

## مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره در پیش‌بینی برخی خصوصیات خاک (مطالعه موردي: استان گلستان)

فریدون سرمدیان<sup>۱\*</sup>، روح الله تقیزاده مهرجردی<sup>۲</sup>، حسین محمد عسگری<sup>۳</sup> و علی اکبرزاده<sup>۴</sup>

<sup>۱</sup> دانشیار، <sup>۲</sup> دانشجوی دکتری و <sup>۴</sup> کارشناسی ارشد، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران <sup>۳</sup> دانشجوی دکتری، دانشکده منابع طبیعی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران  
(تاریخ دریافت: ۱۳۸۷/۷/۸ - تاریخ تصویب: ۱۳۸۸/۹/۱)

### چکیده

با توجه به مشکلات اندازه‌گیری مستقیم برخی از روش‌های غیر مستقیم برای برآورد این خصوصیات استفاده می‌شود. بدین منظور، در این پژوهش ۱۴۰ نمونه جمع آوری شده از منطقه گرگان مورد آزمایش قرار گرفته و فراوانی نسبی ذرات، کربن آلی، درصد رطوبت اشبع و آهک به عنوان ویژگیهای زودیافت و نقطه پژمردگی، ظرفیت زراعی، ظرفیت تبادل کاتیونی و وزن مخصوص ظاهری به عنوان ویژگیهای دیریافت اندازه‌گیری شدن. سپس کل داده‌ها به دو سری داده، شامل سری آموزش (۸۰٪ داده‌ها) و سری ارزیابی (۲۰٪ داده‌ها) تقسیم گردید. به منظور پیش‌بینی خصوصیات مذکور، از مدل‌های نروفازی، شبکه عصبی مصنوعی و رگرسیون چند متغیره استفاده گردید. نتایج ارزیابی مدل‌ها بر اساس شاخصهای ریشه مربعات خطأ، میانگین خطأ، خطای استاندارد نسبی و ضریب تبیین نشان داد که مدل نروفازی دارای بالاترین دقت در پیش‌بینی ویژگیهای خاک را دارا می‌باشد بطوریکه این مدل به میزان ۳۴، ۱۰، ۷۸ و ۵ درصد دقت پیش‌بینی ویژگیهای FC، CEC، PWP و Bd را به ترتیب، نسبت به روش رگرسیون خطی چندگانه افزایش داده است. بعد از این مدل، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی کارائی بهتر داشته است.

**واژه‌های کلیدی:** خصوصیات خاک، رگرسیون چند متغیره، شبکه عصبی مصنوعی، نروفازی

### مقدمه

نشان داد که جدا کردن داده‌های خاک سطحی و زیرین دقت پیش‌بینی را بالا نبرده است. Heушner et al. (2002) و Kaur et al. (2005) در مطالعات خود به این نتیجه رسیدند که بافت و مواد آلی مؤلفه‌های اصلی در تعیین وزن مخصوص‌ظاهری می‌باشد. Givi and Prasherb (2004) ۱۳ تابع انتقالی نقطه‌ای و پارامتری را برای پیش‌بینی ظرفیت زراعی و نقطه پژمردگی دائم استفاده کردند. نتایج این پژوهشگران نشان داد که توابع انتقالی که در خاکهای مشابه اشتراق پیدا کرده‌اند، دارای کمترین خطأ می‌باشند.

اخیراً تلاش‌هایی برای بکارگیری روش‌ها و فنون جدید در مدل‌بندی چنین توابعی صورت گرفته است که می‌توان برای نمونه به استفاده از شبکه‌های عصبی اشاره نمود (Minansy and McBratney, 2002). شبکه‌های عصبی مصنوعی یکی از روش‌های هوشمند پردازش داده‌ها هستند که به دلیل شیوه تحلیل اطلاعات مشابه با مغز انسان، داشتن قدرت تعمیم، عدم نیاز به یک مدل ریاضی از پیش تعیین شده، عدم نیاز به همراستایی و نرمال بودن داده‌ها و توانایی آموزش و یادگیری می‌توانند در تخمین پارامترهای دیریافت خاک مورد استفاده قرار گیرند.

با توجه به مشکلات موجود در اندازه‌گیری مستقیم برخی خصوصیات خاک، روش‌های غیرمستقیم برآورد و تخمین خصوصیات مزبور در سالهای اخیر مورد توجه قرار گرفته‌اند. یکی از روش‌ها، ایجاد توابع انتقالی خاک است که خصوصیات دیریافت خاک را از خصوصیات زودیافت آن برآورد می‌کند. (Bouma, 1989) در سالهای اخیر توابع انتقالی فراوانی برای تخمین خصوصیات خاک از خصوصیات فیزیکی و شیمیایی خاک ایجاد شده است (Givi and Prasherb, 2004).

Bell and Van (1995) با استفاده از متغیرهای مقدار رس، ماده آلی و اسیدیته خاک تابعی برای برآورد ظرفیت تبادل کاتیونی ارائه نمودند. Krogh et al. (2000) با استفاده از متغیرهای مقدار ماده آلی، رس، سیلت رس و اسیدیته خاک در عصاره کلرور کلسیم توابعی برای برآورد ظرفیت تبادل کاتیونی ارائه دادند. Vos et al. (2005) برای تخمین وزن‌خصوص‌ظاهری از ۱۲ تابع توابع انتقالی استفاده کردند و نتایج ایشان

\* پست الکترونیک مکاتبه کننده: rh\_taghizade@yahoo.com

طور کلی در مواردی که با خطاهای ناشی از ابهام در ساختار معادلات رگرسیونی رو به رو است، میتواند مکمل و یا جایگزین مناسبی برای روش رگرسیون آماری تلقی شود. McBratney (1997) and Odeh (1997) قابلیت منطق فازی را در علوم خاک مانند نقشه برداری، ارزیابی و مدل کردن فرآیندهای فیزیکی به خوبی نشان دادند. Matternicht and Gonzalez (2004) روش فازی را برای ارزیابی میزان فرسایش به کار برden. Ahmed et al. (2000) از روش فازی برای تهیه نقشه ویژگیهای خاک استفاده کردند. Kal et al. (2008) برای پیش بینی مقاومت در برابر فشار از توزیع اندازه ذرات خاک استفاده کرده و برای مدل کردن از دو روش نروفازی و شبکه عصبی استفاده کردند. نتایج نشان از کارائی بالاتر نروفازی در این تحقیق داشت. علاوه بر این محققین مختلفی از منطق فازی در زمینهای مختلفی کار کردند (Feng et al. 2006, Zhu et al. 2001).

با توجه به مشکلات اندازه‌گیری مستقیم ظرفیت تبادل کاتیونی، ظرفیت زراعی، نقطه پژمردگی و وزن مخصوص ظاهری، هدف از این تحقیق مقایسه کارایی نروفازی، شبکه عصبی مصنوعی و رگرسیون چند متغیره در برآورد این ویژگی های با استفاده از متغیرهای زود یافتخاک میباشد.

## مواد و روش ها

**منطقه مورد مطالعه و اطلاعات استفاده شده**

منطقه مورد مطالعه حدود 150000 هکتار وسعت دارد که شمالی‌ترین نقطه آن از مرز ترکمنستان با ایران شروع و در جنوب‌بیشترین نقطه آن به دامنه شمالی البرز در حوزه محمد آباد خاتمه می‌یابد شکل (1).

### تجزیههای فیزیکی و شیمیایی خاک

تعداد 140 نمونه خاک از عمقهای مختلف 40 پروفیل که به طور تصادفی انتخاب شده بودند، جمعاًوری شد و بعد از انتقال به آزمایشگاه، در معرض هوا خشک شده، سپس کوبیده و از الک دو میلیمتر عبور داده شدند. درصد رطوبت اشباع به روش وزن - سنجی، بافت خاک به وسیله هیدرومتری (Gee and Bauder, 1986)، کربن آلی بوسیله تیتراسیون (Black, 1982)، درصد آهک معادل بوسیله حجم‌سنجی (Sparks et al, 1996) و ظرفیت تبادل کاتیونی نمونهای خاک به روش باور اندازه گیری شد (Bower et al, 1952). رطوبت در نقطه ظرفیت زراعی و پژمردگی دائم نیز در فشارهای 33 و 1500 کیلوپاسکال با استفاده از دستگاه صفحات فشاری اندازه گیری شدند (Sparks et al, 1996).

Schap et al. (1998) نشان دادند که شبکههای عصبی میتواند پیش‌بینیهایی با خطاهای کمتر نسبت به روش‌های متداول رگرسیونی ارائه دهد. Pachepsky et al. (1996) شبکههای عصبی مصنوعی را برای تخمین منحنی رطوبتی از خصوصیات زود یافت خاک بکار برden. آنها نشان دادند که شبکههای عصبی میزان آب را در پتانسیلهای ماتریک انتخاب شده بهتر از رگرسیون تخمین زده است. Schap and Liej (1998) با استفاده از شبکه عصبی مصنوعی توابعی برای تخمین پارامترهای معادلات وانگختن، وانگختن-معلم و گاردنر ایجاد کردند. نتایج این محققین نشان داد که هر چه تعداد داده‌های ورودی مورد استفاده در این توابع بیشتر باشد، صحت توابع افزایش خواهد یافت. Parasuraman et al. (2006) بیان داشتند که شبکه عصبی مصنوعی کارائی بهتری نسبت به شبکه عصبی رزتا در تخمین ویژگیهای هیدرولیکی خاک داشته است که این نشان دهنده اهمیت فرآیند آموزش در شبکه عصبی میباشد. Borgesen et al. (2005) برای تخمین پارامترهای معادله وانگختن از توابع نقطه‌های و پارامتری بوسیله شبکه عصبی مصنوعی استفاده کردند. نتایج این محققین نشان داد که با افزایش میزان رس در خاکها میزان Rishne میانگین مربعات خط افزایش پیدا میکند. Tamari et al. (2005) با استفاده از میزان ماده آلی و رس اقدام به برآورد میزان ظرفیت تبادل کاتیونی خاک به وسیله شبکه عصبی و پنج مدل تجربی که بر پایه روش‌های رگرسیونی میباشند نمودند و نتایج این محققین نشان داد که روش شبکه عصبی از برتری قابل قبولی نسبت به سایر روشها برخوردار میباشد.

با این وجود Tamari et al. (1996) نشان داد که اگر ناپایداری داده‌ها بالا باشد، شبکه عصبی از مدل‌های رگرسیونی خطی بهتر نخواهد بود، اما زمانیکه داده‌هایی با دقت بالا بکار برده شود شبکه عصبی کارآیی بالاتری را نشان میدهد.

Merdun et al. (2006) در پژوهشی در کشور ترکیه برای پیش‌بینی ویژگیهای هیدرولیکی خاک از توابع انتقالی نقطه‌های و پارامتری بوسیله شبکه عصبی و رگرسیون خطی پرداختند و نتایج نشان داد که تفاوت معنیداری بین دو روش مذکور وجود نداشت.

در سالهای اخیر استفاده از سیستمهای بر مبنای قوانین فازی برای پژوهش‌های مختلف مهندسی مورد توجه محققین مختلف بوده است. Mohammadi and Taheri (2004) برای ایجاد توابع انتقالی خاک، دو روش رگرسیون آماری و فازی را مورد مقایسه قرار دادند. نتایج تحقیق نشان داد که روش رگرسیون فازی در شرایطی که روابط ابهامی بین متغیرها و به

مسئله اصلی در این شبکه‌ها تعیین تعداد لایه‌های پنهان و تعداد نزونهای آنها می‌باشد که در این رابطه نظرات متفاوتی وجود دارد. در این مورد Nielson (1987) ثابت کرد که در شبکه‌های عصبی با یک لایه مخفی با تابع سیگموئید (معادله ۱) در لایه میانی و تابع خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود، مشروط به اینکه به اندازه کافی نزون در لایه مخفی وجود داشته باشد این قضیه به تقریب ساز جهانی معروف می‌باشد (Menhaj, 2009).

- در این تحقیق شبکه‌ها با یک لایه مخفی که دارای تابع فعال سازی سیگموئید در لایه مخفی و تابع فعالسازی خطی در لایه خروجی بوده و تعداد نزون‌های آن از یک تا ۱۰ نزون متغیر بوده و بهترین تعداد نزون به صورت سعی و خطا تعیین گردید، مورد بررسی قرار گرفت. نتایج نشان داد که برای ویژگی‌های ظرفیت زراعی، نقطه پژمردگی، ظرفیت تبادل کاتیونی و وزن مخصوص ظاهری به ترتیب ساختارهای ۴۳۱، ۴۲۱، ۴۳۱، ۲۶۱ و ۵۲۱ مناسب تشخیص داده شدند. همچنین به علت کارایی، سادگی و سرعت بالا در این تحقیق الگوریتم آموزشی لونبرگ مارکوارت استفاده گردید (Amini et al. 2005).

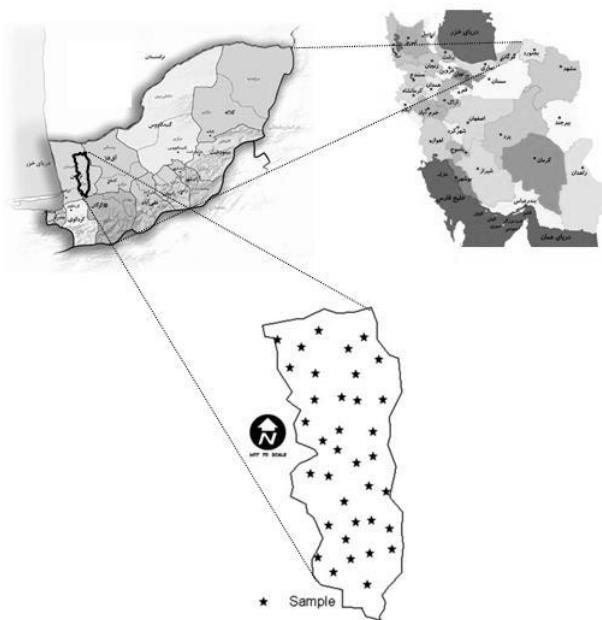
$$O = \frac{1}{1 + e^{net}} \quad (1)$$

که در آن:  $O$  خروجی،  $net$  ورودی تابع خواهد بود.

#### ساختار مدل ANFIS

مدل ANFIS (سیستم فازی تطبیق‌پذیر مبتنی بر شبکه عصبی) اولین بار توسط ژانگ ۱۹۹۳ معرفی شد (Jang et al, 1997). این مدل یک سیستم فازی سوگنو را در یک ساختار عصبی اجرا می‌کند و برای فرآیند آموزش از ترکیبی از روش‌های آموزش پس انتشار خطأ و حداقل مربعات خطأ استفاده می‌کند. مدل ANFIS یک شبکه چند لایه پیشرونده بوده که از الگوریتم‌های یادگیری شبکه‌های عصبی مصنوعی و استدلال‌های فازی برای توصیف یک فضا یا مکان ورودی به یک فضا یا مکان خروجی استفاده می‌کند (Firat and Gungor, 2007). تجربیات اخیر بیانگر قدرت و توانایی ANFIS در مدل سازی فرآیندهای متعدد و مختلف است.

خصوصیاتی از قبیل قدرت یادگیری، نوشتمن و تدوین کردن، هزینه کردن و طبقه‌بندی است. همچنین دارای این حسن بوده که اجازه استخراج قوانین فازی از داده‌های متعدد و تخصصی را داده و به گونه‌های متناسب قوانین پایه و اساسی را می‌سازد. مشکل اصلی این سیستم مدت زمان لازم جهت تهیه ساختار و نحوه آموزش سیستم و تعیین پارامترهای موثر می‌باشد. ANFIS از سویی از توانایی یادگیری شبکه‌های عصبی



شکل ۱- موقعیت منطقه مورد مطالعه و پراکنش نقاط نمونه برداری

#### توابع انتقالی

قبل از ورود عوامل ورودی (متغیرهای مستقل) و ظرفیت تبادل کاتیونی، نقطه پژمردگی، ظرفیت زراعی و وزن مخصوص ظاهری به عنوان خروجیها (متغیر وابسته)، همه آنها تحت آزمون هم راستایی و نرمال بودن قرار گرفتند. آزمون نرمال بودن کولموگروف-اسمیرنوف و نرمال بودن داده‌ها مورد بررسی قرار گرفت. در رگرسیون چندگانه خطی اگر بین متغیرهای مستقل وابستگی خطی قوی مشاهده شود، همراستایی چندگانه به وجود می‌آید. برای چک کردن همراستایی، از رابطه همبستگی بین متغیرهای مستقل استفاده گردید و متغیرهایی که دارای همبستگی زیادی با یکدیگر بودند، حذف گردیدند (Ghrbani and Homaei, 2002).

#### شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک روش شبیه‌سازی می‌باشد که از مطالعه سیستم مغز و شبکه عصبی موجودات زنده الهام گرفته است. یکی از متداولترین شبکه‌های عصبی مورد استفاده، شبکه عصبی پرسپترون چندلایه می‌باشد. این شبکه از یک لایه ورودی، یک لایه خروجی و یک یا چند لایه بین آنها که مستقیماً به داده‌های ورودی و نتایج خروجی متصل نیستند تشکیل یافته‌اند. واحدهای لایه ورودی وظیفه توزیع مقادیر ورودیها به لایه بعد و لایه خروجی نیز پاسخ سیگنالهای خروجی را ارائه میدهد. در این دو لایه، تعداد نزونها برابر با تعداد ورودیها و خروجیها می‌باشد و لایه یا لایه‌های پنهان وظیفه ارتباط لایه‌های ورودی به لایه‌های خروجی و بدست آوردن روابط خطی و غیر خطی را بر عهده دارد (Minansy and McBratney, 1999).

لایه پنجم: لایه پنجم، لایه خروجی بوده که در این لایه هرگره دیگر به مرحله تکمیل خود رسیده و در این لایه خروجی، گرهی که با علامت  $\Sigma$  مشخص شده، خروجی کلی و نهایی را عنوان حاصل جمع تمامی ورودیها محاسبه میکند.

$$O_i^5 = \sum_i W_i^* f_i = \frac{\sum_i W_i^* f_i}{W_i} \quad (5)$$

برای بهینه نمودن مدل ANFIS لازم است که پارامترهای مقدماتی در لایه اول و پارامترهای حاصله در لایه چهارم تعریف شوند. پارامترهای لایه اول به عنوان بخش مرکزی و دامنه تابع عضویت مقدم مطرح میشوند. پارامترهای لایه چهارم با سری  $\{p_i, q_i, r_i\}$  که متناظر با ضریبهای حاصله از معادله چهارم میباشند، تعریف میگردد.

چانگجنگ و همکاران (1993) الگوریتم آموزش هیبرید را برای تعیین پارامترهای ANFIS پیشنهاد دادند. نحوه آموزش شبکه عصبی به صورت یادگیری ناظارتی است. از این رو، هدف این است که با آموزش شبکهها، توابع ناشناخته ارائه شده توسط دادههای آموزشی را دریافت و یاد بگیرد و بتواند متناسب با ارزش پارامترهای ورودی، خروجی را تعیین نماید. از این رو در ساختار ANFIS از الگوریتم آموزش هیبرید استفاده می شود.

#### از زیبایی مدلها

به منظور مقایسه عملکرد مدلهای ANFIS، شبکه عصبی مصنوعی و رگرسیون چند متغیره از پارامترهای خطای استاندارد نسبی (RSE) و میانگین خطای (ME)، مجدور میانگین مربعات خطای (RMSE) که از روابط زیر قابل محاسبه میباشند. (Navabian et al, 2003, Amini et al, 2005)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2} \quad (6)$$

$$RSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2} / Z_{ave} \quad (7)$$

$$ME = \frac{1}{n} \sum (Z_o - Z_p) \quad (8)$$

$$RI = \left( \frac{RMSE_a - RMSE_b}{RMSE_a} \right) \times 100 \quad (9)$$

که در آنها:  $Z_0$  مقادیر پیش بینی شده،  $Z_p$  مقادیر مشاهداتی،  $Z_{ave}$  متوسط مقادیر مشاهداتی و  $n$  تعداد دادهها میباشد.

#### نتایج

در ابتدا، دادهها را به دو دسته تقسیم کرده، به طوریکه دادهها برای آموزش و مابقی دادهها یعنی 20٪ برای اعتبارسنجی

مصنوعی برای تعریف نحوه ارتباط ورودی - خروجی بهره گرفته و از سویی دیگر با بهره‌گیری از قوانین فازی ساختار ورودی سیستم را تهیه و پایه ریزی میکند.

برای سهولت فرض میشود که سیستم استنتاج فازی دارای 2 ورودی است:  $y, x$  و یک خروجی  $z$  لازم به ذکر است که سیستم فازی مورد استفاده سیستم استنتاج (5 و 22) با دو قانون زیر است:

$$\text{قانون اول } (2) \quad \text{If } x \text{ is } A_1, y \text{ is } B_1 \text{ then } f_1 = P_1 x + q_1 y + r_1$$

$$\text{قانون دوم } (3) \quad \text{If } x \text{ is } A_2, y \text{ is } B_2 \text{ then } f_2 = + \triangle q_2 y + r_2$$

$P_1 x$

مدل ANFIS انتخاب شده شامل 5 لایه است. لایه اول یا عناصر ورودی: گرههای موجود در این لایه سریهای فازی در ارتباط با بخش مقدم قوانین فازی را ارائه میدهند. این لایه دارای پارامترهای است که موقعیت بخش مرکزی و اصلی هر سری فازی را کنترل میکند. در این مطالعه از تابع عضویت گوسی برای تعیین درجات عضویت استفاده شد و تابع عضویت اینگونه تعریف شد:

$$M_{Ai}(x) = e^{-\frac{(x-c_i)^2}{2\sigma_i^2}} \quad (4)$$

که در آن:  $C_i$  بیانگر مرکز تابع شماره یک است،  $\sigma_i$ : دامنه و عرض تابع عضویت را نشان میدهد. خروجیهای این لایه مقادیر مقدم توابع عضویت، متناسب با ورودیهای فازی سیستم هستند.

لایه دوم: هر گره در این لایه موظف به محاسبه نتایج ورودیهای خود است. خروجی لایه به صورت  $W_i - i=1,2$   $= M_{Ai}(x) * M_{Bi}(y)$  در این رابطه  $M_{Ai}$  و  $M_{Bi}$  سریهای فازی هستند که به ترتیب برای متغیرهای  $y, x$  تعریف شده‌اند. در این لایه میزان فعالسازی قوانین خاص فازی تعیین میشود.

لایه سوم: در این لایه بخش نسبت درجه فعالیت مربوط به هر یک از قوانین فازی نرمال میشدن. رابطه مربوط در این لایه بدین شرح است:

$$W_i^* = \frac{W_i}{W_1 + W_2} \quad i=1,2 \quad (3)$$

لایه چهارم: گرههای موجود در این لایه دیگر به صورت تطبیق‌پذیر درآمده و هر تابع موجود گرهها یک مدل درجه اول با پارامترهای حاصله ارائه میدهند. خروجی حاصله از این لایه به صورت زیر نشان داده می شود.

$$\begin{aligned} & \text{خروجی لایه سوم} \gg W_i \\ & \text{سری پارامتری هستند} \gg \{p_i, q_i, r_i\} \\ & O_i^* = W_i^* f_i = W_i^* (p_i x + q_i y + r_i) \end{aligned} \quad (4)$$

برای انتخاب داده‌های آزمون و تست خود از تی تست استفاده کردند و بیان داشتند اگر بین داده‌های تست و آموزش تفاوت معنیداری وجود نداشته باشد، میتوان انتظار نتایج بهتری را از مدل داشت. در جدول (1) معیارهای آماری مربوط به داده‌های تست و آموزش ارائه شده است.

اختصاص داده شد (Menhaj, 2009, Amini et al, 2005). برای این منظور دو دسته داده بطور تصادفی تعیین گردید بطوریکه از نظر معیارهای آماری از قبیل میانگین و انحراف معیار تا حد ممکن شبیه یکدیگر باشند. همچنین این دو گروه داده تفاوت معنیداری در سطح 5٪ نداشتند. Tomasela et al. (2000)

جدول 1 - پارامترهای آماری داده‌های استفاده شده در مدل نروفازی، شبکه عصبی و رگرسیون چند متغیره

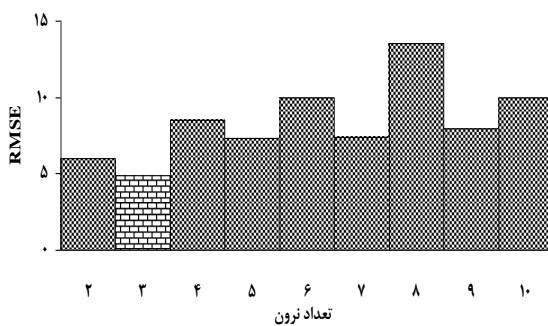
آهک٪	رطوبت٪	کربن-آلی٪	شن٪	رس٪	وزن مخصوص ظاهری (g/cm <sup>3</sup> )	CEC(Cmol/kg)	نقاطه پژمردگی٪	ظرفیت زراعی٪	پارامتر آماری
0	24/0	0/1	4/0	16/0	11/6	1/2	6/0	5/1	19/7
49/1	86/5	15/0	60/0	73/0	75/4	1/6	56/0	30/2	46/7
16/1	52/9	1/4	19/8	40/4	39/4	1/4	18/9	17/1	31/2
9/8	12/9	2/6	12/4	12/4	14/5	0/1	9/3	6/2	7/0
1/0	-0/1	0/4	1/1	0/2	-0/6	0/36	0/7	1/1	-0/59
0/31	0/31	0/3	1/2	0/5	0/1	-0/22	0/6	0/4	0/3
داده‌های آموزش (12)									
0	25/2	0/1	6/0	21/0	16/4	1/3	6/6	6/2	15/9
56/1	74/2	10/2	46/4	61/4	68/0	1/6	43/4	27/0	44/7
19/4	47/7	1/3	20/7	42/1	37/2	1/5	20/4	16/7	30/7
12/6	11/6	2/2	12/3	11/5	13/5	0/1	8/5	5/3	7/8
1/1	0/3	0/2	-./6	-1/1	-0/5	-0/1	0/3	-0/8	-0/8
0/8	0/6	0/9	0/6	-0/1	0/6	-0/3	0/5	-0/1	0/3
داده‌های تطبیق‌نجی (28)									
چولگی									

(2) و (3) ملاحظه می‌شود که حداقل مقدار RMSE در پارامتر ظرفیت زراعی مربوط به شبکه با سه نرون در لایه مخفی و برای نقطه پژمردگی شبکه با دو نرون در لایه مخفی میباشد. همان طور که در شکلها دیده میشود تغییرات RMSE دارای روند مشخصی نمیباشد، چون شبکه عصبی یک مدل جعبه سیاه میباشد و وزنهای به طور تصادفی انتخاب می‌شوند نه میتوان این روند موجود را به طور کامل توضیح داد. فقط باعث با سعی و خطأ بهترین ساختار را بدست آورد. اما توجه که می‌شود آورده این است که با پیچیده تر شدن مدل شبکه عصبی بیش از حد آموزش می‌خند و قادر به برآش مناسب بر روی داده‌های جدی نمیباشد. مقادیر RMSE و RSE برای پارامتر ظرفیت زراعی با بهترین ساختار شبکه عصبی به ترتیب 5/8 و 0/19 و پارامتر نقطه پژمردگی 4/5 و 0/27 بدست آمده است. در هر دو پارامتر با افزایش تعداد نرونها عملکرد مدلها بدتر شده است.

نتایج شبکه عصبی پس از تعیین مجموعه داده‌های تست و آموزش، داده‌های ورودی به شبکه را باید استانداردسازی 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 نرونها حتی به حد آتش رسیده، در حالی که برخی دیگر از نرونها حتی به آستانه فعالیت نیز نرسیده‌اند (Menhaj, 2007). لذا در ابتدا، داده‌ها را با استفاده از رابطه 10 استاندارد شده، یعنی بین یک دامنه عددی که معمولاً 0/0 و 0/9 می‌باشد، قرار گیرند.

$$y = 0.8 \times \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + 0.1 \quad (10)$$

که در آن:  $X_{\min}$  کوچکترین داده و  $X_{\max}$  بزرگترین داده سری داده‌های ورودی میباشد. با استفاده از این رابطه، داده‌های ورودی بین 0/1 و 0/9 قرار میگیرد. در مرحله بعد، مدل مختلف شبکه عصبی با یک لایه مخفی که تعداد نرونها آن به بین 2 تا 10 نرون میباشد، ساخته و ساختار بهینه شبکه به روش سعی و خطأ با استفاده از معیارهای RMSE و RSE تعیین گردید. برای پیش‌بینی درصد رطوبت در نقطه ظرفیت زراعی و پژمردگی، ورودیهای شبکه ویژگیهای درصد رس، سیلت، شن و کربناتی بود. برای این دو ویژگی مقادیر RMSE در شکل‌های (2) و (3) ارائه شده است. با توجه به شکل‌های



شکل 2- مقادیر RMSE برای تعداد نرون متفاوت در پیش‌بینی پارامتر FC

### نتایج رگرسیون چند متغیره خطی

برای تعیین رگرسیون چند متغیره پارامترهای مورد مطالعه، رابطه رگرسیونی مربوطه را با استفاده از داده های آموزش تعیین کرده که به صورت روابط (11)، (12)، (13) و (14) می-

باشد. در رگرسیون چندگانه خطی، اگر بین متغیرهای مستقل وابستگی خطی قوی مشاهده شود، همراستائی چندگانه به وجود می‌آید (Navabian et al, 2003). از آنجائی که فراوانی نسبی ذرات شامل رس، شن و سیلت همراستا بودند، برای جلوگیری از همراستائی در توابع به دست آمده، در ایجادتابع انتقالی به جای یکی از آنها از نسبت رس به سیلت استفاده شده است (1).

$$R^2=0.83 \quad (p<0.05) \quad FC=-33.7+0.615 \text{ Sand} + 0.731 \text{ Clay/Silt} + 0.325 \text{ OC} \quad (11)$$

$$R^2=0.86 \quad (p<0.05) \quad PWP= 5.8 - 0.002 \text{ Sand Sand} + 0.151 \text{ Clay/Silt} + 0.121 \text{ OC} \quad (12)$$

$$R^2=0.89 \quad (p<0.05) \quad CEC = 2.23 + 4.11 \text{ OC} + 0.316 \quad (13)$$

$$R^2=0.81 \quad (p<0.05) \quad BD= 0.63 + 0.007 \text{ Sand} + 0.009 \text{ Clay/Silt} + 0.001 \text{ CaCO}_3 - 0.0008 \text{ SP} \quad (14)$$

### نتایج ANFIS

در این ساختار مجموعه های 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. نتایج و خصوصیات مدل ANFIS به کار رفته برای هر یک از پارامترها نیز در جدول 2 ارائه شده است. بهترین ساختار با توجه به معیار RMSE تعیین گردید.

جدول 2- ویژگی های مدل ANFIS انتخابی برای پیش‌بینی ویژگیهای خاک

			تعداد توابع	نوع تابع	روش	روش دلایل کار	تکرار	عضویت	یادگیری	مثلى
					ظرفیت زراعی	میانگین وزنی	پس خور	مثلى		
3	200	200			ظرفیت پذمردگی	میانگین وزنی	پس خور	مثلى		
3	3000	3000			ظرفیت تبدال کاتیونی	میانگین وزنی	پس خور	گوسی		
3	3800	3800			وزن مخصوص	میانگین وزنی	هیبرید	مثلى		
5	1100	1100								

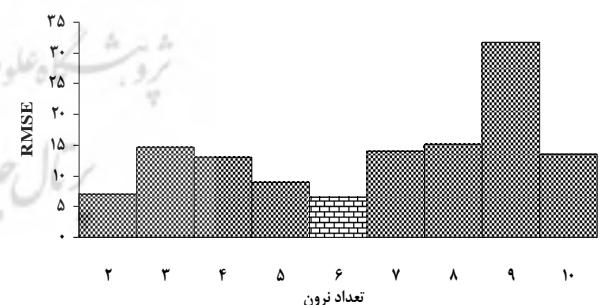
### نتایج ارزیابی مدلها

نتایج مربوط به نروفازی، شبکه عصبی و رگرسیون چند متغیره مربوط به پارامترهای مورد اندازه‌گیری در جدول 3 آورده شده است. با توجه به این جدول ملاحظه میشود در کل بهترین عملکرد در همه برای پیش‌بینی ویژگیهای مربوط 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 بهترین عملکرد را به خود اختصاص داده است. مقدار پایین RMSE برای اکثر مدلها، پایین بودن خطأ و دقت بالای مدلها برآش داده شده را نشان میدهد. همچنین نتایج نشان داد که در سطح ۵٪ تفاوت معنیداری بین مدل -

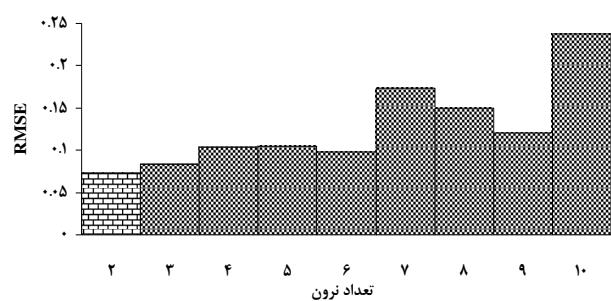


شکل 3- مقادیر RMSE برای تعداد نرون متفاوت در پیش‌بینی پارامتر PWP

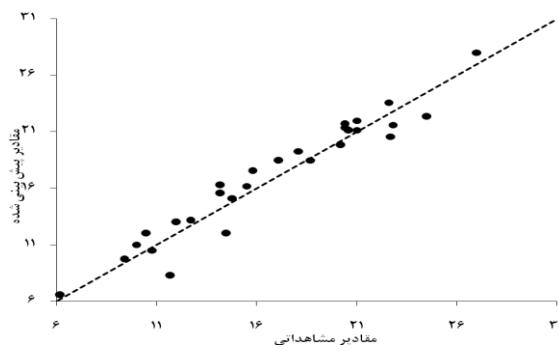
همچنین برای پیش‌بینی ظرفیت تبدال کاتیونی ورودی های شبکه شامل درصدهای رس و کربن آلی و برای پیش‌بینی وزن مخصوص ظاهری، ورودیهای شبکه شامل درصدهای رس، سیلت، شن، آهک و رطوبت اشباع میباشد. برای انتخاب ویژگیهای ورودی از رگرسیون گام به گام در سطح ۰.۵ استفاده گردید. در این قسمت مقادیر RMSE برای تعداد نرون های مختلف بر حسب عوامل انتخابی در اشکال (4) و (5) ارائه شده است. با توجه به اشکال فوق ملاحظه میشود حداقل مقدار RMSE برای پارامتر ظرفیت تبدال کاتیونی مربوط به شبکه با شدن نرون در لایه مخفی میباشد. همچنین برای وزن مخصوص ظاهری، بهترین ساختار با توجه به معیارهای مورد ارزیابی، شبکه عصبی با دو نرون در لایه مخفی بود. مقادیر RMSE پارامتر ظرفیت تبدال کاتیونی برای شبکه با سه نرون در لایه مخفی به ترتیب ۶/۴۹ و ۰/۳۱ و برای وزن مخصوص ظاهری به ترتیب ۰/۰۷ و ۰/۰۵ بدست آمده که از لحاظ هر دو معیار مذکور برتر از مدلها دیگر میباشد.



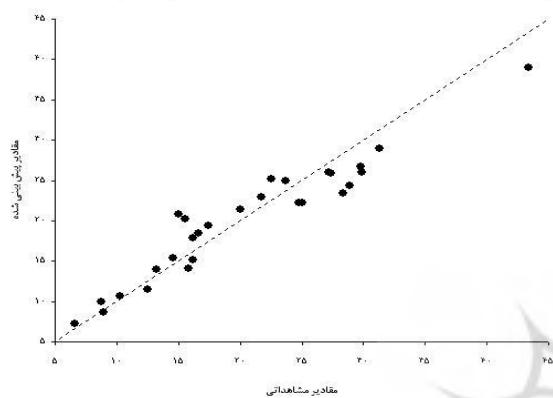
شکل 4- مقادیر RMSE برای تعداد نرون متفاوت در پیش‌بینی پارامتر CEC



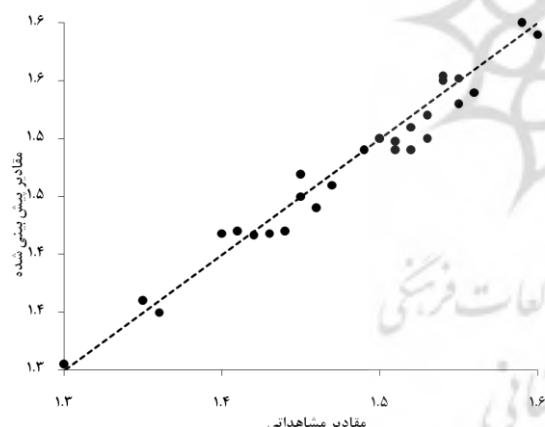
شکل 5- مقادیر RMSE برای تعداد نرون متفاوت در پیش‌بینی پارامتر BD



شکل 7- دیاگرام پراکنش برای مقادیر مشاهداتی و شبیه سازی شده در PWP



شکل 8- دیاگرام پراکنش برای مقادیر مشاهداتی و شبیه سازی شده در CEC



شکل 9- دیاگرام پراکنش برای مقادیر مشاهداتی و شبیه سازی شده در BD

هایی که ویژگیهای FC، PWP و Bd را تخمین زده‌اند، وجود ندارد.

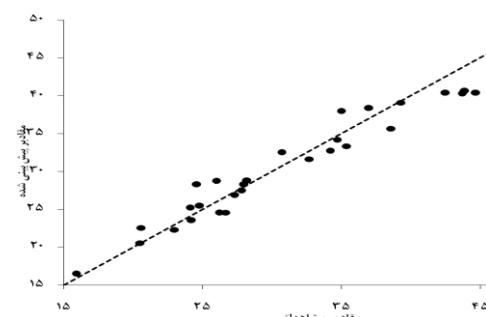
این مسئله بخصوص در مورد BD دیده می‌شود، که علت آن میتواند مربوط به ویژگی این خصوصیت و ارتباط متغیر مذکور به چندین پارامتر مختلف باشد. از طرف دیگر نتایج ارتباط خطی خوب بین BD با پارامترهای ورودی را نشان میدهد، که در این شرایط به کار بردن مدل‌های غیرخطی نتوانسته تغییر معنیداری را در داده‌های پیش‌بینی شده ایجاد کند. در چنین شرایطی برای ارزیابی کارائی مدلها میتوان از شاخص RI استفاده نمود. این آماره نشان‌دهنده میزان کاهش خطا در مدل‌های مختلف نسبت به روش رگرسیون می‌باشد. همانطور که در جدول (3) ارائه شده، مدل نروفازی دقت پیش‌بینی را نسبت به روش رگرسیون خطی چندگانه برای ویژگیهای PWP، FC و CEC و Bd به ترتیب به میزان 34، 10، 78 و 5 درصد، افزایش داده است.

جدول 3- مقایسه نتایج بدست آمده از مدل‌های ANFIS، ANN و MR

#### جهت پیش‌بینی خصوصیات خاک

خصوصیت خاک	مدل	RSE	RMSE	ME	RI
نروفازی	شبکه عصبی	0/17	4/4	0/35	34
شبکه عصبی	رگرسیون	0/19	5/8	0/45	13
رگرسیون	رگرسیون	0/21	6/7	0/55	0
نروفازی	شبکه عصبی	0/27	4/2	-0/24	10
شبکه عصبی	رگرسیون	0/27	4/5	-0/29	4
رگرسیون	رگرسیون	0/28	4/7	-0/34	0
نروفازی	شبکه عصبی	0/4	5/3	0/33	78
شبکه عصبی	کاتیونی	0/31	6/4	0/47	73
کاتیونی	رگرسیون	1/2	24/4	0/51	0
نروفازی	شبکه عصبی	0/04	0/071	0/005	5
شبکه عصبی	وزن مخصوص	0/05	0/073	0/007	2
وزن مخصوص	رگرسیون	0/06	0/075	0/008	0

در اشکال (6) تا (9) دیاگرامهای پراکنش داده‌های 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 45 درجه می‌باشد که نشان از دقت بالای برآورد توسط مدل نروفازی در هر چهار پارامتر مورد بررسی می‌باشد.



شکل 6- دیاگرام پراکنش برای مقادیر مشاهداتی و شبیه سازی شده در F.C.

در این تحقیق با استفاده از مدل‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره، مقادیر رطوبت ظرفیت زراعی، رطوبت نقطه پذیردگی، ظرفیت تبادل کاتیونی و وزن مخصوص ظاهری خاک برآورده گردید. انتخاب پارامترهای ورودی بر اساس روش SPSS شده و بعد از انتخاب متغیرهای وابسته و مستقل داده‌ها وارد شده گام به گام صورت گرفت. به این ترتیب که همه رگرسیون گام به گام را در سطح ۰.۵٪ اجرا کرده و نتیجه متناسبهای موثر بر روی ویژگی مورد نظر مشخص شد. در اکثر کارهای صورت گرفته برای پیش‌بینی ظرفیت تبادل کاتیونی از

روابط ناشناخته بین متغیرها رو به رو هستیم. در چنین شرایطی، از مدلهایی باید بهره گرفت که قادر به ارائه الگوهای مناسبتر باشند، به گونه‌ای که این مدلها بتوانند انطباق بیشتری با دنیای واقعی داشته باشند. بدین ترتیب با توجه به ماهیت ابهامی پدیدهای مرتبط با خاک یا تقریبی بودن مقادیر اندازهگیری شده خصوصیات مختلف خاک، به نظر میرسد کارائی بالاتر مدل مبتنی بر مجموعه‌های فازی در پردازش توابع انتقالی خاک به همین علت باشد (Mahammdi, 2007).

Mohammadi and Taheri (1384) نتیجه گرفتند که روش رگرسیون فازی در شرایطی که روابط ابهامی بین متغیرها و به طور کلی در مواردی که با خطاها ناشی از ابهام در ساختار معادلات رگرسیونی مطرح است، میتواند مکمل و یا جایگزین مناسبی برای روش رگرسیون آماری تلقی شود.

در تحقیق حاضر نیز نتایج مشابهی به دست آمد. به طوری که شبکه عصبی مصنوعی در مقایسه با نروفازی دارای کارائی کمتری در برآورد پارامترهای خاک بود. مقدار RMSE محاسبه شده مدل نروفازی در مورد تمام پارامترهای خاک کمتر از شبکه عصبی و رگرسیون میباشد که نشان دهنده دقیق‌تر این مدل در مقایسه با سایر مدلها میباشد. البته نتایج نشان داد که در سطح 5٪ تفاوت معنیداری بین مدلهایی که ویژگیهای FC، PWP و Bd را تخمین زده‌اند، وجود ندارد. اما برای ارزیابی کارائی مدلها از شاخص RI استفاده گردید که این آماره نشان داد که مدل نروفازی دقیق‌تر پیش‌بینی را نسبت به روش رگرسیون خطی چندگانه برای ویژگیهای FC، PWP و CEC و Bd به ترتیب به میزان 34، 30، 78 و 5 درصد، افزایش داده است. محققین بسیاری بر کارائی مدل نروفازی در علوم خاک اشاره داشته‌اند (Feng et al., 2006 and Amini et al., 2005).

امروزه خاکشناسان، بیش از گذشته، نسبت به تغییرپذیری پیوسته خاکها در گسترهای مکانی و چگونگی توصیف و ساختاربندی آنها حساس میباشند و نسبت به عدم قطعیت سیستم طبیعی خاک و کارکردهای آن در فرآیند شناخت و درک این سیستم، آگاه میباشند و از راه کارهای سنتی پردازش آن نامطمئن هستند. بخش مهمی از این عدم قطعیت، در نتیجه فراوانی و پیچیدگیهای اطلاعات و آگاهی‌های بشر و رشد شتابان ساختارهای علمی و تکنولوژی است. حل چنین به ظاهر تناقض، نیازمند مسلح شدن به نظریه‌های مبنی بر منطق کارآمد و جامع نگر است. در حال حاضر، تنها گزینه در پیش روی انسانها، نظریه فازی است (Mohammadi, 2007). لذا پیشنهاد میگردد در مطالعات آتی در زمینه علوم

مقادیر رس و کربن آلی استفاده شده است (Krogh et al, 2000, Bell and Van, 1995, Amini et al, 2005). همچنین برای برآورد خصوصیات هیدرولیکی خاک، از اجزاء بافت و ماده آلی به عنوان پارامترهای مستقل نام برده‌اند (Givi and Prasher, 2004, Heusler et al, 2005, Vos et al. 2005). در نتیجه در تحقیق حاضر از عوامل رس، کربن آلی، آهک و درصد رطوبت اشباع به عنوان ورودی مدلها استفاده گردید.

پس از تعیین ساختار بهینه هر یک از مدلها، با استفاده از معیار آماری RMSE اقدام به پیش‌بینی خصوصیات خاک با استفاده از مدل مربوطه گردید. نتایج این بررسی نشان داد که در مورد مطالعه شده، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی کارائی بهتر داشته است. زیرا احتمالاً از یک طرف کارائی توابع انتقالی بدست آمده در مناطق مختلف با هم متفاوتند و از طرف دیگر بر طبق نظر Schap 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 رگرسیون داشته است. نتایج بدست آمده از این تحقیق با آنچه که Amini et al. (2005) در برآورد CEC در منطقه اصفهان بدست آورده، همخوانی دارد. ایشان نیز نشان داد که شبکه‌های عصبی کارائی بالاتری در برآورد ظرفیت تبادل کاتیونی خاک نسبت به سایر توابع انتقالی که به صورت خطی هستند، دارد.

Pachepsky et al. (1996) با استفاده از آمارهای ضربی همبستگی و ریشه میانگین مربعات خطأ به بررسی شبکه عصبی مصنوعی و آنالیز رگرسیون پرداختند. آنها نتیجه گرفتند که شبکه عصبی برآورد بهتر و با خطا کمتری، بر اساس داده‌های زودیافت خاک دارد. نتایج مشابهی توسط Tammarri 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 آورده‌اند. Tammarri et al. (1996) همچنین نشان دادند که اگر ناپایداری داده‌ها بالا باشد، شبکه عصبی از مدل‌های رگرسیونی خطی بهتر نخواهد بود، اما زمانیکه داده‌هایی با دقیق‌تر بکار برده شوند شبکه عصبی کارائی بالاتری را نشان میدهد.

همانطور که گفته شد، تمامی این روشها بر پایه فرض دقیق بودن متغیرهای مورد مطالعه و مشاهدات مربوط به آنها استوار است و روابط بین متغیرها نیز دقیق فرض میگردد. حال آنکه در سیستمهای طبیعی مانند خاک، عموماً با مشاهدات یا

مدل نروفازی دارای بالاترین دقت در پیش‌بینی پارامترهای خاک دارا می‌باشد. بعد از این مدل شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی پایه کارائی بهتر داشته 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 کارائی بالاتر مدل مبنی بر مجموعه‌های فازی در پردازش توابع انتقالی خاک به همین علت باشد.

## REFERENCES

- Ahamed, T., Rao, K. and Murthy, J. (2000) Fuzzy class membership approach to soil erosion modeling. *Agric Syst*, 63(2), 97– 110.
- Amini, M., Afyuni, M., Fathianpour, N., Khademi, H. and Fluchler, H. (2005) Continuous soil pollution mapping using fuzzy logic and spatial interpolation. *Geoderma*, 124 (2005), 223–233.
- 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. *Euro. J. Soil Sci*, 53, 748–757.
- Bell, M. A. and van Keulen, H. (1995) Soil pedotransfer functions for four Mexican soils. *J. Soil Sci. Soc. Am*, 59, 865–871.
- Black, C. A. (1982) Method of soil analysis, (Vol. 2), Chemical and microbiological properties, *American Society of Agronomy, INC.*
- Borgesen, C. D. and Schaap, M. (2005) Point and parameteer pedotransfer functions for water retention predictions for Danish soils. *Geoderma*, 127, 154–167.
- Bouma, J. (1989) Using soil survey data for quantitative land evaluation. *Soil Sci*, 9, 177–213.
- Bower, C. A., Reitmeir, R. F. and Fireman, M. (1952) Exchangeable cation analysis of saline and alkali soils. *Soil Sci*, 73, 251–261.
- Feng, Q., Zhu, A., Harrower, M. and Burt, J. E. (2006) Fuzzy soil mapping based on prototype category theory. *Geoderma*, 136, 774–787.
- Firat, M. and Gungor, M. (2007) River flow estimation using adaptive neuro fuzzy inference system. *Math & Comp in Simulation*, 75, 87–96.
- Gee, G. and Bauder, J. W. (1986) Particle size distribution analysis. In: Klute, A. (Ed.), Method of soil analysis. Part 1, second ed. Agron. Monogr. 9. ASA and SSSA, Madison, WI, pp. 383–411.
- Ghorbani-Dashtaki, Sh. and Homaei, M. (2002) Prediction of parametric hydraulic function in unsaturated soils using pedotransfer functions. *Agri. Engi. Res. J*, 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. *Agri. Water Manag*, 70, 83–96.
- Heuscher, S.A., Brandt, C. C. and Jardin, P.M. (2005) Using soil physical and chemical properties to estimate bulk density. *J. Soil Sci. Soc. Am*, 69, 51–56.
- Jang, J., Sun, C. and Mizutani, E. (1997) Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence. Prentice Hall, Upper Saddle River, New Jersey, USA.
- Kalkan, E., Akbulut, S. and Tortum, A. (2008) Prediction of the unconfined compressive strength of compacted granular soils by using inference systems. *Environ Geol*, 5, 324– 330.
- Kaur, R., Kumar, S. and Gurung, H. P. (2002) A pedotransfer function soil data and its comparison with existing PTFs. *Aust. J. Soil Res*, 40, 847–857.
- Krogh, L., Breuning-madsen, H. and Greve, M. H. (2000) Cation exchange capacity pedotransfer function for Danish soils. *Soil and Plant Sci*, 50, 1–12.
- McBratney, A. B. and Odeh I. O. A. (1997) Application of fuzzy sets in soil science: fuzzy logic, fuzzy measurements and fuzzy decisions. *Geoderma*, 77, 85–113.
- Menhaj, M. (2009) Fundamental of Artificial neural networks. Amirkabir Press. (In Farsi)
- Merdun, H., Ozer, C., 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 & Till Res*, 90, 108–116.
- Metternicht, G. And Gonzalez, S. (2004) Foundations of a fuzzy exploratory model for soil erosion hazard prediction. *Environ Model & Soft*, 20 (6), 715–728.
- Minasny, B. and McBratney, A. B. (2002) The Neuro-n method for fitting neural network parametric pedotransfer functions. *J. Soil Sci. Soc. Am*, 66, 352–361.
- 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.
- Mohammadi, J. (2006) Pedometrics. Tehran: Pelk press. (In Farsi)
- Mohammadi, J. (200) Testing an artificial neural network for predicting soil water retention characteristics from soil physical and chemical

خاک بخصوص توسعه توابع انتقالی از نظریه مجموعه‌های فازی استفاده گردد.

## نتیجه‌گیری

برای پیش‌بینی ظرفیت تبادل کاتیونی، عوامل رس و کربن آلی و برای پیش‌بینی وزن مخصوص ظاهری عوامل بافت، آهک و درصد رطوبت اشباع و برای پیش‌بینی رطوبت زراعی و پژمردگی دائم از بافت و کربن آلی استفاده گردید. با توجه به معیارهای ارزیابی (RI، ME و RMSE)، نتایج بررسی نشان داد که

- properties. 17<sup>th</sup> WCSS. Thailand. Paper No. 221.
- Mohammadi, J. and Taheri, M. (2005) Estimation of pedotransfer function using fuzzy regression. *Journal of Agri Sci & Tech*, 2, 51-60. (In Farsi)
- Navabian, M., Liaghat, A. and Homari, M. (2003) Determination of soil saturated hydraulic conductivity using pedotransfer function. *Agri. Engi. Res. J*, 4 (16), 1-12. (In Farsi)
- Pachepsky, Y. A., Timilin, D. and Varallyay, G. (1996) Artificial neural networks to estimate soil water retention from easily measurable data. *J. Soil Sci. Soc. Am*, 60, 727-733.
- Parasuraman, K., Elshorbagy, C. and Si, B. (2006) Estimating saturated hydraulic conductivity in spatially variable fields using neural network in Ensembles. *J. Soil Sci. Soc. Am*, 70, 1851-1859.
- Schaap, M. G. and Leij, F. J. (2000) Improved prediction of unsaturated hydraulic conductivity with the Mualem-Van Genuchten model. *J. Soil Sci. Soc. Am*, 64, 843-851.
- Schaap, M. G., Leij, F. J. and van Genuchten, M. Th. (1998b) Neural network analysis for hierarchical prediction of soil hydraulic properties. *J. Soil Sci. Soc. Am*, 62, 847-855.
- Sparks, D. L., Page, A. L., Helmke, P. A., Leopert, R. H., Soltanpour, P. N., Tabatabai, M. A., Johnston, G. T. and Summer, M. E. (1996) Methods of soil analysis, SSSA, Madison, Wisconsin.
- Tamari, S., Wosten, J. H. M. and Ruz-suarez, J. C. (1996) Testing an artificial neural network for predicting soil hydraulic conductivity. *J. Soil Sci. Soc. Am*, 60, 1732-1741.
- Tomasella, J., Hodnett, M. G. and Rossato, L. (2000) Pedotransfer functions for the estimation of soil water retention in Brazilian soils. *J. Soil Sci. Soc. Am*, 49, 1100-1105.
- Vos, B. D., Meirvenne, M. V., Quataert, P., Deckers, J. and Muys, B. (2005) Predictive quality of pedotransfer functions for estimating bulk density of forest soils. *J. Soil Sci. Soc. Am*, 69, 500-510.
- Zhu, X., Hudson, B., Burt, J., Lubich, K. and Simonson, D. (2001) Soil Mapping Using GIS, Expert Knowledge, and Fuzzy Logic. *J. Soil Sci. Soc. Am*, 65, 1463-1472.

