

## بررسی روش‌های مختلف برای ایجاد توابع انتقالی خاک‌های بخشی از مناطق مرطوب شمال ایران

روح‌الله تقی‌زاده مهرجردی\*<sup>۱</sup>، شهلا محمودی<sup>۲</sup>، علی اکبرزاده<sup>۳</sup> و هادی رحیمی لاکه<sup>۴</sup>

<sup>۱</sup> دانشجوی دکتری، <sup>۲</sup> استاد و <sup>۳</sup> دانش‌آموخته کارشناسی ارشد گروه مهندسی علوم خاک، پردیس کشاورزی و منابع

طبیعی دانشگاه تهران <sup>۴</sup> دانش‌آموخته کارشناسی ارشد گروه خاکشناسی، دانشکده علوم کشاورزی دانشگاه گیلان

(تاریخ دریافت: ۱۳۸۸/۸/۱۰ - تاریخ تصویب: ۱۳۸۹/۳/۲۲)

### چکیده

تخمین پارامترهای دیرپافت خاک با استفاده از اطلاعات موجود خاک، توابع انتقالی نامیده می‌شود. جهت توسعه توابع انتقالی می‌توان از مدل‌های رگرسیون چند متغیره، شبکه عصبی مصنوعی و نروفازی استفاده کرد. بنابراین در این مطالعه به منظور مقایسه مدل‌های مذکور، ۱۵۳ نمونه جمع آوری شده از ناحیه شمالی شهرستان رشت مورد آزمایش قرار گرفته و درصد شن، سیلت، رس و کربن آلی به عنوان ویژگی‌های زودپافت و ظرفیت تبادل کاتیونی به عنوان ویژگی دیرپافت اندازه‌گیری شدند. سپس کل داده‌ها به دو سری داده، شامل سری آموزش (۸۰٪ داده‌ها) و سری ارزیابی (۲۰٪ داده‌ها) تقسیم گردید. نتایج ارزیابی نشان داد که مدل نروفازی بر اساس شاخص‌های ریشه مربعات خطا، میانگین خطا و ضریب تبیین به ترتیب ۰/۷۳، ۰/۰۷ و ۰/۶۶ دارای بالاترین دقت در پیش‌بینی ظرفیت تبادل کاتیونی خاک می‌باشد. همچنین این مدل بر اساس شاخص درصد کاهش ریشه مربعات خطا به میزان ۱۴ درصد دقت پیش‌بینی ویژگی CEC را نسبت به روش رگرسیون خطی چندگانه افزایش داده است. بعد از این مدل، شبکه‌های عصبی مصنوعی پسانتشار، پایه شعاعی و آبشاری به ترتیب نسبت به معادلات رگرسیونی کارائی بهتری داشته‌اند.

**واژه‌های کلیدی:** توابع انتقالی، رگرسیون چند متغیره، شبکه‌های عصبی مصنوعی، نروفازی

عصبی و سامانه‌های فازی) اشاره کرد.

### مقدمه

نمونه‌برداری مستقیم همراه با اندازه‌گیری‌های مستقیم آزمایشگاهی یا صحرایی معمولاً بسیار پرهزینه و وقت‌گیر بوده و در نتیجه برای اهداف کاربردی دارای محدودیت می‌باشند. تاکنون تلاش‌های زیادی صورت گرفته تا روابط ممکن بین خصوصیات دیرپافت خاک با دیگر خصوصیات آن که در خاکشناسی به توابع انتقالی (Pedotransfer functions, PTFs) معروف هستند تعیین شود. توابع انتقالی خاک توابع برآورد کننده خصوصیات پرهزینه (Costly measured properties) خاک از خصوصیات کم‌هزینه (Readily available properties) خاک می‌باشند (Bouma, 1989). از خصوصیات پرهزینه خاک می‌توان به ویژگی‌های هیدرولیکی، حرارتی، مکانیکی و ویژگی‌های شیمیایی مانند ظرفیت تبادل کاتیونی اشاره کرد. توزیع اندازه ذرات خاک، ماده آلی، کربنات کلسیم، وزن مخصوص ظاهری نیز از جمله خصوصیات زودپافت خاک‌ها هستند. برای برآزش این توابع انتقالی روش‌های مختلفی وجود دارد که از آن جمله می‌توان به رگرسیون خطی چند متغیره و استفاده از تکنیک‌های هوش محاسباتی (تلفیق شبکه‌های

رگرسیون یک روش آماری برای بررسی و مدل‌سازی رابطه بین متغیرها است. تاکنون مطالعات بسیار زیادی در رابطه با مدل‌سازی خواص مختلف خاک‌ها با استفاده از این نوع از توابع انتقالی (رگرسیون چند متغیره خطی و غیر خطی) انجام گرفته است که به چند نمونه اشاره شده است. برای پیش‌بینی ظرفیت زراعی و نقطه پژمردگی دائم Givi et al. (2004) از ۱۳ تابع انتقالی نقطه‌ای و پارامتری استفاده کردند. نتایج نشان داد که توابع انتقالی بسط داده شده از خاک‌های مشابه دارای کمترین خطا بودند. همچنین Rajkai et al. (2004) برای پیش‌بینی بینی منحنی رطوبتی خاک از روش رگرسیون خطی و غیر خطی استفاده کردند. نتایج بر اساس دو معیار ارزیابی AIC (Schwarz and SBC) و (Akaka's Information Criterion) و Bayesian Criterion نشان داد که معادلات غیر خطی از کارایی بالاتری برخوردار بودند. برای پیش‌بینی ظرفیت تبادل کاتیونی در خاک‌های آمریکا Seybold et al. (2005) از مدل‌های خطی استفاده نمودند و میزان رس و درصد کربن آلی را به عنوان موثرترین پارامترها در تخمین مورد نظر معرفی کردند. نتایج همچنین نشان داد که نوع رس و ظرفیت زراعی نیز از دیگر پارامترهای تأثیرگذار در پیش‌بینی ظرفیت تبادل کاتیونی بودند.

داشتند. با وجود این که رگرسیون خطی عملکرد بهتری از شبکه عصبی نداشت، آن‌ها برای توابع انتقالی نقطه‌ای رگرسیون خطی را توصیه نمودند. Merdun et al. (2006) در پژوهشی در کشور ترکیه برای پیش‌بینی خصوصیات هیدرولیکی خاک از توابع انتقالی نقطه‌ای و پارامتری که با استفاده از شبکه عصبی و رگرسیون خطی بسط داده شده بود، استفاده کردند. نتایج نشان داد که تفاوت معنی داری بین دو روش مذکور وجود نداشت.

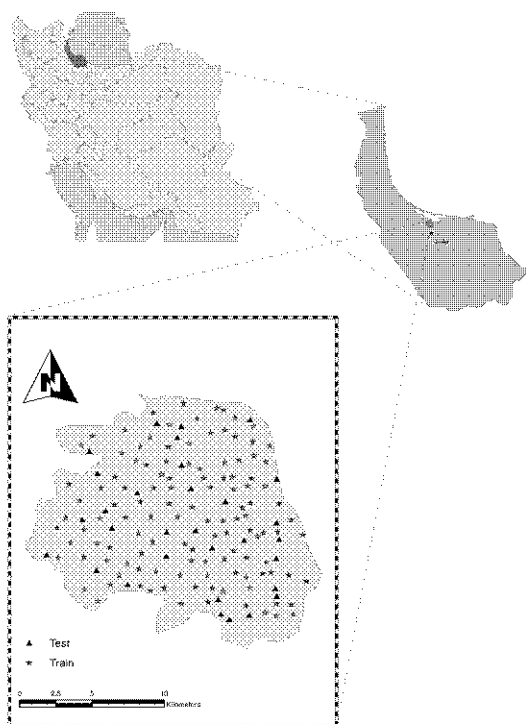
به منظور استفاده از منطق فازی در امر ارتباط دادن ورودی‌ها و خروجی‌ها از سیستم استنتاج فازی (Fuzzy inference system) استفاده می‌شود. سیستم (مدل) نوروفازی (Neuro-Fuzzy model) که ترکیب شبکه عصبی با منطق فازی می‌باشد با استفاده از الگوریتم آموزش شبکه عصبی پارامترهای سیستم فازی را تعیین می‌کند. این سیستم ترکیبی بر اساس سیستم فازی که بیانگر عدم قطعیت‌ها می‌باشد، پایه‌گذاری شده است. از انواع مدل‌های نوروفازی می‌توان به مدل‌های نوروفازی همزمان (Concurrent)، مدل‌های نوروفازی تعاونی (Cooperative) و مدل‌های نوروفازی دورگه (Hybrid) اشاره کرد. در مدل‌های نوروفازی دورگه تغییرات انجام شده در روند یادگیری را می‌توان از هر دو منظر شبکه عصبی و منطق فازی تفسیر کرد. از این شبکه‌ها می‌توان به سیستم فازی تطبیق پذیر مبتنی بر شبکه عصبی (Adaptive Neuro-Fuzzy Inference System, ANFIS) اشاره کرد که برای اولین بار توسط Jang (1993) معرفی شد. این مدل یک سیستم فازی را در یک ساختار عصبی اجرا می‌کند و برای فرآیند آموزش از ترکیبی از روش‌های آموزش شامل شیب نزولی (Gradient descent) و حداقل مربعات خطا (Least square error) استفاده می‌کند (Kisi, 2005; Drake, 2000). مطالعات اخیر، کارایی بیشتر مدل‌های نوروفازی را در مقایسه با دیگر توابع انتقالی نشان می‌دهد. به عنوان مثال Moghaddamnia et al. (2009) میزان تبخیر را با استفاده از چندین مدل تجربی، شبکه عصبی و مدل نوروفازی ANFIS تخمین زدند. نتایج نشان داد که مدل نوروفازی دارای کارایی بیشتری بر اساس معیار ریشه مربعات خطا نسبت به دو مدل دیگر بود. Akbarzadeh et al. (2009) میزان پاشمان ذرات خاک و رواناب تولید شده در خاکهای مارنی استان زنجان را با استفاده از رگرسیون چندمتغیره، شبکه عصبی و نوروفازی تخمین زدند. نتایج نشان داد که مدل نوروفازی دقت بالاتری نسبت به مدل‌های دیگر در پیش‌بینی پارامترهای مذکور داشت. Kalkan et al. (2008) برای پیش‌بینی ویژگی مکانیکی (Unconfined compressive strength) خاک‌های فشرده شده (Compacted soils) از توزیع اندازه ذرات ۸۴ نمونه خاک

شبکه عصبی مصنوعی (Artificial neural networks) یک روش شبیه‌سازی می‌باشد که از مطالعه سیستم مغز و شبکه عصبی موجودات زنده الهام گرفته است. قدرت بالای عملکرد سیستم‌های بیولوژیک ناشی از طبیعت موازی برنامه‌ریزی نرون‌های آن‌ها می‌باشد. یک شبکه عصبی مصنوعی این ساختار را با توزیع شبیه‌سازی در واحدهای پردازشگر کوچک و ساده به هم پیوسته (که نرون نامیده می‌شود) انجام می‌دهد. مهمترین مزیت شبکه‌های عصبی مصنوعی نسبت به دیگر روش‌های ایجاد توابع انتقالی این است که آن‌ها برای پیش‌بینی پارامترهای خاک احتیاجی به یک مدل اولیه در ارتباط دادن بین داده‌های ورودی و خروجی ندارند. مزیت دیگر شبکه‌های عصبی نسبت به سیستم‌های هوشمند دیگر قدرت یادگیری آن‌ها در مقیاس خیلی کوچک از محیط پیرامونشان و توانایی تعمیم این یادگیری می‌باشد. بطور کلی در این روش سعی می‌شود بر اساس روابط ذاتی میان داده‌ها، مدلی خطی یا غیرخطی بین متغیرهای مستقل و وابسته برقرار گردد. Rahimi Lake et al. (2009).

به عنوان مثال Schaap et al. (1998) نشان دادند که شبکه عصبی مصنوعی می‌تواند پیش‌بینی‌هایی با خطاهای کمتر نسبت به روش‌های متداول رگرسیونی ارائه دهد. Sarmadian et al. (2009) نیز با استفاده از رگرسیون خطی چند متغیره و شبکه عصبی مصنوعی اقدام به مدل‌سازی ظرفیت تبادل کاتیونی و درصد آب در نقطه ظرفیت زراعی و نقطه پژمردگی دائم در منطقه گرگان نمودند. نتایج نشان داد که شبکه عصبی با دو نرون در لایه مخفی کارایی بالاتری نسبت به رگرسیون چند متغیره خطی در پیش‌بینی پارامترهای مذکور داشت. Amini et al. (2005) با استفاده از مقدار ماده آلی و رس اقدام به برآورد میزان CEC خاک در منطقه اصفهان، به وسیله شبکه عصبی مصنوعی و پنج مدل تجربی که بر پایه روش‌های رگرسیونی می‌باشند، نمودند. نتایج آنها نیز نشان داد که روش شبکه عصبی از برتری قابل قبولی نسبت به سایر روش‌ها برخوردار است. Rahimi Lake et al. (2009) نیز کارایی شبکه عصبی مصنوعی را در پیش‌بینی خواص فیزیکوشیمیایی و هیدرولوژیکی خاکهای استان گیلان از قبیل میانگین وزنی قطر خاکدانه‌ها، سرعت نفوذ نهایی آب در خاک، ظرفیت تبادل کاتیونی، هدایت الکتریکی و درصد سدیم تبادلی بهتر از رگرسیون خطی چند متغیره عنوان کردند. Minasny et al. (1999) نیز برای پیش‌بینی منحنی رطوبتی خاک از سه روش شبکه عصبی، رگرسیون خطی و غیر خطی استفاده کردند. نتایج نشان داد که برای تابع انتقالی پارامتری شبکه عصبی و رگرسیون غیر خطی عملکرد یکسانی

مطالعه براساس روش دومارتن اقلیم خیلی مرطوب نوع الف ( $A=5/33$ ) و براساس روش آمبرژه از نوع خیلی مرطوب است. متوسط بارندگی سالیانه ۱۲۹۴ میلی‌متر و متوسط دمای سالیانه ۱۵/۸ درجه سانتی‌گراد است. بنابراین، رژیم‌های رطوبتی خاک‌های منطقه (نرم افزار نیهوال) Udic و یا Aquic و رژیم حرارتی آن Thermic است.

از لحاظ زمین‌شناسی، عمدتاً رسوبات از نوع دلتایی و رودخانه‌ای دوران کواترنر و به صورت محدود رسوبات قدیمی ساحلی در بخش شمال منطقه است. عمده‌ترین کاربری منطقه شالیزار به صورت غرقابی است و سایر کاربری‌ها شامل کشت صیفی‌جات و درختکاری است. این منطقه دارای واحدهای فیزیوگرافی (به ترتیب از جنوب به شمال منطقه) شامل دشت-های آبرفتی رودخانه‌ای (River Alluvial Plains)، اراضی حاشیه رودخانه‌ها (River Bank)، اراضی پست (Low Lands) و بالاخره اراضی حاشیه ساحلی (دریای خزر) و تپه‌های ماسه‌ای (Coastal Lands and Sand Dunes) هستند. عمدتاً فیزیوگرافی منطقه مطالعاتی دشت‌های آبرفتی رودخانه‌ای است که براساس موقعیت و شیب دارای بخش‌های فوقانی، میانی و تحتانی است. خاکهای محدوده مطالعاتی از نظر رده‌بندی بر اساس طبقه‌بندی جامع آمریکایی (Soil Taxonomy, USDA) (2010) در سه رده الفی‌سول، اینسپتی‌سول و انتی‌سول قرار می‌گیرند. شکل (۱) موقعیت منطقه مورد مطالعه و پراکنش ۱۵۳ نقاط نمونه‌برداری را نشان می‌دهد.



شکل ۱- موقعیت منطقه مورد مطالعه و پراکنش نقاط نمونه‌برداری

استفاده کردند. برای مدل کردن ویژگی مذکور از دو روش نروفازی و شبکه عصبی استفاده نمودند. نتایج نشان داد که مدل نروفازی از نوع ANFIS دارای کارایی بالاتری نسبت به مدل شبکه عصبی مصنوعی بود. Kisi (2005) نشان داد که مدل نروفازی ANFIS در مقایسه با مدل‌های شبکه عصبی مصنوعی و رگرسیون چند متغره خطی دارای دقت بالاتری در پیش‌بینی مقدار رسوب معلق بود. Kayadelen et al. (2009) با استفاده از چند ویژگی فیزیکی خاک شامل وزن مخصوص ظاهری، حد خمیرایی و درصد خاکدانه‌های درشت و ریز اقدام به مدل‌سازی مقاومت برشی خاک کردند. نتایج نشان داد که مدل نروفازی ANFIS در مقایسه با مدل شبکه عصبی مصنوعی دارای دقت بالاتری در پیش‌بینی مقاومت برشی است.

هدف از انجام تحقیق حاضر عبارت است از پیش‌بینی ظرفیت تبادل کاتیونی بخشی از خاک‌های مناطق مرطوب ناحیه شمالی شهرستان رشت با استفاده از انواع مختلف توابع انتقالی خاک از قبیل شبکه‌های عصبی مصنوعی پس‌انتشار (Feed Forward)، پایه شعاعی (General Regression Neural Network) و آبشاری (Cascade Forward)، مدل‌های نروفازی و رگرسیون چند متغیره است. در این تحقیق از فراوانی نسبی ذرات و کربن آلی به عنوان ویژگی‌های زودیافت خاک در تخمین ظرفیت تبادل کاتیونی که یک ویژگی دیریافت خاک است، استفاده می‌شود. بدیهی که با مقایسه این توابع با یکدیگر و معرفی کارآمدترین آن‌ها در پیش‌بینی پارامتر مذکور به درک صحیحی از کارایی هر یک آن‌ها می‌انجامد.

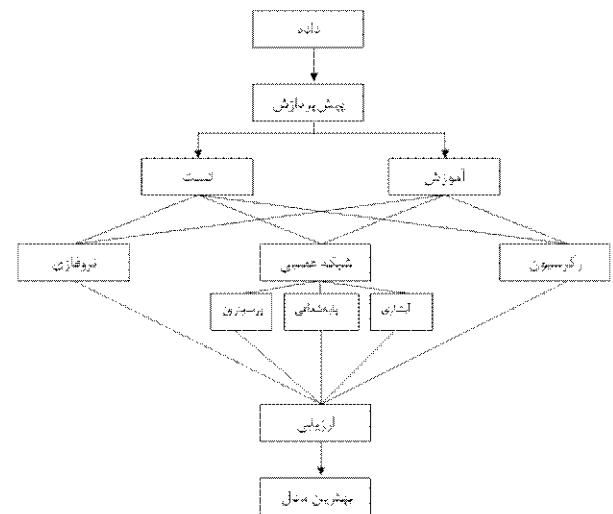
## مواد و روش‌ها

### منطقه مورد مطالعه

منطقه مورد مطالعه در ناحیه شمالی شهرستان رشت در استان گیلان در موقعیت جغرافیایی  $31^{\circ} 31' 00''$  تا  $49^{\circ} 45' 00''$  طول شرقی و  $37^{\circ} 07' 30''$  تا  $37^{\circ} 27' 08''$  عرض شمالی قرار دارد. محدوده طرح از سمت شمال به دریای خزر، از سمت شرق به رودخانه گیشه دمرده، از سمت جنوب و جنوب غرب به کانال آب بر شهر سنگر - رشت و از سمت غرب به رودخانه سیاهرود منتهی می‌گردد. مساحت منطقه مورد مطالعه ۲۴۳۰۰ هکتار بوده و عمدتاً در دلتای سفیدرود واقع شده و شامل اراضی جلگه ای می‌باشد که شیب آن کمتر از یک درصد است (شکل ۱). بالاترین نقطه ارتفاعی آن حدود ۴۰ متر و حداقل ارتفاع آن ۲۸- متر از سطح دریای آزاد قرار دارد. برای تعیین اقلیم و وضعیت آب و هوایی منطقه از اطلاعات ایستگاه سینوپتیک رشت استفاده شده است. بر اساس خصوصیات اقلیمی، منطقه مورد

**مراحل تحقیق**

این تحقیق دارای چندین مرحله می‌باشد که به صورت روندنما (شکل ۲) ارائه شده است.



شکل ۲- فلوچارت مراحل انجام کار

مرحله اول پیش‌پردازش داده‌ها بود. در این مرحله در ابتدا داده‌های پرت (۱۲ داده) از کل داده‌ها با استفاده از نرم‌افزار MINTAB حذف گردید. در ادامه با استفاده از رگرسیون گام به گام پارامترهای موثر برای پیش‌بینی ظرفیت تبادل کاتیونی خاک انتخاب گردیدند. سپس بررسی همراستایی بین داده‌های مستقل صورت گرفت. برای چک کردن همراستایی، از رابطه همبستگی بین متغیرهای مستقل استفاده گردید و متغیرهایی که دارای همبستگی زیادی با یکدیگر بودند، حذف گردیدند (Ghorbani Dashtaki and Homaei, 2002). سرانجام دو دسته داده آموزش و آزمون برای انواع مدل‌های مورد استفاده انتخاب گردید.

مرحله دوم ایجاد توابع انتقالی بود. در این مرحله ابتدا مدل رگرسیونی بر روی داده‌های آموزش برازش داده شد و بعد از بدست آوردن معادله مورد نظر، این معادله بر روی داده‌های آزمون کنترل گردید. دومین مدل مورد بررسی انواع شبکه‌های عصبی (پس انتشار، آبشاری و پایه شعاعی) می‌باشد. برای استفاده از داده‌ها در شبکه‌های عصبی مذکور باید آن‌ها را استانداردسازی (Normalization) کرد. در صورتی که داده‌ها به صورت خام وارد شبکه شود، به علت تغییرات زیاد داده‌ها، تاثیر متفاوتی بر روی شبکه گذاشته، به طوری که برخی از نرون‌های خیلی زود به حد آتش رسیده، در حالی که برخی دیگر از نرون‌ها حتی به آستانه فعالیت نیز نرسیده‌اند (Menhaj, 2007).

بنابراین داده‌های ورودی و خروجی با استفاده از معادله (۱) استانداردسازی شدند یعنی داده‌ها در محدوده ۰/۱ تا ۰/۹ قرار می‌گیرند. سومین مدل مورد استفاده، نروفازی می‌باشد. که در این مدل برای بهینه کردن ساختار اولیه از روش سعی و خطا

استفاده شد.

$$y = 0.8 \times \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} + 0.1 \quad (1)$$

مرحله سوم ارزیابی مدل‌ها بود. به منظور مقایسه عملکرد مدل‌های ANFIS، شبکه عصبی مصنوعی و رگرسیون چند متغیره از پارامترهای میانگین خطا (Mean Error, ME) و مجذور میانگین مربعات خطا (Root Mean Square Method, RMSE) که از روابط (۳) و (۴) قابل محاسبه می‌باشند، استفاده گردید.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2} \quad (2)$$

$$ME = \frac{1}{n} \sum (Z_o - Z_p) \quad (3)$$

که در آن‌ها:  $Z_o$  مقادیر پیش بینی شده،  $Z_p$  مقادیر مشاهداتی،  $Z_a$  متوسط مقادیر مشاهداتی و  $n$  تعداد داده‌ها می‌باشد. برای ارزیابی مدل هر چه پارامترهای مورد اشاره به صفر نزدیکتر باشند مدل از کارایی بالاتری برخوردار می‌باشد (Amini et al., 2005).

علاوه بر معیارهای آماری فوق الذکر برای بررسی کارایی مدل‌های مختلف از شاخص درصد کاهش ریشه مربعات خطا (Relative Improvement, RI) نیز استفاده گردید (رابطه ۴).

$$RI = \left( \frac{RMSE_a - RMSE_b}{RMSE_a} \right) \times 100 \quad (4)$$

که در این مدل  $RMSE_a$  میزان ریشه مربعات خطا در روش رگرسیون و  $RMSE_b$  ریشه مربعات خطا در سایر روش‌ها می‌باشد. این آماره نشان‌دهنده میزان کاهش خطا در مدل‌های مختلف نسبت به روش رگرسیون می‌باشد. در واقع مدلی مناسب‌تر است که RI بیشتری داشته باشد (Amini et al., 2005).

**نتایج**

**پیش‌پردازش**

در ابتدا، با استفاده از روش رگرسیون گام به گام (Step by step)، پارامترهای موثر برای هر مدل تشخیص داده شد که نتایج آن در جدول (۱) ارائه شده است. بر اساس جدول (۱)، درصد رس و کربن آلی به عنوان مهم‌ترین عوامل تأثیر گذار بر تغییرات ظرفیت تبادل کاتیونی معرفی شدند. اما در رگرسیون چندگانه خطی اگر بین متغیرهای مستقل وابستگی خطی زیادی مشاهده شود، همراستایی چندگانه به وجود می‌آید (Ghorbani Dashtaki and Homaei, 2002). از آنجائی‌که فراوانی نسبی ذرات رس، شن و سیلت همراستا

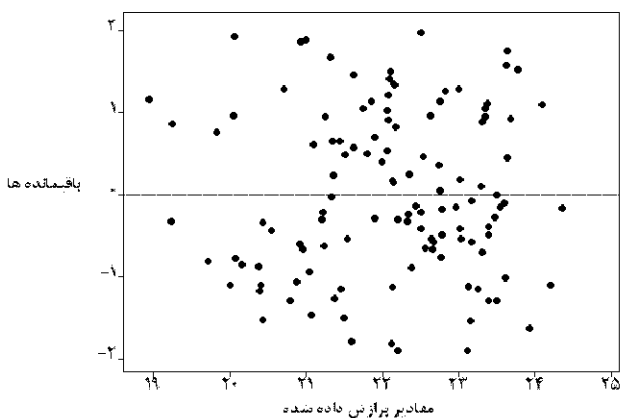
شبه یکدیگر بودند. همچنین این دو گروه داده تفاوت معنی‌داری در سطح ۵٪ نداشتند. در جدول (۲) معیارهای آماری مربوط به داده‌های تست و آموزش ارائه شده است. در مرحله بعد نرمال بودن داده‌ها با استفاده از روش کولموگروف-اسمیرنوف مورد بررسی قرار گرفت. نتایج نشان داد که تنها داده کربن آلی از توزیع نرمال پیروی نمی‌کند و چون فرض آمار کلاسیک (رگرسیون) بر نرمال بودن داده است، در نتیجه این خصوصیت با لگاریتم‌گیری نرمال‌سازی گردید.

دهنده صحت مدل رگرسیونی و عدم وجود هم‌راستایی در بین پارامترهای ورودی دارد (جدول ۴).

$$CEC = 19.3 + 0.0779Clay + 2.28 \log O.C \quad (5)$$

جدول ۴- نتایج تجزیه واریانس برای رگرسیون

منابع	درجه آزادی	مجموع مربعات	میانگین مربعات	اف فیش	مقدار پی
رگرسیون	۲	۱۷۰	۸۵	۸۳	<۰/۰۱
باقیمانده خطا	۱۱۸	۱۲۱	۱		
کل	۱۲۰	۱۲۰	۲۹۱		



شکل ۳- نمودار پراکنش مقادیر خطا که نشان‌دهنده توزیع تصادفی باقیمانده‌ها می‌باشد

#### شبکه عصبی پرسپترون چند لایه

پس از تعیین مجموعه داده‌های تست و آموزش، داده‌های ورودی به شبکه استانداردسازی گردیدند. در مرحله بعد، مدل شبکه عصبی با یک لایه مخفی که تعداد نرون‌های آن به بین ۲ تا ۲۰ نرون می‌باشد، ساخته و ساختار بهینه شبکه به روش سعی و خطا با استفاده از معیارهای ME و RMSE تعیین گردید. برای پیش‌بینی ظرفیت تبادل کاتیونی ورودی‌های شبکه شامل درصد‌های رس و کربن آلی بود. برای این ویژگی مقادیر RMSE و ME در اشکال (۴) و (۵) ارائه شده است. با توجه به این شکل ملاحظه می‌شود که حداقل مقدار RMSE و ME مربوط به شبکه با هشت نرون در لایه مخفی می‌باشد. مقادیر RMSE و ME برای پارامتر ظرفیت تبادل کاتیونی با بهترین

(Multicollinearity) بودند، باعث محدودیت استفاده از این خصوصیات شد. بنابراین، فقط از درصد رس و کربن آلی به عنوان ورودی هر سه مدل استفاده شد.

سپس داده‌ها به دو دسته تقسیم شد، به طوری که ۸۰٪ داده‌ها برای آموزش و مابقی داده‌ها یعنی ۲۰٪ برای اعتبارسنجی اختصاص داده شد (Amini et al., 2005). برای این منظور دو دسته داده به طور تصادفی تعیین گردید به طوری که از نظر معیارهای آماری از قبیل میانگین و انحراف معیار تا حد ممکن

جدول ۱- ضرایب همبستگی (r) ویژگی‌های مورد مطالعه

کربن آلی / رس	رس / سیلت	سیلت / شن	ظرفیت تبادل کاتیونی (Cmolc/kg)
۰/۳۹***	۱		
۰/۱۵	-۰/۶۸***	۱	
-۰/۱۴	-۰/۷۱***	-۰/۱۵	۱
۰/۴۷***	۰/۵۸***	-۰/۳۳***	-۰/۴۷***

جدول ۲- پارامترهای آماری داده‌های استفاده شده در مدل نروفازی، شبکه

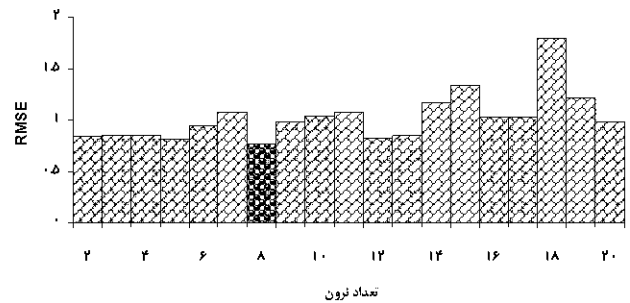
#### عصبی و رگرسیون چند متغیره

پارامتر آماری	ظرفیت تبادل کاتیونی (Cmolc/kg)	رس / سیلت	کربن آلی / رس
میانگین	۲۲/۱	۳۶/۸۸	۱/۲۱
انحراف معیار	۱/۵۶	۱۱/۲۶	۰/۸۳
کمترین	۱۸/۹	۱۲/۴۰	۰/۱۲
بیشترین	۲۵/۴	۶۱/۶۰	۳/۱۲
چولگی	-۰/۱۲	-۰/۱۶	۰/۷۷
کمترین	۲۱/۴۵	۳۳/۶۹	۰/۹۰
بیشترین	۱/۲۴	۱۲/۵۲	۰/۶۸
میانگین	۱۹/۰	۱۲/۲۰	۰/۰۴
انحراف معیار	۲۳/۶۰	۶۰/۴۰	۲/۹۶
چولگی	-۰/۱۴	۰/۳۳	۱/۱۹

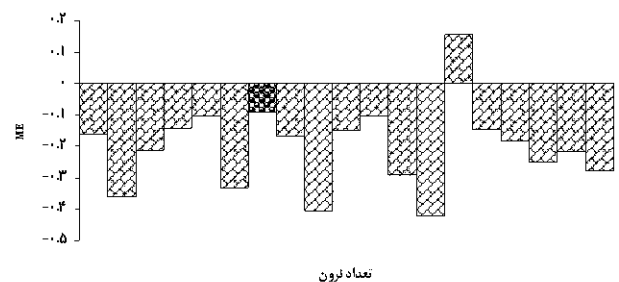
#### نتایج رگرسیون چند متغیره خطی

برای تعیین رگرسیون چند متغیره پارامتر مورد مطالعه، رابطه رگرسیونی مربوطه با استفاده از داده‌های آموزش تعیین گردید (معادله ۵). این رابطه سپس بر روی داده‌های آزمون اعمال گردید و نتایج ریشه مربعات خطا، میانگین خطا و ضریب تبیین به ترتیب ۰/۸۵، ۰/۰۳- و ۰/۵۵ بدست آمد. مقادیر ضرایب رگرسیونی دارای عدد پی کوچکتر ۰/۰۱ می‌باشد، همچنین جدول تجزیه واریانس نیز برای رگرسیون محاسبه گردید که نتایج از معنی‌دار بودن معادله برازش داده شده حکایت دارد (p<0.01) در نهایت پراکنش مقادیر خطا محاسبه شد، که با توجه به شکل (۳) توزیع تصادفی را نشان می‌دهد که نشان-

ساختار شبکه عصبی به ترتیب ۰/۸۳ و ۰/۰۶ برای داده‌های آموزش و ۰/۷۵ و ۰/۱۰- برای آزمون بدست آمده است.



شکل ۴- مقادیر RMSE برای تعداد نرون متفاوت در پیش بینی پارامتر CEC



شکل ۵- مقادیر ME برای تعداد نرون متفاوت در پیش بینی پارامتر CEC

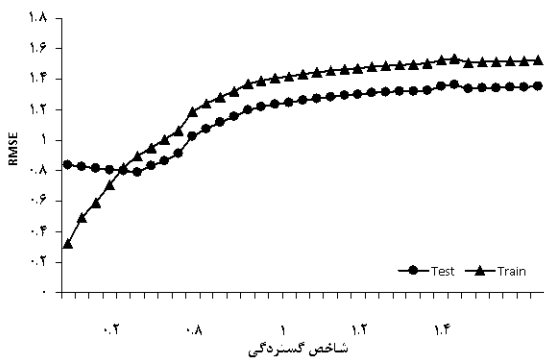
#### شبکه عصبی آبشاری

برای اجرای این شبکه نیازی به ساختار اولیه (تعداد نرون در لایه مخفی) ندارد و این جزء حسن‌های این شبکه می‌باشد. پس در این شبکه نیازی به روش سعی و خطا نمی‌باشد. نتایج خطای این روش بر اساس معیارهای ریشه مربعات خطا، میانگین خطا و ضریب تبیین به ترتیب ۰/۸۱، ۰/۲۴- و ۰/۵۹ بدست آمد.

#### شبکه عصبی پایه شعاعی

حسن این شبکه الگوریتم سریع یادگیری آن است یعنی شبکه با یک دوره آموزش پیدا می‌کند. برای این شبکه تنها پارامتر مورد تنظیم میزان شاخص گستردگی (SPREAD) می‌باشد. بنابراین، مقدار بهینه این پارامتر را که حساسیت تابع به ورودی را نشان می‌دهد را با استفاده از نمودار (۶) محاسبه شد. همان طور که در این شکل مشاهده می‌گردد مقادیر RMSE برای داده‌های آموزش و تست دارای روند متفاوتی است، بنابراین دو مقدار شاخص گستردگی را برای ارائه انتخاب گردید (Amini et al., 2005) زمانی که این پارامتر برای داده‌های آزمون حداقل است و (۲) نقطه‌ای که گراف‌های آموزش و آزمون همدیگر را قطع کرده‌اند. در نتیجه دو مدل شبکه برای GRNN استفاده گردید. نتایج معیارهای ریشه مربعات خطا، میانگین خطا و ضریب تبیین برای مدل GRNN1 به ترتیب ۰/۸۰، ۰/۱۸- و ۰/۶۱ و برای مدل GRNN2 به ترتیب ۰/۷۹، ۰/۱۷- و

۰/۶۱ بدست آمد.



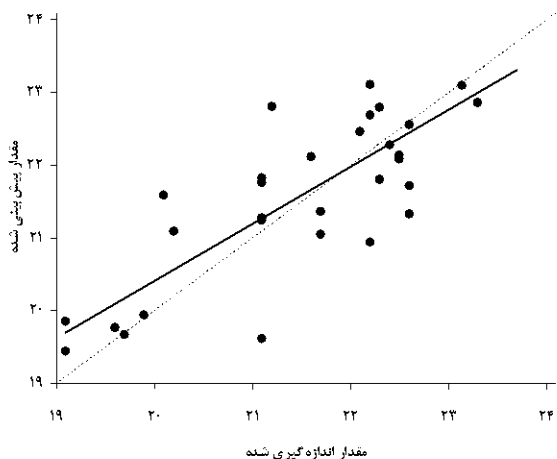
شکل ۶- نمودار مقادیر RMSE برای داده‌های آموزش و آزمون

#### سیستم فازی تطبیق پذیر مبتنی بر شبکه عصبی (ANFIS)

در این ساختار مجموعه‌های فازی را می‌توان به عنوان وزن ارتباطات و متغیرهای ورودی و خروجی را به عنوان نرون‌ها تفسیر کرد و الگوریتم یادگیری ساختارها، پارامترها و یا هر دوی آن‌ها را اصلاح می‌کند. برای ایجاد این شبکه باید چند پارامتر بهینه شوند که شامل نوع تابع عضویت، تعداد تابع و روش یادگیری و تعداد اپوک (Epoch) می‌باشد. برای اینکار تمام حالات را بوسیله سعی و خطا بدست آمد، که نتایج خصوصیات مدل ANFIS به کار رفته برای پیش‌بینی CEC نشان داد که تعداد عضویت ۷ و تعداد قانون ۱۲ بهترین ساختار را می‌دهد. همچنین این ساختار در تکرار ۶۰۰ با روش یادگیری پس‌خور و روش دفازی کردن میانگین‌وزنی بدست آمد. نتایج معیارهای ریشه مربعات خطا، میانگین خطا و ضریب تبیین برای مدل ANFIS به ترتیب ۰/۷۳، ۰/۰۷- و ۰/۶۶ بدست آمد.

#### ارزیابی مدل‌ها

نتایج مربوط به مدل‌های نروفازی، شبکه‌های عصبی و رگرسیون چند متغیره مربوط به پارامتر مورد اندازه‌گیری در جدول (۵) ارائه شده است. با توجه به این جدول ملاحظه می‌شود در کل بهترین عملکرد در پیش‌بینی ویژگی مورد مطالعه مربوط به مدل نروفازی می‌باشد. از لحاظ هر سه معیار بهتر از شبکه عصبی و رگرسیون چند متغیره می‌باشد. بعد از مدل ANFIS شبکه عصبی مصنوعی پس انتشار، پایه شعاعی و آبشاری به ترتیب بهترین عملکرد را به خود اختصاص داده است. مقدار پایین RMSE برای اکثر مدل‌ها، پایین بودن خطا و دقت بالای مدل‌های برازش داده شده را نشان می‌دهد. همچنین نتایج نشان داد که در سطح ۵٪ تفاوت معنی‌داری بین مدل‌هایی که ویژگی CEC را تخمین زده‌اند، وجود ندارد. در چنین شرایطی برای ارزیابی کارایی مدل‌ها می‌توان از شاخص RI استفاده نمود. این آماره نشان‌دهنده میزان کاهش خطا در مدل‌های مختلف



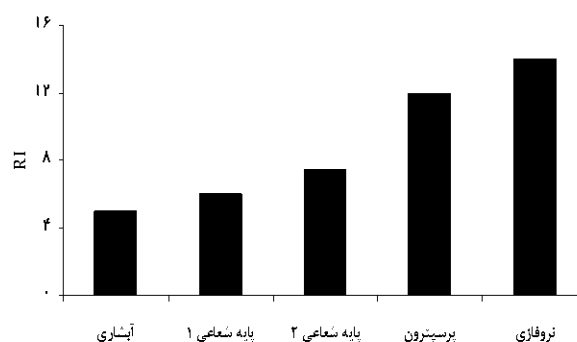
شکل ۹- نمودار پراکنش برای مقادیر مشاهداتی و شبیه سازی شده داده‌های آموزش آزمون در ANFIS

### بحث

نتایج این بررسی نشان داد که شبکه‌های عصبی مصنوعی نسبت به معادله رگرسیونی کارآئی بهتر به میزان ۱۲ درصد (جدول ۵) در پیش‌بینی ظرفیت تبادل کاتیونی خاک داشته است. زیرا احتمالاً بر طبق نظر Schaap et al. (1998) در طراحی شبکه‌های عصبی نوع خاصی از معادلات لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد و به علت وجود روابط غیر خطی میان متغیرهای وابسته و پیش‌بینی شونده شبکه عصبی عملکرد بهتری نسبت به مدل‌های رگرسیونی داشته است. نتایج مشابهی توسط Tamari et al. (1996) به دست آمده است. آن‌ها نیز مقدار RMSE کمتری از برآورد خصوصیات خاک با شبکه عصبی مصنوعی نسبت به رگرسیون خطی چندگانه به دست آوردند. آنها همچنین نشان دادند که اگر ناپایداری داده‌ها بالا باشد، شبکه عصبی از مدل‌های رگرسیونی خطی بهتر نخواهد بود، اما زمانی که داده‌هایی با دقت بالا بکار برده شوند شبکه عصبی کارآئی بالاتری را نشان می‌دهد.

تمامی روش‌های ذکر شده در این تحقیق بر پایه فرض دقیق بودن متغیرهای مورد مطالعه و مشاهده‌های مربوط به آنها استوار است و روابط بین متغیرها نیز دقیق فرض می‌گردد. حال آن‌که در سیستم‌های طبیعی مانند خاک، عموماً با مشاهدات یا روابط ناشناخته بین متغیرها مطرح است. در چنین شرایطی، از مدلی باید بهره گرفت که قادر به ارائه الگوهای مناسب‌تر باشند، به گونه‌ای که این مدل‌ها بتوانند انطباق بیشتری با دنیای واقعی داشته باشند. نتایج این بررسی نشان داد که دقت مدل نروفازی در پیش‌بینی خاک از تمام انواع شبکه‌های عصبی مورد استفاده بیشتر بود. به دلیل ساختار غیر خطی مدل‌های شبکه عصبی و ابهام در متغیرهای مدل‌های سیستم

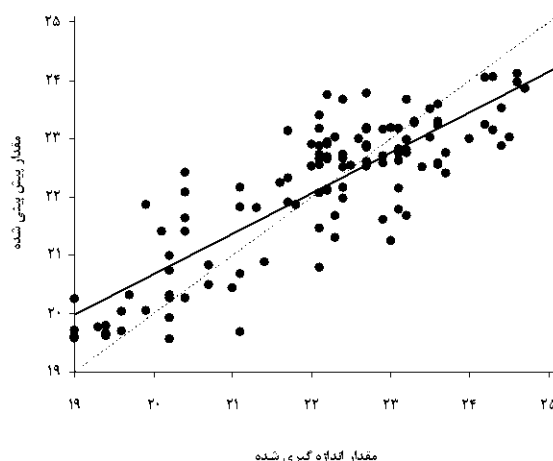
نسبت به روش رگرسیون می‌باشد. همانطور که در جدول (۵) و شکل (۷) ارائه شده، مدل نروفازی دقت پیش‌بینی را نسبت به روش رگرسیون خطی چندگانه برای ویژگی CEC به میزان ۱۴ درصد افزایش داده است. همچنین آماره منفی میانگین خطا نشان دهنده این است که تمام مدل‌ها مقداری کم برآزش داشته‌اند. در اشکال (۸) تا (۹) دیاگرام‌های پراکنش داده‌های آموزش و تست برای مدل نروفازی که بهترین عملکرد را به خود اختصاص داده آورده شده است. با توجه به این شکل ملاحظه می‌شود بهترین خط برآزش داده شده دارای زاویه ای نزدیک به ۴۵ درجه می‌باشد که نشان از دقت بالای برآورد توسط مدل نروفازی دارد.



شکل ۷- مقایسه نتایج RI در روش‌های مختلف

جدول ۵- مقایسه نتایج ارزیابی خطا در روش‌های مختلف برای پیش‌بینی

ظرفیت تبادل کاتیونی				
RI	R <sup>2</sup>	ME	RMSE	مدل
۰	۰/۵۵	-۰/۰۳	۰/۸۵	رگرسیون
۵	۰/۵۹	-۰/۳۴	۰/۸۱	شبکه‌عصبی آبشاری
۶	۰/۶۰	-۰/۱۸	۰/۸۰	شبکه‌عصبی پایه شعاعی ۱
۷	۰/۶۰	-۰/۱۶	۰/۷۹	شبکه‌عصبی پایه شعاعی ۲
۱۲	۰/۶۲	-۰/۱۰	۰/۷۵	شبکه‌عصبی پس انتشار
۱۴	۰/۶۶	-۰/۰۷	۰/۷۳	نروفازی



شکل ۸- نمودار پراکنش برای مقادیر مشاهداتی و شبیه سازی شده داده‌های آموزش آزمون در ANFIS

پایه شعاعی و آبشاری به ترتیب بهترین عملکرد را به خود اختصاص داده است. در پایان باید اذعان داشت که با توجه به ماهیت ابهامی پدیده‌های مرتبط با خاک یا تقریبی بودن مقادیر اندازه‌گیری شده خصوصیات مختلف خاک، به نظر می‌رسد کارایی بالاتر مدل مبتنی بر مجموعه‌های فازی در پردازش توابع انتقالی خاک به همین علت باشد.

### معرفی نمادها و علائم

ANFIS: مدل نروفازی  
 CEC: ظرفیت تبادل کاتیونی  
 CFNN: شبکه عصبی آبشاری  
 Clay: درصد رس خاک  
 FFBP: شبکه عصبی پیش‌خور  
 GRNN1: شبکه عصبی پایه شعاعی اول  
 GRNN2: شبکه عصبی پایه شعاعی دوم  
 OC: درصد کربن آلی  
 Test: داده‌های مورد استفاده در مرحله ارزیابی  
 Train: داده‌های مورد استفاده در مرحله آموزش  
 Regression: مدل رگرسیون چند متغیره  
 AIC: شاخص آکایی که برای بررسی دقت مدل‌های متفاوت با تعداد ورودی گوناگون به کار می‌رود  
 SBC: شاخصی است برای ارزیابی مدل‌ها بر اساس آمار بیز  
 Unconfined compressive strength: این ویژگی مقدار مقاومت و پایداری خاکدانه های خاک را در برابر نیروهای وارده بر آن نشان می دهد.

### REFERENCES

- Aali, K. A., Parsinejad, M. and Rahmani, B. (2009). Estimation of saturation percentage of soil using multiple regression, ANN, and ANFIS techniques. *Computer and Information Science*, 2(3), 127-136.
- Akbarzadeh, A., Taghizadeh Mehrjardi, R., Rouhipour, H., Gorji M. and Refahi, H.G. (2009). Estimating of soil erosion covered with rolled erosion control systems using rainfall simulator (neuro-fuzzy and artificial neural network approaches). *Journal of Applied Sciences Research*, 5(5), 505-514.
- Amini, M., Abbaspour, K. C., Khademi, H., Fathianpour, N., Afyuni, M. and Schulin, R. (2005). Neural network models to predict cation exchange capacity in arid regions of Iran. *European Journal of Soil Science*, 53, 748-757.
- Azmathulla, H. Md., Chang, C. K., Ab.Ghani, A., Ariffin, J., Zakaria, N. A. and Abu Hasan, Z. (2008). An ANFIS-based approach for predicting the bed load for moderately sized rivers. *Journal of Hydro-environment Research*, 3(1), 35-44.
- Bouma, J. (1989). Using soil survey data for quantitative land evaluation. *Advanced Soil Science*, 9, 177-213.
- Civelekoglu, G., Perendeci, A., Yigit, N. O. and Kitis, M. (2007). Modeling carbon and nitrogen removal in an industrial wastewater treatment plant using an adaptive network-based fuzzy inference system. *CLEAN-Soil, Air, Water*, 35 (6), 617-625.
- Drake, J. T. (2000). *Communications phase synchronization using the adaptive network fuzzy inference system*. Ph. D. dissertation, New Mexico State University, Las Cruces, New Mexico, USA.
- Ghorbani Dashtaki, Sh. and Homaei, M. (2002). Parametric assessment of hydraulic function of the unsaturated soil section by pedotransfer functions. *Journal of Agricultural Engineering Research*, 3(12), 3-15. (In Farsi)
- Givi, J., Prasher, S. O. and Patel, R. M. (2004). Evaluation of pedotransfer functions in predicting the soil water contents at field capacity and wilting point. *Agricultural Water Management*,

استنتاج فازی امروزه بیشتر محققین در تجزیه و تحلیل متغیرهایی که دارای توزیع مکانی می‌باشند، تمایل به استفاده از مدل‌های هیبریدی مانند سیستم فازی تطبیق پذیر مبتنی بر شبکه عصبی (ANFIS) دارند (Lee, 2000). به عنوان مثال Aali et al. (2009) نشان دادند که مدل ANFIS در پیش‌بینی درصد رطوبت اشباع خاک دارای دقت بالاتری نسبت به مدل شبکه عصبی مصنوعی بود. و یا Azamathulla et al. (2008) مدل ANFIS را در پیش‌بینی بار بستر چندین رودخانه در مالزی مناسب تر از مدل‌های رگرسیونی دیگر تشخیص دادند. به طور مشابه Civelekoglu et al. (2007) در مدل‌سازی هدر رفت نیتروژن و کربن از خاک به این نتیجه رسیدند که مدل ANFIS در مقایسه با مدل‌های رگرسیونی دیگر برآورد دقیق‌تری دارد. Terzi et al. (2006) نیز مدل ANFIS را بهترین روش در پیش‌بینی تبخیر سطحی معرفی کردند. بدین ترتیب با توجه به وجود عدم قطعیت (Uncertainty) در پدیده‌های مرتبط با خاک یا تقریبی بودن مقادیر اندازه‌گیری شده خصوصیات مختلف خاک، به نظر می‌رسد کارایی بالاتر مدل مبتنی بر مجموعه‌های فازی در پردازش توابع انتقالی خاک به همین علت باشد.

### نتیجه‌گیری

برای پیش بینی ظرفیت تبادل کاتیونی، عوامل رس و کربن آلی استفاده گردید. با توجه به معیارهای ارزیابی ( $ME$ ,  $R^2$ ,  $RMSE$  و  $RI$ )، نتایج بررسی نشان داد که مدل نروفازی دارای بالاترین دقت و به میزان ۱۴ درصد در پیش‌بینی پارامتر خاک موثرتر می‌باشد. بعد از مدل ANFIS شبکه عصبی مصنوعی پس انتشار،



- 70, 83–96.
- Jang, J. -S. R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685.
- Kalkan, E., Akbulut, S., Tortum, A. and Celik, S. (2008). Prediction of the unconfined compressive strength of compacted granular soils by using inference systems. *Environmental Geology*, 12(4), 254–267.
- Kayadelen, C., Günaydin, O., Fener, M., Demir, A. and Özvan, A. (2009). Modeling of the angle of shearing resistance of soils using soft computing systems. *Expert Systems with Applications*, 36(9), 11814–11826.
- Kimar, M., Raghuwanshi, N. S., Singh, R., Wallender, W. W. and Pruitt, W. O. (2002). Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, 128(4), 224–233.
- Kisi, O. (2005). Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrological Sciences–Journal–des Sciences Hydrologiques*, 50(4), 683–696.
- Lee E. S. (2000). Neuro-Fuzzy estimation in spatial statistics. *Journal of Mathematical Analysis and Applications*, 249, 221–231.
- Manyame, C., Morgan, C. L., Heilman, J. L., Fatondji, D., Gerard, B. and Payne, W. A. (2007). Modeling hydraulic properties of sandy soils of Niger using pedotransfer functions. *Geoderma*, 141, 407–415.
- Menhaj, M. 2007. *Fundamental of Artificial neural networks*. Amirkabir Press.
- 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 & Tillage Research*, 90, 108–116.
- 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, 225–253.
- Moghaddamnia, A., Ghafari Gousheh, M. Piri, J., Amin, S. and Han, D. (2009). Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*, 32 (6), 88–97.
- Rahimi Lake, H., Akbarzadeh, A. and Taghizadeh Mehrjardi, R. (2009). Development of pedo transfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zones of the Caspian Sea. *Journal of Ecology and the Natural Environment*, 1(7), 160–172.
- Rajkai, K., Kabos, S. and van Genuchten, M. Th. (2004). Estimating the water retention curve from soil properties: comparison of linear, nonlinear and concomitant variable methods. *Soil & Tillage Research*, 79(2), 145–152.
- Sarmadian, F., Taghizadeh Mehrjardi, R. and Akbarzadeh, A. (2009). Modeling of some soil properties using artificial neural network and multivariate regression in Gorgan province, north of Iran. *Australian Journal of Basic and Applied Sciences*, 3(1), 323–329.
- Schaap, M. G., Leij, F. J. and van Genuchten, M. Th. (1998). Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Science Society of America Journal*, 62, 847–855.
- Seybold, C. A., Grossman, R. B. and Reinsch, T. G. (2005). Predicting Cation Exchange Capacity for Soil Survey Using Linear Models. *Soil Science Society of American Journal*, 69: 856–86.
- Tamari, S., Wosten, J. H. M. and Ruz-suarez, J. C. (1996). Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Science Society American Journal*, 60, 1732–1741.
- Terzi, O., Keskin, M. E. and Taylan, E. D. (2007). Estimating evaporation using ANFIS. *Journal of Irrigation and Drainage Engineering*, 132(5), 503–507.

