

اشتقاق توابع انتقالی برای برآورد هدایت هیدرولیکی اشباع خاک در شمال غرب دریاچه

ارومیه

شکراله اصغری*: دانشیار گروه علوم و مهندسی خاک، دانشکده‌ی کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل

مژگان حاتم‌وند: دانش‌آموخته کارشناسی ارشد علوم و مهندسی خاک، دانشکده‌ی کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل

مهسا حسنیور کاشانی: استادیار، گروه مهندسی آب، دانشکده‌ی کشاورزی و منابع طبیعی، دانشگاه محقق اردبیلی، اردبیل

تاریخچه مقاله (تاریخ دریافت: ۱۳۹۸/۱۱/۰۲ تاریخ پذیرش: ۱۳۹۸/۱۲/۱۴)

چکیده

هدایت هیدرولیکی اشباع خاک (K_s) در اکثر مدل‌های شبیه‌سازی فرسایش و فرایندهای هیدرولوژیکی خاک در آبخیزها، نقش مهمی را ایفا می‌کند. اندازه‌گیری مستقیم هدایت هیدرولیکی اشباع (K_s) خاک، کاری وقت‌گیر، دشوار و پرهزینه است. هدف از این پژوهش، مقایسه‌ی دقت توابع انتقالی (PTF_s) رگرسیونی، شبکه عصبی مصنوعی (ANN) و نروفازی در برآورد K_s خاک‌های متأثر از نمک واقع در شمال غرب دریاچه‌ی ارومیه بود. برای تعیین برخی متغیرهای فیزیکی و شیمیایی زود یافت خاک، تعداد ۱۰۰ نمونه خاک دست‌خورده و دست‌نخورده از عمق ۰ تا ۱۰ سانتی‌متری اراضی کشاورزی و بایر بخش شندآباد در منطقه‌ی شبستر برداشته شد. متغیر K_s در آزمایشگاه به روش بار ثابت یا افتان اندازه‌گیری شد. برای اشتقاق توابع رگرسیونی از نرم‌افزار SPSS استفاده شد و برای توابع ANN و نروفازی از نرم‌افزار MATLAB. هشتاد درصد داده‌ها برای آموزش و بیست درصد آن برای آزمون توابع به کار رفت. نتایج توابع رگرسیونی، ANN و نروفازی نشان داد که تابع انتقالی با دو متغیر سیلت و جرم مخصوص ظاهری، بهترین تابع برای برآورد K_s خاک در منطقه‌ی مورد مطالعه است. مقادیر ضریب تبیین (R^2)، مجذور میانگین مربعات خطا (RMSE) و میانگین خطا (ME) به ترتیب ۰/۶۵، ۰/۱۱۹ cm/min و ۰/۰۵۹- و ۰/۷۳، ۰/۰۸۷ و ۰/۰۰۶ cm/min و ۰/۶۹، ۰/۱۲۷ cm/min و ۰/۰۵۱- به ترتیب برای بهترین تابع رگرسیونی، ANN و نروفازی به دست آمد. بنابراین، توابع ANN به دلیل داشتن R^2 بالا و RMSE پایین در مقایسه با توابع رگرسیونی و نروفازی، دقت بیشتری برای برآورد K_s خاک در منطقه‌ی مورد مطالعه دارد.

واژگان کلیدی: تخمین، خاک‌های متأثر از نمک، رگرسیون، نروفازی، ویژگی‌های هیدرولیکی.

۱- مقدمه

هدایت هیدرولیکی اشباع خاک (K_s)، یکی از ویژگی‌های مهم هیدرولیکی خاک است که در مدل‌سازی انتقال آب و املاح، تعیین گروه‌های هیدرولوژیکی خاک و پیش‌بینی فرسایش آن کاربرد دارد. بنابراین، دانستن ارتباط ویژگی‌های فیزیکی خاک با K_s در برآورد این ویژگی اهمیت فراوان دارد. اندازه‌گیری مستقیم K_s در صحرا و آزمایشگاه به علت تغییرات زمانی و مکانی بالای این پارامتر، کاری وقت‌گیر، طاقت‌فرسا و پرهزینه است.

* نویسنده مسئول: Shasghari@uma.ac.ir

توابع انتقالی^۱ (PTFs) خاک، می‌تواند ویژگی‌های دیریافت خاک مانند K_s را با استفاده از ویژگی‌های زودیافت و سهل‌الوصول آن مانند شن، سیلت، رس، کربن آلی، آهنک و جرم مخصوص ظاهری تخمین بزند. واژه‌ی توابع انتقالی، اولین بار توسط بوما در سال ۱۹۸۹ معرفی شد (Bouma, 1989). او این واژه را بر توابعی اطلاق کرد که داده‌های موجود را به داده‌هایی ناموجود - که به آنها نیاز است - تبدیل می‌کند. برای این منظور، محققان مختلف از توابع رگرسیونی (Ahmadi et al, 2018)، شبکه عصبی مصنوعی^۲ (Ahmadi et al, 2019 & Doaei et al, 2005) و نروفازی^۳ (Nadiri and Yousefzadeh, 2018) استفاده کرده‌اند.

نتایج پژوهش Doaei و همکاران (۲۰۰۵) در ۲۲۱ نمونه خاک رسی برداشته‌شده از استان گیلان، نشان داد که مدل شبکه عصبی (ANN) می‌تواند K_s را با استفاده از متغیرهای ورودی رس، کربن آلی و جرم مخصوص ظاهری با ضریب تبیین (R^2) ۰/۹۷۴ و مجذور میانگین مربعات خطا (RMSE) ۰/۱۶ cm/min برآورد کند. Rezae Arshad و همکاران (۲۰۱۲)، از توابع رگرسیونی و ANN به منظور پیش‌بینی K_s خاک‌های استان خوزستان استفاده کردند. نتایج نشان داد ANN در تخمین K_s در مرحله‌ی آزمون مدل، کارایی بیشتری دارد؛ به طوری که مقادیر R^2 و RMSE به ترتیب ۰/۶۵ و ۰/۰۴ cm/min برای مدل ANN و ۰/۳۴ و ۰/۴۴ cm/min برای مدل رگرسیونی به دست آمد. Khalili Moghadam و همکاران (۲۰۱۵) با استفاده از ویژگی‌های توپوگرافی، پوشش گیاهی و برخی ویژگی‌های زودیافت خاک، کاربرد روش‌های رگرسیونی و ANN را برای برآورد K_s خاک در منطقه‌ی زاگرس مرکزی ارزیابی کردند. نتایج بیانگر آن بود که ANN در تخمین K_s با $R^2=0/88$ در مقایسه با رگرسیون چند متغیره با $R^2=0/69$ ، کارایی بالاتری دارد. Norouziyan Azizi و همکاران (۲۰۱۶) به منظور مدل‌سازی K_s ، از مدل‌های رگرسیون چند متغیره خطی، شبکه عصبی پرسپترون چندلایه و شبکه عصبی تابع پایه شعاعی استفاده کردند. نتایج بیانگر برتری مدل پرسپترون شبکه عصبی با دو لایه مخفی با تابع فعال‌ساز سیگموئیدی نسبت به سایر مدل‌ها در منطقه‌ی مورد مطالعه بود. مدل بهینه نیز نسبت به متغیرهای ورودی جرم مخصوص ظاهری، pH و تخلخل کل، دارای بالاترین حساسیت بود. نتایج پژوهش Ahmadi و همکاران (۲۰۱۸) بر ۱۶۰ نمونه خاک برداشته‌شده از مناطق مختلف استان آذربایجان شرقی نشان داد که براساس داده‌های سری اعتبارسنجی، استفاده از روش برنامه‌ریزی بیان ژن در مقایسه با توابع انتقالی رگرسیونی در تخمین K_s به افزایش R^2 از ۰/۷۶ به ۰/۹۲ و کاهش RMSE از ۳/۱۱ به ۲/۲۷ cm/h منجر شد. آنها بیان کردند که مناسب‌ترین متغیرهای ورودی برای برآورد K_s در توابع رگرسیونی، پارامترهای شن، رس و جرم مخصوص ظاهری و در برنامه‌ریزی بیان ژن، تخمین گره‌های رس و جرم مخصوص ظاهری بود. Nadiri and Yousefzadeh (۲۰۱۸) بیان کردند که براساس معیار RMSE (m/day) در داده‌های سری آزمونی، مدل نروفازی (۱/۱۲) در برآورد هدایت هیدرولیکی آبخوان مراغه - بناب نسبت به مدل‌های فازی (۲/۳) و ANN (۲/۸۷) از دقت بالاتری برخوردار است. Zhao و همکاران (۲۰۱۶)، روش‌های مختلف رگرسیون خطی چندگانه و ANN را برای پیش‌بینی K_s در کشور چین مقایسه کردند. نتایج نشان داد که K_s دارای ضریب تغییرات نسبتاً بالا (CV=۶۷٪) بود و تابع رگرسیونی با متغیرهای ورودی جرم مخصوص ظاهری، سیلت و رس، به عنوان بهترین مدل برای برآورد K_s تعیین شد.

¹ Pedotransfer Functions (PTF)

² Artificial Neural Network (ANN)

³ Neuro-Fuzzy

مدل‌های مختلفی برای تخمین K_s ارائه شده‌است، ولی با عنایت به اینکه توابع انتقالی خاک به مکان وابسته هستند؛ از این رو این پژوهش به منظور اشتقاق توابع رگرسیونی، شبکه عصبی مصنوعی و نروفازی، برای تخمین K_s خاک‌های متأثر از نمک منتخب از شمال غرب دریاچه‌ی ارومیه و مقایسه‌ی دقت برآورد مدل‌های مذکور انجام شد.


۲- مواد و روش‌ها

منطقه‌ی مورد مطالعه

تعداد ۱۰۰ نمونه خاک دست‌خورده و دست‌نخورده (با استفاده از استوانه‌های استیل به قطر و ارتفاع ۵ سانتی‌متر) از عمق ۰ تا ۱۰ سانتی‌متر اراضی بایر و کشاورزی در حاشیه‌ی دریاچه‌ی ارومیه واقع در بخش شندآباد منطقه‌ی شبستر (مختصات جغرافیایی ۴۵ درجه و ۳۶ دقیقه و ۳۴ ثانیه تا ۴۵ درجه و ۳۶ دقیقه و ۳۸ ثانیه طول شرقی و ۳۸ درجه و ۶ دقیقه و ۳۷ ثانیه تا ۳۸ درجه و ۷ دقیقه و ۴۲ ثانیه عرض شمالی) برداشته شد (شکل ۱).

اندازه‌گیری ویژگی‌های خاک

توزیع اندازه ذرات شن، سیلت و رس به روش هیدرومتری ۴ قرائته (Gee and Or, 2002)، اندازه‌گیری و پارامتر میانگین هندسی قطر ذرات (d_g) از روی آنها محاسبه شد (Campbell, 1985). کربن آلی به روش اکسیداسیون تر (Nelson and Sommers, 1982)، اسیدیته (pH_e) در گل اشباع، هدایت الکتریکی (EC) و نسبت جذبی سدیم (SAR) در عصاره‌ی ۱ به ۲/۵ (Hamzhepoura and Bogaert, 2017) و آهک به روش تیتراسیون با اسید و سود (Page, 1985) تعیین شد. جرم مخصوص ظاهری (BD) در استوانه‌های استیل (Blake and Hartge, 1986a) و جرم مخصوص حقیقی (PD) به روش پیکنومتر (Blake and Hartge, 1986b) اندازه‌گیری شد. سپس تخلخل کل از روی داده‌های BD و PD (Danielson and Sutherland, 1986) محاسبه شد. هدایت هیدرولیکی اشباع خاک (K_s) به روش بار ثابت، در کاربری کشاورزی (به دلیل بافت خاک نسبتاً درشت) و به روش بار افتان، در کاربری بایر (به دلیل بافت خاک نسبتاً ریز) در نمونه‌های دست‌نخورده (استوانه‌های استیل) اندازه‌گیری شد (Klute and Dirksen, 1986).



شکل ۱: موقعیت جغرافیایی و نقشه‌ی توزیع نقاط نمونه‌برداری در تصویر ماهواره‌ای منطقه‌ی مورد مطالعه

اشتقاق توابع انتقالی رگرسیونی، شبکه عصبی مصنوعی و نروفازی

پس از اطمینان از نرمال بودن توزیع داده‌ها با آزمون کولموگروف - اسمیرنوف، محاسبه‌ی پارامترهای آمار توصیفی و ضریب همبستگی پیرسون بین متغیرها و اشتقاق توابع رگرسیونی خطی چندگانه بین متغیرهای زود یافت خاک با متغیر دیر یافت (K_s)، به روش گام به گام و با استفاده از نرم‌افزار SPSS 18 انجام شد. اشتقاق توابع انتقالی K_s ، به روش شبکه عصبی مصنوعی (ANN) و نروفازی نیز با استفاده از نرم‌افزار MATLAB انجام شد. شبکه عصبی پرسپترون سه لایه (یک لایه ورودی، یک لایه پنهان و یک لایه خروجی) با الگوریتم پس انتشار خطا و ۱۰۰۰ تکرار به کار گرفته شد و تعداد نرون‌های مناسب به روش سعی و خطا در لایه پنهان انتخاب شد (Moghaddamnia et al, 2009). بهترین ساختار توابع نروفازی نیز به روش سعی و خطا و با به کارگیری توابع عضویت و تکرارهای مختلف برای هر کدام از توابع، تعیین شد که در نهایت تابع عضویت مثلثی (trimf) و ثابت (Constant) به ترتیب به‌عنوان بهترین توابع عضویت لایه‌های ورودی و خروجی انتخاب شد. همچنین تعداد تکرار بهینه‌ی برابر ۳۰، برای همه‌ی توابع تعیین شد (Moghaddamnia et al, 2009). در همه‌ی توابع به کار رفته در پژوهش حاضر، از مجموع ۱۰۰ داده برای هر متغیر، ۸۰ درصد داده‌ها برای آموزش مدل و ۲۰ درصد برای آزمون آن در نظر گرفته شد.

برای ارزیابی و انتخاب بهترین روش و تابع تخمینی K_s از محک‌های آماری ضریب تبیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و میانگین خطا (ME) استفاده شد. مقادیر بالای R^2 (نزدیک به ۱)، بیانگر دقت بالای تخمین است. مقادیر RMSE هر چه به صفر نزدیک باشد، دقت تخمین بیشتر است. مقادیر مثبت ME، بیش‌برآوردی و مقادیر منفی آن، کم‌برآوردی تابع را نشان می‌دهد (Merdun et al, 2006).

۳- یافته‌ها (نتایج) و بحث

توصیف آماری متغیرها، در جدول ۱ و ضرایب همبستگی پیرسون (r) بین آنها، در جدول ۲ آورده شده است. با توجه به جدول ۱ مشاهده می‌شود اکثر متغیرهای مورد استفاده از نظر توزیع و پراکندگی داده‌ها از وضعیت نسبتاً مطلوبی برخوردار هستند که این موضوع از نظر توسعه و ارزیابی توابع انتقالی در روش‌های رگرسیونی، شبکه عصبی مصنوعی (ANN) و نروفازی، نکته‌ای کلیدی محسوب می‌شود؛ ضریب تغییرات (CV) بالای SAR (۱۶۷/۸۶٪)، K_s (۱۳۰/۳۶٪)، EC (۱۱۷/۰۵٪)، میانگین هندسی قطر (d_g) ذرات (۸۸/۴۴٪)، رس (۷۳/۲۳٪)، کربن آلی (۵۸/۴۶٪) و شن (۵۱/۴۷٪) مؤید این موضوع می‌باشد. مطابق طبقه‌بندی و بلدینگ و درس (Wilding and Dress, 1983)، اگر CV بالای ۳۵ درصد باشد، متغیر از تغییرپذیری بالایی برخوردار است. براساس مثلث بافت آمریکایی (شکل ۲)، خاک‌های مورد مطالعه دارای کلاس بافت لوم شنی ($n=39$)، لوم سیلتی ($n=22$)، لوم ($n=20$)، لوم رسی سیلتی ($n=7$)، رسی سیلتی ($n=7$)، شن لومی ($n=3$) و رسی ($n=2$) بود که توزیع مناسب اندازه ذرات شن، سیلت و رس را در پژوهش حاضر نشان می‌دهد. نقشه‌ی تغییرات مکانی متغیرهای خاک در منطقه‌ی مورد مطالعه نشان داد که با فاصله گرفتن از بستر خشکیده-ی دریاچه‌ی ارومیه و فاصله گرفتن از کاربری بایر (دشت رسوبی) به سمت کاربری کشاورزی (دشت دامنه‌ای)، از مقادیر EC، SAR، اسیدیته، آهک، رس، سیلت و جرم مخصوص ظاهری کاسته شد و بر مقادیر شن، کربن آلی، پایداری خاکدانه و K_s افزوده شد (Asghari and Shahabi, 2019 & Asghari and Shahabi, 2018).



شکل ۲: توزیع بافت خاک در منطقه‌ی مورد مطالعه براساس مثلث بافت آمریکایی

جدول ۱: آماره‌های توصیفی متغیرهای خاک در منطقه‌ی مورد مطالعه

متغیر	واحد	میانگین	حداقل	حداکثر	ضریب تغییرات (%)
Sand شن	%	۴۱/۶۵	۲/۶۲	۸۰/۰۴	۵۱/۴۷
Silt سیلت	%	۴۱/۰۴	۱۶/۴۸	۶۵/۹۱	۳۰/۳۴
Clay رس	%	۱۷/۲۹	۳/۳۱	۵۱/۴۱	۷۳/۲۳
میانگین هندسی قطر ذرات d_g	mm	۰/۱۱	۰/۰۰۵	۰/۴۳	۸۸/۴۴
کربن آلی OC	%	۱/۷۸	۰/۰۹	۵/۰۷	۵۸/۴۶
آهک $CaCO_3$	%	۲۴/۹۴	۱۶/۶۹	۳۵/۲۷	۲۲/۱۴
اسیدیته pH_e	-	۷/۹۷	۶/۸۱	۹/۳۷	۵/۴۳
هدایت الکتریکی $EC_{1:2.5}$	dS/m	۱/۶۱	۰/۲۶	۹/۶۷	۱۱۷/۰۵
نسبت جذبی سدیم $SAR_{1:2.5}$	$(meq/l)^{0.5}$	۸/۲۴	۰/۵۳	۶۳/۹۹	۱۶۷/۸۶
جرم مخصوص ظاهری BD	g/cm^3	۱/۲۹	۰/۹۶	۱/۵۷	۹/۹۹
جرم مخصوص حقیقی PD	g/cm^3	۲/۵۴	۲/۳۱	۲/۸۴	۴/۷۳
تخلخل کل TP	cm^3/cm^3	۰/۴۹	۰/۳۹	۰/۶۱	۹/۰۵
هدایت هیدرولیکی اشباع K_s	cm/min	۰/۱۸	۰/۰۰۰۲	۱/۱۰	۱۳۰/۳۶

جدول ۲: ضریب همبستگی پیرسون (r) بین متغیرهای مورد مطالعه (n=100).

Variable	K_s	d_g	BD	PD	TP	$CaCO_3$	Sand	Silt	Clay	OC	pH_e	EC	SAR
K_s	۱	۰/۵۷**	-۰/۵۲**	-۰/۵۳**	۰/۳۱**	-۰/۵۸**	۰/۶۰**	-۰/۶۰**	-۰/۴۳**	۰/۳۶**	-۰/۴۴**	-۰/۲۲*	-۰/۳۵**
d_g		۱	-۰/۳۹**	-۰/۶۹**	۰/۰۸	-۰/۳۷**	۰/۹۳**	-۰/۸۵**	-۰/۷۴**	۰/۴۳**	-۰/۵۸**	-۰/۳۳**	-۰/۳۸**
BD			۱	۰/۴۸**	-۰/۸۸**	۰/۴۵**	-۰/۴۷**	۰/۴۰**	۰/۴۱**	-۰/۳۳**	۰/۴۵**	-۰/۰۱	۰/۱۸
PD				۱	-۰/۰۲	۰/۵۵**	-۰/۷۲**	۰/۶۲**	۰/۶۱**	-۰/۵۱**	۰/۵۳**	-۰/۴۰**	۰/۵۱**
TP					۱	-۰/۲۱*	۰/۱۵	-۰/۱۲	-۰/۱۴	۰/۱۱	-۰/۲۳*	۰/۲۲*	۰/۰۶
$CaCO_3$						۱	-۰/۷۸**	۰/۸۰**	۰/۵۴**	-۰/۱۳	۰/۶۸**	-۰/۱۷	۰/۴۰**
Sand							۱	-۰/۸۶**	-۰/۸۴**	۰/۴۳**	-۰/۶۶**	-۰/۴۰**	-۰/۶۰**
Silt								۱	۰/۴۶**	-۰/۴۰**	۰/۵۷**	۰/۲۹**	۰/۴۱**
Clay									۱	-۰/۳۳**	۰/۵۶**	۰/۴۰**	۰/۶۲**
OC										۱	-۰/۲۳*	-۰/۴۱**	-۰/۳۸**
pH_e											۱	۰/۱۵	۰/۶۱**
$EC_{1:2.5}$												۱	۰/۵۹**

* و **: به ترتیب معنی دار در سطح احتمال ۱ و ۵ درصد. توصیف علائم متغیرها در جدول ۱ آورده شده است.

با توجه جدول ۲ مشاهده می‌شود که بین هر یک از متغیرهای جرم مخصوص ظاهری با تخلخل کل؛ d_g با شن، سیلت، رس و PD؛ آهک با شن، سیلت و اسیدیته؛ PD با شن، سیلت و رس؛ شن با سیلت، رس، اسیدیته و SAR؛ و رس با SAR همبستگی خطی قوی ($r > 0.60$) وجود دارد؛ از این رو برای اجتناب از همراستایی چندگانه^۱، از این متغیرها همزمان برای اشتقاق توابع رگرسیونی به منظور تخمین K_s در یک تابع استفاده نشد (Ahmadi et al, 2018). همچنین نتایج آنالیز هم خطی حداکثر تورم واریانس^۲ (VIF) توابع مربوطه (جدول ۳)، مقادیر کمتر از ۵ را نشان داد که مقدار حداکثر آن در این پژوهش ۲/۴ است. اگر آماره VIF برای یک متغیر کمتر از ۵ باشد، آن متغیر در مدل وارد می‌شود؛ در غیر این صورت، باید از مدل حذف شود (Norouzian Azizi et al, 2016).

اشتقاق توابع رگرسیونی برای برآورد K_s

بین K_s با سیلت، رس، آهک، اسیدیته، EC، SAR، BD و PD همبستگی منفی و معنی‌دار یافت شد؛ در حالی که بین K_s با شن و کربن آلی همبستگی مثبت و معنی‌دار (جدول ۲). Ahmadi و همکاران (۲۰۱۸) نیز در بررسی خاک‌های منتخب از استان آذربایجان شرقی به این نتیجه رسیدند که بین K_s با BD ($r = -0.81^{**}$) همبستگی منفی و معنی‌دار و بین K_s با شن ($r = 0.84^{**}$) همبستگی مثبت و معنی‌داری وجود دارد. افزایش شن و کاهش رس از طریق تغییر در توزیع اندازه منافذ خاک (افزایش سهم منافذ درشت در مقایسه با منافذ ریز و متوسط)، به افزایش هدایت هیدرولیکی اشباع خاک منجر می‌شود (Hillel, 2004). با افزایش SAR به علت بالارفتن نسبت غلظت سدیم به مجموع کلسیم و منیزیم در محلول خاک، پایداری خاکدانه‌ها (Asghari and Shahabi, 2018) کاهش می‌یابد، منافذ خاک مسدود می‌شود و در نهایت، K_s نیز تنزل می‌یابد. همچنین مشاهده می‌شود با افزایش جرم مخصوص ظاهری و کاهش تخلخل کل، به دلیل کاهش فشردگی خاک از قابلیت مسیر برای هدایت آب و املاح (K_s) کاسته می‌شود؛ در حالی که با افزایش ماده آلی، به دلیل افزایش پایداری خاکدانه‌ها بر میزان K_s افزوده می‌شود. شاکر شه‌مار بیگللو و همکاران (Shaker et al, 2019) نیز گزارش دادند که بین هدایت هیدرولیکی اشباع با جرم مخصوص ظاهری، هدایت الکتریکی و درصد سدیم تبادلی خاک در اراضی متأثر از نمک در حاشیه‌ی غربی دریاچه‌ی ارومیه، رابطه‌ی همبستگی منفی و معنی‌داری وجود دارد. به طور کلی، ۸ تابع رگرسیونی برای برآورد K_s خاک با استفاده از متغیرهای زودیافت تشکیل شد (جدول ۳).

¹ Multicollinearity

² Variance Inflation Factor (VIF)

جدول ۳: توابع رگرسیونی اشتقاق یافته برای برآورد هدایت هیدرولیکی اشباع (K_s) خاک

توابع رگرسیونی	حد اکثر VIF	متغیرهای ورودی	شماره تابع
$K_s=0.835+0.005\text{sand}-0.671\text{BD}$	۱/۲	sand, BD	۱
$K_s=1.479-0.718\text{BD}-0.009\text{silt}$	۱/۱	silt, BD	۲
$K_s=0.463-0.705\text{BD}+0.006\text{sand}+0.048\text{pH}$	۱/۹	sand, BD, pH	۳
$K_s=1.385-0.747\text{BD}+0.017\text{pH}-0.023\text{EC}+0.009\text{OC}-0.008\text{silt}$	۱/۷	silt, BD, pH, EC, OC	۴
$K_s=1.427-0.770\text{BD}+0.018\text{pH}-0.009\text{silt}-0.024\text{EC}$	۱/۶	silt, BD, pH, EC	۵
$K_s=1.481-0.771\text{BD}+0.011\text{pH}-0.009\text{silt}-0.027\text{EC}+0.0005\text{SAR}$	۲/۴	silt, BD, pH, EC, SAR	۶
$K_s=1.546-0.018\text{CaCO}_3-0.686\text{BD}$	۱/۲	CaCO_3 , BD	۷
$K_s=1.261-0.666\text{BD}-0.011\text{CaCO}_3+0.610d_g$	۲/۲	BD, CaCO_3 , d_g	۸

توصیف متغیرها در جدول ۱ آورده شده است.

در جدول ۴ مقادیر آماره‌های R^2 ، RMSE و ME برای ارزیابی این توابع از نظر دقت برآورد K_s ارائه شد. با توجه به اینکه ممکن است استفاده از R^2 به تنهایی برای ارزیابی اعتبار توابع فریب‌دهنده باشد و R^2 نزدیک به ۱ نیز الزاماً بر تطابق کامل مقادیر اندازه‌گیری شده با مقادیر برآورد شده‌ی متغیر دلالت نداشته باشد؛ یعنی بالا بودن R^2 دلیلی بر کمتر بودن خطا نیست؛ از این رو در پژوهش حاضر، رتبه‌بندی توابع بر مبنای پایین بودن RMSE انجام شد. بر اساس آماره RMSE در داده‌های آزمونی، تابع رگرسیونی شماره‌ی ۲ (جدول ۴) با متغیرهای ورودی سیلت و جرم مخصوص ظاهری (BD)، از نظر برآورد K_s در مقایسه با سایر توابع دقت بالاتری دارد. مقادیر R^2 ، RMSE و ME این تابع برای داده‌های آموزشی به ترتیب برابر ۰/۴۴، ۰/۱۸۹ cm/min و $8/3 \times 10^{-17}$ cm/min و برای داده‌های آزمونی برابر با ۰/۶۵، ۰/۱۱۹ cm/min و $-0/059$ cm/min بود (جدول ۴). مقادیر منفی ME برای داده‌های آموزشی و آزمونی، برآورد کمتر از مقدار واقعی K_s خاک را توسط تابع شماره‌ی ۲ نشان می‌دهد. همچنین معادله‌ی رگرسیونی این تابع (جدول ۳) نشان می‌دهد که تأثیر منفی متغیر BD به علت داشتن ضریب رگرسیونی بالاتر در تخمین K_s ، به مراتب بیش از متغیر سیلت است. در رتبه‌های بعدی، تابع شماره‌ی ۱ با متغیرهای ورودی شن و BD و تابع ۸ با متغیرهای ورودی BD، آهک و میانگین هندسی قطر ذرات (d_g)، دقت بیشتری در برآورد K_s دارد (جدول ۴).

جدول ۴: معیارهای ارزیابی توابع انتقالی رگرسیونی برای برآورد هدایت هیدرولیکی اشباع (K_s) خاک

شماره تابع	متغیرهای ورودی	داده‌های آموزشی			داده‌های آزمونی		
		R^2	RMSE (cm/min)	ME (cm/min)	R^2	RMSE (cm/min)	ME (cm/min)
۱	sand, BD	۰/۴۲	۰/۱۹۷	$-۷/۴ \times ۱۰^{-۱۷}$	۰/۶۴	۰/۱۲۱	-۰/۰۳۷
۲	silt, BD	۰/۴۴	۰/۱۸۹	$-۸/۳ \times ۱۰^{-۱۷}$	۰/۶۵	۰/۱۱۹	-۰/۰۵۹
۳	sand, BD, pH	۰/۴۳	۰/۱۹۱	$-۱/۲ \times ۱۰^{-۱۶}$	۰/۶۳	۰/۱۲۹	-۰/۰۳۳
۴	silt, BD, pH, EC, OC	۰/۴۵	۰/۱۸۶	$-۲/۸ \times ۱۰^{-۱۷}$	۰/۶۱	۰/۱۳۷	-۰/۰۰۸
۵	silt, BD, pH, EC	۰/۴۵	۰/۱۸۷	$-۱/۱ \times ۱۰^{-۱۷}$	۰/۶۱	۰/۱۳۷	-۰/۰۱۲۹
۶	silt, BD, pH, EC, SAR	۰/۴۵	۰/۱۸۷	$-۱/۲ \times ۱۰^{-۱۶}$	۰/۵۹	۰/۱۴۲	-۰/۰۱۱۹
۷	CaCO ₃ , BD	۰/۴۳	۰/۱۹۱	$۲/۲۲ \times ۱۰^{-۱۷}$	۰/۶۴	۰/۱۴۷	-۰/۰۱۰۷
۸	BD, CaCO ₃ , d _g	۰/۴۵	۰/۱۸۷	$-۱/۲ \times ۱۰^{-۱۶}$	۰/۶۶	۰/۱۲۸	-۰/۰۸۰

RMSE: مجذور میانگین مربعات خطا، ME: میانگین خطا، R^2 : ضریب تبیین. توصیف متغیرها در جدول ۱ آورده شده است.

متغیرهای ورودی بهترین توابع رگرسیونی در جدول ۴ نشان می‌دهد که جرم مخصوص ظاهری، سیلت، شن و d_g مناسب‌ترین متغیر زودیافت برای برآورد K_s در منطقه‌ی مورد مطالعه است. این نتایج با یافته‌های Kelishadi و همکاران (۲۰۱۳)، Amirabedi و همکاران (۲۰۱۹) و Zhao و همکاران (۲۰۱۶) همخوانی دارد. Kelishadi و همکاران (۲۰۱۳) معتقدند که پارامترهای جرم مخصوص ظاهری نسبی و ماده آلی، مهم‌ترین متغیر زودیافت در تابع رگرسیونی برای برآورد K_s خاک در منطقه‌ی زاگرس مرکزی است. در پژوهش Amirabedi و همکاران (۲۰۱۹) نیز بهترین مدل رگرسیونی با پارامترهای ورودی شن، سیلت و جرم مخصوص ظاهری با R^2 و RMSE برابر با ۰/۵۳ و ۰/۰۷، برای برآورد K_s در خاک‌های منتخب از دشت اردبیل تعیین شد. Zhao و همکاران (۲۰۱۶) نیز متغیرهای جرم مخصوص ظاهری، سیلت و رس را به‌عنوان مناسب‌ترین متغیرهای زودیافت برای برآورد K_s در توابع رگرسیونی به‌دست آوردند.

اشتقاق توابع شبکه عصبی مصنوعی (ANN) برای برآورد K_s

برای اشتقاق توابع شبکه عصبی مصنوعی (ANN) برآورد کننده‌ی K_s ، از ۸ تابع با همان متغیرهای ورودی توابع رگرسیونی (جدول ۴) استفاده شد؛ برای این منظور، تابع فعال‌ساز تانژانت سیگموئیدی در لایه پنهان و تابع خطی در لایه خروجی ساختار پرسپترون شبکه عصبی مصنوعی همه‌ی توابع در نظر گرفته شد (Moghaddamnia et al, 2009). همچنین تعداد نرون‌ها در لایه پنهان توابع انتقالی ANN شماره‌ی ۱ تا ۸ به ترتیب ۳، ۳، ۱، ۳، ۲، ۲ و ۲ به روش سعی و خطا انتخاب شد. جدول ۵، معیارهای ارزیابی توابع ANN ارائه شده برای برآورد K_s خاک را نشان می‌دهد.

جدول ۵: معیارهای ارزیابی توابع شبکه عصبی مصنوعی برای برآورد هدایت هیدرولیکی اشباع (K_s) خاک

شماره تابع	متغیرهای ورودی	داده‌های آموزشی			داده‌های آزمونی		
		R^2	RMSE (cm/min)	ME (cm/min)	R^2	RMSE (cm/min)	ME (cm/min)
۱	sand, BD	۰/۴۷	۰/۵۳۱	۰/۴۵۴	۰/۷۱	۰/۵۲۹	۰/۴۳۶
۲	silt, BD	۰/۴۸	۰/۱۸۳	۰/۰۱۳	۰/۷۳	۰/۰۸۷	۰/۰۰۶
۳	sand, BD, pH	۰/۴۷	۰/۱۸۹	-۰/۰۱۳	۰/۶۹	۰/۰۹۹	-۰/۰۱۰
۴	silt, BD, pH, EC, OC	۰/۴۹	۰/۱۸۴	۰/۰۱۰	۰/۷۶	۰/۰۹۷	-۰/۰۰۸
۵	silt, BD, pH, EC	۰/۴۹	۰/۲۰۸	۰/۰۵۶	۰/۷۴	۰/۱۲۰	۰/۰۳۷
۶	silt, BD, pH, EC, SAR	۰/۵۶	۰/۱۶۸	۰/۰۰۲	۰/۷۱	۰/۰۹۸	-۰/۰۲۸
۷	CaCO ₃ , BD	۰/۴۷	۰/۱۹۰	-۰/۰۴۴	۰/۷۲	۰/۰۹۶	-۰/۰۲۶
۸	BD, CaCO ₃ , d _g	۰/۴۷	۰/۱۸۹	-۰/۰۱۴	۰/۷۴	۰/۰۹۴	-۰/۰۰۸

توصیف متغیرها و علائم در جداول ۱ و ۴ آورده شده است.

رتبه‌بندی توابع ANN نیز همانند توابع رگرسیونی (جدول ۴)، بر اساس کوچک بودن RMSE صورت گرفت. براساس آماره مذکور در داده‌های آزمونی (جدول ۵)، تابع شماره‌ی ۲ با متغیرهای ورودی سیلت و جرم مخصوص ظاهری (BD)، به عنوان بهترین تابع ANN در برآورد K_s خاک تعیین شد. مقادیر R^2 ، RMSE و ME این تابع برای داده‌های آموزشی به ترتیب برابر ۰/۷۳، ۰/۰۸۷ cm/min و ۰/۰۰۶ cm/min و برای داده‌های آزمونی برابر ۰/۴۸، ۰/۱۸۳ cm/min و ۰/۰۱۳ cm/min بود (جدول ۵). مقادیر مثبت ME برای داده‌های آموزشی و آزمونی در تابع ۲ نشان می‌دهد که این تابع، K_s را بیش از مقدار واقعی برآورد می‌کند. در رتبه‌ی بعدی، تابع شماره‌ی ۸ با متغیرهای ورودی BD، آهک و میانگین هندسی قطر ذرات (d_g)، دقت بیشتری در برآورد K_s دارد (جدول ۵).

بهترین توابع ANN در این پژوهش، بیانگر اهمیت زیاد متغیرهای جرم مخصوص ظاهری، سیلت، آهک و میانگین هندسی قطر ذرات در برآورد K_s منطقه‌ی مورد مطالعه است. بنابراین با مشاهده‌ی جداول ۴ و ۵ می‌توان گفت که در پژوهش حاضر، متغیرهای ورودی بهترین توابع رگرسیونی و بهترین توابع ANN تخمین‌زننده‌ی K_s ، تقریباً یکسان هستند. Rezae Arshad و همکاران (۲۰۱۲) گزارش کردند تابع شبکه عصبی مصنوعی با متغیرهای ورودی سنگریزه، تخلخل کل، شن و ماده آلی دارای بیشترین R^2 و کمترین RMSE در برآورد K_s خاک‌های منتخب از منطقه‌ی خوزستان بودند. در پژوهش Doaei و همکاران (۲۰۰۵) نیز مدل شبکه عصبی (ANN) با متغیرهای ورودی رس، کربن آلی و جرم مخصوص ظاهری، به عنوان بهترین مدل در برآورد K_s معرفی شد.

اشتیاق توابع نروفازی برای برآورد K_s

توابع هیبرید نروفازی، برای مدل‌سازی روابط دینامیک پیچیده توسعه یافته‌اند. مدل‌های نروفازی رفتار یک سیستم را با قوانین منطق فازی سوگنو در داخل ساختار شبکه عصبی شبیه‌سازی می‌کنند. در واقع این مدل‌ها، مزایای هر دو مدل شبکه‌های عصبی و سیستم‌های فازی را دارند. این مدل، برخی پارامترها را به وسیله‌ی قانون یادگیری هیبرید - که شامل

روش‌های پس انتشار گرادیان خطا و حداقل مربعات است - برآورد می‌کند. این پارامترها به همراه توابع عضویت، برای ساخت مجموعه قوانین اگر - آنگاه فازی به کار می‌روند (Moghaddamnia et al, 2009). در پژوهش حاضر برای اشتقاق توابع نروفازی برآورد کننده K_s (جدول ۶) نیز از ۸ تابع با همان متغیرهای ورودی توابع رگرسیونی (جدول ۴) استفاده شد.

جدول ۶: معیارهای ارزیابی توابع نروفازی برای برآورد هدایت هیدرولیکی اشباع (K_s) خاک

شماره تابع	متغیرهای ورودی	داده‌های آموزشی			داده‌های آزمونی		
		R^2	RMSE (cm/min)	ME (cm/min)	R^2	RMSE (cm/min)	ME (cm/min)
۱	sand, BD	۰/۵۱	۰/۱۷۷	۱/۹۴ × ۱۰ ^{-۸}	۰/۶۸	۰/۱۳۱	-۰/۰۵۶
۲	silt, BD	۰/۵۲	۰/۱۷۴	۲/۱۹ × ۱۰ ^{-۸}	۰/۶۹	۰/۱۲۷	-۰/۰۵۱
۳	sand, BD, pH	۰/۶۴	۰/۱۵۲	-۴/۵ × ۱۰ ^{-۷}	۰/۶۶	۰/۱۹۵	-۰/۰۸۶
۴	silt, BD, pH, EC, OC	۰/۹۹	۰/۰۰۹	-۷/۸ × ۱۰ ^{-۷}	۰/۲۵	۲/۲۰	-۰/۲۲۴
۵	silt, BD, pH, EC	۰/۷۹	۰/۱۱۵	-۱/۳ × ۱۰ ^{-۸}	۰/۱۱	۲/۱۳	-۰/۷۰۵
۶	silt, BD, pH, EC, SAR	۰/۸۷	۰/۰۹۱	۴/۲۹ × ۱۰ ^{-۶}	۰/۰۲	۶/۶۳	-۲/۵۴
۷	CaCO ₃ , BD	۰/۵۱	۰/۱۷۶	۲/۴۷ × ۱۰ ^{-۸}	۰/۵۶	۰/۱۴۹	-۰/۰۸۴
۸	BD, CaCO ₃ , d _g	۰/۶۵	۰/۱۴۷	۱/۷ × ۱۰ ^{-۷}	۰/۳۰	۰/۳۰۳	-۰/۰۷۲

توصیف متغیرها و علائم در جداول ۱ و ۴ آورده شده است.

جدول ۶، معیارهای ارزیابی توابع نروفازی ارائه شده در برآورد K_s خاک را نشان می‌دهد. رتبه‌بندی این توابع نیز همانند توابع رگرسیونی و شبکه عصبی مصنوعی (جداول ۴ و ۵)، بر اساس کوچک بودن RMSE صورت گرفت. براساس آماره مذکور در داده‌های آزمونی (جدول ۶)، تابع شماره ۲ با متغیرهای ورودی سیلت و جرم مخصوص ظاهری (BD) به عنوان بهترین تابع نروفازی در برآورد K_s خاک تعیین شد. مقادیر R^2 ، RMSE و ME این تابع برای داده‌های آموزشی به ترتیب برابر ۰/۵۲، ۰/۱۷۴ cm/min و $۱/۹۴ \times 10^{-8}$ و برای داده‌های آزمونی برابر ۰/۶۹، ۰/۱۲۷ cm/min و -۰/۰۵۱ بود (جدول ۶). مقادیر مثبت ME برای داده‌های آموزشی، بیانگر بیش-برآوردی و مقادیر منفی ME برای داده‌های آزمونی، بیانگر کم‌برآوردی تابع ۲ در تخمین K_s می‌باشد. در رتبه‌های بعدی، تابع شماره ۱ با متغیرهای ورودی شن و BD و تابع شماره ۷ با متغیرهای ورودی آهک و BD، دقت بیشتری در برآورد K_s دارد (جدول ۵). بنابراین براساس بهترین توابع نروفازی می‌توان گفت که در بین متغیرهای زود یافت خاک، پارامترهای جرم مخصوص ظاهری، سیلت، شن و آهک در تخمین K_s خاک در منطقه‌ی مورد مطالعه اهمیت بالایی دارد. Nadiri and Yousefzadeh (۲۰۱۸) گزارش کردند مدل‌های نروفازی در مقایسه با مدل‌های شبکه عصبی مصنوعی و فازی، از نظر برآورد هدایت هیدرولیکی دقت بالایی دارند. در پژوهش Yazdani و همکاران (۲۰۱۲)، تابع نروفازی با متغیرهای ورودی جرم مخصوص ظاهری و حقیقی، تخلخل کل و بعد فراکتال اندازه ذرات خاک با R^2 و RMSE به ترتیب ۰/۸ و ۰/۱۲ mm/min در سری آموزش و ۰/۸۶ و ۰/۰۲ mm/min در سری

آزمون، دارای بهترین عملکرد در تخمین K_s هستند. در مدل نروفازی ارائه شده توسط Behmanesh and Rezaie (۲۰۱۵) متغیرهای شن، سیلت، جرم مخصوص ظاهری و حقیقی به عنوان بهترین ورودی در تخمین K_s با مقادیر R^2 و RMSE به ترتیب ۱ و $10^{-7} \times 1/2$ و در سری آموزش و $0/98$ و $0/0006$ m/day در سری آزمون انتخاب شدند.

مقایسه دقت توابع رگرسیونی، شبکه عصبی مصنوعی و نروفازی در برآورد K_s

مقایسه مقادیر R^2 و RMSE برای بهترین توابع انتقالی رگرسیونی، شبکه عصبی مصنوعی و نروفازی ارائه شده در برآورد K_s در داده‌های آزمونی (جدول ۷)، نشان می‌دهد که شبکه‌های عصبی مصنوعی به علت داشتن R^2 بیشتر ($0/73$) در مقابل $0/65$ و $0/69$ به ترتیب برای توابع رگرسیونی و نروفازی) و RMSE کمتر ($0/087$) در مقابل $0/119$ و $0/127$ cm/min به ترتیب برای توابع رگرسیونی و نروفازی)، در مقایسه با توابع رگرسیونی و نروفازی از دقت بالاتر و خطای کمتری در برآورد K_s برخوردارند. این نتایج با یافته‌های Ahmadi و همکاران (۲۰۱۹) مطابقت دارد. آنها نشان دادند که در برآورد رطوبت خاک با استفاده از پارامترهای فراکتالی در استان اردبیل، دقت مدل شبکه عصبی بیش از مدل رگرسیونی بود. مقایسه مقادیر R^2 ، RMSE و ME برای بهترین توابع انتقالی رگرسیونی و نروفازی (جدول ۷) نشان می‌دهد که توابع مذکور از نظر دقت تخمین هدایت هیدرولیکی اشباع خاک در منطقه‌ی مورد مطالعه، تفاوت چندانی با یکدیگر نداشت.

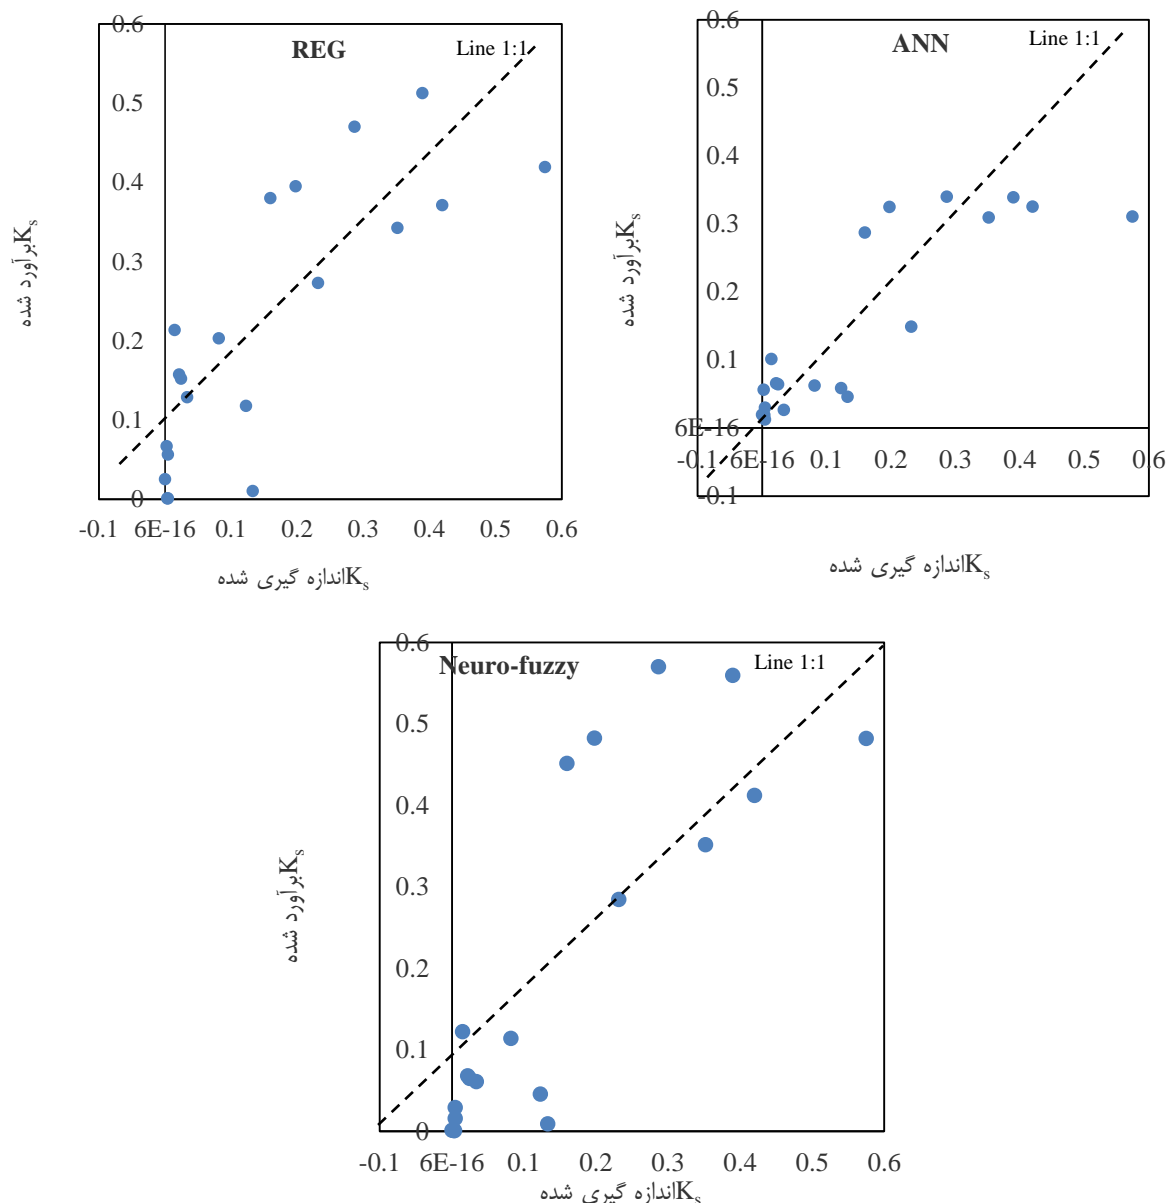
جدول ۷: مقایسه دقت توابع انتقالی در برآورد هدایت هیدرولیکی اشباع (K_s) خاک بر اساس بهترین تابع در داده‌های آزمونی

تابع	شماره	متغیرهای ورودی	ME (cm/min)	RMSE (cm/min)	R^2
رگرسیون	۲	silt, BD	$-0/059$	$0/119$	$0/65$
شبکه عصبی مصنوعی ANN	۲	silt, BD	$0/006$	$0/087$	$0/73$
نروفازی Neuro-fuzzy	۲	silt, BD	$0/051$	$0/127$	$0/69$

توصیف متغیرها و علائم در جداول ۱ و ۴ آورده شده است.

شکل ۲ نمودار ۱:۱، مقادیر اندازه‌گیری و برآورد شده‌ی هدایت هیدرولیکی اشباع خاک را با استفاده از بهترین تابع رگرسیونی (تابع شماره‌ی ۲ در جدول ۴)، شبکه عصبی مصنوعی (تابع شماره‌ی ۲ در جدول ۵) و نروفازی (تابع شماره-ی ۲ در جدول ۶) براساس داده‌های آزمونی نشان می‌دهد. با توجه به شکل ۲ مشاهده می‌شود که پراکندگی داده‌ها حول محور ۱:۱ در بهترین توابع رگرسیونی و نروفازی، بیش از بهترین تابع شبکه عصبی اشتقاق یافته برای برآورد K_s در خاک‌های منطقه‌ی مورد مطالعه است؛ به عبارت دیگر، دقت مدل شبکه عصبی مصنوعی در تخمین K_s به مراتب بیش از مدل‌های رگرسیونی و نروفازی است. Amirabedi و همکاران (۲۰۱۹) معتقدند که شبکه‌های عصبی مصنوعی با متغیرهای ورودی یکسان، هدایت هیدرولیکی اشباع خاک را با دقت بیشتری ($R^2=0/84$) نسبت به توابع رگرسیونی ($R^2=0/53$) در دشت اردبیل برآورد کرده است. این نتایج با یافته‌های Rezae Arshad و همکاران (۲۰۱۲) و Khalili و Moghadam و همکاران (۲۰۱۵) نیز در یک راستا می‌باشد. Minasny و همکاران (۲۰۰۲) معتقدند علت برآورد دقیق‌تر شبکه‌های عصبی مصنوعی نسبت به توابع انتقالی رگرسیونی، نحوه‌ی عملکرد شبکه پرسپترون سه لایه است. عملکرد این شبکه به این صورت است که ابتدا الگویی به شبکه، عرضه و خروجی آن محاسبه می‌شود. سپس شبکه،

این خروجی را با مقادیر اندازه‌گیری شده‌ی متغیر یا متغیرهای خروجی مقایسه می‌کند و ضرایب وزنی شبکه را به نوعی تغییر می‌دهد که بین مقادیر برآورد و اندازه‌گیری شده، کمترین اختلاف وجود داشته باشد.



شکل ۲: نمودار ۱:۱ مقادیر اندازه‌گیری و برآورد شده K_s (cm/min) با استفاده از بهترین تابع رگرسیونی (REG)، شبکه عصبی مصنوعی (ANN) و نروفازی (Neuro-fuzzy) بر اساس داده‌های آزمونی ($n=20$). اطلاعات مربوط به توابع و متغیرهای ورودی در جدول ۷ آورده شده است. خط چین بیانگر نمودار ۱:۱ است.

۴- نتیجه‌گیری

در پژوهش حاضر توابع رگرسیونی، شبکه عصبی مصنوعی و نروفازی، به منظور برآورد هدایت هیدرولیکی اشباع (K_s) با استفاده از متغیرهای زودپافت خاک مقایسه شد. این امر در اراضی متأثر از نمک منتخب از شمال غرب دریای ارومیه صورت گرفت. نتایج توابع به‌دست آمده در برآورد K_s خاک منطقه‌ی مورد مطالعه، نشان داد که مهم‌ترین متغیرهای زودپافت شامل جرم مخصوص ظاهری و سیلت است. مقایسه‌ی نتایج بیانگر آن بود که شبکه‌های

عصبی مصنوعی به علت داشتن R^2 بالاتر و RMSE پایین تر، در برآورد K_s خاک نسبت به توابع رگرسیونی و نروفازی از دقت بالاتر و خطای کمتری برخوردارند. همچنین بین توابع رگرسیونی و نروفازی از نظر برآورد K_s خاک منطقه‌ی مورد مطالعه، تفاوت چندانی مشاهده نشد.

منابع

1. Asghari, Sh., & M. Shahabi., (2018). Geostatistical assessment of aggregates stability and sodium adsorption ratio in salt-affected soils around Urmia Lake. *Journal of Water and Soil*. 31 (5), 1302-1312 (In Persian).
2. Asghari, Sh., & M. Shahabi., (2019). Spatial variability of soil saturated hydraulic conductivity and penetration resistance in salt-affected lands around Lake Urmia. *Journal of Water and Soil*. 33 (1), 103-116 (In Persian).
3. Ahmadi, A.; Alimohammadi, M.; & Sh. Asghari, 2019. Pedotransfer functions for estimating soil moisture content using fractal parameters in Ardabil province, *Quarterly Journal of Environmental Erosion Research*, 34(9:2), 37-52 (In Persian).
4. Amirabedi, H.; Asghari, Sh.; Mesri, T.; Balandeh, N.; & E. Johari, 2019. Estimating saturated hydraulic conductivity in selected soils of Ardabil plain using regression and artificial neural networks models, *Applied Soil Research*, In Press. (In Persian)
5. Ahmadi, A.; Palizvan zand, P.; & H. Palivan zand, 2018. Estimation of saturated hydraulic conductivity by using gene expression programming and ridge regression (a case study in East Azerbaijan province), *Iranian Journal of Soil and Water Research*, 48(5), 1087-1095 (In Persian)
6. Behmanesh, J., & E. Rezaie., (2015). Evaluation of regression and neuro-fuzzy models in estimating saturated hydraulic conductivity. *Journal of Water and Soil*. 28(6), 1115-1125 (In Persian)
7. Blake, G. R., & K. H. Hartge., (1986a). Bulk Density. In A. Klute (ed). *Methods of Soil Analysis, Part 1- Physical and Mineralogical Methods*. *Soil Science Society of American Inc., Madison, WI*, pp, 363-375.
8. Blake, G. R., & K. H. Hartge., (1986b). Particle Density. In A. Klute (ed). *Methods of Soil Analysis. Part 1- Physical and Mineralogical Methods*. *Soil Science Society of American Inc., Madison, WI*, pp, 377-382.
9. Bouma, J., 1989. Using soil survey data for qualitative land evaluation, *Advances in Soil Science*, 9, 177-213.
10. Campbell, G.S., 1985. *Soil Physics with Basic: Transport Models for Soil-Plant System*, Elsevier, New York, 150 p.
11. Doaei, M.; Shabanpour-e-shahrestani, M.; & F. Bagheri, 2005. Modelling of saturated hydraulic conductivity of Gilan Province involving artificial neural networks, *The Agricultural Science Research Report, Faculty of Agriculture, Gilan Univesity*, 94p.
12. Danielson, R. E., & P. L. Sutherland., (1986). Porosity.. In: Klute A (ed). *Methods of Soil Analysis. Part 1, 2 nd ed. Agronomy Monograph. 9. Soil Science Society of American Inc., Madison. WI*, 443-461p.
13. Gee, G. W., & D. Or., (2002). Particle-size analysis. In: Dane, J.H., Topp, G.C. (eds.), *Methods of Soil Analysis, Part 4. Soil Science Society of America Inc. Book Series No. 5. Madison, WI*, pp, 255-293.
14. Hamzehpoura, N., & P. Bogaert., (2017). Improved spatiotemporal monitoring of soil salinity using filtered kriging with measurement errors: An application to the West Urmia Lake, Iran. *Geoderma*. 295, 22–33.
15. Hillel, D., 2004. *Introduction to Environmental Soil Physics*, Elsevier Academic Press, 494p.

16. Kelishadi, H.; Mosaddeghi, M. R.; Hajabbasi, M. A.; & S. Ayoubi, 2013. Evaluating and developing pedotransfer functions to predict soil saturated hydraulic conductivity at landscape scale in central Zagros, *Applied Soil Research*, 1(2), 16-33 (In Persian)
17. Klute, A., & C. Dirksen., (1986). Hydraulic conductivity and diffusivity: Laboratory methods. In: Klute A(ed). *Methods of Soil Analysis. Part 1, Physical and Mineralogical Methods*, 2nd ed. *ASA and Soil Science Society of America, Madison, WI*. Pp, 687-734.
18. Khalili Moghadam, B.; Afyuni, M.; Jalalian, A.; Abbaspour, K. C.; & A. A. Dehghani, 2015. Estimation of soil saturated hydraulic conductivity in part of central Zagroos using regression and ANNs method, *J. Sci. & Technol. Agric. & Natur. Resour., Water and Soil Sci*, 19(71), 217-228 (In Persian)
19. Moghaddamnia, A.; Remesan, R.; Hasanpour Kashani, M.; Mohammadi, M.; Han, D.; & J. Piri, 2009. Comparison of LLR, MLP, Elman, NNARX and ANFIS Models—with a case study in solar radiation estimation, *Journal of Atmospheric and Solar-Terrestrial Physics*, 71, 975–982.
20. Merdun, H.; Cinar, O.; Meral, R.; & M. Apan, 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity, *Soil and Tillage Research*, 90, 108–116.
21. Minasny, B., & A. B. Mcbartney., (2002). The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*. 66, 352-361.
22. Nelson, D. W., & L. E. Sommers., (1982). Total carbon, organic carbon, and organic matter. In A.L. Page et al. (ed.) *Methods of Soil Analysis. Part 2. 2nd ed. Agron. Monogr. 9. ASA and SSSA, Madison, WI*. p.p, 539–579.
23. Nadiri, A., & S. Y. ousefzadeh., (2018). A comparison of the performance of artificial neural network, fuzzy logic and adaptive neuro-fuzzy inference systems models in the estimation of aquifer hydraulic conductivity. A case study: Maraghe-Bonab aquifer. *Journal of Hydrogeomorphology*. 3 (10), 21-40. (In Persian)
24. Norouzian Azizi, Z.; Ghajar Sepanlou, M.; Emadi, S. M.; & F. Sadeqzade, 2016. Evaluation of regression and artificial neural network models to estimate the saturated hydraulic conductivity in Mazandaran province, *Iranian Journal of Soil Research*, 31(1), 76-88. (In Persian)
25. Page, A. L., 1985. *Methods of Soil Analysis. Part 2. Chemical and Microbiological Methods. Agron. Monogr.9. ASA and SSSA, Madison, WI*.
26. Rezae Arshad, R.; Sayyad, G. H.; Mazloom, M.; Shorafa, M.; & A. Jafarnejady, 2012. Comparison of artificial neural networks and regression pedotransfer functions for predicting saturated hydraulic conductivity in soils of Khuzestan province, *J. Sci. & Technol. Agric. & Natur. Resour., Water and Soil Sci*, 16(60), 107–118. (In Persian)
27. Shaker Shahmarbeigloo, P.; Khodaverdiloo, H.; & H. R. Momtaz, 2019. Testing of new inputs to predict near-saturated soil hydraulic conductivity, *Applied Soil Research*, 7(1), 54-69. (In Persian)
28. Wilding, L. P., & L. R. Dress., (1983). Spatial variability and pedology. In: Wilding L.P, Smeckand N.E, and Hall GF, (EDs). *Pedogenesis and Soil Taxonomy. I. Concepts and Interactions. Elsevier Science Pub*, pp, 83-116.
29. Yazdani, V.; Ghahreman, B.; Davari, K.; & M. E. Fazeli, 2012. Using fractal dimension of particle size in estimating saturated hydraulic conductivity, *Journal of Water and Soil*, 26 (3), 648-659. (In Persian)
30. Zhao, C.; Shao, M. A.; Jia, X.; Nasir, M.; & C. Zhang, 2016. Using pedotransfer functions to estimate soil hydraulic conductivity in the loess plateau of China, *Catena*, 143, 1-6.

Deriving Pedotransfer Functions for Estimating Soil Saturated Hydraulic Conductivity in North West of Urmia Lake

Shokrollah Asghari¹: Associate professor, Department of Soil Sciences and engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil

Mozhgan Hatamvand: Graduated MSc. Student Department of Soil Sciences and engineering, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil

Mahsa Hasanpour Kashani: Assistant Professor, Water Engineering Department, Faculty of Agriculture and Natural Resources, University of Mohaghegh Ardabili, Ardabil

Article History (Received: 2020/01/22

Accepted: 2020/03/04)

Extended abstract

1- Introduction

Soil saturated hydraulic conductivity (K_s) is an important factor in the estimation of water, solute transport models and erosion processes. Direct measurement of soil saturated hydraulic conductivity (K_s) in field and laboratory is time-consuming, laborious and expensive because of high temporal and spatial variability; especially in salt-affected soils around Urmia Lake, K_s measurement is difficult because of high sodium concentration and consequently poor stability of soil aggregates. Therefore, many different regressions, artificial neural network (ANN) and the neuro-fuzzy pedotransfer functions (PTF) have been developed to estimate K_s from readily available soil variables such as sand, silt, clay, bulk density (BD), particle density (PD), electrical conductivity (EC), pH, and organic carbon (OC). The objectives of this study were to derive pedotransfer functions by using regression, artificial neural network, and neuro-fuzzy methods to estimate K_s from some soil variables in the salt-affected soils selected from the northwest of Urmia Lake and to compare the performance of the neuro-fuzzy, artificial neural network and regression models.

2- Methodology

Disturbed and undisturbed (steel cylinders with 5 cm diameter and height) soil samples ($n=100$) were systematically taken from 0-10 cm soil depth of bare and agricultural lands of Shend Abad region located at the 15 km of Shabestar city, northwest of Urmia Lake, Iran ($45^{\circ} 36' 34''$ E and $38^{\circ} 6' 37''$ N). The values of sand, silt, and clay (hydrometer method), CaCO_3 (titration method), bulk density (cylinder method), particle density (pycnometer method), organic carbon (wet oxidation method), and total porosity (calculating from BD and PD) were measured in the laboratory. The mean geometric diameter (d_g) of soil particles was computed using the percentages of sand, silt, and clay. The EC and sodium adsorption ratio (SAR) were measured in 1:2.5 (soil: distilled water) extra. The pH_e was determined in a/the saturated paste. The soil saturated hydraulic conductivity (K_s) was measured by constant (agricultural lands) and falling (bare lands) head method using steel cylinders in the laboratory. The data were divided into two series as 80 data for training and 20 data for testing. The SPSS 18 software with a/the stepwise method to derive the regression PTFs and MATLAB software to derive the artificial neural network and neuro-fuzzy PTFs were used. A three-layer perceptron network and the tangent sigmoid transfer function were used for the artificial neural network modeling. In estimating soil saturated hydraulic conductivity, the accuracy of neuro-fuzzy,

¹ Corresponding Author: shasghari@uma.ac.ir

artificial neural network and regression pedotransfer functions were evaluated by the coefficient of determination (R^2), root mean square error (RMSE) and mean error (ME) criteria.

3- Results & Discussion

Most of the studied soil variables had good distribution for developing and evaluating regression, ANN, and neuro-fuzzy PTFs. The high values of the coefficient of variation (CV) were found for SAR (167.86%), K_s (130.36%), EC (117.05%), d_g (88.44%), clay (73.23%), OC (58.46%) and sand (51.47%) in the studied area. The textural classes of studied soils were loamy sand ($n=3$), sandy loam ($n=39$), loam ($n=20$), silt loam ($n=22$), silty clay loam ($n=7$), silty clay ($n=7$) and clay ($n=2$). There were found significant correlations between soil saturated hydraulic conductivity (K_s) and sand ($r=0.60^{**}$), silt ($r=-0.60^{**}$), clay ($r=-0.43^{**}$), organic carbon ($r=0.36^{**}$), bulk density ($r=-0.52^{**}$), particle density ($r=-0.53^{**}$), total porosity ($r=0.31^{**}$), $CaCO_3$ ($r=-0.58^{**}$), mean geometric diameter ($r=0.57^{**}$), SAR ($r=-0.35^{**}$), EC ($r=-0.22^*$) and pH_e ($r=-0.44^{**}$). These results are in line with the findings of the former studies that reported direct relation of K_s with OC, sand, and inverse relation of K_s with silt, clay, BD, and SAR. Generally, 8 regression, artificial neural network, and neuro-fuzzy pedotransfer functions were constructed to estimate soil saturated hydraulic conductivity (K_s) from measured readily available soil variables. The results of the best regression, artificial neural network and neuro-fuzzy pedotransfer functions indicated that the most suitable input variables to estimate soil saturated hydraulic conductivity (K_s) were bulk density and silt in the studied region. The values of R^2 , RMSE and ME were obtained equal to 0.65, 0.119 $cm\ min^{-1}$, 0.059 $cm\ min^{-1}$ and 0.73, 0.087 $cm\ min^{-1}$, 0.006 $cm\ min^{-1}$ and 0.69, 0.127 $cm\ min^{-1}$, -0.051 $cm\ min^{-1}$ for the best regression, artificial neural network, and neuro-fuzzy K_s pedotransfer functions, respectively. According to these results, the ANN PTF was the best in estimating K_s because of having high R^2 and low RMSE compared with regression and neuro-fuzzy PTFs. The former researchers also obtained bulk density and silt as the best input variables for estimating soil saturated hydraulic conductivity (K_s) in different soils and regions.

4- Conclusions

The results showed that bulk density and silt are the most suitable readily available soil variables to estimate soil saturated hydraulic conductivity (K_s) in the studied salt-affected soils. According to the RMSE criterion, the precision of an/the artificial neural networks in estimating K_s was more than regression and neuro-fuzzy pedotransfer functions in this research. Also, regression and neuro-fuzzy PTFs have not an/the observable difference in estimating K_s .

Key Words: Estimation, Hydraulic properties, Neuro-Fuzzy, Regression, Salt-affected soils.