

کاربرد روش‌های رگرسیونی و شبکه‌های عصبی به منظور تخمین هدایت هیدرولیکی اشباع خاک منطقه زاگرس مرکزی

بیژن خلیلی مقدم^{۱*}، مجید افیونی^۲، احمد جلالیان^۲، کریم عباسپور^۳ و امیراحمد دهقانی^۴

(تاریخ دریافت: ۱۳۹۰/۵/۲۵؛ تاریخ پذیرش: ۱۳۹۳/۵/۱۱)

چکیده

در سال‌های اخیر با ظهور سامانه اطلاعات جغرافیایی و تکنولوژی سنجش از دور، ویژگی‌های توپوگرافیکی (ارتفاع، شب و جهت شب) و ویژگی‌های پوشش گیاهی به راحتی به وسیله مدل‌های رقومی ارتفاع و شاخص پوشش گیاهی (NDVI) در مقیاس‌های مختلف (حوزه‌ای و منطقه‌ای) قابل دسترس می‌باشد. هدف از انجام این پژوهش، بررسی امکان استفاده از ویژگی‌های توپوگرافیکی و پوشش گیاهی به همراه ویژگی‌های خاک به عنوان ویژگی‌های زود یافته برای تخمین هدایت هیدرولیکی اشباع خاک است. برای این کار توزیع اندازه ذرات خاک، ویژگی‌های آلی، کربنات کلسیم و چگالی ظاهری در افق‌های رویین و زیرین و ویژگی‌های توپوگرافیکی و NDVI از افق رویین خاک اندازه‌گیری شدند. سه ساختار شبکه عصبی پرسپترون برای مقایسه با رگرسیون چندمتغیره خطی مورد استفاده قرار گرفتند. کارایی توابع انتقالی خاک و توابع پیش‌بینی مکانی خاک به وسیله ضریب همبستگی اسپیرمن (r)، میانگین مربعات خطای نرمال شده (NMSE) و میانگین خطای مطلق (MAE) بین مقادیر اندازه‌گیری شده و مشاهده شده مورد ارزیابی قرار گرفت. نتایج نشان داد که ویژگی‌های توپوگرافیکی و پوشش گیاهی از متغیرهای حساس در تخمین هدایت هیدرولیکی اشباع خاک در مراتع زاگرس مرکزی می‌باشند. به طور کلی شبکه‌های عصبی $r=0.87$ داری کارایی بهتری از رگرسیون چندمتغیره خطی $r=0.69$ در تخمین هدایت هیدرولیکی اشباع خاک هستند.

واژه‌های کلیدی: شبکه عصبی مصنوعی، هدایت هیدرولیکی اشباع خاک، مدل‌های ریاضی-فیزیکی، مراتع زاگرس مرکزی

۱. گروه خاک‌شناسی، دانشکده کشاورزی و منابع طبیعی رامین خوزستان

۲. گروه خاک‌شناسی، دانشکده کشاورزی، دانشگاه صنعتی اصفهان

۳. گروه علوم و تکنولوژی آب مؤسسه تحقیقاتی EWAG سوئیس

۴. گروه مهندسی آب دانشگاه علوم کشاورزی و منابع طبیعی گرگان

*: مسئول مکاتبات، پست الکترونیکی: moghaddam623@yahoo.ie

مقدمه

شده‌اند، که از مهم‌ترین شبکه‌های عصبی، شبکه عصبی پرسپترون (Perceptron) می‌باشد که برای مدل‌سازی فرآیندهای اکولوژیکی و هیدرولوژیکی بسیار مورد استفاده قرار گرفته است. لیجی و همکاران (۹) و پاچپسکی و همکاران (۱۹) برای ایجاد PTFs در یک شبیت تپه از ویژگی‌های توپوگرافیکی به همراه ویژگی‌های فیزیکی خاک به ترتیب در مریلند آمریکا و باسیلیکاتا ایتالیا استفاده کردند و نتایج آنها نشان داد که با کاربرد پارامترهای توپوگرافیکی نظیر شبیت و جهت شبیت کارایی تخمین PTFs در پیش‌بینی منحنی رطوبتی خاک بهبود یافت. هم‌چنین، پاچپسکی و همکاران (۱۹) با ارایه معادلات رگرسیونی نشان دادند که پارامترهای توپوگرافیکی استخراج شده از مدل‌های رقومی ارتفاع باعث بهبود کارایی PTFs گردید. امروزه با افزایش دسترسی به داده‌های سنجدش از دور با تفکیک‌پذیری بالا، می‌توان از ویژگی‌های رویین زمین به عنوان ویژگی‌های زود یافته برای ایجاد و بهبود PTFs در مقیاس‌های منطقه‌ای و حوزه آبخیز سود جست. موهانتی و اسکاگز (۱۴) و شرما و همکاران (۲۴) نشان دادند که ترکیب ویژگی‌های زود یافته مانند عوارض توپوگرافیکی، پوشش گیاهی و ویژگی‌های خاک برای پیش‌بینی میزان رطوبت خاک مناسب می‌باشند. تاکنون تلاش‌های زیادی در جهت ایجاد رابطه بین هدایت هیدرولیکی اشباع خاک و ویژگی‌های زود یافته خاک مانند توزیع اندازه ذرات خاک، کربن آلی خاک، میانگین هندسی قطر ذرات و انحراف معیار هندسی قطر ذرات و چگالی ظاهری خاک انجام گردیده‌اند (۳، ۲۵ و ۲۷). بر اساس رابطه بین کربن آلی خاک با کاربری اراضی و پوشش گیاهی و نیز رابطه بین ویژگی‌های توپوگرافیکی نظیر شبیت و جهت شبیت با توزیع اندازه ذرات خاک می‌توان از شاخص پوشش گیاهی و ویژگی‌های توپوگرافیکی برای تخمین هدایت هیدرولیکی اشباع خاک استفاده نمود.

در این مطالعه فرض بر این است که ویژگی‌های توپوگرافیکی و پوشش گیاهی اثر غیرمستقیم روی هدایت هیدرولیکی اشباع خاک دارند. بنابراین، دارای این پتانسیل

در سال‌های اخیر استفاده از مدل‌های ریاضی- فیزیکی برای شبیه‌سازی روان‌آب و فرسایش، گسترش چشمگیری یافته است. برای کاربرد این مدل‌ها در مقیاس منطقه‌ای و حوزه آبخیز نیاز به پارامترهای ورودی نظری هدایت هیدرولیکی اشباع خاک (K_s) می‌باشد. ولی از آنجا که اندازه‌گیری مستقیم هدایت هیدرولیکی اشباع پرهزینه و زمان‌بر می‌باشد، بنابراین تعیین آنرا در مقیاس‌های بزرگ بسیار مشکل می‌سازد. برای حل این مشکل از روش‌های غیرمستقیم مانند توابع انتقالی خاک (Pedotransfer functions، PTFs) و توابع پیش‌بینی مکانی خاک (Soil spatial prediction functions، SSPFs) استفاده می‌گردد (۲۰). PTFs توابع پیش‌بینی کننده‌ای هستند که داده‌های زود یافته خاک (Easily-available soil properties) مانند توزیع اندازه ذرات، چگالی ظاهری و ماده آلی را به ویژگی‌های دیریافت خاک مانند ویژگی‌های هیدرولیکی و مکانیکی مرتبط می‌کنند. SSPFs توابع پیش‌بینی کننده‌ای هستند که علاوه بر ویژگی‌های زود یافته خاکی از ویژگی‌های زود یافته غیرخاکی مانند توپوگرافی و پوشش گیاهی برای برآورد ویژگی‌های هیدرولیکی و مکانیکی استفاده می‌نمایند. روش‌های مختلفی برای بسط PTFs و SSPFs ارائه شده‌اند، که این روش‌ها شامل جدول‌های ساده تا روش‌های پیشرفته‌تری مثل رگرسیون چندمتغیره خطی و غیرخطی، رگرسیون درختی و شبکه‌های عصبی مصنوعی (ANNs) می‌باشند (۴). گوپتا و لارسون (۸) از روش رگرسیون خطی، رآلز و همکاران (۲۱) و میناسنی و همکاران (۱۳) از روش غیرخطی برای تخمین ویژگی‌های هیدرولیکی استفاده کردند. به تدریج شبکه‌های عصبی جایگزین روش‌های رگرسیونی گردیدند که از آن جمله می‌توان به پژوهش‌های انجام شده توسط پاچپسکی و همکاران (۱۸)، اسخاپ و بوتن (۲۳) و میناسنی و همکاران (۱۳) اشاره نمود. نتایج این مطالعات حاکی از آن است که شبکه‌های عصبی کارایی بهتری از سایر روش‌ها دارند. امروزه شبکه‌های عصبی به عنوان ابزاری مناسب برای مدل‌سازی روابط غیرخطی شناخته

کاربری اراضی و قابلیت اراضی به واحدهای کاری مجزایی تفکیک شده است (۷). برای این کار در محیط نرم‌افزار آرک ویو با استفاده از نقشه‌های توپوگرافی (۱:۵۰۰۰۰)، زمین‌شناسی (۱:۱۰۰۰۰۰)، کاربری اراضی (۱:۲۵۰۰۰۰) و منابع و قابلیت اراضی (۱:۲۵۰۰۰۰) واحد کاری ایجاد شده است. در هر واحد کاری به صورت تصادفی نظارت شده، با درنظر گرفتن سطح هر واحد نمونه برداری صورت گرفت، که در کل منطقه، ۱۲۰ نمونه در ۳ تکرار برداشت گردید. نمونه برداری از افق‌های رویین و زیرین خاک از اوایل تیرماه تا اواخر مهرماه ۱۳۸۶ صورت گرفته است.

ویژگی‌های خاک

توزیع اندازه ذرات خاک به روش هیدرومتری (۶)، درصد سنگریزه خاک به روش حجمی و با استفاده از الک، درصد رطوبت خاک به روش وزنی، چگالی ظاهری به روش سیلندرهای نمونه‌گیری، مقدار کربن آلی خاک به روش والکلی و بلاک (۲۶) و مقدار کربنات کلسیم معادل خاک با استفاده از روش تیتراسیون برگشته (۱۵) اندازه گیری شدند. هدایت هیدرولیکی اشباع به روش تک سیلندر اندازه گیری شده است (۲۲).

مشخصه‌های پستی و بلندی و پوشش گیاهی

با استفاده از نقشه مدل‌های رقومی ارتفاع ۱۰ در ۱۰ متر (۲)، مشخصه‌های پستی و بلندی نظری شیب، جهت شیب و ارتفاع نقاط موردنظر اندازه گیری شدند. برای ارزیابی پوشش گیاهی از شاخص پوشش گیاهی (Normalized Difference Vegetation Index: NDVI) استفاده شده است (۱۰).

روش‌های مدل‌سازی توابع انتقالی خاک

برای ایجاد توابع انتقالی و پیش‌بینی مکانی خاک از روش رگرسیون چندمتغیره خطی و شبکه‌های عصبی مصنوعی استفاده گردید. برای این کار با استفاده از نرم‌افزار آماری SAS (۲۲) و Neurosolutions ۵ (۱۷)، توابع انتقالی و پیش‌بینی مکانی

می‌باشد که به عنوان ویژگی‌های زود یافت به همراه ویژگی‌های خاک مورد استفاده قرار گیرند. اهداف انجام این پژوهش عبارتند از:

الف- مدل‌سازی توابع انتقالی خاک با استفاده از روش‌های رگرسیونی و شبکه‌های عصبی مصنوعی برای تخمین هدایت هیدرولیکی اشباع خاک.

ب- ارزیابی کارایی روش‌های به کار گرفته شده در مدل‌سازی توابع انتقالی خاک با کارگیری شاخص‌های پوشش گیاهی و توپوگرافیکی و ویژگی‌های خاک رویین و زیرین به عنوان متغیرهای زود یافت.

ج- ارزیابی کارایی توابع انتقالی حاصل از روش‌ها و داده‌های زود یافت ذکر شده در برآورد هدایت هیدرولیکی اشباع خاک.

مواد و روش‌ها

منطقه مورد مطالعه بخشی از مراتع زاگرس مرکزی با موقعیت ۴۰° ۳۲۰ شمالي و ۱۲° ۲۷' ۵۰" تا ۴۳° ۳۵" شرقی و ۳۲° ۳۲" تا ۳۳° ۶۰" کیلومترمربع است که متوسط حداقل و حداکثر بلند مدت بارندگی و درجه حرارت در این منطقه به ترتیب ۵-۱۲ درجه سلسیوس می‌باشد. ارتفاع منطقه بین ۲۱۰۰ تا ۳۱۰۰ متر بالاتر از سطح دریا است، بنابراین توپوگرافی منطقه، کوهستانی می‌باشد. جهت شیب غالب، منطقه شمال شرقی و شمال و ۹۰ درصد از منطقه شیبی بیش از ۱۵ درصد دارد. کاربری اراضی غالب منطقه، مرتع و مرتع تخریب شده (۷۲ درصد از مساحت) با ۱۳ درصد اراضی کشاورزی و ۱۵ درصد صخره می‌باشد. زمین‌شناسی غالب منطقه نهشته‌های تراس‌های قدیمی غنی شده از گچ و سنگ آهک با هوازدگی و فرسایش پذیری متوسط است (۱). بافت خاک منطقه شامل لوم شنی، سیلت رسی لومی، رس سیلتی، لوم سیلتی، لوم، لوم شنی، لوم رسی و رسی می‌باشد.

روش نمونه برداری

این منطقه براساس ویژگی‌های توپوگرافیکی، زمین‌شناسی،

جدول ۱. ساختارهای متفاوت شبکه عصبی پرسپترون (۱۶)

شبکه عصبی	شرح	کاربرد و مزايا
پرسپترون چند لایه استاندارد (MLP)	معمول‌ترین شبکه عصبی مورد استفاده	گروه‌بندی عمومی یا رگرسیون
پرسپترون چند لایه پیشخور عمومی (GFF)	پرسپترون چند لایه استاندارد با یک لایه ارتباطی اضافی	قدرت محاسبه‌های اضافی در مقایسه با پرسپترون چند لایه استاندارد
پرسپترون چند لایه پیشخور مدولار (MNN)	دارای چندین شبکه MLP موازی که خروجی واحدی دارد	تعداد وزن‌های بین لایه‌ها در مقایسه با پرسپترون چند لایه استاندارد کم‌تر می‌باشد و دارای سرعت بالاتری است ولی دقت کم‌تری دارد

زود یافت انجام گرفت (۱۷).

در این پژوهش سه مدل رگرسیونی و سه مدل شبکه عصبی مورد بررسی قرار گرفت و در ابتدا سه گروه از متغیرهای زود یافت برای مدل‌های تجزیه رگرسیون چندمتغیره خطی (جدول ۲) انتخاب گردید. متغیرهای زود یافت مدل ۱ صرفاً براساس ویژگی‌های افق رویین خاک شامل توزیع اندازه ذرات، کربن آلی، کربنات کلسیم معادل، چگالی ظاهری و درصد سنگریزه خاک بودند. در مدل ۲ علاوه بر ویژگی‌های افق رویین خاک از ویژگی‌های افق زیرین نیز استفاده شده است. در نهایت در مدل ۳ از ویژگی‌های پستی و بلندی و شاخص پوشش گیاهی به همراه ویژگی‌های افق رویین خاک استفاده گردید. متغیرهایی که با تحلیل حساسیت به روش در حدود متوسط با استفاده از نرم‌افزار ۵ Neurosolutions برای هر یک از مدل‌های رگرسیونی ۱ تا ۳ گزینش می‌شوند، به ترتیب برای مدل‌های ۱ تا ۳ شبکه عصبی مورد استفاده قرار می‌گیرند.

آزمون شبکه‌های عصبی مصنوعی

موقعی که شبکه‌های عصبی مصنوعی مورد آزمون قرار می‌گیرند در واقع، توانایی شبکه عصبی مصنوعی در تعییم‌سازی، مورد آزمایش قرار گرفته است. برای آزمون شبکه‌های عصبی از روش اعتبارسازی نمونه‌های تقسیم شده (Split sample validation) استفاده شد (۵). در روش اعتبارسازی نمونه‌های

هدايت هیدروليكى اشبع خاک ايجاد گردید. در اين پژوهش سه مدل از داده‌های زود یافت و سه ساختار شبکه عصبی پرسپترون مورد بررسی قرار گرفته‌اند. ساختارهای مختلف شبکه عصبی پرسپترون شامل پرسپترون چند لایه استاندارد (Multilayer Perceptron: MLP)، شبکه پیشخور عمومی (Generalized Feed Forward: GFF) و شبکه عصبی مدولار (Modular Neural Network: MNN) می‌باشند (جدول ۱).

تعداد نرون، اندازه گام و مقدار ممتومن به وسیله روش سعی و خطأ تعیین شده‌اند. براین اساس، کمترین تعداد نرونی که عملکرد رضایت‌بخشی حاصل نمایند، انتخاب می‌شود (قضاؤت بر اساس کارایی شبکه). برای نرمال‌کردن داده‌ها از رابطه زیر استفاده شد (۱۱):

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad [1]$$

که در آن: X_n بیان گر داده‌های نرمال شده، X معرف داده‌های مشاهده‌ای و X_{\max} و X_{\min} به ترتیب بیان گر داده‌های مشاهده‌ای حداقل و حداقل می‌باشند. این رابطه، داده‌ها را در بازه $[0/9]$ و $[0/1]$ تبدیل می‌کند. ماکریم ۱۰۰۰۰ دور (اچ) در نظر گرفته شده است و توقف زودهنگام در حین آموزش به وسیله اعتبارسازی انجام گردید. تحلیل حساسیت به روش حساسیت در حدود متوسط (Sensitivity about mean) با استفاده از نرم‌افزار ۵ Neurosolution برای هر یک از مدل‌های داده‌های

جدول ۲. ویژگی‌های زود یافته مورد استفاده در شبکه‌های عصبی مصنوعی و رگرسیون چندمتغیره خطی (مدل‌های ۱ تا ۳)

مدل	شماره	متغیرها
رگرسیونی	۱	ویژگی‌های لایه رویین خاک: توزیع اندازه ذرات، مقدار کربن آلی، چگالی ظاهری، مقدار کربنات کلسیم معادل و درصد سنگریزه خاک
شبکه عصبی	۲	ویژگی‌های لایه رویین و زیرین خاک: توزیع اندازه ذرات، مقدار کربن آلی، چگالی ظاهری، مقدار کربنات کلسیم معادل و درصد سنگریزه
شبکه عصبی	۱	شیب، جهت شیب، ارتفاع و NDVI به همراه ویژگی‌های فیزیکی لایه رویین خاک
شبکه عصبی	۲	ویژگی‌های لایه رویین خاک: درصد شن، مقدار کربن آلی، چگالی ظاهری، مقدار کربنات کلسیم معادل و درصد سنگریزه
NDVI	۳	درصد شن لایه رویین و زیرین، مقدار کربن آلی و کربنات کلسیم معادل لایه رویین و چگالی ظاهری خاک و درصد سنگریزه
NDVI	۳	درصد شن و کربن آلی لایه رویین، چگالی ظاهری، درصد سنگریزه، ارتفاع، شیب، جهت شیب و

که در آن n تعداد نمونه‌ها، y و \hat{y} به ترتیب مقادیر اندازه‌گیری و برآورده شده، s واریانس مقادیر اندازه‌گیری شده و e مقدار خطای حاصل از تفاضل مقادیر اندازه‌گیری و برآورده شده می‌باشدند.

هم‌چنین تجزیه واریانس داده‌ها به وسیله نرم‌افزار آماری SAS برای تعیین معنی‌دار بودن تفاوت بین ساختارهای شبکه عصبی پرسپترون، شبکه عصبی و رگرسیون و مدل‌های مختلف در پیش‌بینی هدایت هیدرولیکی اشباع خاک انجام گرفت (۲۲).

نتایج و بحث

ویژگی‌های خاک منطقه مورد بررسی که برای ایجاد توابع انتقالی و پیش‌بینی مکانی خاک به کار رفته‌اند، در جدول ۳ آورده شده‌اند. با انجام تحلیل حساسیت شبکه عصبی به روش تحلیل حساسیت درحدود میانگین برای سه گروه از داده‌ها، پارامترهای حساس هر گروه مشخص گردید. این پارامترهای حساس به صورت سه مدل شامل، مدل‌های ۱، ۲ و ۳ (جدول ۲) برای برآورده هدایت هیدرولیکی اشباع افق رویین خاک با استفاده از ساختارهای مختلف شبکه عصبی به کار برده شدند (جدول ۲).

تقسیم شده، ۶۶ (۰۰ درصد اعتبارسازی) و ۳۴ درصد داده‌ها به ترتیب برای آموزش و آزمون انتخاب شدند. این روش معمولی‌ترین روش برای تخمین خطای تعمیم‌سازی در شبکه‌های عصبی مصنوعی می‌باشد که در آن داده‌ها به دو بخش آموزش و آزمون تقسیم می‌شوند و از داده‌های آزمون در فرایند آموزش استفاده نمی‌شود. پس از آموزش شبکه عصبی، داده‌های آزمون به وسیله شبکه آموزش‌دیده تحلیل می‌شود و خطای داده‌های آزمون به دست می‌آید.

شاخص‌های ارزیابی

از ضریب همبستگی اسپیرمن (r)، میانگین مربعات خطای نرمال شده (Normalized Mean Square Error, NMSE) و میانگین خطای مطلق (Mean Absolute Error, MAE) برای بررسی کارایی مدل‌های مختلف استفاده شد که فرمول شاخص‌های فوق به قرار زیر می‌باشد (۲۷):

$$NMSE = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2}{s^2} \quad [2]$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| = \frac{1}{n} \sum_{i=1}^n |e_i| \quad [3]$$

جدول ۳. محاسبه‌های آماری ویژگی‌های خاک و هدایت هیدرولیکی اشایع خاک برای داده‌های آموزش و آزمون (شبکه عصبی مصنوعی) و
واسنجی و اعتبارسازی (رگرسیون چندمتغیره خطی) برای ایجاد توابع انتقالی و توابع پیش‌بینی مکانی خاک

متغیر	داده‌های آموزشی یا واسنجی						داده‌های آزمون یا اعتبارسازی					
	داده‌های آزمون یا اعتبارسازی			داده‌های آموزشی یا واسنجی			داده‌های آزمون یا اعتبارسازی			داده‌های آموزشی یا واسنجی		
حداکثر	حداقل	انحراف معیار	حداکثر	حداقل	انحراف معیار	حداکثر	حداقل	انحراف معیار	حداکثر	حداقل	انحراف معیار	
۱۲۶۸	۱۵۹/۲۵	۳۰۱/۵۰	۵۵۳/۸۰	۱۲۹۶	۱۴۴	۲۶۶/۵	۵۳۸/۷	(سانتی‌متر در روز) K_s				
۴۰/۳۱	۱۱/۴۳	۷/۸۴	۲۴۳/۶	۴۷/۸۳	۱۰/۱۵	۶/۹۰	۲۶/۴۷	درصد شن A				
۵۷/۱۴	۲۲/۳۹	۸/۱۵	۴۴/۷۷	۶۰/۸	۲۸/۶۶	۷/۳۷	۴۶/۷۰	درصد سیلت A				
۱/۷۱	۰/۱۵	۰/۳۹	۰/۷۴	۲/۰۱	۰/۰۷	۰/۳۸	۰/۸۶	درصد کربن آلی A				
۱/۶۲	۱/۱۱	۰/۱۰	۱/۳۳	۱/۶۳	۱/۰۱	۰/۱۲	۱/۳	چگالی ظاهری (گرم بر سانتی‌متر مکعب)				
۵۵	۰/۵	۱۲/۵۳	۱۴/۶	۶۵	۱	۱۲	۱۶/۸۵	درصد کربنات کلسیم معادل A				
۵۸/۸۳	۷/۳۱	۱۱/۵۶	۳۱/۱۳	۵۱/۵۰	۴/۰۱	۹/۸۷	۲۹/۷۹	درصد شن B				
۷۴/۸۷	۱۹/۵۶	۱۰/۹۶	۴۳/۲۳	۸۲/۳۱	۲۵/۶۵	۸/۶۲	۴۳/۹۱	درصد سیلت B				
۱/۱۸	۰/۱	۰/۲	۰/۶۷	۱/۳۱	۰/۰۷	۰/۲۵	۰/۷	درصد کربن آلی B				
۵۸	۱	۱۰/۹۹	۱۴/۶۵	۵۷	۰/۵	۱۱/۳۹	۱۷/۳۴	درصد کربنات کلسیم معادل B				
۲۳/۴	۰/۲۳	۵/۹۳	۸/۸۵	۲۳/۸	۰/۷۴	۵/۵۸	۸/۷۹	درصد سنگریزه				
۲۶۸۰	۲۰۹۰	۱۲۲/۶	۲۲۶۴	۲۸۶۰	۲۱۰۴	۱۳۶	۲۳۸۶	ارتفاع (متر)				
۵۱/۴۸	۰	۹/۸۶	۱۰/۹۲	۷۲/۶۹	۰	۱۱/۲۸	۱۲/۰۸	درصد شیب				
۳۵۴/۵۶	۰	۱۲۰/۹۸	۱۷۷/۱۹	۳۵۱/۸	۰	۱۱۹/۱	۱۳۲/۷	جهت شیب (درجه)				
۰/۳۴	۰	۰/۰۴	.۷/۲۳	۰/۳۶	۰	۰/۰۴	۰/۲۷	NDVI				

A: افق رویین خاک B: افق زیرین خاک

در کارایی مدل ایجاد می‌کند. تغییر تعداد نرون از ۲ تا ۱۱ نشان

می‌دهد که شبکه‌های عصبی مسئله را با تعداد نرون بیشتر از ۵ نرون به خوبی یاد می‌گیرند، زیرا متوسط MSE نهایی به مقادیر یکسانی همگرا می‌گردد.

همین‌طور اندازه گام بین ۰/۳ تا ۰/۸ در شبکه عصبی GFF و بین ۰/۶ تا ۰/۹ در شبکه عصبی MNN متغیر می‌باشد، که این اندازه گام کمک به پیداکردن حداقل‌های نسبی و نهایی می‌نماید. میزان ممتومن در شبکه عصبی GFF و MNN بین ۱ تا ۱/۳ متغیر می‌باشد، که با این اندازه ممتومن شبکه قادر به پیداکردن حداقل نسبی و نهایی است.

تعیین پارامترهای مناسب شبکه عصبی

نتایج تعیین مقادیر بهینه پارامترهای شبکه عصبی مصنوعی شامل تعداد نرون لایه پنهان، اندازه گام در سطح خطأ و ممتومن نشان داد که شبکه عصبی GFF نمی‌تواند مسئله را با تعداد نرون کمتر از ۵، در لایه پنهان یاد بگیرد. وقتی تعداد نرون‌ها به بیش از ۴ نرون بر سرد منجر به بهبود معنی دار مینیمم MSE می‌شود. ولی افزایش تعداد نرون به ۱۰ و ۱۱ اصلاح کمی در کارایی مدل ایجاد می‌کند.

شبکه عصبی MNN مسئله را با تعداد نرون بیشتر از ۷ در لایه پنهان یاد می‌گیرد و افزایش تعداد نرون به ۱۱ اصلاح کمی


پوشش گیاهی بر ویژگی‌های خاک مانند توزیع اندازه ذرات و ساختمان خاک می‌باشد که این ویژگی‌ها تأثیر به سزایی روی منافذ درشت خاک دارند (۲۵) و منافذ درشت خاک رابطه مستقیمی با K_s دارد (۱۳). نوابیان و همکاران (۳) با استفاده از رگرسیون چندمتغیره نشان دادند که ویژگی‌های زود یافته (میانگین هندسی قطر ذرات و انحراف معیار هندسی) که همبستگی بیشتری با ساختمان خاک داشته باشند، هدایت هیدرولیکی را بهتر برآورد می‌کنند. به استثناء مدل یک، در دیگر مدل‌ها، شبکه عصبی MNN دارای ضریب همبستگی کمتری در مقایسه با شبکه‌های دیگر بود و بیشترین ضریب همبستگی برای هدایت هیدرولیکی اشباع خاک به وسیله شبکه عصبی MLP به دست آمد. شبکه عصبی GFF با داشتن یک لایه اضافی کارایی بهتری از خود نسبت به شبکه MNN نشان داده است اگرچه شبکه عصبی MLP با بالاترین ضریب همبستگی و پایین‌ترین خطای کاراترین شبکه در برآورد K_s می‌باشد. با وجود این که شبکه MNN دارای سرعت بیشتری در تخمین K_s نسبت به سایر شبکه‌ها می‌باشد ولی از کارایی و دقیق‌تری برخوردار است (شکل ۱). NMSE و MAE (جدول ۴) همان روند ضریب همبستگی را نشان می‌دهند، به طوری که کمترین NMSE و MAE با بیشترین ضریب همبستگی هم‌خوانی دارد. استفاده از ویژگی‌های پستی و بلندی و شاخص پوشش گیاهی باعث افزایش ضریب همبستگی برای تخمین K_s گردیده است. بنابراین استفاده از این مدل می‌تواند باعث بهبود کارائی تخمین K_s در مراتع زاگرس مرکزی در مقیاس حوزه آبخیز گردد. اطلاعات لازم برای این مدل می‌تواند از داده‌های سنجش از دور و سامانه اطلاعات جغرافیایی به دست آید. شرما و همکاران (۲۴) نیز از ویژگی‌های پستی و بلندی و شاخص پوشش گیاهی برای ایجاد PTFs به وسیله ANNs برای تخمین منحنی مشخصه رطوبتی خاک استفاده کردند. نتایج نشان می‌دهد که، ویژگی‌های پستی و بلندی و NDVI باعث بهبود کارایی PTFs شده‌اند.

پیش‌بینی هدایت هیدرولیکی اشباع خاک با استفاده از شبکه عصبی

برای پیش‌بینی هدایت هیدرولیکی اشباع خاک با استفاده از شبکه عصبی، ساختارهای مختلف شبکه عصبی پرسپترون مورد ارزیابی قرار گرفت. برای این کار داده‌های مورد نظر به دو بخش جداگانه آموزش یا واسنجی و آزمون یا اعتبارسازی تقسیم شده‌اند (جدول ۳). در همه فرآیندهای آموزشی به طور خودکار بهترین وزن‌ها در حداقل خطای اعتبارسازی (در صورت در نظر گرفتن بخشی از داده‌ها برای اعتبارسازی) یا حداقل خطای آموزشی (در صورت در نظر نگرفتن بخشی از داده‌ها برای اعتبارسازی) ذخیره گردیده‌اند.

برخلاف سیستم خطی، شبکه‌های عصبی با یک سری داده‌های مشخص با اعمال وزن‌های اولیه مختلف می‌توانند به جواب‌های متفاوتی برسند. برای رسیدن به MSE نهایی، مدل‌های شبکه عصبی چندین بار آموزش یافته‌ند. برای به دست آوردن شبکه عصبی مناسب، ساختارهای مختلف شبکه عصبی پرسپترون مورد ارزیابی قرار گرفت. ضریب همبستگی بین مقادیر اندازه‌گیری شده و پیش‌بینی شده K_s به وسیله ساختارهای مختلف شبکه عصبی پرسپترون در جدول ۴ نشان داده شده است.

با کاربرد ویژگی‌های لایه روین خاک (مدل ۱) به عنوان ویژگی‌های زود یافت در مقایسه با سایر مدل‌ها ضریب همبستگی کمتری به دست آمد. ضریب همبستگی از مدل ۱ به طرف مدل ۳ برای همه ساختارهای شبکه عصبی افزایش یافته است. افزودن ویژگی‌های افق زیرین خاک به ویژگی‌های روین خاک باعث افزایش ضریب همبستگی در همه ساختارهای شبکه‌های عصبی گردید. این نشان می‌دهد که K_s متأثر از ویژگی‌های افق زیرین خاک می‌باشد. با ترکیب ویژگی‌های پستی و بلندی و شاخص پوشش گیاهی به همراه ویژگی‌های افق روین خاک بالاترین ضریب همبستگی برای همه ساختارها ایجاد شد. این موضوع نشان دهنده اثر شیب، جهت شیب و



شکل ۱. مقایسه هدایت هیدرولیکی اشباع خاک اندازه‌گیری شده و تخمین زده برای سه مدل: مدل ۱ (ویژگی‌های لایه رویین خاک: درصد شن و سیلت، مقدار کربن آلی، چگالی ظاهری و مقدار کربنات کلسیم)، مدل ۲ (درصد شن لایه رویین و زیرین، مقدار کربن آلی و کربنات کلسیم لایه رویین و چگالی ظاهری خاک) و مدل ۳ (درصد شن و کربن آلی لایه رویین، چگالی ظاهری، ارتفاع، شب، جهت شیب و NDVI). نتایج پرسپترون چند لایه پیشخور عمومی (GFF) در سمت چپ و پرسپترون چند لایه پیشخور مدلار (MNN) در سمت راست نشان داده شده‌اند

جدول ۴. برآورد شبکه‌های عصبی مصنوعی در پیش‌بینی هدایت هیدرولیکی اشباع خاک

NMSE	MAE	r	شبکه‌های عصبی مصنوعی	مدل
۰/۶۴۸	۰/۱۱	۰/۶۲	GFF	مدل ۱
۰/۶۴۱	۰/۱۱۵	۰/۶۲	MLP	
۰/۸۸	۰/۱۳	۰/۶۲	MNN	
۰/۵۶	۰/۱۰	۰/۶۹	GFF	
۰/۵۵	۰/۱۰	۰/۶۹	MLP	مدل ۲
۰/۸۸	۰/۱۳	۰/۶۳	MNN	
۰/۴۲	۰/۰۹۲	۰/۷۸	GFF	
۰/۳۷	۰/۰۸۷	۰/۸۱	MLP	
۰/۸۴	۰/۱۲	۰/۶۴	MNN	مدل ۳

GFF: پرسپترون چند لایه پیشخور عمومی، MLP: پرسپترون چند لایه استاندارد، MNN: پرسپترون چند لایه پیشخور مدولار

جدول ۵. مدل‌های رگرسیونی برای پیش‌بینی هدایت هیدرولیکی اشباع خاک

متغیرها	مدل ۱	مدل ۲	مدل ۳
عرض از مبدأ	-۰/۶۷	-۰/۶۹	-۰/۶۴
درصد شن A	۰/۰۰۴۱	۰/۰۰۲۹	۰/۰۰۲
درصد سیلت A			
درصد کربن آلی A	۰/۱۰۸	۰/۰۸۹	۰/۰۶۴
درصد سنگریزه	۰/۰۱۱	۰/۰۰۹	۰/۰۰۸
چگالی ظاهری (گرم بر سانتی متر مکعب)			
درصد کربنات کلسیم معادل A	۰/۰۰۳۸	۰/۰۰۳	۰/۰۰۲۷
درصد شن لایه B		۰/۰۰۳۴	
درصد سیلت لایه B			
درصد کربن آلی B			
NDVI			۰/۶۶۷
ارتفاع (متر)		۰/۰۰۰۱۸	
درصد شیب		۰/۰۰۰۳۴	
جهت شیب (درجه)		۰/۰۰۰۴۲	
r	۰/۰۵	۰/۰۵۹	۰/۶۹

A: افق رویین خاک B: افق زیرین خاک

چندمتغیره خطی به ترتیب در جداول‌های ۴ و ۵ آورده شده است. اختلاف کارایی شبکه‌های عصبی مصنوعی GFF و MLP با رگرسیون چندمتغیره در پیش‌بینی K_s معنی‌دار (در سطح ۵

مقایسه شبکه‌های عصبی مصنوعی و رگرسیون خطی برای برآورد هدایت هیدرولیکی اشباع خاک تخمین به وسیله شبکه‌های عصبی مصنوعی و رگرسیون

نتیجه‌گیری

مشخصه‌های پستی و بلندی و شاخص پوشش گیاهی NDVI به عنوان عوامل مؤثر در تخمین هدایت هیدرولیکی اشباع خاک شناخته شده‌اند، بنابراین کاربرد مشخصه‌های پستی و بلندی و شاخص پوشش گیاهی به همراه ویژگی‌های افق رویین خاک باعث بهبود کارایی PTFs گردید. توابع انتقالی ایجاد شده بر اساس شبکه عصبی MLP بهتر از سایر PTFs (رگرسیونی و شبکه عصبی)، هدایت هیدرولیکی اشباع خاک را پیش‌بینی نمود و به طور معنی‌داری دقت تخمین را بهبود بخشید. به طور کلی، کارایی شبکه‌های عصبی بهتر از رگرسیون چندمتغیره خطی می‌باشد.

درصد) می‌باشد. در حالی که تفاوت شبکه عصبی MNN با رگرسیون معنی‌دار نیست. تفاوت بین شبکه عصبی GFF و MLP با MNN در سطح ۵ درصد معنی‌دار بود، ولی تفاوت معنی‌داری بین GFF و MLP وجود ندارد. پاچپسکی و همکاران (۱۷) با مقایسه شبکه عصبی پرسپترون و رگرسیون چندمتغیره به این نتیجه رسیدند که به طور کلی کارایی شبکه‌های عصبی در تخمین ویژگی‌های هیدرولیکی خاک، بهتر از رگرسیون چندمتغیره می‌باشد. و هم‌چنین مردون و همکاران (۲) با ارزیابی شبکه عصبی سری سه لایه Cascade Forward Network: CFN) و رگرسیون چندمتغیره برای برآورد K نشان دادند که کارایی شبکه عصبی بهتر از رگرسیون چندمتغیره است ولی تفاوت معنی‌داری بین آنها وجود ندارد.

منابع مورد استفاده

۱. امامی، ن. ۱۳۸۸. نقشه زمین‌شناسی کشور. شهرکرد، ایران.
۲. سازمان نقشه‌برداری کشور. ۲۰۰۶. نقشه مدل‌های رقومی ارتفاع شهرکرد، ایران.
۳. نوابیان، م.، ع. لیاقت و م. همایی. ۱۳۸۲. تخمین هدایت هیدرولیکی اشباع خاک با استفاده از توابع انتقالی، مجله پژوهش مهندسی کشاورزی ۴(۱۶): ۱-۱۲.
4. Dawson, C. W. and R. L. Wilby. 2001. Hydrological modeling using artificial neural networks. *Prog. Phys. Geogr.* 25: 80-108.
5. Efron, B. and R. J. Tibshirani. 1993. An Introduction to the Bootstrap. Monographs on Statistics and Applied Probability. Chapman and Hall., New York.
6. Gee, G. W., and J. W. Bauder. 1986. Particle size analysis. PP. 383-411. In: Methods of soil analysis. 2nd ed., Klute, A. (eds). Agron. Monogr. 9. ASA. Madision. WI.
7. Gunn, R. H. and J. M. Aldrick. 1988. Australian Soil and Land Survey Handbook: Guidelines for Conducting Surveys. Inkata Press, Melbourne.
8. Gupta, S. C. and W. E. Larson. 1979. Estimating soil water characteristic from particle size distribution, organic matter percent, and bulk density. *Water Resour. Res.* 15: 1633-1635.
9. Leij, F. J., N. Romano., M. Palladino and M. G. Schaap. 2004. Topographical attributes to predict soil hydraulic properties along a hillslope transect. *Water Resour. Res.* 40: 1-15.
10. Lillesand, T. M. and W. Keifer. 1994. Remote Sensing and Image Interpretation, John Wiley & Sons, New York.
11. Maier, H. R. and Dandy, G. C. 2000. Application of artificial neural networks to forecasting of surface water quality variables: Issues, applications and challenges. In: Artificial neural networks in hydrology. PP: 287-309. Govindaraju, R.S. and A. Ramachandra Rao (Eds). Kluwer academic publishers, the Netherlands.
12. Merdun, H., Cinar, O., Meral, R. and Apan, M. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil Till Res.* 90: 108-116.

13. Minasny, B., A. B. McBratney and K. L. Bristow. 1999. Comparison of different approaches to the development of pedotransfer functions for water retention curves. *Geoderma*, 93: 225-253.
14. Mohanty, B. P. and T. H. Skaggs. 2001. Spatio-temporal evolution and time-stable characteristic of soil moisture within remote sensing footprints with varying soil, slope, and vegetation. *Adv. Water Res.* 24: 1051-1067.
15. Nelson, R. E. 1982. Carbonate and gypsum. PP. 181-199. In: A.L. Page (Eds.), *Methods of Soil Analysis*, part 2. American Society of Agronomy, Madison. WI.
16. NeuroSolutions TM 5.0. NeuroDimension INC, 3701 NW 40th Terrace Fl 3260 www. nd. com,. 2005.
17. Pachepsky, Ya., D. J. Timlin and G. Varallyay. 1996. Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Sci. Soc. Am. J.* 60:727-773.
18. Pachepsky, Ya., D. J. Timlin and W. J. Rawls. 2001. Soil water retention as related to topographic variables. *Soil Sci. Soc. Am. J.* 65: 1787-1795.
19. Principe, J. C., N. R. Euliano and W. C. Lefebvre. 2000. *Neural and Adaptive Systems: Fundamentals Through Simulations*. John Wiley & Sons, NewYork.
20. Rawls, W. J., T. J. Gish and D. L. Brakensiek. 1991. Estimating soil water retention from soil physical properties and characteristics. *Adv. Soil Sci.* 9: 213-234.
21. Reynolds, W. D. and D. E. Elrick. 1990. Ponded infiltration from a single ring. I. Analysis of steady flow. *Soil Sci. Soc. Am. J.* 54: 1233-1241.
22. SAS Institute Inc. 1999. *SAS/STAT User's Guide*. Ver. 8.0. SAS Institute Inc., Cary, NC.
23. Schaap, M. G. and W. Bouten. 1996. Modeling water retention curves of sandy soils using neural networks. *Water Resour. Res.* 32: 3033-3040.
24. Sharma, S. K., B. P. Mohanty and J. Zhu. 2006. Including topography and vegetation attributes for developing pedotransfer functions. *Soil Sci. Soc. Am. J.* 70: 1430-1440.
25. Tietje, O. and V. Hennings. 1996. Accuracy of the saturated hydraulic conductivity prediction by pedo-transfer functions compared to the variability within FAO textural classes. *Geoderma* 69: 71-84.
26. Walkly, A., and Black, I.A. 1934. An examination of digestion method for determining soil organic matter and proposed modification of the chromic acid titration. *Soil Sci.* 37: 29-38.
27. Wosten, J. H. M., Ya. A. Pachepsky and W. J. Rawls. 2001. Pedotransfer functions: Bridging the gap between available basic soil data and missing soil hydraulic characteristics. *J. Hydrol.* 251: 123-150.