

Comparison of the Performance of Artificial Neural Networks and Gene Expression Programming in Estimating the Forest Soil Water Characteristic Curve

MOHAMMAD MAHDI JAFARI¹, HASSAN OJAGHLOU^{1*}, MASOUD KARBASI¹

1. Department of Water Sciences and Engineering, Faculty of Agriculture, University of Zanjan, Zanjan, Iran.

(Received: Apr. 29, 2021- Revised: June. 18, 2021- Accepted: June. 30, 2021)

ABSTRACT

One of the most important and practical physical parameters in studies of soil water flow is Soil Water Characteristic Curve (SWCC). Measuring the soil moisture characteristic curve through the direct method is expensive and time-consuming. For this reason, a variety of indirect methods including intelligent models have been developed. In this study, the performance of three models included multilayer perceptron neural networks (MLP), cascade neural network (Cascade-NN) and gene expression programming (GEP) were evaluated and compared to estimate of SWCC. The measured data from 108 soil samples, including soil particle size distribution, soil moisture in different suctions and the bulk density were used. In all models, three different input data combinations were used. Comparison of predicted and observed values of soil moisture showed acceptable performance of all three models, however, the Cascade-NN neural network model was relatively superior. The R^2 values of test phase for the best structure of the neural networks (MLP), neural networks (Cascade-NN) and gene expression programming (GEP) were 0.95, 0.96 and 0.93, respectively, and the RMSE values were 3.74, 3.25 and 4.10 %, respectively. Comparison of the results of different input data scenarios indicated the low accuracy and difference between the results of the models in the first scenario, but adding the parameters of porosity and moisture at field capacity point to the input data in the second and third scenarios, increased the accuracy and difference between the results achieved by the models. Finally, it can be emphasized that the cascade-NN model was introduced as the superior option, using all the mentioned physical data.

Keywords: Intelligent Models, Prediction, Soil Moisture, Suction.

مقایسه عملکرد شبکه‌های عصبی مصنوعی و برنامه‌ریزی بیان ژن در برآورد منحنی مشخصه آب در خاک‌های جنگلی

محمد مهدی جعفری^۱، حسن اوجاقلو^{۱*}، مسعود کرباسی^۱

۱. گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران.

(تاریخ دریافت: ۱۴۰۰/۲/۹ - تاریخ بازنگری: ۱۴۰۰/۳/۲۸ - تاریخ تصویب: ۱۴۰۰/۴/۹)

چکیده

منحنی مشخصه آب خاک یکی از پارامترهای فیزیکی مهم و کاربردی در مطالعات مرتبط با جریان آب در خاک شناخته می‌شود. روش مستقیم اندازه‌گیری منحنی مشخصه آب خاک مستلزم صرف زمان و هزینه بالایی است. به همین دلیل روش‌های غیرمستقیم متنوعی از جمله مدل‌های هوشمند توسعه پیدا نموده‌اند. در این تحقیق عملکرد سه روش شبکه‌های عصبی پرسپترون چندلایه (MLP)، شبکه‌های عصبی آبخاری (Cascade-NN) و برنامه‌ریزی بیان ژن (GEP) در برآورد منحنی مشخصه آب خاک مورد ارزیابی و مقایسه قرار گرفت. در این پژوهش اطلاعات اندازه‌گیری شده مربوط به تعداد ۱۰۸ نمونه خاک مناطق جنگلی شامل درصد توزیع اندازه ذرات خاک، مقادیر رطوبت در هفت مکش مختلف و جرم مخصوص ظاهری مورد استفاده قرار گرفت. سه سناریو شامل ترکیب‌های مختلف از داده‌های ورودی تعیین و مدل‌های مذکور برای هر کدام اجرا شد. مقایسه مقادیر پیش‌بینی شده و مشاهداتی رطوبت خاک نشان دهنده عملکرد قابل قبول هر سه مدل بود؛ برای مرحله آزمون مقادیر R^2 برای بهترین ساختار در سه روش شبکه‌های عصبی MLP، Cascade-NN و GEP به ترتیب ۰/۹۵، ۰/۹۶ و ۰/۹۳ و مقادیر RMSE نیز به ترتیب ۳/۷۴، ۳/۲۵ و ۴/۱۰ درصد بود. مقایسه نتایج سناریوهای مختلف داده ورودی نیز نشان داد، دقت و اختلاف بین نتایج مدل‌ها در سناریوی اول کم بود ولی در سناریوی دوم و سوم به ترتیب با اضافه شدن پارامترهای تخلخل و رطوبت نقطه ظرفیت زراعی به داده‌های ورودی، دقت و از سوی دیگر اختلاف بین نتایج مدل‌ها بیشتر شد. در نهایت شبکه‌های عصبی آبخاری با استفاده از تمام داده‌های فیزیکی اشاره شده به عنوان گزینه مطلوب شناخته شد.

واژه‌های کلیدی: پیش‌بینی، رطوبت خاک، مدل‌های هوشمند، مکش.

مقدمه

دستیابی به مدیریت صحیح آبیاری، ذخیره رطوبتی مطلوب خاک در مناطق خشک و عملکرد زراعی قابل قبول، نیازمند آگاهی از ویژگی‌های هیدرولیکی خاک است (Ghorbani Dashtaki and Homaei, 2002). میزان رطوبت خاک در مکش‌های مختلف، یکی از مهم‌ترین نمایه‌های هیدرولیکی خاک به عنوان ورودی در بیش-تر مدل‌های مرتبط با آب و خاک و به‌خصوص مطالعات مربوط به جریان غیراشباع آب در خاک است (Haghverdi et al., 2011; Sheikhesmaeili et al., 2016). به منظور تعیین منحنی مشخصه آب خاک دو روش مستقیم و غیرمستقیم وجود دارد. یکی از پرکاربردترین روش‌های مستقیم، استفاده از دستگاه‌های جعبه شنی و صفحات فشاری است که نتایج آن بالاترین دقت را در بین روش‌های مختلف دارد. اما این روش از یک سو نیازمند تجهیزات گران قیمت و بالقوه خطرناک بوده و از سوی دیگر مستلزم صرف زمان و هزینه زیادی است (Davari et al., 2019 Wosten et al., 2019).

(al., 2001). در سال‌های اخیر روش‌های غیرمستقیم شامل مدل‌های تجربی، رگرسیونی و هوشمند به منظور برآورد ویژگی‌های دیر یافت خاک از جمله منحنی مشخصه آب خاک و هدایت هیدرولیکی با استفاده از ویژگی‌های زود یافت مانند بافت، جرم مخصوص ظاهری، درصد مواد آلی خاک و غیره توسعه پیدا نموده‌اند (Mermoud and Xu, 2006). در بین روش‌های غیرمستقیم، مدل‌های هوشمند عملکرد قابل قبولی را از خود نشان داده‌اند به طوری که مطالعات مختلفی در زمینه کاربرد این روش‌ها در مدل‌سازی منحنی مشخصه رطوبتی خاک انجام گرفته است. شبکه‌های عصبی مصنوعی به عنوان یکی از مدل‌های هوشمند پیشرو در پیش‌بینی خصوصیات فیزیکی خاک به شمار می‌رود و مطالعات زیادی در این خصوص انجام گرفته است (Minasny and McBratney, 2002; Mohammadi, 2002; Lentzsch et al., 2005; Ryan et al., 2005; Akbarzadeh et al., 2009; Rahimi Lake et al., 2009; Zhu and Julian, 2011; Kianpoor Kalkhajah et al., 2012; Oliaei et al., 2019).

Cascade را جهت برآورد رسوب در استان لرستان مورد بررسی قرار دادند. (Zarei *et al.*, 2017) کارایی روش مذکور را در پیش-بینی و برآورد میزان رواناب حوزه‌های مناطق خشک مورد بررسی قرار دادند و عملکرد مناسب این روش را گزارش نمودند. (Ghorbani *et al.*, 2020) روش Cascade-NN را به منظور پیش-بینی جریان روزانه در دو رودخانه واقع در استرالیا به عنوان ابزاری مناسب و قابل قبول توصیف نمودند. کاربرد این رویکرد جدید از شبکه‌های عصبی مصنوعی در زمینه پیش‌بینی ویژگی‌های فیزیکی خاک از جمله منحنی مشخصه آب خاک مورد بررسی قرار نگرفته است. روش برنامه‌ریزی بیان ژن یکی دیگر از مدل‌های هوشمند و پرکاربرد در علوم آب و خاک بوده و با توجه به ارائه رابطه ریاضی بین ورودی‌ها و خروجی از مزیت نسبی برخوردار می‌باشد. عملکرد مطلوب این روش در زمینه‌های مختلف مرتبط با علوم مهندسی آب و خاک شامل مدل‌سازی جریان رودخانه (Solgi *et al.*, 2017; Dehghani *et al.*, 2017) پیش‌بینی خشکسالی (Abbasi *et al.*, 2020) یکنواختی پخش آب (Rostamlou *et al.*, 2018) برآورد تبخیر-تعرق مرجع (Traore and Guven, 2012; Shiri *et al.*, 2014) بزرگنمایی خاک‌های ماسه‌ای (Alidadi and Mahdavian, 2018) برآورد میزان اکسیژن محلول در آب رودخانه (Mehdipour *et al.*, 2017; Shahinejad and Dehaghani, 2018) شبیه‌سازی بارش- رواناب (Kisi *et al.*, 2013; Hosseini *et al.*, 2020) گزارش شده است. با این وجود کاربرد این روش در برآورد منحنی مشخصه آب خاک کمتر مورد توجه قرار گرفته است. (Mahmoudabadi *et al.*, 2017) به ارزیابی عملکرد رگرسیون چندمتغیره، شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در برآورد برخی خصوصیات خاک پرداختند. نتایج حاصل از ارزیابی مدل‌ها براساس آماره‌های RMSE و R^2 در مرحله آزمون نشان داد که شبکه عصبی مصنوعی پرسپترون، بهترین عملکرد را داشته است. در مطالعه‌ای دیگر، مدل برنامه‌ریزی بیان ژن به عنوان روش مناسب به منظور برآورد ظرفیت تبادل کاتیونی خاک معرفی شد (Emamgolizadeh *et al.*, 2015). (Johari and Hooshmand, 2015) به پیش‌بینی منحنی مشخصه رطوبتی خاک با استفاده از برنامه‌ریزی بیان ژن پرداختند. اطلاعات ورودی مدل شامل تخلخل، مقدار رطوبت اولیه، مکش و درصد ذرات شن، سیلت و رس بود. نتایج ایشان بیان کننده اثر قابل توجه مقدار رس خاک بر دقت پیش‌بینی منحنی مشخصه آب خاک بود. استفاده از مدل‌های هوشمند در برآورد خصوصیات فیزیکی خاک هنوز مورد توجه محققین قرار دارد. در یکی از مطالعات انجام

مطالعه‌ای عملکرد شبکه عصبی مصنوعی و توابع انتقال رگرسیونی در پیش‌بینی منحنی مشخصه آب خاک و هدایت هیدرولیکی اشباع مورد مقایسه قرار گرفت. در این تحقیق، نتایج شبکه عصبی مصنوعی امیدوارکننده گزارش شده و استفاده از الگوریتم‌های جدید در مطالعات آینده پیشنهاد شده است (Merdun *et al.*, 2006). در پژوهشی با هدف برآورد منحنی مشخصه آب خاک، برتری روش شبکه‌های عصبی مصنوعی در اشتقاق توابع انتقالی مختلف با میانگین کلی آماره‌های RMSE و R^2 به ترتیب برابر با ۰/۳۱۶ و ۰/۸۴۲ گزارش شده است (Haghverdi *et al.*, 2011). (Jenadeleh *et al.*, 2017) بیان داشتند، شبکه عصبی مصنوعی در برآورد نقطه‌ای منحنی مشخصه آب خاک از دقت بالایی برخوردار بوده و همچنین تلفیق شبکه عصبی با الگوریتم ژنتیک، به منظور بهینه‌سازی شرایط اجرایی آن، مثبت ارزیابی شده است. پژوهش‌های مختلف دیگری نیز گزارش کردند جهت برآورد منحنی مشخصه آب خاک، شبکه‌های عصبی مصنوعی، در مقایسه با روش‌های دیگر برتری بیشتری دارند (Sarmadian *et al.*, 2009; Moosavizadeh-Mojarrad and Sepaskhah, 2011; Shirani Johari *et al.*, 2011). نتایج مطالعه (and Rafienejad, 2012) بیانگر برتری مدل تلفیقی الگوریتم ژنتیک و شبکه عصبی، نسبت به شبکه‌ی عصبی مصنوعی بدون فرایند بهینه‌سازی به منظور پیش‌بینی رفتار مکانیکی خاک‌های غیراشباع بود. (Bayat *et al.*, 2013) ترکیبی از شبکه‌های عصبی مصنوعی و تئوری فراکتال را به منظور پیش‌بینی منحنی مشخصه رطوبتی خاک با تعداد ۱۴۸ نمونه خاک از شمال غربی ایران بکار بردند و بیان داشتند که کاربرد شبکه عصبی مصنوعی در این زمینه بسیار سودمند بوده است. (Garg *et al.*, 2014) سه روش هوش مصنوعی رگرسیون بردار پشتیبان، شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیکی چند ژنی (MGGP) را به منظور مدل‌سازی منحنی مشخصه رطوبتی خاک مورد مقایسه قرار دادند. نتایج نشان داد، مدل MGGP در مقایسه با دو مدل دیگر از عملکرد بهتری برخوردار بود. (Fahlman and Lebiere, 1990)، برای اولین بار شبکه‌های عصبی آبشاری (Cascade-NN) را به عنوان یکی از انواع شبکه‌های عصبی مصنوعی با رویکرد ویژه‌ای در تعیین ساختار مناسب شبکه معرفی کردند. کاربرد این روش در زمینه‌های مختلفی مورد ارزیابی قرار گرفته است. (Diamantopoulou *et al.*, 2007) از این ساختار شبکه عصبی توسعه داده شده به منظور برآورد داده‌های گمشده کیفیت آب رودخانه استفاده نمودند. (Yosefi and Poorshariaty, 2014) روش‌های شبکه عصبی مصنوعی با الگوریتم‌های یادگیری مختلف از جمله الگوریتم

از سه عمق مختلف برداشت شده است. منحنی رطوبتی خاک با استفاده از مقادیر رطوبت خاک در مکش‌های ۱، ۱۰، ۳۲، ۶۳، ۱۰۰، ۱۰۰۰ و ۱۶۰۰۰ سانتی‌متر به دست آمد. با توجه به نوع بافت نمونه خاک‌ها، بیشترین تغییرات منحنی مشخصه آب خاک در مکش‌های زیر ۱۰۰۰ سانتی‌متر بوده و در مکش‌های بالا تغییرات رطوبتی ناچیز است. به طور متوسط مقدار تغییر رطوبت خاک از مکش ۱۰۰۰ تا ۱۰۰۰۰ سانتی‌متر حدود ۴ درصد است. در حالی که میانگین تغییرات رطوبت خاک بین مکش‌های ۱ تا ۱۰۰ سانتی‌متر حدود ۲۸ درصد می‌باشد. منحنی دانه بندی خاک نیز با استفاده از روش هیدرومتری اندازه‌گیری شد و براساس آن درصد ذرات کوچک تر از ۲ میکرو متر، ۶-۲۰، ۲۰-۶۰، ۶۰-۲۰۰، ۲۰۰-۶۰۰، ۶۰۰-۲۰۰۰ و بزرگتر از ۲۰۰۰ میکرومتر از طریق درون‌یابی تعیین شد. مقادیر جرم مخصوص ظاهری خاک نیز براساس روش استاندارد نمونه دست نخورده تعیین شد. مقدار تخلخل خاک معادل رطوبت حجمی در نقطه اشباع در نظر گرفته شد. مقادیر جرم مخصوص ظاهری برخی نمونه‌ها به دلیل بالا بودن مواد آلی خاک کمتر از حد معمول می‌باشد.

شبکه عصبی مصنوعی^۱ MLP

شبکه عصبی مصنوعی که الهام گرفته از شبکه عصبی بیولوژیکی مغز انسان است، شامل شبکه‌ای از نرون‌ها بوده که قادر است رفتار پیچیده بین نرون‌ها را نشان دهد. توانایی یادگیری، مهمترین ویژگی شبکه عصبی و هر سیستم هوشمند است که با پردازش داده‌ها، قوانین نهفته در انبوه داده‌ها را به ساختار شبکه عصبی انتقال می‌دهد. یکی از پرکاربردترین انواع شبکه عصبی مصنوعی شبکه پرسپترون چندلایه (MLP) می‌باشد. این شبکه شامل یک لایه ورودی، یک یا چند لایه پنهانی و یک لایه خروجی است. در این شبکه تعداد لایه پنهان و تعداد نرون‌های هر لایه ثابت نمی‌باشد. هر لایه ممکن است از نرون‌های مختلفی تشکیل شده باشد که این موضوع به نوع کار آن‌ها بستگی دارد. کاربر باید تعیین کند که برای کاربرد مورد نظرش، چند لایه و چند نرون در هر لایه باید انتخاب گردد. اساس آموزش شبکه‌های عصبی، بر مبنای روش آزمون و خطا می‌باشد تا بهترین آرایش لایه پنهان و نرون‌های آن‌ها، نوع تابع محرک، الگوریتم آموزشی و تعداد تکرار مرحله آموزش جهت برآورد پارامتر خروجی مورد نظر، ارائه شود. معیار مناسب بودن آرایش لایه پنهان را می‌توان با اعمال رگرسیون خطی میان مقادیر اندازه‌گیری شده و مقادیر برآورد شده و محاسبه ضریب تبیین بیان کرد. ضریب تبیین (R^2) بالا

یافته، (Nikooee et al. (2020) منحنی مشخصه رطوبتی خاک را با یک رویکرد مبتنی بر هوش مصنوعی مدل‌سازی نمودند. در این تحقیق، یک پایگاه داده از ۴۳۷ نوع خاک مختلف به همراه مدل برنامه نویسی ژنتیکی چند ژنی (MGGP) به منظور ایجاد رابطه بین مکش، رطوبت نقطه اشباع، تخلخل و توزیع اندازه ذرات خاک استفاده شد. مدل پیشنهادی به عنوان یک رویکرد جایگزین روابط صرفاً تجربی، و همچنین مدل‌های مفهومی مبتنی بر فیزیک، در تعیین منحنی مشخصه رطوبتی خاک معرفی شد. بر اساس بررسی‌های انجام گرفته، عملکرد روش‌های شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن، در پیش‌بینی خصوصیات فیزیکی خاک، قابل قبول توصیف شده است. هر چند مطالعات محدودی در زمینه کاربرد روش برنامه‌ریزی بیان ژن در پیش‌بینی منحنی مشخصه آب خاک وجود دارد. از سوی دیگر روش شبکه عصبی Cascade از طریق الگوریتم بهینه‌سازی نرون‌های لایه مخفی می‌تواند منجر به بهبود نتایج گردد. با این وجود کاربرد این روش جدید در برآورد منحنی مشخصه آب خاک مورد ارزیابی قرار نگرفته است. در این پژوهش، عملکرد سه روش هوشمند شبکه عصبی مصنوعی نورمال، شبکه عصبی مصنوعی آبشاری و برنامه‌ریزی بیان ژن به منظور پیش‌بینی منحنی مشخصه آب خاک در اراضی جنگلی مورد ارزیابی و مقایسه قرار گرفته است. با توجه به اینکه مطالعه انجام شده بر روی خاک‌های جنگلی و با بافت سبک تا نیمه سبک انجام یافته است می‌توان از نتایج این مطالعه برای مناطق جنگلی کشور از جمله مناطق شمالی کشور استفاده نمود.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های استفاده شده

در تحقیق حاضر، از داده‌های اندازه‌گیری شده منحنی مشخصه آب خاک، توزیع اندازه ذرات خاک، جرم مخصوص ظاهری و تخلخل مربوط به تعداد ۱۰۸ نمونه خاک که در اطراف ایستگاه هیتیاالا در مرکز فنلاند و در یک محدوده جنگلی با مساحت حدود ۴۰۰ کیلومتر مربع برداشت شده است، استفاده گردید (Jauhiainen, 2004). بافت خاک اغلب نمونه‌ها سبک یا نیمه سبک بود که در قالب پنج دسته بافت خاک شامل ۳۵ نمونه با بافت شنی، ۳۴ نمونه شن لومی، ۳۱ نمونه لوم شنی، ۴ نمونه لوم و ۴ نمونه سیلتی لوم بر اساس استاندارد وزارت کشاورزی ایالات متحده آمریکا طبقه بندی شدند. برخی ویژگی‌های فیزیکی نمونه‌های مورد استفاده در این تحقیق در جدول ۱ ارائه شده است. نمونه خاک‌ها از ۳۶ نقطه با پراکنش مناسب و در هر نقطه

فیزیکی خاک شامل درصد رس، درصد سیلت، جرم مخصوص ظاهری، مکش، تخلخل، رطوبت ظرفیت زراعی خاک و مقدار مکش و لایه خروجی را مقدار رطوبت خاک تشکیل داد. توابع انتقال و تعداد نرون در لایه پنهان مورد آزمون و خطا قرار گرفت و بهترین ساختار شبکه بر اساس کمترین میزان RMSE و بالاترین مقدار R^2 تعیین شد. در تحقیق حاضر، از نرم افزار MATLAB 2020a به منظور مدلسازی شبکه عصبی مصنوعی استفاده شده است.

نشان دهنده دست یافتن به آرایشی مناسب به منظور برآورد پارامتر خروجی است. هر نرون در شبکه MLP دو نوع محاسبه انجام می‌دهد. در نوع اول محاسبات، سیگنال تابعی انجام می‌شود و در نوع دوم محاسبات، برآورد لحظه‌ای از گرادینان منحنی خطا انجام می‌پذیرد. این گرادینانها جهت پخش سیگنال‌های خطا در شبکه مورد نیاز می‌باشند (Kia, 2009). در این پژوهش از شبکه پرسپترون با الگوریتم لونیبرگ مارکوات و تابع فعال‌ساز میانی سیگموئید و خروجی خطی استفاده شد. لایه ورودی را پارامترهای

جدول ۱- مشخصات فیزیکی نمونه خاک‌ها در کلاس‌های مختلف بافت خاک

بافت خاک	تعداد نمونه‌ها	تخلخل (%)	جرم مخصوص ظاهری (gr/cm^3)
شنی	۳۵	۰/۲۶-۰/۶۱	۱/۰۶-۱/۶۵
شن لومی	۳۴	۰/۳۲-۰/۶۳	۱/۰۵-۱/۷۷
لوم شن	۳۱	۰/۳۱-۰/۶۲	۱/۰۵-۱/۷۰
لوم	۴	۰/۴۴-۰/۶۳	۱/۱۲-۱/۵۴
سیلتی لوم	۴	۰/۴۴-۰/۵۸	۱/۰۶-۱/۶۲

قبول خطا برسد ادامه می‌یابد. به منظور افزودن یک نرون جدید، تعدادی نرون به‌عنوان کاندید ایجاد شده و ضرایب ورودی آنها طوری تغییر می‌یابد تا همبستگی نرون خروجی با میزان خطای شبکه افزایش یابد. سپس نرونی که بیشترین همبستگی را دارد انتخاب می‌گردد. نرون جدید در ساختار شبکه قرار گرفته و کلیه ضرایب ورودی آن ثابت می‌شوند و ضرایب ورودی نرون‌های خروجی آموزش داده می‌شوند. این آموزش تا جایی ادامه پیدا می‌کند که یا خطا از حد مورد نظر کمتر گردد و یا سرعت تغییرات کاهش یابد (Fahlman and Lebiere, 1990).

برنامه‌ریزی بیان ژن

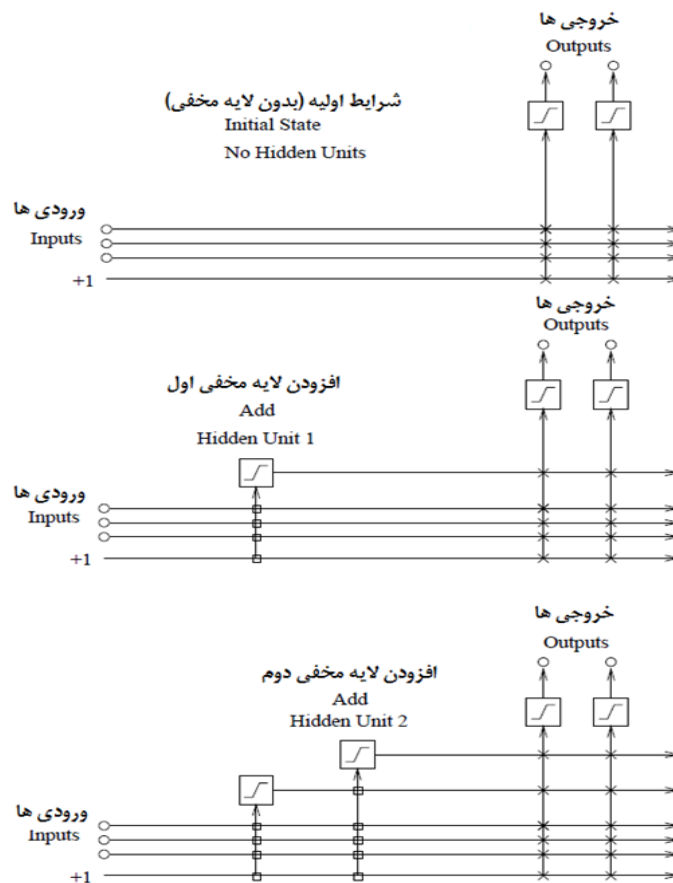
روش برنامه‌ریزی بیان ژن (GEP) برای اولین بار توسط Ferreira (2001) ارائه شد. در این برنامه‌ریزی، کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آن چه که در الگوریتم ژنتیک استفاده می‌شود و ساختارهای شاخه‌ای با اندازه‌ها و شکل‌های متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک، ترکیب می‌شوند. اولین مرحله در شبیه‌سازی‌ها به کمک این نرم‌افزار، تولید جمعیت اولیه از راه‌حل‌هاست که به کمک یک سری توابع و ترمینال‌ها صورت می‌گیرد. سپس کروموزوم‌ها به صورت بیان درختی نشان داده و توسط تابع برآزش ارزیابی می‌شوند. در صورت دستیابی به راه‌حل مطلوب و یا رسیدن نسل‌ها به تعداد معین، تکامل متوقف و بهترین راه‌حل ارائه می‌شود. اگر شرایط توقف حاصل نشود، نخبه‌گزینی صورت می‌گیرد و باقی راه‌حل‌ها به فرآیندی گرینشی واگذار می‌شوند. این فرآیند برای چندین نسل تکرار شده و با پیش رفتن نسل به جلو کیفیت جمعیت نیز به‌طور نسبی

شبکه عصبی مصنوعی Cascade correlation

در شبکه‌های عصبی کلاسیک از جمله MLP ساختار شبکه که شامل تعداد لایه‌های مخفی و نرون‌های هر لایه است باید از قبل مشخص شوند، بنابراین تشخیص دقیق معماری بهینه در اکثر موارد با پیچیدگی همراه است و معمولاً از آزمون و خطا به منظور یافتن ساختار مناسب استفاده می‌شود. از طرف دیگر آموزش بر روی شبکه به‌دست آمده بر روی تمامی شبکه همراه با هم صورت می‌گیرد که در برخی مواقع موجب رفت و برگشت خطا بین منابع مختلف خطا می‌گردد. شبکه‌های عصبی Cascade correlation همانند سایر انواع شبکه‌های عصبی، شامل یک لایه ورودی و یک لایه خروجی هستند. تفاوت آن‌ها در نرون‌های لایه مخفی آن-هاست. این شبکه‌ها در هر مرحله با افزودن یک نرون مخفی جدید، شبکه را گسترش می‌دهند. هر نرون جدید از هر یک از نرون‌های ورودی و تمامی نرون‌های مخفی قبلی ورودی می‌گیرد و به ورودی تمامی نرون‌های خروجی، خروجی دارد. علاوه بر روابط بین نرون‌های مخفی، بین هر یک از نرون‌های ورودی و نرون‌های خروجی نیز یک ارتباط برقرار می‌گردد (شکل ۱). شبکه‌های Cascade در اولین قدم مانند شبکه‌های کلاسیک تنها با نرون‌های ورودی و خروجی آموزش می‌بینند. در صورتی که خطا پس از طی کردن تعداد تکرارهای مشخصی قابل قبول باشد، فرآیند آموزش متوقف می‌شود. در غیر اینصورت از این پس در هر مرحله با افزودن یک نرون جدید و آموزش شبکه به شکل مناسب، مدل مجدداً اجرا می‌شود تا بتواند خطای باقی‌مانده را کاهش دهد. این فرآیند تا جایی که بلاخره شبکه به میزان قابل

اولیه تابع برازش نشان داد، استفاده از تابع برازش ضریب تعیین (R^2) و ریشه نسبی مربعات خطا (RMSE) در مقایسه با سایر توابع، عملکرد بهتری دارند. همچنین از بین توابع پیوند شامل جمع و ضرب، تابع پیوند جمع عملکرد بهتری در مقایسه با تابع پیوند ضرب دارد و آخرین گام، انتخاب عملگرهای اصلی برای ساخت درخت تجزیه و توابع ریاضی مناسب برای تفسیر مدل می‌باشد. در این پژوهش از نرم افزار GeneXpro Tools 5.0 به منظور اجرای مدل برنامه‌ریزی بیان ژن استفاده گردید.

بهبود می‌یابد (Ferreira, 2006). در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و ترمینال‌ها، مدل‌سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی، مثلثاتی و یا توابع تعریف شده توسط کاربر هستند که معتقد است، می‌توانند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مسئله تشکیل شده‌اند. همه پارامترهای ذکر شده در بالا با سعی و خطا تا دست یابی به حداکثر ضریب همبستگی مدل توسط کاربر انتخاب می‌شود. گام نخست در بررسی مدل، انتخاب یک تابع برازش مناسب است. نتایج انتخاب



شکل ۱- ساختار شبکه عصبی مصنوعی Cascade correlation

کمتز تحت تاثیر سایر عوامل قرار دارد، قابل لحاظ خواهد بود. از سوی دیگر کاهش تعداد پارامترهای ورودی مدل‌ها و محدود کردن سناریوهای داده ورودی به پارامترهای فیزیکی خاک می‌تواند به عنوان یک مزیت در روش‌های غیرمستقیم برآورد منحنی مشخصه آب خاک محسوب گردد. در این تحقیق برآورد رطوبت حجمی با استفاده از مدل‌های هوشمند به روش نقطه‌ای می‌باشد. در یک نمونه خاک مشخص، به منظور تخمین رطوبت حجمی خاک در یک نقطه مشخص از منحنی مشخصه آب خاک (مقدار مکش معین) از داده‌های ورودی شامل درصد ذرات رس، درصد

داده‌های ورودی و خروجی مدل‌ها

داده‌های فیزیکی خاک از قبیل بافت، جرم مخصوص ظاهری، تخلخل و ماده آلی به عنوان داده‌های ورودی سهل الوصول و ارزان به منظور پیش بینی خصوصیات فیزیکی خاک نظیر منحنی مشخصه آب خاک مطرح می‌باشند. در این تحقیق از تمامی داده‌های اشاره شده به جز ماده آلی (به دلیل در دسترس نبودن) استفاده شد. با این وجود می‌توان بیان داشت اثر ماده آلی خاک از طریق جرم مخصوص ظاهری با توجه به رابطه مستقیم این دو پارامتر به خصوص در مناطق جنگلی که جرم مخصوص ظاهری

در تحقیق حاضر، از داده‌های فیزیکی و زود یافت خاک در سه ترکیب مختلف به عنوان ورودی مدل‌ها استفاده شد (جدول ۲).

معیارهای آماری برای مقایسه مدل‌ها

به منظور مقایسه و ارزیابی عملکرد مدل‌های هوشمند در برآورد منحنی مشخصه رطوبتی خاک، از شاخص‌های آماری ضریب تعیین (R^2)، جذر میانگین مربعات خطا (RMSE)، میانگین انحراف خطا (MBE) و معیار درصد میانگین مطلق خطاهای پیش‌بینی (MAPE) به شرح روابط زیر استفاده شد.

$$R^2 = \frac{(\sum_{i=1}^n (x_i - x_{\text{mean}})(y_i - y_{\text{mean}}))^2}{\sum_{i=1}^n (x_i - x_{\text{mean}})^2 \sum_{i=1}^n (y_i - y_{\text{mean}})^2} \quad (\text{رابطه ۱})$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (\text{رابطه ۲})$$

$$\text{MBE} = \frac{1}{n} \sum_{i=1}^n (y_i - x_i) \quad (\text{رابطه ۳})$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - x_i}{y_i} \right| \times 100 \quad (\text{رابطه ۴})$$

در روابط بالا، x_i : داده‌های اندازه‌گیری شده، y_i : داده‌های شبیه‌سازی شده، x_{mean} و y_{mean} به ترتیب میانگین داده‌های اندازه‌گیری شده، شبیه‌سازی شده و n : تعداد داده‌های مشاهداتی می‌باشند.

جدول ۲- سناریوهای مختلف داده ورودی مدل‌های هوشمند

سناریوهای مختلف داده ورودی مدل‌های هوشمند		
سناریو	ورودی	خروجی
اول	درصد رس، درصد سیلت، جرم مخصوص ظاهری، مکش خاک	درصد رطوبت حجمی خاک
دوم	درصد رس، درصد سیلت، جرم مخصوص ظاهری، مکش، تخلخل	درصد رطوبت حجمی خاک
سوم	درصد رس، درصد سیلت، جرم مخصوص ظاهری، مکش، تخلخل، رطوبت ظرفیت زراعی خاک	درصد رطوبت حجمی خاک

اول، دوم و سوم به ترتیب ۵، ۵ و ۶ تعیین شد. در روش شبکه عصبی مصنوعی با ساختار Cascade، دستیابی به تعداد نرون‌های بهینه مشابه روش MLP از طریق آزمون و خطا نبوده و تعداد نرون‌های بهینه برای لایه پنهان به صورت خودکار تعیین شد (شکل ۳).

با توجه به شکل ۳ ملاحظه می‌گردد که مدل Cascade نسبت به مدل MLP حساسیت کمی به افزایش نرون‌ها نشان داده است (سناریوهای ۲ و ۳). بطوریکه تا نرون شماره ۴، شیب ملایم کاهشی در مقدار RMSE مشاهده می‌شود و با افزایش نرون‌ها از ۴ به بعد، نوسانات خطا ناچیز می‌باشد. در سناریو ۱، نوسانات خطا با تغییرات تعداد نرون کمی بیش‌تر از دو سناریوی دیگر بود. تعداد بهینه نرون لایه مخفی براساس کم‌ترین میزان RMSE برای سناریوهای اول، دوم و سوم در مدل شبکه عصبی Cascade به ترتیب ۸، ۹ و ۴ تعیین شد.

ذرات سیلت، جرم مخصوص ظاهری، تخلخل و رطوبت ظرفیت زراعی استفاده شد. در هر کدام از مدل‌های هوشمند، ضرایب وزنی بهینه به هر کدام از پارامترهای ورودی اختصاص داده می‌شود. پارامتر خروجی در همه شبیه‌سازی‌ها، درصد رطوبت حجمی خاک به ازای مقادیر مکش‌های معین شده می‌باشد. ترکیب‌های مشابه ترکیب داده ورودی استفاده شده در تحقیق حاضر قبلاً توسط محققین مختلف مورد مطالعه و ارزیابی قرار گرفته است (Haghverdi et al., 2012; Johari et al., 2006). در اجرای مدل‌های هوشمند، ۷۵ درصد داده‌ها (۸۱ نمونه خاک) برای مرحله آموزش و ۲۵ درصد داده‌ها (۲۷ نمونه خاک) به منظور آزمون مدل‌ها استفاده شد. به منظور استانداردسازی داده‌های مورد استفاده در مدل‌ها، از رابطه (۱) استفاده شد:

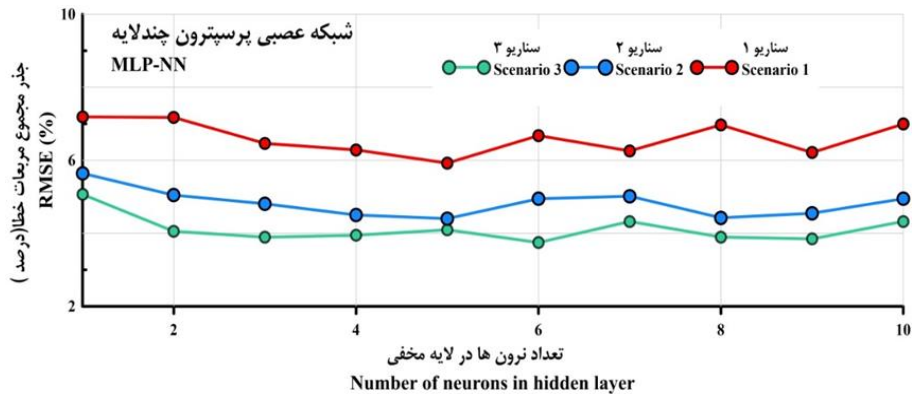
$$X_n = \left(\frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \right) \quad (\text{رابطه ۱})$$

در رابطه (۱)، X_n : داده استاندارد شده، X : داده اندازه‌گیری شده، X_{max} و X_{min} به ترتیب معرف داده‌های اندازه‌گیری شده حداقل و حداکثر است.

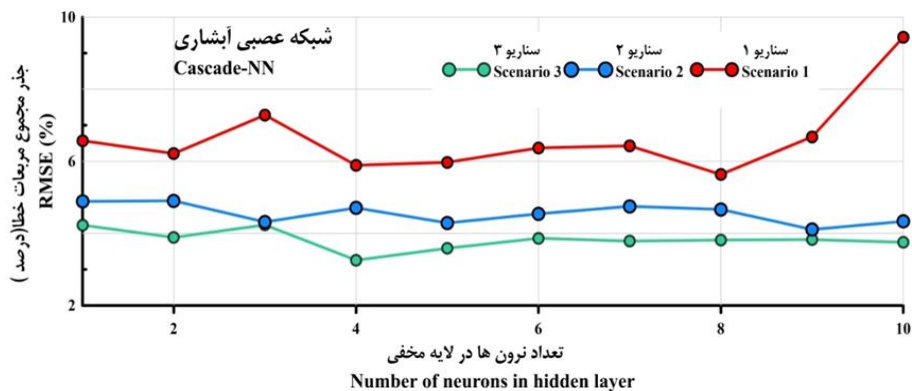
نتایج و بحث

تعیین بهترین ساختار شبکه عصبی مصنوعی

در ابتدا بهترین ساختار شبکه عصبی مصنوعی برای هر یک از سناریوهای داده ورودی تعیین شد (شکل ۲). در سناریوهای ۱ و ۲، با افزایش تعداد نرون‌های مخفی تا میزان ۵ نرون، مقدار خطا کاهش یافته ولی پس از آن مجدد روند صعودی به خود گرفته است. در سناریو ۳ نیز کمترین مقدار خطا مربوط به تعداد ۶ نرون مخفی به‌دست آمد. تعداد بهینه نرون بطور کلی تغییرات RMSE دارای روند مشخصی نمی‌باشد چون در شبکه‌های عصبی وزن‌ها به طور تصادفی انتخاب می‌شوند و نمی‌توان روند موجود را به طور کامل توضیح داد و باید با سعی و خطا بهترین ساختار را به‌دست آورد. اما باید توجه کرد که پیچیده کردن بیش از حد مدل سبب عدم برازش مناسب بین داده‌ها می‌شود. در نهایت تعداد بهینه نرون لایه مخفی براساس کمترین مقدار RMSE برای سناریوهای



شکل ۲- مقادیر RMSE مربوط به تعداد نرون ها در لایه مخفی - مدل شبکه عصبی پرسپترون چند لایه



شکل ۳- مقادیر RMSE مربوط به تعداد نرون ها در لایه مخفی - مدل شبکه عصبی آبشاری

ارزیابی عملکرد مدل‌ها - سناریوی اول

شبیه‌سازی‌ها با استفاده از مدل‌های MLP-NN، Cascade-NN و GEP برای هر کدام از مقادیر مکش به طور جداگانه انجام شد. مقادیر شاخص‌های آماری مربوط به بهترین ساختار هر مدل در جدول (۳) ارائه شده است. ملاحظه می‌گردد دقت هر سه مدل وابسته به مقدار مکش می‌باشد. در سناریوی اول، خطای هر سه مدل در مکش‌های پایین بیشتر از مکش‌های بالا می‌باشد. میانگین شاخص خطای RMSE مدل‌ها در مکش‌های کمتر از ۳۰۰ سانتی‌متر ۶/۳۸ درصد و در مکش‌های بالاتر از آن ۴/۵۷ درصد محاسبه شد. از سوی دیگر میانگین شاخص خطای RMSE برای مدل‌های MLP-NN، Cascade-NN و GEP به ترتیب ۵/۸، ۵/۶ و ۶/۲ درصد تعیین شد. مقادیر RMSE بدست آمده بیان کننده عملکرد تقریباً نزدیک هر سه مدل می‌باشد، با این وجود روش Cascade دارای برتری جزئی نسبت به دو روش دیگر می‌باشد. نمودارهای همبستگی بین مقادیر پیش‌بینی شده و مشاهده‌ای مربوط به تمامی مکش‌ها در شکل (۴) نشان داده شده است. اختلاف فاحشی بین مقادیر ضریب تعیین سه مدل مشاهده نمی‌شود، بطوریکه اختلاف بین مقادیر ضریب تعیین در سه روش کمتر از ۲ درصد می‌باشد. میانگین ضریب تعیین برای مرحله آموزش و آزمون به ترتیب برابر ۰/۸۷ و ۰/۸۶ محاسبه شد. نتایج

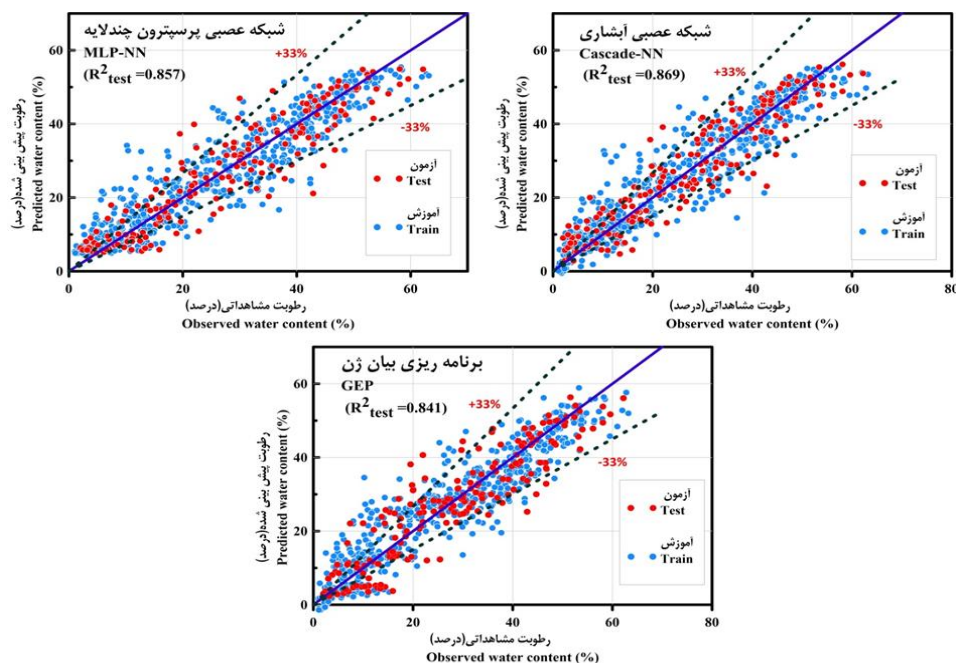
مطالعه (Haghverdi *et al.*, 2011) نیز تایید کننده نتیجه به دست آمده می‌باشد، به طوری که پیش‌بینی منحنی مشخصه رطوبتی خاک با استفاده از روش‌های مختلف هوش مصنوعی با اطلاعات ورودی مدل شامل رطوبت خاک، چگالی ظاهری خاک و پتانسیل ماتریک، بدون در نظر گرفتن رطوبت ظرفیت زراعی و تخلخل با میانگین کلی آماره‌های RMSE و R^2 به ترتیب برابر ۰/۳۱۶ و ۰/۸۴۲ قابل قبول گزارش نمودند. استفاده از تمامی اطلاعات پایه خاک به عنوان نمایه ورودی برای مدل‌سازی بهترین نتایج را در پی دارد. همچنین در بیشتر مطالعات بررسی شده تاثیرگذارترین پارامتر ورودی مدل‌ها نیز مقدار مکش خاک معرفی شده است (Hsu., 1995; Zare zade Mehrizi and Bozorg Hadad, 2008) که در این تحقیق نیز اثرگذاری مقدار این پارامتر بر دقت نتایج بدست آمده مشاهده شد. مقادیر شاخص MBE در مرحله آزمون نشان داد، در بیشتر مکش‌ها، مدل‌های MLP و GEP برآورد بیشتر و مدل Cascade برآورد کمتری نسبت به داده‌های مشاهداتی رطوبت خاک داشته‌اند. در روش Cascade ساختار شبکه با اضافه کردن نرون‌های جدید تعیین می‌شود و به جای آموزش تمام شبکه در هر مرحله، تنها بخشی از شبکه آموزش می‌بیند. این کار منجر به تعیین خودکار ساختار بهینه شده و بازدهی افزایش می‌یابد. در سناریوی اول تنها از داده‌های بافت و

ورودی توانایی شبیه‌سازی تغییرات شدید رطوبت را در مکش‌های پایین ندارند.

جرم مخصوص ظاهری خاک به عنوان ورودی مدل‌های هوشمند استفاده شده است و به نظر می‌رسد مدل‌ها با این ترکیب داده

جدول ۳- مقادیر شاخص‌های آماری مدل‌های هوشمند به تفکیک مکش‌های مختلف (سناریوی اول)

مکش (cm)	مرحله مدل‌ها	آموزش			آزمون		
		RMSE	MAPE	MBE	RMSE	MAPE	MBE
۱۰	MLP	۵/۷۶	۱۰/۳۵	-۱/۹۳	۵/۳۲	۹/۰۶	-۱/۲۴
	Cascade	۵/۲۰	۱۰/۰۷	-۱/۹۷	۵/۳۸	۹/۴۰	-۰/۵۱
	GEP	۵/۵۲	۹/۸۲	-۱/۴۷	۵/۲۵	۹/۱۶	-۰/۳۴
۳۲	MLP	۷/۰۰	۱۵/۵۸	-۰/۱۳	۷/۳۹	۲۰/۳۰	-۰/۲۰
	Cascade	۶/۳۸	۱۴/۲۰	-۱/۳۷	۷/۱۴	۱۸/۷۱	-۰/۸۹
	GEP	۷/۴۸	۱۶/۱۰	-۰/۰۱	۷/۴۵	۱۹/۷۰	۱/۱۲
۶۳	MLP	۷/۰۰	۱۷/۸۷	۱/۰۰	۷/۶۰	۳۳/۱۰	-۰/۴۲
	Cascade	۶/۲۱	۱۵/۹۷	-۰/۵۳	۷/۱۹	۲۸/۸۸	-۰/۷۳
	GEP	۷/۷۸	۲۱/۰۴	۱/۹۹	۷/۳۴	۲۸/۳۰	۱/۰۸
۱۰۰	MLP	۶/۵۷	۱۷/۲۹	-۰/۸۲	۶/۳۱	۳۱/۲۰	-۰/۰۳
	Cascade	۶/۳۲	۱۶/۰۷	۱/۳۰	۶/۱۱	۲۵/۷۶	-۰/۳۶
	GEP	۶/۱۳	۱۸/۷۵	-۰/۲۱	۵/۹۴	۳۱/۳۳	-۰/۵۹
۳۰۰	MLP	۵/۸۵	۲۶/۷۷	-۰/۰۳	۶/۳۵	۴۵/۸۸	-۱/۵۱
	Cascade	۵/۹۶	۲۹/۶۵	-۰/۳۳	۶/۳۴	۳۹/۱۰	-۱/۳۳
	GEP	۶/۶۰	۳۵/۷۶	-۱/۷۳	۷/۱۲	۵۳/۷۰	-۳/۳۰
۱۰۰۰	MLP	۴/۴۷	۳۸/۰۲	-۰/۸۲	۳/۸۱	۴۱/۰۹	-۰/۲۱
	Cascade	۴/۵۵	۴۵/۵۱	-۰/۶۲	۳/۶۴	۳۶/۴۲	-۰/۶۱
	GEP	۴/۷۰	۳۹/۶۶	-۰/۹۵	۳/۵۳	۳۳/۹۳	-۰/۲۰
۱۶۰۰	MLP	۴/۱۲	۶۰/۱۳	-۰/۹۴	۳/۲۲	۶۹/۹۶	-۰/۰۱
	Cascade	۴/۴۴	۶۵/۱۲	-۰/۳۷	۳/۲۱	۵۳/۴۹	-۰/۱۲
	GEP	۵/۱۲	۴۱/۳۳	۳/۵۴	۴/۲۲	۵۲/۸۲	۲/۹۳



شکل ۴- همبستگی بین مقادیر رطوبت خاک پیش‌بینی شده و مشاهداتی (سناریوی اول)

مقادیر شاخص‌های آماری مربوط به بهترین ساختار برای هر کدام از مدل‌های MLP-NN، Cascade-NN و GEP مربوط به

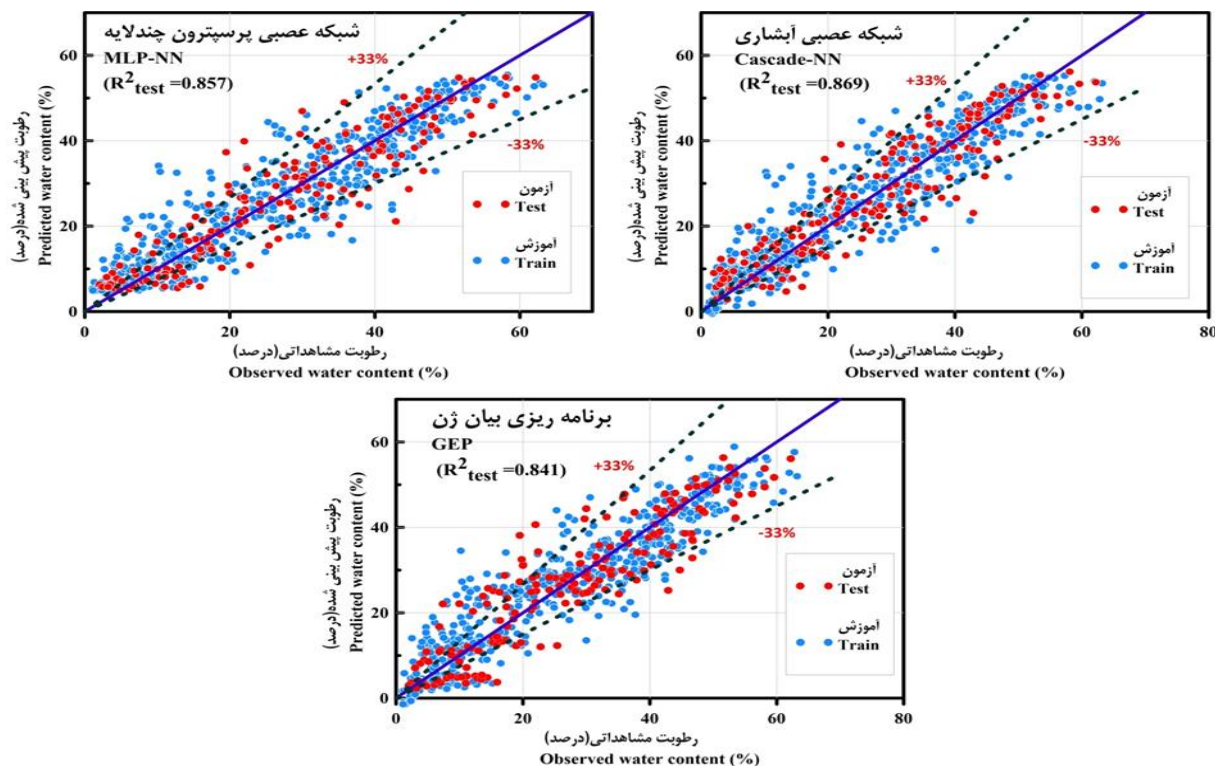
ارزیابی عملکرد مدل‌ها- سناریوی دوم

تقریباً نزدیک دو مدل شبکه عصبی مصنوعی می‌باشد. از سوی دیگر دقت روش برنامه ریزی بیان ژن نسبت به این مدل‌ها کاهش یافته است. نمودارهای همبستگی بین مقادیر پیش‌بینی شده و مشاهده‌ای مربوط به تمامی مکش‌ها در شکل (۵) نشان داده شده است. در این سناریو نیز بهترین عملکرد مربوط به شبکه عصبی Cascade می‌باشد. میانگین شاخص ضریب تعیین برای مرحله آموزش و آزمون به ترتیب برابر با ۰/۹۴ و ۰/۹۳ برآورد شد. ضعیف‌ترین همبستگی نیز مربوط به مدل GEP و با مقادیر ضریب تعیین ۰/۹ و ۰/۸۹ به ترتیب برای مراحل آموزش و آزمون بود. عملکرد ضعیف برنامه‌ریزی بیان ژن در مقایسه با روش‌های شبکه عصبی مصنوعی و رگرسیون چند متغیره در تخمین برخی خصوصیات فیزیکی خاک توسط (Mahmoudabadi et al., 2017) گزارش شده است. در مقابل در بیشتر مطالعاتی که در آن‌ها از شبکه‌های عصبی مصنوعی استفاده شده نتایج قابل قبول‌تری گزارش شده است (Shirani and Oliaei et al., 2019; Rafienezad, 2012).

سناریوی دوم، در جدول شماره (۴) آورده شده است. در سناریوی دوم و با اضافه شدن پارامتر تخلخل خاک به داده‌های ورودی، دقت هر سه مدل در مکش‌های پایین افزایش یافته است. به طور کلی در این سناریو نسبت به سناریوی اول، اثرگذاری مقادیر مختلف مکش بر نتایج مدل‌ها کاهش یافته است به طوری که میانگین شاخص خطای RMSE مدل‌ها در مکش‌های کمتر از ۳۰۰ سانتی‌متر ۴/۴۷ درصد و در مکش‌های بالاتر از آن ۴/۴۱ درصد محاسبه شد. کاربرد پارامتر تخلخل خاک در داده‌های ورودی منجر به بالا رفتن قابل ملاحظه دقت نتایج هر سه مدل در برآورد رطوبت حجمی خاک در مکش‌های ۱۰ و ۳۲ سانتی‌متر شد به طوری که شاخص خطای RMSE حاصل از مقایسه مقادیر رطوبت حجمی مشاهده‌ای و پیش‌بینی شده در دو مقدار مکش اشاره شده برای سناریوهای اول و دوم به ترتیب ۶/۲۲ و ۳/۰۶ درصد تعیین شد. میانگین شاخص خطای RMSE برای مدل‌های MLP-NN، Cascade-NN و GEP به ترتیب ۴/۲، ۳/۹ و ۵/۱ درصد تعیین شد. مقادیر RMSE بدست آمده بیان‌کننده عملکرد

جدول ۴- مقادیر شاخص‌های آماری مدل‌های هوشمند به تفکیک مکش‌های مختلف (سناریوی دوم)

مکش (cm)	مرحله	آموزش			آزمون		
		مدل‌ها	شاخص‌های آماری	شاخص‌های آماری	شاخص‌های آماری	شاخص‌های آماری	
		RMSE	MAPE	MBE	RMSE	MAPE	MBE
۱۰	MLP	۲/۱۹	۳/۷۰	-۰/۱۹	۱/۹۶	۳/۵۳	-۰/۸۹
	Cascade	۱/۵۹	۲/۶۸	-۰/۲۲	۲/۰۳	۳/۵۸	-۰/۲۲
	GEP	۲/۸۱	۵/۱۴	-۰/۶۴	۳/۴۵	۵/۷۰	-۰/۶۴
۳۲	MLP	۳/۸۸	۸/۷۶	-۰/۲۲	۳/۱۱	۶/۱۷	-۰/۲۰
	Cascade	۳/۳۹	۷/۲۴	-۰/۲۸	۳/۰۷	۶/۵۸	-۰/۵۱
	GEP	۵/۲۴	۱۳/۹۶	-۰/۴۳	۴/۷۵	۱۰/۴۱	-۰/۸۴
۶۳	MLP	۱۹/۸۵	۰/۵۴	۲/۹۸	۵/۵۰	۱۴/۹۱	۲/۹۸
	Cascade	۲۰/۳۰	-۰/۴۳	۱/۷۳	۴/۷۹	۱۳/۱۵	۱/۷۳
	GEP	۲۴/۴۹	۲/۲۳	۴/۱۳	۷/۰۱	۱۶/۰۵	۴/۱۳
۱۰۰	MLP	۲۱/۷۴	۰/۷۴	۲/۵۷	۵/۰۷	۱۴/۴۹	۲/۵۷
	Cascade	۱۷/۴۷	۰/۳۲	۱/۶۵	۴/۷۸	۱۳/۸۶	۱/۶۵
	GEP	۲۶/۷۵	۰/۲۷	۱/۶۷	۵/۷۴	۱۵/۴۰	۱/۶۷
۳۰۰	MLP	۳۴/۸۷	-۰/۸۵	۱/۵۲	۵/۱۷	۲۲/۶۳	۱/۵۲
	Cascade	۲۶/۴۷	-۰/۴۰	۱/۴۳	۵/۰۶	۲۲/۱۴	۱/۴۳
	GEP	۴۴/۰۶	-۲/۷۸	۶/۳۹	۵/۵۵	۲۵/۰۰	-۰/۷۶
۱۰۰۰	MLP	۳۷/۳۲	۲/۰۵	۲/۷۱	۵/۱۵	۳۱/۹۹	۲/۷۱
	Cascade	۲۶/۲۰	-۰/۲۶	۰/۵۳	۴/۲۶	۴۱/۳۱	۰/۵۳
	GEP	۴۲/۰۰	-۰/۴۵	-۰/۴۵	۴/۶۳	۳۶/۱۸	-۰/۴۵
۱۶۰۰	MLP	۵۸/۲۳	-۰/۶۸	-۰/۵۰	۳/۶۰	۶۴/۲۴	-۰/۵۰
	Cascade	۴۷/۴۷	۰/۰۸	۰/۸۷	۳/۸۸	۵۸/۰۱	۰/۸۷
	GEP	۹۷/۷۳	۰/۷۷	۱/۸۰	۴/۹۵	۸۹/۶۸	۱/۸۰



شکل ۵- همبستگی بین مقادیر رطوبت خاک پیش‌بینی شده و مشاهداتی (سناریوی دوم)

بیان ژن با مدل‌های شبکه عصبی مصنوعی کاهش یافته است. نمودارهای همبستگی بین مقادیر پیش‌بینی شده و مشاهده‌ای مربوط به تمامی مکش‌ها در شکل (۶) نشان داده شده است. در این سناریو نیز مدل شبکه عصبی مصنوعی با ساختار Cascade-NN بهترین عملکرد را داشت. مقدار ضریب تعیین برآورد شده بر ای روش مذکور در هر دو مرحله آموزش و آزمون برابر با ۰/۹۶ محاسبه شد. ضعیف‌ترین عملکرد را نیز در بین سه مدل بکار رفته، مدل GEP از خود نشان داد. براساس شاخص MBE، مشاهده می‌شود که در بیشتر مکش‌ها، مدل GEP کم برآورد و دو مدل دیگر بیش برآورد داشته‌اند.

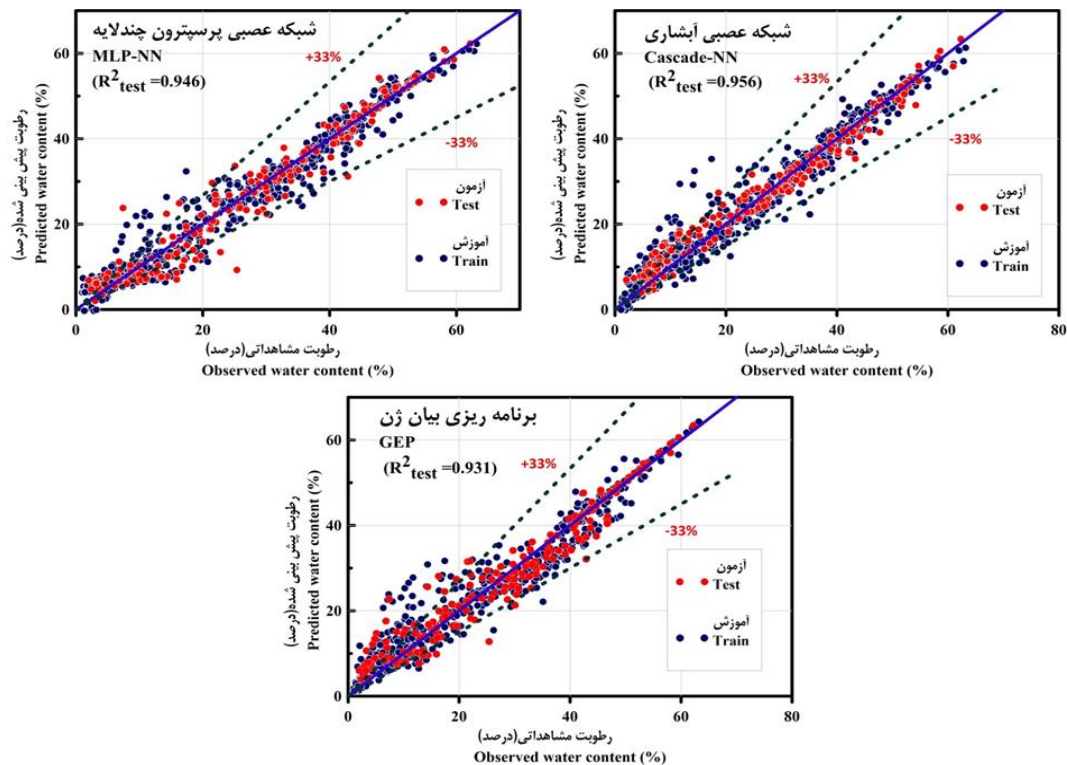
نتایج به‌دست آمده قابل مقایسه با نتایج گزارش شده در مطالعات پیشین می‌باشد. Johari and Hooshmand Nejad (2015) مقدار ضریب تعیین و میانگین خطای نسبی محاسبه شده از مقایسه بین داده‌های مشاهداتی و پیش‌بینی شده رطوبت خاک با استفاده از روش برنامه‌ریزی بیان ژن را به ترتیب حدود ۰/۹۴ و ۲۸/۷ درصد گزارش نمودند. (Jenadeleh et al. (2017) مقادیر ضریب تعیین و میانگین مربعات خطای نرمال شده را برای مدل شبکه عصبی بهینه شده به ترتیب برابر با ۰/۹۶ و ۵/۴ درصد به‌دست آوردند.

ارزیابی عملکرد مدل‌ها - سناریوی سوم

مقادیر شاخص‌های آماری مربوط به بهترین ساختار برای هر کدام از مدل‌های MLP-NN، Cascade-NN و GEP مربوط به سناریوی سوم، در جدول شماره (۵) آورده شده است. دقت پیش‌بینی مدل‌ها با استفاده از ترکیب داده ورودی سوم و با اضافه شدن پارامتر رطوبت حجمی در نقطه ظرفیت زراعی به طور چشمگیر افزایش یافته است. نتایج این سناریو مشابه سناریوی دوم نیز نشان می‌دهد اضافه شدن پارامترهای جدید از قبیل تخلخل و رطوبت ظرفیت زراعی به داده‌های ورودی، عمدتاً منجر به بالا رفتن دقت پیش‌بینی‌ها در مکش‌های پایین شده است و دقت مقادیر رطوبت پیش‌بینی شده در مکش‌های بالا کمتر تحت تاثیر تغییر سناریوها قرار گرفته است. با این وجود سناریوی سوم بهترین عملکرد را در بین سه سناریو در پیش‌بینی مقادیر رطوبت در مکش‌های بالا از خود نشان داد. میانگین شاخص خطای RMSE مدل‌ها در مکش‌های کمتر از ۳۰۰ سانتی‌متر ۳/۲ درصد و در مکش‌های بالاتر از آن ۳/۹ درصد محاسبه شد. میانگین شاخص خطای RMSE برای مدل‌های MLP-NN، Cascade-NN و GEP به ترتیب ۳/۵، ۳/۱ و ۳/۸ درصد تعیین شد. مقادیر RMSE به‌دست آمده بیان‌کننده عملکرد تقریباً نزدیک سه مدل می‌باشد. در سناریوی سوم اختلاف بین نتایج روش برنامه‌ریزی

جدول ۵- مقادیر شاخص‌های آماری مدل‌های هوشمند به تفکیک مکش‌های مختلف (سناریوی سوم)

مکش (cm)	مرحله آموزش			مرحله آزمون		
	مدل‌ها	MAPE	RMSE	MAPE	RMSE	MBE
۱۰	MLP	۰/۰۳	۱/۶۴	۱/۰۳	۱/۰۳	-۰/۱۵
	Cascade	۰/۱۹	۱/۹۷	۱/۲۲	۱/۶۳	-۰/۲۲
	GEP	-۰/۱۹	۱/۱۴	۱/۵۹	۰/۹۵	-۰/۲۸
۳۲	MLP	-۰/۷۸	۶/۸۸	۲/۹۰	۵/۰۵	-۱/۳۰
	Cascade	-۰/۱۳	۸/۴۶	۳/۴۳	۷/۰۵	-۰/۲۴
	GEP	-۰/۲۸	۸/۶۵	۳/۶۲	۶/۹۴	-۱/۱۳
۶۳	MLP	-۰/۸۴	۹/۱۴	۲/۹۶	۸/۶۷	۱/۴۶
	Cascade	-۰/۴۴	۸/۸۶	۲/۴۷	۷/۴۰	۰/۳۷
	GEP	۲/۱۲	۱۰/۰۹	۳/۴۰	۹/۰۵	۳/۰۴
۱۰۰	MLP	-۰/۷۳	۱۳/۳۷	۴/۰۰	۱۱/۵۱	۰/۶۷
	Cascade	۰/۲۳	۱۵/۱۸	۳/۶۱	۱۲/۹۶	۰/۶۵
	GEP	-۰/۶۰	۲۰/۴۸	۴/۹۸	۱۳/۷۲	۱/۰۹
۳۰۰	MLP	-۱/۴۲	۲۸/۳۰	۵/۱۱	۲۱/۱۹	-۰/۶۸
	Cascade	-۱/۳۲	۳۲/۱۲	۵/۸۶	۱۹/۲۵	۰/۱۳
	GEP	-۲/۴۰	۴۰/۱۷	۶/۷۲	۲۹/۰۳	-۱/۲۴
۱۰۰۰	MLP	۱/۲۲	۳۱/۷۰	۳/۳۴	۳۱/۷۱	۲/۴۹
	Cascade	-۰/۷۶	۲۹/۴۲	۲/۹۴	۳۲/۱۵	-۰/۱۹
	GEP	-۱/۵۶	۴۲/۵۷	۳/۹۹	۵۱/۳۹	-۱/۲۷
۱۶۰۰۰	MLP	-۰/۴۸	۷۰/۷۸	۳/۱۰	۵۷/۲۸	۰/۷۳
	Cascade	-۰/۲۷	۴۳/۶۸	۲/۶۴	۴۴/۱۰	-۰/۲۶
	GEP	-۰/۷۲	۵۰/۰۷	۲/۷۴	۵۷/۷۷	-۰/۵۱



شکل ۶- همبستگی بین مقادیر رطوبت خاک پیش‌بینی شده و مشاهداتی (سناریوی سوم)

به منظور بررسی اثر نوع داده‌های ورودی بر عملکرد مدل‌ها از

مقایسه نتایج سناریوها

به سناریو اول به طور معنی‌داری موجب کاهش خطا شده است. شکل (۷) مقادیر مشاهداتی و پیش‌بینی شده رطوبت حجمی را برای بهترین ساختار هر کدام از مدل‌های بکار گرفته شده در سناریوی سوم نشان می‌دهد. مطابق نمودارهای ارائه شده در مکش‌های زیاد و یا به عبارت دیگر مقادیر رطوبت‌های پایین، دقت پیش‌بینی مدل‌ها کمتر از سایر نقاط می‌باشد، به طوری که بیش‌ترین اختلاف‌ها بین مقادیر مشاهداتی و پیش‌بینی شده در محدوده رطوبت حجمی زیر ۵ درصد مشاهده شد. در حالی که در سایر نقاط منحنی مشخصه آب خاک انطباق قابل قبولی بین داده‌های پیش‌بینی شده و مشاهداتی وجود داشت. با این وجود مقایسه بین نمودارها نیز نشان می‌دهد، در مکش‌های زیاد نیز عملکرد روش Cascade-NN نسبت به دو مدل دیگر نسبتاً بهتر بوده است. در خاک‌های سبک و نیمه سبک، تغییرات رطوبت در مکش‌های بالاتر از ۱۰۰۰ سانتی‌متر به طور قابل ملاحظه‌ای کاهش می‌یابد و مقدار رطوبت حجمی در یک گرادین کند کاهش می‌یابد. به نظر می‌رسد با کند شدن شیب کاهشی رطوبت خاک، عملکرد مدل‌های هوشمند نیز تحت تاثیر قرار گرفته و دقت پیش‌بینی‌ها نسبت به مکش‌های پایین کمتر می‌گردد.

توابع خروجی برنامه‌ریزی بیان ژن

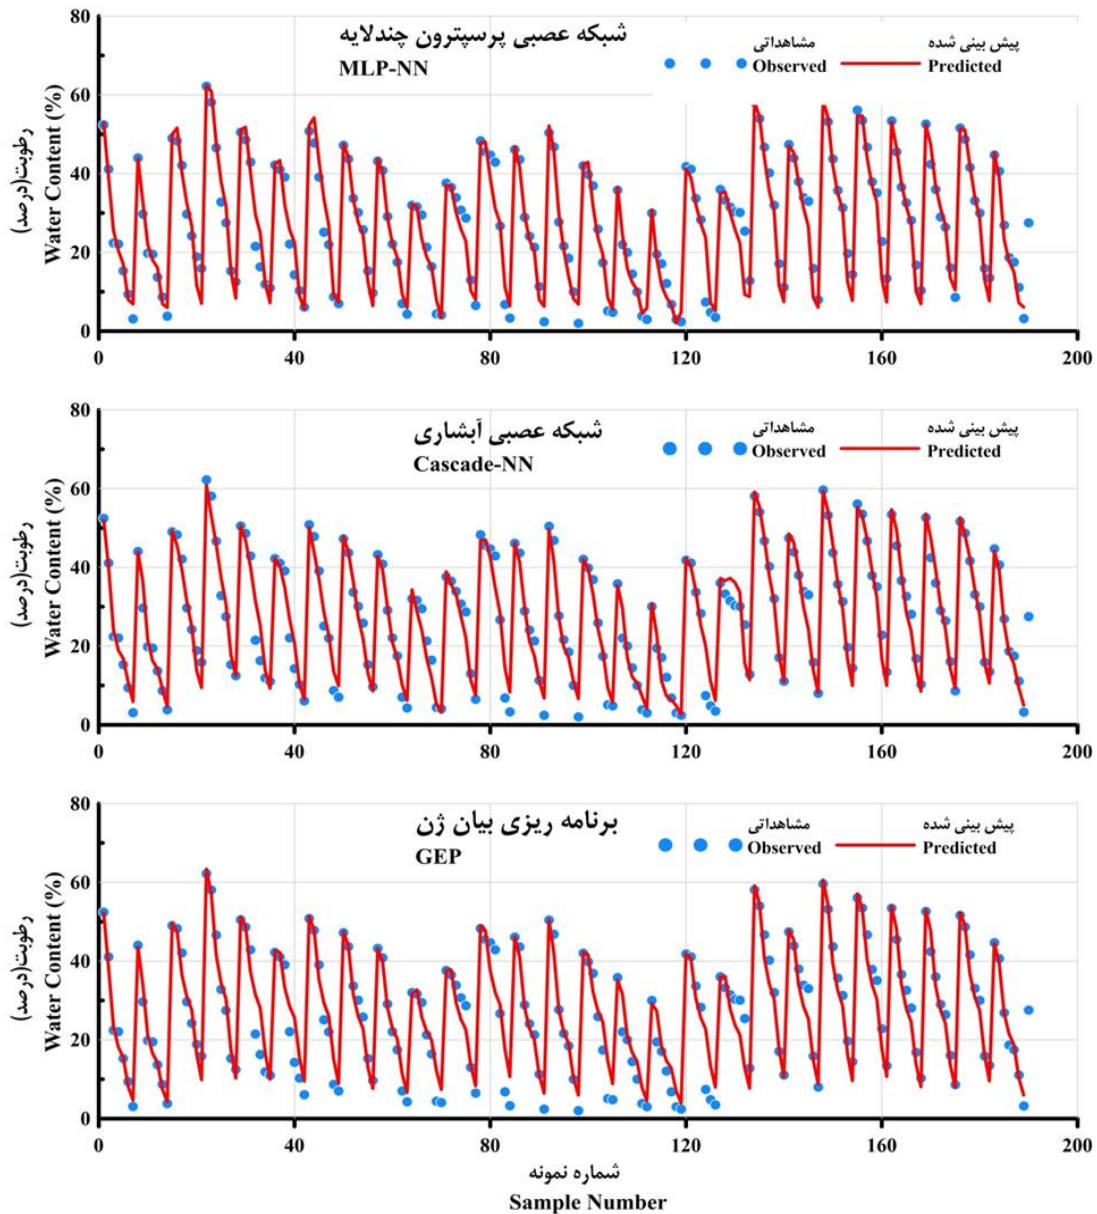
معادلات ریاضی مستخرج از اجرای مدل برنامه‌ریزی بیان ژن برای هر کدام از سناریوها (بهترین ساختار) در جدول (۶) ارائه شده است. اگرچه نتایج نشان داد در بین سه مدل ارزیابی شده به منظور برآورد منحنی مشخصه آب خاک، مدل برنامه‌ریزی بیان ژن کمترین دقت را دارا می‌باشد، با این وجود اختلاف بین مدل‌ها در برخی سناریوها از جمله سناریوی اول و سوم زیاد نبود. از سوی دیگر با توجه به اینکه مدل برنامه‌ریزی بیان ژن یک رابطه ریاضی بین ورودی‌ها و خروجی برقرار می‌نماید، می‌تواند از نظر کاربردی بیشتر از سایر مدل‌های هوشمند مورد توجه قرار گیرد.

مقادیر میانگین شاخص‌های آماری در مرحله آزمون استفاده شد. میانگین مقادیر ضریب تعیین سه مدل برای سناریوهای اول، دوم و سوم به ترتیب ۰/۸۵، ۰/۹۲ و ۰/۹۴ تعیین شد. ملاحظه می‌گردد با اضافه شدن پارامتر تخلخل در سناریو دوم، مقدار همبستگی بین مقادیر رطوبت خاک پیش‌بینی شده و مشاهداتی، افزایش حدود ۰/۰۷ و در سناریوی سوم نیز با اضافه شدن پارامتر رطوبت نقطه ظرفیت زراعی، مقدار همبستگی بهبود نسبی حدود ۰/۰۲ یافته است. میانگین مقادیر RMSE سه مدل برای سناریوهای اول، دوم و سوم به ترتیب ۵/۸۶، ۴/۴۵ و ۳/۴۵ درصد تعیین شد. اضافه شدن تخلخل به داده‌های ورودی در سناریوی دوم منجر به کاهش شاخص خطای RMSE به میزان ۱/۴ درصد شده است. با اضافه شدن رطوبت نقطه ظرفیت زراعی به داده‌های ورودی در سناریوی سوم، مقدار RMSE نسبت به سناریوی اول و دوم به ترتیب ۲/۴۱ و ۱/۰ درصد کاهش یافته است. از مقایسه اختلاف شاخص‌های R^2 و RMSE در سه سناریوی داده ورودی می‌توان بیان داشت که سناریوی سوم نسبت به دو سناریوی دیگر در تمامی مدل‌ها منجر به افزایش دقت پیش‌بینی‌ها شده است. نتایج بدست آمده با یافته‌های (Schaap *et al.*, 1998) همخوانی دارد. دقت پیش‌بینی مدل‌ها در مکش‌های پایین بیشتر از مکش‌های بالا تحت تاثیر سناریوهای داده ورودی قرار داشت به طوری که در مکش‌های کمتر از ۳۰۰ سانتی‌متر، مقدار خطای پیش‌بینی مدل‌ها در سناریوی سوم نسبت به سناریوهای اول و دوم به طور متوسط به ترتیب ۳/۱۴ و ۱/۲۳ درصد کاهش یافت. نتایج نشان داد، مدل‌های مورد استفاده در سناریوهای مختلف، قدرت تعمیم‌پذیری خوبی دارند. آزمون t به منظور مقایسه میانگین سناریوهای مختلف در مدل برتر CascadeNN انجام پذیرفت. نتایج آزمون نشان داد سناریوی سوم نسبت به سناریوهای اول و دوم به طور معنی‌داری موجب کاهش خطا و نزدیک شدن میانگین آن به میانگین داده‌های هدف بوده است. همچنین سناریوی دوم نسبت

جدول ۶- توابع ریاضی مستخرج از مدل برنامه‌ریزی بیان ژن برای سناریوهای مختلف

سناریو	بهترین معادله
اول	$\theta = -3.138 \left[(1.38 - \rho b) + 1.038 \rho b^{\frac{1}{9}} \right] \times \left(48.1 \times \frac{\rho b}{(2.15 \times (\log suc)^2)^{\left(\frac{\log suc}{3.299}\right)}} \right)^{\frac{1}{2}} \times \left(\left[-1.33 - (silt - 2.85 \log suc)^{\frac{1}{3}} \right] - clay^{\frac{1}{3}} \right)^{\frac{1}{3}}$
دوم	$\theta = \frac{-11.08 \log suc + W_0 - clay}{1.54} \times \left[1.55^{\left(\frac{silt - \log suc}{-2.476}\right)} + (1.57 \log suc - 5.32) \right]^2 \times \left[clay + \left(\frac{silt}{\left(\frac{-0.53}{\rho b} \right) - silt} (0.42 - \log suc) \right)^3 \right]$
سوم	$\theta = \left(\sqrt{\frac{FC}{0.44}} \right)^3 - \left(FC - \left(\frac{W_0}{4.73} \right) - FC \right) \times \left(\frac{W_0}{(W_0^2 \times \log suc^2) + (FC^2 \times 3.13)} \right) \times \left(\frac{(2.14 W_0) \sqrt{\log suc}}{FC + \log suc} + \sqrt{FC} \right)$

در روابط بالا، θ : درصد رطوبت حجمی، ρb : جرم مخصوص ظاهری، suc : مکش، $silt$: درصد سیلت، $clay$: درصد رس، W_0 : تخلخل و FC : رطوبت در نقطه ظرفیت زراعی می‌باشد.



شکل ۷- مقادیر مشاهداتی و پیش‌بینی شده درصد رطوبت خاک - سناریوی سوم

نتیجه‌گیری

و شبکه عصبی آبشاری (Cascade-NN)، شبکه عصبی آبشاری عملکرد نسبتاً بهتری نسبت به شبکه عصبی پرسپترون چند لایه از خود نشان داد. مقایسه بین نتایج سناریوهای مختلف نشان داد، استفاده از اطلاعات بافت، جرم مخصوص ظاهری، تخلخل و رطوبت نقطه ظرفیت زراعی خاک به عنوان داده‌های ورودی مدل-ها منجر به بیشترین دقت می‌گردد. با این وجود نتایج سناریوی دوم نیز که در آن پارامتر رطوبت ظرفیت زراعی در داده‌های ورودی قرار نداشت، قابل قبول ارزیابی شد. در نهایت می‌توان مدل شبکه عصبی Cascade-NN را با سناریوی سوم به عنوان بهترین روش و با سناریوی دوم به عنوان روش مقرون به صرفه‌تر معرفی نمود.

"هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد"

در این تحقیق با استفاده از برخی اطلاعات فیزیکی سهل الوصول خاک اقدام به ارزیابی و مقایسه عملکرد سه مدل هوشمند در پیش‌بینی منحنی مشخصه آب خاک شد. مدل‌های مورد استفاده در این مطالعه، مدل شبکه عصبی پرسپترون چندلایه، شبکه عصبی آبشاری و برنامه‌ریزی بیان ژن بود که پس از تعیین ساختار بهینه در هر یک از آن‌ها، مقادیر رطوبت خاک پیش‌بینی شده در مکش‌های مختلف با مقادیر مشاهداتی مورد مقایسه قرار گرفت. براساس مقادیر آماره‌های ارزیابی در هر دو فاز آموزش و آزمون، روش‌های شبکه عصبی دارای دقت بیشتری در برآورد منحنی مشخصه رطوبتی خاک در مقایسه با مدل برنامه‌ریزی بیان ژن بود. بین دو مدل شبکه عصبی پرسپترون چند لایه (MLP-NN)

REFERENCES

- Abbasi, A., Khalili, K., Behmanesh, J. and Shirzad, A. (2020). Comparison of artificial neural networks, bayesian network and gene expression programming in drought prediction (Case Study: Maragheh Synoptic Station). *Journal of Watershed Management Research*, 11(21), 59-71. (In Farsi)
- Akbarzadeh, A., Taghizadeh Mehrjardi, R., Rahimi Lake, H. and Ramezani, H. (2009). Application of artificial intelligence in modeling of soil properties (Case study: Roodbar Region, North of Iran). *Environmental Research Journal*, 3(2), 19-24.
- Alidadi, N. and Mahdavian, A. (2018). Modeling the amplification ratio of sandy soils using two methods of neural network and gene. *Scientific Quarterly Journal, Geosciences*, 107, 87-98. (In Farsi)
- Bayat, H., Neyshaburi, M. R., Mohammadi, K., Nariman-Zadeh, N., Irannejad, M. and Gregory, A. S. (2013). Combination of artificial neural networks and fractal theory to predict soil water retention curve. *Computers and Electronics in Agriculture*, 92, 92-103.
- Davari, M., Zalvae, Z. and Mahmoodi, M. A. (2019). A comparison between empirical and fractal models fitted to the measured soil moisture characteristic curve data. *Iranian Journal of Soil and Water Research*, 50(4), 847-862. (In Farsi)
- Dehghani, R., Younesi, H. and Torabi Poteh, H. (2017). Comparing the performance of support vector machine, gene expression programming and bayesian networks in predicting river flow (Case study: Kashkan River). *Journal of Water and Soil Conservation*, 24(4), 161-177. (In Farsi)
- Diamantopoulou, M. J., Antonopoulos, V. Z. and Papamichail, D. M. (2007). Cascade correlation artificial neural networks for estimating missing monthly values of water quality parameters in rivers. *Water Resour Manage*, 21, 649-662.
- Emangolizadeh, S., Bateni, S. M., Shahsavani, D., Ashrafi, T. and Ghorbani, H. (2015). Estimation of soil cation exchange capacity using genetic expression programming (GEP) and multivariate adaptive regression splines (MARS). *Journal of Hydrology*, 529(3), 1590-1600.
- Fahlman, S. E. and Lebiere, C. (1990). The cascade-correlation learning architecture. *Advances in Neural Information Processing Systems*, 524-532.
- Ferreira, C. (2001). Gene expression programming a new adaptive algorithm for solving problems. *Complex Systems*, 13(2), 87-129.
- Ferreira, C. (2006). Gene expression programming: mathematical modeling by an artificial intelligence 2nd ed. *Springer-Verlag, Germany*.
- Garg, A., Garg, A. and Tai, K. (2014). A multi-gene genetic programming model for estimating stress-dependent soil water retention curves. *Comput Geosci*, 18, 45-56.
- Ghorbani Dashtaki, SH. and Homaei, M. (2002). Derivation of the retention curve parameters using pedotransfer function. *Journal of Agricultural Engineering Research*, 3(12), 1-16. (In Farsi)
- Ghorbani, M. A., Deo, R. C., Kim, S., Kashani, M. H., Karimi, V. and Izadkhah, M. (2020). Development and evaluation of the cascade correlation neural network and the random forest models for river stage and river flow prediction in Australia. *Soft Computing*, 24, 12079-12090.
- Haghverdi, A., Ghahraman, B., Joleini, M., Khoshnud Yazdi, A. A. and Arabi, Z. (2011). Comparison of different artificial intelligence methods in modeling water retention curve (Case study: North and Northeast of Iran). *Journal of Water and Soil Conservation*, 18(2), 65-84. (In Farsi)
- Hosseini, S. A., Golabi, M. R., Marofi, S., Khalediyan, N. and Solatani, M. (2020). Evaluation of extended kalman filter-based neural network (EKFN) model and gene expression programming in rainfall-runoff model. *Journal of Watershed Engineering and Management*, 12(3), 771-784. (In Farsi)
- Hsu, K. L., Gupta, H. V. and Sorooshian, S. (1995). Artificial neural network modeling of the rainfall-runoff process. *Water Resources Research*, 31(10), 2517-2530.
- Jauhainen, M. (2004). Relationships of particle size distribution curve, Soil water retention curve and unsaturated hydraulic conductivity and their implications on water balance of forested and agricultural hillslopes, *Ph. D thesis, Helsinki University of Technology, Helsinki/Finland*.
- Jenadeleh, N., Nadian, H. A., Khalilimoghadam, B. and Ghorbani dashtaki, S. (2017). Point estimation of soil moisture characteristic curve using artificial neural networks and its optimizing by genetic algorithm in Agro-Industries of Khuzestan. *Watershed Management Research (Research and Construction)*, 113, 40-50. (In Farsi)
- Johari, A., Habibagahi, G. and Ghahramani, A. (2006). Prediction of Soil-Water Characteristic Curve Using Genetic Programming. *Journal of Geotechnical and Geoenvironmental Engineering*, 132:661-665.
- Johari, A., Javadi, A. A. and Habibagahi, G. (2011). modeling the mechanical behavior of unsaturated soils using a genetic algorithm-based neural network. *Computer and Geotechnic*, 38, 2-13.
- Johari, A. and Hooshmand Nejad, A. (2015). Prediction of soil-water characteristic curve using gene expression programming. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 39(1), 143-165.
- Kia, M. (2009). Neural networks in matlab. *Kian Rayan Sabz Publication, Tehran*, pp, 408. (In Farsi)
- Kianpoor Kalkhajeh, Y., Rezaie Arshad, R., Amerikhah, H. and Sami, M. (2012). Multiple linear regression, artificial neural network (MLP, RBF) and ANFIS models for modeling the saturated hydraulic conductivity of tropical region soils (A case study: Khuzestan Province: Southwest Iran). *International Journal of Agriculture: Research and Review*, 2(3), 255-265.
- Kisi, O., Shiri, J. and Tombul, M. (2013). Modeling rain fall-runoff process using soft computing

- techniques. *Computers Geosciences*, 51, 108-117.
- Lentzsch, P., Wieland, R. and Wirth, S. (2005). Application of multiple regression and neural network approaches for landscape-scale assessment of soil microbial biomass. *Soil Biology and Biochemistry*, 37, 1577-1580.
- Mahmoudabadi, E., Karaimi, A. R., Haghnia, Gh. H. and Sepehr, A. (2017). Assessing performance of multivariate linear regression (MLR), artificial neural network (ANN) and gene expression programming (GEP) in estimating soil properties. *Journal of Water and Soil Conservation*, 24(2), 23-44. (In Farsi)
- Mehdipour, V., Memarianfard, M. and Homayounfar, F. (2017). Application of gene expression programming to water dissolved oxygen concentration prediction. *International Journal of Human Capital in Urban Management*, 2(1), 1-10.
- 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 and Tillage Research*, 90, 108-116.
- Mermoud, A. and Xu, D. (2006). Comparative analysis of three methods to generate soil hydraulic functions. *Soil and Tillage Research*, 87, 89-100.
- Minasny, B. and McBratney, A. B. (2002). The neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Science Society of America Journal*, 66, 352-361.
- Mohammadi, J. (2002). Testing an artificial neural network for predicting soil water retention characteristics from soil physical and chemical properties. *17TH WORLD CONGRESS OF SOIL SCIENCE, Thailand*, 378-943.
- Moosavizadeh-Mojarrad, R. and Sepaskhah, A. R. (2011). Predicting soil water retention curve by artificial neural networks. *Archives of Agronomy and Soil Science*, 57(1), 3-13.
- Nikoee, E., Mirghafari, R., Habibagahi, G., Ghadamgahi Khorassani, A. and Nouri, A. M. (2020). Determination of soil-water retention curve: an artificial intelligence-based approach. *E3S Web of Conferences*, 195, 1-6.
- Oliaei, M. S., Barikloo, A. and Servati, M. (2019). Performance evaluation of artificial neural networks conjunct with genetic algorithm for estimation of soil infiltration rate (Case Study: Khoda afarin Region of East Azerbaijan Province). *Iranian Journal of Soil and Water Research*, 50(5), 1127-1139. (In Farsi)
- Rahimi Lake, H., Akbarzadeh, A. and Taghizadeh Mehrjardi, R. (2009). Development of pedotransfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zones of the Caspian Sea. *Ecology and The Natural Environment*, 1(7), 160-172.
- Rostamlou, M., Ojaghrou, H. and Karbasi, M. (2018). Comparison performance of adaptive neuro-fuzzy inference system (ANFIS) and gene expression programming (GEP) to estimate water distribution uniformity coefficient in classic sprinkle irrigation systems. *Iranian Water Research Journal*, 12(4), 85-94. (In Farsi)
- Ryan, M., Müller, C., Di, H. J. and Cameron, K. C. (2005). The use of artificial neural networks (ANNs) to simulate N₂O emissions from a temperate grassland ecosystem. *Ecological Modelling*, 175, 189-194.
- Sarmadian, F., Taghizadeh Mehrjui, R. A. and Akbarzadeh, A. (2009). Optimization of pedotransfer functions using an artificial neural network. *Australian Journal of Basic and Applied Sciences*, 3, 323-329.
- Schaap, M. G., Leij, F. J. and Van Genuchten, M. T. (1998). Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Science Society of America Journal*, 62, 847-855.
- Shahinejad, B. and Dehaghani, R. (2018). Comparison of wavelet neural network models, support vector machine, and gene expression programming in estimating the amount of oxygen dissolved in rivers. *Iran-Water Resources Research*, 14(3), 265-277. (In Farsi)
- sheikhesmaeili, O., Moazed, H. and Naseri, A. A. (2016). Evaluation of estimation methods for water field capacity in soils of Khuzestan Province. *Iranian Journal of Soil and Water Research*, 47(1), 55-63. (In Farsi)
- Shirani, H. and Rafienejad, N. (2012). Prediction of some difficult-to-measure soil characteristics using regression pedotransfer functions and artificial neural network in kerman province. *Iranian Journal of Soil Research (Soil and Water Science)*, 25(4), 349-359.
- Shiri, J., Sadraddini, A. A., Nazemi, A. H., Kisi, O., Landaras, G., Fakheri Fard, A. and Marti, P. (2014). Generalizability of gene expression programming-based approaches for estimating daily reference evapotranspiration in coastal stations of Iran. *Journal of Hydrology*, 508, 1-11.
- Solgi, A., Zarei, H. and Golabi, M. R. (2017). Performance assessment of gene expression programming model using data preprocessing methods to modeling river flow. *Journal of Water and Soil Conservation*, 24(2), 185-201. (In Farsi)
- Traore, S. and Guven, A. (2012). Regional specific numerical models of evapotranspiration using gene-expression programming interface in Sahel. *Water Resources Management*, 26, 4367-4380.
- Wosten, J. H. M., Pachepsky, Y. A. and Rawls, W. J. (2001). Pedotransfer functions bridging the gap between available basic soil data and missing soil hydraulic characteristics. *Hydrology*, 251, 123-150.
- Yosefi, M. and Poorshariaty, R. (2014). Suspended sediment estimation using neural network and algorithms assessment (Case Study: Lorestan Province). *Journal of Watershed Management Research*, 5(10), 85-97. (In Farsi)
- Zarei, M. M., Dastorani, M. T., Mesdaghi, M. and Eshghizadeh, M. (2017). Evaluation of the efficiency of different artificial intelligence and statistical methods in estimating the amount of

runoff (Case Study: Shahid Noori Watershed of Kakhk, Gonabad). *Journal of Watershed Management Research*, 8(16), 11-21. (In Farsi)

Zare zade Mehrizi, M. and Bozorg Hadad, A. (2008). Optimization of number of layers and neurons in artificial neural network with genetic algorithm method in flow prediction. *3rd Conference of*

Water Resources Management. Tabriz University. Faculty of Civil Engineering. Available in <http://www.civilica.com>. (In Farsi)

Zhu, A. X. and Julian, J. (2011). Unsaturated hydraulic properties of anisotropic soils. *State Water Resources Research Institute Program.*