحصالی واقعی، کفایت SaltMod از مدل‌های شبکه عصبی برای شبیه‌سازی و پیش‌بینی شوری منطقه توسعه ریشه بیش‌تر بوده است (۱۹). از این نظر تولید داده توسط SaltMod در این پژوهش در واقع تلاشی برای شبیه‌سازی کارکرد مدل SaltMod (در شبیه‌سازی و پیش‌بینی شوری نیمرخ خاک در منطقه توسعه ریشه) به‌وسیله شبکه‌های عصبی بود. ضمن اینکه کمبود داده‌های واقعی در منطقه مورد مطالعه مانع از این امر بود که اجرای مدل‌های شبکه عصبی فقط با استفاده از داده‌های واقعی صورت پذیرد. در واقع مطالب گفته شده از مهم‌ترین دلایلی بودند که در این پژوهش مطالعات مدل‌سازی شوری در دشت تبریز در سطحی وسیع، در چندین مرحله و در تکرارهای بسیار زیاد انجام پذیرفت. با این هدف که کفایت مدل‌های شبکه عصبی (با تکیه بر کاربرد الگوریتم ژنتیک) در شبیه‌سازی عملکرد مدل تخصصی برآورد شوری SaltMod مورد آزمون قرار گیرد.

مواد و روش‌ها

ویژگی‌های محدوده مورد مطالعه

محدوده مورد مطالعه در تحقیق حاضر دشت تبریز با وسعت حدود ۱۰۰۰۰۰ هکتار واقع در کوه‌های آذربایجان شرقی است که از شمال به دامنه‌های جنوبی کوه‌های میشو، از جنوب به دامنه‌های شمالی سه‌سهند، از شرق به محدوده شهر تبریز و از غرب به اراضی شور هزار و دریاچه ارومیه محدود می‌گردد. رودخانه آجی‌چای اصلی‌ترین منبع تأمین آب سطحی در منطقه است. این رودخانه از شرق به غرب در جریان است و زمین‌های مناطق شرقی و جنوب شرقی دشت تبریز را آبیاری می‌نماید. از نظر موقعیت جغرافیایی محدوده گفته شده در بین طول‌های شرقی $30^{\circ} 45'$ تا $15^{\circ} 46'$ و عرض‌های شمالی $37^{\circ} 56'$ تا $17^{\circ} 38'$ واقع گردیده است (۵). تنها حدود ۷ درصد از کل اراضی دشت تبریز برای کشت و کار مناسب است. این گروه خاک‌ها هیچگونه محدودیتی برای رشد گیاهان رایج در منطقه ایجاد نمی‌کند و عملکرد محصولات در آن‌ها در حد بالایی است. حدود ۳۲ درصد اراضی در کلاس دو واقع شده که نسبتاً مناسب می‌باشند. خاک منطقه مورد مطالعه دارای بافت متوسط، ریز و به‌طور نسبی ریز با واکنش (pH) $7/6$ تا $8/3$ است. گندم، جو و گلرنگ مهم‌ترین گیاهان پاییزه و چغندر، سورگوم، سیر و سبزیجات مهم‌ترین گیاهان بهاره می‌باشند. یونجه و باغ‌ها نیز به‌صورت دائمی در روی زمین باقی می‌مانند. متوسط سالانه سرعت باد $1/88$ m/s، رطوبت نسبی ۵۵ درصد، دمای هوا $12/2^{\circ}C$ و متوسط ساعات آفتابی در روز $7/5$ می‌باشد (۵). پهنه‌بندی شوری در اراضی تحت مطالعه در شکل ۱ نشان داده شده



شکل ۱- پهنه بندی شوری در اراضی مورد مطالعه (ه)

جدول ۱- برخی از عوامل ورودی مورد نیاز مدل SaltMod (ع)

مقدار				عامل	نشانه	ردیف
گروه ۴	گروه ۳	گروه ۲	گروه ۱			
۱/۱۸۹	۲/۰۸۴	۴/۵۸	۱/۶۴۷	آب آبیاری (m/year)	Ia	۱
۳/۲۲۲	۳/۲۲۲	۲/۸۵	۳/۲۲۲	تبخیر- تعرق پتانسیل (m/year)	Ep	۲
-۰/۲۹۱	-۰/۲۹۱	-۰/۲۹۱	-۰/۲۹۱	بارش (m/year)	Pp	۳
۲۵	۱۲	۶	۴	متوسط شوری اولیه در ناحیه توسعه ریشه در اراضی تحت آبیاری (dS/m)	C0	۴
۲۰	۲۰	۲۰	۲۰	ضخامت سفره (m)	Dq	۵
۱	۱	۱	۱	ضخامت منطقه ریشه (m)	Dr	۶
۴	۴	۴	۴	ضخامت منطقه انتقال (m)	Dx	۷
۰/۸	۰/۸	۰/۷	۰/۸	راندمان آبشویی منطقه ریشه	Flr	۸
۲/۲۵	۲/۲۵	۲/۲۵	۲/۲۵	عمق زهکش زیرسطحی (فرض شده) (m)	Dd	۹
۰/۰۵	۰/۰۵	۰/۰۵	۰/۰۵	تخلخل مؤثر منطقه ریشه	Per	۱۰
۳۳۵۸	۵۸۷۰	۴۶۲۲	۵۹۷۸	مساحت هر منطقه (ha)	Area	۱۱

پیچیده (۱) در این پژوهش از شبکه‌های پرسپترون سه لایه برای مدل‌سازی استفاده شد. پرسپترون‌ها شبکه‌هایی با ساختار پیشخور

مدل سازی ANN

با توجه به توانمندی شبکه‌های پرسپترون در تخمین نگاشت‌های

میزان آب آبیاری برای یک منطقه که به صورت دو عامل مجزا برای فصول اول و دوم در داده‌های ورودی مدل SaltMod در نظر گرفته شده بود با هم جمع شده و به عنوان یک عامل ورودی برای شبکه‌های عصبی به کار رفت.

در مورد تلفیق مکانی هم به روش بالا برای مناطق سه گانه (A)، (U و B) که در ورودی‌های مدل SaltMod بر حسب نوع کشت جداگانه در نظر گرفته می‌شوند داده‌های ورودی تلفیق گشتند. برای هر عامل بر اساس تغییر عوامل در حالت واقعیت و همچنین محدودیت‌های مدل SaltMod محدوده‌ای انتخاب شد و ترکیبات گوناگونی برای آن‌ها در نظر گرفته شد. در مجموع برای هر منطقه ۶۰۰ بار شبیه سازی تحت شرایط مختلف تغییر عوامل انتخابی ورودی انجام شد. برای هر کدام از ترکیب‌ها، نرون‌های خروجی به دو صورت در نظر گرفته شدند. شبکه‌ای با یک نرون خروجی برای برآورد شوری در انتهای سال (مدل‌های زوج در جدول ۳) و شبکه‌ای با دو نرون خروجی برای برآورد همزمان شوری انتهای فصل اول و انتهای سال (فصل دوم)، (مدل‌های فرد در جدول ۳).

هستند که عموماً با الگوریتم‌های پس انتشار خطای پایا آموزش می‌بینند. مزیت عمده این شبکه‌ها استفاده آسان از آن‌هاست. پرسپترون‌ها در واقع پس از پیشنهاد الگوریتم پس انتشار خطا دوباره در سطحی وسیع به کار گرفته شدند. این الگوریتم خطا را در بین شبکه منتشر می‌کند و اجازه می‌دهد که وزن‌های لایه‌های میانی نیز تنظیم شوند (۱۶). در جدول ۲ عوامل مورد استفاده در این پژوهش شرح داده شده‌اند. برای انتخاب این عوامل، در مدل‌های شبکه عصبی در اولین مرحله ۸۳ عامل (کل ورودی‌های مدل SaltMod) در نظر گرفته شدند. در نهایت ۳۸ عامل به عنوان نرون‌های ورودی در ۱۱ ترکیب مختلف در شبکه‌های عصبی به کار رفتند. بدین ترتیب که ۱۷ عامل آن‌ها دقیقاً ورودی‌های مدل SaltMod بودند (ورودی‌های مدل ۱۷ و ۱۸ در جدول ۳). این عوامل پس از بررسی‌های اولیه و با توجه به ویژگی‌های ذاتی و میزان تغییر پذیری عوامل ورودی مدل SaltMod در واقعیت انتخاب گشتند. مابقی عوامل از ترکیبات مختلف این ۱۷ عامل (در زمان و مکان) بدست آمدند (جدول ۳). تلفیق زمانی داده‌ها به این طریق صورت پذیرفت که به عنوان مثال

جدول ۲- عوامل ورودی مدل‌های شبکه عصبی مصنوعی و SaltMod استفاده شده در این پژوهش

۱- مولفه‌های بیلان آب

(m) (IaA_n, IaB_n) : آب آبیاری برای زمین‌های تحت کشت گیاهان گروه A و B در فصل n ام

(m) (I): کل آب آبیاری در سال برای همه مناطق

(m) (Ip): کل آب آبیاری و بارش در سال برای همه مناطق

(m) (Ia_n) : آب آبیاری در فصل n ام

(m) (p_p) : مجموع بارش در سال

(m) (Ip_n) : مجموع بارش و آب آبیاری در فصل n ام

(m) (Pp_n) : بارندگی در فصل n ام

(m) (IaA, IaB) : مجموع آب آبیاری در فصل اول و دوم در گروه A و B

(m) (IEA, IEB) : تفاضل مجموع بارش و آب آبیاری با تبخیر- تعرق پتانسیل در سال در گروه A و B

(m) (Ipe) : تفاضل مجموع بارش و آب آبیاری با تبخیر- تعرق پتانسیل در سال

(m) (Ipe_n) : تفاضل مجموع بارش و آب آبیاری با تبخیر- تعرق پتانسیل در فصل n ام

(m) (E_p_n) : تبخیر- تعرق پتانسیل در فصل n ام

(m) (EPA_n, EPB_n, EPU_n) : تبخیر- تعرق پتانسیل گیاهان گروه A و B و U در فصل n ام

(m) (EpA, EpB) : مجموع تبخیر- تعرق پتانسیل در فصل اول و دوم در گروه A و B

(m) (E): کل تبخیر- تعرق پتانسیل در سال برای تمامی مناطق

۲- ویژگی‌های خاک

(C): مجموع غلظت اولیه نمک رطوبت خاک اشباع در ناحیه ریشه در گروه‌های A و B و $(dS/m) U$

(C_0) : میانگین غلظت اولیه نمک رطوبت خاک اشباع در ناحیه ریشه در گروه‌های A و B و $(dS/m) U$

(CA_0, CB_0, CU_0) : غلظت اولیه نمک رطوبت خاک اشباع در ناحیه ریشه در گروه‌های A و B و $(dS/m) U$

(Cr_n) : شوری رطوبت خاک در منطقه ریشه در پایان فصل n ام (dS/m)

۳- عوامل سیستم زهکشی و شرایط مرزی

(DW_0) : عمق اولیه سطح ایستابی (m)

(QH_1) : نسبت تخلیه زهکش‌ها به ارتفاع سطح ایستابی بالای سطح زهکش‌ها (sec^{-1})

(QH_2) : نسبت تخلیه زهکش‌ها به مجذور ارتفاع سطح ایستابی بالای سطح زهکش‌ها $(m.sec^{-1})$

جدول ۳- عوامل ورودی در مدل‌های مختلف شبکه‌های عصبی مصنوعی

مدل*	عوامل ورودی
۲و۱	Ia ₁ , Ia ₂ , Ep ₁ , Ep ₂ , Pp ₁ , Pp ₂ , CA ₀ , CB ₀ , CU ₀ , Dw ₀ , QH ₁ , QH ₂
۴و۳	Ip ₁ , Ip ₂ , Ep ₁ , Ep ₂ , CA ₀ , CB ₀ , CU ₀ , Dw ₀ , QH ₁ , QH ₂
۶و۵	IpE ₁ , IpE ₂ , CA ₀ , CB ₀ , CU ₀ , Dw ₀ , QH ₁ , QH ₂
۸و۷	IpE ₁ , IpE ₂ , C ₀ , Dw ₀ , QH ₁ , QH ₂
۱۰و۹	IpE, C ₀ , Dw ₀ , QH ₁ , QH ₂
۱۲و۱۱	IaA, IaB, EPA, EPB, EpU ₁ , CA ₀ , CB ₀ , CU ₀ , Dw ₀ , QH ₁ , QH ₂ , Pp ₁ , Pp ₂
۱۴و۱۳	IaA, IaB, EPA, EPB, PP, EpU ₁ , CA ₀ , CB ₀ , CU ₀ , Dw ₀ , QH ₁ , QH ₂
۱۶و۱۵	IEA, IEB, EpU ₁ , CA ₀ , CB ₀ , CU ₀ , Dw ₀ , QH ₁ , QH ₂
۱۸و۱۷	IaA ₁ , IaA ₂ , IaB ₁ , IaB ₂ , EpU ₁ , EpA ₁ , EpA ₂ , EpB ₁ , EpB ₂ , Pp ₁ , Pp ₂ , CA ₀ , CB ₀ , CU ₀ , Dw ₀ , QH ₁ , QH ₂
۲۰و۱۹	I, C, E, Pp, Dw ₀ , QH ₁ , QH ₂
۲۲و۲۱	Ip, C, E, Dw ₀ , QH ₁ , QH ₂

*- مدل‌های زوج یک نرون (Cr₂) و مدل‌های فرد دو نرون (Cr₁, Cr₂) در لایه خروجی دارند.

جدول ۴- حالت‌های سه گانه آزمایش شده برای ساختارهای مختلف مدل‌های شبکه عصبی مصنوعی

ردیف	لایه میانی		لایه خروجی	
	تابع انتقال	الگوریتم آموزش	تابع انتقال	الگوریتم آموزش
حالت اول	تانزانت هیپربولیک	مومنتم	خطی	مومنتم
حالت دوم	سیگموئید	مومنتم	خطی	مومنتم
حالت سوم	تانزانت هیپربولیک	لونبرگ مارکوت	خطی	لونبرگ مارکوت

بنابراین در مجموع ۲۲ ساختار مختلف برای هر کدام از چهار گروه مورد بررسی قرار گرفت (جدول ۳). تعداد نرون‌های لایه میانی از یک تا ۱۵ تغییر داده شد. هفتاد درصد داده‌ها برای آموزش، ۲۰ درصد داده‌ها برای اعتبار سنجی، و ۱۰ درصد برای هدف آزمون استفاده شدند.

برای تمامی ساختارها، سه ترکیب مختلف از الگوریتم آموزش و تابع انتقال برای لایه میانی و خروجی مورد آزمون قرار گرفت (جدول ۴). این انتخاب بر اساس نتایج پژوهش‌های پیشین بود که نشان می‌دادند اگر از توابع فعالیت سیگموئیدی در لایه‌های مخفی و تابع فعالیت خطی در لایه خروجی استفاده شود عملکرد شبکه بهبود می‌یابد (۱۴).

برای اجرای مدل‌های شبکه عصبی از نرم افزار NeuroSolutions نسخه ۵ استفاده شد (www.nd.com). این نرم افزار قابلیت اجرای مدل‌های شبکه عصبی را در محیط نرم افزار Excel دارد و همچنین می‌تواند به نرم افزار Matlab متصل شود. از دو شاخص کمی ریشه میانگین مربعات خطا (رابطه ۱) و ضریب تعیین (رابطه ۲) جهت ارزیابی کارکرد شبکه‌های عصبی مصنوعی استفاده شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{est} - y_{act})^2}{n}} \quad (1)$$

$$R^2 = 1 - \frac{\sum (y_{act} - y_{est})^2}{\sum y_{act}^2 - \frac{\sum y_{est}^2}{n}} \quad (2)$$

که در آن‌ها y_{act} مقادیر واقعی (خروجی از مدل SaltMod)، مقادیر تخمینی y_{est} (خروجی از مدل‌های شبکه عصبی مصنوعی)، \bar{y}_{est} میانگین مقادیر تخمینی شوری نیمرخ خاک در منطقه ریشه و n تعداد داده‌ها می‌باشد. نرمال سازی عوامل مورد استفاده در شبکه عصبی به منظور یکسان سازی تقریبی وزن ورودی‌ها و همچنین افزایش سرعت همگرایی در فرآیند آموزش (۱۴) با استفاده از رابطه ۳ انجام شد.

$$y_{normal} = \left[\frac{y - \bar{y}}{y_{max} - y_{min}} \right] + 0.5 \quad (3)$$

که در آن y_{normal} مقدار نرمال شده عوامل (شامل تمامی عوامل ورودی و خروجی مدل‌های شبکه عصبی)، y مقدار واقعی هر عامل، y_{max} بیش‌ترین مقدار عامل مورد نظر، y_{min} کم‌ترین مقدار عامل مورد نظر و \bar{y} مقدار متوسط عامل مورد نظر می‌باشد.


تحلیل حساسیت، آرایش داده‌های ورودی و کاربرد الگوریتم ژنتیک

برای بهترین نتایج مدل‌سازی در گروه‌های چهارگانه توسط شبکه‌های عصبی و به منظور شناخت میزان تأثیر عوامل ورودی، با استفاده از نرم افزار NeuroSolutions.5 تحلیل حساسیت انجام شد. به طور اصولی تحلیل حساسیت برای آشکار شدن تأثیر هر یک از نرون‌های ورودی بر نرون (یا نرون‌های) خروجی و به تبع آن حذف عوامل کم تأثیر برای کاهش حجم شبکه که خود باعث کاهش پیچیدگی و در نتیجه افزایش سرعت آن می‌شود، انجام می‌پذیرد (۱۴). با استفاده از الگوریتم ژنتیک برای تعدادی از مدل‌های شبکه عصبی در نرم افزار NeuroSolutions.5 امکان سنجی دستیابی به عملکرد بهتر و بهبود نتایج حاصله انجام شد تا عوامل مختلف تشکیل دهنده ساختاری مدل‌ها بهینه شود. برای نیل به این مقصود الگوریتم ژنتیکی با ۵۰ کروموزوم در ۱۰۰ نسل در نظر گرفته شد. تأثیر نوع آرایش و نحوه تخصیص داده‌های تولیدی توسط SaltMod برای کار با مدل‌های شبکه عصبی به منظور تعیین میزان تأثیرگذاری درجه همپوشانی تغییرات داده‌های فاز آموزش با کلیه تغییرات ممکن، بر دقت و کارایی شبکه انجام شد. بدین منظور داده‌های تولیدی توسط مدل SaltMod که برای کار با شبکه‌های عصبی آماده شده بودند به دو روش کلی متمایز مورد استفاده قرار گرفتند. در روش اول داده‌های تولیدی به صورت مستقیم مورد استفاده قرار گرفتند. بدیهی است که در چنین شرایطی تمامی تغییرات یک عامل ورودی مانند سطح ایستابی در دنباله یکدیگر قرار داشت و به همین علت شبکه در فاز آزمون بایستی تأثیر تغییرات عواملی را بر شوری نیم‌رخ خاک شبیه سازی و برآورد می‌نمود که در فاز آموزش از آن‌ها استفاده نشده بود و در روش دوم داده‌ها از لحاظ نوع آرایش تصادفی شدند.

نتایج و بحث

نتایج مدل‌سازی ANN و SaltMod


نتایج واسنجی مدل SaltMod برای مناطق چهارگانه در شکل ۲



شکل ۲- نتایج مدل‌سازی توسط مدل SaltMod برای مناطق چهارگانه

نشان داده شده است که حاکی از عملکرد قابل قبول مدل SaltMod است. این نتایج مشابه با نتایج گزارش شده توسط دیگر محققین بود (۲۱ و ۱۹). در مجموع بیش از ۴۰۰۰ بار مدل‌های شبکه عصبی در گروه‌های چهارگانه خاک مورد آزمون قرار گرفتند. شکل ۳ نتایج ارزیابی آماری کلیه مدل‌های ۲۲ گانه (جدول ۳) را برای گروه‌های چهارگانه منطقه و جدول ۵ بهترین مدل‌های با یک و دو نرون خروجی را برای این گروه‌ها نمایش می‌دهد (ذکر تمامی نتایج امکان پذیر نمی‌باشد).

بیشترین ضریب تعیین و کمترین خطا در مدل بهینه گروه ۴ مشاهده شد. میانگین ضریب تعیین و میزان خطای شوری برآورد شده انتهای سال در گروه یک (۰/۶۸۶ و ۰/۳۱۵)، دو (۰/۶۸۵ و ۰/۳۷۲)، سه (۰/۸۸۶ و ۰/۳۹۹) و چهار (۰/۹۵ و ۰/۰۲) می‌باشد و این مقادیر برای شوری برآورد شده انتهای فصل اول به ترتیب برای گروه یک (۰/۷۹۳ و ۰/۰۲۸)، دو (۰/۷۷۸ و ۰/۰۱۶)، سه (۰/۷۱۱ و ۰/۰۰۴) و چهار (۰/۹۴۴ و ۰/۰۱۷) بدست آمد که نشان می‌دهد به طور کلی نتایج در گروه‌های ۳ و ۴ نسبت به گروه‌های ۱ و ۲ مطلوبتر بودند. البته در تمامی ۲۲ مدل در گروه‌های چهارگانه این بهبود نتایج ملاحظه نگردید (شکل ۳). نتایج به طور کلی در مدل‌هایی که تعداد نرون‌های لایه ورودی آن‌ها بیش‌تر بود بهتر از مدل‌های بود که تعداد نرون کمتری داشتند. با توجه به افزایش دقت مدل‌سازی از گروه ۱ به ۴ این فرضیه وجود دارد که شبکه عصبی در گروه‌های با شوری بالا عملکرد بهتری دارد که شاید به دلیل ماهیت عامل شوری و رابطه‌اش با دیگر عوامل باشد. در کل الگوریتم آموزش لونیبرگ و تابع فعالیت تانژانت هیپربولیک نسبت به الگوریتم مومنتوم و تابع فعالیت سیگموئید عملکرد بهتری داشتند. الگوریتم آموزش لونیبرگ از لحاظ تعداد دوره‌های آموزش نسبت به مومنتوم سرعت همگرایی بالاتری داشت هر چند ضعف عمده این الگوریتم کاهش شدید سرعت آموزش با افزایش تعداد نرون‌های لایه پنهان نسبت به الگوریتم مومنتوم بود.



شکل ۳- بهترین نتایج حاصله از مدل‌سازی توسط شبکه‌های عصبی مصنوعی در گروه‌های ۱ (a)، ۲ (b)، ۳ (c) و ۴ (d).

نمایه RMSE در تمامی شکل‌ها برای نمایش بهتر ۱۰ برابر بزرگتر شده‌است.

نتایج تحلیل حساسیت، آرایش داده‌های ورودی و کاربرد الگوریتم ژنتیک

نتایج تحلیل حساسیت برای بهترین مدل‌های مشاهده شده در شکل ۴ نشان داده شده است. به طور کلی صرف نظر از نوع مدل، عوامل ورودی در هر ۴ گروه بر Cr_2 نسبت به Cr_1 تأثیر بیشتری داشتند. شوری اولیه نیمرخ خاک در مناطق گوناگون یکی از تأثیر گذارترین عوامل بود. همچنین در کل تأثیر تبخیر- تعرق از مقادیر

بارش و آبیاری بیش‌تر بود.

در تمامی گروه‌ها عوامل مربوط به فصل دوم نسبت به عوامل مربوط به فصل اول تأثیر بیشتری بر شوری داشته‌اند. تأثیر بسیار زیاد از نمایه QH_1 به خصوص بر شوری انتهایی سال در گروه یک مشاهده شد که در گروه‌های دیگر مشهود نبوده است.


جدول ۵- بهترین نتایج مدل سازی توسط مدل های شبکه عصبی مصنوعی در داده های فاز آزمون برای گروه های چهارگانه

گروه	مدل	دور آموزش	توپولوژی	فاز آزمایش		فاز اعتبار		فاز آزمون		
				RMSE	R ²	سنجی	RMSE	R ²	Cr ₁	Cr ₂
۱	۱۷	۱۳۲	۱۷-۷-۲	۰/۰۲۳	۰/۰۴۱	۰/۰۲	۰/۸۴	۰/۰۱۹	۰/۹	
۱	۱۸	۳۹	۱۷-۱۴-۱	۰/۰۲۲	۰/۰۴۴	-	-	۰/۰۱۷	۰/۹۱	
۲	۱	۸۳۵	۱۲-۵-۲	۰/۰۱۸	۰/۰۶۴	۰/۰۰۸	۰/۸۹۷	۰/۰۲۷	۰/۹۱	
۲	۱۲	۱۷۵	۱۳-۴-۱	۰/۰۰۲	۰/۰۵۷	-	-	۰/۰۲	۰/۹۵	
۳	۱۵	۲۶	۹-۶-۲	۰/۰۲۱	۰/۰۶۹	۰/۰۰۳	۰/۸۲	۰/۰۴۵	۰/۸۷	
۳	۲	۳۰	۱۲-۴-۱	۰/۰۱۲	۰/۰۶۴	-	-	۰/۰۱۶	۰/۹۸	
۴	۱۷	۵۳	۱۷-۱۰-۲	۰/۰۱۱	۰/۰۴۵	۰/۰۰۷	۰/۹۹	۰/۰۱۳	۰/۹۸	
۴	۱۸	۴۶	۱۷-۶-۱	۰/۰۰۶۳	۰/۰۵۵	-	-	۰/۰۱۳	۰/۹۸	

*- الگوریتم آموزش در تمامی ساختارهای بهینه لونبرگ مارکوت و تابع انتقال در لایه میانی تانژانت هیپربولیک بود.

این نمایه را در تغییرات شوری نشان می دهد. در بررسی های اولیه در این پژوهش، دیگر عوامل مربوط به شرایط اولیه خاک از جمله تخلخل قابل زهکشی و راندمان آبشویی نیز برای استفاده در مدل های شبکه عصبی به عنوان ورودی استفاده شدند که به خاطر عدم تاثیر قابل توجه بر تغییرات شوری در محاسبات نهایی جزو عوامل ورودی منظور نگردید.

تأثیر زیاد نمایه های مربوط به تبخیر- تعرق و بارندگی مشابه نتایج بدست آمده توسط سرنگی و همکاران (۱۹) بود. با این تفاوت که در پژوهش نامبردگان تحلیل حساسیت برای انتخاب عوامل ورودی شبکه های عصبی مصنوعی و قبل از آموزش آن ها و توسط روش های آماری با نرم افزار MARS.2 انجام پذیرفته بود. تاثیر زیاد مقدار شوری اولیه مناطق در این پژوهش اهمیت بالایی



تعداد داده های فاز آزمون

شکل ۴- نمایش بهترین نتایج مدل سازی شوری نیمرخ خاک (dS/m) توسط مدل های شبکه های عصبی مصنوعی

به حفظ کردن خروجی‌های مطلوب پرداخته است. تأثیر زیاد آرایش داده‌ها (شکل ۶) مؤید این نکته مهم می‌باشد که تمامی شرایط تغییر عوامل ورودی بایستی به شبکه آموزش داده شود زیرا شبکه قدرت پیش‌بینی شرایطی را که برای آن‌ها آموزش ندیده است را ندارد. پس از بررسی نتایج اولیه مدل‌سازی (شکل ۳) برای مدل‌های ۷ و ۹ در گروه‌های ۱ و ۲ که ضعیف‌ترین نتایج را داشتند مدل‌سازی با استفاده از شبکه‌های عصبی که از الگوریتم ژنتیک در ساختار خود بهره می‌برند تکرار شد. نتایج استفاده از الگوریتم ژنتیک نشان دهنده بهبود نسبی عملکرد مدل‌ها نسبت به حالات‌هایی بود که در آن از الگوریتم ژنتیک استفاده نشده بود (شکل ۷). این نتیجه مشابه نتایج جین و سربینواسولو (۱۳) بود. با این وجود نتایج نشان داد که به طور لزوم استفاده از الگوریتم ژنتیک در همه موارد منجر به بهبود نتایج نمی‌شود (شکل ۷- مدل ۹ گروه ۲).


نتیجه گیری

در این پژوهش شوری نیمرخ خاک در ناحیه توسعه ریشه در قسمت‌هایی از اراضی دشت تبریز با استفاده از مدل‌های شبکه عصبی و SaltMod شبیه‌سازی و پیش‌بینی شد. برای نیل به این مقصود با استفاده از داده‌های استحصال واقعی، مدل SaltMod در چهار گروه مختلف اراضی با توزیع متفاوت شوری واسنجی شد. تولید داده توسط مدل SaltMod برای یک سال و به مدت دو فصل برای آموزش شبکه‌های عصبی انجام شد و شوری نیمرخ خاک در ناحیه توسعه ریشه به عنوان خروجی مدل استحصال گردید. نتایج حاصله نشان می‌دهند که مدل‌های شبکه عصبی به خوبی قادرند شوری نیمرخ خاک را با دقتی قابل قبول و عوامل مورد نیاز کمتری از مدل رایانه‌ای SaltMod شبیه‌سازی کنند. نتایج ضعیف در مورد برخی مدل‌ها، گروه‌ها و حالت‌ها بیان‌گر این نکته بسیار مهم بود که مدل‌های شبکه عصبی با هر ساختاری به طور اصولی نتایج خوبی را ارائه نخواهند داد و ارائه نتایج خوب توسط آن‌ها محتاج دقت در انتخاب عوامل تشکیل دهنده شبکه و همچنین انجام تکرارهای زیاد انتخاب عوامل مناسب تشکیل دهنده شبکه می‌باشد. همچنین نتایج این پژوهش نشان داد که فراگیری ماشین حتی در صورت ارائه جواب‌های مطلوب به معنی درک روابط بین نرون‌های ورودی و خروجی نمی‌باشد و استفاده از الگوریتم ژنتیک در ساختار شبکه عصبی می‌تواند منجر به بهبود نتایج مدل‌سازی شود.


عدم تاثیر زیاد نمایه‌های مذکور (تخلخل قابل زهکشی و راندمان آبشویی) توسط سرنگی و همکاران (۱۹) نیز گزارش شده است، لیکن آن‌ها در تحقیق خود شوری اولیه نیمرخ خاک را به عنوان ورودی شبکه‌های عصبی استفاده نکردند و شاید این امر یکی از دلایل نتایج نامطلوب تحقیق آن‌ها بود که هیچ عاملی که نشان دهنده شرایط اولیه خاک در منطقه مورد مطالعه باشد را جزو نمایه‌های ورودی خود منظور نکردند.

بر طبق نتایج تحلیل حساسیت مدل‌های شبکه عصبی تا حد بسیار زیادی قادر به درک روابط بین هر ورودی و شوری نیمرخ خاک به عنوان خروجی بود. به طوری که به عنوان مثال در مورد گروه ۲ شوری فصل اول به عوامل فصل اول و شوری فصل دوم بیشتر به عوامل فصل دوم وابسته است. هر چند ضعف‌ها و نکات ابهامی هم در این رابطه وجود دارد. از آن جمله که در نتایج تحلیل حساسیت گروه ۴ عوامل مربوط به فصل دوم که نباید هیچ تاثیری بر شوری انتهای فصل اول داشته باشند، در عمل تاثیری هر چند بسیار اندک دارند (شکل ۵). در واقع به دلیل اینکه نمایه‌های ورودی برای شبکه‌های عصبی از ورودی‌های مدل SaltMod انتخاب گشتند در این پژوهش از لحاظ درک روابط ورودی‌ها و خروجی‌های مدل‌های شبکه عصبی برخلاف بیش‌تر پژوهش‌های مشابه که ساختاری به طور کامل جعبه سیاه را دارند با یک ساختار جعبه خاکستری روبرو بوده‌ایم. نتایج تحلیل حساسیت در این پژوهش نشان داد حتی در صورت ارائه جواب‌های مطلوب، ممکن است شبکه‌های عصبی درکی مطلق و منطقی از روابط کلاسیک و اثبات شده نداشته باشند. همچنین عدم وجود یک الگوی واحد از لحاظ میزان تاثیر عوامل ورودی بر شوری در گروه‌ها و مدل‌های مختلف موید این نکته مهم می‌باشد که عوامل بسیار زیادی که بر شوری تاثیر گذارند در اختلاط با یکدیگر می‌توانند در گروه‌های گوناگون تاثیرات متفاوتی داشته باشند. به نظر می‌رسد این بحث نیاز به بررسی بیشتری داشته باشد.

نتایج کلی مدل‌سازی توسط شبکه‌های عصبی در دو حالت تصادفی کردن داده‌های ورودی تولیدی توسط مدل SaltMod و عدم تصادفی کردن، در هر چهار گروه در شکل ۶ نشان داده شده است. در حالت عدم تصادفی کردن ورودی‌ها، داده‌های تولید شده در اثر تغییر یک عامل، مانند سطح ایستابی، به دنبال هم آورده شده بودند و بنابراین نتایج بسیار ضعیف بودند و به‌خصوص حتی در صورت کارکرد مطلوب شبکه در فاز آزمایش، شبکه در فاز آزمون با مشکل مواجه می‌شد، این امر نشان‌گر این است که شبکه به جای حل مسئله



شکل ۵- تحلیل حساسیت عوامل ورودی برای بهترین نتایج مدل‌سازی شوری نیم‌رخ خاک (ds/m) توسط شبکه‌های عصبی مصنوعی در گروه‌های چهارگانه (ستون‌های پر رنگ (CI₂) و ستون‌های هاشور زده (CI₁) می‌باشند)



شکل ۶- مقایسه نتایج در داده‌های تصادفی و غیر تصادفی و شکل ۷- نتایج برای گروه‌های چهارگانه ناشی از بکارگیری GA

منابع

- ۱- البرزی م. ۱۳۸۰. آشنایی با شبکه‌های عصبی مصنوعی. انتشارات علمی دانشگاه صنعتی شریف ۱۳۸ صفحه.
- ۲- بایوردی م. ۱۳۷۸. اصول مهندسی زهکشی و بهسازی خاک. انتشارات دانشگاه تهران. چاپ هشتم. ۶۴۱ صفحه.
- ۳- جورابیان م.، و هوشمند ر. ۱۳۸۲. منطق فازی و شبکه عصبی مفاهیم و کاربردها. انتشارات دانشگاه شهید چمران اهواز. ۳۰۰ صفحه.
- ۴- حق وردی ا. ۱۳۸۶. تخمین شوری پروفیل خاک در شبکه آبیاری و زهکشی دشت تبریز با استفاده از مدل‌های شبکه عصبی مصنوعی و مدل کامپیوتری SALTMOD. پایان نامه کارشناسی ارشد. گروه مهندسی آب دانشکده کشاورزی. دانشگاه بوعلی سینای همدان. ۱۱۷ صفحه.

- ۵- شرکت مهندسی مشاور یکم، ۱۳۸۴. مطالعات شبکه آبیاری و زهکشی دشت تبریز، مطالعات بازنگاری بهنگام نمودن و خدمات اضافی مرحله اول. شرکت سهامی آب منطقه‌ای آذربایجان شرقی و اردبیل. ۱۲۱ صفحه.
- ۶- کوره پزان دزفولی ا.، ۱۳۸۵. اصول تئوری مجموعه‌های فازی و کاربردهای آن در مدل سازی مسائل مهندسی آب. انتشارات جهاد دانشگاهی صنعتی امیرکبیر. ۲۶۱ صفحه.
- ۷- واکر و، و اسکوگربوگ. ۱۳۸۵. (موسوی، فرهاد. و مصطفی زاده فرد، بهروز، مترجمان). آبیاری سطحی تئوری و عمل. انتشارات کنکاش. چاپ سوم. ۵۸۲ صفحه.
- 8- Amini M., Abbaspour K.C., Khademi H., Fathianpour N., Afyuni M., and Schulin R. 2005. Neural network models to predict cation exchange capacity in arid regions of Iran, *European Journal of Soil Science*, 56: 551-559.
- 9- ASCE Task Committee on Artificial Neural Networks in Hydrology. 2000. Artificial neural networks in hydrology. I: Preliminary concepts, *Journal of Hydrologic Engineering*, 5(2): 115-123.
- 10- Bahceci I., Dinc N., Tari A.F., Agar A.I., and Sonmez B. 2006. Water and salt balance studies using SaltMod, to improve subsurface drainage design in the Konya-Cumra Plain, Turkey, *Agricultural Water Management*, 85(3): 261-271.
- 11- Haykin S. 1994. *Neural network: A comprehensive foundation*. 2nd Ed. Macmillan. New York.
- 12- Hsu K.L., Gupta H.V., and Sorooshian S. 1995. Artificial neural network modeling of the rainfall-runoff process, *Water Resources Research*, 31(10): 2517-2530.
- 13- Jain A., and Srinivasulu S. 2004. Development of effective and efficient rainfall-runoff models using integration of deterministic, realcoded genetic algorithms and artificial neural network techniques, *Water Resources Research*, 40(4): W04302.
- 14- Kaustra I., and Boyd M.S. 1995. Forecasting futures trading volume using neural networks, *The Journal of Future Markets*, 15(8): 953-970.
- 15- Oosterbaan R.J. 2002. *SALTMOD Description of Principles, User Manual, and Examples of Application*. ILRI Wageningen, The Netherlands.
- 16- Oosterbaan R.J., and Abu Senna M. 1990. Using SaltMod to predict drainage for salinity control. Towards integration of irrigation and drainage management. In: *Proceedings of the Jubilee Symposium at the Occasion of the 40th Anniversary of ILRI, Wageningen, The Netherlands*, pp. 43-49.
- 17- Parasuraman K., and Elshorbagy A. 2007. Cluster-based hydrologic prediction using genetic algorithm-trained neural networks, *Journal of Hydrologic Engineering*, 12(1): 52-62.
- 18- Principe J., Lefebvre C., Lynn G., Fancourt C., and Wooten D. 2005. *NeuroSolutions Help PDF pages 1001*. available now in: www.nd.com.
- 19- Sarangi A., Singh M., Bhattacharya A.K., and Singh A.K. 2006. Subsurface drainage performance study using SALTMOD and ANN models, *Agricultural Water Management*, 4: 240-248.
- 20- Sharma V., Negi S.C., Rudra R.P., and Yang S. 2003. Neural networks for predicting nitrate-nitrogen in drainage, *Agricultural Water Management*, 63: 169-183.
- 21- Singh M., Bhattacharya A.K., Singh A.K., and Singh A. 2002. Application of SALTMOD in coastal clay soil in India, *Irrigation and Drainage Systems*, 16(3): 213-231.
- 22- Skaggs R.W. 1978. *A Water Management Model for Shallow Water Table Soils*, Technical Report No. 134. Water Resources Research Institute, University of North Carolina. Raleigh. NC. USA.
- 23- Skaggs R.W. 1991. Drainage. In: *Modeling plant and Soil Systems*. Agronomy Monograph No. 31, ASA-CSSA-SSSA, pp. 205-243.
- 24- Van Dam J.C., Huygen J., Wesseling J.G., Feddes R.A., Kabat P., Van Walsum P.E.V., Groenendijk P., and Van Diepen C.A. 1997. *Theory of SWAP Version 2.0: Simulation of Water Flow, Solute Transport and Plant Growth in the Soil-Water- Atmosphere-Plant. Environment*. Department of Water Resources, Agricultural University Report 71/DLO Winand Staring Centre Technical Document, 45, Wageningen, The Netherlands.
- 25- Wagenet R.J., and Hutson J.L. 1989. *LEACHM, Leaching Estimation and Chemistry Model—A Process based Model of Water and Solute Movement, Transformations, Plant Uptake, and Chemical Reactions in the Unsaturated Zone*. Water Resources Institute, Cornell University, Ithaca, USA.

Estimation of Soil Salinity Profile in Tabriz Irrigation and Drainage Network Using SaltMod and ANN Models

A. Haghverdi^{1*} - K. Mohammadi² - S.A. Mohseni Movahed³ - B. Ghahraman⁴ - M. Afshar⁵

Received: 23-5-2010

Accepted: 21-11-2010

Abstract

Soil salinity within plant root zone is one of the most important problems that cause reduction in yield in agricultural lands. In this research, salinity in soil profile was simulated in Tabriz irrigation and drainage network using SaltMod and Artificial Neural Networks (ANNs) models. Based on initial spatial distribution of salinity in soil profile, studying area was divided to 4 different soil and water groups and for two seasons in one year salinity was predicted. The SaltMod model was calibrated and then was applied to generate 2400 data sets for training ANN models. Some of the input data of SaltMod were used in ANN models including irrigation water depth, evapotranspiration, water table depth, rainfall, and initial soil salinity. Efficiency of genetic algorithm in training phase of ANNs was analyzed. The mean of correlation coefficient (R^2) and root mean square error (RMSE) of estimated salinity in all groups was 0.8 and 0.032 respectively. In conclusion ANNs could perform well in simulation of soil salinity and it could be replaced SaltMod with enough accuracy. The results showed that overall performance of ANN models improve by applying genetic algorithm.

Keywords: Tabriz plain, Soil profile salinity, Genetic Algorithm, Artificial Neural Networks, SaltMod

1,4- PhD Student and Professor, Department of Water Engineering, Faculty of Agriculture, Ferdowsi University of Mashhad

(* - Corresponding Author Email: amirhaghverdii@gmail.com)

2- Associate Professor, Department of Irrigation and Drainage Engineering, Tarbiat Modares University of Tehran

3- Assistant Professor, Department of Water Engineering, Faculty of Agriculture, University of Arak

5- Researcher, Yekom Consulting Engineers, Tehran