

ارزیابی و مقایسه سیستم استنتاج فازی - عصبی و شبکه عصبی مصنوعی پرسپترون چند لایه در برآورد هدایت هیدرولیکی اشباع خاک با استفاده از بافت خاک (مطالعه موردی: شبکه آبیاری دشت فتحعلی مغان)

یاسر حسینی* و رضا صدقی**

* نگارنده مسئول: دانشکده کشاورزی و منابع طبیعی مغان، پارس آباد، اردبیل، ایران. تلفن: ۰۴۵)۲۷۴۶۳۴۱۷،

پيام‌نگار: yaser_hoseini@ymail.com

** به ترتیب: استادیار دانشکده کشاورزی و منابع طبیعی مغان - دانشگاه محقق اردبیلی؛ و مربی دانشکده فنی و حرفه ای سما، دانشگاه آزاد اسلامی

اردبیل

تاریخ دریافت: ۹۴/۶/۱۴؛ تاریخ پذیرش: ۹۴/۱۰/۱۹

چکیده

اندازه‌گیری مستقیم ویژگی‌های هیدرولیکی خاک وقت‌گیر و پر هزینه است اما می‌توان این ویژگی‌ها را با بهره‌گیری از داده‌های زودبافت مثل بافت خاک، جرم مخصوص ظاهری و با استفاده از روش‌هایی چون توابع انتقالی و سیستم استنتاج فازی - عصبی نیز به دست آورد. در این تحقیق برای برآورد هدایت هیدرولیکی اشباع خاک، از مدل شبکه عصبی مصنوعی و سیستم استنتاج فازی - عصبی استفاده شد. ورودی‌های مدل، شامل درصد رس، سیلت و شن بود. معماری شبکه عصبی دارای ۳ نرون در لایه ورودی، ۱۱ نرون در لایه پنهان با تابع انتقال تانژانت سیگموئید و یک نرون در لایه خروجی با تابع انتقال خطی با ۱۰۰۰ تکرار بود و در تمام شبکه از سرعت یادگیری و مومنت مساوی با ۰/۳ استفاده شد. سیستم استنتاج فازی - عصبی دارای ۲۷ قانون است و برای تابع عضویت متغیرهای ورودی از تابع گوسین استفاده شد. همچنین، برای بهینه‌سازی سیستم استنتاج فازی - عصبی از روش هیبرید استفاده شد. برای ارزیابی عملکرد مدل از پارامترهای مجذور میانگین مربعات خطا (سانتی متر بر روز)، درصد خطای نسبی، میانگین خطای مطلق (سانتی متر بر روز)، ضریب جرم باقیمانده، راندمان مدل و ضریب تبیین استفاده شد که برای مدل فازی - عصبی به ترتیب ۰/۳۲، ۰/۶۲۷، ۰/۱۸، ۰/۰۰۰۰۰۲۳، ۰/۹۹۹ و ۰/۹۹۷ به دست آمد. برای شبکه عصبی مصنوعی نیز با الگوریتم آموزشی لونیگ-مارکوت در تخمین هدایت هیدرولیکی اشباع خاک این مقادیر به ترتیب ۱/۲۲، ۱/۴۴، ۱/۲۱، ۰/۰۰۰۰۱۵، ۰/۹۹۷ و ۰/۹۹ به دست آمد. نتایج تحقیق نشان می‌دهد که سیستم استنتاج فازی - عصبی نسبت به شبکه عصبی مصنوعی دقیق‌تر است و نسبت به داده‌های اندازه‌گیری شده نتایجی نزدیکتر ارائه می‌دهد.

واژه‌های کلیدی

تخمین، دانه‌بندی خاک، سیستم استنتاج فازی - عصبی، شبکه عصبی مصنوعی، هدایت هیدرولیکی خاک

مقدمه

پروژه‌های زهکشی نقش بسزایی دارد. اندازه‌گیری این ویژگی‌ها به دلیل نیاز به صرف هزینه و زمان زیاد و تغییرپذیری مکانی و زمانی فراوان آنها، اغلب با دشواری‌هایی همراه است. بنابراین، استفاده از روش‌هایی

اندازه‌گیری ویژگی‌های هیدرولیکی خاک، مانند هدایت هیدرولیکی اشباع خاک که از مهمترین ویژگی‌های فیزیکی خاک است، در طراحی و امکان‌پذیر بودن فنی و اقتصادی

به یادگیری نیست. به عبارت دیگر، با استفاده از داده‌های مشاهده‌ای نمی‌توان سیستم فازی را آموزش داد. اما شبکه‌های عصبی با استفاده از مجموعه داده‌ها، قابلیت خودآموزی دارند. در عین حال، شبکه‌های عصبی غیر صریح هستند و نمی‌توانند از زبان بشری استفاده کنند. رالز (Rawls, 2004) در تحقیقی دیگر به منظور برآورد هدایت هیدرولیکی اشباع ماتریس و منافذ درشت خاک، مدل فرش سرپینسکی را با معادله هدایت هیدرولیکی مارشال (Marshall, 1958) ترکیب کرد؛ نتایج این بررسی نشان داد که معادله هدایت هیدرولیکی اشباع تعدیل شده مارشال برآوردهایی منطقی از هدایت هیدرولیکی اشباع ماتریس و منافذ درشت خاک می‌دهد. در این تحقیق، ضریب همبستگی بین مقادیر هدایت هیدرولیکی اشباع برآورد شده و اندازه‌گیری شده توسط این محققان ۰/۸۹ به دست آمد. در چند سال اخیر سیستم‌های قدرتمندی به نام سیستم‌های استنتاج فازی-عصبی (ANFIS) در علوم مختلف به کار برده شده است. رضایی‌ارشد (Rezaie-Arshad, 2010) در تحقیقی برای مقایسه توانایی شبکه‌های عصبی مصنوعی با روش‌های رگرسیونی چندگانه برای تخمین هدایت هیدرولیکی اشباع از شاخص‌های زود یافت خاک، از جمله درصد توزیع اندازه ذرات و جرم مخصوص ظاهری، به این نتیجه رسید که شبکه‌های عصبی ایجاد شده قادرند هدایت هیدرولیکی اشباع را با دقت بیشتری (ضریب تبیین ۰/۸۲ نسبت به ۰/۵) نسبت به رگرسیون‌های خطی چندگانه برآورد کنند. عابدی (Amir-Abedi, 2012) نیز در مقایسه دقت برآورد شبکه‌های عصبی و مدل‌های رگرسیونی به نتایج مشابه دست یافت؛ وی در تحقیقی خصوصیات فیزیکی خاک از جمله هدایت هیدرولیکی اشباع خاک را از ویژگی‌های زود یافت خاک برآورد و با مدل‌های رگرسیونی مقایسه کرد. نتایج بررسی‌های این محقق نشان داد که مدل‌های شبکه عصبی و مدل‌های رگرسیونی با میزان ضریب تبیین

که بتوانند این ویژگی‌ها را با استفاده از پارامترهای زود یافت خاک مانند بافت، کربن آلی و چگالی ظاهری با دقت مناسب تخمین بزنند، لازم به نظر می‌رسد. یکی از این روش‌ها، روش سیستم استنتاج فازی-عصبی^۱ (ANFIS) است. در گذشته، از مدل‌های ریاضی برای پیدا کردن رابطه بین ورودی‌ها و خروجی‌های هر فرایند استفاده می‌شد. اما این رویکرد منطقی کلاسیک نیاز به تعریف دقیقی از معادلات مدل ریاضی توصیف شده برای آن پدیده داشت. امروزه، اثبات شده است که در بسیاری از کاربردها روش منطقی فازی^۲، نسبت به چارچوب‌های ریاضی کلاسیک، برتری دارد زیرا منطقی فازی از نظر مفهومی بسیار ساده و انعطاف‌پذیر است و در واقع به آسانی می‌توان یک سیستم فازی را برای حل مسئله‌ای پیچیده با استفاده از قوانین اگر- آنگاه سازماندهی کرد.

لیپمان (Lippman, 1987) می‌گوید شبکه عصبی مصنوعی (ANN) روش دیگری است و با مدل‌سازی ارتباطات سیناپسی و ساختار نرونی مغز انسان، رویکردی برای پیاده‌سازی مصنوعی ویژگی‌های فیزیولوژیک آن است. هر چند شبکه‌های عصبی مصنوعی با مدل واقعی مغز فاصله زیادی دارند، اما توانایی این شبکه‌ها در کشف روابط غیر خطی میان داده‌های ورودی و استخراج مدل دینامیک غیر خطی حاکم بر داده‌ها قابل توجه است و در مقایسه با مدل‌های مرسوم، این مدل‌ها به ورودی‌های کمتر و تلاش محاسباتی اندکی نیاز دارند.

رحیمی اجدادی و عباسپور گیلانده (Rahimi-Ajdadi & Abbaspour-Gilandeh, 2011) برتری مدل شبکه عصبی مصنوعی، نسبت به مدل رگرسیونی کلاسیک، را گزارش داده‌اند. هریک از سیستم‌های فازی-عصبی و شبکه‌های عصبی مصنوعی دارای مزایا و نواقصی است. کاراتاپولوس (Karatalopoulos, 2000) می‌گوید سیستم فازی قادر به استفاده از زبان بشری است و می‌تواند از تجربیات بشر و افراد متخصص و خبره استفاده کند اما قادر

رگرسیون و فازی برای ایجاد توابع انتقالی خاک به این نتیجه رسیدند که وقتی روابط بین متغیرها، و به طور کلی هنگامی که با خطاهای ناشی از ابهام در ساختار معادلات رگرسیونی روبه‌رو هستیم، روش فازی می‌تواند جایگزین روش‌های رگرسیونی شود. تحقیقات سرمدیان و همکاران (Sarmadian *et al.*, 2010) برای تخمین خصوصیات خاک از جمله نقطه پژمردگی، ظرفیت زراعی و وزن مخصوص ظاهری از روی داده‌های زودیافت خاک مانند بافت خاک و کربن آلی و آهک با استفاده از روش‌های نورو فازی و شبکه عصبی و رگرسیون چند متغیره، نتایج برتری سیستم‌های نورو فازی را نسبت به روش‌های دیگر نشان داد اما در برخی از ویژگی‌ها مثل حد ظرفیت زراعی، نقطه پژمردگی و چگالی ظاهری، نتایج مدل‌ها در سطح ۵ درصد معنی‌دار نگردید. سیستم‌های نورو فازی علاوه بر آنکه قدرت یادگیری سیستم‌های شبکه عصبی را دارند، به دلیل برخورداری از قوانین کیفی، خطاهایشان کمتر است و انتظار می‌رود در برآوردها همواره بهتر از شبکه‌های عصبی عمل کنند؛ با این همه، در پاره‌ای از موارد نتایج سیستم‌های مبتنی بر شبکه‌های عصبی از سیستم‌های فازی - عصبی دقیق‌تر بوده است. به طور مثال، نتایج تحقیقات کیانپور کلخواجه (Kianpur-Kalkhajeh, 2012) برای برآورد هدایت هیدرولیکی اشباع خاک از داده‌های زودیافت خاک با استفاده از روش‌های رگرسیونی خطی و شبکه عصبی و سیستم نورو فازی نشان می‌دهد که شبکه عصبی با ضریب تبیین ۰/۸۱، نسبت به روش رگرسیون خطی چندگانه با ضریب تبیین ۰/۵۱ و مدل ANFIS با ضریب تبیین ۰/۷۱، دقت بالاتری در برآورد هدایت هیدرولیکی خاک دارد. فیروزی و همکاران (Firoozi *et al.*, 2014) برای برآورد عملکرد انرژی مصرفی در زمین‌های کشاورزی از روش‌های ANFIS و ANN استفاده کردند. نتایج بررسی‌ها نشان می‌دهد که شبکه عصبی با ۶ ورودی و ۴ نرون برای هر لایه پنهان، با ضریب

۰/۷۶ و ۰/۷۲ توانایی خوبی در تعیین هدایت هیدرولیکی اشباع خاک دارند اما دقت مدل‌های شبکه عصبی بالاتر است. در بسیاری از تحقیقات برای برآورد خصوصیات هیدرولیکی خاک، از اجزای بافت خاک به عنوان پارامترهای مستقل با حساسیت بالا نام برده شده است (Givi *et al.*, 2004; Heusher *et al.*, 2005; Vos *et al.* 2005).

نصرتی و همکاران (Nosrati *et al.*, 2012) در تحقیقی هدایت هیدرولیکی اشباع را از پارامترهای زودیافت خاک با استفاده از شبکه‌های عصبی برآورد کردند و پارامترهای درصد شن و رس، رطوبت در مکش ۰/۳ بار، تخلخل کل و میانگین هندسی اندازه ذرات خاک را در برآورد هدایت هیدرولیکی اشباع پارامترهایی حساس می‌دانند.

مردون و همکاران (Merdun *et al.*, 2006) با استفاده از توابع انتقالی و شبکه‌های عصبی مصنوعی، هدایت هیدرولیکی اشباع را برآورد کردند. در این پژوهش، ۱۳۰ نمونه از داده‌ها برای پی‌ریزی مدل‌ها و ۶۵ نمونه باقی‌مانده برای ارزیابی مدل‌ها به کار گرفته شد. نتایج این پژوهش نشان داد که مدل‌های رگرسیونی، نسبت به شبکه‌های عصبی مصنوعی، برآورد بهتری از هدایت هیدرولیکی اشباع داشته‌اند.

درباره برتری مدل‌های ANFIS نسبت به سایر مدل‌ها در برآوردهای مربوط به خاک، محمدی (Mohammadi, 2002) می‌گوید از آنجا که در سیستم‌های طبیعی، مانند خاک، عموماً با مشاهدات یا روابط ناشناخته بین متغیرها روبه‌رو هستیم باید قادر به ارائه الگوهایی باشیم که انطباق بیشتری با دنیای واقعی داشته باشند. از این رو با توجه به ماهیت ابهامی پدیده‌های خاک و تقریبی بودن مقادیر اندازه‌گیری شده، به نظر می‌رسد دلیل کارایی مدل‌های مبتنی بر مجموعه‌های فازی - عصبی در پردازش توابع انتقالی خاک همین باشد. محمدی و طاهری (Mohammadi & Taheri, 2005) با مقایسه دو روش

وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و پایین آمدن دقت شبکه می‌شود؛ برای اجتناب از چنین شرایطی و همچنین به منظور یکسان کردن ارزش داده‌ها، پیش از آموزش شبکه عصبی، داده‌های ورودی به آن باید استاندارد شوند (Mohammadi, 2002). این کار مانع از کوچک شدن بیش از حد وزن‌ها می‌شود (Soltani & Morid, 2002). هدف از نرمال‌سازی آن است که داده‌ها به اعدادی بین صفر تا یک تبدیل شوند زیرا در این پژوهش برای نرون‌ها در لایه مخفی، تابع انتقال سیگموئیدی انتخاب شد که خروجی این تابع اعدادی بین صفر تا یک است و بنابراین باید داده‌های ورودی به این تابع نیز اعدادی بین صفر و یک باشند (Menhaj, 1998). برای ورودی‌های نزدیک به صفر تا یک، تغییرات وزن نرون‌ها حداقل خواهد بود زیرا در این اعداد، نرون‌ها به دلیل شکل تابع سیگموئید، کند عمل می‌کنند. ولی برای مقادیر ورودی‌های نزدیک به نیم، پاسخ نرون‌ها به سیگنال ورودی سریع‌تر خواهد بود (Wosten et al., 1999).

سیستم‌های استنتاج فازی - عصبی (ANFIS)

اساس ANFIS بر پایه‌ای از مجموعه داده‌های ورودی/خروجی سیستم استنتاج فازی (FIS) است. این سیستم بر پایه قوانین ترکیبی از سه قسمت: ۱- توابع عضویت متغیرهای ورودی و خروجی (فازی کردن)، ۲- قوانین فازی (پایگاه قواعد)، استنتاج مکانیزم (ترکیب قواعد با ورودی فازی) و ۳- مشخصه‌های خروجی و نتایج سیستم (غیر فازی‌سازی). اولین بار جانگ (Jang, 1993) توانست از قدرت زبانی سیستم‌های فازی و آموزش شبکه‌های عصبی استفاده و سیستمی به نام سیستم‌های فازی-عصبی تطبیقی ارائه کند؛ این سیستم‌ها به سیستم‌های ANFIS معروف شده‌اند. سیستم‌های ANFIS را بیشتر با استفاده از یک سیستم فازی تاکاگی-سوگنو-کانگ^۱ (TSK) به صورت ساختار شبکه‌ای پیش‌رونده

این راستا هدایت هیدرولیکی خاک در بالای سطح ایستابی با استفاده از دستگاه نفوذسنج گلف اندازه‌گیری شده است. در اندازه‌گیری به روش گلف ابتدا چاهکی با اوگر مخصوص تا عمق مورد نظر در خاک حفر و کف آن با اوگر مربوط صاف گردید. سپس دستگاه در چاهک مربوطه قرار داده شد و قرائت‌ها مطابق روش استاندارد یک بار تا ارتفاع آب به میزان ۵ سانتی‌متر و یک بار تا ارتفاع ۱۰ سانتی‌متر آب درون چاهک صورت گرفت. برای اندازه‌گیری هدایت هیدرولیکی در زیر سطح ایستابی نیز از روش چاهک استفاده شد. با بررسی آماری داده‌های فیزیکی خاک مشخص شد که میزان شن خاک بین ۴/۳ تا ۵۷/۳ درصد با میانگین ۳۰/۸ درصد، میزان سیلت خاک بین ۱۴/۷ تا ۵۶/۳ درصد با میانگین ۳۵/۵ درصد و میزان رس خاک بین ۷/۸ تا ۸۱ درصد با میانگین ۴۴/۳ درصد متغیر است. دامنه زیاد تغییرات در پارامترهای فیزیکی خاک می‌تواند به دلیل وسعت محدوده مورد مطالعه باشد. دامنه تغییرات هدایت هیدرولیکی ۱۰۸/۷ تا ۱۶۶/۶ سانتی‌متر بر روز با میانگین ۱۳۱/۲ سانتی‌متر بر روز است.

آماده‌سازی داده‌ها

تعداد کل داده‌های به دست آمده ۱۳۵ بود که از این میان از ۱۲۰ داده برای مرحله آموزش مدل و از ۱۵ داده برای مرحله آزمون مدل استفاده شد. داده‌ها در دامنه صفر تا ۱، طبق رابطه ۱ نرمال شدند (Anon, 2008).

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

که در آن، X_{norm} = مقادیر نرمال شده؛ X = مقدار مشاهده شده؛ و X_{min} و X_{max} به ترتیب مقادیر بیشینه و کمینه مشاهده شده است.

C_i و a_i = مجموعه پارامتر (پارامترهای اولیه) و x = ورودی
گره i ام.
لایه دوم: (گره‌های قاعده) هر گره در این لایه درجه فعالیت
هر قانون را محاسبه می‌کند (رابطه ۸):

$$O_{2,i} = w_i = \mu A_i(x) \times \mu B_i(y) \quad i=1,2 \quad (8)$$

لایه سوم: خروجی این لایه نرمال شده لایه قبلی است
(رابطه ۹):

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (9)$$

لایه چهارم: (گره‌های نتیجه) در این لایه خروجی هر گره
برابر است با (رابطه ۱۰):

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (P_i x + q_i y + r_i), \quad i=1,2 \quad (10)$$

لایه پنجم: (گره‌های خروجی) در این لایه هر گره مقدار
خروجی نهایی را به صورت رابطه ۱۱ محاسبه می‌کند
(تعداد گره‌ها برابر تعداد خروجی‌هاست):

$$O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i W_i f_i}{\sum_i W_i} \quad (11)$$

بر اساس نظر جانگ و سان (Jang & Sun, 1997)،
آموزش این سیستم‌ها به این مفهوم است که با استفاده از
داده‌های آموزشی پارامترهای غیرخطی مربوط به توابع
عضویت فازی در لایه اول و پارامترهای خطی لایه چهارم
طوری تعیین شوند که به ازای ورودی دلخواه، خروجی
مطلوب حاصل شود.

روش بهینه‌سازی هیبرید^۳ یکی از مهم‌ترین روش‌های
بهینه‌سازی سیستم‌های استنتاج فازی-عصبی است. این
روش ترکیبی از روش حداقل مربعات و روش کاهش شیب
پسانتشار^۴ است.

به کار می‌برند. برای سادگی کار فرض می‌کنیم که سیستم
فازی دو ورودی x و y دارد و خروجی آن z است. حال اگر
قوانین به صورت روابط ۲ و ۳ باشند:

$$Rule1: \text{if } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } f_1 = P_1 x + q_1 y + r_1 \quad (2)$$

$$Rule2: \text{if } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } f_2 = P_2 x + q_2 y + r_2 \quad (3)$$

و اگر برای غیرفازی‌سازی (تبدیل خروجی نهایی
سیستم به یک عدد کلاسیک) از روش میانگین مراکز
استفاده کنیم خروجی به صورت رابطه ۴ خواهد بود.

$$f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad (4)$$

$$st \quad \bar{w}_1 = \frac{w_1}{w_1 + w_2},$$

$$\bar{w}_2 = \frac{w_2}{w_1 + w_2}$$

ساختار معادل ANFIS که از پنج لایه به صورت زیر
تشکیل شده در شکل ۲ آمده است.
لایه اول: (گره‌های ورودی) در این لایه، درجه عضویت
گره‌های ورودی به بازه‌های مختلف فازی با استفاده از تابع
عضویت، مشخص می‌شود (روابط ۵ و ۶):

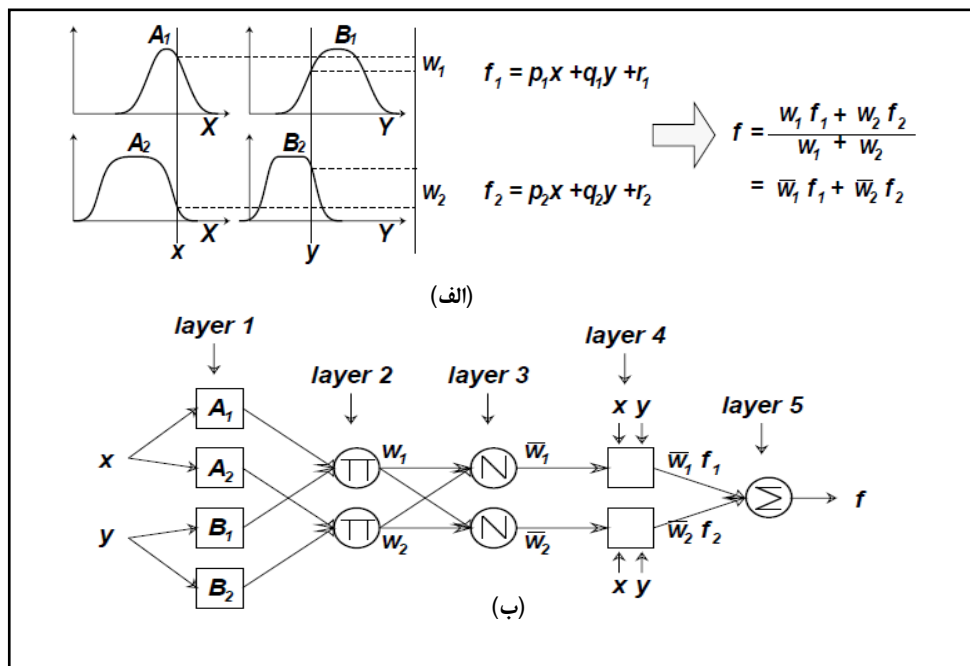
$$O_{1,i} = \mu A_i(x), \quad \text{for } i=1,2 \quad (5)$$

$$O_{1,i} = \mu B_i(y), \quad \text{for } i=1,2 \quad (6)$$

تابع عضویت گوسین^۱ $\mu A_i(x)$ به صورت رابطه ۷ بیان
می‌شود.

$$\mu A_i(x) = \exp \left[- \left(\frac{x - c_i}{a_i} \right)^2 \right] \quad (7)$$

که در آن،



شکل ۲- (الف) مدل فازی مرتبه اول سوگنو و (ب) ساختار ANFIS

پیش‌بینی وجود دارد که به طور عمده بر اساس اختلاف بین خروجی‌های پیش‌بینی شده و خروجی‌های مطلوب و واقعی استوارند. برای ارزیابی عملکرد مدل از پارامترهای RMSE، درصد خطای نسبی (ε)، MAE، ضریب تبیین (R^2)، ضریب باقیمانده جرم (CRM) و کارایی مدل (EF) استفاده شد (روابط ۱۲ تا ۱۷). بهترین پیش‌بینی‌ها زمانی رخ می‌دهد که MAE، CRM، ε ، RMSE به صفر و EF و R^2 به یک میل کنند.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_i - P_i)^2} \quad (12)$$

$$\varepsilon = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{Q_i - P_i}{Q_i} \right| \quad (13)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Q_i - P_i| \quad (14)$$

$$R^2 = \frac{\left[\sum_{i=1}^N (P_i - \bar{P})(Q_i - \bar{Q}) \right]^2}{\sum_{i=1}^N (P_i - \bar{P})^2 \sum_{i=1}^N (Q_i - \bar{Q})^2} \quad (15)$$

ارزیابی عملکرد مدل

در تحقیق حاضر از روش هیبرید برای بهینه‌سازی شبکه استفاده شد. در این روش، بر اساس نظر عقیل و همکاران (Aqil et al., 2007) همچنین ایلماز و کاینار (Yilmaz & Kaynar, 2011)، از ورودی‌های مدل برای تعیین قوانین در لایه اول استفاده می‌شود و روش‌های مختلفی برای انتخاب قوانین موجود است.

برای استفاده از این روش باید داده‌ها نرمال شوند زیرا تحقیقات لوک و همکاران (Luk et al., 2000) نشان داده است که داده‌های نرمال شده در منطق فازی نتایج بهتری خواهند داشت. محققانی چون فینل و همکاران (Finol et al., 2001) و گکسلو (Gokceoglu, 2002) و کاراکوس و تاتمس (Karakus & Tutmes, 2006) پارامترهای آماری مجذور میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) را برای ارزیابی دقت مدل‌های مبتنی بر شبکه عصبی و منطق فازی به کار برده‌اند. معیارهای مختلفی برای ارزیابی مدل‌های

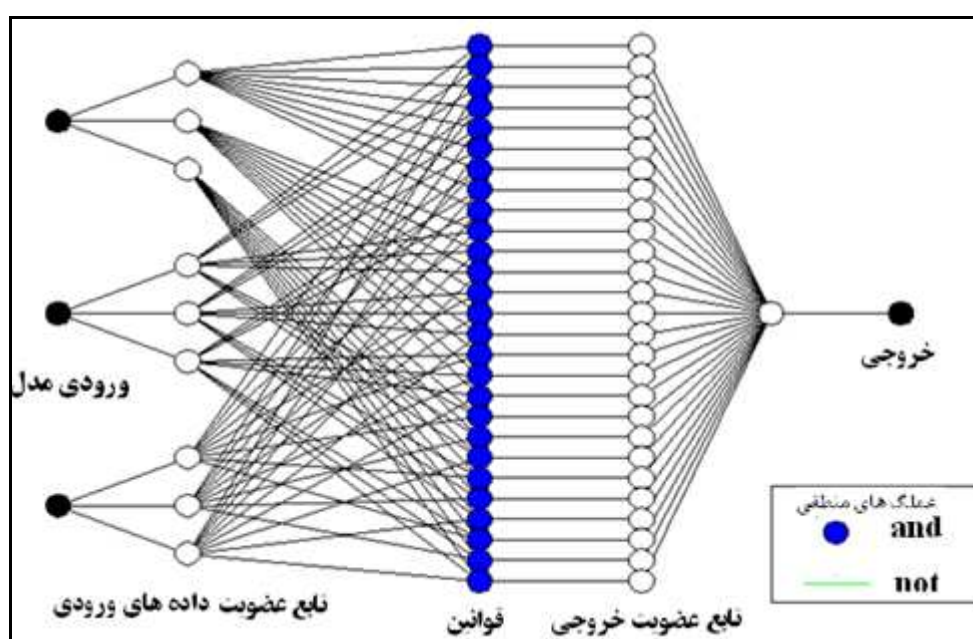
Q_i = مقادیر واقعی؛ \bar{P} = میانگین مقادیر پیش‌بینی شده توسط مدل؛ و \bar{Q} = میانگین مقادیر واقعی (Jacovides, 1997). در این تحقیق، مدل ANFIS با سه ورودی درصد شن، سیلت و رس و خروجی هدایت هیدرولیکی اشباع خاک در نرم‌افزار (MATLAB (Version 7.12.0) و در قسمت Fuzzy Logic Toolbox ایجاد شد. شکل ۳ ساختار مدل را نشان می‌دهد.

$$CRM = \frac{\sum_{i=1}^N Q_i - \sum_{i=1}^N P_i}{\sum_{i=1}^N Q_i} \quad (16)$$

$$EF = \frac{\sum_{i=1}^N (Q_i - \bar{Q})^2 - \sum_{i=1}^N (P_i - Q_i)^2}{\sum_{i=1}^N (Q_i - \bar{Q})^2} \quad (17)$$

که در آنها،

N = تعداد نمونه؛ P_i = مقادیر پیش‌بینی شده توسط مدل؛



شکل ۳- ساختار مدل ANFIS برای برای برآورد هدایت هیدرولیکی اشباع خاک با استفاده از بافت خاک


نتایج و بحث

روش، ترکیبی از روش حداقل مربعات و روش کاهش شیب پسانتشار است که به همین دلیل در این تحقیق نسبت به روش پسانتشار برتری داده شده است. از آنجا که تابع عضویت گوسی از مزیت‌های نرمی و مقدار غیر صفر در کلیه نقاط برخوردار است، و تغییرات آن برای عضویت داده‌های ورودی به مقادیر کم، متوسط و زیاد بدون چولگی و متقارن است، از این رو در این تحقیق از تابع عضویت مذکور استفاده شد. همچنین، از آنجا که مدل ANFIS فقط در مورد سیستم‌های سوگنو^۲ کاربرد


در مدل ANFIS برای توابع عضویت متغیرهای ورودی از تابع عضویت گوسین و متغیرهای زبانی پایین، متوسط و بالا استفاده شد (شکل ۴). مدل ANFIS شامل ۲۷ قانون و ۷۸ گره است و همچنین ۱۰۸ پارامتر خطی (در لایه^۱ دوم)، ۱۸ پارامتر غیرخطی (در لایه^۱ اول) و در کل ۱۲۶ پارامتر دارد. برای آموزش سیستم استنتاج فازی از روش هیبرید استفاده شد. از روش بهینه‌سازی هیبرید^۱ برای آموزش پارامترهای تابع عضویت استفاده می‌شود و این

مقدار R^2 برابر ۰/۹۹ و مقدار RMSE برابر ۰/۰۳۲ سانتی متر بر روز است که توانایی مدل ANFIS در ایجاد ارتباط بین ورودی و خروجی و نزدیکی نتایج به مقادیر اندازه‌گیری شده را نشان می‌دهد. نتایج این تحقیق از نتایج مطالعات اقیار و همکاران (Agyare et al., 2007)، که مقدار RMSE را برابر ۰/۴ و R^2 را برابر ۰/۶ برآورد کرده‌اند بسیار دقیق‌تر است. همچنین، در تحقیقات نادرلو و همکاران (Naderloo et al., 2012)، مقدار R^2 برابر ۰/۹۵ و مقدار RMSE برابر ۰/۴۴ برآورد شده است که هدایت هیدرولیکی برآورد شده در این تحقیق به مقادیر اندازه‌گیری شده نزدیکتر است.

دارد و این سیستم‌ها دارای توابع عضویت خروجی خطی هستند، لذا تابع عضویت خروجی مدل ANFIS نیز از نوع خطی بود. شکل ۵ رابطه بین RMSE و تکرار را برای مراحل آموزش و واریس و شکل ۶ نتایج خروجی مدل فازی ANFIS به صورت نمودارهای سه‌بعدی بر حسب پارامترهای ورودی و خروجی است که تأثیر تغییرات پارامترهای ورودی (رس، سیلت و شن) را بر خروجی مدل (هدایت هیدرولیکی) نشان می‌دهد. جدول ۱ خصوصیات مدل ANFIS و ارزیابی آن را بر اساس پارامترهای آماری RMSE، درصد خطای نسبی (ϵ)، MAE و ضریب تبیین ارائه می‌کند. همان‌طور که در جدول ۱ مشخص است،



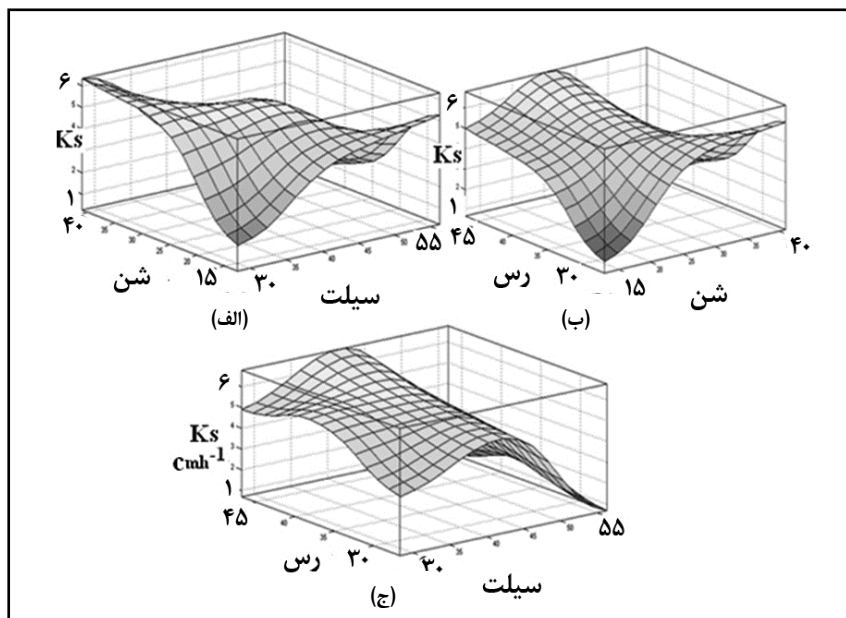
شکل ۴- توابع عضویت متغیرهای ورودی: درصد شن، سیلت و رس



شکل ۵- تعداد تکرارها در مقابل مجذور میانگین مربعات خطا برای آموزش و واریسی داده‌ها

جدول ۱- خصوصیات مدل ANFIS و ارزیابی آن بر اساس پارامترهای آماری

ضریب تبیین	MAE (سانتی‌متر بر روز)	خطای نسبی (درصد)	RMSE (سانتی‌متر بر روز)	روش بهینه‌سازی	تعداد پارمترها		نوع تابع عضویت	
					ورودی	تکرار	خروجی	ورودی
۰/۹۹۷	۰/۱۸	۰/۶۲۷	۰/۰۳۲	هیبرید	۳	۳۰	خطی	گوسی



شکل ۶- هدایت هیدرولیکی اشباع خاک در مقابل: (الف) درصد شن و سیلت، (ب) درصد شن و رس و (ج) درصد رس و سیلت

پارامترهای آموزشی و تابع عملکرد انتخاب شدند، آموزش شبکه با استفاده از هر یک از الگوریتم‌ها، ابتدا با یک نرون پنهان و ۲ اپوک، شروع شد و با افزایش آن تا حداکثر

پس از آنکه داده‌های ورودی و خروجی شبکه نرمال شدند، الگوریتم آموزشی، تابع انتقال، تعداد نرون‌های لایه پنهان، تعداد لایه‌های پنهان، تعداد تکرار (اپوک)، مقادیر

غیرخطی در MLP افزایش و در نتیجه میزان همگرایی شبکه عصبی کاهش یابد. حتی ممکن است با افزایش تعداد لایه‌های مخفی و تشدید حالت غیرخطی، MLP در فاز آموزش دچار نوسان‌های شدید یا واگرایی شود. به همین دلیل در کاربردهای عملی MLP، به ندرت بیش از سه لایه مخفی انتخاب می‌شود. در استفاده از MLP برای حل مسائل مهندسی، عمدتاً از یک یا حداکثر دو لایه مخفی استفاده می‌شود.

به طور کلی در کاربردهای عملی، MLP با یک لایه مخفی بیشترین استفاده را دارد. نرون‌های مخفی اگر در یک لایه قرار داشته باشند، چون به طور موازی با هم قرار می‌گیرند، تأثیر کمتری در افزایش حالت غیرخطی MLP خواهند داشت. افزایش توان پردازش عاملی در جهت افزایش تعداد نرون‌های مخفی است، در حالی که کاهش حالت غیرخطی عاملی در جهت کاهش تعداد این نرون‌هاست. معمولاً تعداد نرون‌های مخفی در MLP با مصالحه‌ای بین این دو عامل انتخاب می‌شود.

تاکنون الگوریتم کلی برای این امر به جز در موارد خاص ارائه نشده است و تعداد نرون‌های مخفی غالباً با اتکا به تجربه‌های پیشین یا با استفاده از روش سعی و خطا انتخاب می‌شود (Amjadi, 2002). در شبکه عصبی پرسپترون چند لایه برای نرون‌های لایه خروجی معمولاً از تابع انتقال سیگموئید یا تانژانت سیگموئید (همانند لایه‌های مخفی) استفاده می‌شود. به عبارت دیگر، می‌توان گفت که لایه ورودی و لایه خروجی، مرز MLP با دنیای بیرون را تشکیل می‌دهند (Amjadi, 2002)

تعداد نرون‌های لایه پنهان یا مخفی عموماً به طور تجربی به دست می‌آید؛ برای شبکه‌ای عصبی با اندازه‌های معقول تعداد نرون‌های پنهان با نسبتی کوچک از تعداد ورودی‌ها انتخاب می‌شود. اگر MLP به جواب مطلوب همگرا نشود، تعداد نرون‌های لایه پنهان را افزایش

تعداد نرون و تکرار ادامه یافت. در تمام مراحل فوق پس از هر بار آموزش، شبکه ارزیابی شد. برای ارزیابی بهتر عملکرد و انتخاب شبکه بهینه به آنالیز رگرسیونی و تعیین ضریب همبستگی بین داده‌های ورودی و خروجی در مرحله آموزش و درصد خطا در مرحله ارزیابی اقدام گردید. تعداد بهینه نرون پنهان و تکرار در الگوریتم‌های آموزشی بر اساس بالاترین ضریب همبستگی مشخص می‌شود. با داشتن تعداد بهینه نرون پنهان و تکرار، می‌توان با استفاده از روش سعی و خطا در نوع تابع انتقال، مقادیر پارامترهای آموزشی و تعداد لایه‌های میانی تجدید نظر کرد تا شبکه، اگر عملکردی بهتر پیدا کرد به عنوان شبکه بهینه انتخاب شود. در هر صورت، بهترین نوع شبکه بر اساس بالاترین ضریب همبستگی در مرحله آموزش و پایین‌ترین خطا در مرحله ارزیابی تعیین شد. برای یافتن حالت بهینه شبکه عصبی مصنوعی از توابع انتقال مختلفی از جمله تابع لگاریتم سیگموئید^۱، تابع خطی^۲ و تانژانت سیگموئید^۳ و همچنین برای بهینه‌سازی وزن‌های شبکه‌های پرسپترون از الگوریتم آموزشی لونبرگ-مارکوت استفاده شد. الگوریتم لونبرگ-مارکوت، سریع‌ترین روش برای شبکه‌های پیش‌خور با اندازه معمول است و با تابع trainlm اجرا می‌شود (Demuth & Beale, 2000).

برای هر شبکه ANN، ابتدا با تکرارهای متفاوت، مقادیر ضریب تبیین و RMSE بررسی شد. بعد از آنکه تعداد لایه، تعداد نرون، توابع انتقال و الگوریتم آموزش تعیین شد، آموزش شبکه آغاز و وزن‌های نهایی نرون‌ها تعیین شد. در کاربردهای عملی، به طور معمول تعداد نرون‌های مخفی و به خصوص تعداد لایه‌های مخفی در MLP از حدی بیشتر افزایش داده نمی‌شود. از آنجا که لایه‌های مخفی به طور سری با هم قرار دارند، نرون‌هایشان در نتیجه پردازش با هم ترکیب می‌شود. این امر موجب خواهد شد که با افزایش تعداد لایه‌های مخفی حالت

1- Logsig(n)

3- Tansig(n)

2- Purlin(n)

مقادیر بالای ضریب تبیین و مقدار پایین خطا در مراحل آموزش و آزمون شبکه مؤید این مطلب است که مدل شبکه عصبی به خوبی توانسته هدایت هیدرولیکی اشباع خاک را با استفاده از خصوصیات زودیافت خاک تخمین بزند. بدیهی است که هر چه مقدار ضریب تبیین بیشتر (و به یک نزدیکتر) باشد، و هر چه مقدار خطا کمتر (و به صفر نزدیکتر) باشد، دقت پیش‌بینی مدل بیشتر خواهد بود. با توجه به دقت مدل شبکه عصبی به کار رفته در این تحقیق، نتایج این تحقیق با نتایج تحقیق سالازار و همکاران (Salazar et al., 2008)، که هدایت هیدرولیکی اشباع را با استفاده از مدل رزتاً^۱ برآورد کرده بودند، مطابقت نمی‌کند؛ این محققان در بررسی‌های خود مقدار هدایت هیدرولیکی اشباع را با استفاده از مدل رزتاً، که دارای ماهیت شبکه عصبی است، ۱۵ درصد از مقادیر واقعی کمتر برآورد کرده‌اند.

می‌دهند و اگر شبکه همگرا گردید و از قدرت تعمیم خوبی هم برخوردار بود در صورت امکان تعداد نرون‌های پنهان کمتری را می‌آزمایند. در نهایت می‌توان یک مقدار مناسب برای تعداد نرون‌های لایه پنهان بر اساس عملکرد کلی سیستم تعیین کرد؛ حداکثر تعداد این نرون‌ها باید طوری تعیین شود که پارامترهای شبکه بیشتر از داده‌های یادگیری نگردد (Menhaj, 1998).

معماری انتخاب شده برای شبکه عصبی این پژوهش دارای ۳ نرون در لایه ورودی، ۱۱ نرون در لایه پنهان با تابع انتقال تانژانت سیگموئید و یک نرون در لایه خروجی با تابع انتقال خطی با تعداد تکرار ۱۰۰۰ است. در تمام شبکه از سرعت یادگیری و مومنتم مساوی با ۰/۳ استفاده شده است. نتایج حاصل از این مدل در برابر داده‌های اندازه‌گیری شده، رسم شد و با برازش بهترین خط عبوری از میان آنها، مقادیر ضریب تبیین و خطا محاسبه شدند (جدول ۲).

جدول ۲- شاخص‌های کمی ارزیابی شبکه‌های ساخته شده با استفاده از الگوریتم آموزشی لونیبرگ-مارکوت

تعداد نرون‌ها	پارامترهای شبکه		پارامترهای آماری شبکه			ضرایب همبستگی شبکه		میانگین دقت شبیه‌سازی (درصد)
	سرعت یادگیری	مومنتم	RMSE (سانتی‌متر بر روز)	ضریب تبیین	آموزش	ارزیابی	آزمون	
۱۱	۰/۳	۰/۳	۱/۲۲	۰/۹۹۷	۰/۹۹۹	۰/۹۹۶	۰/۹۹۸	۹۹/۷

مدل ANFIS نسبت به مدل ANN در پیش‌بینی هدایت هیدرولیکی اشباع خاک دقت بالاتری دارد. نتایج این تحقیق با نتایج تحقیق کیانپور و کلخواجه (Kianpur-Kalkhajeh, 2012) و فیروزی و همکاران (Firoozi et al., 2014) همخوانی ندارد؛ در تحقیقات این پژوهشگران، مدل ANN در مقایسه با مدل ANFIS، در تعیین هدایت هیدرولیکی اشباع خاک از پارامترهای زودیافت خاک نتایج دقیق‌تری ارائه داده است.

برای مقایسه دقت دو مدل در تعیین هدایت هیدرولیکی اشباع منطقه، جدول ۳ میزان هدایت هیدرولیکی برآورد شده توسط مدل‌ها را در مرحله واری و جدول ۴ شاخص‌های کمی ارزیابی مدل ANN و ANFIS را بر اساس پارامترهای RMSE، درصد خطای نسبی (ε)، MAE و ضریب تبیین نشان می‌دهد. اگرچه روش شبکه عصبی مصنوعی توانسته هدایت هیدرولیکی اشباع در منطقه را به خوبی برآورد کند، اما مقایسه عملکرد مدل‌ها نشان می‌دهد که

جدول ۳- هدایت هیدرولیکی اشباع برآورد شده توسط مدل‌های شبکه عصبی و ANFIS در مرحله وارسی (سانتی‌متر در روز)

مقادیر اندازه‌گیری شده	برآورد شده با مدل ANFIS	برآورد شده با مدل ANN
۱۲۶/۵۲۸۹	۱۲۶/۵۱۵۴	۱۲۶/۵۲۸۸
۱۲۹/۵۵۸۹	۱۲۹/۵۵۴۲	۱۲۹/۵۵۸۸
۱۱۰/۶۵۵۹	۱۱۰/۸۹۶۱	۱۱۰/۶۵۵۹
۱۱۵/۰۷۵۹	۱۱۵/۰۸۳۳	۱۱۵/۰۷۵۹
۱۱۹/۹۶۲۹	۱۱۹/۹۲۴۸	۱۱۹/۹۶۲۶
۱۲۵/۵۱۵۹	۱۲۵/۴۵۶۶	۱۲۵/۵۱۶۰
۱۲۸/۱۵۲۹	۱۲۸/۱۷۸۱	۱۲۸/۱۵۲۹
۱۲۹/۷۴۲۹	۱۲۹/۷۲۵۱	۱۲۹/۷۴۲۸
۱۳۰/۰۱۰۹	۱۳۰/۰۱۱۰	۱۳۰/۰۱۰۷
۱۳۷/۴۴۰۹	۱۳۷/۵۰۷۴	۱۳۷/۴۴۰۷
۱۳۴/۲۴۳۹	۱۳۴/۳۰۱۱	۱۳۴/۲۴۳۶
۱۲۸/۲۹۳۹	۱۲۸/۲۶۶۸	۱۲۸/۲۹۳۹
۱۳۳/۴۸۳۹	۱۳۳/۵۳۹۳	۱۳۳/۴۸۳۹
۱۲۴/۶۴۷۹	۱۲۴/۶۴۴۰	۱۲۴/۶۴۷۷
۱۱۸/۵۵۳۹	۱۱۸/۵۱۳۸	۱۱۸/۵۵۴۲

جدول ۴- شاخص‌های عملکردی مدل‌ها

مدل	راندمان مدل	ضریب جرم باقیمانده	RMSE (سانتی‌متر بر روز)	MAE (سانتی‌متر بر روز)	خطای نسبی (درصد)	ضریب تبیین
ANFIS	۰/۹۹۹	-۰/۰۰۰۰۰۲۳	۰/۰۳۲	۰/۱۸	۰/۶۲	۰/۹۹۷
ANN	۰/۹۹۷	-۰/۰۰۰۰۱۵	۱/۲۲	۱/۲۱	۱/۲۴	۰/۹۹

نتیجه‌گیری

در این تحقیق از سیستم استنتاج فازی- عصبی (ANFIS) و شبکه عصبی مصنوعی (ANN) برای برآورد هدایت هیدرولیکی اشباع خاک استفاده شد. معماری بهینه انتخاب شده برای شبکه عصبی دارای ۳ نرون در لایه ورودی، ۱۱ نرون در لایه پنهان با تابع انتقال تانژانت سیگموئید و یک نرون در لایه خروجی با تابع انتقال خطی با تعداد تکرار ۱۰۰۰ است. در قسمت آموزش شبکه‌های عصبی می‌توان با اعمال عددی بین صفر و یک به عنوان مومنتوم^۱ در الگوریتم traindm به شبکه اجازه داد تا علاوه بر تغییرات شیب به تغییرات سطح خطا نیز واکنش نشان دهد و همگرایی سریع‌تر و دقیق‌تری را سبب شود که در

تحقیق مذکور مقدار ۰/۳ برای میزان آموزش و مومنتوم دارای کمترین واریانس خطا شد لذا در تمام شبکه از سرعت یادگیری و مومنتم مساوی با ۰/۳ استفاده شد. سیستم استنتاج فازی- عصبی دارای ۲۷ قانون است و برای تابع عضویت متغیرهای ورودی از تابع گوسین و برای آموزش سیستم استنتاج فازی- عصبی از روش هیبرید استفاده شد. همچنین، برای ارزیابی این مدل‌ها از پارامترهای آماری RMSE، درصد خطای نسبی، MAE و ضریب تبیین و آماره‌های ضریب جرم باقیمانده و راندمان مدل بهره گرفته شد. نتایج تحقیقات نشان می‌دهد که هر دو روش در تعیین میزان هدایت هیدرولیکی اشباع خاک دقت بالایی دارند اما دقت سیستم ANFIS، نسبت به

رگرسیون خطی می‌تواند از روش شبکه عصبی دقیق‌تر باشد. نتایج این تحقیق نشان می‌دهد که با استفاده از داده‌های بیشتر در مرحله آموزش و ساختار شبکه عصبی ساده‌تر از لحاظ تعداد لایه‌های پنهان و نرون‌های لایه پنهان، برای جلوگیری از پیچیدگی فرآیند آموزش شبکه عصبی، می‌توان نتایج دقیق‌تری را به دست آورد و کارایی شبکه عصبی را در پیش‌بینی فرآیندهای مربوط به خاک افزایش داد. به طور مثال، رحمان و مهندس (Rehman & Mohandes, 2008) برای برآورد تابش خورشیدی در شهر آبهای عربستان سعودی از دما و رطوبت نسبی با دوره آماری ۵ ساله (۲۰۰۲-۱۹۹۸) استفاده کردند. نتایج به دست آمده نشان داد که شبکه‌های عصبی قادرند تابش خورشیدی را تنها از دما و رطوبت نسبی برآورد کنند که می‌تواند برای برآورد تابش خورشیدی مناطقی که فقط دما و رطوبت در آن اندازه‌گیری می‌شود، به کار گرفته شود.

طبق نظر شاپ و لیج (Schaap & Leij, 1998) در طراحی شبکه‌های عصبی نوع خاصی از معادلات لازم نخواهد بود و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست یافت و به علت وجود روابط غیرخطی میان متغیرهای وابسته و پیش‌بینی شونده شبکه عصبی می‌تواند نتایج را با تشخیص این روابط غیرخطی به شکلی دقیق پیش‌بینی کند. همان‌طور که نتایج تحقیقات تاماری و همکاران (Tamari et al., 1996) نشان داده است مدل شبکه عصبی ممکن است در مواردی که داده‌ها ناپایدارند و دقت کافی ندارند، نتایج دقیق را پیش‌بینی نکند. از آنجا که داده‌های مربوط به خاک با این خصیصه همراهند، نتایج تحقیق نشان می‌دهد که در منطقه مذکور، با فرض وجود داده‌های با دقت پایین در مجموعه داده‌های ورودی، مدل با قابلیت غیرخطی خود توانسته است تاثیر این داده‌ها را در نتایج به حداقل برساند. به نظر می‌رسد که افزایش نرون‌ها در لایه پنهان می‌تواند تأثیر

ANN، بالاتر است و نتایج نیز به داده‌های اندازه‌گیری شده نزدیکتر است. نتایج نشان می‌دهد که با در نظر گرفتن بافت خاک به عنوان پارامتر حساس و مهم در تعیین هدایت هیدرولیکی خاک، هر دو سیستم هدایت هیدرولیکی خاک را با دقت بالا پیش‌بینی کردند؛ دلیل آن ممکن است تعداد بالای داده‌های ورودی به مدل برای آموزش سیستم باشد که هر دو مدل را قادر به آموزش مناسب سیستم کرده و خطای محاسبات را به کمترین مقدار رسانده است. علاوه بر این، افزایش تعداد داده ورودی به مدل می‌تواند خطای ناشی از بی‌دقتی در اندازه‌گیری تعدادی از داده‌های ورودی را در مرحله آموزش در سیستم‌های نورو فازی و شبکه‌های عصبی خنثی کند که ممکن است علت دقت مدل‌های دیگر در مقابل سیستم‌های نورو فازی و شبکه‌های عصبی ناشی از به کارگیری تعداد پایین داده‌های ورودی در مرحله آموزش باشد. نتایج بررسی‌ها نشان می‌دهد که سیستم ANFIS به دلیل ساختار ساده و استفاده از قواعدی که بر پایه داده‌های اندازه‌گیری شده نوشته شده است و همچنین به دلیل ایجاد رابطه‌ای خطی‌تر بین داده‌های ورودی و خروجی، برآورد دقیق‌تری از هدایت هیدرولیکی اشباع خاک با استفاده از بافت خاک ارائه می‌دهد. نتایج بررسی‌ها همچنین نشان می‌دهد که پارامترهای درصد اندازه ذرات خاک مهم‌ترین و حساس‌ترین پارامترهای زودیافت خاک در تعیین هدایت هیدرولیکی اشباع خاک هستند. این موضوع در تحقیق رضایی‌ارشد (Rezaie-Arshad, 2010) نیز تایید شده است؛ وی در تحقیق خود با در نظر گرفتن پارامترهای مختلف در تعیین نفوذپذیری نهایی در خاک با استفاده از MLP، به این نتیجه رسید که شبکه عصبی با ورودی رس، سیلت و شن بیشترین دقت را در برآورد نفوذ نهایی خاک دارد. این پژوهشگر همچنین مشخص می‌کند که اگر ورودی‌های شبکه عصبی داده‌های کمی داشته باشد، نتایج روش

بی‌دقتی در برخی از داده‌های اندازه‌گیری شده را در برآورد نهایی مدل کاهش دهد. همچنین، نتایج نشان می‌دهد که تابع عضویت گوسی در مدل ANFIS به دلیل مزیت نرمی و داشتن مقدار غیر صفر در کلیه نقاط و همچنین با توجه به اینکه عضویت داده‌های ورودی (درصد اندازه ذرات خاک) به مقادیر کم، متوسط و زیاد بدون چولگی است و تغییرات نرمی ندارند، این تابع برای مسائل مربوط به خاک در مدل‌های نورو- فازی تابعی مناسب باشد.

قدردانی

این مقاله با حمایت معاونت محترم پژوهشی دانشگاه محقق اردبیلی طی قرارداد طرح شماره ۹۲/۵/۹/۵۶۸۷، تهیه شده است و از ایشان قدردانی می‌شود.

مراجع

- Agyare, W. A., Park, S. J. and Vlek, P. L. G. 2007. Artificial neural network estimation of saturated hydraulic conductivity. *Vadose Zone J.* 6(2): 423-431.
- Amir-Abedi, H. 2012. Estimation soil hydraulic properties of Ardabil plain using artificial neural networks and regression methods. M. Sc. Thesis. Faculty of Agricultural Technology and Natural Resources. University of Mohaghegh Ardabili. (in Persian)
- Amjadi, N. 2002. Introduction to Intelligent Systems. Semnan University Press. (in Persian)
- Anon. 2008. MATLAB software help manual. Version 7.6.0.2008b. The Math Works, Inc.
- Aqil, M., Kita, I., Yano, A. and Nishiyama, S. 2007. A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff. *J. Hydrol.* 337(1-2): 22-34.
- Demuth, H. and Beale, M. 2000. Neural network toolbox user Guide. Copyright 1992-2002. By The Math Works, Inc. Version 4.
- Finol, J., Guo, Y. K. and Jing, X. D. 2001. A rule based fuzzy model for the prediction of petrophysical rock parameters. *J. Petrol. Sci. Eng.* 29, 97-113.
- Firoozi, S., Sheikhdavoodi, M. J. and Sami, M. 2014. Evaluation the ability of different artificial intelligence-based modeling techniques in prediction of yield using energy inputs data of farms. *J. life Sci. Biomed.* 4(3): 214-220.
- Givi, J., Prasher, S. O. and Patel, R. M. 2004. Evaluation of pedotransfer functions in predicting the soil water contents at field capacity and wilting point. *Agri. Water Manage.* 70, 83-96.
- Gokceoglu, C. 2002. A fuzzy triangular chart to predict the uniaxial compressive strength of the Ankara agglomerates from their petrographic composition. *Eng. Geol.* 66, 39-51.
- Heuscher, S. A., Brandt, C. C. and Jardin, P. M. 2005. Using soil physical and chemical properties to estimate bulk density. *Soil Sci. Soc. Am. J.* 69, 51-56.
- Jacovides, C. P. 1997. Reply to comment on Statistical procedures for the evaluation of evapotranspiration models. *Agri. Water Manage.* 3, 95-97.
- Jang, J. S. R. 1993. ANFIS: Adaptive Network Based Fuzzy Inference System. *IEEE Trans. Syst. Man Cybern.* 23 (3): 665-685.
- Jang, J. S. R. and Sun, C. T. 1997. Neuro-fuzzy modeling and control. *Proceedings of the IEEE.* 83(3): 378-406.

- Karakus, M. and Tutmez. B. 2006. Fuzzy and multiple regression modeling for evaluation of intact rock strength based on point load, Schmidt hammer and sonic velocity, *Rock Mech. Rock Eng.* 39(1): 45-57.
- Karatalopoulos, S. V. 2000. *Understanding Neural Networks and Fuzzy Logic-Basic Concepts and Applications*. Wiley-IEEE Press. New-Delhi. India.
- Kianpur-Kalkhajeh, U., Rezaie-Arshad, R., Amerikhah, H. and Sami. M. 2010. Multiple linear regression, artificial neural network (MLP, RBF) and ANFIS models for modeling the saturated hydraulic conductivity of tropical region soils (case study: Khuzestan province: sothwest Iran). *Int. J. Agr. Res and Rev.* 2(3): 255-265
- Lippman, R. P. 1987. An introduction to computing with neural nets. *ASSP Magazine, IEEE.* 4(2):4-22.
- Luk, K. C., Ball, J. E. and Sharma. A. 2000. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. *J. Hydrol.* 227(1-4): 56-65.
- Marshal, T. J. 1958. A relationship between permeability and size distribution of pores. *Soil Sci.* 9, 1-8.
- Menhaj, M. B. 1998. *Principle of Neural Networks*. First edition. Professor Hesabi Publishing Center. Tehran. Iran.
- 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(1-2): 108-116.
- Mohammadi, J. 2002. Testing an artificial neural network for predicting soil water retention characteristics from soil physical and chemical properties. 17th WCSS. Thailand. Paper No. 221.
- Mohammadi, J. and Taheri, M. 2005. Estimation of pedotransfer function using fuzzy regression. *J. Agric. Sci. Technol.* 9(2): 51-60. (in Persian)
- Naderloo, L., Alimardani, R., Omid, M., Sarmadian, F., Javadikia, P., Yaser Torabi, M. and Alimardani. F. 2012. Application of ANFIS to predict crop yield based on different energy inputs. *Measurement.* 45, 1406-1413.
- Nosrati-Karizak, F., Movahhedi-Naieni, S. A. R., Hezarjaribi, A., Roshani, Gh. A. and Dehghani, A. H. 2012. Using artificial neural networks to estimate the saturated hydraulic conductivity of readily available soil properties. *Soil Manage. Sustain. Prod.* 2(1): 95-110.
- Rahimi-Ajdadi, F. and Abbaspour-Gilandeh. Y. 2011. Artificial neural network and stepwise multiple range regression methods for prediction of tractor fuel consumption. *Measurement.* 44(10): 2104-2111.
- Rawls, W. J. 2004. Pedotransfer functions for the United States. *Dev. Soil Sci.* 30, 437-447.
- Rehman, S. and Mohandes, M. 2008. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energ. Policy.* 36, 571-576.
- Rezaie-Arshad. R. 2010. Expansion pedo transfer functions of soil hydraulic conductivity with artificial neural networks and statistical regression methods for Khouzeestan province soils. M.S Thesis. Faculty of Agricultural Science. University of Shahid Chamran. (in Persian)
- Salazar, O., Wesstrom, I. and Joel. A. 2008. Evaluation of Drainmod using saturated hydraulic conductivity estimated by a pedotransfer function model. *J. Agr. Water Manage.* 95, 1135-1143.
- Sarmadian, F., Taghizadeh-Mehrjerdi, R., Mohammad-Askari, H. and Akbarzadeh, A. 2010. Comparison of nero fuzzy, neural network and multiple regression methods to predicting some soil properties (Case Study: Golestan province). *Iranian J. Soil Water Res.* 41(1): 211-220.

- Schaap, M. G. and Leij, F. J. 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil Till. Res.* 47, 37-42.
- Soltani, S. and Morid, S. 2002. Comparison of Conceptual model with artificial neural network to simulate rainfall-runoff process. *Proceeding of the 6th International River Engineering Conference*. Shahid Chamran University. Ahvaz. Iran. (in Persian)
- Tamari, S., Wosten, J. H. M. and Ruz-suarez, J. C. 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Sci. Soc. Am. J.* 60, 1732-1741.
- Vos, B. D., Meirvenne, M. V., Quataert, P., Deckers, J. and Muys, B. 2005. Predictive quality of pedotransfer functions for estimating bulk density of forest soils. *Soil Sci. Soc. Am. J.* 69, 500-510.
- Wosten, J. H. M., Lilly, A. Nemes, A. and Bas, C. 1999. Development and use of a database of hydraulic properties of European soils. *Geoderma*. 90, 169-185.
- Yilmaz, I. and Kaynar, O. 2011. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. *Expert Syst. Appl.* 38(5): 5958-5966.

Adaptive Neuro Fuzzy Inference System and Multilayer Perceptron Neural Networks to Estimate Saturated Hydraulic Conductivity by Soil Texture

A Case Study for Fath-Ali Irrigation Network in Moghan Plain

Y. Hoseini* and R. Sedghi

* Corresponding Author: Assistance Professor, Moghan College of Agriculture and Natural Resources, University of Mohaghegh, Ardabili, Iran. Email: yaser_hoseini@ymail.com

Received: 5 September 2015, Accepted: 9 January 2016

Direct measurement of soil hydraulic conductivity is time-consuming and expensive. Direct measurement of soil hydraulic properties can be replaced by simple measurement of properties such as soil texture and bulk density using transfer functions and an adaptive neuro fuzzy inference system (ANFIS). The present study used ANFIS and neural network models to estimate saturated soil hydraulic conductivity. The model inputs included percentage of silt, clay, and sand. The architecture for this network contained 3 neurons in the input layer and 11 neurons in the hidden layer using the tangent sigmoid transfer function, and an output layer of neurons with a linear transfer function and 1000 iterations. In all networks, the learning rate and momentum was 0.3. The neuro fuzzy inference system had 27 rules, a Gaussian membership function was used for input data, and a hybrid method was used to optimize the ANFIS model. The root mean square error (mmd^{-1}), percentage of relative error (ϵ), mean absolute error (cmd^{-1}), coefficient of residual mass, efficiency, and coefficient of determination were used to evaluate the performance of the model. For the ANFIS model, these values were 0.032, 0.62%, 0.18, -0.0000023, 0.999, and 0.997, respectively. The values for the Levenberg-Marquardt training algorithm were 1.22, 1.44%, 1.21, -0.00015, 0.997, and 0.99, respectively. Performance evaluation of the models showed that the ANFIS model predicted soil hydraulic conductivity with greater accuracy than did the neural network and the results of this method were closer to actual measurement results.

Keywords: ANFIS, ANN, Estimation, Saturated Hydraulic Conductivity, Soil Gradation