

Error and Uncertainty Analysis in the Preparation of Thematic Maps using Artificial Neural Network and Environmental Data

(A Case Study: Digital Soil Map of Shahrekord Plain)

**Mojtaba Shahini Shamsabadi ¹, Isa Esfandiarpour-Borujeni ^{2*}, Zohreh Mosleh ³,
Hossein Shirani ⁴, Mohammad Hassan Salehi ⁵**

¹ PhD Student of Soil Science Department, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

² Associate prof. of Soil Science Department, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

³ Assistant prof., Member of Scientific Board in Research, Education and Extension Organization, Karaj Agricultural and Natural Resources Research Center, Soil and Water Research Division, Karaj, Iran

⁴ Professor of Soil Science Department, Faculty of Agriculture, Vali-e-Asr University of Rafsanjan, Rafsanjan, Iran

⁵ Professor of Soil Science Department, Faculty of Agriculture, Shahrekord University, Shahrekord, Iran

Abstract

Soil maps have considerable significance as basic maps in many environmental and natural resources studies. Digital soil maps are based on the relationship between environmental variables and soil properties. The main purpose of this research was to analyze error and uncertainty of digital soil classes predicted at different taxonomic levels of Soil Taxonomy system using an artificial neural network. One hundred and twenty soil profiles were described and sampled based on a regular grid scheme in Shahrekord plain. Two groups of soil properties (qualitative and quantitative) and auxiliary parameters (including geologic map, landform map, landform-phase map, traditional soil map, normalized difference vegetation index, and some derivatives of digital elevation model) were used to estimate soil classes. After preparing the soil properties maps and checking their accuracy, these maps were used along with auxiliary parameters for estimating soil classes using an artificial neural network model in the R software. Finally, the accuracy and uncertainty of the model were evaluated by overall accuracy and confusion index, respectively. Results showed that the entry of more details in the soils classification at the lower levels of the Soil Taxonomy system, while increasing the number of classes, leads to decreasing the overall accuracy and increasing uncertainty. It is noticeable that the artificial neural network model has a good accuracy up to the great group level through the acceptable level of overall accuracy (i.e., 75 %), hence it has a high degree of uncertainty. Therefore, the accuracy of the model could not be effective in its selection through the modeling process; however, paying attention to its uncertainty is also very important along with the model error. Accordingly, we suggest using the other methods of soft computing for modeling in plain areas or in low relief regions.

Key words: Error Matrix, Modeling, Soil Map, Soil Taxonomy System.

بررسی خطا و عدم قطعیت در تهیه نقشه‌های موضوعی با استفاده از شبکه عصبی مصنوعی و داده‌های محیطی

مطالعه موردی: نقشه رقومی خاک دشت شهرکرد

مجتبی شاهینی شمس‌آبادی: دانشجوی دکتری علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ولی‌عصر رفسنجان، رفسنجان، ایران
عیسی اسفندیارپور بروجنی^{*}: دانشیار گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ولی‌عصر رفسنجان، رفسنجان، ایران
زهره مصلح: استادیار بخش خاک و آب، مرکز تحقیقات کشاورزی و منابع طبیعی کرج، کرج، ایران
حسین شیرانی: استاد گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه ولی‌عصر رفسنجان، رفسنجان، ایران
محمدحسن صالحی: استاد گروه علوم خاک، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران

وصول: ۱۳۹۸/۰۲/۱۳ پذیرش: ۱۳۹۸/۰۲/۲۴، صص ۳۶-۲۳

چکیده

نقشه‌های خاک به‌منزله یکی از نقشه‌های پایه در بسیاری از مطالعات مرتبط با محیط و منابع طبیعی اهمیت زیادی دارند. نقشه‌های رقومی خاک بر پایه ارتباط بین ویژگی‌های محیطی و خاک پایه‌ریزی شده‌اند. هدف از انجام پژوهش حاضر، بررسی خطا و عدم قطعیت کلاس‌های رقومی خاک پیش‌بینی‌شده در سطوح مختلف سامانه رده‌بندی آمریکایی با استفاده از مدل شبکه عصبی مصنوعی است. تعداد ۱۲۰ خاک‌رخ بر مبنای یک الگوی شبکه‌ای منظم در دشت شهرکرد حفر، تشریح و نمونه‌برداری شد. برای تخمین کلاس‌های خاک، دو گروه ویژگی‌های خاکی (کمی و کیفی) و داده‌های کمکی (شامل نقشه زمین‌شناسی، نقشه شکل اراضی، نقشه فاز شکل اراضی، نقشه خاک سنتی منطقه، شاخص تفاضل نرمال‌شده پوشش گیاهی و بعضی مشتقات مدل ارتفاع رقومی) مدنظر قرار گرفت. پس از تهیه نقشه‌های ویژگی‌های خاک و اطمینان از صحت و دقت آنها، این نقشه‌ها به همراه داده‌های کمکی برای تخمین کلاس‌های خاک با مدل شبکه عصبی مصنوعی در محیط نرم‌افزار R استفاده شدند و در نهایت دقت و عدم قطعیت مدل مزبور به ترتیب با صحت عمومی و شاخص درهمی ارزیابی شد. نتایج نشان داد ورود جزئیات بیشتر در رده‌بندی خاک‌ها در سطوح پایین طبقه‌بندی، ضمن افزایش تعداد کلاس‌ها، کاهش صحت عمومی و افزایش عدم قطعیت را به همراه داشته است. با توجه به حد پذیرفته صحت عمومی (۷۵ درصد)، مدل شبکه عصبی مصنوعی از صحت لازم تا سطح گروه بزرگ برخوردار بوده است؛ اما عدم قطعیت زیادی را داشته است؛ بنابراین صرف توجه به صحت مدل در انتخاب آن برای مدل‌سازی مؤثر نیست؛ بلکه در کنار خطای مدل، توجه به عدم قطعیت آن نیز بسیار مهم است. بر این اساس، به‌کارگیری روش‌های دیگری از محاسبات نرم برای مدل‌سازی در مناطق دشت یا مناطق با ناهمواری‌های کم پیشنهاد می‌شود.

واژه‌های کلیدی: ماتریس خطا، مدل‌سازی، نقشه خاک، سامانه طبقه‌بندی خاک.

مقدمه

در نقشه‌برداری رقومی خاک همواره تخمین‌های حاصل کمی خطا دارند و در نتیجه برآوردهای انجام‌شده با عدم قطعیت همراه هستند. عدم قطعیت نتیجه نبود اطمینان از واقعیت است (Heuvelink, 2014: 335). عدم قطعیت نقشه‌های رقومی خاک معمولاً با استفاده از مجموعه‌ای از مشاهدات مستقل خاک و بعضی شاخص‌ها (مانند شاخص درهمی^۲) ارزیابی می‌شود.

پژوهش لاگاچری و همکاران (۲۰۱۹) نشان داد با کاهش تعداد نقاط مشاهداتی، مقدار شاخص‌های عدم قطعیت بیشتر شده است (Lagacherie et al, 2019: 1320).

شادمان رودپشتی و همکاران (۲۰۱۹) با استفاده از روش آنروپی عدم قطعیت دو مدل شبکه عصبی عمیق^۳ و جنگل تصادفی عمومی^۴ را در رابطه با طبقه‌بندی تصویر ابرطیفی^۵ بررسی و نتیجه‌گیری کردند الگوریتم شبکه عصبی عمیق دقت بیشتری برای تخمین طبقه‌بندی داشته، اما مقدار عدم قطعیت آن بیشتر از روش جنگل تصادفی عمومی بوده است (Shadman Roodposhti et al, 2019: 78).

پاداریان و همکاران (۲۰۱۹) با استفاده از مدل شبکه عصبی حلقوی^۶، نقشه‌های رقومی خاک را تهیه و نتیجه‌گیری کردند این مدل در مقایسه با روش‌های سنتی، خطا را به میزان ۳۰ درصد کاهش داده است. آنها همچنین عدم قطعیت این نقشه‌ها را به روش ۹۰ درصد فاصله تخمین به دست آوردند و اظهار داشتند این مدل در مقایسه با روش‌های سنتی عدم قطعیت تخمین کمتر

مطالعات محیطی و جغرافیایی نقش بسیار مهمی در استفاده درست و پایدار از سرزمین و نقشه‌های خاک به منزله یکی از نقشه‌های پایه اهمیت زیادی در بسیاری از مطالعات مرتبط با محیط و منابع طبیعی دارند. در واقع نقشه‌های خاک، نمایش ساده‌ای از پراکنش خاک‌ها در طبیعت‌اند. امروزه نقشه‌برداری رقومی خاک به دلیل صرفه‌جویی در وقت و هزینه، کاربرد گسترده‌ای در برآورد کلاس‌های خاک پیدا کرده است (Padarian et al, 2019: 18). به منظور بررسی آثار متقابل متغیرهای محیطی و تأثیر آنها در تشکیل خاک، مدل‌سازی مکانی عوارض زمین، راهکار مناسب و ثابت‌شده‌ای در این زمینه است (Behrens et al, 2018: 136). یکی از اجزای اصلی نقشه‌برداری رقومی خاک، تابع یا مدل ارتباط‌دهنده بین متغیرهای محیطی و خاک است. یکی از مدل‌های استفاده‌شده در نقشه‌برداری رقومی خاک، مدل شبکه عصبی مصنوعی است. شبکه‌های عصبی مصنوعی، گروهی از مدل‌های داده‌محور غیرخطی و عمومی پایدار در برابر تغییرات ناگهانی‌اند و توانایی آموزش و تعمیم را در محیط‌هایی دارند که از نظر داده غنی هستند (Oscar and Melin, 2002: 1396). این شبکه‌ها را برای نخستین بار در سال ۱۹۴۳ وارن مک‌کولوچ و والتر پیتس^۱ معرفی کردند. به طور کلی شبکه‌های عصبی مصنوعی برمبنای ایجاد سامانه‌ای به وجود آمده‌اند که توانایی شبیه‌سازی محاسبات مغز را دارد. این شبکه‌ها این پتانسیل را دارند که در فرایند مدل‌سازی جایگزین روش‌های سنتی شوند (Bekat et al, 2012: 883).

² Confusion index (CI)

³ Deep neural network

⁴ Popular random forest

⁵ Hyperspectral image classification

⁶ Convolutional neural network

¹ McCulloch and Pitts, 1943

ادامه براساس داده‌های محیطی به دست آمده از مدل رقومی ارتفاع و نقشه‌های کمکی، وجود یا نبود افق‌های مزبور با استفاده از شبکه عصبی مصنوعی در کل منطقه پیش‌بینی و برای تخمین درصد رس، درصد ذرات درشت، درصد کربنات کلسیم معادل، کرومای کوچک‌تر یا مساوی ۲ و ظرفیت تبادل کاتیونی نیز از شبکه عصبی مصنوعی استفاده شد. پس از تهیه نقشه‌های ویژگی‌های خاک یادشده و اطمینان از صحت نقشه‌های به دست آمده، این نقشه‌ها به همراه داده‌های کمکی برای تخمین کلاس‌های خاک به کار رفتند.

داده‌های کمکی استفاده شده در پژوهش حاضر شامل نقشه زمین‌شناسی، نقشه شکل اراضی، نقشه فاز شکل اراضی، نقشه خاک سنتی منطقه، شاخص تفاضل نرمال شده پوشش گیاهی (NDVI)^۱ (Rouse et al, 1974: 55) و بعضی مشتقات مدل ارتفاع رقومی شامل انحنا طولی^۲، انحنا مقطعی^۳، جهت شیب^۴، ارتفاع^۵، مقدار شیب^۶، تحلیل سایه‌اندازی تپه‌ها^۷، شاخص همگرایی^۸، حوضچه‌های بسته^۹، منطقه آبرگیر^{۱۰}، شاخص خیزی ناهمواری^{۱۱}، عامل LS^{۱۲}، سطح پایه شبکه کانال^{۱۳}، فاصله عمودی تا شبکه کانال^{۱۴}، عمق دره^{۱۵} و موقعیت شیب نسبی^{۱۶} بود. برای

و توانایی بیشتری در پیش‌بینی کربن لایه‌های عمقی خاک دارد (Padarian et al, 2019: 89).

تاکنون بیشتر مطالعات انجام شده درباره تهیه نقشه عدم قطعیت ویژگی‌های خاک بوده (Kempen et al, 2014: 85-90, Padarian et al, 2019: 79-89, Lagacherie et al, 2016: 201-215, Heuvelink et al, 2019: 1320-1328, Szatmari and Pasztor, 2019: 1329-1340) و کمتر برای تهیه نقشه عدم قطعیت کلاس خاک تلاش شده است؛ بنابراین در این مطالعه سعی شده است نخست نقشه‌های رقومی کلاس‌های خاک دشت شهرکرد با شبکه عصبی مصنوعی برای سلسله‌مراتب مختلف موجود در سامانه رده‌بندی آمریکایی (۲۰۱۴) و سپس نقشه‌های پیوسته عدم قطعیت این نقشه‌های رقومی با استفاده از شاخص درهمی (CI) تهیه و مقایسه شوند.

روش‌شناسی پژوهش

تهیه نقشه‌های ویژگی‌ها و کلاس‌های خاک

در پژوهش حاضر از دو گروه مختلف اطلاعات شامل ویژگی‌های خاکی (مستخرج از اطلاعات ۱۲۰ خاک‌رخ حفار شده در دشت شهرکرد) و داده‌های کمکی برای تخمین کلاس‌های خاک استفاده شد؛ همچنین بعضی افق‌های مشخص شامل افق تجمع رس (آرجیلیک)، افق تجمع کربنات‌ها (کلسیک) و افق تجمع کربنات‌های سخت شده (پتروکلسیک)، ویژگی‌های اصلی تفکیک‌کننده خاک‌های مطالعاتی در هر سطح از سطوح سلسله‌مراتبی سامانه رده‌بندی آمریکایی (۲۰۱۴)، به مثابه ویژگی‌های خاکی مدنظر قرار گرفتند و پس از بررسی وجود یا نبود آنها، به همراه داده‌های کمکی در فرایند مدل‌سازی استفاده شدند. در

¹ Normalized difference vegetation index

² Longitudinal curvature

³ Cross sectional curvature

⁴ Aspect

⁵ Elevation

⁶ Slope

⁷ Analytical hill shading

⁸ Convergence index

⁹ Closed depressions

¹⁰ Catchment area

¹¹ Topographic wetness index

¹² LS factor

¹³ Channel network base level

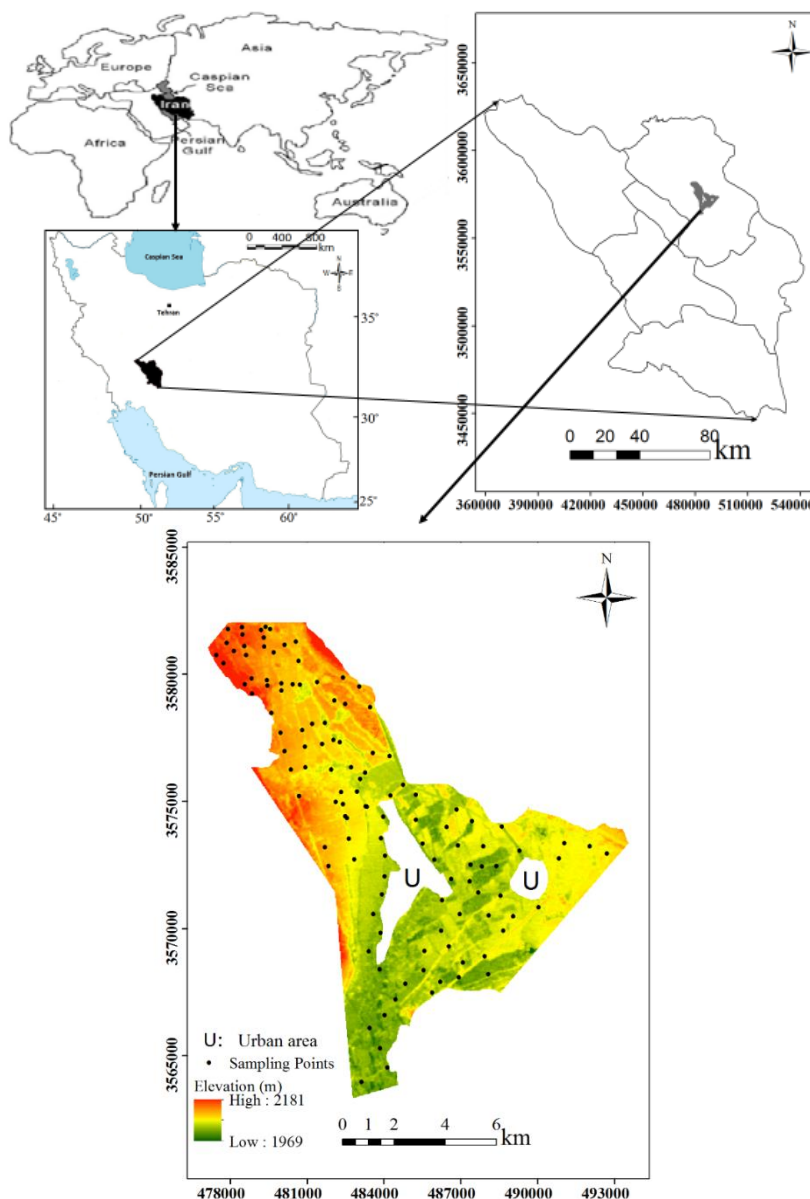
¹⁴ Vertical distance to channel network

¹⁵ Valley depth

¹⁶ Relative slope position

سلسله‌مراتب ارائه‌شده با زینک (-Zinck, 1989: 39) 45 تهیه شدند؛ همچنین نقشه زمین‌شناسی منطقه با مقیاس ۱:۲۵۰۰۰ و نقشه خاک منطقه با مقیاس ۱:۵۰۰۰۰ (محمدی، ۱۳۶۵: ۱-۲۳۹) بود. شاخص NDVI (Rouse et al, 1974: 55) نیز براساس اطلاعات حاصل از تصاویر به‌دست‌آمده از ماهواره لندست ۸ در ژوئن ۲۰۱۷ محاسبه شد.

تهیه این مشتقات، نخست مدل ارتفاع رقومی منطقه با قدرت تفکیک ۳۰×۳۰ متر از سازمان نقشه‌برداری کشور ایران و سپس با استفاده از نرم‌افزارهای Arc-GIS (نسخه ۱۰/۳) و SAGA (نسخه ۴.۱.۲) (Olaya, 2004: 1-208)، مشتقات مدل ارتفاع رقومی تهیه شد. نقشه‌های ژئوform منطقه (شامل نقشه شکل اراضی و نقشه فاز شکل اراضی) نیز با بهره‌گیری از عکس‌های هوایی ۱:۴۰۰۰۰ (تهیه‌شده در سال ۱۳۸۱) و براساس



شکل ۱. محل ۱۲۰ نقطه نمونه‌برداری شده در دشت شهرکرد

نشان‌دهنده خطاهای مطلق تخمین است و با استفاده از رابطه زیر محاسبه می‌شود (Farifteh et al, 2007):

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

در این رابطه، P_i و O_i به ترتیب مقادیر پیش‌بینی شده و واقعی ویژگی مدنظرند و n تعداد کل مشاهدات است.

به دلیل حساسیت بیشتر RMSE به داده‌های پرت (Farifteh et al, 2007: 73)، آماره جذر میانگین مربع خطای نسبی (RMSE%) با رابطه زیر محاسبه شد:

$$RMSE\% = \frac{RMSE}{\bar{X}} \times 100 \quad (3)$$

در این رابطه \bar{X} میانگین مقادیر واقعی مشاهدات است.

بدون بعدبودن آماره اخیر، امکان مقایسه صحت برای ویژگی‌های مختلف با دامنه تغییرپذیری متفاوت را فراهم می‌کند (Park and Vlek, 2002: 128). هنگل و همکاران (۲۰۰۴) اظهار داشتند مقادیر RMSE% کمتر از ۴۰، حاکی از تخمین درست و مقادیر بیش از ۷۱ به معنای آن است که پیش‌بینی مدنظر عدم قطعیت بسیاری دارد (Hengl et al, 2004: 90).

تعیین عدم قطعیت مدل‌ها

پس از مدل‌سازی کلاس‌های خاک، عدم قطعیت در هر یک از سطوح رده‌بندی سامانه رده‌بندی آمریکایی (۲۰۱۴) با استفاده از شاخص درهمی (CI) تعیین شد (Odgers et al, 2011: 41; Brungard et

مدل‌های استفاده‌شده برای پیش‌بینی کلاس‌های رقومی خاک

برای پیش‌بینی کلاس‌های خاک در هر یک از سطوح رده‌بندی آمریکایی (۲۰۱۴) از شبکه عصبی مصنوعی استفاده و این مدل در نرم‌افزار رایگان R 3.1.1 ([https://cran.r-project.org/bin/windows/](https://cran.r-project.org/bin/windows/base/old/3.1.1/)) اجرا شد. در این نرم‌افزار برای اجرای مدل شبکه عصبی مصنوعی، بسته‌های caret و nnet به کار رفت.

ارزیابی صحت مدل‌ها

داده‌های استفاده‌شده در پژوهش حاضر به‌طور تصادفی به داده‌های آموزشی (۸۰ درصد) و اعتبارسنجی (۲۰ درصد) تقسیم و مدل‌های مختلف با داده‌های آموزشی برازش داده شدند؛ سپس پیش‌بینی براساس داده‌های اعتبارسنجی انجام شد. ارزیابی صحت مدل‌ها در پیش‌بینی ویژگی‌های کیفی و کلاس‌های خاک با مقایسه ویژگی‌ها و کلاس‌های خاک دیده و پیش‌بینی‌شده با استفاده از شاخص صحت عمومی (OA)^۱ به صورت زیر انجام شد (Byrt et al, 1993: 425):

$$OA = \sum_{i=1}^n X_{ii} / N \quad (1)$$

در این رابطه n تعداد سطرها یا ستون‌های ماتریس خطا، X_{ii} کلاس‌هایی که به درستی پیش‌بینی شده‌اند و N تعداد کل مشاهدات است.

درباره ارزیابی صحت ویژگی‌های کمی مدنظر، شاخص RMSE در نظر گرفته شد.

¹ Overall accuracy

است. بخش اعظم دشت شهرکرد به‌واسطه زمین‌های حاصلخیز زیر کشت قرار دارد و کاربری عمده اراضی موجود در این منطقه شامل کشت آبی گندم، یونجه، سیب‌زمینی و ذرت علوفه‌ای است.

یافته‌های پژوهش

خاک‌های شناسایی‌شده در منطقه برمبنای سامانه رده‌بندی آمریکایی (۲۰۱۴)

در شکل (۲) نحوه توزیع فامیل‌های خاک و جدول (۱) شرح فامیل‌های خاک موجود نشان داده شده است. تعداد کلاس‌های خاک در سطوح رده، زیررده، گروه بزرگ، زیرگروه و فامیل خاک، به ترتیب ۲، ۳، ۶، ۱۰ و ۵۱ (کل فامیل‌ها نشان داده نشده‌اند) است و فامیل Fine, mixed, semiactive, mesic Typic Calcixerepts با فراوانی ۱۰ درصد، غالب‌ترین خاک در منطقه محسوب می‌شود. از آنجا که بعضی مشاهدات فقط یک نمونه دارند، با یکدیگر با نام «دیگر فامیل‌های خاک» ادغام شدند (Pahlavan Rad et al, 2014: 104) که در شکل (۲) و جدول (۱) با حرف «A» نشان داده شده است.

al, 2015: 75). برای این منظور میزان احتمال حضور هر یک از کلاس‌های خاک در هر پیکسل تعیین و در نهایت با تجمیع تمامی این لایه‌ها، شاخص CI براساس رابطه زیر محاسبه شد:

$$CI = [1 - (\mu_{max} - \mu_{(max-1)})] \quad (4)$$

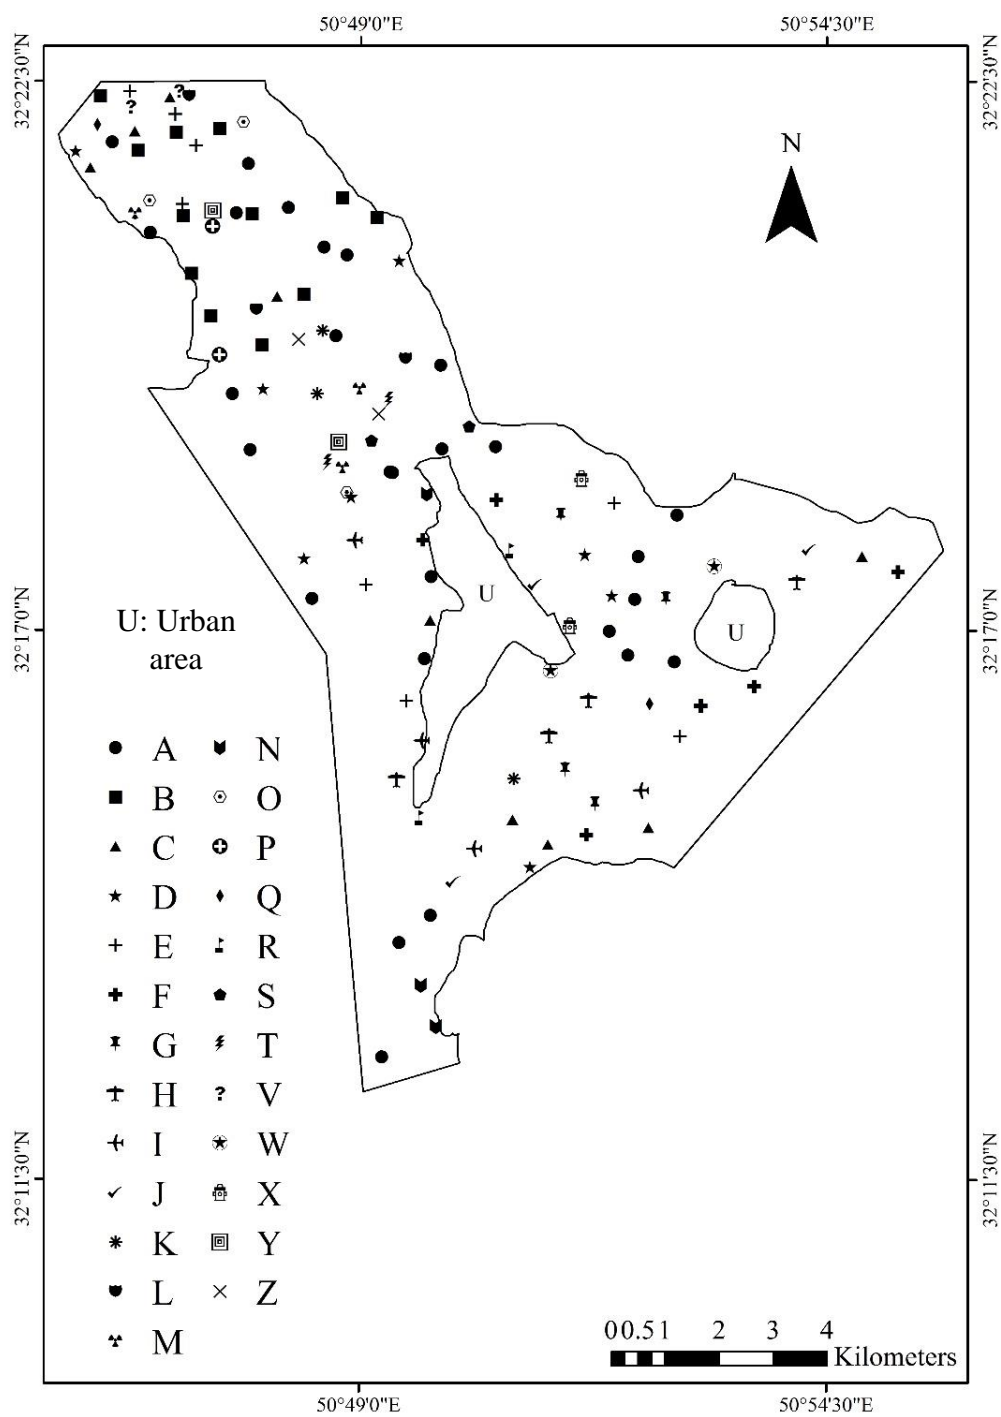
در این رابطه μ_{max} مقدار بیشینه احتمال در هر پیکسل و $\mu_{(max-1)}$ مقدار دومین احتمال در همان پیکسل است. مقادیر شاخص CI از صفر تا یک متغیر و مقادیر بیش از آن نشان‌دهنده عدم قطعیت بیشتر است.

معرفی محدوده پژوهش

منطقه پژوهش بخشی از دشت شهرکرد واقع در استان چهارمحال و بختیاری است که بین طول‌های جغرافیایی ۵۰ درجه و ۴۵ دقیقه تا ۵۰ درجه و ۵۹ دقیقه شرقی و عرض‌های جغرافیایی ۳۲ درجه و ۱۲ دقیقه تا ۳۲ درجه و ۲۳ دقیقه شمالی قرار گرفته است. مساحت تقریبی منطقه پژوهش ۱۰۰۰۰ هکتار است که از این مساحت، ۴۸۰۰ هکتار آن شامل اراضی قابل کشت است (شکل ۱). میانگین بارندگی و دمای سالیانه منطقه در یک دوره آماری ۵۰ ساله (سال‌های ۱۹۶۷ تا ۲۰۱۷) به ترتیب ۳۲۶ میلیمتر و ۱۲/۲ درجه سلسیوس و میانگین ارتفاع منطقه از سطح دریا، ۲۰۶۰ متر است. رژیم‌های رطوبتی و حرارتی خاک‌های منطقه مطالعاتی به ترتیب زیریک^۱ و مزیک^۲ هستند. فیزیوگرافی اصلی این منطقه، دشت آبرفتی و مواد مادری آن به‌طور عمده شامل سنگ‌های آهکی

^۱ Xeric

^۲ Mesic



شکل ۲. توزیع فامیل‌های مختلف خاک در منطقه مطالعاتی

جدول ۱. راهنمای فامیل‌های خاک موجود در شکل ۲

| درصد فراوانی | فامیل خاک | علامت |
|--------------|---|-------|
| 21.7 | Other soil families | A |
| 10 | Fine, Mixed, Semiactive, Mesic Typic Calcixerepts | B |
| 8 | Fine-silty, Mixed, Semiactive, Mesic Typic Calcixerepts | C |
| 6.7 | Fine-silty, Carbonatic, Mesic Typic Calcixerepts | D |
| 6.7 | Fine-silty, Mixed, Active, Mesic Typic Calcixerepts | E |
| 5 | Fine-silty, Mixed, Active, Calcareous, Mesic Typic Haploxerepts | F |
| 3.3 | Fine, Carbonatic, Mesic Typic Haploxerepts | G |
| 3.3 | Fine, Mixed, Semiactive, Calcareous, Mesic Typic Haploxerepts | H |
| 3.3 | Fine-silty, Mixed, Semiactive, Calcareous, Mesic Typic Haploxerepts | I |
| 2.5 | Coarse-silty, Carbonatic, Mesic Typic Haploxerepts | J |
| 2.5 | Fine, Carbonatic, Mesic Typic Calcixerepts | K |
| 2.5 | Fine, Mixed, Semiactive, Mesic Petrocalcic Calcixerepts | L |
| 2.5 | Fine-silty, Carbonatic, Mesic Petrocalcic Calcixerepts | M |
| 2.5 | Fine-silty, Mixed, Semiactive, Calcareous, Mesic Aquic Haploxerepts | N |
| 2.5 | Loamy-skeletal, Carbonatic, Mesic Typic Calcixerepts | O |
| 1.7 | Clayey, Carbonatic, Mesic, Shallow Petrocalcic Calcixerepts | P |
| 1.7 | Coarse-loamy, Carbonatic, Mesic Typic Calcixerepts | Q |
| 1.7 | Fine, Carbonatic, Mesic Aquic Haploxerepts | R |
| 1.7 | Fine, Mixed, Semiactive, Mesic Calcic Haploxeralfs | S |
| 1.7 | Fine, Mixed, Semiactive, Mesic Petrocalcic Palaxeralfs | T |
| 1.7 | Fine-loamy, Mixed, Active, Mesic Typic Calcixerepts | V |
| 1.7 | Fine-silty, Carbonatic, Mesic Aquic Haploxerepts | W |
| 1.7 | Fine-silty, Carbonatic, Mesic Typic Haploxerepts | X |
| 1.7 | Fine-silty, Carbonatic, Mesic, Shallow Petrocalcic Calcixerepts | Y |
| 1.7 | Fine-silty, Mixed, Active, Mesic, Shallow Petrocalcic Calcixerepts | Z |

ویژگی‌های خاکی پیش‌بینی شده

پیش‌بینی شده در پژوهش حاضر است. همچنین در

جدول (۲) نشان‌دهنده مقادیر صحت عمومی

جدول (۳) نتایج ارزیابی حاصل از پیش‌بینی

(OA) محاسبه شده برای ویژگی‌های کیفی خاک

ویژگی‌های کمی خاک آورده شده است.

جدول ۲. مقادیر صحت عمومی پیش‌بینی ویژگی‌های کیفی خاک با مدل شبکه عصبی مصنوعی

| صحت عمومی | ویژگی کیفی خاک |
|-----------|--|
| 0.89 | افق تجمع رس (آرجیلیک) |
| 0.73 | افق تجمع کربنات‌ها (کلسیک) |
| 0.85 | افق تجمع کربنات‌های سخت‌شده (پتروکلسیک) |
| 0.5 | افق دارای شرایط اولیه تغییر و تحول (کمبیک) |
| 0.87 | کرومای مساوی ۱ |
| 0.78 | کرومای مساوی ۲ |

جدول ۳. مقادیر خطای پیش‌بینی ویژگی‌های کمی خاک با مدل شبکه عصبی مصنوعی

| ویژگی کمی خاک | RMSE | RMSE% |
|--|------|-------|
| درصد سنگریزه | 2.5 | 89 |
| درصد رس خالص | 10.9 | 32 |
| ظرفیت تبادل کاتیونی ($\text{cmol} + \text{kg}^{-1}$) | 1.1 | 9 |
| درصد کربنات کلسیم معادل | 11.2 | 38 |

خطی تعمیم‌یافته و رگرسیون خطی چندگانه معرفی کردند (Mosleh et al, 2016: 1).

باقری بداغ‌آبادی و همکاران (۲۰۱۵) نیز مدل شبکه عصبی مصنوعی را مدلی توانا در نقشه‌برداری رقمی خاک با استفاده از مشتقات مدل رقمی ارتفاع می‌دانند (Bagheri Bodaghabadi et al, 2015: 589). جدول‌های (۴) و (۵) به ترتیب نشان‌دهنده داده‌های محیطی انتخاب‌شده برای هر ویژگی (با توجه به اطلاعات موجود در جدول‌های ۲ و ۳) هستند.

ملاحظه می‌شود که مدل شبکه عصبی مصنوعی برای ویژگی‌های درصد رس خالص، درصد کربنات کلسیم معادل و ظرفیت تبادل کاتیونی پیش‌بینی پذیرفته‌ای را ارائه داده است (جدول ۳)؛ لیکن در تخمین سنگریزه دقت خوبی نداشته و برای این ویژگی به استفاده از مدل‌های دیگری نیاز است.

مصلح و همکاران (۲۰۱۶) مدل شبکه عصبی مصنوعی را بهترین مدل برای پیش‌بینی درصد ذرات درشت نسبت به مدل‌های درخت رگرسیون، مدل

جدول ۴. داده‌های محیطی انتخاب‌شده برای هر ویژگی کیفی خاک براساس نتایج مدل شبکه عصبی مصنوعی

| ویژگی کیفی خاک | داده‌های محیطی |
|--|---|
| افق تجمع رس (آرجیلیک) | منطقه آبگیر، تحلیل سایه‌اندازی تپه‌ها، مقدار شیب |
| افق تجمع کربنات‌ها (کلسیک) | سطح پایه شبکه کانال، عمق دره |
| افق تجمع کربنات‌های سخت‌شده (پتروکلسیک) | منطقه آبگیر، شاخص خیزی ناهمواری، تحلیل سایه‌اندازی تپه‌ها |
| افق دارای شرایط اولیه تغییر و تحول (کمبیک) | سطح پایه شبکه کانال، عمق دره |
| کرومای مساوی ۱ | سطح پایه شبکه کانال، عمق دره، منطقه آبگیر |
| کرومای مساوی ۲ | سطح پایه شبکه کانال، عمق دره |

جدول ۵. داده‌های محیطی انتخاب‌شده برای هر ویژگی کمی خاک براساس نتایج مدل شبکه عصبی مصنوعی

| ویژگی کمی خاک | داده‌های محیطی |
|--|---|
| درصد سنگریزه | عامل LS، انحنای مقطعی، مقدار شیب |
| درصد رس خالص | منطقه آبگیر، سطح پایه شبکه کانال، انحنای مقطعی |
| ظرفیت تبادل کاتیونی ($\text{cmol} + \text{kg}^{-1}$) | منطقه آبگیر، سطح پایه شبکه کانال، موقعیت شیب نسبی |
| درصد کربنات کلسیم معادل | منطقه آبگیر، سطح پایه شبکه کانال |

پیش‌بینی اهمیت بیشتری دارد. به‌طورکلی درباره ویژگی‌های کیفی خاک، دو عامل سطح پایه شبکه

همان‌طور که در جدول‌های (۴) و (۵) دیده می‌شود برای هر ویژگی چند عامل محیطی در انجام

تغییرات شاخص درهمی (CI) یا به عبارتی عدم قطعیت افزایش می‌یابد. این نتایج با یافته‌های پژوهشگران مختلف (از جمله: Heung et al, 2016; Szatmári and Brungard et al, 2015: 80؛ 62؛ Pásztor, 2019: 1337) همخوانی دارد.

نتایج همچنین نشان داد علاوه بر ویژگی‌های خاکی انتخاب‌شده کارشناس برای مدل‌سازی کلاس‌های خاک در هرکدام از سطوح سامانه رده‌بندی خاک آمریکایی (به بند ۲-۲ در بخش مواد و روش‌ها مراجعه شود)، داده‌های محیطی تحلیل سایه‌اندازی تپه‌ها در سطح رده، منطقه آبگیر در سطح زیررده، سطح پایه شبکه کانال و عمق دره در سطح گروه بزرگ، سطح پایه شبکه کانال در سطح زیرگروه و منطقه آبگیر در سطح فامیل براساس بهترین مدل در تخمین کلاس‌های خاک مؤثر بوده‌اند.

کانال و عمق دره، نقش بارزتری داشته‌اند؛ این در حالی است که درباره ویژگی‌های کمی خاک، عوامل منطقه آبگیر و سطح پایه شبکه کانال از اهمیت بیشتری برخوردار بوده‌اند.

باقری بداغ‌آبادی و همکاران (۲۰۱۱) نیز مشتقات مدل رقومی ارتفاع را عوامل مهمی برای تخمین انواع خاک بیان کرده‌اند (Bagheri Bodaghabadi et al, 2011: 66).

خطا و عدم قطعیت پیش‌بینی کلاس‌های رقومی خاک

جدول (۶) نتایج ارزیابی شبکه عصبی مصنوعی را در پیش‌بینی کلاس‌های رقومی خاک برای سطوح مختلف سامانه رده‌بندی آمریکایی (۲۰۱۴) نشان می‌دهد. به‌طور کلی دیده می‌شود از سطح رده به سمت فامیل، مقدار صحت عمومی (OA) کاهش و دامنه

جدول ۶. نتایج مدل‌سازی کلاس‌های خاک در سطوح مختلف سامانه رده‌بندی آمریکایی (۲۰۱۴)*

| شاخص درهمی | صحت عمومی | سطح رده‌بندی |
|------------|-----------|--------------|
| 0.1-0.7 | 0.82 | رده |
| 0.22-0.41 | 0.86 | زیررده |
| 0.42-0.83 | 0.68 | گروه بزرگ |
| 0.2-0.9 | 0.43 | زیرگروه |
| - | 0.18 | فامیل |

* علامت خط تیره (-) نشان‌دهنده آن است که مدل توانایی پیش‌بینی کلاس‌های خاک را برای سطح مربوطه نداشته است.

عصبی صحت لازم را دارد. هرچند در سطح گروه بزرگ (۶۸ درصد) مقدار صحت عمومی به دست آمده از حد ۷۵ درصد کمتر است، لیکن این عدد در حد صحت متوسط رو به بالا پذیرفته است.

نکته شایسته تأمل در این زمینه، صحت محاسبه‌شده برای سطح فامیل یعنی ۱۸ درصد است؛ به بیان دیگر به یک‌باره از سطح زیرگروه به سطح



براساس استاندارد، کمترین خلوص لازم برای تعریف یک واحد نقشه همگون^۱، ۷۵ درصد است که شامل دست‌کم ۵۰ درصد از خاک غالب و ۲۵ درصد از خاک مشابه آن است (Soil Science Division Staff, 2017: 257)؛ بنابراین با توجه به حد پذیرفته صحت عمومی (۷۵ درصد)، تا سطح گروه بزرگ مدل شبکه

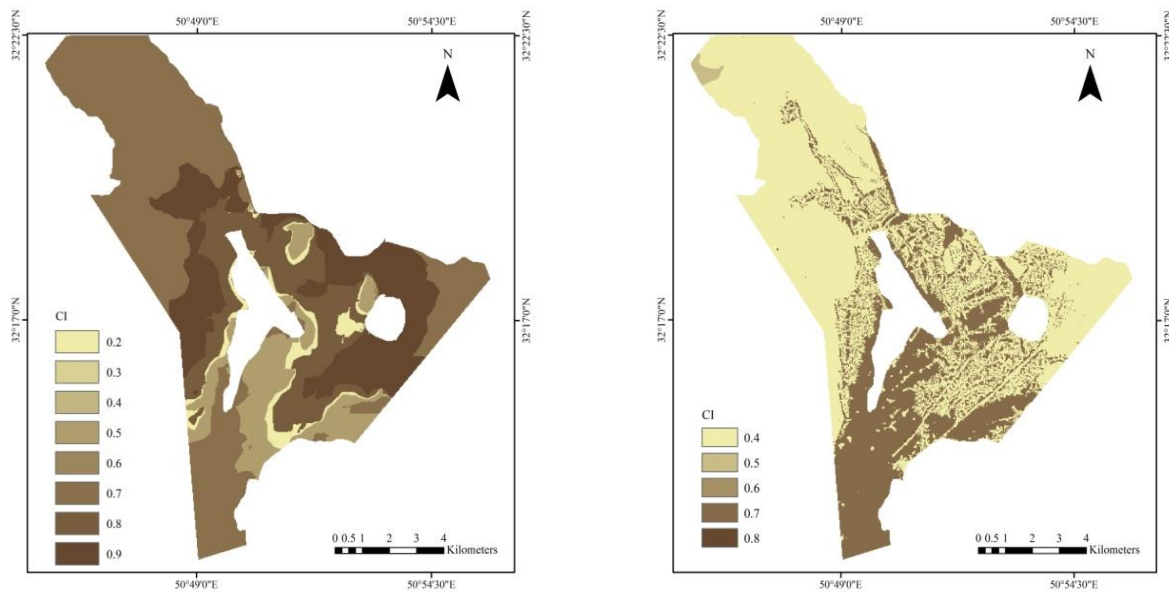
¹ Consociation

بیان‌کننده روشی مناسب یا نقشه‌ای خوب نیست؛ به دیگر سخن هرچند روش شبکه عصبی مصنوعی صحت خوبی را برای پیش‌بینی کلاس‌های خاک در این سطح داشته، اما این پیش‌بینی با عدم قطعیت زیاد همراه است و در نتیجه به نتایج حاصل اعتماد چندانی نیست. شاید یکی از دلایلی که شبکه عصبی مصنوعی عدم قطعیت زیادی را نشان داده است، همواربودن منطقه مطالعاتی (دشت شهرکرد) باشد. در دیگر پژوهش‌های انجام‌شده (مانند Bagheri Behrens et al, و Bodaghabadi et al, 2015: 582 و 2005: 23)، تنوع ناهمواری‌ها در منطقه مطالعاتی آنها زیاد بوده است؛ بنابراین روش شبکه عصبی مصنوعی را به‌متابۀ مدلی مناسب برای پیش‌بینی کلاس‌های خاک بیان کرده‌اند. البته باید به این نکته نیز توجه داشت که در هیچ‌یک از پژوهش‌های مزبور عدم قطعیت مدل محاسبه نشده است.

فامیل، مقدار صحت مدل به کمتر از نصف کاهش یافته است (جدول ۶). دلیل احتمالی این موضوع، افزایش ناگهانی فراوانی کلاس‌ها در سطح فامیل است. نتایج مشابهی را باقری بداغ‌آبادی و همکاران (۲۰۱۵) به دست آورده‌اند (Bagheri Bodaghabadi et al, 2015: 580).

نقشه‌های عدم قطعیت برای پیش‌بینی در سطوح رده، زیررده، گروه‌های بزرگ و زیرگروه‌های خاک در شکل (۳) نشان داده شده‌اند. همان‌طور که ملاحظه می‌شود از سطح رده تا سطح زیرگروه عدم قطعیت افزایش می‌یابد. این موضوع از این نظر بدیهی است که در سطح زیرگروه باید تعداد ۱۰ کلاس پیش‌بینی شود و در سطح رده فقط دو کلاس وجود دارد. وجود عدم قطعیت زیاد (۰/۸۳ - ۰/۴۲) برای سطح گروه بزرگ و در عین حال صحت کلی نسبتاً خوب (۰/۶۸) برای این سطح رده‌بندی، نشان‌دهنده این نکته است که الزاماً صحت خوب





شکل ۳. نقشه‌های عدم قطعیت پیش‌بینی کلاس‌های خاک برای رده (بالا، سمت راست)، زیررده (بالا، سمت چپ)، گروه بزرگ (پایین، سمت راست) و زیرگروه (پایین، سمت چپ) سامانه رده‌بندی آمریکایی

نتیجه‌گیری

نتایج پژوهش حاضر نشان داد همگام با خطای مدل، باید به عدم قطعیت آن نیز توجه داشت. به نظر می‌رسد علاوه بر نوع مدل، تعداد کلاس‌ها در هر سطح طبقه‌بندی و توزیع مکانی کلاس‌های خاک در منطقه مطالعاتی اهمیت بسزایی دارند. از سوی دیگر نظر کارشناس خیره و اطلاع از عوامل تأثیرگذار بر تغییرات مکانی خاک، نقش مؤثری در ایجاد یک نقشه خاک با صحت زیاد ایفا می‌کند. براساس نتایج در مناطق هموار، مدل شبکه عصبی مصنوعی در پیش‌بینی مقادیر کمی مناسب است؛ اما در پیش‌بینی مقادیر کیفی (نوع یا کلاس خاک) عدم قطعیت زیادی دارد. این موضوع به‌کارگیری روش‌های دیگری از محاسبات نرم مانند فازی، جنگل تصادفی، ماشین‌بردار پشتیبان و ... را در پیش‌بینی مقادیر کیفی به‌ویژه برای مناطق با ناهمواری کم خاطر نشان می‌کند.

منابع

محمدی، مهدی، (۱۳۶۵). گزارش مطالعات خاک‌شناسی نیمه‌تفصیلی استان چهارمحال و بختیاری (مناطق شهرکرد و بروجن)، نشریه فنی، دوره ۱، شماره ۶۹۶، مؤسسه تحقیقات خاک و آب، ۱-۲۳۹.

Bagheri Bodaghabadi, M., Martínez-Casasnovas, J.A., Salehi, M.H., Mohammadi, J., Esfandiarpour Borujeni, I., Toomanian, N., and Gandomkar, A., (2015). **Digital Soil Mapping using Artificial Neuronal Networks (ANN) and Terrain-Modelling Attributes**, Pedosphere, Vol 25 (4), Pp 580-591.

Bagheri Bodaghabadi, M., Salehi, M.H., Martínez-Casasnovas, J.A., Mohammadi, J., Toomanian, N., and Esfandiarpour Borujeni, I., (2011). **Using Canonical Correspondence Analysis (CCA) to identify the most important DEM**

- products**, In: GlobalSoilMap. CRC Press, Pp 335–340.
- Heuvelink, G.B.M., Kros, J., Reinds, G.J., and De Vries, W., (2016). **Geostatistical prediction and simulation of European soil property maps**, Geoderma, Vol 7 (2), Pp 201–215.
- <https://cran.r-project.org/bin/windows/base/old/3.1.1/>
- Kempen, B., Heuvelink, G., Brus, D., and Walvoort, D., (2014). **Towards GlobalSoilMap.net products for The Netherlands**, In: Arrouays, D., N. McKenzie, J. Hempel, A.C. Richer de Forges, and A. McBratney (Eds.), GlobalSoilMap. CRC Press, Pp 85–90.
- Lagacherie, P., Arrouays, D., Bourennane, H., Gomez, C., Martin, M., and Saby, N.P., (2019). **How far can the uncertainty on a Digital Soil Map be known?: A numerical experiment using pseudo values of clay content obtained from Vis-SWIR hyperspectral imagery**, Geoderma, Vol 337 (1), Pp 1320-1328.
- McCulloch, W.S., Pitts, W.H., (1943). **A logical calculus of the ideas immanent in nervous activity**, Bulletin Mathematical Biology, Vol 5 (4), Pp 115-133.
- Mosleh, Z., Salehi, M.H., Jafari, A., Esfandiarpour Borujeni, I., and Mehnatkesh, M., (2016). **The effectiveness of digital soil mapping to predict soil properties over low relief areas**, Environmental Monitoring and Assessment, Vol 188 (3), Pp 1-13.
- Odgers, N.P., McBratney, A.B., and Minasny, B., (2011). **Bottom-up digital soil mapping**, I. Soil layer classes, Geoderma, Vol 163 (1-2), Pp 38-44.
- Olaya, V.F., (2004). **A gentle introduction to SAGA GIS**, User Manual, The SAGA User Group e.V., First Edition, 208 p.
- Oscar, C., Melin, P., (2002). **Hybrid intelligent system for time series prediction using neural network, fuzzy logic and fractal theory**, IEEE Transaction on Neural Network, Vol 13 (6), Pp 1395-1408.
- attributes for digital soil mapping applications**, Catena, Vol 86 (1), Pp 66-74.
- Behrens, T., Schmidt, K., MacMillan, R., and Rossel, R.V., (2018). **Multiscale contextual spatial modelling with the Gaussian scale space**, Geoderma, Vol 310 (1), Pp 128–137.
- Behrens, T., Forster, H., Scholten, T., Steinrucken, U., Spies, E.D., and Goldschmitt, M., (2005). **Digital soil mapping using artificial neural networks**, Journal of Plant Nutrition and Soil Science, 168 (1), Pp 21-33.
- Bekat, T., Erdogan, M., Inal, F., and Genc, A., (2012). **Prediction of the bottom ash formed in a coal-fired 384 power plant using artificial neural networks**, Energy, Vol 45 (1), Pp 882-887.
- Brungard, C.W., Boettinger, J.L., Duniway, M.C., Wills, S.A., and Edwards, T.C., (2015). **Machine learning for predicting soil classes in three semi-arid landscapes**. Geoderma, Vol 239-240 (1), Pp 68–83.
- Byrt, T., Bishop, J., and Carling, J.B., (1993). **Bias, prevalence and kappa**, Journal of Clinical Epidemiology, Vol 46 (5), Pp 423- 429.
- Farifteh, J., van der Meer, F.D., Atzberger, C., and Carranza, E.J.M., (2007). **Quantitative analysis of salt-affected soil reflectance spectra: A comparison of two adaptive methods (PLSR and ANN)**. Remote Sensing of Environment, Vol 110 (1), Pp 59–78.
- Hengl, T., Huvelink, G.B.M., and Stein, A., (2004). **A generic framework for spatial prediction of soil variables based on regression-kriging**, Geoderma, Vol 120 (1–2), Pp 75–93.
- Heung, B., Ho, H.C., Zhang, J., Knudby, A., Bulmer, C.E., and Schmidt, M.G., (2016). **An overview and comparison of machine-learning techniques for classification purposes in digital soil mapping**, Geoderma, Vol 265 (1), Pp 62–77.
- Heuvelink, G., (2014). **Uncertainty quantification of GlobalSoilMap**

- Soil Science Division Staff, (2017). Soil survey manual. C. Ditzler, K. Scheffe, and H.C. Monger (eds). USDA Handbook 18. Government Printing Office, Washington, D.C. 639 p.
- Soil Survey Staff, (2014). Soil taxonomy: a basic systems of soil classification for making and interpreting soil surveys, USDA, NRCS, Twelfth Edition, 372 p.
- Szatmári, G., Pásztor, L., (2019). **Comparison of various uncertainty modelling approaches based on geostatistics and machine learning algorithms**, Geoderma, Vol 337 (1), Pp 1329-1340.
- Taghizadeh-Mehrjardi, R., Minasny, B., Triantafyllidis, J., Sarmadian, F., and Omid, M., (2014). **Digital mapping of soil classes using decision tree and auxiliary data in the Ardakan region, Iran**, Arid Land Research and Management, Vol 28 (2), Pp 147-168.
- Zinck, J.A., (1989). **Physiography and soils (Lecture notes for soil students)**, Soil Science Division, Soil survey courses subject matter, K6. Enschede, the Netherlands: ITC.
- Padarian, J., Minasny, B., and McBratney, A.B., (2019). **Using deep learning for digital soil mapping**, Soil, Vol 5 (1), Pp 79-89.
- Pahlavan Rad, M.R., Toomanian, N., Khormali, F., Brungard, C.W., Komaki, C.B., and Bogaert, P., (2014). **Updating soil survey maps using random forest and conditioned Latin hypercube sampling in the loess derived soils of northern Iran**, Geoderma, Vol 232–234 (1), Pp 97–106.
- Park, S.J., Vlek, P.L.G., (2002). **Environmental correlation of three-dimensional soil spatial variability: a comparison of three adaptive techniques**, Geoderma, Vol 109 (1-2), Pp 117–140.
- Rouse, J.W., Hass, R.H., Schell, J.A., and Deering, D.W., (1974). **Monitoring vegetation systems in the Great Plains with ERTS**, Proceedings of 3rd Earth Resource Technology Satellite (ERTS) Symposium, Vol 1 (1), Pp 48-62.
- Shadman Roodposhti, M., Aryal, J., Lucieer, A., and Bryan, B.A., (2019). **Uncertainty Assessment of Hyperspectral Image Classification: Deep Learning vs. Random Forest**, Entropy, Vol 21 (1), Pp 78-88.