



دانشگاه فردوسی مشهد

مجله پژوهش‌های حفاظت آب و خاک

جلد هجدهم، شماره دوم، ۱۳۹۰

www.gau.ac.ir/journals

مقایسه روش‌های مختلف هوش مصنوعی در مدل‌سازی منحنی مشخصه رطوبتی خاک (مطالعه موردی: شمال و شمال شرق ایران)

امیر حق‌وردی^۱، *بیژن قهرمان^۲، محمد جلیلی^۳، علی اصغر خشنود یزدی^۴ و زهرا عربی^۵
^۱ دانشجوی دکتری گروه مهندسی آب، دانشگاه فردوسی مشهد، استاد گروه مهندسی آب، دانشگاه فردوسی مشهد،
^۲ استادیار پژوهش مرکز تحقیقات کشاورزی خراسان رضوی، مربی آموزشکده کشاورزی شیروان، دانشگاه فردوسی مشهد،
^۳ کارشناس ارشد خاکشناسی
تاریخ دریافت: ۸۸/۱۲/۲۲؛ تاریخ پذیرش: ۸۹/۱۰/۲۶

چکیده

میزان رطوبت خاک در مکش‌های گوناگون، یکی از مهم‌ترین نمایه‌های ورودی در بیش‌تر مدل‌های مرتبط با علوم کشاورزی، آب و خاک است. توابع انتقالی، خصوصیات دیریافت را با استفاده از خصوصیات پایه خاک پیش‌بینی می‌کنند و بنابراین برتری عمده آن‌ها، ارزان بودن و اشتقاق آسان می‌باشد. دو هدف عمده در این پژوهش مطرح است. هدف اول سنجش عملکرد شبکه‌های عصبی-فازی و عصبی-ژنتیک در اشتقاق توابع انتقالی به منظور تعیین میزان رطوبت در نقاط پتانسیلی مشخص در مقایسه با مدل‌های شبکه‌های عصبی مرسوم هم‌چون پرسپترون‌های چندلایه می‌باشد. دومین هدف از انجام این پژوهش، معرفی و اعتبارسنجی توابع جدید شبه پارامتریک و مقایسه کارکرد این توابع در مدل‌سازی منحنی مشخصه رطوبتی در مقایسه با توابع نقطه‌ای و پارامتریک است. برای نیل به این مقصود، ۱۲۲ نمونه خاک از شمال و شمال شرق ایران با گستره‌ای از بافت خاک‌ها شامل لوم، رسی، لوم رسی و لوم شنی انتخاب شد و نتایج به دست آمده از مدل‌سازی توسط شبکه‌های مختلف با یکدیگر مقایسه شدند. نتایج نشان از توفیق مدل‌های شبکه عصبی مصنوعی در اشتقاق توابع انتقالی مختلف داشت به گونه‌ای که میانگین کلی آماره‌های RMSE و R^2 به ترتیب برابر با ۰/۰۳۱۶ و

* مسئول مکاتبه: bijangh@ferdowsi.um.ac.ir

۰/۸۴۲ بود. بهترین و ضعیف‌ترین نتایج به ترتیب مربوط به توابع شبه پارامتریک (با آماره‌های RMSE و R^2 به ترتیب برابر ۰/۰۲۲ و ۰/۹۲) و پارامتریک (با آماره‌های RMSE و R^2 به ترتیب برابر ۰/۰۴۴ و ۰/۷۲) بود. همچنین با توجه به نتایج به دست آمده از مدل‌سازی، می‌توان گفت که استفاده از شبکه‌های عصبی - فازی منجر به بهبود نتایج به دست آمده از شبکه‌های پرسپترون نمی‌شود، ولی استفاده از الگوریتم ژنتیک در ساختار شبکه‌های عصبی می‌تواند منجر به بهبود نتایج گردد.

واژه‌های کلیدی: توابع انتقالی، شبکه‌های عصبی- فازی، شبکه‌های ژنتیک- فازی، منحنی مشخصه رطوبتی

مقدمه

امروزه نیاز به تعیین رطوبت خاک در مکش‌های گوناگون به‌عنوان یکی از مهم‌ترین نمایه‌های ورودی در بیش‌تر مدل‌های موجود بیش از پیش اهمیت یافته است. از این‌رو توابع انتقالی خصوصیات هیدرولیک بسیاری توسعه یافته‌اند تا این نیاز را برطرف نمایند (میناسنی و همکاران، ۱۹۹۹). به دلیل این‌که توابع انتقالی خصوصیات دیریافت را با استفاده از خصوصیات پایه خاک پیش‌بینی می‌کنند، برتری عمده ارزان بودن و اشتقاق آسان را دارند (وستون و همکاران، ۲۰۰۱).

در سال‌های اخیر روش‌های مبتنی بر هوش مصنوعی، هم‌چون الگوریتم ژنتیک، شبکه‌های عصبی و تئوری مجموعه‌های فازی به‌خوبی به‌عنوان یک راه‌کار جایگزین برای غلبه بر مشکلات روش‌های سنتی ارتقاء یافته‌اند. تجربه نشان داده است که پیاده‌سازی ساختارهای محاسباتی سیستم بیولوژیکی می‌تواند منجر به ایجاد الگوهای محاسباتی بهتری برای مسایل مبهم و پیچیده شود (جورابیان و هوشمند، ۲۰۰۳). توابع انتقالی توسعه یافته با استفاده از شبکه‌های عصبی توسط محققان بسیاری مورد استفاده قرار گرفته است و تقریباً نتیجه تمامی پژوهش‌های پیشین نشان می‌دهد که این مدل‌ها حداقل به اندازه بقیه روش‌های مورد استفاده خوب عمل می‌کنند و به‌خوبی بر مفروضات آماری درگیر با توابع انتقالی فائق می‌آیند. کاربردهای متعددی از شبکه‌های عصبی برای تخمین خصوصیات هیدرولیکی خاک (مردون و همکاران، ۲۰۰۶؛ میناسنی و همکاران، ۱۹۹۹؛ میناسنی و مک‌برانتی، ۲۰۰۲) گزارش شده که نشان می‌دهد هنوز هم این مسأله در حال پژوهش می‌باشد و تمامی زوایای آن به‌طور کامل شناخته نشده است.

به‌طور عمده توابع انتقالی توسعه‌یافته به‌وسیله شبکه‌های عصبی، نقطه‌ای (که میزان رطوبت را در پتانسیل‌های ماتریک خاصی شبیه‌سازی می‌نمایند (میناسنی و مک‌برانتی، ۲۰۰۲)) و یا پارامتریک (که مؤلفه‌های یک معادله نگهداشت آب خاک مثل ونگنوختن را برآورد می‌کنند (میناسنی و مک‌برانتی، ۲۰۰۲)) می‌باشند. عدم توانایی ارایه عملکردی پیوسته بزرگ‌ترین مشکل توابع نقطه‌ای می‌باشد. توابع پارامتریک با داشتن عملکردی پیوسته این مشکل را ندارند اما به‌دلیل این‌که تنها ضرایب یک معادله خاص، مثلاً ونگنوختن را برآورد می‌کنند در نهایت عملکردی مشابه با معادله یاد شده با ضرایب بهینه‌اش دارند و بنابراین اگر معادله نام برده برای خاک موردنظر عملکرد مطلوبی نداشته باشلسم، تابع پارامتریک متناظر با آن هم کارایی نخواهد داشت. در نتیجه برآورد ضرایب بهینه توسط توابع انتقالی پارامتریک در صورت لزوم به معنی دستیابی به بهترین برآورد ممکن از میزان رطوبت نمی‌باشد. در این پژوهش کوشش شده است که توابع انتقالی شبکه عصبی جدیدی معرفی شوند که با وجود عملکردی پیوسته نیاز به در نظر گرفتن یک معادله نگهداشت آب خاک بین پتانسیل ماتریک و رطوبت نداشته باشند.

آگاهی از بالاترین حد توانایی مدل‌سازی خصوصیات خاک توسط مدل‌های شبکه عصبی، وابسته به آزمون ساختارهای مختلف آن‌ها و مقایسه نتایج می‌باشد. به بیان بهتر با پیشرفت مباحث مدل‌سازی در زمینه شبکه‌های عصبی کموم،^۱ نتیجه گرفته شده از پژوهش‌های رایانه‌ای، ریاضی و آماری می‌باشد، لزوم استفاده از دستاوردهای جدید در مقاصد مدل‌سازی کشاورزی به‌خوبی احساس می‌شود. کاربرد هم‌زمان منطق فازی و شبکه‌های عصبی در قالب یک شبکه عصبی-فازی (Fuzzy-NN)^۱ و همچنین استفاده از الگوریتم ژنتیک در فرایند آموزش شبکه‌های عصبی مصنوعی به‌منظور بهینه‌سازی پارامترهای مختلف در قالب یک شبکه عصبی-الگوریتم ژنتیک (GA-NN)^۲ از جمله این دستاوردهای نوین می‌باشد.

در علوم خاک، اکبرزاده و همکاران (۲۰۰۹) ظرفیت تبادل کاتیونی ۸۰ نمونه خاک از ایران را به‌وسیله شبکه‌های عصبی مختلف مدل‌سازی نمودند. آن‌ها از رگرسیون‌های خطی چندگانه، شبکه‌های عصبی-فازی و شبکه‌های پسانتشار خطا استفاده نمودند. نتایج نشان داد که شبکه‌های عصبی-فازی نسبت به رگرسیون‌های چندگانه و شبکه‌های پسانتشار خطا عملکرد بهتری داشتند. در سایر شاخه‌های علوم

1- Fuzzy Neural Network

2- Genetic Algorithm Neural Network

مرتبط با آب و خاک نیز شبکه‌های عصبی- فازی کاربرد دارد. به‌عنوان مثال ساهو و همکاران (۲۰۰۵) از شبکه‌های عصبی- فازی، شعاعی و شبکه‌های پس‌انتشارخا در پژوهشی مرتبط با کیفیت آب استفاده کردند که عملکرد شبکه‌های عصبی- فازی از بقیه ضعیف‌تر بود. آن‌ها عنوان نمودند که تعاملاً سیستم استنتاج فازی قادر به تهیه قوانین فازی مطلوبی از داده‌های آموزش نبوده است همچنین کیشی و اوزتورک (۲۰۰۷) از شبکه‌های عصبی- فازی به‌منظور تخمین تبخیر- تفرق استفاده نمودند. آن‌ها در پژوهش خود نشان دادند که روش عصبی- فازی تخمین‌های دقیق‌تری از روش‌های تجربی و مدل‌های معمول شبکه عصبی به‌دست می‌دهد. رحیمی‌لک و همکاران (۲۰۰۹) تعدادی از خصوصیات هیدرولوژیکی و شیمیایی- فیزیکی خاک را به‌وسیله شبکه‌های عصبی مدل‌سازی نمودند. آن‌ها در پژوهش خود استفاده از شبکه‌های عصبی- فازی را به‌عنوان یکی از موضوعات پراهمیت پژوهش در آینده به‌خصوص برای اشتقاق توابع انتقالی هیدرولیکی خاک پیشنهاد کرده‌اند.


برخی محققان از الگوریتم ژنتیک به‌عنوان یک روش بهینه‌سازی در فرایند آموزش در مباحث مختلف علوم آب و خاک به‌منظور افزایش کارایی مدل‌های شبکه عصبی سود جست‌اند (هسو و همکاران، ۱۹۹۵؛ چن و همکاران، ۲۰۰۱؛ جین و سرینیواسولو، ۲۰۰۴؛ پراساد و ماتور، ۲۰۰۷). هسو و همکاران (۱۹۹۵) با استفاده از روش کم‌ترین مجددورات خطی^۱ سرعت هم‌گرایی را برای دست‌یابی به مقادیر بهینه وزن‌ها و ارب‌ها (بایاس‌ها) در یک مدل بارندگی- رواناب افزایش دادند. آن‌ها پیشنهاد کردند که کارایی مدل‌های شبکه عصبی می‌تواند با استفاده از الگوریتم ژنتیک بهبود یابد. زارع‌زاده مهریزی و بزرگ‌حداد (۲۰۰۸) به‌منظور پیش‌بینی جریان توسط شبکه‌های عصبی، بهینه‌یابی تعداد لایه‌ها و نرون‌های شبکه عصبی را توسط الگوریتم ژنتیک انجام دادند. آن‌ها عنوان نمودند که استفاده از الگوریتم ژنتیک نسبت به روش موسوم آزمون و خطا، بهتر می‌باشد.

بررسی منابع و پژوهش‌های انجام شده در نقاط مختلف دنیا نشان می‌دهد که از شبکه‌های عصبی- فازی و عصبی- الگوریتم ژنتیک تا به حال به‌منظور اشتقاق توابع انتقالی هیدرولیک خاک استفاده نشده است. این پژوهش دو هدف عمده را دنبال می‌کند. هدف اول امکان‌سنجی ارتقاء نتایج مدل‌سازی منحنی مشخصه رطوبتی با استفاده از شبکه‌های عصبی- فازی و عصبی- الگوریتم ژنتیک در مقایسه با شبکه‌های عصبی مرسوم می‌باشد. دومین هدف از انجام این پژوهش معرفی و

اعتبارسنجی توابع جدید شبه‌پارامتریک و مقایسه کارکرد این توابع در مدل‌سازی منحنی مشخصه رطوبتی در مقایسه با توابع نقطه‌ای و پارامتریک است. برای رسیدن به این مقصود ۱۲۲ نمونه خاک از شمال و شمال‌شرق ایران انتخاب شد و نتایج به‌دست آمده از مدل‌سازی توسط شبکه‌های مختلف با یکدیگر مقایسه شدند.

مواد و روش‌ها

مشخصات مناطق و نمونه‌های خاک: برای انجام این پژوهش، ۱۲۲ نمونه خاک سطحی دست‌خورده و دست‌نخورده (۳۰-۰ سانتی‌متر) از مناطق آمل- بابل (۱۸ نمونه)، کرج (۳۲ نمونه) و بجنورد (۷۲ نمونه) انتخاب شد (خشنودی، ۱۹۹۱؛ عربی، ۲۰۰۴). جدول ۱ و شکل ۱ به‌ترتیب مشخصات فیزیکی خاک‌های مورد مطالعه و پراکنش بافت خاکی آن‌ها را نشان می‌دهند. نگاهی اجمالی به جدول ۱ و شکل ۱ نشان می‌دهد که میزان کربن آلی از مقادیر کم تا به‌نسبت زیاد متغیر است و پراکنش بافت خاکی نمونه‌های بجنورد بسیار بیش‌تر از دو منطقه دیگر می‌باشد.



شکل ۱- پراکندگی بافت خاک در نمونه‌های ایرانی.

جدول ۱ - مشخصات فیزیکی خاک‌های مورد استفاده در این پژوهش.

عوامل*	داده‌های آمی و بابل (تعداد نمونه خاک: ۱۸)				داده‌های کرج (تعداد نمونه خاک: ۳۲)			
	CV	SD	Med	Max	CV	SD	Med	Max
شن	۳۸/۴۵	۱۵/۱	۳۹/۲	۷۷/۲	۱۹/۸۱	۷/۹۷	۴۰/۲۲	۵۶/۸
سیلت	۱/۸۲	۱۱	۴۲/۱	۵۹/۶	۱۵/۱۱۲	۵/۱۳	۳۳/۹۵	۵۰
رس	۳۱/۸۱	۶/۵	۸۷/۱	۳۲/۲	۲۵/۴۶	۶/۵۹	۲۵/۸۹	۴۰/۸
کربن آلی	۴۴/۳۴	۸/۰	۶/۰	۴/۱	۳۶/۶	۰/۲۲	۰/۶۱	۰/۹۹
p _b	۲۰/۲	۳۰/۰	۳/۱	۱۵/۱	۳/۹	۰/۰۵۷	۱/۴۷	۱/۶۳
p _{۰.۵} **	-	-	-	-	۹/۵۱	۳/۸۷	۴۰/۷	۴۹/۱
p _{۰.۳} **	۵/۱۱	۴/۵	۲۰/۳۳	۲۸/۱	۱۲/۳۳	۳/۶۱	۲۹/۵۲	۳۵/۷
p _{۰.۱۰۰} **	۵/۵۱	۴/۱	۲۶/۵۵	۳۸/۳۳	۱۳/۰۴	۳/۱۰	۳۳/۱۷	۳۱/۳
p _{۰.۰۱۰} **	۲/۵۵	۲/۸	۲۲/۱	۲۷/۸۲	-	-	-	-
p _{۰.۰۰۵} **	-	-	-	-	۱۴/۹۸	۲/۷	۱۸/۰۵	۳۳/۹
p _{۰.۰۰۱} **	۶/۵۱	۳/۰	۱۶/۸۱	۷۰/۳۱	-	-	-	-
p _{۰.۰۰۰۵} **	۱/۹/۶۱	۲/۹	۱۴/۱۴	۳۵/۱۱	۲۶/۶۸	۴/۱۲	۱۵/۴۳	۳۰/۹

CV: ضریب تغییرات، SD: انحراف استاندارد، Max: بیش‌ترین، Min: کم‌ترین و Med: میانگین بر حسب درصد می‌باشد.

** منظور از p: میزان رطوبت خاک بر حسب مترمکعب بر سانتی‌متر مکعب می‌باشد. p_b: چگالی ظاهری خاک بر حسب گرم بر سانتی‌متر مکعب می‌باشد.

نمونه‌برداری‌ها برای ۵۰ نمونه خاک آمل- بابل و کرج در نیمه دوم فصل بهار و به‌صورت چهارگوشه‌بندی معمولی و با فاصله‌های یکسان انجام گرفت. نمونه‌های دست‌خورده خاک پس از خشک شدن در هوا و عبور از الک ۲ میلی‌متری برای انجام آزمایش‌ها آماده شد. بافت خاک به روش هیدرومتری و ماده آلی به روش اکسایشتر پس از حذف آهک و مواد آلی (USDA، ۱۹۸۲) تعیین گردید. مقادیر رطوبت وزنی خاک‌های دست‌نخورده با استفاده از صفحات فشاری و در ۳ تکرار در پتانسیل‌های ماتریک ۱۵۰۰، ۵۰۰، ۱۰۰، ۳۳- و ۵- کیلوپاسکال اندازه‌گیری شد. جرم مخصوص حقیقی همه خاک‌ها ۲/۶۵ گرم بر سانتی‌متر مکعب در نظر گرفته شد. نمونه‌برداری‌ها برای ۷۲ نمونه خاک بجنورد به‌صورت زیگزاگ انجام، و بافت خاک به روش هیدرومتری و با استفاده از دستگاه صفحات فشاری در ۳ تکرار و در مکش‌های ۱۵۰۰، ۱۰۰۰، ۷۰۰، ۴۰۰، ۱۰۰- و ۳۳- کیلوپاسکال میزان رطوبت تعیین شد (عربی، ۲۰۰۴). در تمامی نمونه‌ها میزان کربن آلی برابر ۵۸ درصد کل مواد آلی در نظر گرفته شد.

شبکه‌های عصبی مصنوعی: در این پژوهش برای اجرای مدل‌های شبکه عصبی از نرم‌افزار NeuroSolutions 5.7 استفاده شد. شبکه‌های پرسپترون، پیش‌خور تعمیم‌یافته، عصبی- فازی، عصبی- الگوریتم ژنتیک در این پژوهش استفاده شدند. تمامی نمونه‌های خاک برای استفاده ابتدا به‌وسیله رابطه ۱ نرمال شدند.

$$x_{\text{normal}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (1)$$

که در آن، x_{normal} : مقدار نرمال شده برای هر عامل، x : مقدار واقعی، x_{min} : مقدار کمینه و x_{max} : مقدار بیشینه می‌باشد. ورودی‌ها مقادیر رس، شن، سیلت، چگالی ظاهری و کربن آلی بودند که ترکیب‌های متفاوتی از آن‌ها مطابق با جدول ۲ مورد آزمون قرار گرفت. ۳ حالت کلی برای نرون‌های خروجی نیز به‌شرح زیر در نظر گرفته شد. شبکه‌هایی که در پتانسیل‌های مشخص به پیش‌بینی رطوبت می‌پرداختند در حقیقت توابعی نقطه‌ای^۱ بودند و به‌علت در نظر گرفتن تمامی ۱۲۲ نمونه با هم تنها دارای ۳ نرون خروجی در پتانسیل‌های مشترک در تمامی نمونه‌ها (۳۳-، ۱۰۰- و ۱۵۰۰- کیلوپاسکال) بودند. در حالت بعدی مقادیر مؤلفه‌های α ، n ، θ_s و θ_f در رابطه ونگنوختن (رابطه ۲) به‌عنوان خروجی‌های مدل‌سازی در نظر گرفته شدند که خود طی یک فرایند بهینه‌سازی توسط نرم‌افزار SOILPAR2.00 به‌دست آمده بودند.

1- Point PTFs

$$\theta(h) = \theta_r + \frac{\theta_s - \theta_r}{(1 + |\alpha h|^n)^m} \quad (2)$$

که در آن، θ_r و θ_s به ترتیب رطوبت باقی مانده و اشباع بر حسب مترمکعب بر مترمکعب، α : ضریب، n : فاکتور شکل، m : ثابت تجربی، h : پتانسیل بر حسب کیلوپاسکال و $\theta(h)$: رطوبت در پتانسیل مورد نظر می‌باشد. لازم به ذکر است که انتخاب نرم‌افزار SOILPAR2.00 برای بهینه‌سازی مؤلفه‌های معادله و نگونختن با توجه به بررسی‌های اولیه بود که نشان داد این مدل به خوبی توانایی بهینه‌سازی این مؤلفه‌ها را دارد. در این حالت تمامی پتانسیل‌های موجود مورد استفاده قرار گرفتند. در این حالت توابع به دست آمده توابع پارامتریک بوده و عملکردی پیوسته در تخمین رطوبت داشتند. در حالت سوم میزان مکش نیز علاوه بر ورودی‌های دیگر به عنوان نرون ورودی در نظر گرفته شد و به دنبال آن شبکه‌ها تنها دارای یک نرون خروجی رطوبت بودند. به علت توانایی ارزیابی عملکردی پیوسته همانند توابع پارامتریک و در عین حال استفاده نکردن از معادله‌های نگهداشت آب در خاک (هم‌چون رابطه و نگونختن) واژگان توابع شبه پارامتریک برای روش یاد شده انتخاب شد. در تمامی مدل‌ها داده‌ها پس از تصادفی کردن به ۳ قسمت آموزش (۷۰ درصد)، اعتبارسنجی متقاطع (۲۰ درصد) و آزمون (۱۰ درصد) تقسیم شدند.

جدول ۲- حالات مختلف نرون‌های ورودی استفاده شده در این پژوهش.

ترکیب	تابع	ورودی*
۱	شبه پارامتریک	SSC+h
۲	شبه پارامتریک	SSC+BD+h
۳	شبه پارامتریک	SSC+OC+h
۴	شبه پارامتریک	SSC+BD+OC+h
۵	نقطه‌ای / پارامتریک	SSC
۶	نقطه‌ای / پارامتریک	SSC+BD
۷	نقطه‌ای / پارامتریک	SSC+OC
۸	نقطه‌ای / پارامتریک	SSC+BD+OC

* SSC توزیع اندازه ذرات شامل درصد رس، سیلت و شن و بقیه نمایه‌های ورودی مشابه جدول ۱ می‌باشد.

شبکه‌های پرسپترون چندلایه: پرسپترون‌های چندلایه پرکاربردترین نوع شبکه‌های عصبی می‌باشند. برای انجام این پژوهش از پرسپترون‌های سه‌لایه استفاده شد. توابع فعالیت تانژانت هیپربولیک و سیگموئید در لایه میانی مورد استفاده قرار گرفتند و در تمامی حالات در لایه خروجی تابع انتقال خطی بود. الگوریتم‌های آموزش مورد استفاده لونیبرگ مارکوات و مومتم بودند.

شبکه‌های پیش‌خور تعمیم‌یافته: شبکه‌های پیش‌خور تعمیم‌یافته (GFF)¹ حالت خاصی از شبکه‌های چندلایه MLP می‌باشد که در آن ارتباطات می‌توانند از یک و یا چند لایه بپرند. شبکه‌های MLP بدون توجه به نوع مسأله، به تعداد سیکل‌های آموزشی و مدت زمان بیشتری نسبت به شبکه‌های GFF نیاز دارند (لفوبور، ۲۰۰۱). حالات در نظر گرفته شده برای توابع فعالیت و الگوریتم‌های آموزش در شبکه GFF شبیه به شبکه‌های MLP بود.

شبکه‌های عصبی - فازی: سیستم‌های هم‌زمان استنتاج فازی - عصبی (CANFIS)² ابتدا در سال ۱۹۹۳ توسط جنگ مطرح شدند (جنگ، ۱۹۹۳). مدل CANFIS به‌علت ترکیب ورودی‌های فازی با شبکه‌های عصبی توانایی حل سریع مسایل بسیار پیچیده را دارد (لفوبور، ۲۰۰۱). یک CANFIS شامل ۴ جزء اصلی فازی ساز، پایگاه قوانین فازی، مولد استنتاج فازی و غیرفازی ساز می‌باشد (چن و همکاران، ۲۰۰۳؛ تای و زانگ، ۲۰۰۰). فازی‌ساز، داده‌های واقعی را به فرم قابل قبول توابع عضویت فازی مبدل می‌کند، سپس خروجی‌های فازی ساز به‌عنوان ورودی‌های مولد استنتاج فازی مورد استفاده قرار می‌گیرند. معمول‌ترین نوع سیستم استنتاج فازی که قابلیت قرارگیری در یک شبکه تطبیقی را داراست سیستم فازی سوگنو می‌باشد که خروجی آن یک رابطه خطی است. در این پژوهش از توابع عضویت گوسی و زنگوله‌شکل و سیستم فازی سوگنو استفاده شد. تابع عضویت، مقدار فازی بودن یک مجموعه فازی را نشان می‌دهد. در این پژوهش تعداد توابع عضویت تخصیص‌یافته به هر ورودی شبکه در یک فرایند آزمون و خطا مشخص گردید. در لایه خروجی از الگوریتم‌های آموزش مومتم، کاهش گرادیان و استپ برای دست‌یابی به بهترین ساختار استفاده شد. در تمامی حالات در لایه خروجی تابع انتقال خطی بود.

شبکه‌های عصبی - الگوریتم ژنتیک: الگوریتم ژنتیک در سال ۱۹۶۰ میلادی توسط جان هالند پایه‌ریزی شد و در دهه ۱۹۶۰ توسط وی و همکارانش در دانشگاه میشیگان بسط و توسعه یافت (گولدرگ،

1- Generalized Feed Forward

2- Coactive Neuro-Fuzzy Inference Systems

۱۹۸۹). استفاده از الگوریتم ژنتیک در ساختار شبکه‌های عصبی برای بهینه‌سازی پارامترها می‌باشد. معمول‌ترین پارامترهایی که در فرایند آموزش توسط الگوریتم ژنتیک بهینه می‌شوند ورودی‌های شبکه، تعداد نرون‌های لایه مخفی و سرعت یادگیری می‌باشند. الگوریتم‌های ژنتیک عملگرهای جهش، تقاطع و گزینش را با هدف یافتن بهترین پاسخ برای یک مسأله تلفیق می‌نمایند. آن‌ها راه‌حل بهینه را تا دستیابی به معیار مطلوب تعریف شده برایشان ادامه می‌دهند. به دلیل این که شبکه‌های پرسپترون چندلایه بیش‌ترین کاربرد را در منابع داشته‌اند و مرسوم‌ترین ساختار شبکه‌های عصبی می‌باشند در این پژوهش برای سنجش کارایی یک GA-NN همان ساختار مورد استفاده MLPs مورد استفاده قرار گرفت با این تفاوت که بهینه‌سازی فرایندها و پارامترها با استفاده از الگوریتم ژنتیک صورت پذیرفت. برای رسیدن به این مقصود یک الگوریتم ژنتیک با ۵۰ کروموزوم در ۱۰۰ نسل در نظر گرفته شد.

معیارهای سنجش عملکرد: به منظور سنجش کارایی شبکه‌های مختلف از آماره‌های ضریب همبستگی (رابطه ۳)، ریشه میانگین مربعات خطا (رابطه ۴)، میانگین مربعات خطا نرمال شده (رابطه ۵) و میانگین خطای مطلق (رابطه ۶) استفاده شد.

$$R^r = 1 - \frac{\sum_{i=1}^n (M_i - E_i)}{\sum_{i=1}^n M_i^r - \frac{\sum_{i=1}^n E_i^r}{n}} \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - M_i)^r}{n}} \quad (4)$$

$$NMSE = \frac{\sum_{i=1}^n (E_i - M_i)^r}{\sum_{i=1}^n E_i M_i} \quad (5)$$

$$MAE = \sum_{i=1}^n \frac{|E_i - M_i|}{n} \quad (6)$$

که در آن‌ها، M : بیانگر مقادیر واقعی رطوبت، E : مقادیر تخمینی و n : تعداد نمونه‌های فاز آزمون می‌باشد. در تمامی حالات و مدل‌های مورد آزمون ابتدا نتایج نرمال شده به صورت مقادیر واقعی

درآمدند و سپس مورد سنجش قرار گرفتند. در توابع پارامتریک ملاک ارزش‌گذاری شبکه‌های مختلف مقادیر رطوبت بود که با استفاده از ضرایب برآورد شده معادله ونگنوختن برآورد شده بودند.

تحلیل حساسیت: از آنجایی که انتخاب نرون‌های ورودی در نتایج به‌دست آمده از مدل‌سازی اهمیت فراوان دارد و همچنین به‌منظور شناخت بهتر میزان تأثیر متغیرهای مختلف ورودی در نرون‌های خروجی تحلیل حساسیت بر روی بهترین مدل‌های موجود انجام پذیرفت. به این منظور پس از اتمام مدل‌سازی و مقایسه نتایج، بهترین مدل‌ها برای تمامی توابع (یعنی نقطه‌ای، پارامتریک و شبه‌پارامتریک) شناسایی شدند و پس از آن تحلیل حساسیت نرون‌های خروجی نسبت به تغییرات در نرون‌های ورودی توسط نرم‌افزار NeuroSolution انجام پذیرفت.

نتایج و بحث

مقایسه عملکرد شبکه‌های مختلف: نتایج به‌دست آمده از مدل‌سازی (جدول ۳ و شکل‌های ۲ و ۳) نشان می‌دهد که به‌طورکلی تمامی شبکه‌های عصبی در نظر گرفته شده در توابع انتقالی مختلف عملکرد قابل‌قبولی داشتند به‌طوری‌که میانگین کلی آماره‌های RMSE و R^2 به‌ترتیب برابر با ۰/۰۳۱۶ و ۰/۸۴۲ بود. میانگین نتایج به‌دست آمده از شبکه‌های مختلف بسیار به یکدیگر نزدیک بود. با این وجود بهترین نتایج کلی توسط مدل‌های MLPs با آماره‌های RMSE و R^2 به‌ترتیب برابر با ۰/۰۳۲ و ۰/۸۶ به‌دست می‌آید. بر خلاف پژوهش‌های اکبرزاده و همکاران (۲۰۰۹) و کیشی و اوزتورک (۲۰۰۷)، در این پژوهش مدل‌های Fuzzy-NN در مقایسه با شبکه‌های MLPs نتایج بهتری نداشتند. ضعیف‌تر بودن و در برخی مسایل نامطلوب بودن نتایج مدل‌های Fuzzy-NN در مقایسه با مدل‌های شبکه عصبی توسط ساهو و همکاران (۲۰۰۵) در پژوهشی دیگر گزارش گردید. لاً دلایل نتایج ضعیف‌تر مدل‌های Fuzzy-NN در این پژوهش مرتبط با توانایی نداشتن تعیین قوانین حاکم از داده‌های آزمایشی توسط سیستم استنتاج فازی می‌باشد. به‌عبارت بهتر توانایی شبکه‌های عصبی در کشف قوانین حاکم بر روابط میان خصوصیات هیدرولیکی خاک و خصوصیات پایه خاک بیش‌تر از سیستم‌های عصبی فازی می‌باشد. در پژوهش ساهو و همکاران (۲۰۰۵) به این نکته نیز اشاره شده است. به هر حال به‌دلیل این‌که این پژوهش، اولین کاربرد مدل‌های Fuzzy-NN در پیش‌بینی خصوصیات هیدرولیکی خاک می‌باشد امکان مقایسه نتایج با موارد مشابه وجود ندارد. به بیان دیگر چنین تفاوت‌هایی به ماهیت اطلاعات و اندرکنش آن‌ها مربوط می‌باشد. در کل می‌توان این گونه نتیجه

گرفت که با توجه به ماهیت موضوع مورد بررسی امکان برتری برای هر کدام از مدل‌ها وجود دارد. با توجه به بهبود نتایج شبکه‌های MLPs که از الگوریتم ژنتیک در ساختار خود استفاده می‌نمایند (مدل‌های GA-NN) نسبت به شبکه‌های MLPs معمول در توابع نقطه‌ای و شبه‌پارامتریک، به نظر می‌رسد استفاده از الگوریتم ژنتیک در ساختار شبکه‌های عصبی می‌تواند مفید باشد (برای مقایسه می‌توان به نتایج هسو و همکاران (۱۹۹۵) و زارع‌زاده‌مه‌ریزی و بزرگ‌حداد (۲۰۰۸) مراجعه کرد). این بهبود از نظریه احتمالاً نتیجه این امر است که استفاده از الگوریتم ژنتیک در ساختار مدل‌های شبکه عصبی امکان توقف آموزش در یک کمینه محلی را کاهش می‌دهد.

جدول ۳- بهترین نتایج مدل‌سازی توسط شبکه‌های عصبی مصنوعی.

MAE	R ²	NMSE	RMSE	اجزاء شبکه ^{**}	نرون‌های ورودی ^{**}	نوع تابع	نوع شبکه [*]
۰/۰۱۶	۰/۹۲	۰/۰۰۷۳	۰/۰۲۱	LM-tanh	SSC-BD-OC	نقطه‌ای	MLPs
۰/۰۱۸	۰/۹۴	۰/۰۰۹۱	۰/۰۳۲	LM-tanh	SSC-BD-OC	شبه‌پارامتریک	MLPs
۰/۰۳۵	۰/۷۲	۰/۰۳۵	۰/۰۴۴	LM-sig	SSC-BD-OC	پارامتریک	MLPs
۰/۰۱۶	۰/۹۲	۰/۰۰۷۲	۰/۰۲۱	LM-sig	SSC-BD-OC	نقطه‌ای	GFF
۰/۰۱۷	۰/۹۴	۰/۰۰۸۲	۰/۰۲۲	LM-sig	SSC-OC	شبه‌پارامتریک	GFF
۰/۰۳۶	۰/۶۸	۰/۰۴۲	۰/۰۴۷	LM-tanh	SSC-BD-OC	پارامتریک	GFF
۰/۰۱۵	۰/۹۲	۰/۰۰۷۲	۰/۰۲۱	Mum-sig	SSC-BD-OC	نقطه‌ای	GA-NN
۰/۰۱۸	۰/۹۳	۰/۰۰۹۴	۰/۰۲۳	LM-tanh	SSC-BD-OC	شبه‌پارامتریک	GA-NN
۰/۰۳۹	۰/۶۳	۰/۰۴۶	۰/۰۰۵	Mum-tanh	SSC-BD-OC	پارامتریک	GA-NN
۰/۰۱۶	۰/۹۲	۰/۰۰۷۶	۰/۰۲۱	Gaus-Mum	SSC-BD-OC	نقطه‌ای	Fuzzy-NN
۰/۰۲۷	۰/۸۷	۰/۰۰۲	۰/۰۳۳	Bell-Cg	SSC	شبه‌پارامتریک	Fuzzy-NN
۰/۰۳۵	۰/۷۱	۰/۰۳۶	۰/۰۴۴	Bell-Cg	SSC-BD-OC	پارامتریک	Fuzzy-NN

* MLPs: شبکه‌های پرسپترون، GFF: پیش‌خور تعمیم‌یافته، GA-ANN: عصبی-ژنتیک و Fuzzy-NN: فازی-عصبی می‌باشد.

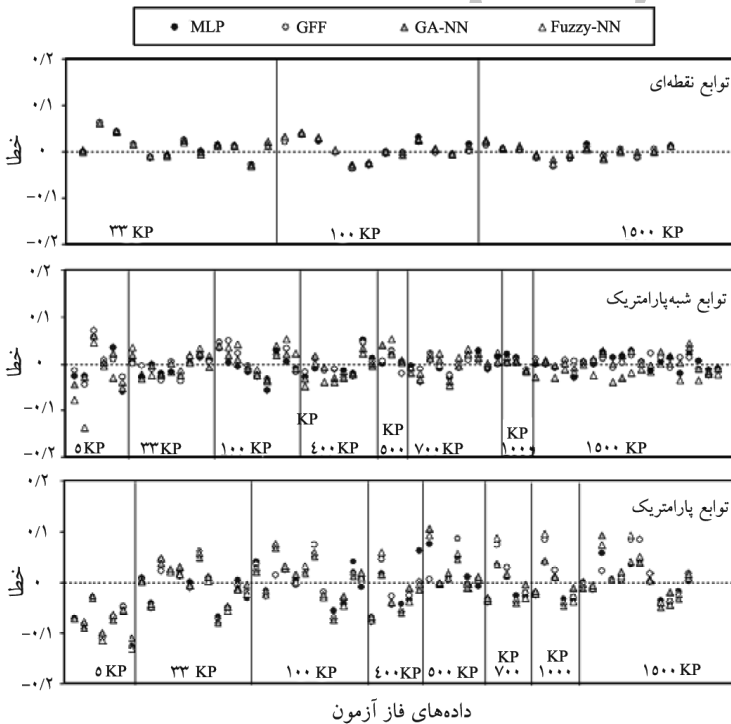
** OC: کربن آلی، BD: چگالی ظاهری و SSC: به ترتیب درصد‌های رس، سیلت و شن و خروجی‌های توابع مختلف مطابق با جدول ۲ می‌باشد.

*** LM: لونیبرگ مارکوات، tanh: تانزانت هیپربولیک، sig: سیگموئید، Mum: مومنتوم، Cg: کاهش گرایان، Gaus: گوسی و Bell: زنگوله‌ای می‌باشد. در تمامی شبکه‌های بهینه عصبی فازی ۳ تابع عضویت به هر ورودی تخصیص داده شده بود.

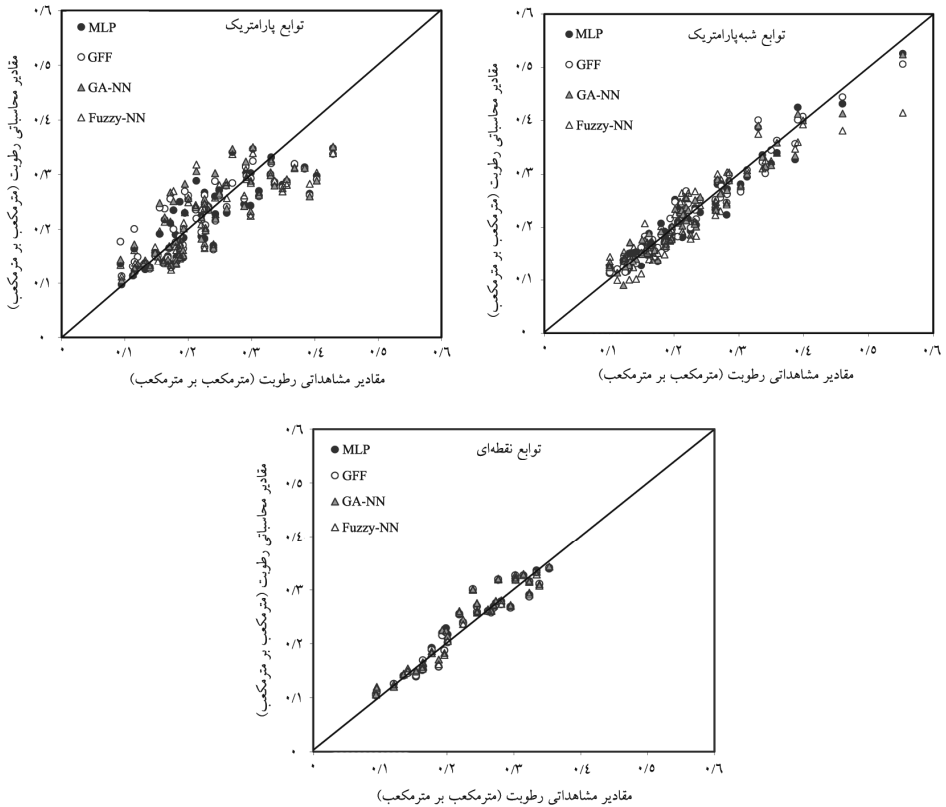
مقایسه عملکرد توابع شبه پارامتریک با توابع نقطه‌ای و پارامتریک: در توابع نقطه‌ای و شبه پارامتریک تمامی شبکه‌ها عملکردی بسیار خوب داشتند و نتایج هک تقریباً یکسان بوده با این حال نتایج مدل‌های Fuzzy-NN در توابع شبه پارامتریک با بقیه مدل‌ها تفاوت اندکی داشت و ضعیف‌تر بود. توابع پارامتریک نسبت به دیگر توابع نتایج ضعیف‌تری داشتند و در این میان بهترین نتایج توسط MLPs و Fuzzy-NN به دست آمد. با ملاک قرار دادن متوسط عملکرد تمامی شبکه‌های استفاده شده، بهترین نتایج مربوط به توابع نقطه‌ای با آماره‌های RMSE و R^2 به ترتیب برابر با ۰/۰۲۱ و ۰/۹۲، و ضعیف‌ترین نتایج مربوط به توابع پارامتریک با آماره‌های RMSE و R^2 به ترتیب برابر با ۰/۰۴۶ و ۰/۶۸ بود. اما بهترین نتایج به دست آمده مربوط به توابع شبه پارامتریک (شبکه‌های GFF) با آماره‌های RMSE و R^2 به ترتیب برابر با ۰/۰۲۲ و ۰/۹۴ و توابع نقطه‌ای (مدل‌های GA-NN) با آماره‌های RMSE و R^2 به ترتیب برابر با ۰/۰۲۱ و ۰/۹۲ و بود و توابع پارامتریک (مدل‌های MLPs) با آماره‌های RMSE و R^2 به ترتیب برابر با ۰/۰۴۴ و ۰/۷۲ ضعیف‌ترین نتایج را داشتند. شکل ۲ مقادیر خطا (تفاوت رطوبت اندازه‌گیری شده و رطوبت برآورد شده) و شکل ۳ پراکنش نتایج مدل‌سازی حول خط ۱:۱ را برای توابع پارامتریک، شبه پارامتریک و نقطه‌ای نشان می‌دهند. پراکنش خطا و نتایج مدل‌سازی در شکل‌های ۲ و ۳ به خوبی بیانگر بهبود مدل‌سازی در توابع شبه پارامتریک در مقایسه با توابع پارامتریک می‌باشد. همچنین در کل می‌توان گفت که با حرکت به سمت مکش‌های بالاتر در تمامی توابع، به خصوص شبه پارامتریک از میزان خطا کاسته می‌شود لکن این امر احتمالاً ناشی از تأثیر ساختمان خاک بر روی منحنی رطوبتی می‌باشد. بنابراین نتایج در توابع شبه پارامتریک پایدارتر هستند که برتری عمده‌ای به شمار می‌آید. در حالی که توابع پارامتریک از نوسانات شدیدی از یک نمونه به نمونه دیگر برخوردارند.

از طرفی انطباق بالای خطا در تمامی مدل‌های شبکه عصبی در توابع نقطه‌ای نشان می‌دهد که استفاده از الگوریتم ژنتیک و منطق فازی منجر به بهبود نتایج در این توابع نمی‌شود. همچنین نتایج نشان داد که عملکرد توابع پارامتریک نسبت به توابع نقطه‌ای ضعیف‌تر است. این نتیجه در پژوهش‌های دیگر نیز گزارش شده است (مردون و همکاران ۲۰۰۶) در پژوهشی نشان دادند

که روش‌های رگرسیونی و شبکه‌های عصبی در برآورد توابع انتقالی نقطه‌ای توانا تر از توابع پارامتریک هستند. با این وجود تخمین پیوسته رطوبت توسط توابع پارامتریک برتری بسیار مهمی است که توابع نقطه‌ای آن را دارا نمی‌باشند. با این حال جدول ۳ نشان می‌دهد که روش شبه پارامتریک به طور عمده بر روش نقطه‌ای برتری دارد. با توجه به نتایج قابل قبول توابع جدید طرح شده در این پژوهش با عنوان توابع شبه پارامتریک و همچنین توانایی تخمین پیوسته رطوبت در مکش‌های گوناگون به نظر می‌رسد این توابع به خوبی نقیصه یاد شده را حل می‌نمایند. اطمینان از کارایی این توابع در مکش‌هایی که در آن آموزش ندیده‌اند نیاز به پژوهشی دیگر دارد و خارج از این بحث است.



شکل ۲- نمایش خطا برای بهترین نتایج مدل‌سازی میزان رطوبت در توابع مختلف به تفکیک مکش (توابع پارامتریک در بالا، شبه پارامتریک در وسط و نقطه‌ای در پایین می‌باشند).




شکل ۳- پراکنش بهترین نتایج مدل‌سازی شبکه‌های عصبی برای توابع مختلف حول خط ۱:۱.

نتایج تحلیل حساسیت: نتایج تحلیل حساسیت برای توابع مختلف در شکل ۴ نشان داده شده است. در توابع نقطه‌ای درصد شن بیش‌ترین میزان تأثیر را در تمامی مؤلفه‌های خروجی شامل میزان رطوبت در مکش‌های ۳۳-، ۱۰۰- و ۱۵۰۰- کیلوپاسکال نشان داد. تأثیر نمایه کربن آلی از چگالی ظاهری در تمامی مکش‌ها بیش‌تر بود. در مکش ۳۳- کیلوپاسکال میزان شن موجود در نمونه مهم‌ترین نمایه مؤثر بود و در مکش‌های بالاتر از تأثیر نمایه کاسته شد و بر تأثیر میزان رس افزوده شد که این امر با اصول فیزیکی مسأله هم‌خوانی دارد.

به عبارت بهتر در مکش‌های بیش‌تر که آب در منافذ ریز خاک موجود می‌باشد میزان رس خاک تأثیر مهم‌تری بر میزان رطوبت دارد و به عکس در مکش‌های کم‌تر تأثیر میزان شن بیش‌تر می‌باشد. در توابع شبه پارامتریک مقدار مکش با اختلاف فاحشی بیش‌ترین تأثیر را بر رطوبت داشت که این امر

دور از انتظار نیست و در توابع پارامتریک میزان رس موجود در نمونه بر نمایه θ_r تأثیر بسیاری دارد که با مطالب ذکر شده برای توابع نقطه‌ای هم‌خوانی داشت. بررسی نمایه‌های ورودی نشان می‌دهد که در بیش‌تر حالات شبکه‌هایی که دارای ۵ نرون ورودی بودند بهترین عملکرد را داشته‌اند. بنابراین به‌نظر می‌رسد استفاده از بیش‌ترین مؤلفه‌های زودیاقت موجود سبب ارتقاء عملکرد شبکه‌های عصبی در برآورد رطوبت می‌شود. همچنین با توجه به تنوع بهترین اجزاء شبکه (الگوریتم‌های آموزش و توابع انتقال) به‌نظر می‌رسد باید تا حد امکان ترکیب‌های مختلف مورد آزمون قرار گیرند. بهبود نتایج به‌دست آمده با در نظر گرفتن متغیرهای کربن آلی و چگالی ظاهری به‌عنوان ورودی در پژوهش‌های انجام شده قبلی نیز گزارش شده است (کرن، ۱۹۹۵؛ راولز و همکاران، ۲۰۰۳).



شکل ۴- نتایج تحلیل حساسیت مدل‌های شبکه عصبی (توابع نقطه‌ای در بالا، شبه پارامتریک در وسط و پارامتریک در پایین) به نمایه‌های ورودی مختلف (درصد شن، سیلت، رس، چگالی ظاهری، درصد کربن آلی و میزان مکش). در توابع پارامتریک θ_r رطوبت باقی مانده، θ_s رطوبت اشباع و α و n عوامل معادله ونگنوختن (رابطه ۲) می‌باشند.

نتیجه‌گیری

نتایج این پژوهش نشان از توفیق نسبی مدل‌های شبکه عصبی در اشتقاق توابع انتقالی مختلف دارد. توابع شبه‌پارامتریک که برای اولین بار در این پژوهش معرفی می‌شوند، بهترین نتایج را نسبت به توابع نقطه‌ای و پارامتریک دارا بودند. با توجه به توانایی این توابع در مدل‌سازی پیوسته رطوبت و نتایج بسیار بهتر نسبت به توابع پارامتریک، به‌نظر می‌رسد این توابع می‌توانند جایگزین خوبی برای توابع پارامتریک باشند و به‌خوبی کاستی‌های آن توابع را بر طرف نمایند. همچنین با توجه به نتایج حاصل از مدل‌سازی می‌توان گفت استفاده از شبکه‌های عصبی - فازی منجر به بهبود نتایج به‌دست آمده از شبکه‌های پرسپترون نمی‌شود ولی استفاده از الگوریتم ژنتیک در ساختار شبکه‌های عصبی مصنوعی می‌تواند منجر به بهبود نتایج گردد. تحلیل حساسیت انجام شده بر روی توابع مختلف و همچنین نتایج بهینه مدل‌سازی مشخص می‌کند که استفاده از تمامی اطلاعات پایه خاک به‌عنوان نمایه ورودی برای مدل‌سازی بهترین نتایج را در پی دارد. همچنین تأثیر بسیار بالای میزان مکش به‌عنوان نمایه ورودی در توابع شبه‌پارامتریک نسبت به دیگر مؤلفه‌های ورودی اثبات می‌کند که در نظر گرفتن مکش به‌عنوان متغیری مستقل برای اشتقاق توابع انتقالی هیدرولیک خاک منجر به نتایج بسیار درخشان توابع شبه‌پارامتریک شده است.

منابع

1. Arabi, Z. 2004. Prediction of soil moisture curve using particle size distribution. MSc Thesis. Azad University. Science and Research Unit. (In Persian)
2. Akbarzadeh, A., Taghizadeh Mehrjardi, R., Rahimi Lake, H., and Ramezanzpour, H. 2009. Application of Artificial Intelligence in modeling of soil properties (Case study: Roodbar Region, North of Iran). Environ. Res. J. 3: 2. 19-24.
3. Chen, W.C., Chang, N.B., and Shieh, W.K. 2001. Advanced Hybrid Fuzzy-Neural Controller for industrial wastewater treatment. J. Environ. Engin. 127: 11. 1048-1059.
4. Chen, W.C., Chang, N., and Chen, J. 2003. Rough set-based hybrid fuzzy-neural controller design for industrial wastewater treatment. Water Research. 37: 95-107.
5. Goldberg, D.E. 1989. Genetic algorithm in search, optimization and machine learning. Addison-wesley. Reading Mass, 399p.
6. 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.

7. 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.
8. Jang, J.S.R. 1993. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man Cybern.* 23: 3. 665-685.
9. Jurabian, M., and Hushmand, R. 2003. Fuzzy logic and Artificial Neural Networks, concepts and applications. Shahid chamran university publication. 300p. (In persian)
10. Kern, J.S. 1995. Evaluation of soil water retention models based on basic soil physical properties. *Soil Sci. Soc. Amer. J.* 59: 1134-1141.
11. Khoshnud Yazdi, A.A. 1991. Estimation of soil moisture curve using some physical characteristics in some soils of Iran. M.Sc. Thesis. Tehran university. Faculty of Agriculture, 144p. (In Persian)
12. Kişi, Ö., and Öztürk, Ö. 2007. Adaptive Neurofuzzy computing technique for evapotranspiration estimation. *J. Irrig. and Drain. Engin.* 133: 4. 368-379.
13. Lefebvre, C. 2001. NeuroSolutions online help. Download the latest release from: <http://www.neurosolutions.com/downloads/documentation.html>.
14. 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.
15. Minasny, B., McBratney, A.B., and Bristow, K.L. 1999. Comparison of different approaches to the development of pedotransfer functions for water-retention curves. *Geoderma*, 93: 3-4. 225-253.
16. Minasny, B., and McBratney, A.B. 2002. The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci. Soc. Amer. J.* 66: 352-361.
17. Prasad, R.K., and Mathur, S. 2007. Groundwater flow and contaminant transport simulation with imprecise parameters. *J. Irrig. and Drain. Engin.* 133: 1. 61-70.
18. Rahimi Lake, H., Akbarzadeh, A., and Taghizadeh Mehrjardi, R. 2009. Development of pedotransfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zones of the Caspian Sea. *J. Ecol. and the Natur. Environ.* 1: 7. 160-172.
19. Rawls, W.J., Pachepsky, Y.A., Ritchie, J.C., Sobecki, T.M., and Bloodworth, H. 2003. Effect of soil organic carbon on soil water retention. *Geoderma*, 116: 1-2. 61-76.
20. Sahoo, G.B., Ray, C., Wang, J.Z., Hubbs, S.A., Song, R., Jasperse, J., and Seymour, D. 2005. Use of artificial neural networks to evaluate the effectiveness of riverbank filtration. *Water Research*, 39: 2505-2516.

21. Tay, J., and Zhang, X. 2000. A fast predicting neural fuzzy model for high-rate anaerobic wastewater treatment systems. *Water Research*, 34: 11. 2849-2860.
22. U.S.D.A. 1982. Procedures for collecting soil samples and methods of analysis for soil survey. *Soil Survey Investigations.*, Report No.1.
23. Wosten, J.H.M., Pachepsky, Y.A.A., and Rawls, W.J. 2001. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics. *J. Hydrol.* 251: 123-150.
24. Zare zade Mehrizi, M., and Bozorg Hadad, A. 2008. Optimization of number of layers and neurons in artificial neural network with genetic algorithm method in flow prediction. 3rd conference of water resources management. Tabriz University. Faculty of civil engineering. Available in <http://www.civilica.com>. (In Persian)

Archive of SID



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 18(2), 2011
www.gau.ac.ir/journals

Comparison of different Artificial Intelligence methods in modeling water retention curve (Case study: North and Northeast of Iran)

**A. Haghverdi¹, *B. Ghahraman², M. Joleini³,
A.A. Khoshnud Yazdi⁴ and Z. Arabi⁵**

¹Ph.D. Student, Dept. of Water Engineering, Ferdowsi University of Mashhad, Iran,

²Professor, Dept. of Water Engineering, Ferdowsi University of Mashhad, Iran,

³Research Assistant Prof., Agricultural Research Center of Khorasan, Iran,

⁴Lecturer, Shirvan College of Agriculture, Ferdowsi University of Mashhad, Iran,

⁵M.Sc. of Pedology

Received: 2010/03/13; Accepted: 2011/01/16

Abstract

Soil moisture in different potentials is one of the most important input parameters in majority of models, which related to agriculture, water and soil sciences. Pedotransfer functions (PTFs) predict the less readily properties using easily collected soil parameters; so they have these advantages to be inexpensive and easy deriving. Two important targets were designed in this paper. First target is performance evaluation of Fuzzy Neural Networks (Fuzzy-NN) and Genetic Algorithm Neural Network (GA-NN) in comparison routine neural networks such as Multilayer Perceptrons (MLPs) in predicting moisture in predefined potential points. The second target is introducing and evaluating a new PTF, pseudo parametric and comparing its performance in modeling water retention curve with point and parametric PTFs. For achieving these targets, 122 soil samples from north and northeast of Iran in variety of soil textures, such as loam, clay, clay loam and sandy loam were selected and modeling results from different networks were compared. Results showed that in general the performance of all structures of neural networks was acceptable, so that the average of R^2 and RMSE statistics were 0.0316 and 0.842 respectively. The best and worse results belonged to pseudo parametric (with $R^2=0.92$ and $RMSE=0.022$) and Parametric PTFs (with $R^2=0.72$ and $RMSE=0.044$), respectively. In addition, according to results we can say using Fuzzy-NN could not improve the performance of MLPs but GA-NN could.

Keywords: Pedotransfer functions, GA-NN, Fuzzy-NN, Water retention curve

* Corresponding Author; Email: bijangh@ferdowsi.um.ac.ir