

کاربرد شبکه عصبی مصنوعی در پیش‌بینی هدایت هیدرولیکی اشباع با استفاده از پارامترهای فیزیکی خاک

بهزاد قبریان علویجه^{*}, عبدالمجید لیاقت و سمانه سهرابی*

* نگارنده مسئول: نشانی: کرج، پردیس کشاورزی و منابع طبیعی دانشگاه تهران، ص. پ. ۴۱۱، تلفن: ۰۲۶۱ ۲۲۴۱۱۱۹، پیامنگار: b.ghanbarian@gmail.com

** به ترتیب دانشجوی دکتری؛ دانشیار گروه آبیاری و آبادانی دانشکده آب و خاک پردیس کشاورزی و منابع طبیعی دانشگاه تهران؛ و دانشجوی کارشناسی ارشد گروه مهندسی آب دانشکده کشاورزی دانشگاه تبریز
تاریخ دریافت مقاله: ۱۳/۷/۷؛ تاریخ پذیرش: ۱۷/۱۲/۸

چکیده

ویژگی‌های هیدرولیکی خاک همچون هدایت هیدرولیکی اشباع و غیراشباع در مطالعات زیست محیطی نقش مهمی را ایفا می‌نمایند. از آنجائی که اندازه‌گیری مستقیم این قبیل ویژگی‌های هیدرولیکی خاک امری وقت‌گیر و هزینه‌بر است روش‌های غیرمستقیمی چون توابع انتقالی و شبکه‌های عصبی مصنوعی بر مبنای پارامترهای سهل الوصول خاک توسعه یافته‌اند. در این خصوص در این مطالعه، از شبکه عصبی مصنوعی به منظور تخمین هدایت هیدرولیکی اشباع خاک با استفاده از داده‌های اندازه‌گیری شده منحنی مشخصه رطوبتی خاک و جرم مخصوصه ظاهری استفاده شده است. با استفاده از داده‌های اندازه‌گیری شده جرم مخصوصه ظاهری خاک، بعد فرکتالی منحنی مشخصه رطوبتی، مکش در نقطه ورود هوا، تخلخل مؤثر، مقادیر هدایت هیدرولیکی اشباع خاک با استفاده از شبکه عصبی مصنوعی تخمین زده شدند. در مرحله آموزش مدل از ۱۱۴ داده اندازه‌گیری شده منحنی مشخصه رطوبتی و جرم مخصوصه ظاهری خاک و در مرحله آزمون از ۲۸ داده باقیمانده استفاده شد. مقادیر MSE و R^2 در مرحله آزمون مدل شبکه عصبی مصنوعی با چهار پارامتر ورودی به ترتیب $0/0/28/0$ و $0/76$ محاسبه شدند. مقایسه عملکرد مدل شبکه عصبی مصنوعی با دو مدل ارائه شده توسط رائلز و همکاران نشان داد که مدل شبکه عصبی مصنوعی با دقت بالاتری هدایت هیدرولیکی اشباع خاک را پیش‌بینی می‌نماید.

واژه‌های کلیدی

شبکه عصبی مصنوعی، منحنی مشخصه رطوبتی، هدایت هیدرولیکی اشباع

تخمین هدایت هیدرولیکی اشباع به کار رفته است. در مقاله کرییر (Carrier, 2003) به محدودیت‌های استفاده از این رابطه اشاره شده است، از جمله اینکه واکنش‌های الکتروشیمیایی بین ذرات خاک و مولکول‌های آب که در نمونه خاک‌های رسی منجر به پایین آمدن دقت مدل می‌شود، در نظر گرفته نشده است.

آهوجا و همکاران (Ahuja *et al.*, 1984) رابطه کازنی-کارمن را با استفاده از پارامتر تخلخل مؤثر اصلاح کردند و کارایی مدل مذکور را برای محدوده‌ای وسیع از

مقدمه

از روش‌های تخمین هدایت هیدرولیکی اشباع خاک، می‌توان به روش‌های تجربی هزن (Hazen, 1911) و نیمه تجربی کازنی-کارمن (Carman, 1927; Kozeny, 1927; Carman, 1938; Kozeny, 1938)، توابع انتقالی و مدل‌های شبکه عصبی مصنوعی اشاره کرد. رابطه نیمه تجربی کازنی-کارمن (Kozeny, 1927; Carman, 1938; Kozeny, 1938; Carman, 1956) که کازنی (Kozeny, 1927; Carman, 1938; Carman, 1956) ارائه داد و بعدها کارمن (Carman, 1927) آن را اصلاح کرد، به طور وسیع در (Carman, 1938)

ساچالسکی و همکاران (Spychalski *et al.*, 2007) با استفاده از ۳۵ داده اندازه‌گیری شده هدایت هیدرولیکی اشباع و تخلخل مؤثر، ضرائب رابطه آهوجا و همکاران (Ahuja *et al.*, 1984) را اصلاح و برای ۳۱ نمونه دو رابطه غیرخطی بهمنظور تخمین هدایت هیدرولیکی اشباع خاک ارائه دادند. نتایج مقایسه روابط مذکور برای ۱۲۸ نمونه از داده‌های بانک اطلاعاتی UNSODA با توابع انتقالی (Cosby *et al.*, 1984) همچون کاسبای و همکاران (Saxton *et al.*, 1986)، جابرو (Dane & Puckett, 1994) و (Jabro, 1992)، دن و پاکت (Schaap *et al.*, 2001) Rosetta نشان داد که مدل سه جمله‌ای ارائه شده، نسبت به سایر مدل‌ها، دقیق‌تری دارد.

معادلات رگرسیونی که پارامترهای هیدرولیکی دیریافت را با استفاده از اطلاعات موجود خاک تخمین می‌زنند، توابع انتقالی خاک نامیده می‌شوند (Bouma, 1989) که در ارائه آنها از روش‌های رگرسیون‌گیری چندگانه (خطی، غیرخطی) و شبکه‌های عصبی استفاده می‌شود (Navabian *et al.*, 2004). تاکنون توابع انتقالی متعددی به منظور تخمین هدایت هیدرولیکی اشباع خاک ارائه شده‌اند که از جمله می‌توان به تحقیقات برانکسیک و همکاران (Brakensiek *et al.*, 1984)، کمپل (Campbell, 1985)، سکستن و همکاران (Vereecken *et al.*, 1986)، وریکن و همکاران (Wösten, 1997)، وستن (*et al.*, 1990) (Wösten *et al.*, 1998)، وستن و همکاران (Rawls *et al.*, 1998) (Rawls *et al.*, 1999) اشاره کرد. دلیل توسعه این قبیل روش‌ها در بررسی ویژگی‌های هیدرولیکی خاک، تغییرات مکانی و زمانی، وقت‌گیر بودن، و هزینه‌بر بودن اندازه‌گیری‌های مستقیم آزمایشگاهی یا صحرایی است.

در سال‌های اخیر از شبکه‌های عصبی مصنوعی^۱ (ANN) بهمنظور شبیه‌سازی، تشخیص الگو، کلاس‌بندی،

داده‌های جمع‌آوری شده در منطقه جنوبی ایالت متحده، هاوایی، و آریزونا به اثبات رساندند. این محققان، توان ۴ یا ۵ را برای رابطه ارائه شده پیشنهاد کردند و نشان دادند که توان ۵، نسبت به توان ۴، برای مقادیر قیاس شده هدایت هیدرولیکی اشباع به نتایج بهتری منجر می‌شود. در مطالعات مختلف، برای ضرایب B و n (پارامترهای رابطه اصلاح شده کازنی-کارمن) مقادیری متفاوت ارائه شده است. برای مثال، آهوجا و همکاران (Ahuja *et al.*, 1989) پارامترهای B و n را برای ۹ بافت درشت به ترتیب ۰/۰۰۲۹ متر بر ثانیه و ۳/۲۱ را به دست آوردند. فرانز‌میر (Franzmeier, 1991) ایالت ایندیانا این دو رقم را به ترتیب ۰/۰۵ متر بر ثانیه و ۳/۲۵ پیشنهاد کرد.

مسینگ (Messing, 1989) با استفاده از داده‌های اندازه‌گیری شده هدایت هیدرولیکی اشباع خاک، پارامترهای تجربی رابطه آهوجا و همکاران (Ahuja *et al.*, 1984) را بررسی کرد. بدین منظور، داده‌های اندازه‌گیری شده را بر اساس درصد ذرات رس، به چهار گروه ۱۵-۲۵، ۲۵-۴۰، ۴۰-۶۰، و بیشتر از ۶۰ درصد تقسیم‌بندی کرد. نتایج مطالعات نشان داد که ضرایب B و n مقادیری ثابت نیستند و به ترتیب در محدوده ۱۵/۰۰-۹۵/۰۰ تا ۰/۰۰۹۵ متر بر ثانیه و ۱/۷۸ (ریز بافت) تا ۳/۰۱ (درشت بافت) قرار دارند. تیملین و همکاران (Timlin *et al.*, 1996) برای ضرایب B و n به ترتیب مقادیر ۰/۰۰۲۱ و ۳/۲۹ را برای محدوده وسیعی از خاک‌ها گزارش کردند. رائولز و همکاران (Rawls *et al.*, 1982) به ترتیب مقادیر ۰/۰۰۲۸ متر بر ثانیه و ۴ را برای خاک‌هایی با درصد ذرات رس کمتر از ۶۰ درصد و شن کمتر از ۴۰ درصد پیشنهاد کردند. در مطالعه‌ای دیگر، رائولز و همکاران (Rawls *et al.*, 1998) مقدار بعد فرکتالی منحنی مشخصه رطوبتی را برای توان رابطه اصلاح شده کازنی-کارمن و تخمین هدایت هیدرولیکی اشباع پیشنهاد کردند.

پارامتر B و n برای مقادیر $1 > \lambda$ ثابت و به ترتیب برابر با 0.0026 متر بر ثانیه و $2/5$ است. با کاهش مقدار λ از یک تا صفر مقادیر B و n کاهش یافته‌ند. نتایج همچنین نشان داد که پارامتر n با ضریب همبستگی بالای $R^2=0.945$ به پارامتر B وابسته است.

هدف از این مطالعه، ارائه مدل شبکه عصبی مصنوعی به منظور تخمین هدایت هیدرولیکی اشباع خاک با استفاده از پارامترهای فیزیکی خاک مانند جرم مخصوص ظاهری، تخلخل مؤثر، بعد فرکتالی منحنی مشخصه رطوبتی و مکش در نقطه ورود هواست که تاکنون ارائه نشده است.

نتوری

تايلر و ويٽ كرافت (Tyler & Wheatcraft, 1990) مدل فرکتالی زير را به منظور مدل کردن منحنی مشخصه رطوبتی ارائه دادند:

$$\frac{\theta(h)}{\theta_s} = \left(\frac{h}{h_b} \right)^{D-3} \quad (1)$$

كه در آن، D =بعد فرکتالی؛ h_b =مکش در نقطه ورود هوا (کیلوپاسکال)؛ h =پتانسیل ماتریک (کیلوپاسکال)؛ θ_s =روطوت اشباع (سانتی‌متر مکعب بر سانتی‌مترمکعب)، و $\theta(h)=$ روطوت حجمی خاک در پتانسیل ماتریک h است. آهوجا و همکاران (Ahuja et al., 1984) رابطه اصلاح شده کازنی-کارمن را به منظور تخمین هدایت هیدرولیکی اشباع خاک به شکل زير ارائه دادند:

$$K_s = B \Phi_e^n \quad (2)$$

keh در آن، K_s =هدایت هیدرولیکی اشباع خاک (متر بر ثانیه)؛ Φ_e =تخلخل مؤثر؛ B =(متر بر ثانیه)؛ و n ضرائب معادله فوق هستند.

و بهينه‌سازی در علوم مختلف مهندسی به طور گسترده استفاده شده است (Menhaj, 2000). قابلیت‌های مدل شبکه‌های عصبی این مدل را به ابزاری مناسب برای مدلسازی خصوصیات هیدرولیکی خاک تبدیل کرده است (Minasny & McBratney, 2002) (Jain & Kumar, 2006) (Amini et al., 2005) (Doaee et al., 2005) استفاده شده است.

پاراسورامان و همکاران (Parasuraman et al., 2006) در کانادا برای تخمین هدایت هیدرولیکی اشباع خاک از شبکه عصبی مصنوعی در مقیاس مزرعه و مدل شبکه عصبی Rosetta (Schaap et al., 2001) استفاده کردند. نتایج به دست آمده از تحقیقات آنها حاکی از کارایی بیشتر شبکه عصبی مصنوعی است که در مقیاس مزرعه توسعه پیدا کرده بود. این محققان کارایی بیشتر این شبکه عصبی را مربوط به فرایند مرحله آموزش شبکه دانستند که با داده‌های مزرعه انجام شده است در حالی که مدل (Schaap et al., 2001) Rosetta داده‌های عمومی تری دارد.

مردون و همکاران (Merdun et al., 2006) در پژوهشی در ترکیه برای پیش‌بینی هدایت هیدرولیکی اشباع خاک از ۱۹۵ داده زودیافت خاک مانند جرم مخصوص ظاهری، توزیع اندازه‌ای ذرات، و سه کلاس تخلخل استفاده کردند. نتایج آزمون مدل نشان داد که رگرسیون چند متغیره، نسبت به شبکه عصبی مصنوعی، دقیق‌تری دارد.

پاچپسکی و همکاران (Pachepsky et al., 1999) با استفاده از شبکه عصبی مصنوعی پارامترهای مدل اصلاح شده کازنی-کارمن (Ahuja et al., 1984) شامل B و n را از داده‌های منحنی مشخصه رطوبتی همچون مکش در نقطه ورود هوا و شاخص توزیع اندازه خلل و فرج خاک برآورد کردند. نتایج این تحقیق نشان داد که مقدار دو

که در آن، K_s = هدایت هیدرولیکی اشباع (سانتی‌متر بر ساعت)؛ ϕ = تخلخل کل؛ R = ماکریم شعاع خلل و فرج خاک (سانتی‌متر)؛ x = ضریبی که برابر $1/3^3$ در نظر گرفته شده؛ و l پارامتری است که با توجه به مقدار بعد فرکتالی

از رابطه تجربی زیر محاسبه می‌شود:

$$l = 1.86D^{5.34} \quad (6)$$

ماکریم شعاع خلل و فرج (سانتی‌متر) نیز با استفاده از رابطه موسینگی (Alizadeh, 2005) تعیین می‌شود:

$$R = \frac{0.148}{h_b} \quad (7)$$

که در آن، h_b = مکش در نقطه ورود هوا (سانتی‌متر) است.

مواد و روش‌ها

جمع‌آوری و آنالیز داده‌ها

در این مطالعه از سه بانک اطلاعاتی مختلف شامل: بانک اطلاعاتی پاکت و همکاران (Puckett *et al.*, 1985) با ۴۲ نمونه، بانک اطلاعاتی UNSODA (Leij *et al.*, 1996) و بانک اطلاعاتی GRIZZLY (Haverkamp *et al.*, 1997) با ۵۹ نمونه خاک استفاده شد. در مجموع ۱۴۲ نمونه خاک که از نقاط مختلف جغرافیایی و تحت شرایط کشت گوناگون و از افق‌های متفاوت برداشت شده بودند آنالیز شدند. دامنه تغییرات ویژگی‌های اندازه‌گیری شده در جدول ۱ آورده شده‌اند.

تخلخل مؤثر را می‌توان از رابطه زیر محاسبه کرد:

$$\Phi_e = \theta_s - \theta_{FC} \quad (3)$$

که در آن، θ_{FC} = رطوبت در نقطه ظرفیت زراعی مزرعه و معادل درصد رطوبت در مکش ماتریک ۳۳-کیلوپاسکال است. مقدار تخلخل مؤثر، از داده‌های منحنی مشخصه رطوبتی قابل محاسبه است.

رائولز و همکاران (Rawls *et al.*, 1998) استفاده از بعد فرکتالی را به جای پارامتر n در رابطه ۲ پیشنهاد و رابطه مذکور را به شکل زیر اصلاح کردند:

$$K_s = B\Phi_e^D \quad (4)$$

این محققان از رابطه ۴ برای کلاس‌های مختلف خاک در تخمین هدایت هیدرولیکی اشباع خاک استفاده کردند و نشان دادند که رابطه ۴ از دقت بالایی ($R^2=0.92$) برخوردار است. همچنین مقدار ضریب B با استفاده از آنالیز کلاس‌های مختلف بافت خاک برابر با 0.00053 متر بر ثانیه به دست آورده شد.

رابطه دیگری که بر اساس تئوری مارشال (Marshal, 1958) و با استفاده از مدل سنگ فرش سرینسکی به منظور تخمین هدایت هیدرولیکی اشباع خاک توسط رائولز و همکاران (Rawls *et al.*, 1993) اصلاح شد، به شکل زیر است:

$$K_s = 4.41 \times 10^7 \left(\frac{\phi^x}{l^2} \right) R^2 \quad (5)$$

جدول ۱- دامنه تغییرات پارامترهای فیزیکی اندازه‌گیری شده برای ۱۴۲ نمونه خاک موجود در سه بانک اطلاعاتی

پارامتر	دامنه تغییرات
جرم مخصوص ظاهری (گرم بر سانتی‌متر مکعب)	۰/۱۷۶-۱/۹۱
تخلخل مؤثر	۰/۰۰۵-۰/۳۸۷
بعد فرکتالی	۰/۴۱-۲/۹۶۷
مکش در نقطه ورود هوا (سانتی‌متر)	۰/۲-۲۸۶/۴
هدایت هیدرولیکی اشباع (سانتی‌متر بر روز)	۰/۰۱-۳۰۲۴

از لایه خروجی در تکرار k ام از رابطه زیر به دست می‌آید:

$$e_p(k) = t_p(k) - z_p(k) \quad (9)$$

برای یادگیری تعداد رفت و برگشت‌ها^۱ نشان دهنده تعداد تکرارها یا K است. $X_{(k)}$ ام خروجی متناظر با ورودی p متغیر (k) z_p که مجموعه‌ای از زوج‌هاست. با ارائه نمونه‌های مختلفی از ورودی و خروجی به شبکه، تابع خطای زیر حداقل می‌شود:

$$E = \frac{1}{2} \sum_{p=1}^Q e_p^2 \quad (10)$$

در الگوریتم BP، خطای با استفاده از فرایند زیر حداقل می‌شود. اگر شبکه^۲ لایه اتصال کامل با n نرون در لایه مخفی در نظر بگیریم، خروجی نرون^۳ Z_{pk} لایه آخر از رابطه زیر محاسبه می‌شود:

$$Z_{pk} = g(I_{pk}) \quad (11)$$

که در آن،

$$g(I_{pk}) = \frac{1}{1 + e^{-I_{pk}}} \quad (12)$$

بعد فرکتالی منحنی مشخصه رطوبتی و مکش در نقطه ورود هوا برای نمونه‌های مورد مطالعه، از برآش مستقیم مدل تایلر و ویت کرافت (Tyler & Wheatcraft, 1990) به داده‌های اندازه‌گیری شده منحنی مشخصه رطوبتی به دست MATLAB آورده شدند. در این خصوص از نرم افزار (Anon, 2006) و روش بهینه‌سازی غیرخطی حداقل مجدد مربعات خطأ^۴ استفاده شد.

شبکه عصبی

متداول‌ترین شبکه‌ها در پیش‌بینی و حل مسائل غیرخطی در مدل‌های شبکه عصبی مصنوعی، شبکه‌های چند لایه پرسپترون^۵ (MLP) هستند. آموزش این شبکه‌ها با استفاده از الگوریتم پس انتشار خطأ^۶ (BP) صورت می‌پذیرد، یعنی به ازای هر ورودی در مرحله واسنجی باید خروجی متناظر و مناسب آن برای طی روند یادگیری شبکه موجود باشد. تعداد Q زوج داده یادگیری در شبکه BP را می‌توان به شکل زیر نشان داد (Karamooz & Araghinejad, 2005):

$$\{(X_1, t_1), (X_2, t_2), \dots, (X_Q, t_Q)\} \quad (8)$$

که در آن، X =بردار ورودی شبکه؛ و t = خروجی یا پاسخ مطلوب برای آن است. سیگنال خطأ در خروجی نرون i ام

باشد. از آنجا که دامنه تابع سیگموئید شامل کلیه اعداد حقیقی است، در مورد اعداد ورودی به شبکه هیچ محدودیت وجود ندارد. در عین حال برای جلوگیری از اشباع زودهنگام نرون‌ها، ورودی خالص آنها باید در محدوده خطی تابع سیگموئیدی قرار بگیرد که به معنای محدود کردن دامنه تابع سیگموئیدی در بازه $[1 - 1]$ است. مشخصاتی از ANN مانند تعداد نرون‌های لایه میانی، تعیین تعداد رفت و برگشت‌ها، میزان یادگیری، مومنتوم، و سرعت یادگیری به منظور تعیین مقادیر بهینه آنها نیاز به آزمون و خطا دارند.

در این تحقیق، از جعبه ابزار Neural Network نرم‌افزار MATLAB (Anon, 2006) استفاده شد. در این بررسی، ۴ لایه به عنوان ورودی به مدل و ۱ لایه به عنوان خروجی از مدل در نظر گرفته شده است. تعداد داده‌های موجود در هر لایه ۱۴۲ است که ۸۰ درصد اولیه (۱۱۴) داده به عنوان داده‌های آموزشی مدل و ۲۰ درصد باقیمانده (۲۸ داده) به عنوان داده‌های آزمایشی مدل انتخاب و مشخص شدند. همچنین، داده‌های موجود در هر لایه با استفاده از رابطه ۱۷ استاندارد شدند.

$$P^{new} = P^{old} / \max \quad (17)$$

که در آن، P^{new} = داده استاندارد شده؛ P^{old} = داده اولیه؛ و \max ماکریم داده هر لایه است. چهار لایه ورودی آموزشی مشخص شده به عنوان لایه ورودی و ۱ لایه خروجی آموزشی مشخص شده به عنوان لایه خروجی مورد انتظار، به مدل در محیط شبکه عصبی معرفی و تابع فعال‌سازی در لایه میانی و لایه خروجی LOGSIG انتخاب شد. در این حالت، دامنه داده‌های ورودی در بازه $(-\infty, +\infty)$ و دامنه داده‌های خروجی در بازه $(0, +1)$ قرار می‌گیرد. در این مطالعه تعداد رفت و برگشت‌ها برای آموزش شبکه با سعی و خطا انتخاب شد.

برابر با تابع محرک سیگموئیدی است:

$$I_{pk} = \sum_{i=1}^{n_1} W_{ki} Y_{pi} + W_{k0} \quad (18)$$

که در آن، I_{pk} = ورودی جرم‌دار شده به نرون k در لایه آخر برای زوج i ؛ n_1 = تعداد نرون‌های لایه میانی؛ W_{ki} = جرم اتصال نرون مخفی (میانی) i به خروجی k ؛ و W_{k0} = مقدار بایاس نرون k است. Y_{pi} خروجی نرون i لایه مخفی است که از رابطه زیر محاسبه می‌شود:

$$Y_{pi} = g(I_{pi}) \quad (19)$$

در رابطه فوق:

$$I_{pi} = \sum_{j=1}^{n_0} W_{ij} X_{pj} + W_{i0} \quad (20)$$

که در آن، n_0 = تعداد نرون‌های لایه ورودی؛ W_{ij} = جرم اتصال نرون ورودی j به نرون i لایه میانی؛ و W_{i0} = مقدار بایاس نرون i است. جرم‌های شبکه در فرایند آموزش با استفاده از رابطه زیر به روز می‌شوند:

$$\Delta W_{ij} = -\eta \frac{\partial E}{\partial W_{ij}} \quad (21)$$

که در آن، η = میزان یادگیری و بین 0 تا 1 متغیر است. یادگیری نگاشت مفروض، از روی ارائه مجموعه داده‌های یادگیری ورودی- خروجی است و از این رو در انتخاب و نحوه ارائه داده‌ها به شبکه عصبی باید دقت کرد. زیرا در پروسه یادگیری از اطلاعات موجود در نمونه‌های یادگیری جهت فهم و استنتاج نگاشت مفروض و پیاده‌سازی تقریبی آن استفاده می‌شود. از این جهت ترتیب ارائه داده‌های یادگیری به شبکه باید به گونه‌ای باشد که شبکه برای یادگیری همه داده‌ها امکان برابر داشته

$$MR = \frac{\sum_{i=1}^n (P_i - O_i)}{n} \quad (20)$$

$$RSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{O_{ave}}} \quad (21)$$

$$AIC = n \ln(\frac{ESS}{n}) + 2p \quad (22)$$

که در آن، P_i و O_i به ترتیب مقادیر اندازه‌گیری و پیش‌بینی شده؛ n تعداد نقاط اندازه‌گیری؛ O_{ave} متوسط داده‌های اندازه‌گیری شده؛ ESS مجموع مربعات خطاء؛ و p تعداد پارامترهای ورودی مدل است.

ارزیابی مدل

برای ارزیابی مدل شبکه عصبی مصنوعی در مرحله آموزش از دو معیار مجدد مربعات خطاء (MSE) و همبستگی داده‌ها (R^2) (روابط ۱۸ و ۱۹) استفاده شد:

$$R^2 = \frac{\sum_{i=1}^n (O_i - O_{ave})(P_i - P_{ave})}{\sqrt{\sum_{i=1}^n (O_i - O_{ave})^2 \sum_{i=1}^n (P_i - P_{ave})^2}} \quad (18)$$

$$MSE = \frac{\sum_{i=1}^n (O_i - P_i)^2}{n} \quad (19)$$

که در آن، O_i داده اندازه‌گیری شده؛ P_i داده پیش‌بینی شده؛ O_{ave} میانگین داده‌های اندازه‌گیری شده؛ P_{ave} میانگین داده‌های پیش‌بینی شده؛ و n تعداد داده‌ها است. هر چه میزان خطاء (MSE) کمتر و میزان همبستگی داده‌ها (R^2) بیشتر باشد میزان آموزش مدل بهتر است. همچنین، به ازای تغییر تعداد نمونه‌ها در لایه میانی، میزان آموزش شبکه تغییر می‌کند و بدین ترتیب با تغییر تعداد نمونه‌ای لایه میانی، بهترین حالت آموزش شبکه انتخاب شد. در ادامه، ۲۰ درصد داده‌های باقیمانده به عنوان ورودی آزمایشی، به مدل معرفی شد و با استفاده از الگوی تعداد نمونه منتخب در حالت آموزشی، داده‌های خروجی آزمایشی پیش‌بینی شدند. در حالت آزمایشی می‌توان شدت و دقیقیت کارکرد مدل شبکه عصبی را ارزیابی کرد.

نتایج و بحث
دامنه وسیع پارامترهای استفاده شده در این مطالعه، جدول ۱، جامعیت مدل شبکه عصبی مصنوعی توسعه داده شده را نشان می‌دهد. برای مثال، دامنه تغییرات جرم مخصوص ظاهری (۱/۹۱-۰/۱۷۶) گرم بر سانتی‌متر مکعب مخصوص ظاهری (۱/۸-۱/۱) گرم بر سانتی‌متر مکعب) بلکه خاک‌هایی را نیز زیر پوشش قرار می‌دهد که مقدار قابل توجهی ماده آلی دارند (Dexter, 2004).

تغییرات هدایت هیدرولیکی اشباع خاک در مقابل چهار پارامتر: بعد فرکتالی، مکش در نقطه ورود هوا، تخلخل مؤثر، و جرم مخصوص ظاهری برای ۱۴۲ نمونه خاک در شکل ۱ نشان می‌دهد که با افزایش مقدار مکش در نقطه ورود هوا، مقدار هدایت هیدرولیکی اشباع خاک کاهش می‌یابد. این مطلب مؤید رابطه‌ای است که رائولز و همکاران (Rawls et al., 1993) (رابطه ۵) ارائه داده‌اند. در این رابطه، هدایت هیدرولیکی اشباع با توان دوم بزرگ‌ترین شعاع خلل و فرج رابطه مستقیم و به عبارت

به منظور مقایسه عملکرد مدل شبکه عصبی مصنوعی با دو مدل رائولز و همکاران (Rawls et al., 1993; 1998) (روابط ۴ و ۵) از پارامترهای آماری همچون متوسط باقیمانده‌ها (MR)، خطای استاندارد نسبی (RSE)، و ضریب آکائیک (AIC) استفاده شد.

می‌دهد که استفاده از شبکه عصبی مصنوعی به عنوان ابزاری مناسب در جهت تخمین هدایت هیدرولیکی اشباع خاک گریز ناپذیر خواهد بود.

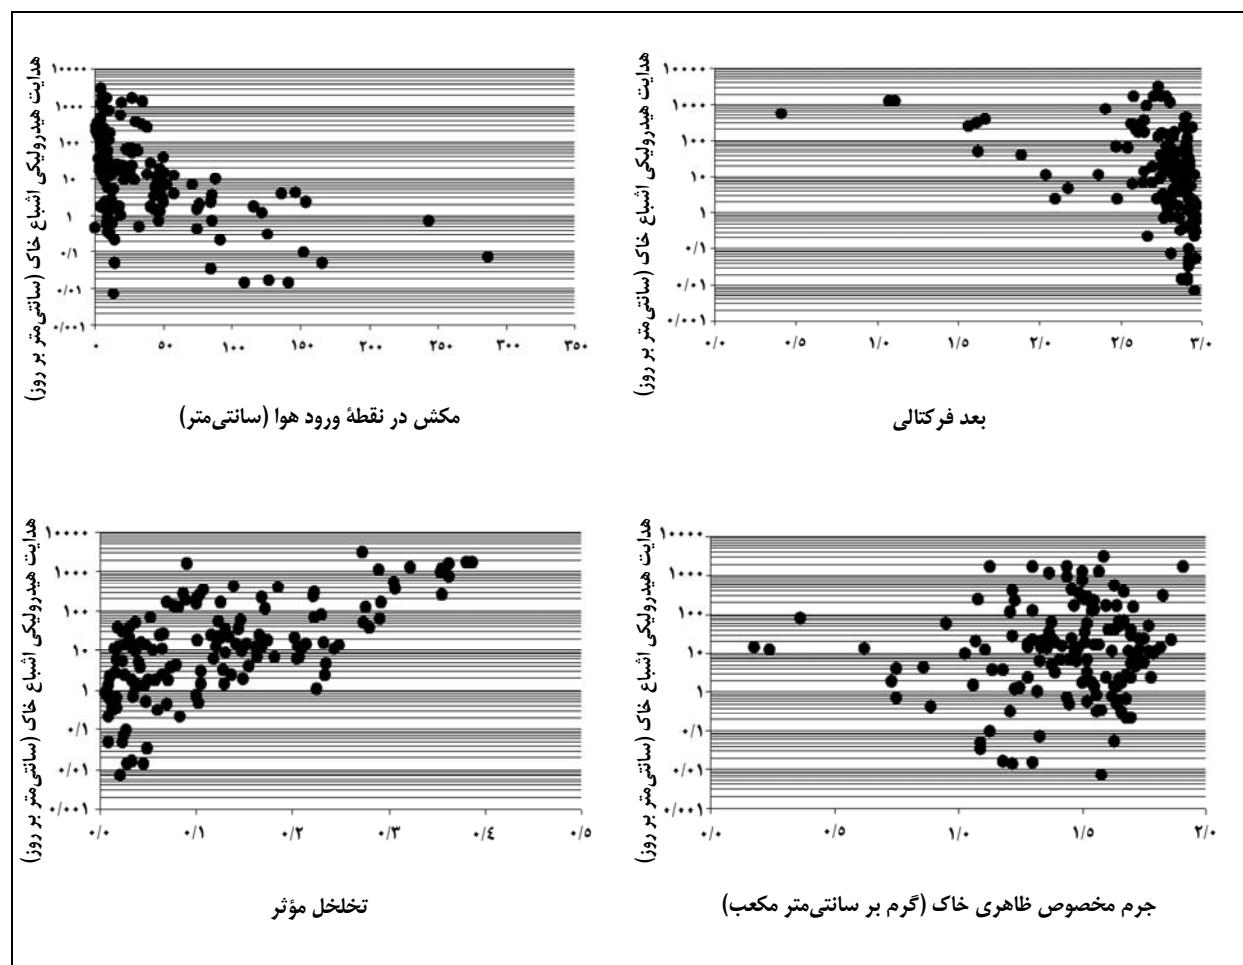
جدول ۲ نتایج بهدست آمده به ازای ۳۰ الگوی مختلف در مرحله آموزش و آزمون مدل شبکه عصبی مصنوعی را نشان می‌دهد. کمترین مقدار میانگین مربعات خطای (MSE) مربوط به حالتی است که ۲۴ نرون در لایه میانی وجود داشته باشد.

در شکل ۳ نتایج بهدست آمده در مرحله آموزش برای پیش‌بینی هدایت هیدرولیکی اشباع خاک از پارامترهای ورودی نشان داده شده است. نتایج نشان می‌دهد که شبکه عصبی مصنوعی به خوبی آموزش دیده شده است زیرا تغییرات هدایت هیدرولیکی اشباع پیش‌بینی شده در مقابل هدایت هیدرولیکی اشباع اندازه‌گیری شده روی خط یک به یک واقع شده‌اند. شبیخ خط نزدیک به یک (۰/۹۹)، عرض از مبدا نزدیک به صفر (۰/۰۰۱)، و ضریب همبستگی ۹۹۲/۰ بهدست آمده مؤید این مطلب است.

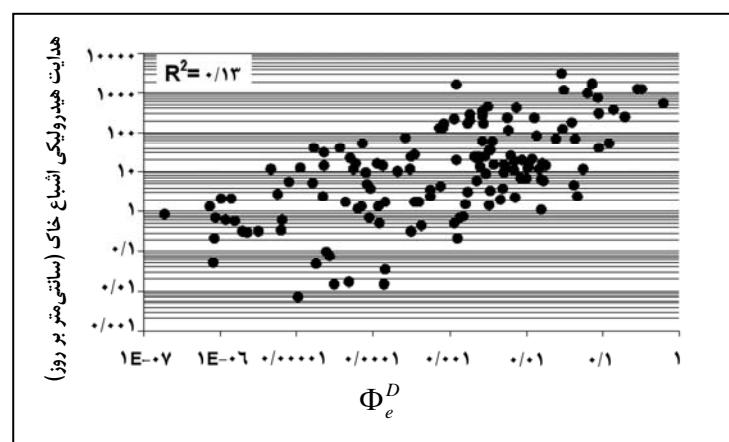
به منظور صحتسنجی شبکه عصبی مصنوعی ارائه شده، از ۲۸ داده باقیمانده استفاده شد. بدین ترتیب که با استفاده از بعد فرکتالی منحنی مشخصه رطوبتی، مکش در نقطه ورود هوا، تخلخل مؤثر، و جرم مخصوص ظاهری خاک، مقادیر هدایت هیدرولیکی اشباع خاک به وسیله شبکه عصبی مصنوعی تخمین زده شدند. نتایج بهدست آمده در شکل ۴ نشان داده شده‌اند. شبیخ خط ۷۹/۰، عرض از مبدا ۱۱/۰، و ضریب همبستگی ۷۶/۰ بهدست آمده در مرحله آزمون شبکه عصبی مصنوعی نشان می‌دهد که این مدل هدایت هیدرولیکی اشباع خاک را با دقیقی مناسب تخمین می‌زند.

دیگر با توان دوم مقدار مکش در نقطه ورود هوا رابطه عکس دارد. همچنین با افزایش بعد فرکتالی، مقدار هدایت هیدرولیکی اشباع خاک کاهش می‌یابد. از آنجائی که با افزایش درصد ذرات رس خاک، بعد فرکتالی منحنی مشخصه رطوبتی نیز افزایش می‌یابد (Huang & Zhang, 2005; Ghanbarian-Alavijeh *et al.*, 2008) رابطه معکوس بین هدایت هیدرولیکی اشباع خاک و بعد فرکتالی توجیه‌پذیر است. ذکر این نکته حائز اهمیت است که در حالت کلی، با در نظر گرفتن بافت خاک و بدون توجه به ساختمان آن می‌توان گفت که با کاهش اندازه ذرات، هدایت هیدرولیکی اشباع خاک نیز کاهش می‌یابد. اما این پارامتر نه تنها تابعی از بافت بلکه بیشتر تابعی از ساختمان و خلل و فرج بزرگ خاک است. بنابراین تحت شرایط کشت و شخم متفاوت، مقادیر متنوعی از هدایت هیدرولیکی اشباع اندازه‌گیری می‌شود. همانطور که مشاهده می‌شود با افزایش تخلخل مؤثر، هدایت هیدرولیکی اشباع خاک نیز افزایش می‌یابد و طبق رابطه ۲ این افزایش با توان n صورت می‌پذیرد. از طرف دیگر هیچ رفتار مشخصی بین هدایت هیدرولیکی اشباع و جرم مخصوص ظاهری مشاهده نشد. در حالی که از جرم مخصوص ظاهری به منظور تعیین مقدار تخلخل استفاده می‌شود که بیانی کمی از ساختمان خاک است (Alizadeh, 2004).

در شکل ۲ نیز رابطه هدایت هیدرولیکی اشباع و مقدار Φ_e^D در مقیاس لگاریتمی برای ۱۴۲ نمونه خاک ترسیم شده است. شبیخ خط، عرض از مبدا، و ضریب همبستگی حاصل از برآش رگرسیون خطی به داده‌های شکل ۲ به ترتیب برابر ۲۲۵۴، ۰/۰۵/۸، و ۰/۱۳ بهدست آورده شد. ضریب همبستگی پایین ($R^2=0.13$) نشان



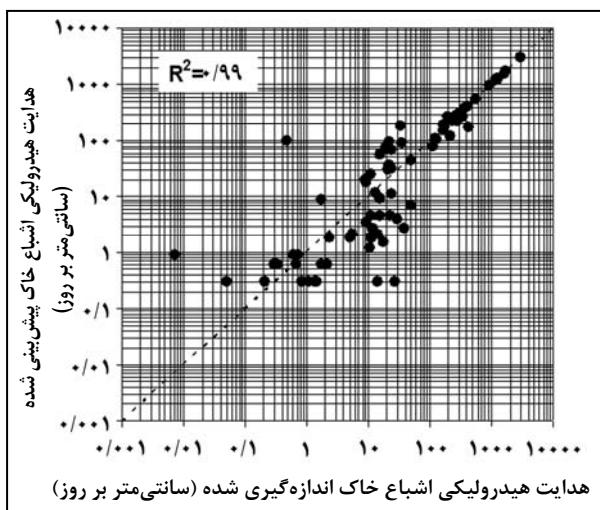
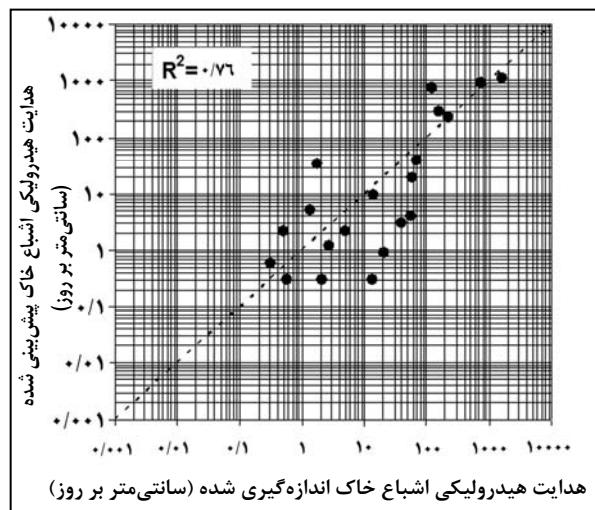
شکل ۱- تغییرات لگاریتمی هدایت هیدرولیکی اشباع خاک در مقابل بعد فرکتالی، مکش در نقطه ورود هوا، جرم مخصوص ظاهری، و تخلخل مؤثر



شکل ۲- تغییرات لگاریتمی هدایت هیدرولیکی اشباع در مقابل Φ_e^D

جدول ۲- مقادیر MSE و R^2 برای تعداد نرون‌های مختلف در لایه میانی برای مرحله آموزش و آزمون مدل شبکه عصبی مصنوعی

آزمون				آموزش				الگو			
MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2	MSE	R^2
۰/۰۰۵۹	۰/۵۷۴	۰/۰۰۰۱	۰/۹۹۷	۱-۱۶-۱	۰/۰۱۴۰	۰/۵۸۸	۰/۰۰۷۱	۰/۶۵۴	۱-۱-۱		
۰/۰۰۸۸	۰/۶۳۶	۰/۰۰۰۲	۰/۹۹۰	۱-۱۷-۱	۰/۰۲۳۴	۰/۵۹۳	۰/۰۰۵۷	۰/۷۲۵	۱-۲-۱		
۰/۰۱۰۳	۰/۱۴۷	۰/۰۰۰۱	۰/۹۹۴	۱-۱۸-۱	۰/۰۰۳۵	۰/۶۸۵	۰/۰۰۰۸	۰/۹۶۳	۱-۳-۱		
۰/۰۰۹۰	۰/۲۷۱	۰/۰۰۰۵	۰/۹۷۸	۱-۱۹-۱	۰/۰۲۰۵	۰/۴۹۶	۰/۰۰۴۰	۰/۸۱۲	۱-۴-۱		
۰/۰۰۸۲	۰/۸۵۰	۰/۰۰۱۳	۰/۹۴۱	۱-۲۰-۱	۰/۰۰۳۷	۰/۶۸۷	۰/۰۰۰۳	۰/۹۸۷	۱-۵-۱		
۰/۰۰۷۲	۰/۷۲۶	۰/۰۰۰۳	۰/۹۸۷	۱-۲۱-۱	۰/۰۰۶۶	۰/۷۰۹	۰/۰۰۰۲	۰/۹۹۹	۱-۶-۱		
۰/۰۰۶۳	۰/۷۲۸	۰/۰۰۰۱	۰/۹۹۶	۱-۲۲-۱	۰/۰۰۵۳	۰/۵۴۱	۰/۰۰۰۳	۰/۹۸۸	۱-۷-۱		
۰/۰۰۷۳	۰/۸۰۴	۰/۰۰۱۵	۰/۹۲۹	۱-۲۳-۱	۰/۰۱۰۵	۰/۲۰۳	۰/۰۰۰۱	۰/۹۹۹	۱-۸-۱		
۰/۰۰۲۸	۰/۷۵۶	۰/۰۰۰۲	۰/۹۹۲	۱-۲۴-۱	۰/۰۳۰۹	۰/۵۸۲	۰/۰۰۰۱	۰/۹۹۳	۱-۹-۱		
۰/۰۰۷۶	۰/۳۴۶	۰/۰۰۰۳	۰/۹۸۴	۱-۲۵-۱	۰/۰۰۵۹	۰/۵۱۸	۰/۰۰۰۲	۰/۹۹۲	۱-۱۰-۱		
۰/۰۰۸۳	۰/۳۸۸	۰/۰۰۰۱	۰/۹۹۴	۱-۲۶-۱	۰/۰۰۴۵	۰/۹۷۲	۰/۰۰۰۱	۰/۹۹۹	۱-۱۱-۱		
۰/۰۰۶۱	۰/۴۹۳	۰/۰۰۱۷	۰/۹۲۱	۱-۲۷-۱	۰/۰۰۳۹	۰/۷۸۳	۰/۰۰۰۴	۰/۹۸۳	۱-۱۲-۱		
۰/۰۰۶۱	۰/۸۰۶	۰/۰۰۱۰	۰/۹۵۴	۱-۲۸-۱	۰/۰۰۶۱	۰/۵۵۳	۰/۰۰۰۲	۰/۹۹۲	۱-۱۳-۱		
۰/۰۰۹۰	۰/۲۷۳	۰/۰۰۰۲	۰/۹۹۱	۱-۲۹-۱	۰/۰۰۸۶	۰/۷۵۱	۰/۰۰۰۴	۰/۹۹۸	۱-۱۴-۱		
۰/۰۰۸۰	۰/۲۹۵	۰/۰۰۰۴	۰/۹۸۱	۱-۳۰-۱	۰/۰۰۹۱	۰/۲۲۷	۰/۰۰۰۱	۰/۹۹۶	۱-۱۵-۱		



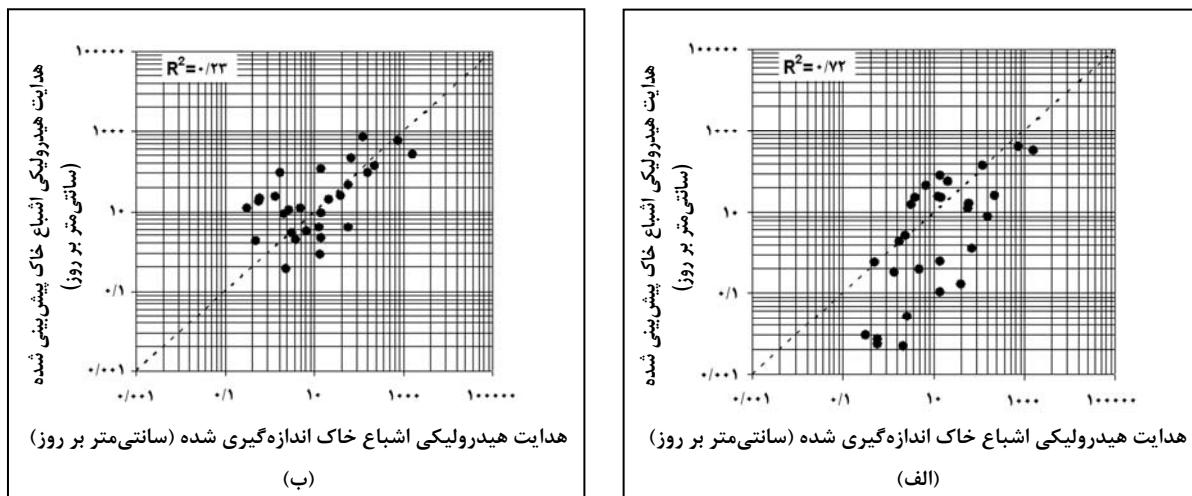
شکل ۴- مقایسه مقادیر هدايت هیدرولیکی اشباع خاک پیش‌بینی و اندازه‌گیری شده در مرحله آموزش مدل شبکه عصبی

شکل ۳- مقایسه مقادیر هدايت هیدرولیکی اشباع خاک پیش‌بینی و اندازه‌گیری شده در مرحله آموزش مدل شبکه عصبی

کاربرد شبکه عصبی مصنوعی در پیش‌بینی هدایت هیدرولیکی...

Rawls *et al.*, 1993; 1998) مبنی بر دقت نسبی این مدل‌ها به دست آورده‌اند تصدیق می‌کند. تحقیقات نشان داده‌اند که ضریب B در رابطه ۴ برای خاک‌های مختلف ثابت نیست، اما با قرار دادن مقدار 0.00053^0 متر بر ثانیه، که با استفاده از آنالیز کلاس‌های مختلف بافت خاک توسط رائولز و همکاران (Rawls *et al.*, 1998) ارائه شده است، نتایج قابل قبولی به دست آورده شد. در هر صورت، به منظور تخمین هدایت هیدرولیکی اشباع خاک با استفاده از رابطه آهوجا و همکاران (Ahuja *et al.*, 1984) تخمین پارامترهای آن چاره‌ناپذیر است.

با استفاده از داده‌های مرحله آزمون مدل شبکه عصبی مصنوعی، عملکرد دو مدل رائولز و همکاران (Rawls *et al.*, 1993; 1998) (روابط ۴ و ۵) نیز بررسی شد. بدین منظور، با استفاده از مقادیر تخلخل کل، تخلخل مؤثر، بعد فرکتالی، و مکش در نقطه ورود هوا، مقادیر هدایت هیدرولیکی اشباع خاک پیش‌بینی شدند. نتایج به دست آمده از مقایسه مقادیر هدایت هیدرولیکی اشباع پیش‌بینی شده و مقادیر اندازه‌گیری شده، در شکل ۵ نشان داده شده‌اند. این شکل، نتایجی را که آهوجا و همکاران (Ahuja *et al.*, 1984) و رائولز و همکاران



شکل ۵- مقایسه مقادیر هدایت هیدرولیکی اشباع خاک پیش‌بینی شده با مقادیر اندازه‌گیری شده با استفاده از (الف) مدل رائولز و همکاران (Rawls *et al.*, 1998) و (ب) مدل رائولز و همکاران (Rawls *et al.*, 1993)

نسبت به سایر مدل‌ها، هدایت هیدرولیکی اشباع خاک را با دقت بالاتری پیش‌بینی می‌کند.

با توجه به مقایسه مدل شبکه عصبی مصنوعی با دو مدل رائولز و همکاران (Rawls *et al.*, 1993; 1998) (روابط ۴ و ۵)، می‌توان نتیجه‌گیری کرد که با استفاده از مدل شبکه عصبی مصنوعی و پارامترهایی چون بعد فرکتالی منحنی مشخصه رطوبتی، مکش در نقطه ورود

جدول ۳، مقادیر پارامترهای آماری محاسبه شده را برای مدل‌های مختلف بیان می‌کند. مقایسه مقادیر متوسط باقیمانده‌ها نشان می‌دهد که در حالت کلی هر دو رابطه ۴ و ۵ مقادیر هدایت هیدرولیکی اشباع خاک را کمتر از مقادیر واقعی پیش‌بینی می‌کنند. همچنین، مقادیر کمتر خطای استاندارد نسبی و ضریب آکائیک (AIC) نشان می‌دهد که مدل شبکه عصبی مصنوعی،

هوای تخلخل مؤثر، و جرم مخصوص ظاهری خاک می‌توان هدایت هیدرولیکی اشباع خاک نتایجی قابل قبول به دست آورد.

جدول ۳- پارامترهای آماری محاسبه برای مدل‌های مختلف در پیش‌بینی هدایت هیدرولیکی اشباع خاک

AIC	RSE	MR	مدل
۲۹۱/۸	۱/۴	۷/۷	شبکه عصبی مصنوعی
۳۱۶/۴	۲/۲	-۷۱/۲	مدل رائولز و همکاران (۱۹۹۸) (رابطه ۴)
۳۲۲/۳	۲/۵	-۲۸/۶	مدل رائولز و همکاران (۱۹۹۳) (رابطه ۵)

رفت، نتایج نشان داد که تئوری رائولز و همکاران (Rawls *et al.*, 1998) روشی جامع برای تخمین هدایت هیدرولیکی اشباع خاک نیست و از این رو شبکه عصبی مصنوعی با ۴ پارامتر ورودی به منظور تخمین هدایت هیدرولیکی اشباع خاک ارائه شد. نتایج به دست آمده در مرحله اعتبارسنجی مدل شبکه عصبی مصنوعی ارائه شده نشان داد که می‌توان هدایت هیدرولیکی اشباع خاک را از داده‌های منحنی مشخصه رطوبتی و جرم مخصوص ظاهری خاک با دقتی مناسب پیش‌بینی کرد.

نتیجه‌گیری

در این مطالعه، به منظور تخمین هدایت هیدرولیکی اشباع خاک از پارامترهای فیزیکی خاک همچون بعد فرکتالی منحنی مشخصه رطوبتی، مکش در نقطه ورود هوا، تخلخل مؤثر، و جرم مخصوص ظاهری خاک استفاده و مدل شبکه عصبی مصنوعی برای محدوده وسیعی از خاک‌ها با خصوصیات متفاوت آموزش دیده شد. با توجه به طیف وسیعی از داده‌های اندازه‌گیری شده که در این مطالعه به کار

مراجع

- Ahuja, L. R., Naney, J. W., Green, R. E. and Nielsen, D. R. 1984. Macroporosity to characterize spatial variability of hydraulic conductivity and effects of land management. *Soil Sci. Soc. Am. J.* 48, 699-702.
- Ahuja, L. R., Cassel, D. K., Bruce, R. R. and Barnes, B. B. 1989. Evaluation of spatial distribution of hydraulic conductivity using effective porosity data. *Soil Sci.* 148, 404-411.
- Alizadeh, A. 2004. *Soil Physics*. Imam Reza University Pub. (in Farsi)
- Alizadeh, A. 2005. *Soil, Water, Plant Relationships*. Imam Reza University Pub. (in Farsi)
- Amini, M., Abbaspour, K. C., Khademi, H., Fathianpour, N., Afyuni, M. and Schulin, R. 2005. Neural network models to predict cation exchange capacity in arid regions of Iran. *European J. Soil Sci.* 56, 551-559.
- Anon. 2006. *MATLAB: The Language of Technical Computing*. version 7.3.
- Bouma, J. 1989. Using soil survey data for quantitative land evaluation. *Adv. Soil Sci.* 9, 177-213.

- Brakensiek, D. L., Rawls, W. J. and Stephenson, G. R. 1984. Modifying SCS hydrologic soil groups and curve numbers for rangeland soils. ASAE Paper PNR-84-203. St. Joseph. MI 49085-9659. USA.
- Campbell, G. S. 1985. *Soil Physics with Basic*. Elsevier. New York.
- Carman, P. C. 1938. The determination of the specific surface of powders. *J. Soc. Chem. Ind. Trans.* 57, 225.
- Carman, P. C. 1956. *Flow of gases through porous media*. Butterworths. Scientific Pub. London.
- Carrier, W. D. 2003. Goodbye, Hazen; Hello, Kozeny-Carman. *J. Geotech. Geoenviron. Eng.* 129, 1054-1056.
- Cosby B. J., Hornberger, G. M., Clapp, R. B. and Ginn, T. R. 1984. A statistical exploration of soil moisture characteristics to the physical properties of soils. *Water Resour. Res.* 20, 682-690.
- Dane, J. H. and Puckett, W. 1994. Field soil hydraulic properties based on physical and mineralogical information. In: van Genuchten, M. Th. (Eds) *Proceedings of the International Workshop on Indirect Method for Estimation Hydraulic Properties of Unsaturated Soils*. California University. Riverside. CA. 389-403.
- Dexter, A. R. 2004. Soil physical quality Part I. Theory, effects of soil texture, density, and organic matter, and effects on root growth. *Geoderma* 120, 201-214.
- Doaee, M., Shabanpour sharestani, M. and Bagheri, F. 2005. Modeling saturated hydraulic conductivity in clay soils in guilan province (Iran) using artificial neural networks. *J. Agric. Sci.* 1: 41-48. (in Farsi)
- Franzmeier, D. P. 1991. Estimation of hydraulic conductivity from effective porosity data for some Indiana soils. *Soil Sci. Soc. Am. J.* 55: 1801-1803.
- Ghanbarian-Alavijeh, B., Lighat, A. M., Shorafa, M. and Moghimi-Araghi, S. 2008. Prediction of soil water retention curve using soil particle-size distribution. *J. Agric. Eng. Res.* 9, 63-80. (in Farsi)
- Haverkamp, R., Zammit, C., Boubkraoui, F., Rajkai, K., Arrué, J. L. and Heckmann, N. 1997. GRIZZLY. Grenoble soil catalogue: Soil survey of field data and description of particle-size, soil water retention and hydraulic conductivity functions. LTHE. Grenoble. France.
- Hazen, A. 1911. Discussion of Dams on sand foundations by A. C. Koenig. *Trans. Am. Soc. Civ. Eng.* 73, 199-203.
- Huang, G. and Zhang, R. 2005. Evaluation of soil water retention curve with the pore-solid fractal model. *Geoderma*. 127, 52-61.
- Jabro, J. D. 1992. Estimation of saturated hydraulic conductivity of soils from particle size distribution and bulk density data. *Trans. ASAE*. 35, 557-560.
- Jain, A. and Kumar, A. 2006. An evaluation of artificial neural network technique for the determination of infiltration model parameters. *Appl. Soft Comput.* 6, 272-282.

- Karamooz, M. and Araghinejad, S. 2005. Advance Hydrology. Amir Kabir University Pub. (in Farsi).
- Kozeny, J. 1927. Ueber kapillare Leitung des Wassers im Boden. Wien. Akad.
- Leij, F. J., Alves, W. J., van Genuchten, M. Th. and Williams, J. R. 1996. Unsaturated soil hydraulic database. UNSODA 1.0 user's manual. Rep. EPA/600/R96/095. USEPA.
- Marshall, T. J. 1958. A relation between permeability and size distribution of pores. European J. Soil Sci. 9, 1-8.
- Menhaj, M. 2000. Fundamental of artificial neural network. Amir kabir Pub. (in Farsi)
- Merdun, H., Ozer, C., 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.
- Messing, I. 1989. Estimation of saturated hydraulic conductivity in clay soils from soil moisture retention data. Soil Sci. Soc. Am. J. 53, 665-668.
- Minasny, B. and McBratney, A. B. 2002. Neural Networks Package for fitting pedotransfer function. Technical Notes. Version 1.0.
- Navabian, M., Liaghat, A. M. and Homae, M. 2004. Estimating soil saturated hydraulic conductivity using pedotransfer functions. J. Agric. Eng. Res. 4, 1-11. (in Farsi)
- Pachepsky, Y. A., Timlin, D. J. and Ahuja, L. R. 1999. Estimating saturated soil hydraulic conductivity using water retention data and neural networks. Soil Sci. 164, 552-560.
- Parasuraman, K., Elshorbagy, A. and Si, B. C. 2006. Estimating saturated hydraulic conductivity in spatially variable fields using neural network in Ensembles. Soil Sci. Soc. Am. J. 70, 1851-1859.
- Puckett, W. E., Dane, J. H. and Hajek, B. F. 1985. Physical and mineralogical data to determine soil hydraulic properties. Soil Sci. Soc. Am. J. 49, 831-836.
- Rawls, W. J., Brakensiek, D. L. and Saxton, K. E. 1982. Estimation of soil water properties. Trans. ASAE. 25, 1316-1320.
- Rawls, W. J., Brakensiek, D. L. and Logsdon, S. D. 1993. Predicting saturated hydraulic conductivity utilizing fractal principles. Soil Sci. Soc. Am. J. 57, 1193-1197.
- Rawls, W. J., Gimenez, D. and Grossman, R. 1998. Use of soil texture, bulk density, and slope of the water retention curve to predict saturated hydraulic conductivity. Trans. ASAE. 41, 983-988.
- Saxton, K. E., Rawls, W. J., Romberger, J. S. and Papendick, R. I. 1986. Estimating generalized soil water characteristics from texture. Soil Sci. Soc. Am. J. 50, 1031-1036.
- Schaap, M. G., Leij, F. J. and van Genuchten, M. Th. 2001. Rosetta: A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions, J. Hydrol. 251, 163-176.

- Spychalski, M., Kaźmierowski, C. and Kaczmarek, Z. 2007. Estimation of saturated hydraulic conductivity on the basis of drainage porosity. EJPAU 10(1): 04 (<http://www.ejpau.media.pl/volume10/issue1/art-04.html>).
- Timlin, D. J., Ahuja, L. R. and Williams, R. D. 1996. Methods to estimate soil hydraulic parameters for regional scale applications of mechanistic methods. In Application of GIS to the Modeling of Non-point Source Pollutants in the Vadose Zone. SSSA Agronomy. Madison. WI. 185-203.
- Tyler, S. W. and Wheatcraft, S. W. 1990. Fractal processes in soil water retention. Water Resour. Res. 26, 1047-1054.
- Vereecken, H., Maes, J., Feyen, J. 1990. Estimating unsaturated hydraulic conductivity from easily measured soil properties. Soil Sci. 149, 1-12.
- Wösten, J. H. M. 1997. Pedotransfer functions to evaluate soil quality. In: Gregorich, E. G. and Carter, M. R. (Eds) Soil Quality for Crop Production and Ecosystem Health. Developments in Soils Science. Elsevier. Amsterdam. 25, 221-245.
- Wösten, J. H. M., Lilly, A., Nemes, A. and Le Bas, C. 1999. Development and use of a database of hydraulic properties of European soils. Geoderma. 90, 169-185.



Application of Artificial Neural Networks in Prediction of Saturated Hydraulic Conductivity Using Soil Physical Parameters

B. Ghanbarian-Alavijeh*, A. M. Liaghat and S. Sohrabi

* Corresponding Author: Ph.D. Student, University of Tehran, P. O. Box: 4111, Tehran, Iran. E-mail: bghanbarian@gmail.com

Soil hydraulic properties such as saturated and unsaturated hydraulic conductivity play an important role in environmental research. Since direct measurement of these soil hydraulic properties is time-consuming and costly, indirect methods such as pedotransfer functions and artificial neural networks (ANN) were developed based on readily available parameters. In this study, the use of ANN to predict saturated hydraulic conductivity using a measured soil moisture curve and bulk density was investigated. Measured bulk density and soil moisture curves were used to estimate saturated hydraulic conductivity from calculated fractal dimensions, air entry values, bulk density and effective porosity using ANN. In the training and testing steps of ANN, 114 and 28 measured soil samples were used, respectively. R^2 and MSE were 0.76 and 0.0028, respectively, for the ANN method with four inputs. A comparison of ANN with Rawls et al. (1993, 1998) models showed that the neural network more accurately predicts saturated hydraulic conductivity.

Key Words: Artificial Neural Network, Saturated Hydraulic Conductivity, Soil Moisture Curve