

## مقایسه روش‌های نروفازی، الگوریتم ژنتیک، شبکه عصبی، و رگرسیون چندمتغیره در پیش‌بینی شوری خاک (مطالعه موردی: شهرستان اردکان)

- ❖ روح‌الله تقی‌زاده مهرجردی؛ استادیار دانشکده کشاورزی و منابع طبیعی دانشگاه اردکان
- ❖ فریدون سرمدیان؛ استاد گروه مهندسی علوم خاک، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران
- ❖ غلامرضا ثوابی؛ استاد گروه مهندسی علوم خاک، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران
- ❖ محمود امید؛ استاد گروه مهندسی ماشین‌آلات کشاورزی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران
- ❖ نورایر تومانیان؛ استادیار پژوهشی مرکز تحقیقات کشاورزی و منابع طبیعی اصفهان
- ❖ محمدجواد روستا؛ عضو هیئت علمی مرکز ملی تحقیقات شوری
- ❖ محمدحسین رحیمیان؛ کارشناس سنجش از دور و GIS، مرکز ملی تحقیقات شوری

### چکیده

در سال‌های اخیر از روش‌های غیرمستقیم برای برآورد شوری خاک استفاده می‌شود. بدین منظور، در این پژوهش ششصد نمونه جمع‌آوری شده از منطقه اردکان آزمایش شد و قرائت‌های افقی - عمودی دستگاه القای الکترومغناطیس و پارامترهای سطح اراضی - شامل شاخص اراضی، شاخص خیسبی، و انحنا شیب - به عنوان ویژگی‌های زودیافت استفاده شد و میزان شوری خاک به صورت وزنی در اعماق ۳۰ و ۱۰۰ سانتی‌متری به عنوان ویژگی‌های دیریافت تخمین زده شد. در این زمینه، داده‌ها به دو سری تقسیم شد: سری آموزشی (۸۰٪ داده‌ها)؛ سری ارزیابی (۲۰٪ داده‌ها). به منظور مدل‌سازی و پیش‌بینی شوری، از مدل‌های نروفازی، شبکه عصبی مصنوعی، الگوریتم ژنتیک، و رگرسیون چندمتغیره استفاده شد. نتایج ارزیابی مدل‌ها - بر اساس شاخص‌های ریشه مربعات خطا، میانگین خطا، خطای استاندارد نسبی، و ضریب تبیین - نشان داد که مدل نروفازی دارای بالاترین دقت در پیش‌بینی ویژگی‌های خاک است، به طوری که این مدل به میزان ۱۷ و ۱۱ درصد دقت پیش‌بینی شوری را، به ترتیب، در اعماق ۳۰ و ۱۰۰ سانتی‌متری، نسبت به روش رگرسیون خطی چندگانه، افزایش داده است. پس از این مدل، الگوریتم ژنتیک و شبکه‌های عصبی مصنوعی، نسبت به معادلات رگرسیونی، کارایی بهتری داشت.

واژگان کلیدی: الگوریتم ژنتیک، شوری خاک، شبکه عصبی مصنوعی، رگرسیون چندمتغیره، نروفازی.

## مقدمه

اقدامات انجام شده برای پایش و ارزیابی شوری خاک، به طور فزاینده‌ای، در سطح دنیا در حال گسترش است. این در حالی است که نمونه برداری مستقیم همراه با اندازه‌گیری‌های آزمایشگاهی یا صحرایی، معمولاً، پرهزینه و وقت‌گیر بوده و، در نتیجه، برای اهداف کاربردی دارای محدودیت است. بنابراین، در سال‌های اخیر برای تخمین شوری خاک از روش‌های غیرمستقیم استفاده می‌شود (Bouma, 1989). در دو دهه اخیر، بسیاری از تکنیک‌های جدید، مانند آرایه ونر<sup>۱</sup> (Rhoades & Ingvalson, 1971)، پروب‌های هدایت الکتریکی رودز (Rhoades, 1976)، روش انعکاس سنجی زمانی<sup>۲</sup> یا TDR، و روش القای الکترومغناطیسی<sup>۳</sup> (McNeill, 1980)، برای اندازه‌گیری غیرمستقیم شوری خاک، در شرایط مزرعه، استفاده شده‌اند. در این میان، تکنیک القای الکترومغناطیسی، به سبب آنکه برای اندازه‌گیری به نمونه‌گیری از خاک نیازی ندارد، از سهولت و راحتی بیشتری برخوردار است. Triantafilis et al. (2001) از داده‌های EM برای پیش‌بینی شوری خاک استفاده کردند. Saey et al. (2009) نیز از داده‌های EM برای پیش‌بینی بافت خاک در کشور بلژیک استفاده کرده و کارایی این داده‌ها را تأیید کردند. Sudduth et al. (2001) از داده‌های EM<sup>۳۸</sup> برای پیش‌بینی شوری خاک در کشور امریکا استفاده کردند و به نتایج قابل قبولی دست یافتند. علاوه بر این، برای پیش‌بینی شوری خاک می‌توان از پارامترهای اراضی نیز استفاده کرد (Sheng, et al., 2009). McKenzie & Austin (1993) جهت پهنه‌بندی شوری خاک، در کشور استرالیا، از مشتقات اولیه و ثانویه نقشه رقوم ارتفاع و برای مدل کردن از روش رگرسیون استفاده کردند.

برای ارتباط دادن متغیرها با میزان شوری خاک روش‌های مختلفی وجود دارد، از آن جمله می‌توان

به رگرسیون خطی چندمتغیره و تکنیک‌های هوش محاسباتی (تلفیق شبکه‌های عصبی و سامانه‌های فازی) اشاره کرد. رگرسیون روشی است آماری برای بررسی و مدل‌سازی رابطه بین متغیرها. تاکنون پژوهش‌های بسیار زیادی درباره مدل‌سازی خواص مختلف خاک‌ها، با استفاده از این نوع از توابع انتقالی (رگرسیون چندمتغیره خطی و غیرخطی) انجام گرفته که به چند نمونه اشاره شده است. Vos et al. (2005)، برای تخمین وزن مخصوص ظاهری، از ۱۲ تابع انتقالی استفاده کردند. نتایج نشان داد جداکردن داده‌های خاک سطحی و زیرین دقت پیش‌بینی را بالا نبرده است. Lesch et al. (1995) از روش رگرسیون برای کالیبره کردن دستگاه EM استفاده کردند و پس از به دست آوردن معادله مورد نظر به پیش‌بینی شوری خاک اقدام نمودند. نتایج ایشان حاکی از ارتباط بالای داده‌های هدایتگر و شوری خاک است. Sommer et al. (2003) نیز از داده‌های القاگر مغناطیسی برای تهیه نقشه شوری خاک استفاده کرده و با استفاده از روش رگرسیون چندمتغیره دستگاه را کالیبره کردند. Eklund et al. (1998) جهت نقشه رقوم شوری خاک از داده‌های EM و برای مدل‌سازی از درخت تصمیم استفاده کردند.

اخیراً تلاش‌هایی برای به‌کارگیری روش‌ها و فنون جدید در مدل‌بندی چنین توابعی صورت گرفته است؛ برای نمونه می‌توان به کاربرد شبکه‌های عصبی اشاره کرد (Minansy & McBratney, 2002). شبکه عصبی مصنوعی<sup>۴</sup> یک روش شبیه‌سازی و الهام‌گرفته از مطالعه سیستم مغز و شبکه عصبی موجودات زنده است. قدرت بالای عملکرد سیستم‌های بیولوژیک ناشی از طبیعت موازی برنامه‌ریزی نورون‌های آنهاست. یک شبکه عصبی مصنوعی این ساختار را با توزیع شبیه‌سازی در واحدهای پردازشگر کوچک و ساده به هم پیوسته (نورون) انجام می‌دهد. مهم‌ترین مزیت شبکه‌های عصبی مصنوعی، نسبت به روش‌های ایجاد توابع

1. Wenner Array
2. Time Domain Reflectometry
3. Electromagnetic Induction
4. Artificial neural networks

انتقالی، آن است که، برای پیش‌بینی پارامترهای خاک، به یک مدل اولیه در ارتباط دادن بین داده‌های ورودی و خروجی احتیاجی ندارند. مزیت دیگر شبکه‌های عصبی نسبت به سیستم‌های هوشمند، قدرت یادگیری آن‌ها در مقیاس خیلی کوچک از محیط پیرامونشان و توانایی تعمیم این یادگیری است. به طور کلی، در این روش سعی می‌شود، بر اساس روابط ذاتی میان داده‌ها، مدلی خطی یا غیرخطی بین متغیرهای مستقل و وابسته برقرار شود. Schap et al. (1998) نشان دادند شبکه‌های عصبی می‌توانند پیش‌بینی‌هایی با خطاهای کمتر نسبت به روش‌های متداول رگرسیونی ارائه دهند. Cockx et al. (2010) برای ارتباط دادن داده‌های EM و شوری خاک از شبکه‌ی مصنوعی استفاده کرده و، با به‌کارگیری داده‌های پیش‌بینی‌شده‌ی مدل، نقشه‌ی شوری خاک را تهیه کردند. Parasuraman et al. (2006) بیان کردند که شبکه‌ی عصبی مصنوعی کارایی بهتری نسبت به شبکه‌ی عصبی رزتا<sup>۱</sup> در تخمین ویژگی‌های هیدرولیکی خاک دارد و این نشان‌دهنده‌ی اهمیت فرایند آموزش در شبکه‌ی عصبی است. Amini et al. (2005)، با استفاده از میزان ماده‌ی آلی و رس، به برآورد میزان ظرفیت تبادل کاتیونی خاک به وسیله‌ی شبکه‌ی عصبی و پنج مدل تجربی - که بر پایه‌ی روش‌های رگرسیونی است - پرداختند. نتایج این محققان نشان داد روش شبکه‌ی عصبی، نسبت به سایر روش‌ها، از برتری قابل قبولی برخوردار است.

از دیگر روش‌های مناسب در پیش‌بینی خصوصیات خاک استفاده از سیستم‌های فازی عصبی است. سیستم (مدل) نروفازی<sup>۲</sup>، که ترکیب شبکه‌ی عصبی با منطق فازی است، با استفاده از الگوریتم آموزش شبکه‌ی عصبی، پارامترهای سیستم فازی را تعیین می‌کند. این سیستم ترکیبی بر اساس سیستم فازی، که بیانگر علم

قطعی‌هاست، پایه‌گذاری شده است. از انواع مدل‌های نروفازی می‌توان به نروفازی همزمان<sup>۳</sup>، نروفازی تعاونی<sup>۴</sup>، و نروفازی دورگه<sup>۵</sup> اشاره کرد. در مدل‌های نروفازی دورگه تغییرات انجام‌شده در روند یادگیری را می‌توان از هر دو منظر - شبکه‌ی عصبی و منطق فازی - تفسیر کرد. از این شبکه‌ها می‌توان به سیستم فازی تطبیق‌پذیر مبتنی بر شبکه‌ی عصبی<sup>۶</sup> اشاره کرد که نخستین بار توسط Jang (1997) معرفی شد. این مدل یک سیستم فازی را در ساختاری عصبی اجرا می‌کند و برای فرایند آموزش از ترکیبی از روش‌های آموزش - شامل شیب نزولی<sup>۷</sup> و حداقل مربعات خطا<sup>۸</sup> - استفاده می‌کند (Kisi, 2005; Drake, 2000). مطالعات اخیر، کارایی بیشتر مدل‌های نروفازی را، در مقایسه با دیگر توابع انتقالی، نشان می‌دهد. Mohammadi & Taheri (2005)، برای ایجاد توابع انتقالی خاک، دو روش رگرسیون آماری و فازی را مقایسه کردند. نتایج نشان داد روش رگرسیون فازی در شرایطی که روابط بین متغیرها دارای ابهام است و، به طور کلی، در مواردی که با خطاهای ناشی از ابهام در ساختار معادلات رگرسیونی روبه‌روست، مکمل و یا جایگزین مناسبی برای روش رگرسیون آماری است. McBratney & Odeh (1997) قابلیت منطق فازی را در علوم خاک، مانند نقشه‌برداری، ارزیابی، و مدل‌کردن فرایندهای فیزیکی، به‌خوبی نشان دادند. علاوه بر این، برخی محققان از منطق فازی در زمینه‌های مختلف بهره برده‌اند (Feng et al., 2006; Zhu et al., 2001).

هدف از پژوهش حاضر عبارت است از پیش‌بینی شوری خاک بخشی از خاک‌های مناطق خشک ناحیه‌ی شمالی دشت یزد - اردکان با استفاده از انواع مختلف توابع انتقالی خاک، از قبیل شبکه‌های عصبی مصنوعی پس‌انتشار<sup>۹</sup> و آبشاری<sup>۱۰</sup>، مدل‌های نروفازی،

1. Rosetta
2. Neuro-Fuzzy model
3. Concurrent
4. Cooperative
5. Hybrid
6. Adaptive Neuro-Fuzzy Inference System, ANFIS
7. Gradient descent
8. Least square error
9. Feed Forward
10. Cascade Forward


اگر و فقط اگر یک واحد نمونه‌برداری در هر ردیف و هر ستون وجود داشته باشد. یک هایپرکیوب لاتین تعمیم این مفهوم به تعداد اختیاری از ابعاد است، به طوری که هر واحد نمونه‌برداری فقط در یک صفحه آن قرار گرفته باشد. LHS شامل نمونه‌برداری  $n$  و لیو از توزیع تشریح‌شده هر متغیر است. توزیع تجمعی هر متغیر به  $n$  فاصله با احتمال مساوی تقسیم می‌شود و یک و لیو از هر فاصله، تصادفی، انتخاب می‌شود. سپس،  $n$  و لیو به دست آمده برای هر متغیر با متغیرهای دیگر جفت می‌شود. این روش پوشش کاملی از هر متغیر را ایجاد می‌کند. (Minasny & McBratney, 2006). بر اساس تکنیک هایپرکیوب، محل ۱۵۱ پروفیل در منطقه اردکان به وسعت ۷۸۰۰۰ هکتار انتخاب شد (شکل ۱).

الگوریتم ژنتیک، و رگرسیون چندمتغیره. در این تحقیق از داده‌های EM و پارامترهای اراضی، به عنوان ویژگی‌های زودیافت، در تخمین شوری خاک استفاده شد. بدیهی است مقایسه این روش‌ها با یکدیگر و معرفی کارآمدترین آن‌ها در پیش‌بینی پارامتر مذکور به درک صحیحی از کارایی هر یک آن‌ها می‌انجامد.

## روش‌شناسی

### نمونه‌برداری هایپرکیوب<sup>۱</sup>

این روش طرح تصادفی طبقه‌بندی‌شده‌ای است برای نمونه‌برداری مؤثر به کمک توزیع چندمتغیره. یک شبکه مربع حاوی موقعیت‌های نمونه یک شبکه لاتین است



شکل ۱. موقعیت منطقه مورد مطالعه و پراکنش نقاط نمونه‌برداری

## 1. Latin hypercube method

در مرحله بعد، پارامترهای اولیه و ثانویه اراضی - شامل شیب، جهت شیب، انحنای شیب، شاخص خیسی، طول شیب، و شاخص اراضی - مطابق با روش ارائه شده<sup>۱</sup> Hengel et al (2004) توسط نرم افزار SAGA در محل پروفیل‌ها استخراج شد. مبنای محاسبه شاخص‌های مذکور ایجاد یک شبکه سلولی ۳×۳ بر روی تصویر است (شکل ۲).

سپس، تعداد ۶۰۰ نمونه خاک از عمق‌های مختلف جمع‌آوری و، پس از انتقال به آزمایشگاه، در معرض هوا خشک شد، سپس این نمونه‌ها کوبیده و از الک دو میلی‌متر عبور داده و میزان شوری خاک در عصاره اشباع اندازه‌گیری شد (Sparks et al, 1996). همچنین، در محل پروفیل‌ها، قرائت‌های دستگاه EM۳۸ در دو جهت عمودی - افقی و در دو وضعیت انجام گرفت.

ZNB1 WB	ZNB2 WA	ZNB3 WB
ZNB4 WA		ZNB6 WA
ZNB7 WB	ZNB8 WA	ZNB9 WB

شکل ۲. ساختار شبکه DEM، با یک آرایه ۳×۳ متحرک

مشتقات لازم برای محاسبه شاخص‌های پستی و بلندی به شرح زیر است (Moore et al, 1991).

$$G = \frac{df}{dx} = \frac{Z3 + Z6 + Z9 - Z1 - Z4 - Z7}{6.p} \quad (1)$$

$$H = \frac{df}{dy} = \frac{Z1 + Z2 + Z3 - Z4 - Z8 - Z9}{6.p} \quad (2)$$

$$D = \frac{d^2f}{dx^2} = \frac{Z1 + Z3 + Z3 + Z4 + Z6 + Z7 + Z9 - 2.(Z2 + Z5 + Z8)}{3.p^2} \quad (3)$$

$$E = \frac{d^2f}{dx^2} = \frac{Z1 + Z2 + Z3 + Z7 + Z8 + Z9 - 2.(Z4 + Z5 + Z6)}{3.p^2} \quad (4)$$

$$F = \frac{d^2f}{dx^2 dy} = \frac{Z3 + Z7 + Z1 + Z9}{4.p^2} \quad (5)$$

$$Z5^+ = s. \frac{Z1 + Z2 + Z3 + Z4 + Z6 + Z7 + Z8 + Z9}{9} \quad (6)$$

ماکزیمم شیب ( $\beta$ )، جهت شیب ( $\psi$ )، و میانگین انحنای سطح زمین<sup>۱</sup> عبارت‌اند از (Wilson & Gallant, 2000):

$$SLOPE = \sqrt{H^2 + G^2} \quad (7)$$

$$MEANC = - \left( \frac{(1+H^2) D - 2.G.H.F. + (1+G^2)E}{2.(1+G^2+H^2)^{1.5}} \right) \quad (8)$$

$$ASPECT = \arctan\left(\frac{H}{G}\right) \quad (9)$$

قوی مشاهده شود، هم‌راستایی چندگانه به‌وجود می‌آید. برای کنترل‌کردن هم‌راستایی، از رابطه همبستگی بین متغیرهای مستقل استفاده شد و متغیرهایی که همبستگی زیادی با یکدیگر داشتند، حذف شدند (Ghorbani & Homaei, 2002).

### شبکه عصبی مصنوعی

در این تحقیق شبکه‌ها با یک لایه مخفی، که دارای تابع فعال‌سازی سیگموئید در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی بود و تعداد نورون‌های آن از ۲ تا ۱۰ نورون متغیر بود و بهترین تعداد نورون به صورت سعی و خطا تعیین گردید، بررسی شد. همچنین، در این تحقیق، از الگوریتم آموزشی لوبز مارکوارت، به علت کارایی، سادگی، و سرعت بالا، استفاده شد (Amini et al, 2005; Minansy & McBratney, 1999; Menhaj, 2009).

### ساختار مدل ANFIS

در این ساختار مجموعه‌های فازی را می‌توان به عنوان وزن ارتباطات و متغیرهای ورودی و خروجی را به عنوان نورون‌ها تفسیر کرد و الگوریتم یادگیری ساختارها، پارامترها و یا هر دو آن‌ها را اصلاح می‌کند. برای ایجاد این شبکه باید چند پارامتر - نوع تابع عضویت، تعداد تابع، روش یادگیری، و تعداد اپوک - بهینه شوند. برای این کار همه حالات با سعی و خطا به‌دست می‌آید.

### الگوریتم ژنتیک<sup>۳</sup>

الگوریتم ژنتیک یک تکنیک برنامه‌نویسی است که از تکامل ژنتیکی به عنوان الگوی حل مسئله استفاده

شاخص رطوبتی<sup>۱</sup> به عنوان شاخصی از توزیع مکانی رطوبت خاک در طول زمین‌نماست که با معادله (۱۰) محاسبه‌شدنی است.

$$w = \ln\left(\frac{A_s}{\tan \beta}\right) \quad (10)$$

در این معادله مقدار  $A_s$  سطح ویژه حوزه و  $\beta$  درجه شیب است (Zevebergen & Thorne, 1987).

همچنین، در این مطالعه از تصاویر ماهواره‌ای سنجنده ETM استفاده شد. تصاویر این سنجنده مربوط به آگوست ۲۰۰۲، مصادف با ۱۹ مرداد ۱۳۸۱، است. پس از آماده‌سازی تصویر و رفع خطاها، شاخص‌های NDVI و روشنایی محاسبه شد. برای انتخاب پارامترهای مؤثر بر تغییرپذیری شوری خاک از تکنیک آنتروپی شانون استفاده شد (معادله ۱۱). ایده روش فوق این است که هر چه پراکندگی در مقادیر یک شاخص بیشتر باشد، آن شاخص، نسبت به دیگر شاخص‌ها، از اهمیت بیشتری برخوردار است (Soleimani & Zarepisheh, 2009). برای رتبه‌بندی ورودی‌ها از نرم‌افزار EXCEL استفاده شد.

$$E_{ij} = -k \sum (p_{ij} \times \ln p_{ij}) \quad (11)$$

که در آن  $E_{ij}$  آنتروپی،  $P_{ij}$  درایه‌های ماتریس نرمال‌شده، و ضریب است.

### توابع انتقالی

پس از واردکردن عوامل ورودی (متغیرهای مستقل) و میزان شوری خاک به عنوان خروجی‌ها (متغیر وابسته)، همه آن‌ها از نظر هم‌راستایی<sup>۲</sup> و نرمال‌بودن آزمون شدند. با استفاده از آزمون کولموگروف-اسمیرنوف، نرمال‌بودن داده‌ها بررسی شد. اگر در رگرسیون چندگانه خطی بین متغیرهای مستقل وابستگی خطی

1. Wetness Index  
2. Multicollinearity  
3. Genetic Algorithm

$$ME = \frac{1}{n} \sum (Z_o - Z_p) \quad (14)$$

$$RI = \left( \frac{RMSE_a - RMSE_b}{RMSE_a} \right) \times 100 \quad (15)$$

که در آن‌ها  $Z_0$  مقادیر پیش‌بینی شده،  $Z_p$  مقادیر مشاهداتی،  $Z_{ave}$  متوسط مقادیر مشاهداتی،  $n$  تعداد داده‌ها، مجذور میانگین مربعات خطای روش اول، و مجذور میانگین مربعات خطای روش دوم است.

## نتایج

### پیش‌پردازش

نخست، با استفاده از تکنیک آنتروپی شانون، پارامترهای مؤثر برای مدل‌سازی مشخص شد که نتایج آن در جدول ۱ ارائه می‌شود. بر اساس جدول ۱، قرائت‌های عمودی -افقی EM38، شاخص اراضی، باند ۳، شاخص خیسی، و انحنای شیب، به ترتیب، مهم‌ترین عوامل تأثیرگذار بر تغییرات شوری خاک معرفی شدند.

در جدول‌های ۲ و ۳ معیارهای آماری داده‌های آزمون و آموزش برای مقادیر شوری در عمق ۳۰-۰ و ۱۰۰-۰ سانتی‌متر ارائه شده است. دو دسته داده

می‌کند (Ahmed & Simonovic, 2005). در این روش نخست برای تعدادی ثابت، که «جمعیت» نامیده می‌شود، مجموعه‌ای از داده‌ها و پارامترهای هدف، تصادفی، تولید می‌شود و افراد در برابر این مجموعه از داده‌ها آزمایش می‌شوند و مناسب‌ترین آن‌ها باقی می‌مانند و نسل جدید را شکل می‌دهند و این فرایند برای نسل‌های بعدی تا بهینه‌سازی تکرار می‌شود.

### ارزیابی مدل‌ها

به منظور مقایسه عملکرد مدل‌های ANFIS، الگوریتم ژنتیک، شبکه عصبی مصنوعی، و رگرسیون چندمتغیره از پارامترهای خطای استاندارد نسبی<sup>۱</sup> میانگین خطا، بهبود نسبی<sup>۲</sup>، و مجذور میانگین مربعات خطا، که از روابط (۱۲)، (۱۳)، (۱۴)، و (۱۵) محاسبه شدنی‌اند، استفاده شد (Navabian et al., 2003, Amini et al., 2005).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2} \quad (12)$$

$$RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2}}{Z_{ave}} \quad (13)$$

جدول ۱. وزن‌های پارامترهای مؤثر بر تغییرپذیری شوری خاک بر اساس تکنیک آنتروپی شانون

پارامتر آماری	باند ۳	انحنای شیب	شاخص خیسی	شاخص اراضی	قرائت افقی	قرائت عمودی
وزن	۰/۰۰۲	۰/۰۰۱	۰/۰۰۱	۰/۱۸	۰/۳۶	۰/۳۸

### رگرسیون چندمتغیره خطی

برای تعیین رگرسیون چندمتغیره پارامتر شوری در عمق ۳۰ و ۱۰۰ سانتی‌متر، رابطه رگرسیونی مربوطه با استفاده از داده‌های آموزش تعیین شد (معادله‌های ۱۶ و ۱۷). سپس، این روابط بر روی داده‌های آزمون اعمال شد و نتایج ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا، و ضریب تبیین، به ترتیب، ۳۹/۶۸، ۰/۵۴، ۹/۴۸-، و ۰/۶۶ برای شوری در عمق ۳۰ سانتی‌متری

از نظر معیارهای آماری، از قبیل میانگین و انحراف معیار، تا حد ممکن شبیه یکدیگرند. همچنین، این دو گروه داده تفاوت معنی‌داری در سطح ۵% نداشتند. Tomasella et al. (2000) برای انتخاب داده‌های آزمون و تست خود از تی تست (دانکن) استفاده کرده و بیان کردند اگر بین داده‌های آزمون و آموزش تفاوت معنی‌داری وجود نداشته باشد، می‌توان نتایج بهتری از مدل انتظار داشت.

1. Relative Standard Error
2. Mean Error
3. Relative Improvement
4. Root Mean Square Error

جدول ۲. پارامترهای آماری داده‌های استفاده شده در مدل نروفازی، شبکه عصبی، و رگرسیون چندمتغیره برای شوری در عمق ۳۰-۰ سانتی‌متر

پارامتر آماری	شوری	باند ۳	انحنای شیب	شاخص خیسی	شاخص اراضی	قرائت افقی	قرائت عمودی
داده‌های آموزش (۱۲۰)	کمترین	۰/۱۰	۰/۱۰	۰/۱۶	۰/۱۰	۰/۱۰	۰/۱۰
	بیشترین	۰/۸۸	۰/۷۶	۰/۹۰	۰/۹۰	۰/۹۰	۰/۹۰
	میانگین انحراف	۰/۲۸	۰/۳۹	۰/۲۶	۰/۵۲	۰/۱۴	۰/۲۷
داده‌های اعتبارسنجی (۳۱)	معیار	۰/۲۱	۰/۱۶	۰/۰۷	۰/۱۲	۰/۱۷	۰/۱۸
	کشیدگی	۱/۲۶	۰/۶۲	۷/۸۲	۰/۱۵	۲/۲۰	۱/۷۹
داده‌های آموزش (۱۲۰)	کمترین	۰/۱۰	۰/۱۲	۰/۱۰	۰/۳۵	۰/۱۱	۰/۱۱
	بیشترین	۰/۸۶	۰/۶۵	۰/۳۱	۰/۸۴	۰/۷۳	۰/۷۹
	میانگین انحراف	۰/۳۴	۰/۳۷	۰/۲۶	۰/۵۱	۰/۲۷	۰/۳۱
داده‌های اعتبارسنجی (۳۱)	معیار	۰/۲۲	۰/۱۴	۰/۰۴	۰/۱۲	۰/۱۶	۰/۱۹
	کشیدگی	۰/۸۸	۰/۶۵	-۴۰۲	۱۱۱	۱/۴۵	۱/۲۷

جدول ۳. پارامترهای آماری داده‌های استفاده شده در مدل نروفازی، شبکه عصبی، و رگرسیون چندمتغیره برای شوری در عمق ۱۰۰-۰ سانتی‌متر

پارامتر آماری	شوری	باند ۳	انحنای شیب	شاخص خیسی	شاخص اراضی	قرائت افقی	قرائت عمودی
داده‌های آموزش (۱۲۰)	کمترین	۰/۱۰	۰/۱۲	۰/۱۰	۰/۱۰	۰/۱۰	۰/۱۰
	بیشترین	۰/۹۰	۰/۹۰	۰/۹۰	۰/۹۰	۰/۹۰	۰/۹۰
	میانگین انحراف	۰/۳۱	۰/۳۸	۰/۲۶	۰/۵۲	۰/۱۵	۰/۲۷
داده‌های اعتبارسنجی (۳۱)	معیار	۰/۲۰	۰/۱۶	۰/۰۷	۰/۱۳	۰/۱۸	۰/۱۹
	کشیدگی	۰/۸۱	۰/۸۸	۶/۷۱	۰/۲۹	۲/۱۲	۱/۷۴
داده‌های آموزش (۱۲۰)	کمترین	۰/۱۱	۰/۱۰	۰/۲۰	۰/۳۵	۰/۱۰	۰/۱۱
	بیشترین	۰/۷۳	۰/۷۵	۰/۳۵	۰/۷۷	۰/۷۷	۰/۸۶
	میانگین انحراف	۰/۳۵	۰/۴۰	۰/۲۶	۰/۵۴	۰/۱۳	۰/۲۸
داده‌های اعتبارسنجی (۳۱)	معیار	۰/۱۸	۰/۱۷	۰/۰۳	۰/۱۱	۰/۱۶	۰/۱۷
	کشیدگی	۰/۶۲	۰/۶۷	۰/۶۹	۰/۲۹	۱/۸۲	۱/۹۱



تجزیه واریانس نیز برای رگرسیون محاسبه شد که نتایج آن حاکی از معنی دار بودن معادله برازش داده شده است (جدول ۴ و ۵) ( $p < 0.05$ ).

و ۳۳/۲۸، ۰/۶۰، ۱۲/۳۴-، و ۰/۵۴ برای شوری در عمق ۱۰۰ سانتی متری به دست آمد. مقادیر ضرایب رگرسیونی دارای عدد پی کوچکتر ۰/۰۵ است. جدول

(۱۶)

$$EC_{0-30} = 0.03 - 0.10VER + 0.88HOR - 0.34LSFACTOR - 0.02WETNESS + 0.31CURVATURE + 0.11B3$$

(۱۷)

$$EC_{0-100} = 0.14 - 0.53VER + 0.05HOR - 0.45LSFACTOR + 0.05WETNESS + 0.27CURVATURE + 0.01B3$$

جدول ۴. نتایج تجزیه واریانس برای رگرسیون برای شوری در عمق ۳۰-۰ سانتی متر

منابع	درجه آزادی	مجموع مربعات	میانگین مربعات	اف فیشر <sup>۱</sup>	مقدار پی <sup>۲</sup>
رگرسیون	۶	۲,۸۵	۰,۴۷	۲۰,۹۰	< ۰,۰۵
باقی مانده خطا	۱۱۴	۲,۵۹	۰,۰۲		
کل	۱۲۰	۵,۴۵			

جدول ۵. نتایج تجزیه واریانس برای رگرسیون برای شوری در عمق ۱۰۰-۰ سانتی متر

منابع	درجه آزادی	مجموع مربعات	میانگین مربعات	اف فیشر	مقدار پی
رگرسیون	۶	۱,۳۷	۰,۲۲	۸,۶۲	< ۰,۰۵
باقی مانده خطا	۱۱۴	۳,۰۲	۰,۰۲		
کل	۱۲۰	۴,۳۹			

سری داده‌های ورودی است. ساختار بهینه شبکه، به روش سعی و خطا، با استفاده از معیارهای ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا، و ضریب تبیین تعیین شد. برای پیش‌بینی شوری خاک در دو عمق مقادیر ریشه مربعات خطا ارائه شد (شکل‌های ۳ و ۴). با توجه به شکل‌های ۳ و ۴، ملاحظه می‌شود که حداقل مقدار ریشه مربعات خطا در پارامتر شوری عمق ۳۰ سانتی متر مربوط به شبکه با سه نورون در لایه مخفی و برای شوری عمق ۱۰۰ سانتی متر شبکه با دو نورون در لایه مخفی است. مقدار ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا، و ضریب تبیین برای پارامتر شوری در عمق ۳۰ سانتی متر، به ترتیب،

که در آن‌ها VER قرائت عمودی است، HOR قرائت افقی، LSFACOR شاخص اراضی، WETNESS شاخص خیس، CURVATURE شاخص انحنای شیب، و B3 داده‌های باند ۳.

#### شبکه عصبی پرسپترون چندلایه

داده‌های تست و آموزش با استفاده از رابطه (۱۸) استاندارد شده، یعنی بین یک دامنه عددی، که معمولاً ۰/۱ و ۰/۹ است، قرار گیرند.

$$y = 0.8 \times \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + 0.1 \quad (18)$$

که در آن کوچک‌ترین داده و بزرگ‌ترین داده


1. P-value

2. F

۳۰ سانتی‌متر، به ترتیب، ۳۸/۱، ۰/۵۲، ۶/۹۶-، و ۰/۶۸ و برای شوری در عمق ۱۰۰ سانتی‌متر ۳۲/۹، ۰/۵۹، و ۸/۹۶-، و ۰/۶۷ به دست آمد.

### سیستم فازی تطبیق‌پذیر مبتنی بر شبکه عصبی

برای ایجاد این شبکه باید چند پارامتر - نوع تابع عضویت، تعداد تابع، روش یادگیری، و تعداد اپوک - بهینه شوند. برای این کار همه حالات با سعی و خطا به دست آمد. جدول ۶ نتایج خصوصیات مدل ANFIS به کاررفته برای پیش‌بینی شوری در عمق را نشان می‌دهد. بهترین ساختار با توجه به معیار RMSE تعیین شد.




شکل ۴. مقادیر RMSE برای تعداد نرون متفاوت در پیش‌بینی شوری عمق ۱۰۰-۰ سانتی‌متر

۳۶/۶۷، ۰/۵۰، ۶/۱۹، و ۰/۶۸ و برای شوری در عمق ۱۰۰ سانتی‌متر ۳۲/۵۲، ۰/۵۸، ۹/۶۲-، و ۰/۷۰ به دست آمد. در هر دو پارامتر با افزایش تعداد نرون‌ها عملکرد مدل‌ها بدتر شد.

### شبکه عصبی آبخاری

برای اجرای این شبکه، نیازی به ساختار اولیه (تعداد نرون در لایه مخفی) نیست و این جزء محاسن این شبکه است. پس در این شبکه به روش سعی و خطا نیازی نیست. نتایج خطای این روش بر اساس مقدار ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا، و ضریب تبیین برای پارامتر شوری در عمق



شکل ۳. مقادیر RMSE برای تعداد نرون متفاوت در پیش‌بینی شوری عمق ۳۰-۰ سانتی‌متر

جدول ۶. ویژگی‌های مدل ANFIS انتخابی برای پیش‌بینی شوری

تعداد توابع عضویت	تکرار	نوع تابع عضویت	روش یادگیری	روش دفازی کردن	شوری (۲۰-۰ سانتی‌متر)	شوری (۱۰۰-۰ سانتی‌متر)
۳	۲۰۰	مثلثی	پس‌خور	میانگین وزنی		
۲	۳۰۰۰	مثلثی	هیبرید	میانگین وزنی		


در عمق ۱۰۰ سانتی‌متر ۳۱/۷۶، ۰/۵۷، ۷/۹۵-، و ۰/۷۴ به دست آمد.

### ارزیابی مدل‌ها


نتایج مدل‌های نروفازی، شبکه‌های عصبی، الگوریتم ژنتیک، و رگرسیون چندمتغیره پارامترهای مورد اندازه‌گیری در جدول ۷ ارائه شد. با توجه به این

### الگوریتم ژنتیک

در این تحقیق، تعداد جمعیت اولیه ۵۰، حداکثر نسل ۱۰۰، و تعداد گردش برابر با ۱۰۰ دور در نظر گرفته شد. نتایج خطای این روش بر اساس مقدار ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا، و ضریب تبیین برای پارامتر شوری در عمق ۳۰ سانتی‌متر، به ترتیب، ۳۴/۵۴، ۰/۴۷، ۵/۳، و ۰/۷۱ و برای شوری



شکل ۶. مقایسه نتایج RI در روش‌های مختلف برای پیش‌بینی شوری در عمق ۱۰۰-۰ سانتی‌متری



شکل ۵. مقایسه نتایج RI در روش‌های مختلف برای پیش‌بینی شوری در عمق ۳۰-۰ سانتی‌متری


جدول ۷. مقایسه نتایج به‌دست‌آمده از مدل‌های مختلف جهت پیش‌بینی شوری خاک

RI	R <sup>۲</sup>	ME	RMSE	RSE	مدل	خصوصیت خاک
۱۷	۰/۷۸	۵/۱	۳۲/۶۹	۰/۴۵	نروفازی	شوری خاک (۳۰-۰ سانتی‌متر)
۱۳	۰/۷۱	۵/۳	۳۴/۵۴	۰/۴۷	الگوریتم ژنتیک	
۷	۰/۶۸	۶/۱۹	۳۶/۶۷	۰/۵۰	شبکه عصبی پرسپترون	
۴	۰/۶۸	-۶/۹۶	۳۸/۱۰	۰/۵۲	شبکه عصبی آبخاری	
۰	۰/۶۶	-۹/۴۸	۳۹/۶۸	۰/۵۴	رگرسیون	
۱۱	۰/۸	-۵/۸۴	۲۹/۶۶	۰/۵۳	نروفازی	شوری خاک (۱۰۰-۰ سانتی‌متر)
۵	۰/۷۴	-۷/۹۵	۳۱/۷۶	۰/۵۷	الگوریتم ژنتیک	
۲	۰/۷	-۹/۶۲	۳۲/۵۲	۰/۵۸	شبکه عصبی پرسپترون	
۱	۰/۶۷	-۸/۹۶	۳۲/۹۰	۰/۵۹	شبکه عصبی آبخاری	
۰		-۱۲/۳۴	۳۳/۲۸	۰/۶۰	رگرسیون	

مدل‌هایی که شوری را تخمین زده‌اند تفاوت معنی‌داری وجود ندارد. در چنین شرایطی برای ارزیابی کارایی مدل‌ها می‌توان از شاخص RI استفاده کرد. این آماره نشان‌دهنده میزان کاهش خطا در مدل‌های مختلف، نسبت به روش رگرسیون، است. همان‌طور که در جدول ۷ و شکل‌های ۵ و ۶ ارائه شده، مدل نروفازی دقت پیش‌بینی را، نسبت به روش رگرسیون خطی چندگانه، برای شوری در عمق ۳۰ سانتی‌متری به میزان ۱۷ درصد و برای شوری در عمق ۱۰۰ سانتی‌متری ۱۱


جدول، ملاحظه می‌شود، در کل، بهترین عملکرد در پیش‌بینی شوری در هر دو عمق مورد مطالعه مربوط به مدل نروفازی است که از لحاظ هر سه معیار بهتر از شبکه عصبی و رگرسیون چندمتغیره است. پس از مدل ANFIS، الگوریتم ژنتیک، شبکه عصبی مصنوعی پس‌انتشار و آبخاری، به ترتیب، دارای بهترین عملکرد هستند. مقدار پایین RMSE در اکثر مدل‌ها، پایین بودن خطا و دقت بالای مدل‌های برازش‌داده‌شده را نشان می‌دهد. همچنین، نتایج نشان داد در سطح ۵٪ بین

بهترین خط برازش داده شده دارای زاویه‌ای نزدیک به ۴۵ درجه است که نشان‌دهنده دقت بالای برآورد توسط مدل نروفازی است.



شکل ۸. نمودار پراکنش برای مقادیر مشاهداتی و شبیه‌سازی شده داده‌های آزمون در عمق ۱۰۰+ سانتی متری

درصد افزایش داده است. در اشکال ۷ و ۸ دیگرام‌های 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



شکل ۷. نمودار پراکنش برای مقادیر مشاهداتی و شبیه‌سازی شده داده‌های آزمون شوری در عمق ۳۰+ سانتی متری

استفاده از معیار آماری RMSE، به پیش‌بینی خصوصیات خاک، با استفاده از مدل مربوطه، اقدام شد. نتایج این بررسی نشان داد که در مورد مطالعه شده شبکه‌های عصبی مصنوعی، نسبت به معادلات رگرسیونی، کارایی بهتری داشتند، زیرا، احتمالاً، از یک طرف، کارایی توابع انتقالی به‌دست‌آمده در مناطق مختلف با هم متفاوت‌اند، و، از طرف دیگر، بر اساس 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 مناسبی دست یافت و به علت وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی‌شونده شبکه عصبی عملکرد بهتری، نسبت به مدل‌های رگرسیون، داشت. همچنین، همان‌طور که در شکل‌های ۳ و ۴ دیده می‌شود، تغییرات ریشه مربعات خطا دارای روند مشخصی نیست. چون شبکه عصبی یک مدل جعبه سیاه است و وزن‌ها تصادفی انتخاب می‌شوند، نمی‌توان این روند موجود را کاملاً توضیح داد. فقط باید با سعی و خطا بهترین ساختار را به‌دست

## بحث و نتیجه‌گیری

در این تحقیق، با استفاده از مدل‌های نروفازی، شبکه‌های عصبی، الگوریتم ژنتیک، و رگرسیون چندمتغیره، مقادیر شوری در اعماق ۳۰ و ۱۰۰ سانتی‌متری برآورد شد. انتخاب پارامترهای ورودی بر اساس تکنیک آنتروپی شانون صورت گرفت. به این ترتیب، قرائت‌های عمودی-افقی EM۳۸ مهم‌ترین عوامل تأثیرگذار بر تغییرات شوری خاک معرفی شدند. مطالعات بسیاری حاکی از ارتباط بسیار زیاد قرائت‌های EM۳۸ با مقادیر شوری خاک است. Johnston et al (1996) از طریق روابط رگرسیونی کارایی بالای دستگاه EM۳۸ را برای پایش شوری خاک در افریقا تأیید کردند. Sharma & Gupta (2000) نیز برای تهیه نقشه شوری خاک و بالابردن دقت نقشه از داده‌های EM۳۸ استفاده کردند. Saey et al (2009) نیز از داده‌های EM جهت پیش‌بینی بافت خاک در کشور بلژیک استفاده کرده و کارایی این داده‌ها را تأیید کردند.

پس از تعیین ساختار بهینه هر یک از مدل‌ها، با

به آن‌ها استوار است و روابط بین متغیرها نیز دقیق فرض می‌شود. حال آنکه در سیستم‌های طبیعی، مانند خاک، عموماً مشاهدات یا روابط ناشناخته بین متغیرها مطرح است. در چنین شرایطی، از مدل‌هایی باید بهره گرفت که قادر به ارائه الگوهای مناسب‌تر باشند، به گونه‌ای که این مدل‌ها بتوانند با دنیای واقعی انطباق بیشتری داشته باشند. نتایج این بررسی نشان داد دقت مدل نروفازی در پیش‌بینی شوری خاک از همه انواع شبکه‌های عصبی مورد استفاده بیشتر است. به دلیل ساختار غیرخطی مدل‌های شبکه عصبی و ابهام در متغیرهای مدل‌های سیستم استنتاج فازی، امروزه، بیشتر محققان در تجزیه و تحلیل متغیرهایی که توزیع مکانی دارند متمایل‌اند از مدل‌های هیبریدی، مانند سیستم فازی تطبیق‌پذیر مبتنی بر شبکه عصبی، استفاده کنند (Mohammadi & Taheri, 2005). برای نمونه، Aali et al. (2009) نشان دادند که مدل ANFIS در پیش‌بینی درصد رطوبت اشباع خاک دقت بیشتری نسبت به مدل شبکه عصبی مصنوعی دارد که با نتایج این تحقیق هم‌خوانی دارد. بدین ترتیب، با توجه به عدم قطعیت 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.

آورد. اما توجیهی که می‌توان به دست داد، آن است که با پیچیده‌تر شدن مدل شبکه عصبی بیش از حد آموزش می‌بیند و قادر به برازش مناسب بر روی داده‌های جدید نیست. نتایج این تحقیق با آنچه Amini et al. (2005) در برآورد CEC در منطقه اصفهان به دست آوردند هم‌خوانی دارد. Pachepsky et al. (1996)، با استفاده از آماره‌های ضریب همبستگی و ریشه میانگین مربعات خطا، به بررسی شبکه عصبی مصنوعی و آنالیز رگرسیون پرداختند. آن‌ها نتیجه گرفتند که شبکه عصبی برآورد بهتر و خطای کمتری، بر اساس داده‌های زودیافت خاک، دارد. نتایج مشابهی توسط Tammari et al. (1996) به دست آمد؛ آن‌ها نیز مقدار RMSE کمتری از برآورد خصوصیات خاک با شبکه عصبی مصنوعی، نسبت به رگرسیون خطی چندگانه، به دست آوردند. همچنین، نشان دادند که اگر ناپایداری داده‌ها بالا باشد، شبکه عصبی از مدل‌های رگرسیونی خطی بهتر نخواهد بود، اما در صورت استفاده از داده‌ها با دقت، شبکه عصبی کارایی بالاتری را نشان می‌دهد و می‌توان نتیجه گرفت که داده‌های به‌کاربرده شده در تحقیق حاضر نیز از دقت بسیار بالایی برخوردارند. Cockx et al. (2010) نیز برای ارتباط دادن داده‌های EM و شوری خاک از شبکه هوش مصنوعی استفاده کردند.

همه روش‌های ذکر شده در این تحقیق بر فرض دقیق بودن متغیرهای مورد مطالعه و مشاهده‌های مربوط

## References

- [1]. 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, 127–136.
- [2]. Ahmed, S. and Simonovic, S. P. (2005). An artificial neural network model for generating hydrograph from hydro meteorological parameters. *Journal of Hydrology*, 315, 236-251.
- [3]. Amini, M., Afyuni, M., Fathianpour, N., Khademi, H. and Fluchler, H. (2005). Continuous soil pollution mapping using fuzzy logic and spatial interpolation. *Geoderma*, 124, 223–233.
- [4]. 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.
- [5]. Bouma, J. (1989). Using soil survey data for quantitative land evaluation. *Soil Science*, 9, 177–213.
- [6]. Cockx, L., M. Van Meirvenne, U.W.A. Vitharana, F.M.B. Vancoillie, L.P.C. Verbeke, D. Simpson, and Saey, T. (2010). A neural network approach to topsoil clay prediction using an EMI-Based soil sensor, *Proximal Soil Sensing*, Springer press, 444 p.
- [7]. 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.
- [8]. Eklund, P. W., Kirkby, S. D. and Salim, A. (1998). Data mining and soil salinity analysis. *International Journal of geographical information science*, 3, 247-268.
- [9]. Feng, Q., Zhu, A., Harrower, M. and Burt, J. E. (2006). Fuzzy soil mapping based on prototype category theory. *Geoderma*, 136, 774–787.
- [10]. Ghorbani-Dashtaki, Sh. and Homaei, M. (2002). Prediction of parametric hydraulic function in unsaturated soils using pedotransfer functions. *Agriculture Engineering Research Journal*, 3, 3-15.
- [11]. Hengel, T., Huvelink, G. B. M. and Stein, A. (2004). A generic framework for spatial prediction of soil variables based on regression-kriging. *Geoderma*, 120, 75–93.
- [12]. 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.
- [13]. Johnston, M. A., Savage, M. J., M. J., Moolman, J. H. and Du-Plessis, H.M. (1996). Calibration models for interpretation of soil salinity measurements using an electromagnetic induction technique. *South Africa Journal*, 21, 1-6.
- [14]. Kisi, O. (2005). Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrological Sciences–Journal–des Sciences Hydrologiques*, 50, 683–696.
- [15]. Lesch, S.M., Strauss, D.J. and Rhoades, J. D. (1995). Spatial prediction of soil salinity using

- electromagnetic induction techniques 1. Statistical prediction models: A comparison of multiple linear regression and cokriging. *Water Resources Research*, 31, 373–386.
- [16]. 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.
- [17]. McKenzie, N. J. and Austin, M. P. (1993). A quantitative Australian approach to medium and small scale surveys based on soil stratigraphy and environmental correlation. *Geoderma*, 57, 329–355.
- [18]. McNeill, J. D. (1980). Electromagnetic terrain conductivity measurements at low induction numbers. Technical note TN-5 Geonics Ltd. Mississauga, Ontario, Canada, p.15
- [19]. Menhaj, M. (2009). *Fundamental of Artificial neural networks*, Amirkabir Press, 245p.
- [20]. Minasny, B. and McBratney A. B. (2006). A conditioned Latin hypercube method for sampling in the presence of ancillary information. *Computer & Geosciences*, 32, 1378–1388.
- [21]. Minasny, B. and McBratney, A. B. (2002). The Neuro-m method for fitting neural network parametric pedotransfer functions. *Journal of Soil Science Society of America*, 66, 352–361.
- [22]. 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.
- [23]. Mohammadi, J. (2000). Testing an artificial neural network for predicting soil water retention characteristics from soil physical and chemical properties. 17th World Congress of Soil Science. Thailand. Paper No. 221.
- [24]. Mohammadi, J. and Taheri, M. (2005). Estimation of pedotransfer function using fuzzy regression. *Journal of Agriculture Science and Technology*, 2, 51-60.
- [25]. Moore, I. D., Grayson. R. B. and Landson, A. R. (1991). Digital terrain modeling. A review of hydrological, geomorphological, and applications. *Hydrology*, 5, 3– 30.
- [26]. Navabian, M., Liaghat, A. and Homari, M. (2003). Determination of soil saturated hydraulic conductivity using pedotransfer function. *Agriculture Engineering Research Journal*, 4, 1-12.
- [27]. Pachepsky, Y. A., Timilin, D. and Varallyay, G. (1996). Artificial neural networks to estimate soil water retention from easily measurable data. *Journal of Soil Science Society of America*, 60, 727-733.
- [28]. Parasuraman, K., Elshorbagy, C. and Si, B. (2006). Estimating saturated hydraulic conductivity in spatially variable fields using neural network in Ensembles. *Journal of Soil Science Society of America*, 70, 1851-1859.
- [29]. Rhoades, J. D. (1976). Measuring, mapping and monitoring field salinity and water depths with soil resistance measurements. *FAO Soils Bulletin*, 31, 69-1 09.
- [30]. Rhoades, J. D. and Ingvalson, R. D. (1971). Determining salinity in field soils with soil resistance measurements. *Journal of Soil Science Society of America*, 35, 54-60.
- [31]. Saey, T., Van Meirvenne, M., Vermeersch, H., Ameloot, N. and Cockx, L. (2009). A pedotransfer function to evaluate the soil profile textural heterogeneity using proximally sensed apparent electrical conductivity. *Geoderma*, 150, 389–395.
- [32]. Schap, M. G., Leij, F. J. and Van Genuchten, M. T. (1998). Neural network analysis for hierarchical prediction of soil hydraulic properties. *Journal of Soil Science Society of America*, 62, 847–855.

- [33]. Sharma, D. P. and Gupta S. K. (2000). Application of EM38 for soil salinity appraisal: an Indian experience, EM38 Workshop, New Delhi, India.
- [34]. Sheng, J., Ma, L., Jiang, P., Li, B., Huang, F. and Wu, H. (2009). Digital soil mapping to enable classification of the salt-affected soils in desert agro-ecological zones. *Agricultural Water Management*, 35, 54-60.
- [35]. Soleimani-damaneh, M. and Zarepisheh, M. (2009). Shannons entropy combining the efficiency results of different DEA models: Method and application. *Expert System with Applications*, 47-51.
- [36]. Sommer, M., Wehrhan, M., Zipprich, M., Castell, Z.W., Weller, U., Castell, W., Ehrich, S., Tandler, B. and Selige, T. (2003). Hierarchical data fusion for mapping soil units at field scale. *Geoderma*, 112, 179-196.
- [37]. Sparks, D. L., Page, A. L., Helmke, P. A., Leoppert, R. H., Soltanpour, P. N., Tabatabai, M. A., Johnston, G. T. and Summer, M. E. (1996). *Methods of soil analysis, SSSA, Madison, Wisconsin*.
- [38]. Sudduth, K. A., S. T. Drummond and Kitchen, N. R. (2001). Accuracy issues in electromagnetic induction sensing of soil electrical conductivity for precision agriculture. *Computers and Electronics in Agriculture*, 31, 239-264.
- [39]. Tamari, S., Wosten, J. H. M. and Ruz-suarez, J. C. (1996). Testing an artificial neural network for predicting soil hydraulic conductivity. *Journal of Soil Science Society of America*, 60, 1732-1741.
- [40]. Tomasella, J., Hodnett, M. G. and Rossato, L. (2000). Pedotransfer functions for the estimation of soil water retention in Brazilian soils. *Journal of Soil Science Society of America*, 49, 1100-1105.
- [41]. Triantafilis, J., I. O. A. Odeh. and McBratney A. B. (2001). Five Geostatistical Models to Predict Soil Salinity from Electromagnetic Induction Data across Irrigated Cotton. *Journal of Soil Science Society of America*, 65, 869-878.
- [42]. 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. *Journal of Soil Science Society of America*, 69, 500-510.
- [43]. Wilson, J. P. and J. C. Gallant. (2000). *Terrain analysis*. Wiley and Sons press, 479 p.
- [44]. Zevebergen, L. W. and Thorne, C. R. (1987). Quantitative analysis of land surface topography. *Earth Surface Processes Landforms*, 12, 47-56.
- [45]. Zhu, X., Hudson, B., Burt, J., Lubich, K. and Simonson, D. (2001). Soil Mapping Using GIS, Expert Knowledge, and Fuzzy Logic. *Journal of Soil Science Society of America*, 65, 1463-1472.