



دانشگاه علوم کشاورزی و منابع طبیعی گزن

مجله پژوهش‌های حفاظت آب و خاک
جلد شانزدهم، شماره اول، ۱۳۸۸
www.gau.ac.ir/journals

تخمین نفوذپذیری نهایی خاک‌ها با استفاده از مدل شبکه عصبی مصنوعی (مطالعه موردی: مزرعه پردیس ابوریحان)

*کیومرث ابراهیمی^۱ و فاطمه نایب لوئی^۲

استادیار گروه مهندسی آبیاری و آبادانی، دانشگاه تهران، دانشجوی کارشناسی ارشد گروه مهندسی آب، دانشگاه ارومیه
تاریخ دریافت: ۸۶/۸/۱۹؛ تاریخ پذیرش: ۸۷/۹/۲۴

چکیده

نفوذپذیری یکی از مهم‌ترین پارامترهای فیزیکی خاک‌ها و از داده‌های بنیادی طرح‌های آبیاری و زه‌کشی است. اگرچه برای توصیف این پدیده، تاکنون روش‌ها و روابط مختلف تئوری و یا تجربی ارائه شده، ولی هنوز هم از جنبه‌های تطابق و امکان کاربرد علوم جدیدی نظیر روش شبکه‌های عصبی مصنوعی در پیش‌بینی این پدیده، جای تحقیق و بررسی وجود دارد. در تمام روش‌های موجود برای تعیین روابط نفوذ، انجام آزمایش‌های زمان‌بر و پرهزینه صحرایی الزامی است. همچنین وجود عبارت‌های غیرخطی در روابط حاکم بر پدیده نفوذپذیری، مدل‌سازی آن را امری مشکل‌نموده است. از طرفی امروزه توانمندی‌های روش شبکه‌های عصبی مصنوعی در مدل‌سازی مسایل غیرخطی باعث شده تا در علوم مختلف مهندسی به موازات کاربرد روش‌های متداول، از روش شبکه‌های عصبی نیز استفاده شود. در تحقیق حاضر شبکه‌های عصبی مصنوعی به‌عنوان روشی جدید به‌منظور تخمین مقادیر نفوذپذیری نهایی خاک‌ها به‌کار گرفته شده است. در این تحقیق در مدل شبکه عصبی مصنوعی تهیه شده، پارامترهای فیزیکی خاک از جمله درصد مواد آلی، وزن مخصوص حقیقی و ظاهری، تخلخل و همچنین پارامترهای شیمیایی آن نظیر اسیدیته و میزان سدیم به‌عنوان ورودی و در مقابل مقادیر

* مسئول مکاتبه: EbrahimiK@ut.ac.ir

نفوذپذیری نهایی خاک به عنوان پارامتر خروجی مدل لحاظ شده‌اند. همچنین یک مدل آماری براساس رگرسیون‌های چندمتغیره تهیه و خروجی‌های مدل شبکه عصبی و مدل آماری با مقادیر واقعی اندازه‌گیری شده و با کاربرد معیار ضرایب همبستگی مقایسه شده است. نتایج این تحقیق نشان داد که مدل‌های شبکه عصبی مصنوعی با دقت بسیار بالا و قابل قبولی توانایی تخمین و پیش‌بینی مقادیر نفوذپذیری نهایی خاک‌ها را براساس پارامترهای زود یافت خاک دارند. وجه تمایز این تحقیق با سایر تحقیقات مشابه در مدل‌سازی با شبکه‌های عصبی مصنوعی آن است که، در این تحقیق علاوه بر کاربرد شبکه‌های عصبی مصنوعی در مورد نفوذپذیری، توانمندی‌های این روش در یافتن دانش الگوریتم در داده‌های با حجم پایین نیز به اثبات رسید.

واژه‌های کلیدی: پارامترهای فیزیکی و شیمیایی خاک، شبکه عصبی مصنوعی، ضریب نفوذپذیری نهایی، مدل آماری

مقدمه

نفوذپذیری یکی از مشخصات فیزیکی خاک است که در مسایل آبیاری و زه‌کشی اهمیت خاص داشته و در آن عوامل مختلفی از قبیل بافت و ساختمان خاک، رطوبت اولیه، مقدار مواد آلی، مقدار مواد جامد معلق موجود در آب آبیاری - نظیر رس و سیلت، غلظت املاح محلول به‌خصوص سدیم قابل تبادل، دمای آب و خاک، فشردگی و وجود درز و ترک‌های خاک مؤثر می‌باشند (بای بوردی، ۱۹۸۳). روابط نفوذ آرایه شده را می‌توان به دو دسته کلی روابط تجربی و روابط تئوری مبتنی بر فیزیک پدیده نفوذ تقسیم‌بندی نمود. از جمله روابط تئوری می‌توان به رابطه فیلیپ و رابطه گرین امپت و از روابط تجربی نیز به روابط کوستیاکف و هورتن اشاره کرد که هر یک از آنها مزایا و محدودیت‌های خاص خود را دارند (محمدی و رفاهی، ۲۰۰۵؛ فیلیپ، ۱۹۵۷؛ گرین و آمپت، ۱۹۱۱، کوستیاکف، ۱۹۳۲؛ هورتون، ۱۹۴۰). آگاهی از مشخصات نفوذپذیری خاک (به‌خصوص نفوذ پایه یا نهایی)، از اطلاعات اساسی مورد نیاز برای انجام یک طراحی کارآمد و پرثمر سیستم‌های آبیاری است (ماچیوا و همکاران، ۲۰۰۶). به‌عبارت دیگر دانستن سرعت نفوذ پایه در تمامی طرح‌های آب و خاک الزامی است. بنابراین آرایه یک روش مطمئن، سریع، نسبتاً ساده و کم‌هزینه جهت برآورد پارامتر نفوذ نهایی می‌تواند قابل توجه واقع شود. در این زمینه تحقیقاتی از جمله تخمین خصوصیات هیدرولیکی

در حوضه سن پدرو (پوستاوکو و موریسی، ۲۰۰۳) و پیش‌بینی سرعت جریان در زمین‌هایی با نفوذپذیری ناهمگن (شیرلی، ۲۰۰۲) صورت گرفته است.

از آنجا که بشر همواره در تلاش برای یافتن راه‌حل‌هایی بوده تا پردازش اطلاعات، مسایل و پدیده‌هایی را که به راحتی قابل حل نیستند و همچنین یافتن روابط پیچیده میان پارامترهای پدیده‌های مورد نظر را در علوم مختلف تسهیل بخشد، با الگوبرداری از سیستم‌های بیولوژیک به سیستم‌های هوشمندی دست یافته است که قادر به استخراج دانش الگوریتم یا نگاهت از دل محاسبات عددی می‌باشد. سامانه‌های دینامیکی یاد شده که "شبکه‌های عصبی مصنوعی" نامیده می‌شوند با پردازش بر روی داده‌های تجربی دانش یا قانون نهفته در ورای داده‌ها را ارایه می‌کنند. در حقیقت، یک شبکه عصبی مصنوعی مجموعه‌ای از تعداد زیادی واحدهای محاسباتی ساده مرتبط (نرون‌ها) می‌باشد که شبیه به نرون‌های طبیعی مغز انسان هستند (فام، ۱۹۹۹). به‌طور کلی در زمینه استفاده از شبکه‌های عصبی مصنوعی و روش‌های مشابه هیدروانفورماتیک در ارتباط با علوم آب و خاک تاکنون تحقیقات مختلفی صورت گرفته است. مارسل و همکاران (۱۹۹۸) مدل شبکه عصبی را برای پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی در حالت اشباع با استفاده از خصوصیات پایه خاک شامل مقادیر شن، سیلت و رس، وزن مخصوص ظاهری، تخلخل و مقادیر گراول کالیبره کرده و نتیجه گرفتند که به‌طور کلی با افزایش تعداد داده‌ها پیش‌بینی ظرفیت نگهداری رطوبت و هدایت هیدرولیکی در حالت اشباع بهبود می‌یابد و استفاده از این روش به دلیل دقت و میزان انعطاف‌پذیری زیاد در مقابل داده‌های در دسترس مورد توجه قرار گرفت. (نوبیان و همکاران، ۲۰۰۴) امکان برآورد سریع هدایت آبی اشباع خاک توسط شبکه عصبی مصنوعی را بررسی و نتیجه گرفتند که در این مورد شبکه‌های عصبی مصنوعی در مقایسه با روابط رگرسیونی عملکرد نسبتاً بهتری را دارند. مقایسه شبکه عصبی و توابع انتقالی رگرسیون در برآورد نگهداشت آب، خاک و هدایت هیدرولیکی اشباع (مئردان و همکاران، ۲۰۰۶)، نمونه‌ای دیگر از تحقیقات در راستای ارزیابی کارایی شبکه‌های عصبی مصنوعی در علوم آب و خاک می‌باشد. اگرچه در تحقیق اخیر مدل‌های آماری نتایج بهتری نسبت به مدل شبکه‌های عصبی از خود نشان دادند ولی اثبات امکان استفاده از روش نوین شبکه‌های عصبی به‌عنوان یک گزینه جدید به‌عنوان یک دستاورد با ارزش این تحقیق مطرح شده است. ارزیابی روش شبکه‌های عصبی مصنوعی در تعیین پارامترهای مدل نفوذپذیری نیز توسط (جین و کومار، ۲۰۰۶) انجام و براساس نتایج به‌دست آمده به این نکته نیز اشاره شده است که برای مقایسه ارجحیت هر یک از روش

مدل‌های آماری و یا شبکه‌های عصبی مصنوعی اتکا به پارامتر حداقل میانگین مربعات خطا کافی نبوده و مطالعات گسترده‌تر آماری پیشنهاد شده است.

اما با توجه به این که نفوذپذیری به پارامترهای فیزیکی و شیمیایی خاک وابسته می‌باشد، در راستای ارزیابی این روش جدید که محدودیت‌های روش‌های تئوری و تجربی متداول تعیین روابط نفوذ را نداشته باشد و با فرض اینکه نفوذپذیری نهایی خاک‌ها را به کمک پارامترهای زودپافت خاک، خصوصاً در موارد حجم پایین داده‌ها با ارایه یک مدل شبکه عصبی می‌توان برآورد نمود، تحقیق حاضر صورت گرفته است. در این صورت لزوم انجام آزمایش‌های پرهزینه و زمان‌بر تعیین مقادیر نفوذپذیری به حداقل رسیده و تخمین مقادیر کاربردی آن ممکن خواهد بود. در این راستا مدل ریاضی براساس تئوری شبکه‌های عصبی مصنوعی و مدل آماری دیگری نیز به‌منظور پیش‌بینی نفوذپذیری نهایی خاک‌ها- مطالعه موردی اراضی مزرعه تحقیقاتی پردیس ابوریحان از دانشگاه تهران، تهیه و نتایج آنها با توجه به مقادیر واقعی نفوذپذیری‌های اندازه‌گیری شده، مقایسه و تحلیل شد.

مواد و روش‌ها

در تحقیق حاضر از اطلاعات و داده‌های حاصل از تحقیقات میدانی و آزمایشگاهی که توسط مؤلف در مورد روند تغییرات مشخصات فیزیکوشیمیایی و وابستگی آن به نفوذپذیری خاک‌های مورد بحث به انجام رسیده، استفاده شده است. ابتدا ضمن اشاره به روش انجام آزمایش‌های مربوطه، بخشی از داده‌ها که در تهیه مدل‌های شبکه عصبی و آماری مورد استفاده قرار گرفته ارایه، سپس مواد و روش‌های مربوط به مدل شبکه عصبی و مدل آماری بحث شده است.

الف: داده‌های مورد نیاز شبیه‌سازی: مزرعه تحقیقاتی ابوریحان با وسعتی در حدود ۱۲۰ هکتار در دشت ورامین واقع شده است. خاک‌های زراعی محدوده یاد شده، براساس یک شبکه ۲۰۰×۲۰۰ متری به‌عنوان نقاط نمونه‌برداری (۴۰ نقطه) برای تعیین مشخصات فیزیکی و شیمیایی خاک‌ها در محل میخ‌کوبی شدند. برای تمام نقاط ذکر شده، طبقه‌بندی بافت خاک از روش USDA^۱ با استفاده از مثلث بافت خاک، تعیین رنگ خاک از روش نشانه‌گذاری مانسل، اندازه‌گیری وزن مخصوص ظاهری (ρ_b ، گرم بر سانتی‌متر مکعب) و وزن مخصوص حقیقی (ρ_s ، گرم بر سانتی‌متر مکعب) به‌ترتیب با

1- United States Department of Agriculture

کاربرد سیلندره‌های برنجی و به کمک پیکنومتر^۱ انجام شد. همچنین تخلخل خاک (n , درصد) با استفاده از مقادیر وزن مخصوص ظاهری و حقیقی، درصد مواد آلی (MO , درصد) به روش والکلی- بلاک، pH از روش استاندارد الکترومتری، هدایت الکتریکی (Ec , دسی‌زیمنس بر متر) با تهیه عصاره گل اشباع و کاربرد دستگاه کانداکتومتر تعیین شد. مقدار سدیم (Na , میلی‌اکی‌والان گرم در لیتر) با استفاده از فلیم فتومتر و برای اندازه‌گیری مقادیر کلسیم و منیزیم ($Ca^{+}Mg$, میلی‌اکی‌والان گرم در لیتر) از روش تیتراسیون استفاده شد. در مرحله بعد با استفاده از نقشه محدوده مطالعات و انطباق نتایج آزمایش‌های فیزیکی و شیمیایی در محدوده یاد شده، تعداد ۲۰ نقطه آزمایشی در یک پراکنندگی مناسب در محدوده مطالعات برای انجام آزمایش‌های نفوذپذیری انتخاب و سپس پیرامون هر یک از این نقاط در یک شعاع ۱۰ متری، در سه محل کاملاً تصادفی آزمایش‌های نفوذپذیری به روش استوانه‌های مضاعف در سه تکرار برای هر محل انجام شد (در مجموع ۶۰ آزمایش). از میان تکرارها، داده‌های مشکوک و یا داده‌هایی که در حین انجام آزمایش به هر دلیلی با مشکل مواجه بودند از نتایج نهایی حذف و یا آزمایش مجدد صورت گرفت. در پایان این مرحله مقادیر نفوذپذیری نهایی (I_{bas} , سانتی‌متر در ساعت) ۱۸ نقطه آزمایشی (۱۸ نقطه در ۳ تکرار) ثبت شد. لازم به ذکر است با توجه به این‌که نتایج مربوط به بخش ارزیابی مشخصات فیزیکی و شیمیایی خاک‌ها، روابط نفوذپذیری و تحلیل‌های مربوطه طی مقاله علمی دیگری در دست تهیه می‌باشد، به منظور اختصار از ارایه جزئیات آن در اینجا صرف‌نظر شده است. نتایج آزمایش‌های فیزیکی و شیمیایی و مقادیر نفوذپذیری نهایی نقاط آزمایشی مورد استفاده در مدل شبکه عصبی مصنوعی و مدل آماری این مقاله در جدول ۱ ارایه شده است.

در جدول ۱ از بین پارامترهای فیزیکی و شیمیایی پارامترهای درصد مواد آلی، وزن مخصوص ظاهری، وزن مخصوص حقیقی، درصد تخلخل، اسیدیته، هدایت الکتریکی، مقدار سدیم و مقدار کلسیم و منیزیم به‌علت ارتباط بیشتر با نفوذپذیری، سهولت در اندازه‌گیری و کم‌هزینه بودن آزمایش‌های آنها به‌عنوان ورودی مدل‌های شبکه عصبی و آماری، و پارامتر نفوذپذیری به‌عنوان خروجی انتخاب شدند.

1- Pyknometer

ب: مدل شبکه عصبی: در این تحقیق از نسخه ۴ نرم افزار NeuroSolutions برای تهیه مدل پیش‌بینی نفوذ نهایی خاک‌های محدوده مطالعات استفاده شد. در ادامه ضمن معرفی شبکه عصبی انتخابی مورد استفاده به بررسی کلی آن که شامل مراحل مختلف معرفی و ساخت فایل ورودی، تعیین ساختار (تعیین نوع شبکه، تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، نوع توابع آموزش و سایر پارامترهای مرتبط)، آموزش و آزمون شبکه می‌باشد، پرداخته شده است.

جدول ۱- مشخصات فیزیکی و شیمیایی و نفوذپذیری نهایی مورد استفاده.

نقطه آزمایشی	کلسیم و منیزیم (میلی)	هدایت الکتریکی (دسی‌زیمنس بر متر)	مواد آلی (درصد)	تخلخل خاک (درصد)	سدیم (میلی) اکی‌والان (برلیتر)	وزن مخصوص ظاهری (گرم بر سانتی‌متر مکعب)	وزن مخصوص حقیقی (گرم بر سانتی‌متر مکعب)	اسیدیته	نفوذ نهایی (سانتی‌متر بر ساعت)
۱	۳/۵	۲/۰۲	۰/۹۷	۴۴	۱۶	۱/۴۱	۲/۶۴	۸/۹	۱/۸
۲	۱۸	۱/۲۹	۰/۹۷	۴۲	۲۶	۱/۴۱	۲/۴۶	۸/۲	۱/۳۱
۳	۸/۵	۴/۵۸	۰/۸۳	۴۳	۳۵	۱/۴	۲/۴۸	۸/۷	۰/۸۲
۴	۱۲	۰/۵۵	۱/۲۴	۴۰	۱۵	۱/۴۶	۲/۴۵	۸/۷	۱/۳۸
۵	۵/۴	۲/۳	۱/۲۴	۴۰	۱۳	۱/۵	۲/۵۱	۸/۱	۱/۱۷
۶	۳/۸	۱/۸۳	۰/۷۶	۴۰	۱۰	۱/۵۳	۲/۵۷	۸/۴	۲/۰۳
۷	۸	۳/۸۶	۱/۱	۴۵	۳۲	۱/۳۷	۲/۵۳	۸/۴	۱/۵۸
۸	۴/۴	۲/۰۸	۰/۸۳	۴۱	۱۳	۱/۴۶	۲/۴۶	۸/۴	۰/۶۴
۹	۱۷	۵/۸۹	۰/۴۸	۴۷	۳۷	۱/۲۹	۲/۴۸	۸/۲	۰/۵۴
۱۰	۱۹/۸	۴/۰۳	۰/۷۶	۴۷	۲۱	۱/۳۳	۲/۵۱	۸	۳/۱۹
۱۱	۶/۱	۳/۱۷	۰/۲۸	۴۱	۲۱	۱/۴۸	۲/۴۹	۸/۳	۰/۲۹
۱۲	۱۰/۳	۳/۵۶	۰/۲۸	۴۴	۲۸	۱/۳۵	۲/۴۴	۸/۵	۱/۱۸
۱۳	۸/۶	۳/۴۹	۰/۲۱	۴۰	۲۴	۱/۵۵	۲/۵۸	۸/۴	۰/۳۹
۱۴	۱۸	۴/۴۹	۰/۹	۴۱	۳۵	۱/۴۹	۲/۵۶	۸/۲	۱/۷۷
۱۵	۴۷	۳/۰۴	۰/۹۶	۳۸	۲۵	۱/۵۲	۲/۴۸	۸	۲/۰۳
۱۶	۱۰/۶	۲/۱۳	۱/۱	۳۳	۱۳/۲۵	۱/۶۳	۲/۴۶	۸/۵	۱/۱۸
۱۷	۳۴/۴	۱۲/۲۷	۰/۱۸	۴۴	۷۰	۱/۳۷	۲/۴۷	۸/۸	۰/۱
۱۸	۱۱/۲	۱/۷۱	۰/۲۱	۳۶	۱۷	۱/۶۸	۲/۵۱	۸/۷	۱/۵۸
مقدار حداقل	۳/۵	۰/۵۵	۰/۱۸	۳۳	۱۰	۱/۲۹	۲/۴۴	۸	۰/۱
مقدار حداکثر	۴۷	۱۲/۲۷	۱/۲۴	۴۷	۷۰	۱/۶۸	۲/۶۴	۸/۹	۳/۱۹

معرفی و ساخت فایل ورودی: از بین ۱۸ سری از داده‌های انتخابی، نفوذپذیری (به‌عنوان داده‌های خروجی) و مقادیر متناظر خصوصیات فیزیکی و شیمیایی آنها (به‌عنوان داده‌های ورودی) براساس تجربه به دو گروه داده‌های آموزش و آزمون به ترتیب به نسبت ۷۰ به ۳۰ درصد به‌طور تصادفی انتخاب و سپس در فایل ورودی وارد شد. به این ترتیب ۱۴ سری از داده‌های پارامترهای فیزیکی و شیمیایی به‌عنوان داده‌های ورودی شبکه و مقادیر نفوذپذیری نهایی متناظر با آنها به‌عنوان خروجی شبکه، جهت آموزش و ۴ سری از داده‌ها برای آزمون و ارزیابی شبکه مشخص و به نرم‌افزار معرفی شد.

تعیین ساختار شبکه: مهم‌ترین مرحله از ساخت شبکه تعیین ساختار یک شبکه عصبی می‌باشد. اولین قدم در تعیین ساختار شبکه، تعیین نوع شبکه است. با توجه به اینکه یک شبکه پرسپترون با یک لایه مخفی قادر به تقریب زدن هر تابع غیرخطی می‌باشد (منهاج، ۲۰۰۲)، در این تحقیق شبکه‌ای از نوع پرسپترون به‌عنوان اولین گزینه ممکن در نظر گرفته شد. سپس بر مبنای روش سعی و خطا در انتخاب شبکه‌ای با بهترین پیش‌بینی‌ها و کمترین خطا از بین یازده نوع شبکه ممکن قابل انتخاب صحت این گزینه مورد تأیید قرار گرفت که در بخش نتایج دوباره بحث خواهد شد. شبکه انتخاب شده شبکه‌ای از نوع پیش‌رو بوده که براساس روش پس انتشار خطا کار می‌کند. یک شبکه عصبی مصنوعی شامل لایه‌های ورودی، خروجی و مخفی است. معمولاً شبکه‌های عصبی شامل یک لایه ورودی است که اطلاعات را دریافت می‌کند، تعدادی لایه مخفی که اطلاعات را از لایه‌های قبلی می‌گیرند و در نهایت یک لایه خروجی دارد که سیگنال‌های خروجی از نرون‌های لایه میانی مطابق رابطه زیر به آنها می‌رود.

$$y_j = f(\sum w_{ji} x_i) \quad (1)$$

که در آن x_i سیگنال‌های لایه ورودی، w_{ji} وزن‌های سیناپسی (اتصالات منظم بین لایه‌ها) و y_j خروجی شبکه است که تابعی از f مجموع می‌باشد (فام، ۱۹۹۹).

اگرچه فقط یک لایه ورودی و یک لایه خروجی وجود دارد، ولی یک شبکه عصبی مصنوعی می‌تواند دو یا سه لایه مخفی داشته باشد. به‌طورکلی هرچه تعداد لایه‌ها بیشتر باشد، سیستم قادر به درک پیچیدگی‌های بیشتری است، هر چند از طرف دیگر زیاد بودن تعداد لایه‌ها دقت پیش‌گویی را کم کرده و ممکن است مانع هم‌گرا شدن شبکه شود. تعداد لایه‌های مخفی یک شبکه معمولاً براساس آزمون و خطا تعیین می‌شود. پارامتر دیگر، تعداد نرون‌ها در هر لایه است. کم بودن تعداد نرون‌ها

قدرت تجزیه و تحلیل و به دنبال آن دقت عددی پیش‌گویی را کاهش می‌دهد (راسل، ۲۰۰۴). از سوی دیگر زیاد بودن بیش از حد تعداد نرون‌ها باعث می‌شود که سیستم، به‌جای تجزیه و تحلیل داده‌ها، آنها را حفظ کند. در شروع مرحله یادگیری، اطلاعات مربوط به نمونه‌ها یکی یکی به شبکه داده می‌شود. اطلاعات ورودی x_i در شبکه جریان پیدا می‌کند به این معنی که در وزن‌های سیناپسی w_{ji} ضرب شده و نتیجه فعالیت هر نرون به‌صورت سیگنال y_j ، خود ورودی نرون‌های لایه بعدی خواهد بود. در پایان جریان اطلاعات هر نمونه، شبکه پاسخ y_j را در لایه خروجی خواهد داشت.

هدف از آموزش شبکه در واقع تنظیم پارامترهای شبکه می‌باشد، به‌طوری‌که اگر شبکه‌ای برای یک وضعیت خاص کارآمد شد و سپس تغییر کوچکی در شرایط محیطی آن رخ داد برای شرایط جدید نیز قابل کاربرد باشد. در پایان آموزش شبکه تفاضل مقادیر پیش‌بینی شده توسط شبکه و مقادیر اندازه‌گیری شده تجربی آن باید به صفر نزدیک شود. معمول‌ترین روال برای کاهش این خطا، روش توزیع معکوس خطا^۱ می‌باشد که این روش در بسیاری از کاربردهای امروزی شبکه‌های عصبی مورد استفاده است. در روش توزیع معکوس پس از محاسبه خطای پیش‌گویی، وزن‌های سیناپسی از آخرین لایه به سوی نخستین لایه، به‌تدریج طوری تغییر می‌کنند که خطای پیش‌گویی کمتر شود.

این الگوریتم، تغییرات Δw_{ji} که وزن اتصالات بین نرون‌های i و j را مطابق رابطه زیر می‌دهد:

$$\Delta w = \eta \delta_j x_i \quad (2)$$

که در آن η پارامتری است که نرخ یادگیری نامیده شده δ_j و فاکتوری است که به موقعیت نرون بستگی دارد. در این رابطه پارامترها بی‌بعد هستند. یک روال معمول برای سرعت بخشیدن به آموزش هر شبکه افزودن مومنتوم به تساوی فوق می‌باشد:

$$\Delta w_{ji(k+1)} = \eta \delta_j x_i + \mu \Delta w_{ji(k)} \quad (3)$$

که در آن $\Delta w_{ji(k)}$ و $\Delta w_{ji(k+1)}$ به ترتیب تغییرات وزن در دوره k و $k+1$ و μ ضریب مومنتوم می‌باشد. مومنتوم در واقع نوعی اینرسی حرکتی برای تغییر وزن‌ها ایجاد می‌کند که سبب می‌شود با تعداد نمونه‌های کمتر و در زمان کمتری سیستم به مرحله هم‌گرایی برسد. به این ترتیب، برخلاف تأثیر نرخ یادگیری، تأثیر مومنتوم عملاً بر روی اتصالات سیناپسی مختلف متفاوت بوده و تنها میزان حداکثر مجاز آن برای کل سیستم یکسان است (فام، ۱۹۹۹).

1- Back Propagation of Error

نوع آموزش بر سرعت، دقت یادگیری و صحت پیش‌بینی‌های شبکه مؤثر است. در این زمینه روش‌های مختلفی پیشنهاد شده است که در ادامه به‌طور خلاصه به سه روش از روش‌هایی که بیشترین کاربرد را داشته و در تحقیق حاضر نیز مورد استفاده قرار گرفته است اشاره می‌شود. برای مطالعه بیشتر می‌توان به پرینسیپ و همکاران (۲۰۰۰) مراجعه کرد.

الگوریتم آموزش Conjugate Gradient: این الگوریتم برای حل مسایل مربوط به بهینه‌سازی مورد استفاده قرار می‌گیرد. در این روش بردار وزن‌ها در هر مرحله از آموزش در جهت عمود بر مرحله قبل بهینه می‌شوند و به این ترتیب در بسیاری از حالت‌ها باعث افزایش سرعت هم‌گرایی می‌شود. روابط مربوط به تغییرات وزن‌ها در این الگوریتم به‌صورت زیر است:

$$\begin{aligned} \Delta W &= \alpha(n) \cdot p(n) \\ p(n+1) &= -g(n+1) + \beta(n)p(n) \\ \beta(n) &= \frac{g^T(n+1)g(n)}{g^T(n)g(n)} \quad \alpha(n) = \operatorname{argmin} (E(w(n) + \eta p(n))) \end{aligned} \quad (4)$$

در روابط بالا، W : وزن‌ها، p : جهت حرکت کنونی نرون‌ها، g : گرادیان، β : پارامتری که تعیین می‌کند چند مورد از جهت‌های قبلی برای تشکیل جهت جدید ترکیب شوند. و رابطه α نیز یک جستجوی خطی برای یافتن حداقل میانگین خطا در راستای جهت p می‌باشد.

الگوریتم آموزش Delta-Bar-Delta: یک روش قابل سازگاری step-size برای یافتن یک سطح عملکرد می‌باشد. هر دو روش step-size و مومتوم مطابق با مقادیر قبلی خطای المان‌های پردازنده تغییر می‌یابند. اگر وزن کنونی و قبلی یکسان باشند، نرخ آموزش را به‌صورت خطی افزایش می‌دهد. قوانین مربوط به تغییر وزن‌ها در این الگوریتم به‌صورت زیر می‌باشد:

$$\Delta \eta(n) = \begin{cases} K & S_{i(n-1)} \nabla W_{i(n)} > 0 \\ -\beta \eta(n) & S_{i(n-1)} \nabla W_{i(n)} < 0 \\ 0 & otherwise \end{cases} \quad S_{i(n)} = (1-\lambda) \nabla W_{i(n-1)} + \lambda S_{i(n-1)} \quad (5)$$

که در آن: K : ثابت جمع‌پذیر، β : ثابت ضرب‌پذیر (افزاینده)، λ : فاکتور هموارسازی است.

الگوریتم آموزش Momentum: پارامتر مومتوم نوعی اینرسی حرکتی برای تغییر وزن‌ها ایجاد می‌کند، که سبب می‌شود با تعداد نمونه‌های کمتر و در زمان کمتری سیستم به مرحله هم‌گرایی برسد.

در سیستم‌های دقیق که اهمیت هر نمونه زیاد است و خطای عددی کمی در آن وجود دارد می‌توان از مومنتوم بالا استفاده کرد، اما در سیستم‌های غیردقیق باید این میزان را کم انتخاب کرد. قوانین مربوط به تغییر وزن‌ها در این الگوریتم به صورت زیر می‌باشد:

$$\Delta w_{i(n+1)} = \eta_i \nabla w_i + \rho \nabla w_{i(n)} \quad (6)$$

در رابطه ۶ تعریف پارامترها مشابه روابط بالا است.

در مورد شبکه مورد نظر این تحقیق از طرفی پارامترهای فیزیکی و شیمیایی تک تک نمونه‌ها به لایه ورودی داده شد، و از طرف دیگر مقادیر اندازه‌گیری شده نفوذپذیری نهایی خاک‌ها نیز به حافظه شبکه ارایه شد. پس از انتخاب نوع قانون یادگیری، نرخ یادگیری برای لایه مخفی و لایه خروجی تعیین می‌شود. برای این منظور باید ابتدا مقدار نرخ یادگیری مومنتوم لایه خروجی را ثابت نگه داشته و مقدار نرخ یادگیری مومنتوم لایه مخفی را در محدوده صفر تا یک تغییر داده و برای هر تغییر شبکه را دوباره آموزش و میانگین مربعات خطا را ثبت کرد تا به حداقل مقدار آن دست یافت. به همین ترتیب برای به دست آوردن مقدار نرخ یادگیری لایه خروجی لازم است با ثابت در نظر گرفتن نرخ یادگیری تعیین شده در لایه مخفی که در مرحله قبل به دست آمده است، مقدار نرخ یادگیری لایه خروجی را تغییر و مقادیر میانگین مربعات خطا ثبت شود. در این تحقیق شبکه پیش رو به طور جداگانه با ۱ تا ۸ نرون در لایه مخفی آموزش داده شد، همچنین برای بررسی احتمال ساختارهای مناسب‌تر، شبکه‌های پیش رو با دو لایه مخفی با تعداد مختلف نرون آموزش داده و مقادیر میانگین مربعات خطا در آنها ثبت شد.

آزمون شبکه: پس از تعیین ساختار و آموزش شبکه، لازم است که شبکه ساخته شده از نظر عملکرد مورد ارزیابی قرار گیرد. برای این منظور معمولاً حدود ۲۰ درصد از داده‌ها که قبلاً در مرحله معرفی فایل ورودی، به طور تصادفی انتخاب و جهت آموزش شبکه به کار برده نشده‌اند، برای ارزیابی استفاده می‌شوند. در واقع مقادیر پیش‌بینی شده توسط شبکه عصبی با داده‌های یاد شده به روش‌های آماری مقایسه و دقت پیش‌بینی‌های انجام شده و عملکرد شبکه بحث می‌شود.

ج: مدل آماری: به منظور ارزیابی و مقایسه مدل شبکه عصبی تهیه شده با روش مدل‌های آماری، با استفاده از نرم‌افزار SPSS مدل رگرسیونی چندمتغیره رابطه نفوذپذیری با پارامترهای فیزیکی و شیمیایی خاک‌های محدوده مطالعات تهیه شد. جهت ارایه مدل‌های آماری، متغیرهای مستقل شامل درصد مواد آلی، وزن مخصوص ظاهری، وزن مخصوص حقیقی، درصد تخلخل، اسیدیته، هدایت

الکتريکی، مقدار سدیم، مقدار کلسیم و منیزیم و متغیر وابسته مقدار نفوذپذیری نهایی در نظر گرفته و با توجه به تعداد زیاد متغیرهای مستقل از روش رگرسیون چندمتغیره استفاده شد. همچنین به عنوان معیاری از درستی روش کاربردی، مقادیر ضرایب همبستگی داده‌ها بین مقادیر واقعی و مقادیر پیش‌بینی شده توسط مدل شبکه عصبی و مدل آماری با استفاده از ضرایب زیر محاسبه و نتایج آن در بخش نتایج ارائه شده است (نعمت‌الهی، ۲۰۰۱).

$$R = \frac{\sum(t - \bar{t})(a - \bar{a})}{\sqrt{\sum(t - \bar{t})^2 (a - \bar{a})^2}} \quad (7)$$

و

$$ME = \frac{\sum(t - a)}{N} \quad (8)$$

و

$$RMSE = \frac{\sqrt{\sum(t - a)^2}}{N} \quad (9)$$

در روابط فوق R ضریب همبستگی، \bar{a} و \bar{t} به ترتیب مقدار مطلق و متوسط مقادیر خروجی شبکه عصبی و یا مدل آماری، t و \bar{t} نیز به ترتیب برابر مقادیر مطلق و متوسط نفوذپذیری نهایی اندازه‌گیری شده، N تعداد داده‌ها، ME میانگین خطای مطلق (Mean Error) و RMSE میانگین جذر مربعات خطا (Root Mean Square Error) می‌باشند.

نتایج

نتایج مدل‌های شبکه عصبی مصنوعی و آماری


نتایج مدل شبکه عصبی: همان‌گونه که قبلاً نیز اشاره شد، پس از تعیین و معرفی نوع داده‌ها، در مرحله ساخت شبکه عصبی مصنوعی با توجه به نتایج اولیه سعی و خطاهای انجام شده، برای یک شبکه پرسپترون اقدام به تعیین ساختار و آموزش شبکه شد. به عبارت دیگر، شبکه مورد نظر به‌طور جداگانه با ۱ تا ۱۷ نرون در لایه مخفی آموزش داده شد که بهترین حالت ثبت شده مربوط به ۵ نرون برای لایه میانی می‌باشد. نمودار آموزش شبکه انتخابی پس از گذراندن حدود ۱۰۰۰ دور و تغییر وزن مربوطه، به حداقل میانگین مربعات خطایی برابر با $5/4398E-07$ دست یافت، لازم به ذکر است که سایر قوانین و مقادیر نرخ یادگیری دقتی کمتر از موارد انتخابی ذکر شده از خود نشان دادند. همچنین

برای بررسی ساختارهای احتمالی مناسب‌تر، شبکه‌های پیش‌رو با دو لایه مخفی با تعداد نرون‌های مختلف آموزش داده و مقادیر میانگین مربعات خطا در آنها ثبت شد. به‌عنوان نمونه بخشی از مقادیر میانگین مربعات خطای حاصل از آموزش شبکه در جدول ۲ ارائه شده است.

از مقادیر جدول ۲ مشخص است که حداقل میانگین مربعات خطایی برابر با ۰/۰۰۹۷۴ مربوط به شبکه‌ای یک لایه با ۵ نرون می‌باشد بنابراین می‌توان نتیجه گرفت که بهترین ساختار شبکه برای تخمین مقدار نفوذپذیری نهایی خاک‌ها با استفاده از پارامترهای فیزیکی و شیمیایی، شبکه با یک لایه مخفی با ۵ نرون است. همچنین تغییرات میانگین مربعات خطای داده‌های آموزش نسبت به تکرار در شکل ۱ نشان داده شده است.

جدول ۲- مقادیر میانگین مربعات خطا حاصل از آموزش شبکه پیش‌رو با دو لایه مخفی.

تعداد نرون‌های					تعداد نرون‌های لایه اول
تعداد نرون‌های لایه دوم (لایه مخفی)					
۴	۳	۲	۱	۰	
۰/۰۱۷	۰/۰۲۵	۰/۰۰۹۹	۰/۰۲۶	۰/۰۰۹۹۷	۱
۰/۰۰۹۹۰	۰/۰۰۹۸	۰/۰۱۹۶	۰/۰۱۹۲	۰/۰۰۹۸۷	۲
۰/۰۰۹۹۰	۰/۰۰۹۹۴	۰/۰۱۲۹	۰/۰۰۹۸۷	۰/۰۰۹۸۰	۳
۰/۰۰۹۹	۰/۰۰۹۹۴	۰/۰۱۰۷	۰/۰۱۰۵	۰/۰۰۹۹۰	۴
۰/۰۰۹۹	۰/۰۰۹۹۵	۰/۰۱۹۰	۰/۰۱۸۷	۰/۰۰۹۷۴	۵
۰/۰۰۹۹	۰/۰۰۹۹۵	۰/۰۰۹۹۵	۰/۰۰۹۹۴	۰/۰۰۹۷۶	۶
۰/۰۰۹۹	۰/۰۰۹۹۱	۰/۰۰۹۹۵	۰/۰۰۹۸۷	۰/۰۰۹۸۹	۷
۰/۰۰۹۸۶	۰/۰۰۹۹۲	۰/۰۰۹۹۶	۰/۰۰۹۹۷	۰/۰۰۹۸۳	۸



شکل ۱- نمودار تغییرات میانگین مربعات خطا داده‌های آموزش نسبت به تکرار.

همچنین جهت انتخاب توابع آستانه مختلف مربوط به لایه مخفی و لایه خروجی از انواع توابع انتقال برای آموزش شبکه پیش‌رو استفاده و مقادیر میانگین مربعات خطا ثبت و تابع انتقالی پرسپترون که باعث تولید حداقل خطا شد، انتخاب گردید. مقادیر میانگین مربعات خطا حاصل از این مرحله در جدول ۳ ارائه شده است. همان‌طور که از نتایج جدول ۳ مشخص است، تابع انتقال تانژانت هایپربولیک با حداقل خطایی برابر با 0.009773 بهترین تابع انتقال برای مدل شبکه عصبی تحقیق حاضر می‌باشد.

جهت تعیین نوع قانون یادگیری نیز به همین ترتیب شبکه با قوانین یادگیری مختلف مورد بررسی قرار گرفته و نتایج در جدول ۴ ارائه شده است. به دلیل نزدیک بودن مقادیر میانگین مربعات خطا مربوط به سه قانون Δ ، Δ -Bar- Δ ، Conjugate Gradient و Momentum از جدول ۴، شبکه با همین خصوصیات مورد آزمون قرار گرفته و مقادیر میانگین مربعات خطا مربوط به مرحله آزمون آنها با هم مقایسه و بر این اساس قانون یادگیری مومنتوم با حداقل خطای 0.0061 انتخاب شد.

جدول ۳- نتایج حاصل از آموزش شبکه یک لایه مخفی با ۵ نرون توسط توابع آستانه مختلف.

تابع انتقال لایه اول و لایه خروجی	تانژانت هایپربولیک	سیگموئید	سیگموئید خطی	تانژانت هایپربولیک خطی	خطی
میانگین مربعات خطا	0.009773	0.01482	0.009989	0.009919	0.0297

جدول ۴- نتایج حاصل از آموزش شبکه توسط قوانین یادگیری مختلف در مرحله آموزش و آزمون.

نام قانون یادگیری	Conjugate Gradient	Quickprop	Delta-Bar-Delta	Momentum
میانگین مربعات خطا در مرحله آموزش	۰/۰۰۸۵	۰/۰۰۹۸۱	۰/۰۰۷۶۴	۰/۰۰۹۳
میانگین مربعات خطا در مرحله آزمون	۰/۷۵۴	----	۰/۶۷	۰/۶۱

در همین مرحله و دوباره بر مبنای کمترین میانگین مربعات خطا، نرخ یادگیری ۰/۹ در لایه مخفی و ۰/۵ در لایه خروجی به دست آمد. نتایج حاصل از آموزش شبکه با مقادیر مومنتوم مختلف در لایه مخفی و لایه خروجی به ترتیب در جدول ۵ ارایه شده است. به طور خلاصه می توان گفت که در تحقیق حاضر شبکه ای سه لایه شامل: لایه ورودی با ۸ نرون، لایه مخفی با ۵ نرون و لایه خروجی با یک نرون، تابع انتقال تانژانت هایپربولیک، قانون آموزش مومنتوم و نرخ یادگیری برابر با ۰/۹ در لایه مخفی و ۰/۵ در لایه خروجی بهترین نتایج را در برداشت.

جدول ۵- نتایج حاصل از آموزش شبکه برای مقادیر مختلف مومنتوم در لایه مخفی و خروجی.

مقادیر مومنتوم لایه اول	میانگین مربعات خطا لایه مخفی	میانگین مربعات خطا لایه خروجی
۰/۱	۰/۰۰۹۳۹	۰/۰۰۹۵۷
۰/۲	۰/۰۰۹۴۹	۰/۰۰۹۱
۰/۳	۰/۰۰۹۴۷	۰/۰۰۹۰۵
۰/۴	۰/۰۰۹۴۵	۰/۰۰۸۹۱
۰/۵	۰/۰۰۹۲۳	۰/۰۰۸۷۵
۰/۶	۰/۰۰۹۱۴	۰/۰۰۹۳۸
۰/۷	۰/۰۰۹۰۹	۰/۰۰۸۹۵
۰/۸	۰/۰۰۹۰۵	----
۰/۹	۰/۰۰۸۸۹	----
۱	۰/۰۰۹۸۸	----

جدول ۶ نیز خلاصه ای از نتایج آموزش شبکه را نشان می دهد.

جدول ۶- خلاصه‌ای از نتایج حاصل از آموزش انتخابی.

مقدار	پارامتر
۰/۲۸۶۶۰۲۷	میانگین مربعات خطا بین مقادیر مشاهده شده و مقادیر خروجی
۱/۱۶۶۷۱۱۵۷۹	میانگین مربعات خطای نرمال شده
۰/۳۸۸۵۳۶۱۴۳	قدرمطلق میانگین خطاها
۰/۰۰۱۷۰۸۷۹۸	حداقل قدرمطلق خطا
۰/۹۸۴۹۹۷۴۸۲	حداکثر قدرمطلق خطا
۰/۹۳۸۶۰۸۷۰۲	ضریب همبستگی خطی

پس از طراحی و آموزش شبکه، ۴ نمونه از داده‌ها که قبلاً به‌طور تصادفی انتخاب و جهت آموزش به‌کار برده نشده بودند، جهت ارزیابی شبکه به‌کارگرفته شد، که مقادیر پیش‌بینی شده توسط شبکه عصبی و مدل آماری در مقایسه با مقادیر واقعی اندازه‌گیری شده پس از ارایه نتایج مدل آماری آورده شده است.

نتایج مدل آماری: رابطه ۱۰ نتیجه مقایسه ضرایب همبستگی چندین مدل آماری است که بهترین مدل آماری ممکن با حذف متغیر وزن مخصوص ظاهری، به‌دلیل وابستگی خطی آن با تخلخل و به‌کارگیری لگاریتم مقدار سدیم به‌دست آمد.

$$I_{bas} = -۱۳/۷۲۱ + ۰/۴۶۴ MO + ۰/۳۲۰ pH + ۰/۰۳۱ (Ca + Mg) - ۰/۱۵۳ Ec + ۴/۶۳ \rho_b - ۰/۰۹۴ LogNa + ۰/۰۱۲ n \quad (۱۰)$$

که در آن n تخلخل، ρ_v وزن مخصوص ظاهری، pH اسیدیته، EC هدایت الکتریکی، Na ، Ca ، Mg میزان سدیم و منیزیم و کلسیم برحسب میلی‌اکی‌والان بر لیتر و MO درصد مواد آلی می‌باشد. این رابطه دارای عرض از مبدایی برابر با $-۱۳/۷۲۱۰۲$ و ضریب همبستگی ۶۷ درصد می‌باشد. پیش‌بینی‌ها و ارزیابی این مدل در ادامه ارایه شده است.

مقایسه نتایج مدل شبکه عصبی با مدل آماری: نتایج پیش‌بینی‌های مدل شبکه عصبی و مدل آماری چندمتغیره تهیه شده در مقابل مقادیر واقعی اندازه‌گیری شده متناظر آنها در جدول ۷ ارایه شده است. همان‌گونه که از نتایج یاد شده برمی‌آید، ضریب همبستگی مربوط به مدل شبکه عصبی برابر با ۹۴ درصد و ضریب همبستگی مدل آماری برابر با ۹۸ درصد، متوسط خطای مطلق شبکه عصبی $-۰/۳۸۵$

و برای روش آماری ۰/۱۲۲- و در نهایت متوسط جذر مربعات خطا شبکه عصبی ۰/۲۶۶ و برای روش آماری ۰/۰۸۲۵ می‌باشد. ضرایب همبستگی به‌دست آمده به عدد یک نزدیک بوده و نشان می‌دهد که پیش‌بینی مقادیر نفوذپذیری خاک‌ها بسیار مناسب بوده و شبیه‌سازی توسط شبکه عصبی جهت پیش‌بینی مقادیر نفوذپذیری با استفاده از مقادیر پارامترهای فیزیکی و شیمیایی به واقعیت نزدیک است. همچنین از مقایسه مقادیر ضرایب سه‌گانه به‌دست آمده مشخص است که دقت پیش‌بینی‌های شبکه عصبی مصنوعی کمی پایین‌تر از مدل آماری می‌باشد. تفسیر اعداد ۰/۹۴، ۰/۹۸ ضریب همبستگی، ۰/۳۸۵- و ۰/۱۲۲- متوسط خطای مطلق، ۰/۲۶۶ و ۰/۰۸۲۵ متوسط جذر مربعات خطای به‌دست آمده و اظهار نظر در مورد مقایسه و اعتبار هر یک از روش‌های مورد بحث شبکه عصبی و آماری صرفاً براساس نتایج به‌دست آمده از این تحقیق موردی، باید با احتیاط صورت گیرد. چرا که اول این‌که اعداد حاصل محاسبه‌های انجام شده با حجم پایینی از داده‌ها می‌باشد و دوم این‌که قضاوت در این مورد نیازمند تحقیقات بیشتر و در دامنه وسیع‌تری می‌باشد. به‌طور مثال، مطابق با تحقیقات انجام شده در مورد کاربرد شبکه‌های عصبی در تخمین رسوب‌دهی حوزه‌های آب‌خیز (بنی حبیب و امامی، ۲۰۰۵) نتایج مشابهی در مورد اعتبار شبکه‌های عصبی به‌دست آمده است با این تفاوت که نتایج یاد شده نشان‌دهنده کارایی بهتر شبکه عصبی در تخمین رسوب حوزه مورد مطالعه نسبت به مدل‌های آماری بوده است. همچنین همان‌طور که پیش از این نیز اشاره شد (جین و کومار، ۲۰۰۶) در ارزیابی روش شبکه‌های عصبی مصنوعی در تعیین پارامترهای مدل نفوذپذیری علاوه بر توصیه در مورد بررسی و استفاده از شبکه‌های عصبی مصنوعی در موارد نقصان حجم کافی از داده‌ها، تأکید نموده‌اند که برای مقایسه روش مدل‌های آماری با شبکه‌های عصبی مصنوعی پارامترهای ساده‌ای نظیر حداقل میانگین مربعات خطا کافی نبوده، بلکه این قضاوت نیازمند مطالعات گسترده آماری است، که این امر خود انجام تحقیقات بیشتر را می‌طلبد. به‌طور مثال مژدان و همکاران، (۲۰۰۶) با استفاده از ۱۳۰ سری داده به این نتیجه رسیدند که به‌طور کلی عملکرد رگرسیون بهتر از شبکه عصبی مصنوعی بوده، ولی این اختلاف از نظر آماری معنی‌دار نبوده و تغییرات زمانی و مکانی خصوصیات هیدرولیکی و فیزیکی خاک منطقه می‌تواند دلیل ضعف عملکرد شبکه‌های عصبی مصنوعی در مطالعه یاد شده بوده باشد.

جدول ۷- مقادیر پیش‌بینی نفوذپذیری توسط مدل شبکه عصبی و مدل آماری در مقایسه با مقادیر واقعی.

متوسط جذر مربعات خطا (RMS)		متوسط خطای مطلق (ME)		ضریب همبستگی (درصد)		مقادیر پیش‌بینی شده نفوذ		مقادیر واقعی نفوذ (سانتی‌متر بر ساعت)	نقطه آزمایشی
روش شبکه عصبی	روش آماری	روش شبکه عصبی	روش آماری	روش شبکه عصبی	روش آماری	روش شبکه عصبی	روش آماری		
						۱/۴۶	۱/۵	۱/۳۱	۲
۰/۰۸۲۵	۰/۲۶۶	-۰/۱۲۲	-۰/۳۸۵	۹۸	۹۴	۰/۹۳	۱/۰۱	۰/۶۴	۸
						۲/۰۸	۳/۰۱	۲/۰۳	۱۵
						۱/۱۸	۱/۱۸	۱/۱۸	۱۶

بحث و نتیجه‌گیری

هدف اصلی این تحقیق ارزیابی مدل‌های ریاضی براساس تئوری شبکه‌های عصبی مصنوعی به‌منظور پیش‌بینی نفوذپذیری نهایی خاک‌ها در شرایط حجم کم داده‌ها بود. در این مورد نفوذپذیری نهایی خاک‌ها به‌عنوان تابعی از خواص فیزیکی و شیمیایی آنها در نظر گرفته شد. نتایج این تحقیق نشان داد که شبکه عصبی مصنوعی تهیه شده قابلیت خوبی در مدل کردن نفوذپذیری نهایی خاک‌های مورد مطالعه را دارد. همچنین مدل شبکه عصبی پرسپترون سه لایه با یک لایه مخفی ۵ نرونی و تابع انتقال تانژانت هایپربولیک توانست با کاربرد حجم کمی از داده‌ها (۱۸ سری داده) دانش الگوریتم بین مشخصات فیزیکی و شیمیایی و نفوذپذیری نهایی خاک‌ها را با دقت بالایی بیابد. نوایان و همکاران (۲۰۰۴) نیز که از ۴۵ نمونه خاک برای برآورد هدایت آبی اشباع با استفاده از شش پارامتر فیزیکوشیمیایی ورودی توسط شبکه عصبی مصنوعی استفاده کردند، ساختار پرسپترون با یک لایه مخفی ۷ نرونی با تابع آستانه سیگموئیدی و الگوریتم آموزشی مارکوارت-لورنبرگ را مناسب تشخیص داده و مدل آنها دارای عملکرد مناسب‌تری نسبت به مدل آماری داشت که علت عملکرد مناسب‌تر شبکه عصبی را به هوشمند بودن نحوه تجزیه و تحلیل داده‌ها نسبت دادند.

دعایی و همکاران (۲۰۰۵) از ۲۲۱ نمونه خاک رسی استان گیلان با استفاده از پارامترهای فیزیکی درصد رس، کربن آلی و وزن مخصوص ظاهری به‌عنوان پارامترهای زودیافت و نیز مقدار ضریب آب‌گذری اشباع به‌عنوان یک پارامتر دیریافت خاک شبکه عصبی با ساختار پرسپترون سه لایه با یک

لایه مخفی ۶ نرونی و الگوریتم آموزشی مارکوارت- لورنبرگ تشکیل دادند. نتایج نشان داد که شبکه عصبی با ضریب تبیین ۰/۹۷۴ و جذر میانگین مربع باقی مانده برابر با ۰/۱۶۰ بهترین و دقیق ترین تخمین را در مدل سازی ضریب آب گذری اشباع نشان می دهد. مژدان و همکاران (۲۰۰۶) نیز برای پیش بینی ظرفیت نگهداری آب خاک و هدایت هیدرولیکی اشباع با استفاده از خصوصیات پایه خاک مانند توزیع ذرات خاک، وزن مخصوص و سه قطر مختلف منافذ خاک توسط یک شبکه عصبی پیش رو با ۳ لایه و ۶ نرون در هر لایه ایجاد و عملکرد آن با روش آماری رگرسیون چند خطی مورد مقایسه قرار دادند. دقت پیش بینی با ضریب تبیین و جذر میانگین مربعات خطا مورد مقایسه قرار گرفت. مقادیر این پارامترها برای پیش بینی هدایت هیدرولیکی اشباع خاک به ترتیب برابر با ۰/۶۳۷ و ۰/۹۳۸ برای روش رگرسیون و ۰/۵۲۴ و ۳/۵۱۱ برای روش شبکه عصبی به دست آمد.

جهت ارزیابی مدل ریاضی شبکه عصبی تهیه شده، مدل آماری با کمک نرم افزار SPSS تهیه و مقایسه نتایج تطابق خوبی بین نتایج مدل های شبکه عصبی با مدل آماری و داده های واقعی نشان داد. در ادامه همین تحقیق پیشنهاد می شود تا با تهیه داده های بیشتری از مشخصات فیزیکی و شیمیایی خاک ها و مقادیر نفوذپذیری محدوده مطالعات، زمینه ارتقاء مدل تهیه شده و برنامه ریزی علمی در امر مدیریت مزرعه فراهم شود. این امر سبب افزایش دقت پیش بینی های مدل تهیه شده نیز خواهد شد. همچنین انجام تحقیقات مشابه در سایر مناطق امکان مقایسه نتایج و بحث از دیدگاه های مختلف علمی را فراهم خواهد نمود. بنابراین توصیه می شود با توجه به ضرورت و اهمیت بالای پارامتر نفوذپذیری خاک ها در طرح های آب و خاک و همچنین با عنایت به هزینه های بالای آزمایش های یاد شده، تحقیقات مشابه صورت گیرد.

سپاسگزاری

تمام بودجه این تحقیق از محل اعتبارات معاونت پژوهشی دانشگاه تهران، طرح تحقیقاتی مصوب ۷۳۵۱۰۱۷/۲/۰۱، تأمین شده است. بدین وسیله از معاونت پژوهشی دانشگاه تهران سپاسگزاری می نمایم.

منابع

1. Banihabib, M.E., and Emami, A. 2005. An Artificial Neural Network Model for Estimation of Sediment Yield. *Journal of Water and Watershed*, 3: 1-11.
2. Baybourdi, M. 1983. Principles of Irrigation Engineering, Vol. 1, Soil-Water Relationship, Tehran Uni. Press, 633p. (In Persian).
3. Doaei, M., Shabanpour-e-Shahrestani, M., and Bagheri, F. 2005. Modelling of Saturated Hydraulic conductivity of Gilan Province involving Artificial Neural Networks. The Agricultural Science Research Report, Faculty of Agriculture, Gilan University. 1: 6. 41-48. (In Persian).
4. Green, W.H., and Ampt, G.A. 1911. Studies in soil physics: I. The flow of air and water through soils. *J. Agric. Science*, 4: 1-24.
5. Horton, R.E. 1940. An approach toward to physical interpretation of infiltration capacity. *Soil. Sci. Soc. Am. J.*, 5: 399-417.
6. Jafarnejad-e-Ghomi, E.A. 2004. Artificial Intelligence (A Modern Approach). Babol Olome-Rayaneh Press, 400p. (Translated In Persian).
7. Jain, A., and Kumar, A. 2006. An evaluation of artificial neural network technique for the determination of infiltration model parameters, *Applied Soft Computing*, 6: 272-282.
8. Kostiakov, A.N. 1932. On the Dynamic of coefficient of water-percolation in soils and on the necessity for studying it from a dynamic point of view for purposes of amelioration. *Trans sixth comm. Intern. Soil. Sci. Soc. Russia*. Pp: 17-21.
9. Machiwa, D., Madan, K., and Mal, B.C. 2006. Modelling Infiltration and quantifying Spatial Soil Variability in a Wasteland of Kharagpur, India, *Biosystems Engineering*, 95: 4. 569-582.
10. Marcel, G.S., Feike, J.L., and Martinus, T., van Genuchten, h. 1998. Neural Network Analysis for Hierarchical Prediction of Soil Hydraulic Properties, *Soil Science Society*, 62: 847-855.
11. Menhaj, M.B. 2002. Principle of Neural Networks, Vol. 1. Amir Kabir Uni. Press, 502p.
12. Merdun, H., Cinar, O., Meral, R., and Apan, M. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity, *Soil and Tillage Research*, 90: 108-116.
13. Mohammadi, M.H., and Refahi, H. 2005. Estimation of Infiltration through Soil Physical Characteristics. *Iranian Journal of Agricultural Sciences*, 36: 6. 1391-1398.
14. Navvabian, M., Liaghat, E.M., and Homaei, M. 2004. Rapid Estimation of Hydraulic Conductivity using Neural Networks. In: Proceedings of the second National Student Conference on Water and Soil Resources. Shiraz Uni. Press, Pp: 203-211.

15. Nematollahi, N. 2001. Probability & Statistics for Engineers. Elm-o-Sanat Iran Uni. Press, 337p.
16. Pham, D.T. 1999. Neural Networks for Identification, Prediction and Control, Springer-Verlag Pub. Ltd., London, 238p.
17. Philip, J.R. 1957. The theory of infiltration, I. Infiltration equation and its solution. Soil Sci., 83: 345-357.
18. Postawko, S., and Morissey, M. 2003. Use of Artificial Intelligence Methods in Geosciences, University of Oklahoma. P.1
19. Principe, J.C., Euliano, N.R., and Lefebvre, W.C. 2000. Neural and Adaptive Systems: Fundamentals Through Simulations, John Wiley & Sons, electronic book, <http://www.neurosolutions.com/products/nsbook/>.
20. Shirley, C. 2002. Prediction of Fluid Velocity in Highly Heterogeneous Conductivity Fields Using a Genetic Algorithm-Designed Artificial Neural Network. Desert Research Institute. P.1



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 16(1), 2009
www.gau.ac.ir/journals

Estimation of basic infiltration rate using Artificial Neural Network- case study, Aburaihan Campus Farm

***K. Ebrahimi¹ and F. Nayebloei²**

¹Assistant Prof., Dept. of Irrigation and Reclamation Engineering, University of Tehran,
²M.Sc. Student, Dept. of Irrigation Engineering, Urumiye University

Abstract

Infiltration rate is one of the most important soil physical parameters and is a basic input data in irrigation and drainage projects. Although, a number of theoretical or experimental based equations are presented to describe this phenomenon but the evaluation of some new sciences such as artificial neural networks, for prediction of the phenomenon can be investigated. Generally, the infiltration rate is a function of different soil factors, such as: organic materials; porosity; pH; EC; Na and Ca+Mg. Aburaihan campus belongs to the University of Tehran. It has two teaching and research centres, one of them is located in the Waramin lowlands of eastern Tehran (Ghezlagh farm). The farm has about 120 hectares of fertile lands. The present research plan aims to model the infiltration of the soils involving the Artificial Neural Networks (ANN) and the Statistics models. The performances of different types of neural networks, relevant functions and processing elements were examined using mean square error (MSE) as the criterion. The Multilayer perceptrons (MLPs, feed-forward network) with one hidden layer (three layers in total) including five neurons as neural network type and momentum as learning rule were the final option, which were chosen to built up the ANN model. Data from a previous study were used for this purpose. Also, a regression model involving the SPSS software has been used to predict the basic infiltration rate (Ibas). Results obtained from the artificial neural network and the regression models were compared in terms of correlation coefficient between measured and estimated values. The calculated correlation coefficients between the predicted and measured data were found to be 0.94 and 0.98 for the neural network and regression methods, respectively. Results indicated that the variable, Ibas, was predicted more efficiently by the regression model than the ANN model. However, from the encouraging results, it can be concluded that the use of a neural network model can be efficient for prediction of the basic infiltration rate.

Keywords: Physical and Chemical Soil Characteristics, Artificial Neural Networks, Basic Infiltration Rate, Statistics Model

* Corresponding Author; Email: EbrahimiK@ut.ac.ir

