



مدلسازی و مقایسه برآورد میزان گچ در چهار تابع سیگموئید، گوسین، تانژانت هایپربولیک و سکانت هایپربولیک

بهزاد سبحانی^{۱*}، علی عباسپور^۲، صمد امامقلی زاده^۳، پدیده جوادی^۴

۱ و ۲- دانشجوی کارشناسی ارشد و استادیار گروه مهندسی آب و خاک دانشگاه صنعتی شاهرود و ۳- کارشناس ارشد مدیریت

منابع خاک

*Email: behzadsobhani1368@gmail.com

چکیده

دشت اریض شوش به وسعت ۵۱۷۲،۵۱ هکتار، که تعداد ۱۸۱ پروفیل حفاری شده و از آنها نمونه برداری شد. نرم افزار Qnet 2000 که به منظور مدل سازی در این تحقیق استفاده گردید دارای چهار تابع انتقال سیگموئید، گوسین، تانژانت هایپربولیک^۳ و سکانت هایپربولیک^۴ می باشد. که برای هر چهار تابع، ضریب تبیین، مجذور میانگین مربعات خطا، انحراف معیار و صحت یابی اندازه گیری شد. داده های مورد استفاده شامل مقادیر EC، pH، درصد رس و سیلت و شن خاک می باشد که در انجام مدل سازی برای برآورد میزان گچ، ۷۵ درصد داده ها به قسمت آموزش و ۲۵ درصد به قسمت صحت سنجی اختصاص داده شدند. تابع محرک گاوسین با داشتن ضریب همبستگی (۰/۷۶، ۰/۷۴) به ترتیب برای مراحل آموزش و صحت یابی دارای نتایج بهتری نسبت به سایر توابع می باشد. ضریب تبیین بیشتر و خطای کمتر دلیل محکمتری برای پذیرفتن عملکرد خوب مدل است.

کلمات کلیدی: خاکهای گچی، شبکه عصبی مصنوعی (ANN)، Qnet 2000، مدلسازی

مقدمه

از آنجایی که خاک محیطی دینامیک و پویاست لذا به روز بودن مطالعات خاکشناسی و طبقه بندی آنها از اهمیت ویژه ای برخوردار است. به طور کلی خاکهای گچی، خاکهایی هستند که حاوی مقدار قابل توجهی گچ (سولفات کلسیم آبدار) در افق ها باشند. خاکهای حاوی گچ پدوژنیک به طور کلی در نواحی با رژیم رطوبتی یوستیک، زیریک و اریدیک یافت میشوند. این خاکها معمولا در مناطق با شیب کمتر از ۸% وجود دارند و حدود ۴،۲ کیلومتر مربع از خاکهای ایران گچی هستند. عوامل متعددی مانند حاصلخیزی کم، ظرفیت کم نگهداری آب، عمق کم خاک به دلیل وجود سخت لایه، سله های عمودی و شوری از جمله عوامل محدود کننده این خاکها به شمار می رود. همچنین شکل گیری گودالهای فرو نشست کرده در ارتباط با سیستمهای زهکشی، آبیاری و دیگر ساختمانها از دیگر خطرهای شمرده شده در این خاکها میباشند.

شبکه های عصبی مصنوعی (ANNs) یک ساختار شبکه ای از تعدادی عناصر مرتبط به هم به نام نرون هستند که هر نرون دارای ورودی ها و خروجی هایی بوده و یک عمل نسبتا ساده و محلی را انجام می دهند. این شبکه ها پردازنده ای هستند که دانشی را که از طریق تجربه کسب نموده اند، برای استفاده های دیگر ذخیره می نمایند و ابزاری توانمند برای مدل کردن سیستم غیرخطی می باشند. بعضی از پیش زمینه های شبکه عصبی به اواخر قرن نوزدهم و اوایل قرن بیستم بر می گردد. در این دوره کارهای اساسی در فیزیک روانشناسی و نروفیزیولوژیکی صورت پذیرفت. این مدل ها به مدل های مشخص ریاضی عملکرد نرون ها اشاره

¹Sigmoid

²Gaussian

³Hyperbolic Tangent

⁴Hyperbolic Secant



نداشتند. در سال ۱۹۶۹ مدل MP شبکه های عصبی مصنوعی توسط مک کالوخ و پیت مطرح شد که یک مدل خطی ساده بود، سپس پرسپترون الگوریتم های یادگیری را ارائه نمود(منهاج ۱۳۸۱). شبکه های عصبی مصنوعی (ANN)، کلاسی از تکنیک های داده محور است که به عنوان یک ابزار جایگزین برای روش های سنتی در مدل سازی سیستم های دینامیکی غیرخطی به کار گرفته می شوند. در این حالت مکانیسم های ورودی-خروجی ممکن است که دقیقاً قابل ارائه نباشند. به طور کلی روش های متعددی مانند رگرسیون و شبکه های عصبی مصنوعی برای توسعه روش های پیش بینی مورد استفاده قرار می گیرند. روش های رگرسیونی خطی چندگانه مختلفی طی ۲۰ سال گذشته برای پیش بینی جذب فلزات در خاک گسترش یافته اند، (اندرسن و کریستنسن ۱۹۹۸، الزینگا و همکاران ۱۹۹۹، رندز و همکاران ۱۹۹۵، رومکئوس و سالومونس ۱۹۹۸، اسچاک و همکاران ۲۰۰۰، استرک و ریچتر ۱۹۹۷، تیک تاک و همکاران ۱۹۸۷) به کمک روش های مذکور (MLR) رابطه بین ورودی های خاک (خصوصیات) و خصوصیات خروجی خاک تعیین شده و با پیش بینی در مدل رگرسیونی جواب حاصل می گردد. در مقالات مختلف گزارش شده است که شبکه های عصبی مصنوعی عملکرد پیش بینی بهتری در مقایسه با روش های مرسوم ریاضی از جمله مدل های MLR ارائه می دهند (اندرسن و کریستنسن ۱۹۹۸، الزینگا و همکاران ۱۹۹۹، رامکنس و سالومونس ۱۹۹۸، سرمیدیان و تقی زاده مهرجردی ۲۰۰۸، اسچاپ و لچی ۱۹۹۸، استرک و ریچتر ۱۹۹۷، تیک تاک و همکاران ۱۹۹۸، واندز و وانس دی جک ۱۹۸۷). در بسیاری از موارد در مدل رگرسیون، روابط ورودی-خروجی در مهندسی خاک بسیار پیچیده می باشند و به خوبی درک نمی شوند. عدم درک فیزیکی فقدان یک ابزار قدرتمند برای مدل سازی ریاضی، منجر به ساده سازی مسائل می شود. در نتیجه، بسیاری از مدل های ریاضی، موفق به شبیه سازی رفتار پیچیده ترین مشکلات مهندسی خاک نمی شوند. حال آنکه این اندازه گیری ها نسبت به روش های سنتی و معمول بسیار راحت و کم هزینه تر است و مستلزم وجود دامنه ای از داده ها در زمینه ی مورد نظر است. با توجه به کاربرد و توانایی زیاد این مدل ها باید در این زمینه فعالیت ها و مطالعات گسترده تری انجام گیرد چراکه پیشرفت های بعدی وابسته به تلاش ها و مطالعات کنونی است.

روش کار

دشت اریض شوش به وسعت ۵۱۷۲٫۵۱ هکتار بین عرض جغرافیایی ۰۱°-۳۲ تا ۰۳°-۳۲ شمالی و طول جغرافیایی ۰۶°-۴۸ تا ۲۶°-۴۸ شرقی قرار دارد. دشت اریض در جنوب غربی ایران واقع در دشت خوزستان می باشد. این دشت از شمال به دشت دوسالق، از طرف جنوب به دشت باغه، از طرف شرق به رودخانه کرخه، از طرف غرب به کانال اصلی دشت های پای پل محدود می باشد. این دشت در غرب رودخانه کرخه و در جلگه وسیع خوزستان واقع شده است.

در این مطالعه تعداد ۱۸۱ پروفیل و ۱۸۱ مته حفاری، تشریح و نمونه برداری شده است نمونه خاک پس از انتقال به آزمایشگاه و هواخشک شدن از الک ۲ میلیمتری عبور داده شد، بافت خاک به روش هیدرومتری، کلسیم و منیزیم با روش کمپلکسومتری با قابلیت هدایت الکتریکی با استفاده از دستگاه الکتروکنداکتومتر بر روی عصاره گل اشباع، کربن آلی به روش والکی بلاک به روش تیتراسیون آنالیز شد. نرم افزار Qnet 2000 که به منظور مدل سازی در این تحقیق استفاده گردید دارای چهار تابع انتقال سیگموئید^۵، گوسین^۶، تانژانت هایپربولیک^۷ و سکانت هایپربولیک^۸ می باشد.

تابع محرک سیگموئید

از بین توابع موجود در نرم افزار Qnet 2000 تابع سیگموئید، تابع پیش فرض می باشد و بطور وسیعی در شبکه های عصبی انتشار برگشتی کاربرد دارد. این تابع همچنین مقادیر ورودی را بین صفر و یک محدود می کند با این تفاوت که میزان تغییرات آن غیر

^۵Sigmoid

Gaussian

Hyperbolic Tangent

^۸Hyperbolic Secant

خطی است. مزیت این تابع در عملکرد آن با ورودی‌های بزرگ و یا کوچک است. هنگامی که مقادیر ورودی به سمت اعداد منفی بزرگ میل کند مقدار صفر و هنگامی که مقادیر ورودی به سمت صفر میل کند مقدار تابع به سمت ۰/۵ و هنگامی که مقادیر ورودی به سمت مقادیر مثبت بزرگ میل کند مقدار تابع به سمت یک میل خواهد کرد. رفتار این تابع در شکل (۳-۶) نشان داده شده است و به صورت رابطه زیر تعریف می‌شود (راهنمای نرم‌افزار 2000 Qnet):

$$f(n) = sig(n) = \frac{1}{1 + e^{-n}}$$

تابع محرک تانژانت هیپربولیک

تابع محرک دیگر که اغلب توسط بیولوژیست‌ها به عنوان مدل ریاضی از تحریک سلول عصبی مورد استفاده قرار می‌گیرد، تابع تانژانت هیپربولیک است که از نظر شکل شبیه تابع منطقی است:

$$f(n) = tanh(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$$

توابع هیپربولیک قرین با سیگموئید و گوسین، به ترتیب توابع تانژانت هیپربولیک و سکانت هیپربولیک هستند. توابع انتقال سیگموئید، گوسین، تانژانت هیپربولیک و سکانت هیپربولیک سیگنال خروجی که توسط هر گره ساخته شده است را به‌نحی دیگر مینمایند.

داده‌ها و ورودی و خروجی

داده‌های مورداستفاده شامل مقادیر pH، EC، درصد رس و سیلت و شن خاک (بافت خاک) می‌باشد که در انجام مدل‌سازی برای برآورد میزان گچ ۷۵ درصد داده‌ها به قسمت آموزش و ۲۵ درصد به قسمت صحت سنجی اختصاص داده شدند. در مدل‌سازی که انجام شد برای برآورد میزان گچ ورودی شامل درصد شن، رس، سیلت، pH و EC استفاده شد.

نتایج و بحث

برای شروع مدل‌سازی در شبکه‌ی عصبی اولین قدم انتخاب شبکه است که البته ساختارهای مختلف شبکه مورد ارزیابی قرار گرفت در نهایت شبکه‌ی MLP مورداستفاده قرار گرفت دلایلی متفاوتی برای این انتخاب وجود داشت که مهم‌ترین این دلایل توانایی بالای این شبکه برای دسته‌بندی (Classification) و کلاس‌بندی (Clustering) و یافتن نگاهشده‌های نامعلوم می‌باشد (کاشی و همکاران ۲۰۱۲). در این مرحله برای اجرای مدل از یک ساختار یا چهارچوب که دارای یک لایه ورودی به تعداد مشخص پارامتر ورودی یک لایه خروجی و تعداد متفاوت از لایه میانی یا لایه پنهان (از ۱ الی ۱۰) و از توابع انتقال تانژانت هیپربولیک سیگموئید، گوسین و سکانت هیپربولیک استفاده گردید. برای اجرای مدل داده‌ها به صورت تصادفی به ۲ دسته ۷۵٪ و ۲۵٪ به ترتیب برای داده‌های مرحله‌ی آموزش و صحت سنجی تفکیک شدند. همچنین به منظور محاسبه‌ی ضریب تبیین (R^2) (رابطه ۱)، مجذور میانگین مربعات خطا (RMSE) (رابطه ۲) و انحراف معیار (Standard deviation) (رابطه ۳) که از روابط زیر قابل محاسبه می‌باشند، استفاده گردید.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3)$$

$$RMSE = \left[\frac{\sum_{j=1}^n (\hat{y}_j - y_j)^2}{n} \right]^{\frac{1}{2}} \quad (2)$$

$$R^2 = \frac{\left[\sum_{i=1}^n (\hat{y}_i - \bar{y})(y_i - \bar{y}) \right]^2}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

که در آن‌ها: y_i و \hat{y}_i مقادیر پیش‌بینی شده و y_i مقادیر مشاهداتی، \bar{y} متوسط مقادیر مشاهداتی و n تعداد داده‌ها μ میانگین است. نتایج نشان می‌دهد که تابع محرک گوسین با داشتن ضریب همبستگی (۰/۷۶، ۰/۷۴) به ترتیب برای مراحل آموزش و صحت یابی دارای نتایج بهتری نسبت به سایر توابع می‌باشد. جدول ۱ نتایج حاصل از اجرای مدل MLP و توابع تانژانت هیپربولیک و گوسین را برای تخمین میزان گچ خاک را نشان می‌دهد. نتایج در اکثر موارد بیشترین میزان دقت و کمترین میزان خطا را در توابعی با تعداد ۳ لایه‌ی پنهان نشان می‌دهد. شکل ۱ منحنی تغییرات RMSE را در لایه‌های پنهان مختلف برای میزان گچ خاک نشان می‌دهد. علاوه بر پارامتر ضریب تبیین (R^2) که بیشترین مقدار را دارد، پارامتر RMSE و نیز مقادیر کمتری را در

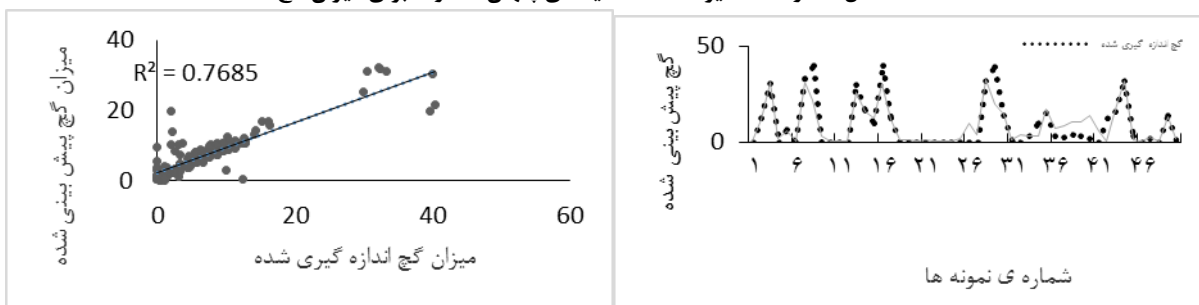
تابع گوسین نشان می‌دهند که نشان از کارایی بالای این تابع دارد؛ زیرا اتکا به پارامتر ضریب تبیین برای بررسی قابلیت‌های مختلف هر شبکه و تابع کافی نبوده و نیاز به مطالعات گسترده‌تر آماری وجود دارد. در شکل‌های ۳ و ۲ پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده میزان گچ خاک برای شبکه‌ی MLP آورده شده است، همانطور که مشاهده می‌شود میزان گچ پیش‌بینی شده با مدل در مقایسه با میزان گچ اندازه‌گیری شده تفاوت زیادی ندارد و مدل توانایی پیش‌بینی خوبی از خود نشان داده است. برای اثبات این موضوع می‌توان به میزان خطا و ضریب تبیین نیز توجه نمود چراکه هرچند میزان ضریب تغییرات در تابع گوسین نسبت به دیگر توابع بالاتر است اما ضریب تبیین بیشتر و خطای کمتر دلیل محکمتری برای پذیرفتن عملکرد خوب مدل است.

جدول نتایج حاصل از اجرای بهترین تابع شبکه MLP برای تخمین میزان گچ خاک


تابع عضویت	R^2 آموزش	RMSE	R^2 صحت سنجی	Std.D
سیگموئید	۰/۳۴	۱۲/۰۱	۰/۰۷	۶/۱۲
گوسین	۰/۷۶	۵/۱۹	۰/۷۴	۱۲/۳۹
سکانت هایپربولیک	۰/۲۱	۱۱/۱۳	۰/۳۴	۴/۹۹
تانژانت هایپربولیک	۰/۳۲	۱۱/۴۶	۰/۰۱	۶/۲



شکل شماره ۱ مقادیر RMSE لایه‌های پنهان متفاوت برای میزان گچ




شکل ۲ نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله‌ی آموزش (مدل MLP)



شکل ۳ نمودار پراکنش داده‌های اندازه‌گیری شده و پیش‌بینی شده برای مرحله‌ی صحت یابی (مدل MLP)

آنالیز حساسیت بر روی پارامترهای ورودی به مدل شبکه‌ی عصبی مصنوعی

برای تعیین همبستگی هر یک از پارامترها با مقدار گچ تخمین زده شده از آنالیز حساسیت استفاده شده است با انجام آنالیز حساسیت می‌توان نقش هر یک از پارامترها را لحاظ کرده و قدرت آن‌ها را محاسبه کرد. تعیین تأثیرگذارترین پارامترها در مقدار گچ تخمین زده شده نیز با انجام این محاسبه امکان‌پذیر می‌شود. نتایج آنالیز حساسیت خاک در شکل نشان ۴ داده شده است. بر اساس نتایج حاصل، در پیش‌بینی میزان گچ خاک میزان EC و pH و رس خاک پارامترهای مهم اصلی به شمار می‌آیند به گونه‌ای که بیشترین تأثیر را دارا می‌باشند. تأثیرگذاری EC از آن جهت که با افزایش میزان گچ میزان نمک‌های محلول خاک افزوده شده و در نتیجه EC تغییر می‌کند، حضور و تجمع گچ در خاکها بسیاری از خصوصیات فیزیکی (ساختمان خاک، بافت خاک، وزن مخصوص ظاهری و هدایت آبی)، خصوصیات شیمیایی (ظرفیت تبادل کاتیونی، اسیدیته خاک و شوری)، مینرالوژیکی و مهندسی خاکها را تحت تأثیر قرار میدهد و در بسیاری از زمینه‌ها مشکلات جدی برای فعالیتهای انسانی ایجاد میکند (Azizi et al., 2011; Baydaa, 2004; Toomanian, 2011; Herrero & Porta, 2000; Baydaa & Abd Farhan, 2009; Ghabour et al., 2008; Al-Dabbas et al., 2010). در مطالعه‌ی عبدالجواد ۱۹۹۲، بررسی خاکهای گچی عراق نشان داد که به دلیل حلالیت بالای گچ، بین گچ و مقدار قابلیت هدایت الکتریکی رابطه مستقیم وجود دارد. که با نتایج این مطالعه کاملا در ارتباط است.



شکل ۴ آنالیز حساسیت سهم لایه‌های ورودی در تخمین میزان گچ

منابع

- سرمدیان ف. تقی زاده ر.ا، عسگری ح.م.، و اکبرزاده ع. ۱۳۸۸. مقایسه روش‌های نروفازی، شبکه عصبی و رگرسیون چند متغیره در پیش‌بینی. برخی خصوصیات خاک مطالعه موردی استان گلستان. مجله تحقیقات آب و خاک ایران ۴۱: ۲۲۰-۲۱۱
- کاشی ح، قربانی ه، امامقلی زاده ص.، هاشمی ع. ۱۳۹۲. تخمین ظرفیت تبادل کاتیونی در دو خاک بکر و کشاورزی توسط شبکه عصبی مصنوعی و رگرسیون خطی. نشریه آب و خاک (علوم و صنایع کشاورزی). ۴۷۲-۴۸۴-۲۷
- Abdelgavad G.M., 1992. Gypsiferous soil properties and management. The Arab center for the studies of arid zones and dry lands. Damascus, Syrian Arab Republic, 68p.



Azizi P., Mahmoodi Sh., Torabi H., Masihabadi M.H., and Homae M. 2011. Morphological, Physico-Chemical and clay mineralogy investigation on gypsiferous soils in southern of Tehran, Iran. *Middle-East Journal of Scientific Research*, 7 (2): 153-161.

Sarmadian, F., Taghizadeh Mehrjardi, R. (2008). Modeling of some soil properties using artificial neural network and multivariate regression in Gorgan Province, North of Iran. *Global Journal of Environmental Research*, 2 (1): 30-35.

Tiktak, A., Alkemade, J.R.M., Van Grinsven, J.J.M., Makaske, G.B. (1998). Modeling cadmium accumulation at a regional scale in the Netherlands. *Nutrient Cycling in Agro ecosystems*, 50: 209-222.

Römkens, P.F.A.M., Salomons, W. (1998). Cd, Cu and Zn solubility in arable and forest soils: consequences of land use changes for metal mobility and risk assessment. *Soil Science*, 163: 859-871.

Reinds, G.J., Bril, J., DeVries, W., Groenbergen, J.E., Breeuwsm, A. (1995). Critical loads and excess loads of cadmium, copper and lead for European forest soils. DLO Winand Staring Centre Report 96. Wageningen, the Netherlands

Modeling and comparing the estimated amount of gypsum in four sigmoid function, Gaussian, hyperbolic tangent and hyperbolic secant

B. Sobhani, A. Abbaspour, S. Emamghizade and P. Javadi

Abstract

Arayez in Shoosh Plain area of 5172.51 hectares, of which 181 profiles were excavated and sampled. Qnet 2000 modeling software was used in this study has four sigmoid transfer function, Gaussian, hyperbolic tangent and hyperbolic secant respectively. For each function, the coefficient of determination, root mean square error, standard deviation and Shtyaby measured. The data used includes amounts EC, pH, clay, silt and sand that the modeling to estimate the amount of gypsum, 75% to education and 25 percent to the validation data were assigned. Stimulus Gaussian function with a correlation coefficient (0/76, 0/74) for training and Recovery with better results than other functions. Coefficient of determination to take stronger and less error due to the good performance of the model.

Keywords: gypsum soils, Artificial Neural Network (ANN), Qnet 2000, modeling