

تهیه نقشه‌های سه بعدی توزیع اندازه ذرات نهایی سازنده خاک (بافت خاک) با استفاده از معادلات عمق و

شبکه‌های عصبی مصنوعی

علیرضا امیریان چکان^۱، روح اله تقی زاده مهرجردی^۲، فریدون سرمدیان^{۳*}، احمد حیدری

۱. استادیار، گروه مرتع و آبخیزداری دانشگاه صنعتی خاتم‌الانبیاء بهبهان

۲. استادیار، گروه مدیریت بیابان و مناطق خشک دانشکده کشاورزی و منابع طبیعی دانشگاه اردکان

۳. استاد، گروه مهندسی علوم خاک دانشگاه تهران

۴. دانشیار، گروه مهندسی علوم خاک دانشگاه تهران

(تاریخ دریافت: ۱۳۹۳/۱۱/۱۹ - تاریخ تصویب: ۱۳۹۵/۴/۲۷)

چکیده

در نقشه‌های مرسوم معمولاً چگونگی تغییرات بافت خاک در فواصل بین نقاط نمونه‌برداری نشان داده نمی‌شود و در این نقشه‌ها و نقشه‌های رقومی، تغییرات تدریجی بافت خاک با عمق به خوبی قابل پیش‌بینی نیست. از تکنیک نقشه‌برداری رقومی برای تخمین ذرات نهایی سازنده خاک در مکان‌های نمونه‌برداری نشده و از معادلات عمق خاک برای نشان دادن تغییرات بافت خاک با عمق و تخمین آن در هر عمق دلخواه می‌توان استفاده نمود. در این مطالعه در ۱۰۳ نقطه مشاهداتی واقع در دشت سیلاخور در شمال غرب شهرستان دورود استان لرستان، معادله عمق اسپلین با سطح برابر بر داده‌های سیلت، شن و رس تا عمق یک متری برآزش داده شد و مقادیر این اجزاء در پنج عمق استاندارد شامل ۵-۰، ۱۵-۵، ۳۰-۱۵، ۶۰-۳۰ و ۱۰۰-۶۰ سانتی‌متر تخمین زده شد. این اطلاعات با متغیرهای کمکی استخراج شده از تصاویر ETM^+ سنجنده‌های ماهواره لندست و مدل رقومی ارتفاعی (DEM) تلفیق و بر اساس روابط بین آن‌ها نقشه پیوسته پیش‌بینی مقدار اندازه ذرات نهایی سازنده خاک و کلاس‌های بافت خاک با استفاده از مدل شبکه‌های عصبی مصنوعی برای کل منطقه به دست آمد. نتایج تجزیه و تحلیل حساسیت نشان داد اهمیت نسبی داده‌های کمکی در پیش‌بینی بافت خاک برای اجزاء مختلف بافت و در اعماق مختلف متفاوت است. بر طبق نتایج حاصله توانایی شبکه‌های عصبی در تخمین بافت خاک در لایه‌های سطحی بیشتر از لایه‌های پایینی بود. مقادیر R^2 برای رس، سیلت و شن از سطح به عمق به ترتیب از ۰/۷۳ تا ۰/۴۹، از ۰/۷۶ تا ۰/۴۳ و از ۰/۶۸ تا ۰/۲۶ به دست آمد. این نتایج در نقشه‌برداری رقومی در حد قابل قبولی هستند. افزون بر این، نتایج نشان داد داده‌های کمکی مستخرج از تصاویر ماهواره‌ای در لایه‌های سطحی و داده‌های مستخرج از DEM در لایه‌های عمقی اهمیت بیشتری در تخمین بافت خاک داشتند.

واژه‌های کلیدی: دشت سیلاخور، سنجش از دور، مدل اسکورپن، نقشه‌برداری رقومی خاک

مقدمه

تخریب اراضی و کاهش تنوع زیستی مورد نیاز است (Hartemink and McBratny, 2008). این قبیل اطلاعات اغلب در مقیاس و شکل مناسب در دسترس نیستند (McBratney *et al.*, 2003; Greve *et al.*, 2012b) و این مشکل در کشورهایی با داده‌های کم که تلاش برای جمع‌آوری داده‌های بیشتر با محدودیت‌های مالی و حمایتی مواجه است، بیشتر مشهود است (Akpa *et al.*, 2014).

بافت خاک یکی از مهم‌ترین ویژگی‌های خاک است که مقدار نگهداری آب و عناصر غذایی، نفوذپذیری، زهکشی، تهویه، مقدار کربن آلی، ظرفیت بافری، تخلخل و بسیاری از خواص مکانیکی خاک را تحت تاثیر قرار می‌دهد (Akpa *et al.*, 2014). از بافت خاک در همه سطوح در سیستم جامع رده‌بندی خاک،

امروزه نیاز رو به رشدی برای استفاده از داده‌های کمی و پیوسته مکانی در راستای ایجاد مدل‌های زیست محیطی و مدیریت منابع طبیعی (Minasny *et al.*, 2008) به ویژه در سطح ملی و فرا ملی وجود دارد (Akpa *et al.*, 2014). خاک بخش مهم و حساس کره زمین است که دارای نقش‌های متعددی از جمله محیط رشد گیاهان و فعالیت موجودات زنده، منبع تامین غذای انسان‌ها و حیوانات و ذخیره آب است (Akumu *et al.*, 2015) که داده‌های مربوط به آن برای بررسی چالش‌های زیست محیطی از جمله تغییر شرایط اقلیمی، کمبود منابع آب و غذا،

* نویسنده مسئول: fsarmad@ut.ac.ir

Malone *et al.*, 2009; Mishra *et al.*, 2009; Malone *et al.*, 2011; Adhikari *et al.*, 2013; Odgers *et al.*, 2012; Taghizade-Mehrjardi *et al.*, 2014a; Akpa *et al.*, 2014

یک اسپلاین با سطح برابر از تعدادی چندجمله‌ای درجه دوم تشکیل شده است که در گره‌هایی که در مرز افق‌های خاک قرار دارند به هم متصل می‌شوند (Bishop *et al.*, 1999) و ویژگی مورد نظر را در مکان‌های بین نقاط نمونه‌برداری شده به صورتی عمودی تا عمق مورد نظر پیش‌بینی می‌کنند. اگر عمق خاک با x ، عمق مرز افق‌ها با $x_0 < x_1, \dots < x_n$ و تابع عمق توصیف کننده مقادیر واقعی ویژگی مورد نظر با $f(x)$ نشان داده شود، مقدار تخمینی ویژگی مورد نظر (y_i) به زبان ریاضی به صورت زیر مدل‌سازی می‌شود:

$$y_i = \bar{f}_i + e_i \quad (\text{رابطه ۱})$$

در این رابطه، \bar{f}_i میانگین $f(x)$ در بازه (x_{i-1}, x_i) و e_i خطا با میانگین صفر و واریانس σ^2 است. تابع $f(x)$ نامعلوم است و باید با استفاده از داده‌های نیم‌رخ خاک تخمین زده شود. توابع اسپلاین با انتخاب مقداری برای $f(x)$ در راستای کمینه-سازی رابطه ۲ به راحتی به داده‌های خاک‌رخ خاک تطابق داده می‌شوند:

$$\frac{1}{n} \sum_{i=1}^n (y_i - \bar{f}_i)^2 + \lambda \int_{x_0}^{x_n} [f(x)]^2 dx \quad (\text{رابطه ۲})$$

بخش اول رابطه ۲ میزان دقت برازش مدل بر داده‌ها را نشان می‌دهد، بخش دوم میزان انحنای تابع $f(x)$ را نشان می‌دهد و λ پارامتر کنترل کننده میزان توازن بین دقت برازش و حد مجاز انحنای اسپلاین است. از آنجا که کارایی تابع اسپلاین به مقدار زیادی به پارامتر λ بستگی دارد، با به کار بردن مقادیر مختلف لاندا (۰.۱، ۱، ۱۰، ۱۰۰، ۱۰۰۰، ۱۰۰۰۰) بهترین مقدار آن انتخاب می‌گردد (Bishop *et al.*, 1999).

برای بررسی تغییرات جانبی متغیر مورد نظر در فواصل بین نقاط نمونه‌برداری شده و در نتیجه تهیه نقشه پیوسته پیش‌بینی آن، نیاز به تخمین آن متغیر با استفاده از روش‌های مختلف است. از نقشه‌برداری رقومی خاک که طی چند سال اخیر جنبه کاربردی آن بیشتر شده است (Vaysse and Laghacherie, 2015) می‌توان برای تهیه این نقشه‌های پیوسته استفاده نمود. پایه نقشه‌برداری رقومی خاک مدل اسکوپن (*scorpan*) است (McBratney *et al.*, 2003). بر اساس این مدل مجموعه‌ای از خواص خاک یا کلاس‌های خاک (مثل کلاس بافت خاک) به عنوان تابعی از متغیرهای کمکی به دست از منابع دیگر از جمله نقشه‌های مرسوم خاک‌شناسی، مدل رقومی ارتفاع، سنجش از دور، سنجش از نزدیک و دانش کارشناسان در

برای شناسایی رده‌ها و هم‌چنین برای طبقه‌بندی خاک‌ها در سطح فامیل و برای شناسایی افق‌های آرجیلیک^۱، ناتریک^۲ و کندیک^۳ استفاده می‌شود (Soil Survey Staff, 2014). داده‌های مربوط به توزیع اندازه ذرات نهایی سازنده خاک، جزو اطلاعات ورودی به اغلب مدل‌های هیدرولوژیکی، اکولوژیکی، اقلیمی و زیست محیطی هستند (LieB *et al.*, 2012). افزون بر این، در برخی از توابع انتقالی^۴ مورد استفاده برای تخمین خواصی از خاک مثل جرم مخصوص ظاهری، قابلیت هدایت آبی و ظرفیت نگهداری آب خاک، از بافت خاک و مقدار برخی از ذرات نهایی سازنده خاک نظیر سیلت و شن استفاده می‌شود (Minasny and Hartemink, 2011). هم‌چنین بافت خاک در تعیین تناسب خاک برای برخی از استفاده‌های خاص و مهم مثل دفن زباله و مدیریت آب نقش اساسی دارد (Thompson *et al.*, 2012).

با وجود اهمیت زیاد بافت خاک، در مقیاس‌های مورد نیاز برای مدل‌سازی‌های زیست محیطی با کمبود داده‌های آن مواجه هستیم. در بیشتر نقشه‌های خاک موجود تغییرات مکانی درون کلاس‌ها و تغییرات تدریجی متغیرها با عمق کمتر مورد توجه قرار گرفته است (Adhikari *et al.*, 2013). خواص خاک معمولاً به صورت تدریجی با عمق تغییر می‌کنند (Ponce-Hernandez *et al.*, 1986) و استفاده از توابع عمق گسسته برای پیش‌بینی یک ویژگی خاک در عمقی مشخص معمولاً با مقداری خطا همراه می‌باشد. بنابراین محققین توابع پیوسته عمق خاک را با این رویکرد که بتوانند تغییرات تدریجی خواص خاک با عمق را بهتر مدل‌سازی کنند، توسعه داده‌اند (Bishop *et al.*, 1999). این توابع از روش‌های ساده دستی^۵ (Jenny, 1941) تا روش‌های پیشرفته مثل توابع کاهشی نمایی^۶ (Minasny *et al.*, 2006)، رگرسیون خطی و چند جمله‌ای‌ها^۷ (Campbell *et al.*, 1970) و اسپلاین‌های با سطح برابر^۸ (Ponce-Hernandez *et al.*, 1986) را شامل می‌شوند. معادلات اسپلاین از جمله معادلات عمقی هستند که در مقایسه با دیگر معادلات از کارایی بیشتری در مدل‌سازی خصوصیات خاک برخوردار هستند (Bishop *et al.*, 1999). از این معادلات در مطالعات متعددی برای مدل‌سازی تغییرات پیوسته خواص خاک با عمق استفاده شده است

1. Argillic horizon
2. Natric horizon
3. Kandic horizon
4. Pedotransfer function
5. Freehand curve
6. Exponential decay functions
7. Polynomials
8. Equal-area spline

نظر گرفته می‌شوند (رابطه ۳) و با استفاده از روش‌های پیش بینی مناسب، این خواص یا کلاس‌ها در نقاط نمونه‌برداری نشده تخمین زده می‌شود (McBratney et al., 2003).

یا $S_c = f(s, c, o, r, p, a, n)$ (رابطه ۳)

یا $S_a = f(s, c, o, r, p, a, n)$

در رابطه (۳)، S_a : خصوصیات خاک، S_c : کلاس‌های خاک، s : خاک (سایر خصوصیات خاک در نقطه مورد نظر)، c : اقلیم (خصوصیات اقلیمی در نقطه مورد نظر)، o : موجودات زنده (پوشش گیاهی، جانوران یا فعالیت انسان)، r : پستی و بلندی، p : مواد مادری، a : زمان و n : موقعیت مکانی است.

برای پیش‌بینی خصوصیات خاک می‌توان از مدل‌های مختلفی از جمله رگرسیون چند متغیره^۱، شبکه‌های عصبی مصنوعی^۲ و درخت رگرسیون^۳ استفاده نمود (Minasny et al., 2006; Baker and Ellison, 2008; Nyssen et al., 2008; Taghizadeh Mehrjardi et al., 2014b; Samarasinghe, 2007). شبکه‌های عصبی مصنوعی سیستم‌های تطبیقی با انعطاف پذیری زیاد هستند که برای پیدا کردن رابطه بین داده‌ها آموزش داده می‌شوند (Kayadelen et al., 2009). پرسپترون تقریباً واحد محاسباتی همه شبکه‌های عصبی مصنوعی است (Du and Swamy, 2006). پرسپترون چند لایه^۴ (MLP) مهم‌ترین و رایج‌ترین شبکه است که قابلیت خود را از پردازش‌های غیر خطی در لایه‌های مخفی به دست می‌آورد. یک شبکه MLP معمولاً از سه لایه تشکیل شده است. داده‌ها از لایه ورودی وارد و در لایه‌های مخفی پردازش و در لایه خروجی نتایج حاصل از ورودی‌های مورد نظر تولید می‌شوند (Sreekanth et al., 2011). با توجه به قابلیت‌های توابع عمق و نقشه‌برداری رقمی خاک، به نظر می‌رسد تلفیق این روش‌ها احتمالاً خواهد توانست ابزار مناسبی برای پیش‌بینی تغییرات سطحی و عمقی خصوصیات خاک ایجاد نماید (Lagacheri et al., 2009; Lacoste et al., 2011; Malone et al., 2009).

در ایران مطالعات کمی در زمینه نقشه‌برداری رقمی سه بعدی خواص خاک انجام شده است. بررسی ادبیات علمی کشور نشان می‌دهد تعداد معدودی مطالعه از این دست یکی در دشت سیلاخور لرستان بر روی ظرفیت تبادل کاتیونی خاک

مواد و روش‌ها

خصوصیات و ویژگی‌های منطقه مورد مطالعه

منطقه مورد مطالعه به وسعت تقریبی ۳۶۰۰ هکتار بخشی از دشت سیلاخور در شمال غربی شهرستان دورود در استان لرستان در محدوده طول شرقی از $49^{\circ} 18' 17''$ تا $49^{\circ} 21' 7''$ و عرض شمالی از $33^{\circ} 31' 30''$ تا $33^{\circ} 36' 46''$ واقع گردیده است (شکل ۱). با توجه به داده‌های ایستگاه هواشناسی شهرستان دورود، متوسط دمای سالیانه ۱۶ درجه سانتی‌گراد، بارش سالیانه ۶۶۵ میلی‌متر و تبخیر سالیانه برابر با ۲۲۳۰ میلی‌متر می‌باشد. بر اساس نقشه ۱:۱۰۰۰۰۰ زمین‌شناسی بروجرد، این دشت عمدتاً از رسوبات آبرفتی شامل پادگانه‌های بلند و قدیمی، پادگانه‌های کم ارتفاع و جوان و رسوبات رودخانه‌ای مربوط به دوره کواترنر تشکیل شده است. آبرفت‌های عهد حاضر در این منطقه بسته به جایگاه رسوب‌گذاری، ترکیب

نظر گرفته می‌شوند (رابطه ۳) و با استفاده از روش‌های پیش بینی مناسب، این خواص یا کلاس‌ها در نقاط نمونه‌برداری نشده تخمین زده می‌شود (McBratney et al., 2003).

$$S_c = f(s, c, o, r, p, a, n) \quad (\text{رابطه ۳})$$

$$S_a = f(s, c, o, r, p, a, n)$$

در رابطه (۳)، S_a : خصوصیات خاک، S_c : کلاس‌های خاک، s : خاک (سایر خصوصیات خاک در نقطه مورد نظر)، c : اقلیم (خصوصیات اقلیمی در نقطه مورد نظر)، o : موجودات زنده (پوشش گیاهی، جانوران یا فعالیت انسان)، r : پستی و بلندی، p : مواد مادری، a : زمان و n : موقعیت مکانی است.

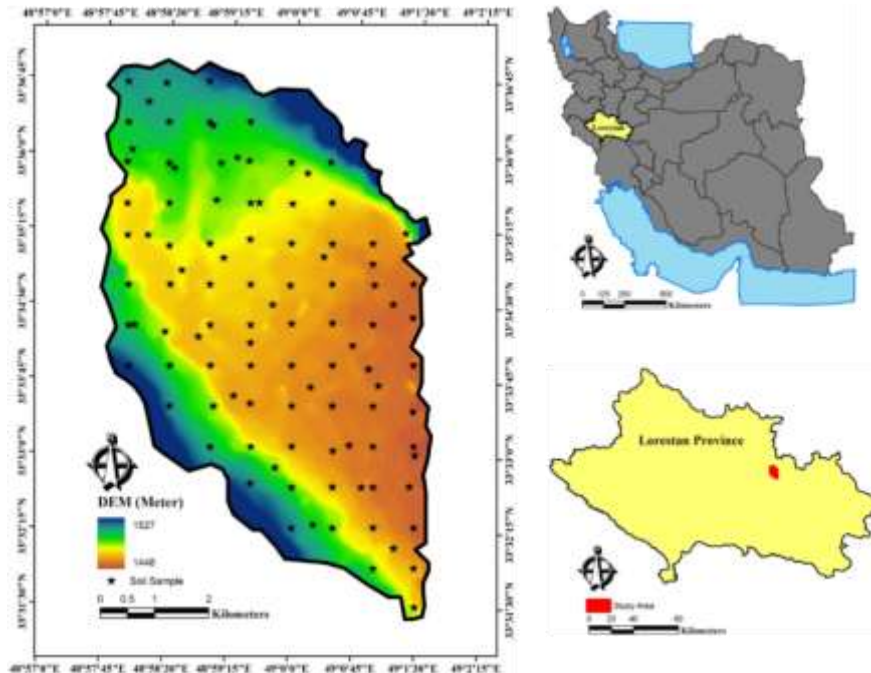
برای پیش‌بینی خصوصیات خاک می‌توان از مدل‌های مختلفی از جمله رگرسیون چند متغیره^۱، شبکه‌های عصبی مصنوعی^۲ و درخت رگرسیون^۳ استفاده نمود (Minasny et al., 2006; Baker and Ellison, 2008; Nyssen et al., 2008; Taghizadeh Mehrjardi et al., 2014b; Samarasinghe, 2007). شبکه‌های عصبی مصنوعی سیستم‌های تطبیقی با انعطاف پذیری زیاد هستند که برای پیدا کردن رابطه بین داده‌ها آموزش داده می‌شوند (Kayadelen et al., 2009). پرسپترون تقریباً واحد محاسباتی همه شبکه‌های عصبی مصنوعی است (Du and Swamy, 2006). پرسپترون چند لایه^۴ (MLP) مهم‌ترین و رایج‌ترین شبکه است که قابلیت خود را از پردازش‌های غیر خطی در لایه‌های مخفی به دست می‌آورد. یک شبکه MLP معمولاً از سه لایه تشکیل شده است. داده‌ها از لایه ورودی وارد و در لایه‌های مخفی پردازش و در لایه خروجی نتایج حاصل از ورودی‌های مورد نظر تولید می‌شوند (Sreekanth et al., 2011). با توجه به قابلیت‌های توابع عمق و نقشه‌برداری رقمی خاک، به نظر می‌رسد تلفیق این روش‌ها احتمالاً خواهد توانست ابزار مناسبی برای پیش‌بینی تغییرات سطحی و عمقی خصوصیات خاک ایجاد نماید (Lagacheri et al., 2009; Lacoste et al., 2011; Malone et al., 2009).

در ایران مطالعات کمی در زمینه نقشه‌برداری رقمی سه بعدی خواص خاک انجام شده است. بررسی ادبیات علمی کشور نشان می‌دهد تعداد معدودی مطالعه از این دست یکی در دشت سیلاخور لرستان بر روی ظرفیت تبادل کاتیونی خاک

1. Multiple regression
2. Artificial neural networks
3. Regression tree
4. Multi-layer perceptron

چهار گروه بزرگ کلسی زریپتز (Calcixerepts)، هاپلوزریپتز (Haploxerepts)، زراورتننز (Xerorthents) و زروفلوننز (Xerofluvents) طبقه‌بندی گردیدند (Soil Survey Staff, 2014).

و اندازه رسوبات و نوع گسترش متفاوت می‌باشند. بر اساس نقشه رژیم‌های رطوبتی و حرارتی خاک‌های ایران، رژیم رطوبتی خاک زریک و رژیم حرارتی خاک ترمیک تعیین گردید. با توجه به مطالعات صحرایی و نتایج تجزیه‌های آزمایشگاهی، خاک‌های منطقه مطالعاتی بر اساس سیستم جامع طبقه‌بندی خاک در



شکل ۱. موقعیت جغرافیایی منطقه مطالعاتی و مکان‌های نمونه‌برداری از خاک

داده‌های کمکی

بر اساس مدل اسکورپن در نقشه‌برداری رقومی خاک، علاوه بر داده‌های خاک به داده‌های کمکی نیز نیاز می‌باشد. در این مطالعه از مدل رقومی ارتفاع (DEM) با قدرت تفکیک ۹۰ متر برای استخراج برخی از متغیرهای کمکی استفاده گردید. خصوصیات زمین‌نما از قبیل شیب، ارتفاع، ارتفاع بالای شبکه زهکشی، مساحت حوزه اصلاح شده، موقعیت میانی شیب، عمق دره، شاخص خیسی توپوگرافی ($TW1^1$)، شاخص همواری دره با درجه تفکیک بالا ($MrVBF^2$)، شاخص بالای پشته با درجه تفکیک بالا و شیب حوزه در محیط سامانه جغرافیایی ساگا^۳ از DEM استخراج گردید (Hengl et al., 2003). منبع دیگر استخراج متغیرهای کمکی برای پیش‌بینی بافت خاک تصویر سنجه ETM^+ ماهواره لندست مربوط به تابستان سال ۱۳۹۲ بود. این تصویر از ۶ باند (باند ۱: ۰/۴۵-۰/۵۲ میکرومتر، باند ۲: ۰/۵۲-۰/۶۰ میکرومتر، باند ۳: ۰/۶۳-۰/۶۹ میکرومتر، باند ۴:

نمونه‌برداری از خاک

در منطقه مطالعاتی نمونه‌برداری خاک از ۱۰۳ مکان انجام گرفت. به همین منظور در محیط نرم افزار آرک‌جی‌ای اس یک شبکه منظم به فاصله نقاط ۷۵۰ متر بر روی تصویر سنجه ETM^+ ماهواره لندست منطقه مورد نظر قرار داده شد. این فاصله تا حدودی بر اساس فاصله نقاط در مطالعات نیمه تفصیلی دقیق (۷۰۰ متر) انتخاب گردید. سپس مختصات نقاط شبکه به دستگاه GPS وارد و موقعیت مکان‌های نمونه‌برداری در صحرا مشخص گردید. در عملیات میدانی تعداد ۷۵ نقطه مشاهداتی با فواصل منظم به صورت یک در میان مته و خاکرخ حفر و تعداد ۲۸ نقطه مشاهداتی نیز در فواصل بین نقاط شبکه منظم به صورت تصادفی برای حفر مته در نظر گرفته شد. سپس نمونه‌های خاک تا عمق ۱۰۰ سانتی‌متری از محل‌های انتخاب شده برداشت و نمونه‌های برداشت شده برای انجام مطالعات بعدی به آزمایشگاه منتقل گردید. بافت خاک نمونه‌های عبور داده شده از الک ۲ میلی متری به روش هیدرومتری اندازه‌گیری شد.

1. Topographic wetness index
2. Multi-resolution valley bottom flatness index
3. SAGAGIS

خاک‌های موجود در منطقه مطالعاتی که عمدتاً شامل انٹی-سول‌ها و اینسپتی‌سول‌ها هستند، فرآیند انتقال رس در این رده‌ها فرآیند غالبی نیست و نمی‌تواند عامل افزایش چشمگیر رس با عمق باشد. چون اغلب خاک‌های منطقه روی رسوبات آبرفتی تشکیل شده‌اند، افزایش رس با عمق شاید به دلیل تفاوت اندازه ذرات لایه‌های مختلف رسوبی باشد. این روند برای شن و سیلت برعکس است؛ به طوری که مقدار سیلت از ۳۷/۵۸ درصد در لایه اول به ۲۳/۱۳ درصد در لایه آخر کاهش می‌یابد. مقدار شن از ۲۳/۰۸ در لایه سطحی تا ۱۹/۷۶ در عمق چهارم روند کاهشی دارد ولی در لایه آخر به ۲۳/۱۳ افزایش می‌یابد. میانگین تغییرپذیری (انحراف معیار) در پنج عمق برای رس بیشترین (۱۳/۷۹) و برای سیلت کمترین است (۴/۹۷). (Adhikari et al., 2013) بیشترین تغییرپذیری را برای رس در سه لایه اول و برای سیلت در لایه‌های پایین‌تر به دست آوردند. در شکل ۲ موقعیت کلاس‌های بافت خاک پیش‌بینی شده در پنج عمق روی مثلث بافت خاک نشان داده شده است. به طور کلی بیشترین خاک‌های مورد بررسی دارای کلاس بافت رسی، لومی رسی و لومی هستند. در عمق اول بیشتر خاک‌ها در کلاس رسی، لومی رسی و لومی قرار دارند و تعداد کمتری در کلاس‌های لومی سیلتی و لومی شنی قرار دارند. در کلاس لومی شنی سه خاک و در کلاس شنی لومی یک خاک قرار دارد. در عمق دوم روند کلی مشابه عمق اول است. در عمق سوم بافت بیشتر خاک‌ها در کلاس‌های رسی، لومی رسی و لومی و تعداد کمتری در کلاس‌های لومی رسی سیلتی و لومی شنی قرار دارند و در سایر کلاس‌ها خاکی وجود ندارد. در عمق چهارم بیشتر بافت خاک‌ها در کلاس رسی و لومی رسی و تعداد کمتری در کلاس‌های لومی، لومی شنی و لومی رسی قرار دارند و یک بافت هم در کلاس لومی سیلتی قرار دارد. در عمق پنجم هم همانند سایر عمق‌ها، بیشترین بافت خاک‌ها در کلاس رسی و پس از آن در کلاس‌های لومی شنی و لومی رسی سیلتی قرار دارند.

پیش‌بینی بافت خاک

در جدول ۲ کارایی بهترین مدل‌های شبکه‌های عصبی مصنوعی در پیش‌بینی ذرات رس، سیلت و شن در پنج عمق استاندارد ارایه شده است. نتایج نشان می‌دهد مقدار RMSE برای ذرات رس از ۷/۰۸ تا ۱۱/۷۵، میانگین خطا از ۰/۵۴ تا ۳/۰۹ و دقت از ۷/۰۵ تا ۱۱/۳۳ به ترتیب از بالا تا پایین خاکرخی خاک متغیر است. این روند کلی را می‌توان در کارایی مدل‌ها در پیش‌بینی درصد سیلت و شن نیز مشاهده نمود؛ به طوری که مقدار

۰/۹۰-۰/۷۶ میکرومتر، باند ۵: ۱/۷۵-۱/۵۵ میکرومتر، باند ۷: ۲/۳۵-۲/۰۸ میکرومتر) تشکیل شده است.

برازش معادله عمق خاک

در این بررسی، معادله عمق اسپیلاین با سطح برابر به داده‌های بافت خاک اندازه‌گیری شده در اعماق مختلف برازش داده شد و سپس درصدهای رس، سیلت و شن در عمق‌های استاندارد پروژه جهانی نقشه‌برداری رقومی خاک^۱ که شامل اعماق ۵-۰، ۱۰-۵، ۳۰-۱۰، ۶۰-۳۰ و ۱۰۰-۶۰ سانتی‌متری می‌باشد، با استفاده از معادله برازش داده شده تخمین زده شدند (Bishop et al., 1999; Malone et al., 2009).

مدل پیش‌بینی

در این تحقیق برای تخمین بافت خاک در نقاط نمونه برداری نشده از مدل شبکه‌های عصبی مصنوعی و برای انجام تخمین‌های

دقیق‌تر از متغیرهای کمکی استفاده شد. الگوریتم MLP مورد استفاده در این تحقیق یک شبکه عصبی چند لایه پیش‌خور^۲ (MFNN) بود که شامل یک متغیر وابسته (بافت خاک) به عنوان خروجی و ۱۴ متغیر مستقل به عنوان ورودی بود. از کل داده‌ها، ۸۰ درصد برای آموزش و ۲۰ درصد باقیمانده به طور تصادفی برای تست مدل انتخاب شدند. برای بررسی کارایی مدل‌ها از ریشه دوم مربعات خطا (RMSE)، ضریب تبیین (R^2) و دقت (PE) (رابطه ۴) استفاده شد. هر چه R^2 بیشتر، RMSE و PE کمتر باشد کارایی مدل‌ها بیشتر است.

$$PE = \sqrt{(RMSE)^2 - (ME)^2} \quad (\text{رابطه ۴})$$

در این رابطه ME میانگین خطا است.

نتایج و بحث

خلاصه آماری داده‌ها

خلاصه آماری مقادیر پیش‌بینی شده رس، سیلت و شن با استفاده از معادلات عمق اسپیلاین برای پنج عمق استاندارد در جدول ۱ ارایه شده است. میانگین مقدار رس از ۳۹/۱۳ درصد در عمق اول تا ۴۶/۱۵ در عمق پنجم متغیر است که بیانگر افزایش مقدار رس با عمق است. در نیجریه و دانمارک نتایج مشابهی به دست آمده است (Akpa et al., 2014; Adhikari et al., 2013). این محققین دلیل این روند را به انتقال رس از افق‌های فوقانی به افق‌های زیرین نسبت دادند. با توجه به رده

1. Global soil map project
2. Multi-layer feedforward neural networks

کم برازش و در اعماق خاک بیش برازش داشته است. در بررسی انجام شده توسط Akpa *et al.* (2014) مقدار رس و سیلت در همه لایه‌ها بیش برازش و مقدار شن کم برازش شده بود. در مطالعه انجام شده توسط Adhikari *et al.* (2013) مقدار رس در همه لایه‌ها بجز لایه چهارم بیش برازش، مقدار سیلت در سه لایه سطحی بیش برازش و در سه لایه عمقی کم برازش، مقدار شن درشت در همه لایه‌ها و مقدار شن ریز در همه لایه‌ها بجز لایه سوم بیش برازش شده بود.

(2014) Nabiolah *et al.* از شبکه‌های عصبی مصنوعی برای مدل‌سازی بافت لایه سطحی خاک‌های منطقه بیجار استفاده کردند و مقادیر ضریب تبیین برای پیش‌بینی درصد‌های رس، سیلت و شن را به ترتیب برابر با ۰/۴۶، ۰/۵۶ و ۰/۵۳ به دست آوردند. در نقشه‌برداری رقومی خاک مقدار R^2 به میزان تغییرات ویژگی‌های مورد بررسی و متغیرهای کمکی بستگی دارد. بخشی از این تغییرات ممکن است توسط مدل‌های مورد استفاده قابل پیش‌بینی نباشد.

مقادیر میانگین خطا نشان می‌دهد که برای هر سه متغیر هدف (شن، سیلت و رس) معادله عمق اسپیلاین در سطح خاک

جدول ۲. ساختار و کارایی مدل‌های شبکه عصبی مورد استفاده برای پیش‌بینی ذرات رس، سیلت و شن در پنج عمق استاندارد

جزء بافت (%)	عمق (cm)	ساختار شبکه*	RMSE	R^2	میانگین خطا	دقت
رس	۰-۵	۱۴-۶-۱	۷/۰۸	۰/۷۳	-۰/۵۴	۷/۰۵
رس	۵-۱۵	۱۴-۳-۱	۸/۰۷	۰/۷۰	-۰/۶۱	۸/۰۴
رس	۱۵-۳۰	۱۴-۹-۱	۸/۳۷	۰/۶۹	۱/۱۵	۸/۲۹
رس	۳۰-۶۰	۱۴-۴-۱	۹/۵۳	۰/۶۷	۱/۸۲	۹/۵۰
رس	۶۰-۱۰۰	۱۴-۶-۱	۱۱/۷۵	۰/۴۹	۳/۰۹	۱۱/۳۳
سیلت	۰-۵	۱۴-۸-۱	۶/۰۲	۰/۷۶	-۰/۳۲	۶/۰۱
سیلت	۵-۱۵	۱۴-۵-۱	۶/۲۰	۰/۶۸	-۰/۵۵	۶/۱۷
سیلت	۱۵-۳۰	۱۴-۲-۱	۵/۱۱	۰/۶۶	۰/۵۱	۵/۰۸
سیلت	۳۰-۶۰	۱۴-۹-۱	۷/۹۱	۰/۵۵	۱/۴۰	۷/۷۸
سیلت	۶۰-۱۰۰	۱۴-۷-۱	۸/۲۴	۰/۴۳	۱/۴۷	۸/۱۰
شن	۰-۵	۱۴-۶-۱	۶/۸۶	۰/۶۸	-۰/۵۳	۶/۸۳
شن	۵-۱۵	۱۴-۳-۱	۷/۰۱	۰/۶۹	-۰/۷۰	۶/۹۷
شن	۱۵-۳۰	۱۴-۶-۱	۷/۳۷	۰/۶۵	۱/۱۰	۷/۲۸
شن	۳۰-۶۰	۱۴-۵-۱	۹/۵۶	۰/۳۴	۱/۶۸	۹/۴۱
شن	۶۰-۱۰۰	۱۴-۸-۱	۱۰/۳۱	۰/۲۶	۱/۷۶	۱۰/۱۵

*: عدد اول (۱۴) تعداد ورودی‌های شبکه، عدد دوم تعداد نرون در لایه مخفی و عدد سوم تعداد خروجی شبکه است.

تفکیک بالا (۱۱٪) مهم‌ترین ورودی‌ها بودند. برای هر سه جزء سازنده بافت خاک در لایه سطحی متغیرهای کمکی مستخرج از تصاویر ماهواره‌ای اهمیت بیشتری داشتند. با افزایش عمق خاک از اهمیت متغیرهای کمکی مستخرج از تصویر ماهواره‌ای کاسته شد و در اعماق بیشتر متغیرهای کمکی مستخرج از خصوصیات اراضی از اهمیت بیشتری برخوردار شدند. تقی زاده مهرجردی و همکاران در بررسی شوری خاک ناحیه اردکان استان یزد به نتایج مشابهی دست پیدا کرده‌اند (Taghizadeh Mehrjardi *et al.*, 2014a). (Adhikari *et al.*, 2013) در بررسی‌های خود نشان داده‌اند که متغیرهای کمکی زمین‌شناسی، درجه شیب،

تجزیه و تحلیل حساسیت

در این تحقیق نتایج تجزیه و تحلیل حساسیت نشان داد که اهمیت نسبی متغیرهای کمکی برای پیش‌بینی نحوه توزیع اجزاء مختلف سازنده بافت خاک در اعماق مختلف متفاوت بوده و بعضی از متغیرهای کمکی از توانایی بیشتری برای افزایش دقت پیش‌بینی توزیع ذرات سازنده بافت خاک برخوردار بودند. به عنوان مثال در پیش‌بینی درصد رس خاک سطحی به ترتیب متغیرهای مولفه اول تصویر سنجده ETM^+ (۴۳٪)، شاخص رس (۴۰٪)، شاخص خبسی (۲۳٪) و شاخص همواری دره با درجه

بیشتری دارند. تعداد زیادی از متغیرهای کمکی که از DEM استخراج و در نقشه برداری رقومی استفاده می‌شوند در مناطق مسطح و کم شیب از تغییرپذیری کمی برخوردارند. بنابراین این متغیرها نمی‌توانند عامل اصلی کنترل کننده تغییرات برخی خواص خاک در این گونه مناطق باشند. در مقابل برخی شاخص‌های استخراج شده از تصاویر ماهواره‌ای مثل شاخص رس می‌توانند تغییرات بافت خاک را بهتر نشان دهند. در تحقیق حاضر نشان داده شد مولفه اول تصویر ماهواره‌ای و شاخص رس که از تصاویر ماهواره‌ای استخراج می‌شوند، بیشترین اهمیت را در پیش‌بینی بافت خاک داشتند.

پهنه‌بندی بافت خاک


با استفاده از متغیرهای کمکی و مدل شبکه عصبی مصنوعی، نقشه پیوسته درصد‌های رس، سیلت و شن و کلاس‌های بافت خاک در کل منطقه و برای پنج عمق استاندارد به دست آمد (شکل ۳). روند کلی توزیع مکانی رس در همه عمق‌ها تقریباً مشابه است. در همه لایه‌ها کمترین مقادیر رس در شمال شرق، جنوب و جنوب غرب منطقه و بیشترین مقادیر به صورت بخش-هایی تقریباً مجزا در قسمت‌های مرکزی دشت پراکنده شده است. به طور کلی با افزایش عمق، مقدار رس در بخش‌های غربی منطقه کاهش و در بخش‌های شرقی افزایش دارد. روند تغییرات شن و سیلت تقریباً برعکس رس است؛ به طوری که در بخش‌های جنوبی و جنوب غربی مقدار شن و سیلت زیاد و در سایر بخش‌ها مقدار آن‌ها کم است. همچنین روند کلی توزیع هر دو جزء در همه اعماق تقریباً مشابه بوده است و با افزایش عمق اختلاف بارزی در توزیع ذرات دیده نشد.

توزیع کلاس بافت لومی در هر پنج عمق تقریباً مشابه و این کلاس در بخش‌های جنوبی، جنوب شرقی و شمال شرقی نسبت به سایر قسمت‌ها غالب است. در بخش‌های مرکز دشت بافت بیشتر خاک‌های سطحی در کلاس لومی رسی و رسی قرار دارد. در بخش مرکزی دشت و در عمق دوم، سطحی از اراضی که در کلاس رسی قرار دارد کاهش و بخش عمده خاک‌های منطقه در کلاس بافت لومی رسی قرار می‌گیرند. هم‌چنین در این عمق مقدار رس در بخش‌های غربی و شمال غربی کاهش نشان داد. روند مشابه توزیع کلاس‌های بافت خاک در لایه‌های سطحی احتمالاً از عملیات شخم و در نتیجه همگن‌سازی بافت خاک در این لایه‌ها ناشی شده است. این وضعیت توسط محققین دیگر نیز گزارش شده است (Adkikari et al., 2013; Akpa et al., 2014). در عمق سوم، توزیع کلاس‌های بافت خاک در منطقه نامنظم است و در قسمت‌های جنوب و جنوب غربی منطقه به همراه بافت لومی، بخش‌های پراکنده‌ای با بافت لومی رسی هم وجود دارد. هم‌چنین در بخش شمال غربی

TWI، شاخص خیزی، MrVBF و عمق دره از بیشترین قابلیت پیش‌بینی برخوردار بوده و عامل جهت شیب نیز از این نظر در مرحله بعد قرار داشته است. (Greve et al., 2012b) در بررسی-های خود نشان داده‌اند که متغیرهای کمکی زمین‌شناسی و زمین‌نما^۱ در افزایش دقت برآوردهای مدل از بیشترین اهمیت برخوردار بوده و متغیرهای کمکی حاصل از داده‌های اقلیمی و درجه شیب به ترتیب در درجات اهمیت بعدی قرار داشته‌اند. در تحقیقی در نیجریه نشان داده شده است که متغیرهای کمکی مختلفی نظیر اطلاعات اقلیمی، شاخص‌های گیاهی، اطلاعات خاک‌شناسی، زمین‌شناسی و باندهای ماهواره لندست بر روی افزایش دقت مدل‌های مورد استفاده برای برآورد نحوه توزیع ذرات سازنده بافت تاثیر داشته و اهمیت نسبی آنها با عمق و از یک جزء تا جزء دیگر متفاوت بوده است (Akpa et al., 2014). همچنین نتایج این تحقیق نشان داد که تاثیر و اهمیت متغیرهای کمکی حاصل از خصوصیات زمین‌نما که بخش عمده‌ای از آن‌ها به کمک مدل رقومی ارتفاع تهیه می‌گردد تا حد بسیار زیادی به دقت مدل رقومی ارتفاع تهیه شده بستگی دارد. دقت مدل رقومی ارتفاع نیز خود تابع مقیاس نقشه توپوگرافی مورد استفاده برای تهیه خطوط تراز و دقت منحنی-های میزان است. افزون بر قدرت تفکیک مدل رقومی ارتفاع، موقعیت جغرافیایی، مواد مادری، زمین‌نما و بارندگی نیز نقش قابل توجهی در افزایش دقت مدل‌های مورد استفاده برای پیش-بینی اجزاء سازنده بافت خاک دارند (Greve et al., 2012b). بررسی‌های انجام شده در دانمارک نشان داده است که متغیرهای کمکی مواد مادری، موقعیت جغرافیایی و زمین‌نما بیشترین تاثیر را بر روی افزایش قابلیت پیش‌بینی مدل برای برآورد بافت خاک سطحی داشتند (Greve et al., 2012a). بر اساس این تحقیق، بارندگی روی رس و سیلت، ارتفاع روی شن درشت، شن ریز و رس، درجه شیب روی سیلت، جهت شیب و شاخص توپوگرافی روی شن ریز بیشترین تاثیر را داشته‌اند. با توجه به وسعت کم منطقه مورد مطالعه در تحقیق حاضر، پستی و بلندی کم و مواد مادری (زمین‌شناسی) نسبتاً یکسان (اغلب رسوبات آبرفتی)، تغییرات اقلیم، مواد مادری و شیب کم و به طور کلی و به خصوص در لایه‌های سطحی رابطه کمتری با بافت خاک داشتند. برخی بررسی‌ها نشان داده‌اند که در مناطق با پستی و بلندی کم مثل دشت‌ها، خصوصیات خاک با عوامل خاکسازگی که در نقشه برداری رقومی استفاده می‌شوند همبستگی زیادی ندارند (Liu et al., 2012). در این مناطق معمولاً شاخص‌های استخراج شده از تصاویر ماهواره‌ای اهمیت

هستند و تغییر بافت خاک با عمق، تغییرات مکانی زیاد بافت (Schaetzl and Anderson, 2005) و تغییر ضخامت لایه‌ها در آنها رایج است. بنابراین و با توجه به اینکه بخش عمده دشت مذکور از رسوبات آبرفتی تشکیل شده است، تفاوت در توزیع ذرات و کلاس‌های بافت خاک در اعماق مختلف، وجود کلاس‌های بافتی متضاد در کنار هم و در یک عمق و پراکنش نامنظم کلاس‌های بافت خاک در برخی از عمق‌ها (به خصوص عمق سوم) تا حدودی طبیعی به نظر می‌رسد. تفاوت در خصوصیات خاک از جمله بافت خاک در بخش‌های مختلف منطقه و هم چنین در عمق‌های مختلف خاک در مطالعات قبلی مشخص گردیده است (Amirian Chakan, 2012).

منطقه بافت لومی نسبت به لایه‌های رویین غالب‌تر شده است. همراه با بافت رسی در بخش‌های مرکزی دشت، قسمت‌هایی پراکنده و نامنظم با بافت شنی وجود دارد. وضعیت توزیع کلاس‌های بافت خاک در لایه‌های چهارم و پنجم تقریباً مشابه لایه اول است ولی به طور کلی سطح بیشتری از بخش مرکزی دشت در این لایه‌ها توسط کلاس بافت رسی پوشیده شده است. با توجه به اینکه دشت سیلاخور بین زون سنندج سیرجان در شمال و رشته کوه‌های زاگرس در جنوب قرار گرفته است، به نظر می‌رسد فاصله از کوه‌های اطراف روی بافت خاک تاثیر گذاشته است به طوری که در نزدیک کوه‌ها، مقدار رس کمتر و با افزایش فاصله از کوه‌ها به دلیل انتقال بیشتر ذرات ریزتر، مقدار رس بیشتر است. اغلب رسوبات آبرفتی لایه لایه



شکل ۳. نقشه رقومی ذرات رس، سیلت، شن و کلاس‌های بافت خاک (به ترتیب از بالا به پایین) در اعماق ۰-۵، ۵-۱۵، ۱۵-۳۰، ۳۰-۶۰ و ۶۰-۱۰۰ سانتی‌متر (به ترتیب از چپ به راست)

نتیجه گیری

داشتند. دقت معادله عمق اسپلاین و شبکه‌های عصبی مصنوعی در تخمین توزیع عمودی و افقی بافت خاک با افزایش عمق کم است که شاید بتوان با استفاده از متغیرهای کمکی و یا روش‌های تخمینی دیگر دقت مدل‌ها را بهبود بخشید. به طور کلی می‌توان نتیجه گرفت تلفیق این دو روش به خصوص در کشورهایی مثل ایران که داده‌های پیوسته مکانی و سه بعدی کم است ولی منابع استخراج متغیرهای کمکی در دسترس و ارزان است، ابزار مناسبی برای نشان دادن تغییرات افقی و عمودی ویژگی‌های خاک است.

نتایج این بررسی نشان داد هر چند که متغیرهای کمکی برای ذرات مختلف و در اعماق مختلف، اهمیت‌های نسبی متفاوتی در پیش بینی بافت خاک داشتند، ولی به طور کلی می‌توان با پیدا کردن ارتباط آنها با بافت خاک از طریق مدل‌هایی مثل شبکه‌های عصبی مصنوعی، نقشه پیوسته بافت خاک را با دقتی در حد قابل قبول در نقشه‌برداری رقومی خاک تهیه نمود. هم چنین خصوصیات استخراج شده از تصویر ماهواره‌ای در تخمین بافت خاک لایه‌های سطحی و خصوصیات استخراج شده از مدل رقومی ارتفاع در تخمین بافت لایه‌های عمقی اهمیت بیشتری

REFERENCES

- Adhikari, K., Kheir, R. B., Greve, M. B., Bocher, P. K., Malone, B. P., Minasny, B., McBratney, A. B. and Greve, M. H. (2013). High-resolution 3-D mapping of soil texture in Denmark. *Soil Science Society of America Journal*, 77, 860-876.
- Akpa, S. I. C., Odeh, I. O. A. and Bishop, T. F. A. (2014). Digital mapping of soil particle-size fractions for Nigeria. *Soil Science Society of America Journal*, 78, 1953-1966.
- Akumu, C. E., Johnson, J. A., Etheridge, D., Uhlig, P., Woods, M., Pitt, D. G. and McMurray, S. (2015). GIS-fuzzy logic based approach in modeling soil texture: Using parts of the Clay Belt and Hornepayne region in Ontario Canada as a case study. *Geoderma*, 239-240, 13-24.
- Amirian Chakan, A. (2012). *Spatial modeling of land suitability using fuzzy sets theory and geostatistics techniques*. Ph. D. dissertation, University of Tehran, Tehran.
- Baker, L. and Ellison, D. (2008). Optimization of pedotransfer functions using an artificial neural network ensemble method. *Geoderma*, 144, 212-224.
- Bishop, T. F. A., McBratney, A. B. and Laslett, G. M. (1999). Modelling soil attribute depth functions with equal-area quadratic smoothing splines. *Geoderma*, 91, 27-45.
- Campbell N. A., Mulcahy M. J. and McArthur W. M. (1970). Numerical classification of soil profiles on the basis of field morphological properties. *Australian Journal of Soil Research*, 8, 43-58.
- Du, K. L. and Swamy, M. N. S. (2006). *Neural networks in a soft computing framework*. London: Springer-Verlag.
- Greve, M. H., Kheir, R. B., Greve, M. B. and Bocher, P. K. (2012a). Quantifying the ability of environmental parameters to predict soil texture fractions using regression-tree model with GIS and LIDAR data: The case study of Denmark. *Ecological Indicators*, 18, 1-10.
- Greve, M. H., Kheir, R. B., Greve, M. B. and Bøcher, P. K. (2012b). Using digital elevation models as an environmental predictor for soil clay contents. *Soil Science Society of America Journal*, 76, 2116-2127.
- Hartemink, A. E. and McBratney, A. B. (2008). A soil science renaissance. *Geoderma*, 148, 123-129.
- Hengl, T., Rossiter D. G. and Stein, A. (2003). Soil sampling strategies for spatial prediction by correlation with auxiliary maps. *Geoderma*, 120, 75-93.
- Jenny, H. (1941). *Factors of soil formation: a system of quantitative pedology*. New York: McGrawHill.
- Kayadelen, C., Taskiran, T., Günaydin, O. and Fener, M. (2009). Adaptive neuro-fuzzy modeling for the swelling potential of compacted soils. *Environmental Earth Sciences*, 59, 109-115.
- Kempen, B., Brus, D. and Stoorvogel, J. J. (2011). Three-dimensional mapping of soil organic matter content using soil type-specific depth functions. *Geoderma*, 162, 107-123.
- Lagacherie, P. (2008). Digital soil mapping: a state of the art. In: A. E. Hartemink, A. B. McBratney, and M.d.L. Mendonça Santos (eds). *Digital soil mapping with limited data*. (pp. 3-14). London: Springer.
- Lacoste, M., Lemerrier, B. and Walter, C. (2011). Regional mapping of soil parent material by machine learning based on point data. *Geomorphology*, 133, 90-99.
- LieB, M., Glaser, B. and Huwe, B. (2012). Uncertainty in the spatial prediction of soil texture: comparison of regression tree and random forest models. *Geoderma*, 170, 70-79.
- Liu, F., Geng, X., Zhu, A. X., Fraser, W. and Waddell, A. (2012). Soil texture mapping over low relief areas using land surface feedback dynamic patterns extracted from MODIS. *Geoderma*, 171-172, 44-52.
- Malone, B. P., McBratney, A. B., Minasny, B. and Laslett, G. M. (2009). Mapping continuous depth functions of soil carbon storage and available water capacity. *Geoderma*, 154, 138-152.
- Malone, B.P., McBratney, A. B., Minasny, B. (2011). Empirical estimates of uncertainty for mapping continuous depth functions of soil attributes.

- Geoderma*, 160, 614-626.
- McBratney, A. B., Mendonça-Santos, M. L. and Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117, 3-52.
- Minasny, B., McBratney, A. B. and Lark, R. M. (2008). Digital soil mapping technologies for countries with sparse data infrastructures. In: A. E. Hartemink, A. B. McBratney, and M. d. L. Mendonça Santos (eds). *Digital soil mapping with limited data*. (pp. 15-30). London: Springer.
- Minasny, B. and Hartemink, A. E. (2011). Predicting soil properties in the tropics. *Earth Science Review*, 106, 52-62.
- Minasny, B., McBratney, A. B., Mendonca-Santos, M. L., Odeh, I. O. A. and Guyon, B. (2006). Prediction and digital mapping of soil carbon storage in the Lower Namoi Valley. *Australian Journal of Soil Research*, 44, 233-244.
- Mishra, U., Lal, R., Slater, B., Calhoun, F., Liu, D. and Van Meirvenne, M. (2009). Predicting soil organic carbon stock using profile depth distribution functions and ordinary kriging. *Soil Science Society of America Journal*, 73, 614-621.
- Nabiollahi, K., Haidari, A. and Taghizadeh Mehrjerdi, R. (2014). Digital mapping of soil texture using regression tree and artificial neural network in Bijar, Kurdistan. *Journal of Water and Soil*, 28, 1025-1036. (In Farsi)
- Nyssen, J., Tmesgen, H., Lemenih, M., Zenebe A., Haregeweyn, N. and Haile M. (2008). Spatial and temporal variation of soil organic carbon stocks in a lake retreat area of the Ethiopian Rift Valley. *Geoderma*, 146, 261-268.
- Ogders, N. P., Libohova, Z. and Thompson, J. A. (2012). Equal-area spline functions applied to a legacy soil database to create weighted-means maps of soil organic carbon at a continental scale. *Geoderma*, 189-190, 153-163.
- Ponce-Hernandez, R., Marriott, F. H. C. and Beckett, P. H. T. (1986). An improved method for reconstructing a soil profile from analysis of a small number of samples. *Journal of Soil Science*, 37, 455-467.
- Samarasinghe, S. (2007). *Neural networks for applied sciences and engineering*. New York: Taylor and Francis.
- Schetzl, R. and Anderson, S. (2005) *Soils: Genesis and geomorphology*. New York: Cambridge University Press.
- Sreekanth, P. D., Sreedevi, P. D., Ahmed, S. and Geethanjali, N. (2011). Comparison of FFNN and ANFIS models for estimating groundwater level. *Environmental Earth Sciences*, 62, 1301-1310.
- Soil Survey Staff. (2014). *Keys to soil taxonomy* (11th ed). Washington: USDA-NRCS.
- Stoorvogel, J. J., Kempen, B., Heuvelink, G. B. M. and Bruin, S. (2009). Implementation and evaluation of existing knowledge for digital soil mapping in Senegal. *Geoderma*, 149, 161-170.
- Taghizadeh Mehrjerdi R., Minasny B., Sarmadian F. and Malone P. B. (2014a). Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*, 213, 15-28
- Taghizadeh Mehrjerdi, R., Amirin Chakan, A. and Sarmadian, F. (2014b). 3D digital mapping of soil cation exchange capacity in Dorud, Lorestan province. *Journal of Water and Soil*, 28, 998-1010. (In Farsi)
- Thompson, J. A., Roecker, S., Grunwald, S and Owens, P. R. (2012). Digital soil mapping: Interactions with and applications for hydrogeology. In: H. Lin (ed). *Hydrogeology*. (pp. 665-709). Amsterdam: Academic Press.
- Vaysse, K. and Lagacherie, P. (2015). Evaluating digital soil mapping approaches for mapping GlobalSpilMap soil properties from legacy data in Languedoc Roussillon (France). *Geoderma*, 4, 20-30.