

مدل سازی منحنی مشخصه رطوبتی برخی خاک‌های ایران با استفاده از توابع انتقالی شبه پارامتریک شبکه عصبی

امیر حق وردی

دانشجوی دکتری علوم و مهندسی آبیاری، دانشکده کشاورزی، دانشگاه فردوسی مشهد (نویسنده مسئول)

بیژن قهرمان

استاد دانشکده کشاورزی، دانشگاه فردوسی مشهد

محمد جلینی

استادیار پژوهش، مرکز تحقیقات کشاورزی خراسان رضوی

علی اصغر خشنود یزدی

مری آموزشی دانشکده کشاورزی، دانشگاه فردوسی مشهد

زهرا عربی

کارشناس ارشد خاکشناسی، دستیار تحقیق

برگرفته از پژوهشی مستقل از پایان نامه و طرح تحقیقاتی.

تاریخ پذیرش: ۸۹/۶/۱۷

تاریخ دریافت: ۸۹/۴/۱۹

چکیده

مدل سازی جریان آب و انتقال املاح در منطقه غیر اشباع نیازمند آگاهی از خصوصیات هیدرولیک خاک از جمله منحنی نگهداشت آب است. تخمین غیر مستقیم این توابع با استفاده از خصوصیات پایه خاک در قالب توابع انتقالی توجه کارشناسان رشته‌های مختلفی را به خود جلب کرده است. امروزه، استفاده از مدل‌های شبکه‌های عصبی برای اشتقاق توابع انتقالی بسیار معمول است. در این پژوهش، توابع جدید شبه پارامتریک شبکه عصبی معرفی و ارزیابی شد و عملکرد آن‌ها با توابع مرسوم نقطه‌ای و پارامتریک مقایسه شد. همچنین، تاثیر دو روش متفاوت آموزش مستقیم و غیر مستقیم مورد ارزیابی قرار گرفت. تمامی تحلیل‌ها بر روی ۱۲۲ نمونه خاک از شمال و شمال شرق ایران (آمل و بابل، کرج و بجنورد) انجام شد که به صورت تصادفی انتخاب شده بودند. به طور کلی، نتایج توابع پارامتریک نسبت به نقطه‌ای بهتر بودند، به طوری که میانگین نمایه‌های r و RMSE در توابع پارامتریک به ترتیب ۰/۹۳ و ۰/۰۳۲ و در توابع نقطه‌ای به ترتیب ۰/۷۶ و ۰/۰۳۴ می‌باشد. از طرف دیگر، توابع شبه پارامتریک توانستند با استفاده از اطلاعاتی مشابه برای آموزش، نتایج توابع نقطه‌ای را بهبود بخشند. میانگین نمایه‌های r و RMSE در توابع شبه پارامتریک به ترتیب برابر با ۰/۹۵ و ۰/۰۲۶ بود. به نظر می‌رسد افزایش نمونه‌ها در فاز آزمایش و انتخاب پتانسیل ماتریک به عنوان ورودی، مهم‌ترین دلایل موفقیت توابع شبه پارامتریک باشد. همچنین نتایج نشان دادند که اشتقاق توابع انتقالی با داده‌های محلی (آموزش مستقیم) نتایج بهتری نسبت به اشتقاق داده‌ها با استفاده از پایگاه داده‌های جهانی (آموزش غیر مستقیم) دارد.

کلمات کلیدی: آموزش مستقیم، آموزش غیر مستقیم، توابع انتقالی، توابع شبه پارامتریک، منحنی نگهداشت آب.

مقدمه

اگر چه خصوصیات هیدرولیکی خاک هم اکنون جزو مهم‌ترین عوامل مورد استفاده در تحقیقات کشاورزی، اکولوژیکی، طرح‌ها و مدل‌های آبیاری و زه‌کشی و مسایل مربوط به حرکت غیر اشباع آب در خاک هستند، اما به آسانی در دسترس نمی‌باشند (Minasny & McBratney, 2002a). زیرا اندازه‌گیری این نمایه‌ها هزینه‌بر، زمان‌بر و نیازمند کار زیاد می‌باشد. بنابراین، مدل‌ها و روابطی تحت عنوان توابع انتقالی توسعه یافته‌اند که خصوصیات هیدرولیکی خاک را با استفاده از داده‌های زود یافت خاک و با کمک یک رابطه ریاضی مناسب پیش‌بینی کنند (Cornelis et al., 2001). گام معمول در اشتقاق توابع انتقالی، ارائه روابطی تجربی میان خصوصیات پایه خاک و عواملی است که باید پیش‌بینی شوند. این امر می‌تواند به وسیله روش‌های مختلف ریاضی همچون رگرسیون‌های چندگانه خطی (Woosten et al., 1995; Rawls et al., 2001) و شبکه‌های عصبی (Merdun et al., 2006; Baker & Ellison, 2008) محقق شود. بیشتر تحقیق‌های انجام شده، شبکه‌های عصبی را توانمندتر از روش‌های رگرسیونی دانسته‌اند (Schaap et al., 1998). این مطلب خصوصاً هنگامی صادق است که تعداد نرون‌های ورودی بیشتر از سه و عدم قطعیت‌ها در کیفیت داده‌ها کوچک باشد (Baker & Ellison, 2008).

اما در این میان، با توجه به پیشرفت‌های صورت گرفته در چند سال اخیر در زمینه کاربرد شبکه‌های عصبی در تعیین خصوصیات هیدرولیکی خاک‌ها و پژوهش‌های انجام شده، نکات و مسائل جدیدتری در باب کارایی این مدل‌ها مطرح می‌باشد. لذا، انجام تحقیقاتی تازه که اصول و چالش‌های جدید مطروحه را در ارتباط با استفاده از این ابزار در بخش‌های مختلف علوم مرتبط با آب و خاک در نظر بگیرد، بسیار ضروری می‌نماید. به عنوان نمونه، هر چند شبکه‌های عصبی در بسیاری از موارد نتایج قابل قبولی را ارائه می‌کنند، لیکن این مدل‌ها پیش‌بینی کننده‌های ناپایداری بوده و تغییرات اندک در داده‌های آموزش، ممکن است مدل‌های بسیار متفاوتی ایجاد کند که نهایتاً نتایج متفاوتی در عملکرد مدل در پیش‌بینی به وجود خواهد آمد (Carney &)

(Cunningham, 1999). لذا، می‌توان چنین عنوان نمود که کیفیت و نوع داده‌های مورد استفاده برای اشتقاق توابع انتقالی خصوصاً در هنگام استفاده از شبکه‌های عصبی اهمیت ویژه‌ای دارد. تعداد زیادی از کشورها و مناطق در دنیا، مقدار کافی داده هیدرولیکی خاک برای اهداف مدل سازی کشاورزی و یا برای توسعه توابع انتقالی در اختیار ندارند. بنابراین، بیش‌تر تحقیقات در این کشورها در یک مقیاس منطقه‌ای انجام می‌شود (Nemes et al., 2003). با توجه به این مطلب که خصوصیات جغرافیایی و منطقه‌ای تنوع‌های گوناگونی را در خاک‌ها پدید می‌آورد، اعتمادپذیر بودن توابع انتقالی رابطه‌ای بسیار قوی با مجموعه داده‌هایی دارد که برای واسنجی آن‌ها به کار می‌رود (Ungaro et al., 2007). لذا، خصوصاً در هنگامی که از شبکه‌های عصبی استفاده می‌شود، بررسی کارایی شبکه آموزش داده شده با پایگاه‌های داده عظیم موجود، برای نمونه‌های خاک محلی بسیار مهم می‌باشد. به طوری که حتی ممکن است نتایج ضعیفی از اجرای شبکه‌های عصبی بدست آید. از طرفی، به علت این‌که به طور ماهوی شبکه‌های عصبی نیازمند تعداد داده‌های زیادی برای آموزش می‌باشند، کاربرد آن‌ها در مقیاس‌های کوچک و سطح مزرعه صرفاً با استفاده از داده‌های موجود محل سوال می‌باشد.

شاپ و لچی (Schaap & Leij, 1998a) مدل‌های شبکه عصبی را برای سه پایگاه داده مختلف مورد ارزیابی قرار دادند. آن‌ها متوجه شدند که توابع انتقالی اشتقاقی از یک پایگاه داده تخمین‌های متفاوتی برای دو پایگاه دیگر می‌دهد. اما وقتی که توابع از تمامی داده‌های موجود منتج شوند، تخمین‌ها بهبود می‌یابد. آن‌ها همچنین نتیجه گرفتند که عملکرد توابع انتقالی وابسته به مجموعه داده‌های مورد استفاده برای ارزیابی و اشتقاق می‌باشد و منبع، اندازه و دیگر خصوصیات داده‌ها می‌تواند بر عملکرد توابع موثر باشد. همچنین نمس و همکاران (Nemes et al., 2003) عنوان نمودند که اشتقاق توابع انتقالی با استفاده از داده‌های کم ولی مناسب، بهتر از استفاده از پایگاه داده‌های بزرگتر ولی عمومی و نامناسب می‌باشد.

توابع انتقالی شبکه عصبی شبیه ساز خصوصیات میزان رطوبت و منحنی نگهداشت آب خاک به دو دسته کلی توابع نقطه‌ای و پارامتریک تقسیم بندی می‌شوند. توابع

و نگونختن بهبود می‌بخشد، لزوماً عملکرد بهتری در پیش بینی رطوبت ندارد (Minasny & McBratney, 2002a; Minasny & McBratney, 2002b; Schaap & Leij, 1998b).

میناسنی و مک برانتی (Minasny & McBratney, 2002a) برای حل مشکلات مطروحه فوق الگوریتم جدیدی را برای توابع پارامتریک عصبی ارائه نمودند که بر مبنای حداقل سازی تفاوت رطوبت پیش بینی شده با استفاده از ضرایب بهینه معادله و نگونختن و میزان رطوبت اندازه‌گیری شده عمل می‌نماید. آن‌ها عنوان نمودند که الگوریتم فوق عملکردی قابل قبول و بهتر از توابع پارامتریک شبکه عصبی پیشین دارد. با توجه به مطالب فوق، می‌توان چنین عنوان نمود که تلاش برای ارائه نوعی از توابع انتقالی که عملکردی پیوسته در برآورد رطوبت داشته باشند و در عین حال مشکلات توابع پارامتریک را نداشته باشند، یکی از مهمترین موضوعات تحقیقات در سالیان اخیر بوده است. در این پژوهش برای نخستین بار مفهوم جدید توابع انتقالی شبه پارامتریک عصبی مطرح شده است که علاوه بر عملکردی پیوسته همانند توابع پارامتریک نیازی به استفاده از معادلات نگهداشت آب خاک (همانند معادله و نگونختن) ندارد و لذا اشکالات عمده مطرح شده به آن وارد نمی‌باشد. اساس کار این تابع جدید برآورد فرم تغییرات منحنی نگهداشت رطوبتی با استفاده از هوش مصنوعی می‌باشد.

با توجه به مطالب مطرح شده فوق پژوهش حاضر به طور مشخص دو هدف عمده زیر را دنبال می‌کند. الف: معرفی و اعتبار سنجی توابع شبه پارامتریک شبکه عصبی و مقایسه عملکرد این توابع با توابع نقطه‌ای و پارامتریک مرسوم. ب: برآورد عملکرد توابع انتقالی شبکه عصبی به منظور پیش‌بینی میزان رطوبت در نقاط پتانسیلی مختلف و منحنی نگهداشت آب خاک تحت دو شیوه متفاوت آموزش مستقیم و غیر مستقیم.

مواد و روش‌ها

نمونه‌های خاک مورد استفاده

۱۲۲ نمونه خاک برای انجام این تحقیق از مناطق آمل- بابل (۱۸ نمونه)، کرج (۳۲ نمونه) و بجنورد (۷۲ نمونه) انتخاب شد (جدول ۱). از اراضی مختلف مناطق

نقطه‌ای میزان رطوبت را در نقاط پتانسیلی خاصی برآورد می‌کنند. مهم‌ترین عیب این دسته از توابع، عدم توانایی ارائه عملکردی پیوسته می‌باشد. به عبارت بهتر، این توابع قادر به شبیه‌سازی یکپارچه منحنی نگهداشت رطوبتی نمی‌باشند. در مقابل، توابع انتقالی پارامتریک قادر به شبیه‌سازی پیوسته منحنی نگهداشت رطوبتی می‌باشند. در واقع این توابع عوامل معادلات نگهداشت آب خاکی نظیر و نگونختن را شبیه‌سازی می‌نمایند و کاربر با داشتن این عوامل برای هر نمونه خاک می‌تواند در هر پتانسیل دلخواه میزان رطوبت را برآورد نماید.

مولفین بسیاری گزارش‌هایی را مبنی بر وجود مشکلات در هنگام تلاش برای ربط دادن عوامل معادلات نگهداشت آب خاک به خصوصیات پایه خاک ارائه کرده‌اند (Minasny & McBratney, 2002a; Minasny & McBratney, 2002b). به عنوان مثال، عوامل تخمینی معادلات ممکن است خطاها را انتقال دهند. یکی از دلایل مهم این است که مدل‌ها همیشه برازش دهنده‌های خوبی برای داده‌ها نیستند و مثلاً در معادله و نگونختن باید با استفاده از تعداد محدودی داده نگهداشت آب خاک تعداد زیادی پارامتر برآورد شود. از این رو پارامترهای برازش داده شده ممکن است خطاها را انتقال دهند در حالی که توجه فیزیکی معنی‌داری در میان نباشد. علاوه بر این، روش معمول ارائه توابع انتقالی پارامتریک بوسیله شبکه‌های عصبی که بر اساس آموزش برای تخمین پارامترهای معادله و نگونختن است، نقائص زیر را در بر دارد. اولاً معادله و نگونختن لزوماً بر داده‌های اندازه‌گیری شده منطبق نمی‌شود، از این رو تضمینی وجود ندارد که شبکه عصبی بهینه شده تخمین‌های خوبی ارائه دهد، ثانیاً هنگامی که معادله و نگونختن برای داده‌های نگهداشت آب خاک برازش داده می‌شود، تفاوت میان مقادیر پیش‌بینی شده و اندازه‌گیری شده رطوبت حداقل می‌گردد. در حالی که شبکه‌های عصبی آموزش داده می‌شود تا تفاوت میان مقادیر پیش‌بینی شده و تخمین زده شده پارامترهای معادله و نگونختن را حداقل کند و بدیهی است که دستیابی به تخمین‌هایی خوب از پارامترهای معادله و نگونختن صرفاً به معنی دستیابی به تخمین‌های قابل قبولی از میزان رطوبت نمی‌باشد. بنابراین، یک تابع انتقالی که پیش‌بینی‌ها را برای یکی از پارامترهای معادله

متر مکعب در نظر گرفته شد. علاوه بر این، ۷۲ سری داده نیز از شمال شرق کشور (بجنورد) مورد استفاده قرار گرفت. نمونه برداری‌ها به صورت زیگزاگ انجام شد و میزان رطوبت با استفاده از دستگاه صفحات فشاری در سه تکرار و در مکش‌های ۱۵۰۰، ۱۰۰۰، ۷۰۰، ۴۰۰، ۱۰۰ و ۳۳- کیلو پاسکال تعیین شد. میزان کربن آلی در مناطق آمل- بابل و کرج برابر ۵۸٪ کل مواد آلی در نظر گرفته شد. مشخصات فیزیکی خاک‌های مورد استفاده در این پژوهش در جدول (۱) به اختصار ارائه شده است.

آمل- بابل و کرج ۵۰ نمونه خاک دست نخورده و دست خورده سطحی (۳۰-۰ سانتی‌متر) انتخاب شد. نمونه برداری‌ها در نیمه دوم فصل بهار و به صورت چهارگوشه بندی معمولی و با فواصل یکسان انجام گرفت. نمونه‌های دست خورده خاک پس از خشک شدن در هوا و عبور از الک دو میلی‌متری برای انجام آزمایش‌ها آماده شد. مقادیر رطوبت وزنی خاک‌های دست نخورده در پتانسیل‌های ماتریک ۱۵۰۰، ۵۰۰، ۱۰۰، ۳۳- و ۵- کیلوپاسکال با استفاده از صفحات فشاری در سه تکرار اندازه‌گیری شد. جرم مخصوص حقیقی کلیه خاک‌ها ۲/۶۵ گرم بر سانتی-

جدول (۱): مشخصات فیزیکی خاک‌های مورد استفاده در این پژوهش (Arabi, 2004; Khoshnud Yazdi, 1991)

داده‌های بجنورد (n=۷۲)					داده‌های آمل- بابل (n=۱۸)					داده‌های کرج (n=۳۲)					عوامل*
CV	SD	Med	Min	Max	CV	SD	Med	Min	Max	CV	SD	Med	Min	Max	
۳۸/۴۵	۱۵/۱	۳۹/۲	۱۰/۲	۷۷/۲	۲۷/۲۱	۹/۳۳	۳۴/۳۲	۱۴/۸	۵۰	۱۹/۸۱	۷/۹۷	۴۰/۲۲	۲۲	۵۶/۸	شن
۲۶/۱	۱۱	۴۲/۱	۱۴/۶	۵۹/۶	۱۷/۶۴	۶/۱۳	۳۴/۷۴	۲۷/۲	۵۲	۱۵/۱۲	۵/۱۳	۳۳/۹۵	۲۷/۴	۵۰	سیلت
۳۱/۸۱	۵/۹	۱۸/۷	۸/۲	۳۲/۲	۲۸/۶۳	۸/۶۸	۳۰/۳۳	۱۸	۵۶	۲۵/۴۶	۶/۵۹	۲۵/۸۹	۱۴	۴۰/۸	رس
۴۴/۳۴	۰/۲۷	۰/۶	۰/۱۲	۱/۴	۲۶/۹	۰/۳۳	۱/۲۴	۰/۶۸	۱/۸۴	۳۶/۶	۰/۲۲	۰/۶۱	۰/۱۹۷	۰/۹۹	کربن آلی
۲/۰۲	۰/۰۳	۱/۴۲	۱/۳۷	۱/۵۱	۲/۶۹	۰/۰۴	۱/۴۷	۱/۳۹	۱/۵۳	۳/۹	۰/۰۵۷	۱/۴۷	۱/۳۷	۱/۶۳	BD
-	-	-	-	-	۱۰/۳۴	۶/۴۵	۶۲/۲۴	۵۴/۹	۷۸/۵	۹/۲۹	۵/۰۷	۵۴/۶۲	۴۶/۶	۶۶/۳	θ [*]
-	-	-	-	-	۹/۷۲	۴/۲۵	۴۳/۹۷	۳۸/۱	۵۵/۳	۹/۵۱	۳/۸۷	۴۰/۷	۳۳	۴۹/۱	θ _{-۵}
۱۵/۱۵	۴/۵۹	۳۰/۳۳	۲۲/۲	۳۸/۱	۱۲/۲۴	۴/۱۴	۳۳/۱۵	۲۵/۲	۳۹/۷	۱۲/۲۳	۳/۶۱	۲۹/۵۲	۲۰	۳۵/۷	θ _{-۳۳}
۱۵/۵۶	۴/۱۳	۲۶/۵۵	۱۹/۲	۳۶/۲۳	۱۳/۴۱	۳/۶۹	۲۷/۴۲	۲۲/۳	۳۵/۱	۱۳/۰۴	۳/۱۰	۲۳/۸۱	۱۶/۳	۳۱/۳	θ _{-۱۰۰}
۱۲/۵۵	۲/۷۹	۲۲/۱۹	۱۶	۲۷/۸۲	-	-	-	-	-	-	-	-	-	-	θ _{-۴۰۰}
-	-	-	-	-	۱۴/۱۳	۳/۰۱	۲۰/۸۲	۱۵/۲	۲۷/۶	۱۴/۹۸	۲/۷	۱۸/۰۵	۱۱/۵	۲۳/۹	θ _{-۵۰۰}
۱۷/۵۹	۳/۰۳	۱۷/۲۱	۱۱/۸	۲۳/۰۸	-	-	-	-	-	-	-	-	-	-	θ _{-۷۰۰}
۱۹/۱۲	۳	۱۵/۶۹	۹/۵۵	۲۱/۵۴	-	-	-	-	-	-	-	-	-	-	θ _{-۱۰۰۰}
۱۹/۸۴	۲/۹	۱۴/۶۴	۸/۳۸	۲۰/۰۸	۱۵/۹۴	۳/۰۳	۱۸/۵۵	۱۴/۸	۲۶/۹	۲۶/۶۸	۴/۱۲	۱۵/۴۳	۹/۳	۳۰/۹	θ _{-۱۵۰۰}

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

** θ_{-h} میزان رطوبت خاک در پتانسیل h- کیلو پاسکال و BD چگالی ظاهری خاک بر حسب گرم بر سانتی متر مکعب می‌باشد.

*** n تعداد نمونه‌های مورد استفاده در هر منطقه می‌باشد.

پاسکال و برای بجنورد میزان رطوبت در پتانسیل‌های ۳۳-، ۱۰۰، ۴۰۰، ۷۰۰، ۱۰۰۰، ۱۵۰۰- کیلو پاسکال در نظر گرفته شد. در حالتی که برای تمامی نمونه‌ها به صورت همزمان مدل‌سازی صورت پذیرفت خروجی مدل‌ها محدود به میزان رطوبت در نقاط پتانسیلی مشترک در هر سه منطقه بود (۳۳-، ۱۰۰- و ۱۵۰۰ کیلو پاسکال). انتخاب عوامل ورودی با توجه به فراهمی اطلاعات و نتایج تحقیقات موجود در منابع صورت پذیرفت (Baker & Ellison, 2008; Sharma et al., 2006; Nemes)

توابع انتقالی

توابع نقطه‌ای و شبه پارامتریک شبکه عصبی

در توابع انتقالی نقطه‌ای شبکه عصبی، میزان رطوبت در پتانسیل‌های ماتریک مشخص به عنوان خروجی مدل- سازی و خصوصیات پایه خاک به عنوان مولفه‌های ورودی در نظر گرفته می‌شود. با توجه به اطلاعات موجود (جدول ۱) خروجی‌های توابع انتقالی نقطه‌ای برای نمونه خاک‌های آمل- بابل و کرج میزان رطوبت در پتانسیل‌های ۵-، ۳۳-، ۱۰۰-، ۵۰۰- و ۱۵۰۰- کیلو

که در آن: x ورودی در فرایند آموزش و $\hat{f}^b(x)$ مدل برازش داده شده توسط هر کدام از B مجموعه داده‌ای است که طی یک فرایند تصادفی انتخاب و با جایگزینی از مجموعه داده‌های اصلی منتج شده‌اند و $\hat{f}_{bag}(x)$ عملکرد کلی یا میانگین مجموعه داده‌های آموزش داده شده می‌باشد. در این پژوهش، برای آموزش توابع نقطه‌ای و شبه پارامتریک از الگوریتم کوچکترین مربعات غیرخطی انطباقی^۱ استفاده شد. هدف از به کارگیری این الگوریتم، حداقل کردن مجموع مربعات باقیمانده بین مقادیر اندازه گیری شده و پیش‌بینی شده با استفاده از رابطه (۲) می‌باشد.

$$O(W, U) = \sum_{i=1}^{N_s} \sum_{k=1}^{N_0} (\hat{P}_{ik}(x_i) - P_{ik})^2 \quad (2)$$

که در آن: N_s تعداد نمونه‌ها، N_0 تعداد خروجی‌ها، W و U وزن‌های لایه میانی و خروجی، P خروجی‌های اندازه‌گیری شده و $\hat{P}(x)$ خروجی‌های پیش‌بینی شده برای ورودی‌های x می‌باشد. در تمامی توابع نقطه‌ای و شبه پارامتریک مورد بررسی تعداد خود راه‌اندازها (نمایه B در فرمول (۱) ۵۰ و تعداد تکرارها ۱۰۰ در نظر گرفته شد. برای اجرای این توابع از نرم افزار NeuroPath استفاده شد.

جدول (۲): حالات مختلف نرون‌های ورودی و خروجی در نرم افزارهای NeuroPath و Neuroman

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 مابقی نمایه‌های ورودی مشابه جدول (۱) می‌باشد.

(et al., 2003). ترکیبات مختلف در نظر گرفته شده برای عوامل ورودی در جدول (۲) نشان داده شده است.

فرض اساسی توسعه توابع جدید شبه پارامتریک در این پژوهش توانایی شبکه‌های عصبی مصنوعی در تعیین فرم واقعی تغییرات رطوبت در پتانسیل‌های ماتریک متفاوت به صورت مستقل از معادلات نگهداشت آب خاک بوده است. برای نیل به این مقصود، ساختار متعارف شبکه‌های نقطه‌ای تغییر داده شد و پتانسیل ماتریک به عنوان یکی از عوامل ورودی در نظر گرفته شد. بنابراین، تمامی توابع شبه پارامتریک دارای یک خروجی رطوبت بودند که با توجه به میزان مکش در نظر گرفته شده در ورودی، متغیر می‌باشد. به علت توانایی ارائه عملکردی پیوسته همانند توابع پارامتریک و در عین حال عدم استفاده از معادلات نگهداشت آب در خاک (همچون رابطه ونگنوختن، واژگان توابع شبه پارامتریک برای روش مذکور انتخاب شد. ترکیبات مختلف نرون‌های ورودی برای توابع شبه پارامتریک در جدول (۲) موجود می‌باشد.

به منظور جلوگیری از توقف آموزش در کمینه‌های محلی و ارائه نتایج غیر پایدار از روش bagging برای آموزش شبکه‌های عصبی استفاده شد. به صورت تجربی اثبات شده است که دقت شبکه‌های عصبی مصنوعی می‌تواند با تولید چندین مدل و در نظر گرفتن مجموع آن‌ها برای تولید یک تخمین bagging و یا ترکیب نتایج با استفاده از روش Boosting افزایش پیدا کند (Parasuraman et al., 2006; Baker & Ellison, 2008). در این روش فرض می‌شود که مجموعه داده‌های آموزش بیانگر جمعیت کلی داده‌ها می‌باشد و گروه‌های چندگانه‌ای از جمعیت می‌تواند از یک مجموعه داده منفرد شبیه‌سازی شود. این امر با تکرار فرایند نمونه‌گیری و جایگزینی از مجموعه داده‌های اصلی با حجم N برای تعیین B مجموعه داده خود راه انداز و هر کدام با حجم N انجام می‌شود. هر مجموعه داده خود راه انداز شامل داده‌های متفاوتی می‌باشد و شبکه عصبی برای هر کدام از داده‌های خود راه انداز آموزش داده می‌شود. تخمین bagging از میانگین هر مدل بدست می‌آید (رابطه ۱):

$$\hat{f}_{bag}(x) = \frac{1}{B} \sum_{b=1}^B \hat{f}^b(x) \quad (1)$$

توابع پارامتریک عصبی مصنوعی

در بین معادلات موجود برای اشتقاق توابع پارامتریک خصوصیات هیدرولیک خاک بیشترین استفاده از معادله ونگنوختن برای ارائه توابع انتقالی پارامتریک می شود (رابطه ۳).

$$\theta(h) = \theta_r + \frac{\theta_s - \theta_r}{(1 + |\alpha h|^n)^m} \quad (3)$$

که در آن θ_r و θ_s به ترتیب رطوبت اشباع و باقیمانده بر حسب متر مکعب بر متر مکعب، α ضریب، n فاکتور شکل، m ثابت تجربی، h پتانسیل بر حسب کیلو پاسکال و $\theta(h)$ رطوبت در پتانسیل مورد نظر می باشد. در حقیقت در توابع پارامتریک شبکه عصبی مولفه های معادلات نگهداشت آب خاک (در این پژوهش معادله ونگنوختن) خروجی شبکه های عصبی و عوامل زود یافت خاک ورودی ها می باشند. بدیهی است که در یک فرایند ثانویه کاربر با استفاده از مولفه های پیش بینی شده (در این پژوهش عوامل α ، n ، θ_s و θ_r) می تواند تخمین پیوسته ای از میزان رطوبت در تمامی مکش ها داشته باشد.

در این پژوهش از تابع هدف جدید ارائه شده توسط مینسانی و مک برانتی (Minasny & McBratney, 2002a) برای مدل های شبکه عصبی استفاده شد که عوامل معادله ونگنوختن را پیش بینی کند، اما تفاوت میان رطوبت اندازه گیری شده و محاسبه شده از عوامل پیش بینی شده را حداقل کند. برای پیاده سازی تابع هدف فوق ابتدا پارامترهای معادله ونگنوختن (θ_s ، θ_r ، α ، n) برای تمامی نمونه های خاک با استفاده از نرم افزار Soilpar 2.00 در یک فرایند بهینه سازی معین شد. سپس آموزش شبکه های عصبی برای پیش بینی نمایه های مذکور با استفاده از اطلاعات خاک پایه با حداقل کردن رابطه (۱) آغاز و از وزن های حاصله به عنوان حدس های اولیه در آموزش ثانویه با هدف کمینه کردن معادله (۴) استفاده شد:

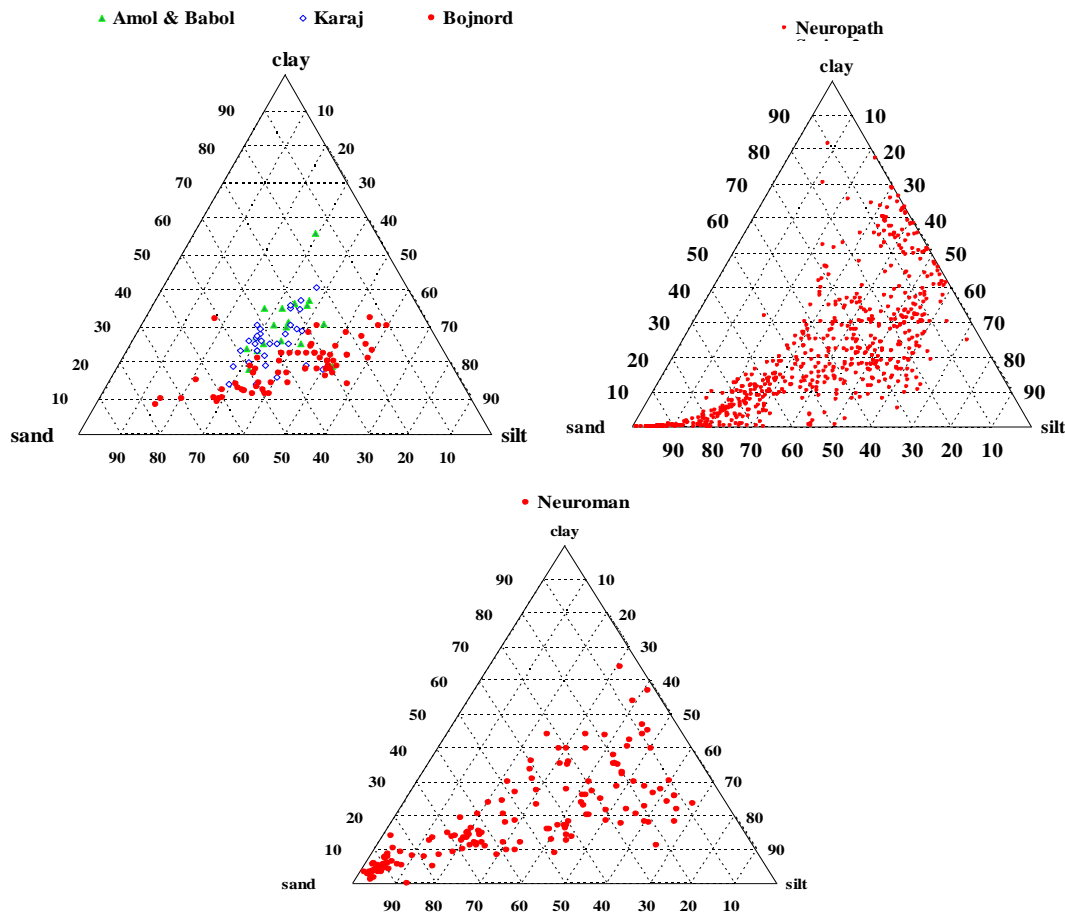
$$O(W, U) = \sum_{i=1}^{N_s} \sum_{s=1}^{Nd(i)} (\hat{\theta}_{is}(x_i, h_{is}, p_i) - \theta_{is}(h_{is}))^2$$

(۴)

که در آن: N_s تعداد نمونه های خاک، N_d تعداد داده های نگهداشت آب در نمونه خاک α_m ، و $\theta(x, h, p)$ رطوبت پیش بینی شده در پتانسیل h با استفاده از پارامتر p است. بدلیل اینکه برخی پارامترها توزیعی غیر نرمال دارند، تبدیل های $\ln(\alpha)$ ، $\ln(n-1)$ و $\ln(\theta_r)$ اعمال شد. برای اشتقاق توابع پارامتریک از نرم افزار Neuroman استفاده شد. به صورت مشابه با توابع قبلی شرح داده شده تعداد خود راه اندازها (نمایه B در فرمول (۱)) ۵۰ و تعداد تکرارها ۱۰۰ در نظر گرفته شد. ترکیبات مختلفی از عوامل ورودی مطابق با جدول (۲) در نظر گرفته شد که مشابه با توابع نقطه ای و شبه پارامتریک بود.

آموزش مستقیم و غیر مستقیم

در این پژوهش، دو رویه کلی در فرایند آموزش مورد بررسی قرار گرفت. در روش اول، آموزش با استفاده از پایگاه داده موجود در نرم افزارها انجام پذیرفت و داده های مناطق مختلف ایران در فاز آزمون مورد استفاده قرار گرفتند. این روش به اختصار در این تحقیق آموزش غیر مستقیم نام گرفت. در روش دوم (آموزش مستقیم) آموزش و آزمون با استفاده از نمونه های خاک ایران انجام پذیرفت. در هر دو روش، نرون های لایه میانی در فاز آموزش از یک تا نه تغییر نمود. در آموزش مستقیم ۸۰ درصد داده های خاک های ایرانی برای آموزش و ۲۰ درصد مابقی برای آزمون به کار گرفته شد. تخصیص داده ها به فازهای آموزش و آزمون به صورت تصادفی انجام پذیرفت. برای هر دو روش جهت تعیین بهترین چیدمان نرون های ورودی، موارد مطروحه در جدول (۲) مورد بررسی قرار گرفت. پراکنش بافت خاکی ۱۲۲ نمونه خاک ایرانی مورد استفاده، ۱۵۰ نمونه خاک پایگاه داده مدل Neuroman و ۶۲۲ نمونه خاک مدل Neuropath در شکل (۱) نشان داده شده است.



شکل (۱): پراکنده‌گی بافت خاک در نمونه‌های ایرانی و پایگاه داده موجود در نرم افزارهای Neuroman و Neuropath

باشد) (رابطه ۷) به منظور ارزیابی کاربرد توابع انتقالی مختلف استفاده شد.

$$r = \frac{\sum_{i=1}^{Nd} (M_i - \bar{M})(E_i - \bar{E})}{\sqrt{\sum_{i=1}^{Nd} (M_i - \bar{M})^2 \sum_{i=1}^{Nd} (E_i - \bar{E})^2}} \quad (5)$$

$$RMSE = \left[\frac{1}{Nd} \sum_{i=1}^{Nd} (E_i - M_i)^2 \right]^{1/2} \quad (6)$$

$$ME = \frac{1}{Nd} \sum_{i=1}^{Nd} (E_i - M_i) \quad (7)$$

که در آن‌ها: M بیانگر مقادیر واقعی رطوبت در مکش‌های مختلف، E مقادیر تخمینی، \bar{M} میانگین مقادیر واقعی، \bar{E} میانگین مقادیر تخمینی، n تعداد

نمونه خاک‌های پایگاه داده موجود در نرم افزار Neuropath در مکش‌های ۰، ۵، ۳۰، ۵۰ و ۱۵۰ کیلو پاسکال حاوی اطلاعات رطوبتی بودند. در پایگاه داده نرم افزار Neuroman اطلاعات رطوبتی خاک در مکش‌های بیشماری موجود بودند. لازم به ذکر است در حالتی که از پایگاه داده موجود در نرم افزار Neuropath برای آموزش استفاده شد به علت نبود اطلاعات میزان کربن آلی، حالات موجود در جدول (۲) به ترکیب‌های ۱ و ۲ تقلیل یافت.

معیارهای سنجش عملکرد

در این پژوهش از نمایه‌های ضریب همبستگی (رابطه ۵)، میانگین مربعات خطا (که بیانگر دقت میانگین پیش بینی می‌باشد و شدت منتظره خطا را نشان می‌دهد) (رابطه ۶) و خطای میانگین (برای تعیین اریب و تمایل به کم یا بیش برآورد، بدین صورت که مقادیر منفی خطای میانگین بیانگر کم برآورد نرم افزار و مقادیر مثبت بیانگر بیش برآورد می

نظر گرفته شده بسیار نزدیک به صفر میباشد و نتیجه می-شود که مدل های بهینه تمایلی به بیش یا کم برآورد از خود نشان ندادند. این امر در پراکنش مدل های بهینه در حول خط ۱:۱ در شکل (۲) نیز مشهود می باشد. با این وجود برتری عملکرد توابع شبه پارامتریک در مقایسه با توابع نقطه ای در مقادیر حاصله از این آماره نیز به خوبی مشخص می باشد.

ترکیب نرون های ورودی در موارد مختلف متفاوت بود و امکان گرفتن نتیجه ای واحد در مورد بهترین ترکیب ورودی وجود نداشت. اما در میان ساختارهای بهینه، شبکه هایی با BD و OC به عنوان ورودی نسبت به شبکه هایی که تنها از توزیع اندازه ذرات استفاده می کردند، حضور پررنگ تری داشتند. مشابه این نتیجه در تحقیق نس و همکاران (Nemes et al., 2003) و شاپ و لگی (Schaap & Leij, 1998b) ذکر شده است که در حالت کلی تعداد نرون بیش تر ورودی منجر به کاهش خطا و به تبع آن تخمین های بهتر می شود.

داده ها، Nd تعداد زوج نقاط $\theta(h)$ در منحنی نگهداشت آب خاک، r ضریب همبستگی، $RMSE$ ریشه میانگین مربعات خطا و ME خطای میانگین می باشد.

بحث

توابع نقطه ای و شبه پارامتریک

بهترین نتایج مدل سازی برای توابع نقطه ای و شبه پارامتریک در جدول (۳) نشان داده شده است. در توابع شبه پارامتریک، نتایج در کل قابل قبول بود. به گونه ای که در چهار سایت کرج، آمل- بابل، بجنورد و کل داده های ایران، به طور میانگین در فاز آزمون در آموزش مستقیم نمایه های r و $RMSE$ به ترتیب $0/97$ و $0/02$ و در آموزش غیر مستقیم $0/93$ و $0/032$ بودند. در هر دو حالت آموزش، مناطق کرج و آمل- بابل نتایج بهتری نسبت به بجنورد داشتند که این امر در آموزش غیر مستقیم مشهودتر بود. همچنین سایت کرج کمترین خطا را در هر دو حالت آموزش داشت. احتمالاً این امر به علت همسانی بافت خاک در نمونه های کرج در قیاس با دو سایت دیگر می باشد (شکل ۱). مقادیر آماره ME به طور کل در تمامی حالات در

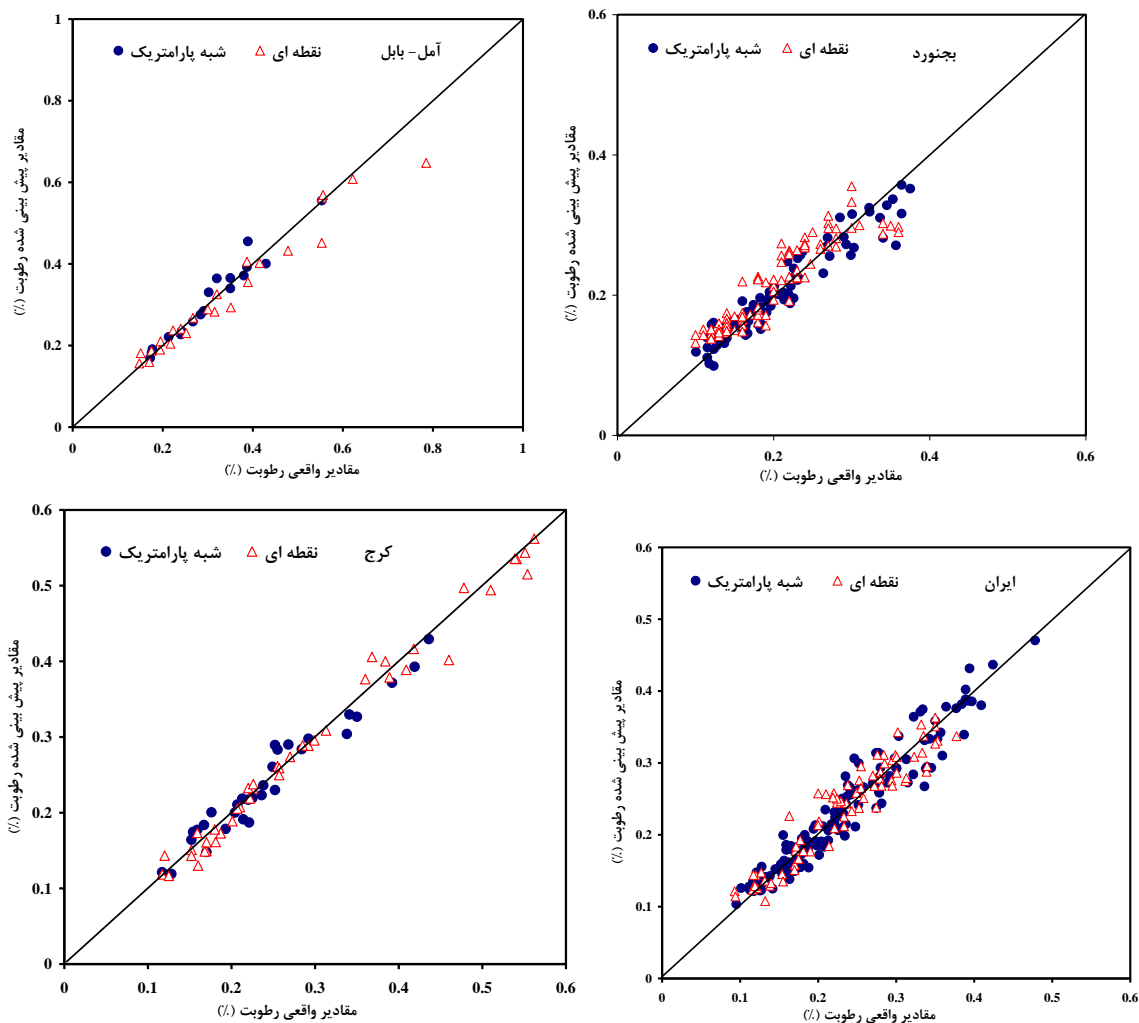
جدول (۳): بهترین نتایج توابع نقطه ای و شبه پارامتریک بر اساس مجموعه های متفاوت آموزش و آزمون

آزمون		آموزش		تعداد نرون	ورودی ها	مجموعه آزمون	مجموعه آموزش
ME	RMSE	r	RMSE	ME	لایه میانی		
الف: رطوبت (θ) - توابع شبه پارامتریک							
-0/005	0/02	0/98	0/02	0/003	4	SSC+BD+OC+h	آمل و بابل
0/003	0/02	0/96	0/015	0/002	9	SSC+BD+OC+h	بجنورد
0/0017	0/018	0/97	0/02	0/003	2	SSC+h	کرج
-0/00008	0/022	0/96	0/19	0/003	9	SSC+BD+OC+h	ایران
0/0048	0/035	0/91	0/039	-0/0009	3	SSC+BD+h	ایران
-0/002	0/027	0/97	0/038	0/0001	9	SSC+BD+h	کرج
0/007	0/031	0/96	0/042	0/0002	9	SSC+OC+h	آمل و بابل
0/01	0/035	0/87	0/039	-0/0009	3	SSC+BD+h	بجنورد
ب: رطوبت (θ_h) - توابع نقطه ای*							
0/015	0/035	0/92	0/017	-0/0004	1	SSC+OC	آمل و بابل
-0/013	0/027	0/61	0/019	0/0004	2	SSC+BD	بجنورد
0/0038	0/015	0/75	0/02	0/0006	1	SSC+BD+OC	کرج
-0/003	0/023	0/8	0/021	-0/0008	4	SSC+OC	ایران
0/003	0/027	0/77	0/035	0/0003	6	SSC+BD+OC	ایران
0/026	0/045	0/78	0/046	0/0009	1	SSC+OC	کرج
0/046	0/06	0/78	0/046	0/0009	1	SSC+OC	آمل و بابل
0/009	0/03	0/69	0/035	0/0002	6	SSC+BD+OC	بجنورد

* در توابع نقطه ای که داده های فاز آموزش و آزمون متفاوت بودند، شبیه سازی تنها در مکش های مشترک انجام پذیرفت.

شبه پارامتریک متراکم تر می‌باشند. همان طور که اشاره شد، از دیگر نقاط قوت توابع شبه پارامتریک افزایش سری داده-های مورد استفاده نسبت به توابع نقطه‌ای می‌باشد. به گونه-ای که هنگامی که تنها ۳۲ نمونه خاک در کرج برای روش معمول آموزش و آزمون در توابع نقطه‌ای در اختیار کاربر می‌باشد، با توجه به اینکه روش به کار گرفته شده در توابع شبه پارامتریک در پنج پتانسیل ۵-، ۳۳-، ۱۰۰-، ۵۰۰- و ۱۵۰۰- کیلو پاسکال هر نمونه را مجزا در نظر می‌گیرد، در حقیقت ۱۶۰ سری داده در اختیار کاربر قرار می‌دهد. از طرفی هنگامی که به تعداد نقاط پتانسیلی مشخص، نرون خروجی تخصیص داده شود، در حالتی که داده‌های فاز آزمون و آموزش از لحاظ تعداد نقاط پتانسیلی متفاوت باشند، شبیه‌سازی محدود به اشتراکات می‌شود و این امر خصوصاً خود منجر به کاهش چشم‌گیر کارایی مدل‌ها می‌شود. در صورتی که در توابع شبه پارامتریک این قبیل مشکلات به راحتی مرتفع می‌شوند.

در توابع نقطه‌ای میانگین عملکرد شبکه‌ها در مکش‌های مختلف مورد استناد قرار گرفت. بر طبق نتایج حاصله عملکرد توابع نقطه‌ای قابل قبول بود، هر چند در قیاس با توابع شبه پارامتریک، شبکه‌های بهینه‌شان ضعیف‌تر بود. به گونه‌ای که به طور میانگین در شبکه‌های بهینه چهار سایت کرج، آمل- بابل، بجنورد و کل داده‌های ایران در فاز آزمون در آموزش غیر مستقیم، نمایه‌های r و RMSE به ترتیب ۰/۷۵ و ۰/۰۴ و در آموزش مستقیم ۰/۷۷ و ۰/۰۲۵ بودند. به نظر می‌رسد دو عامل افزایش نمونه‌ها در فاز آزمایش و در نظر گرفتن میزان مکش به عنوان نمایه ورودی و به تبع آن وجود شبکه‌هایی با یک نرون خروجی مهم‌ترین دلایل توفیق توابع شبه پارامتریک باشند. برای مقایسه دقیق عملکرد توابع نقطه‌ای و شبه پارامتریک در تمامی سایت‌ها نتایج حاصله حول خط ۱:۱ رسم شد (شکل ۲). بر طبق نتایج حاصله در تمامی سایت‌ها پراکنش توابع شبه پارامتریک و نقطه‌ای حول خط ۱:۱ خوب می‌باشد و در اکثر موارد توابع



شکل (۲): پراکنش بهترین مقادیر پیش‌بینی شده رطوبت در سایت‌های مختلف در توابع نقطه‌ای و شبه پارامتریک

ترکیبات مختلف عوامل ورودی و خروجی و همچنین حالت‌های مختلف تخصیص نمونه‌های خاک بر اساس مکان نمونه‌برداری، نتایج قابل قبول بودند. در حالی که از پایگاه داده موجود در نرم افزار به منظور آموزش استفاده شد، نتایج آمل- بابل و کرج به نسبت بهتر از نتایج بجنورد بودند. این اختلاف ممکن است ناشی از نحوه توزیع بافت خاک در نمونه‌های موجود و یا تفاوت ماهوی خاک‌های این مناطق با یکدیگر باشد.

نتایج نشان داد که تابع هدف جدید ارائه شده توسط مینسنای و مک برانتسی (Minasny & McBratney, 2002a) حتی در شرایط استفاده از داده‌های بسیار کم می‌تواند منجر به نتایج درخشانی شود. همچنین مقایسه نتایج جداول (۳) و (۴) نشان می‌دهد که عملکرد توابع پارامتریک نسبت به نقطه-ای بهتر می‌باشد. به گونه‌ای که میانگین نمایه‌های r

بررسی تعداد نرون‌های لایه میانی در توابع نقطه‌ای و وجود چندین شبکه بهینه با تنها یک نرون در لایه میانی بیش از پیش این واقعیت را منعکس می‌سازد که در صورت کمی نمونه‌های خاک کارایی شبکه‌های عصبی خصوصاً در قالب توابع نقطه‌ای محل سوال می‌باشد. زیرا شبکه‌هایی با ساختار یک نرون میانی علاوه بر این که از قوت اساسی شبکه‌های عصبی یعنی پردازش موازی تا حد زیادی بی بهره‌اند، اساساً فرایندی بیش از رگرسیونی ساده را انجام نمی‌دهند و لذا حتی باید به وجود نمایه‌های r و RMSE قابل قبول در آن‌ها به دیده شک نگریسته شود.

توابع پارامتریک

بهترین نتایج مدل‌سازی برای توابع پارامتریک در جدول (۴) نشان داده شده است. بر طبق نتایج حاصله به طور کلی در تمامی حالات مورد آزمون قرار گرفته اعم از

توابع شبه پارامتریک به ترتیب برابر با ۰/۹۵ و ۰/۰۲۶ می‌باشد. مطالب ذکر شده در مورد عدم وجود اریب در نتایج مدل‌سازی (بر حسب مقادیر بدست آمده برای آماره ME) در توابع نقطه‌ای و شبه پارامتریک در این جا نیز صادق می‌باشد، به طوری که دامنه تغییرات آماره ME بین ۰/۰۰۶ تا ۰/۰۳۵- می‌باشد.

و RMSE در توابع پارامتریک به ترتیب ۰/۹۳ و ۰/۰۳۲ و در توابع نقطه‌ای به ترتیب ۰/۷۶ و ۰/۰۳۴ می‌باشد. مشابه این نتایج در تحقیق میناسنی و مک براتنی (Minasny & McBratney, 2002b) گزارش شده است. از طرفی در پژوهش حاضر استفاده از توابع شبه پارامتریک منجر به بهبود نتایج توابع نقطه‌ای به حدی بالاتر از توابع پارامتریک شده است. به گونه‌ای که میانگین نمایه‌های r و RMSE در

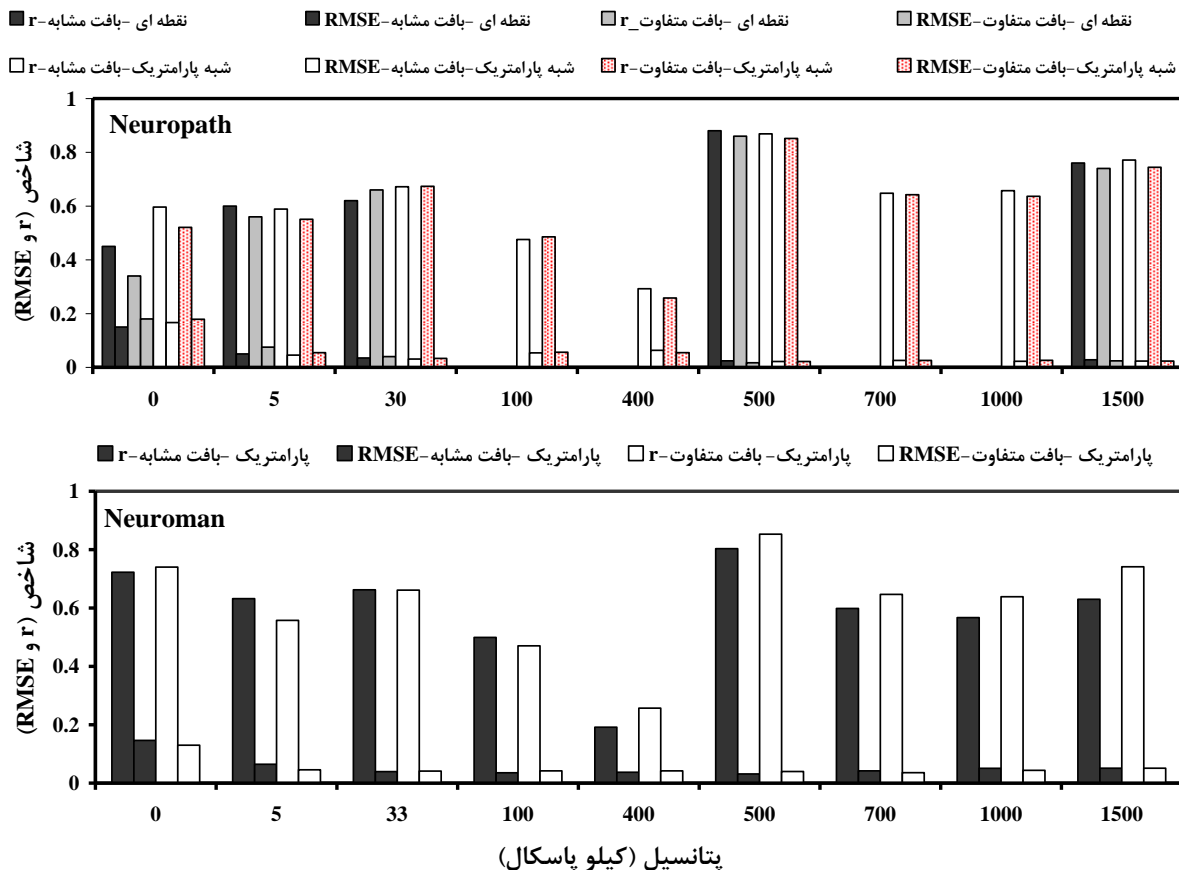
جدول (۴): بهترین نتایج مدل‌سازی برای توابع پارامتریک

آزمون			آموزش		تعداد نرون	ورودی‌ها	مجموعه آزمون	مجموعه آموزش
ME	RMSE	r	RMSE	ME				
۰/۰۰۳۴	۰/۰۲۷	۰/۹۱	۰/۰۲۲	-۰/۰۱۲	۳	SSC+BD+h	بجنورد	بجنورد
-۰/۰۰۳۵	۰/۰۳۱	۰/۹۹	۰/۰۲۴	۰/۰۱۴	۱	SSC+BD+OC+h	آمل و بابل	آمل و بابل
-۰/۰۰۰۷	۰/۰۱۴	۰/۹۸	۰/۰۲۲	۰/۰۰۴۸	۲	SSC+BD+h	کرج	کرج
۰/۰۰۰۵	۰/۰۲۵	۰/۹۶	۰/۰۲۲	۰/۰۰۰۷	۴	SSC+OC+h	ایران	ایران
۰/۰۰۰۶	۰/۰۳۹	۰/۹	۰/۰۳۶	-۰/۰۰۰۶	۲	SSC+h	ایران	پایگاه داده
۰/۰۰۰۱	۰/۰۴۳	۰/۸	۰/۰۳۶	-۰/۰۰۰۷	۲	SSC+h	کرج	پایگاه داده
۰/۰۰۳۲	۰/۰۴۲	۰/۹۶	۰/۰۳۴	-۰/۰۰۰۵	۲	SSC+BD+h	آمل و بابل	پایگاه داده
-۰/۰۰۰۴	۰/۰۳۸	۰/۹۷	۰/۰۳۶	-۰/۰۰۰۷	۲	SSC+h	بجنورد	پایگاه داده

مقصود در توابع نقطه‌ای در مدل Neuropath دو سری داده آموزش ۱۶۰ تایی از پایگاه داده موجود انتخاب شد و در مدل Neuroman دو سری داده ۷۵ تایی برای آموزش استفاده شد. ۱۱۰ نمونه خاک از مناطق مختلف ایران نیز پس از حذف بافت خاک‌هایی که با بقیه خاک‌ها متفاوت بودند، در فاز آزمون به کار گرفته شد. در تمامی حالات نرون‌های ورودی در نرم افزار Neuropath برابر توزیع اندازه ذرات، کربن آلی و چگالی ظاهری و در مدل Neuroman برابر توزیع اندازه ذرات و چگالی ظاهری در نظر گرفته شد.

آنالیز دیگر تغییرات

برای تعیین دقیق میزان تاثیر بافت خاک در فرآیند آموزش بر کارکرد مدل‌های شبکه عصبی در توابع نقطه‌ای، شبه پارامتریک و پارامتریک، پایگاه‌های داده موجود در نرم افزارهای Neuroman و Neuropath به دو بخش مجزا تفکیک گردید. بخشی که یک همخوانی نسبی از لحاظ پراکنش بافت خاکی با داده‌های فاز آزمون داشته باشند و بخشی که به طور کلی دارای کمترین اشتراک با داده‌های فاز آزمون از لحاظ بافت خاک باشند. برای نیل به این



شکل (۳): بهترین نتایج در پتانسیل های مختلف با در نظر گرفتن دو پایگاه داده جداگانه در فاز آموزش

در توابع انتقالی لحاظ نمی شوند (Nemes et al., 2003). شاید به همین دلیل است که توابعی که داده های فاز آموزش و آزمونشان از یک منطقه منتج شده بود نتایج قابل قبول تری داشتند.

نتیجه گیری

در این پژوهش برای ۱۲۲ نمونه خاک در شمال و شمال شرق ایران کارایی توابع جدید شبه پارامتریک در مقایسه با توابع پارامتریک و نقطه ای مورد بررسی قرار گرفت. رطوبت در پتانسیل ها و روش های مختلف در کل به خوبی شبیه سازی شد. بر طبق یافته های تحقیق استفاده از توابع شبه پارامتریک می تواند خصوصاً در شرایط کمبود داده نسبت به توابع نقطه ای نتایج را بهبود ببخشد. نتایج نشان داد که شبکه هایی که در فاز آموزش از داده های خاک های ایران (آموزش مستقیم) استفاده کرده بودند در اکثر موارد نتایج بهتری نسبت به توابع مشابهی

به طور کلی تفاوت بسیار زیادی در هیچ کدام از روش ها میان دو داده مختلف آموزشی مورد استفاده مشاهده نشد و حتی در برخی موارد شبکه هایی که در فاز آموزش با داده هایی با بافت خاک متفاوت آموزش دیده بودند در فاز آزمون عملکردی بهتر داشتند (شکل ۳). همچنین تقریباً در تمامی حالات در پتانسیل های میانی (۱۰۰- و ۴۰۰- کیلو پاسکال) شبکه ها نتایج ضعیف تری از خود نشان دادند.

نتایج قوی تر توابع اشتقاقی از بافت خاک های متفاوت نسبت به توابع منتج از بافت خاک های مشابه این نکته مهم را آشکار می سازد که تفاوت ماهوی خاک های مناطق گوناگون صرفاً ناشی از تفاوت در بافت خاک نیست. به عبارت بهتر به نظر می رسد همواره در استفاده از توابع انتقالی خصوصاً در توابع منتج از پایگاه داده های بزرگ باید این نکته را در نظر داشت که عواملی همچون میزان شوری، کانی شناسی رسی و بسیاری عوامل دیگر وجود دارند که در خصوصیات هیدرولیکی خاک ها تاثیر گذارند و

که داده‌های بسیار کمی برای فاز آموزش وجود داشت (توابع نقطه‌ای) صادق نبود. این مهم خود بیانگر این است که در صورتی که تعداد نمونه‌های خاک کم باشد کاربرد مدل‌های شبکه عصبی خصوصاً در توابع نقطه‌ای و آن هم صرفاً با داده‌های محلی مطلوب نمی‌باشد و باید آموزش شبکه‌ها با نمونه‌های خاک دیگر صورت پذیرد.

داشتند که از پایگاه داده موجود در نرم افزارها (آموزش غیر مستقیم) منتج شده بودند. مشابه این نتایج در مورد برتری نسبی توابع انتقالی اشتقاقی از داده‌های محلی در مقیاس کوچک در تحقیق پاراسورمان و همکاران (Parasuraman et al., 2006)، برای شبیه‌سازی هدایت هیدرولیکی اشباع بدست آمده بود. این امر تنها در مواردی

منابع

۱. خوشنود یزدی، ع. ا. ۱۳۷۰. برآورد منحنی رطوبتی خاک از روی خصوصیات فیزیکی در برخی از خاک‌های ایران. پایان نامه کارشناسی ارشد. دانشکده کشاورزی دانشگاه تهران. ۱۴۴ صفحه.
۲. عربی، ز. ۱۳۸۳. پیش‌بینی منحنی رطوبتی با استفاده از توزیع ذرات خاک. دانشگاه آزاد. واحد علوم و تحقیقات. پایان نامه کارشناسی ارشد. دانشکده کشاورزی. ۸۶ صفحه.
3. Acutis, M. and M. Donatelli. 2003., SOILPAR 2.00: software to estimate soil hydrological parameters and functions. *Eur. J. Agron.*, 18:373–377.
4. Baker, L. and D. Ellison. 2008. Optimisation of pedotransfer functions using an artificial neural network ensemble method. *Geoderma*, 144:212-224.
5. Carney, J. G. and P. Cuningham. 1999. The NeuralBAG algorithm: Optimizing generalization performance in bagged neural networks. 7th European Symposium on Artificial Neural Network. Bruges (Belgium).
6. Cornelis, W.; M. G. Ronsyn; M. Van Meirvenne and R. Hartmann. 2001. Evaluation of pedotransfer functions for predicting the soil moisture retention curve. *Soil Sci. Soc. Am. J.*, 65:638–648.
7. Merdun, H.; O. Cinar; R. Meral and M. Apan. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil & Tillage Research*, 90:108–116.
8. Minasny, B. and A. B. McBratney. 2002a. The Neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci. Soc. Am. J.*, 66:352–361.
9. Minasny, B. and A. B. McBratney. 2002b. Neuropack. Neural network package for fitting pedotransfer functions. Technical Note. v 1.0. Retrieved February 16. 2004 from the Australian Centre for Precision Agriculture. Web site: <http://www.usyd.edu.au/su/agric/acpa>.
10. Nemes, A.; M. G. Schaap and J. H. M. Wösten. 2003. Functional evaluation of pedotransfer functions derived from different scales of data collection, *Soil Sci. Soc. Am. J.*, 67:093–1102.
11. Parasuraman, K.; A. Elshorbagy and B. C. Si. 2006. Estimating saturated hydraulic conductivity in spatially variable fields using neural network ensembles. *Soil Sci. Soc. Am. J.*, 70:1851–1859.
12. Rawls, W. J.; T. J. Gish and D. L. Brakensiek. 1991. Estimating soil water retention from soil physical properties and characteristics. *Adv. Soil Sci.*, 9:213–234.
13. Schaap, M. G. and F. J. Leij. 1998a. Database related accuracy and uncertainty of pedotransfer functions. *Soil Sci.*, 163(10):765-779.
14. Schaap, M. G. and F. J. Leij. 1998b. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil & Tillage Research*, 47:37-42.
15. Sharma, S. K.; B. P. Mohanty and J. Zhu. 2006. Including topography and vegetation attributes for developing pedotransfer functions. *Soil Sci. Soc. Am. J.*, 70:1430-1440.
16. Ungaro, F.; C. Calzolari and E. Busoni. 2005. Development of pedotransfer functions using a group method of data handling for the soil of the Pianura Padano–Veneta region of North Italy: water retention properties. *Geoderma*, 124(3-4):293-317.
17. Wösten, J. H. M.; P. A. Finke and M. J. W. Jansen. 1995. Comparison of class and continuous pedotransfer functions to generate soil hydraulic characteristics. *Geoderma*, 66:227–237.

Modeling water retention curve of some Iranian soils using pseudo parametric neural network pedotransfer functions

Abstract

Modeling water flow and solute transport in unsaturated zone requires knowledge of soil hydraulic properties such as water retention curve. Indirect determination of these functions from basic soil properties using pedotransfer functions (PTFs) has attracted the attention of researchers in a variety of fields. Nowadays using of ANNs models for PTFs deriving is very usual. In this research we introduced and evaluated new pseudo pedotransfer functions and compared with point and parametric pedotransfer function. Also impact of two different method of training, direct and indirect was calculated. All the calculation is done on 122 soil samples of north and north east of Iran that were selected randomly. Generally result of parametric functions was better than point functions. The average of r and RMSE indicators in parametric functions are 0.93 and 0.032 and in point functions are 0.76 and 0.034. On the other hand pseudo parametric functions improved the results of point functions with using the same information's for training. The average of r and RMSE indicators in pseudo parametric functions are 0.95 and 0.026. It seems that increasing of samples in training phase and select the matric potentials as input are the most important factors in pseudo parametric functions success. Also results show that using local data for deriving pedotransfer functions (direct training) is better than using universal data base (indirect training).

Keywords: Pedotransfer Functions, pseudo parametric functions, water retention curve, direct and indirect training.