

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)

MOHAMAD SADEGH OLIAEI^{1*}, ALI BARIKLOO², MOSLEM SERVATI³

1. Assistant Professor, And Faculty Member of the Ministry of Science, Research and Technology, Tehran, Iran

2. M.Sc. Graduated of Soil Science Department, Faculty of Agriculture, University of Zanjan, Zanjan, Iran

3. Assistant Professor, Shahid Bakeri High Education Center of Miandoab, Urmia University, Urmia, Iran

(Received: Aug. 25, 2018- Revised: July. 15, 2018- Accepted: Oct. 20, 2018)

ABSTRACT

Infiltration plays a pivotal role in the hydrologic cycle by effectively acting to partition water into surface and subsurface components. Direct measurement of infiltration rate is expensive and work and time consuming. Artificial Neural Networks (ANNs), Gene Expression Programming (GEP) and hybrid of ANN and Genetic Algorithm (ANN-GA) can be used for estimation of soil infiltration rate as an indirect methods. The main objective of this research was to develop an infiltration rate model in Khoda afarin region based on the collected data (88 double ring infiltration) and some soil properties. The Pierson correlation revealed among the soil properties, sand and silt contents, porosity and organic matter have the most correlation with the infiltration rate. Determination Coefficient (R^2) and Normalized Root Mean Square Error (NRMSE) were calculated to be 0.88 and 7.9%, respectively for the ANN method and 0.75 and 11.3% for the GEP method. Both ANN and GEP methods perform poorly, in extrapolating the minimum and maximum amount of infiltration rate. The hybrid model of ANN-GA was the best model in terms of statistical indices including R^2 (0.93) and RMSE (6.1%). This model comprised of 4 neurons (sand, silt, porosity percentage and OM) in input layer and 5 neurons using sigmoidal tangent functions in the hidden layer and linear activation functions in the output layer. The results indicated that the neural-genetics algorithm can be used to optimize weight parameter of artificial neural network. Overall the hybrid ANN-GA model showed better performance than the other models, so that the R^2 and NRMSE for the hybrid model were 0.93 and 6.1% respectively. Therefore it is suggested as a powerful tool for estimating infiltration rate.

Keywords: Genetics programming, artificial neural network, hybrid algorithm

ارزیابی عملکرد شبکه‌های عصبی مصنوعی با تلفیق الگوریتم ژنتیک در برآورد سرعت نفوذ آب به خاک (مطالعه موردی: منطقه خداآفرین استان آذربایجان شرقی)

محمدصادق علیائی^{۱*}، علی باریکلو^۲، مسلم ثروتی^۳

۱. استادیار، عضو هیات علمی وزارت علوم، تحقیقات و فناوری (معاونت پژوهش و فناوری)، تهران، ایران

۲. دانش‌آموخته کارشناسی ارشد علوم خاک، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

۳. استادیار مرکز آموزش عالی شهید باکری میاندوآب، دانشگاه ارومیه، ارومیه، ایران

(تاریخ دریافت: ۱۳۹۷/۶/۳ - تاریخ بازنگری: ۱۳۹۷/۴/۲۴ - تاریخ تصویب: ۱۳۹۷/۷/۲۸)

چکیده

نفوذ، نقش حیاتی را در چرخه هیدرولوژیکی با میزان پراکندگی آب به اجزای سطحی و زیرسطحی ایفا می‌کند. اندازه‌گیری مستقیم سرعت نفوذ، معمولاً کاربر، هزینه‌بر و وقت‌گیر هستند. شبکه عصبی مصنوعی، برنامه‌ریزی بیان ژن و الگوریتم ترکیبی شبکه عصبی مصنوعی-الگوریتم ژنتیک به‌عنوان روش‌های غیرمستقیم برای تخمین نفوذ آب به خاک استفاده شدند. هدف از این مطالعه، توسعه یک مدل مناسب برای تخمین نفوذ آب به خاک با استفاده از استوانه مضاعف در ۸۸ نقطه از منطقه خداآفرین استان آذربایجان شرقی می‌باشد. آنالیز همبستگی پیرسون نشان داد که از بین ویژگی‌های خاکی، شن، سیلت، تخلخل کل و کربن آلی بیشترین همبستگی را با نفوذ آب به خاک دارند. مقادیر ضریب تبیین و ریشه میانگین مربعات خطای نرمال شده برای مدل شبکه‌های عصبی مصنوعی و برنامه‌ریزی بیان ژن به ترتیب برابر ۰/۸۸، ۷/۹ و ۰/۷۵، ۱۱/۳ محاسبه شد که هر دو روش در ارزیابی حداقل و حداکثر مقادیر نفوذ آب به خاک از دقت کافی برخوردار نبودند. در روش شبکه‌های عصبی مبتنی بر الگوریتم ژنتیک از توابع تانژانت سیگموئیدی در لایه میانی و محرک خطی در لایه خروجی با ۵ نرون در لایه فعال استفاده شد. این مدل از دقت و صحت بیشتری نسبت به مدل شبکه‌های عصبی مصنوعی و برنامه‌ریزی بیان ژن برخوردار می‌باشد، به طوری که مقادیر R^2 و NRMSE برای مدل ترکیبی عصبی-ژنتیک به ترتیب برابر ۰/۹۳ و ۶/۱ درصد بود. نهایتاً الگوریتم ژنتیک با بهینه‌سازی اوزان شبکه‌های عصبی باعث بهبود مدل‌سازی شد، لذا این روش به‌عنوان روش کارا در تخمین نفوذ آب به خاک معرفی می‌گردد.

واژه‌های کلیدی: برنامه‌ریزی بیان ژن، شبکه‌های عصبی مصنوعی، الگوریتم تلفیقی

مقدمه

این فرآیند سبب گردیده است، مدل‌های فیزیکی و تجربی گوناگونی به‌منظور کمی نمودن این فرآیند ارائه گردد (Argyrokastritis and Kerkides, 2003). طی سالیان گذشته مدل‌های فیزیکی و تجربی فراوانی برای کمی کردن فرآیند نفوذ آب به خاک ارائه شده است (Kao and Hunt, 1996; Green and Ampt, 1911). استفاده از توابع انتقالی یکی از روش‌های غیرمستقیم می‌باشد که می‌توان با استفاده از آن‌ها از ویژگی‌های زود یافت خاک، ویژگی‌های دیر یافت خاک را تخمین زد (Kao and Hunt, 1996). بنابراین میزان علاقه به استفاده از توابع انتقالی برای تخمین ویژگی‌های هیدرولیکی خاک روز به روز در حال افزایش است (Leij et al., 2002). از جمله مدل‌های برآوردکننده توابع انتقالی شبکه‌های عصبی مصنوعی می‌باشند (Minasny et al., 2004). شبکه‌های هوشمند عصبی

نفوذ آب به خاک نقشی بسیار مهم در چرخه آبی طبیعت ایفا می‌کند. دستیابی به مدیریت صحیح آبیاری، ذخیره رطوبتی مطلوب خاک در مناطق خشک، عملکرد زراعی قابل قبول و سامانه پایدار حفاظتی خاک در گرو مدنظر قرار دادن نفوذ آب به خاک است (Ghorbani Dashtaki and Homaei, 2000). پیش‌بینی سیل خیزی، فرسایش خاک و انتقال آلاینده‌ها همگی به میزان رواناب ایجاد شده بستگی دارد که به‌طور مستقیم به پدیده‌ی نفوذ آب به خاک وابسته می‌باشد (Tsanis, 2006). کمی کردن پدیده نفوذ آب به خاک، به‌منظور تعیین مقدار آب قابل دسترس برای رشد گیاه و تخمین مقدار آب اضافی موردنیاز که باید از طریق آبیاری تأمین شود و نیز طراحی سامانه‌ای‌های آبیاری دارای اهمیت می‌باشد. اهمیت

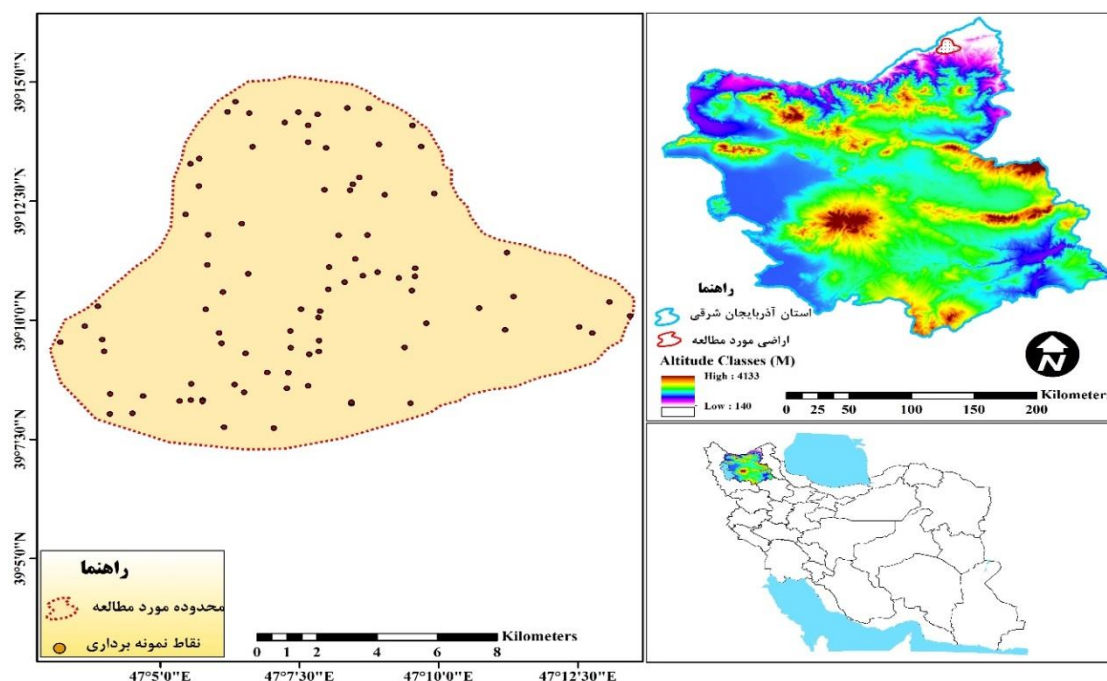
دستگاه ونتوری^۲ معرفی کردند. Barikloo *et al.* (2017) کارایی مدل شبکه‌های عصبی مصنوعی - الگوریتم ژنتیک را با موفقیت برای تشریح رابطه بین عملکرد گندم و ویژگی‌های زودیاقت گزارش کرد، به‌طوری‌که دارای ضریب تبیین بالا (۰/۹۲) و میانگین انحراف مربعات خطای کم (۴۷۳/۵ کیلوگرم در هکتار) بود. کاربرد الگوریتم ژنتیک با هدف کاهش خطاهای شبکه عصبی مصنوعی در برآورد مشخصات جریان چند فازی توسط، Laurentiu *et al.* (2002) بررسی شد. نتایج ارزیابی‌های Haghverdi *et al.* (2011) نیز نشان از برتری عملکرد الگوریتم عصبی ژنتیک نسبت به الگوریتم عصبی فازی در خصوص منحنی مشخصه رطوبتی خاک بود که Goldberg (1989) دلیل آن را در آموزش مناسب‌تر شبکه می‌داند. Prasad and Mathur (2007) با استفاده از شبکه‌های عصبی مصنوعی و تلفیق آن با الگوریتم ژنتیک (ANN-GA) به شبیه‌سازی حرکت املاح آب‌های زیرزمینی پرداختند. آن‌ها نشان دادند در مواقعی که داده‌های اندازه‌گیری شده برای لایه ورودی شبکه عصبی دقت پایینی دارد، الگوریتم ژنتیک در افزایش دقت برآوردهای شبکه عصبی مؤثر است. از آنجایی که داشتن داده‌های بهنگام و به‌روز نفوذ آب به خاک در طراحی و اجرای پروژه‌های آبیاری در پایاب سد خداآفرین اجتناب‌ناپذیر بوده و از طرف دیگر اندازه‌گیری نفوذ آب به خاک به دلیل وقت‌گیر بودن و نیاز به تعداد زیاد اندازه‌گیری با توجه به وسعت منطقه، نیازمند صرف هزینه و وقت زیادی است، لذا مدل‌سازی نفوذ آب به خاک ضروری به نظر می‌رسد. لذا هدف از این پژوهش انتخاب مناسب‌ترین مدل از بین شبکه‌های عصبی مصنوعی، برنامه‌ریزی بیان ژن و الگوریتم ترکیبی شبکه‌های عصبی مصنوعی - الگوریتم ژنتیک در تخمین نفوذ آب به خاک می‌باشد. لازم به ذکر است که دو روش شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک با موفقیت در مدل‌سازی سرعت نفوذ آب به خاک در تحقیقات مختلف به کار گرفته شده و انتظار می‌رود در روش تلفیقی، الگوریتم ژنتیک با افزایش بسیار زیاد سرعت همگرایی به سمت مدل دقیق و پایداری شبکه عصبی نتایج بهتری ارائه نماید.

مواد و روش‌ها

موقعیت و وسعت

منطقه مورد مطالعه از اراضی کشاورزی مناطق روستایی پایاب سد خداآفرین در شمال شرق استان آذربایجان شرقی می‌باشد. از نظر جغرافیایی منطقه در مختصات طولی ۶۷۵۵۰۰ تا ۶۹۲۵۰۰ متر و مختصات عرضی ۴۳۳۲۵۰۰ تا ۴۳۴۹۰۰۰ متر (شکل ۱) واقع شده است.

ANNs^۱) به دلیل توانایی مدل‌سازی سامانه‌های پیچیده در بسیاری از علوم مانند آب و خاک به کار رفته‌اند. شبکه‌های عصبی مصنوعی یکی از رویکردهای جایگزین روش‌های آماری است که براساس فرآیند آموزش داده‌ها و رابطه بین داده‌های ورودی و خروجی عمل می‌کنند (Zare Abyanehe *et al.*, 2010). روش ANNs به‌عنوان پردازشگری هوشمند و موفق در تخمین ویژگی‌های هیدرولیکی خاک نتایج خوبی ارائه داده است (Merdu *et al.*, 2006). Nestor (2006) با استفاده از مدل شبکه‌های عصبی مصنوعی، نفوذ آب به خاک را با دقت بالایی ($R^2 = 0/91$) در فیلپین برآورد و گزارش کرد که رطوبت خاک و هدایت هیدرولیکی دو ویژگی مؤثر در برآورد نفوذ آب به خاک است. Sunli *et al.* (2008) نفوذ آب به خاک را با عامل‌های جرم مخصوص خاک و رطوبت بهینه چهار بافت خاک با ضریب تبیین ۰/۹۵ با استفاده از شبکه عصبی مصنوعی برآورد کردند. یکی دیگر از روش‌های ایجاد و توسعه توابع انتقالی روش برنامه‌ریزی بیان ژن است. روش برنامه‌ریزی بیان ژن جدیدترین شیوه از بین روش‌های الگوریتم تکاملی است که به دلیل دارا بودن دقت کافی، از کاربرد بیشتری برخوردار است (Alvisi *et al.*, 2005). در مطالعات مربوط به آب و خاک روش برنامه‌ریزی بیان ژن در مدل‌سازی فرآیندهای بارش-رواناب (Khu *et al.*, 2001)، برآورد رواناب (Savic *et al.*, 1999)، فرآیند بارش-دبی (Hong *et al.*, 2005)، هدایت هیدرولیکی اشباع (Parasuraman *et al.*, 2007) و رطوبت خاک (Makkeasorn *et al.*, 2006) به کار برده شده است. از سویی محققین با تلفیق الگوریتم ژنتیک و منطق فازی در شبکه‌های عصبی مصنوعی سعی در افزایش دقت برآوردها داشته‌اند (Aytek and Kisi, 2008). به الگوریتم‌های فراابتکاری ترکیبی، مدل‌سازی چندگانه نیز اطلاق می‌شود. مدل‌سازی چندگانه روشی برای اعمال چند مدل در توصیف نوع فرآیند حاکم، برای حصول نتیجه بهتر است. به‌عبارت دیگر قرار گرفتن دو مدل فراابتکاری در کنار یکدیگر می‌تواند ما را به سطح بالاتری از توانمندی‌ها در پاسخگویی به نیازهایمان برساند. به‌عنوان نمونه تلفیق شبکه عصبی مصنوعی با الگوریتم ژنتیک، منجر به برآوردهای مناسب‌تری از مشخصات پرش هیدرولیکی در جریان غیرماندگار نسبت به روش شبکه‌های عصبی مصنوعی شد (Parvareh Rizi *et al.*, 2006). Goldberg (1989) علت برآوردهای بهتر الگوریتم ترکیبی شبکه عصبی مصنوعی - الگوریتم ژنتیک را در آموزش مناسب‌تر شبکه عصبی مصنوعی می‌داند. در پژوهشی، Nasseh *et al.* (2009) ترکیب الگوریتم ژنتیک و شبکه عصبی مصنوعی را روشی قابل اعتماد و موفق در تخمین فشارهای به‌دست آمده از



شکل ۱- موقعیت منطقه مورد مطالعه و نقاط نمونه برداری

گرفت. شکل (۲) نیز به طور خلاصه روند اجرای مطالعه حاضر را نشان می‌دهد به طوری که بعد از آماده‌سازی داده‌ها، مدل‌سازی با استفاده از سه مدل (شبکه‌های عصبی مصنوعی، برنامه‌ریزی بیان ژن و مدل ترکیبی شبکه‌های عصبی مصنوعی - الگوریتم ژنتیک) انجام و سپس این مدل‌ها بر اساس آماره‌های R^2 و RMSE، شیب خط برازش یافته، عرض از مبدأ معادله حاصله از مدل‌های برازشی مورد ارزیابی قرار گرفته و مناسب‌ترین مدل برای تخمین ویژگی نفوذ آب به خاک انتخاب شد. در این تحقیق از نرم‌افزار استفاده MATLAB R2016b برای مدل‌سازی نفوذ آب به خاک استفاده شد.

شبکه‌های عصبی مصنوعی

در این پژوهش برای شبیه‌سازی و پیش‌بینی مقادیر نفوذ آب به خاک، از شبکه‌های MLP استفاده شد (Haykin, 1999). در این ساختار، هر شبکه عصبی مصنوعی شامل ورودی و لایه‌های مخفی و خروجی است. در طی فرآیند یادگیری، میزان فراگیری توسط شبکه به وسیله توابع هدف به طور مرتب مورد ارزیابی و شبکه‌های با کمترین میزان خطا مورد پذیرش قرار گرفت. همچنین برای نرمال‌سازی داده‌های اولیه از رابطه (۱) استفاده شد.

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1) \text{ رابطه}$$

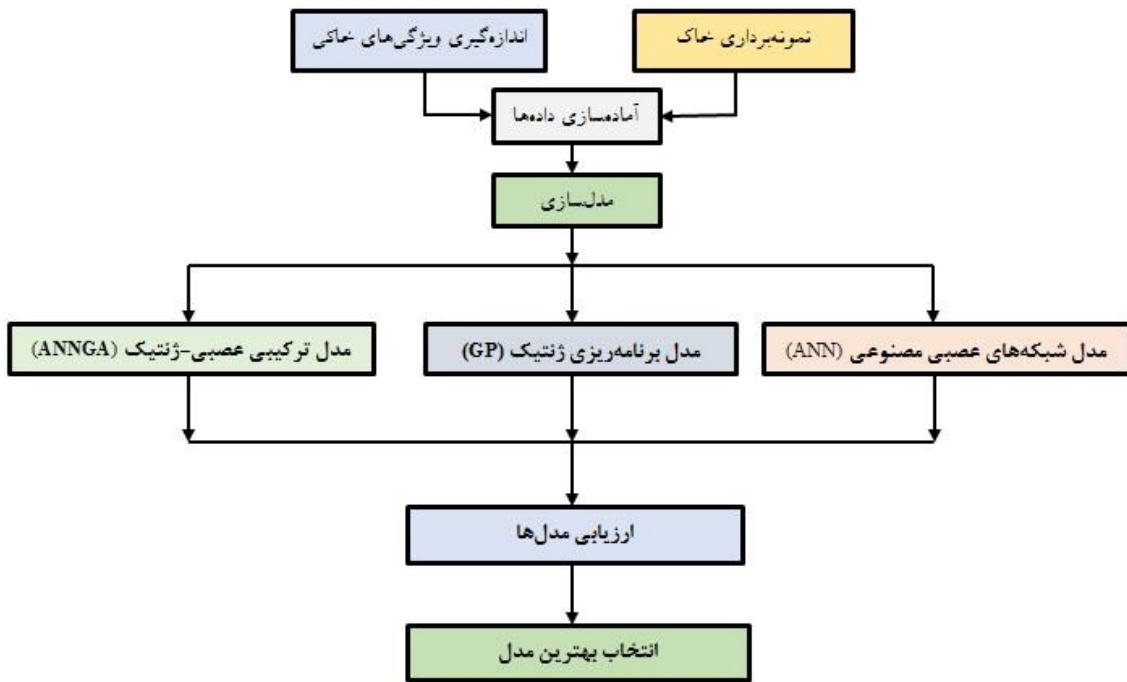
در رابطه (۱) X_n ، X ، X_{max} و X_{min} به ترتیب نشان‌دهنده مقادیر واقعی، نرمال‌شده، حداکثر و حداقل داده‌های تحت بررسی هستند. برای تعیین شبکه بهینه با بیشترین سطح

به منظور دستیابی به اهداف تحقیق ۸۸ نقطه نمونه برداری با کمک سیستم اطلاعات جغرافیایی و مدنظر قرار دادن یکنواختی بافت خاک و نوع کاربری اراضی برای مدل‌سازی انتخاب شد. داده‌های نفوذ آب به خاک با استوانه‌های مضاعف اندازه‌گیری و یک نمونه خاک از هر نقطه از عمق ۳۰ - ۰ سانتی‌متری برداشته شد. لازم به ذکر است که بر اساس مطالعات احمدی (۲۰۱۸) انقطاع لیتوژیکی و لایه محدودکننده در سری‌های مورد مطالعه وجود ندارد (Ahmadi, 2018). آزمایش استوانه‌های مضاعف در ۳ تکرار و تا ثابت شدن سرعت نهایی نفوذ انجام شد. سپس آزمایش‌های فیزیکی و شیمیایی خاک از جمله بافت به روش هیدرومتر (Gee and Or, 2002)، کربن آلی به روش والکلی و بلک (Nelson and Sommer, 1982)، ذرات درشت‌تر از شن به روش حجمی، کربنات کلسیم معادل به روش خنثی‌سازی با اسید (Nelson, 1982) انجام شد.

به منظور ارائه مدل مناسب، داده‌ها به سه دسته تقسیم شدند؛ ۷۰ درصد سری داده‌ها به آموزش، ۱۵ درصد به اعتبارسنجی متقابل و ۱۵ درصد به آزمون شبکه اختصاص یافت. مقادیر پیشنهادی نرم‌افزار برای تخصیص ردیف به آموزش، آزمون شبکه و اعتبارسنجی متقابل به ترتیب برابر با ۶۰، ۲۵ و ۱۵ درصد داده‌ها است. به این ترتیب بر اساس داده‌های آموزشی، مناسب‌ترین رابطه با بیشترین تناسب بین داده‌ها انتخاب شد و صحت و عملکرد رابطه ارائه‌شده در زیر مجموعه آزمایشی مورد بررسی قرار

مناسبترین روش برای آموزش شبکه‌های عصبی مصنوعی طراحی شده می‌باشد و سرعت بالاتری نسبت به دیگر الگوریتم‌های پس‌انتشار خطا دارد (Zare Abyaneh et al., 2009). برای تعیین بهترین تعداد نرون، از ۲ تا ۱۰ نرون در هر لایه در نظر گرفته شد و با روش سعی و خطا بهترین تعداد نرون برای برآورد نفوذ آب به خاک تعیین گردید.

عملکرد از کلیه توابع محرک تعریف شده در نرم‌افزار (تانژانت هیپربولیک آکسون، سیگموئید آکسون، تانژانت هیپربولیک خطی آکسون، سیگموئید خطی آکسون، بایاس آکسون، آکسون خطی و آکسون) به شکل سعی و خطا تا حصول مناسب‌ترین نتیجه استفاده شد. برای آموزش شبکه‌های تعریف شده، از توابع آموزشی لوبنرگ-مارکوارت^۱ (LM) استفاده شد. این الگوریتم آموزشی



شکل ۲- مراحل مدل سازی و انتخاب مناسب ترین مدل

روش ترکیبی شبکه‌های عصبی مصنوعی- الگوریتم ژنتیک (ANNGA)

در این تحقیق از الگوریتم ژنتیک به منظور یافتن نقطه بهینه توابع پیچیده غیرخطی در ترکیب با شبکه عصبی مصنوعی استفاده شد. الگوریتم ژنتیک باعث بهینه‌سازی وزن‌های شبکه عصبی مصنوعی می‌شود. در واقع تابع هدف الگوریتم ژنتیک تابعی از نتایج آماری شبکه عصبی مصنوعی است (Nosrati and Eftekhari, 2014). برای آموزش ابتدا تعداد P (جمعیت هر نسل) شبکه عصبی مصنوعی به‌طور تصادفی مقداردهی اولیه شد و میزان خطا با استفاده از داده‌های آموزش محاسبه گردید. در مرحله بعد به‌روزرسانی ویژگی‌های شبکه با توجه به مقادیر نفوذ آب به خاک و نرخ‌های جهش و آمیزش انجام شد. الگوریتم بالا تا نبود بهبودی در ویژگی‌های شبکه با در نظر گرفتن جمعیت جدید به دست آمده تکرار گردید. در آخرین مرحله خروجی به دست آمده از اجرای شبکه با مقادیر واقعی مقایسه و در صورت حداقل

برنامه‌ریزی بیان ژن

برنامه‌ریزی بیان ژن یک تکنیک برنامه‌ریزی خودکار است که بر اساس تئوری داروین پایه‌ریزی شده و توانایی مدل‌سازی فرآیندهای کاملاً غیرخطی مانند نفوذ آب به خاک را دارد. برنامه‌ریزی بیان ژن تناوبی از راه‌حل‌ها را از طریق ابداع ساختارهای غیرخطی (نمودار درختی^۲) با اندازه‌ها و شکل‌های منخلف ارائه می‌کند. این روش شامل یک رابطه ارتباط‌دهنده بین متغیرهای ورودی و خروجی بوده، لذا قادر به انتخاب خودکار متغیرهای مناسب الگو و حذف متغیرهای غیر مرتبط است که این امر سبب کاهش ابعاد متغیرهای ورودی خواهد شد (Liong et al., 2002; Koza, 1992). مشکل این است که بهسازی‌ها باید روی خود نمودار درختی رخ دهد و تنها دامنه محدودی امکان‌پذیر است (Ferrier and Guisan, 2006). برای این منظور در این تحقیق، ابتدا متغیرهای ورودی، هدف و تابع ارتباط‌دهنده تعریف و سپس الگو و اوزان مشخص شد.

معیارهای مورد نظر از رابطه‌های (۲) و (۳) به دست می‌آیند. همچنین برای سنجش کارایی مدل‌های انتخابی، این مدل‌ها با مدل‌های نفوذ کوستیاکف-لوئیس و فلیپ نیز مقایسه شدند. (رابطه ۲)

$$R = \frac{\sum_{i=1}^n (y_{act} - \bar{y}_{act})(y_{est} - \bar{y}_{est})}{\sqrt{\sum_{i=1}^n (y_{act} - \bar{y}_{act})^2 \sum_{i=1}^n (y_{est} - \bar{y}_{est})^2}}$$

$$NRMSE = \sqrt{\frac{\sum [X(t) - \hat{x}(t)]^2}{\sum x^2(t)}}$$

(رابطه ۳)

در این روابط، مقدار نفوذ y_{act} اندازه‌گیری شده، y_{est} مقدار نفوذ برآورد شده و n تعداد داده‌ها می‌باشد. هرچه R^2 به یک و $NRMSE$ به صفر نزدیک باشد، نشان‌دهنده نزدیکی بیشتر مقادیر برآورد شده به مقادیر اندازه‌گیری شده است.

نتایج و بحث

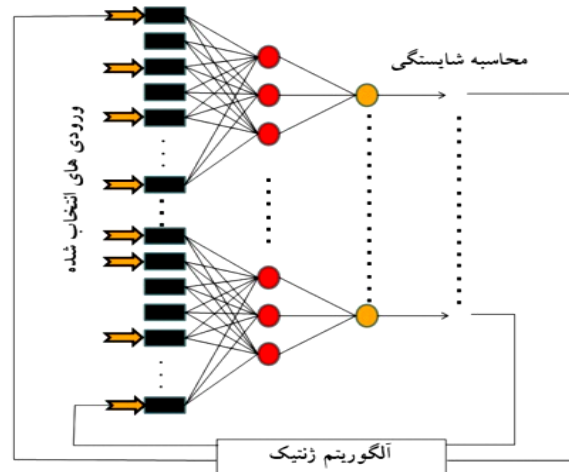
انتخاب متغیرهای مناسب برای مدل‌سازی سرعت نفوذ آب به خاک جدول (۱) پارامترهای آماری برای ویژگی‌های اراضی انتخاب شده در مدل‌سازی نفوذ آب به خاک را در منطقه مطالعاتی نشان می‌دهد.

جدول ۱- ویژگی‌های خاکی انتخابی در مدل‌سازی سرعت نفوذ آب به خاک

نفوذ آب به خاک Cm.h ⁻¹	آهک	ماده آلی	تخلخل	سنگریزه درصد (%)	رس	سیلت	شن	ویژگی‌های آماری
۱۳/۵۳	۱۷	۲/۷۱	۰/۵۱	۹/۵۹	۳۴/۱۵	۳۲/۹۸	۳۲/۸۵	میانگین
۱۲/۲	۱۵/۸	۲/۷۲	۰/۵۲	۱۰	۳۴/۵	۳۲	۳۳	میانه
۶/۹۷	۷/۱۹	۱/۴۶	۰/۱۰	۳/۲۸	۱۱/۵۵	۵/۷۸	۱۰/۵۸	انحراف استاندارد
۳/۹۹	۳/۲۸	۰/۷۸	۰/۰۲۳	۴/۴۲	۳/۸۶	۱/۰۴	۳/۳۹	ضریب تغییرات
۴۸/۶۸	۵۱/۸۳	۲/۱۳	۰/۰۱۲	۱۰/۷۵	۱۳۳/۴۲	۳۳/۴۸	۱۱۲/۰۵	واریانس
۱/۰۷	۰/۵۹	-۰/۰۳	-۰/۳۴	۰/۱	-۰/۱۱	-۰/۱۶	-۰/۰۱	چولگی
۰/۸۴	-۰/۳۵	-۱/۱۳	۰/۵۴	-۰/۹۷	-۰/۵۵	-۰/۳۸	-۰/۴۹	کشدگی
۳/۱	۴/۸	۰/۱۷	۰/۲۸	۴	۷	۱۹	۱۰	حداقل
۳۴/۵	۲/۳۴	۵/۲۳	۰/۶۸	۱۶	۵۹	۴۵	۰/۵۹	حداکثر

بر ساعت و حداکثر آن ۳۴/۵ سانتی‌متر بر ساعت می‌باشد که می‌تواند به دلیل وابستگی به فرآیندهای ذاتی و مدیریتی خاک باشد. نتایج حاصل از ضریب همبستگی پیرسون بین متغیر مستقل (نفوذ آب به خاک) و متغیرهای وابسته (ویژگی‌های خاک)

شدن تفاوت بین دو مقدار بالا، اجرای مدل خاتمه یافت. شکل (۳) فلوجارت مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک را نمایش می‌دهد.



شکل ۳- فلوجارت الگوریتم ترکیبی شبکه عصبی مصنوعی-الگوریتم ژنتیک (ANN-GA)

معیارهای ارزیابی و عملکرد مدل‌ها

برای انتخاب مناسب‌ترین مدل، مقایسه مقادیر نفوذ آب به خاک برآوردی با اندازه‌گیری شده با استفاده از معیار جذر میانگین مربعات خطای نرمال شده^۱ ($NRMSE$) با هدف کمینه شدن خطا، معیار ضریب تبیین (R^2) و نمودارهای ترسیمی در هر سه سری داده مرحله آموزش، اعتبارسنجی و آزمون صورت گرفت.

ضریب تغییرات معیاری بدون بعد بوده و برای مقایسه تغییرات ویژگی‌ها کاربرد دارد. در این راستا، بیشترین و کمترین ضریب تغییرات مربوط به درصد سنگریزه با ۴/۴۲ درصد و تخلخل با ۰/۰۲۳ درصد می‌باشد. حداقل نفوذ آب به خاک ۳/۱ سانتی‌متر

شدن خلل و فرج و کم شدن نفوذ آب به خاک است و احتمالاً به این دلیل هیچ‌گونه همبستگی بین درصد رس و نفوذ آب به خاک وجود نداشت (Kazman et al., 1983). در خصوص عدم همبستگی رس با نفوذ آب به خاک می‌توان مطرح کرد که ذرات رس همانند سیمان در خاکدانه‌ها عمل کرده و به دلیل آماس موجب کاهش نفوذ آب به خاک می‌شود. در مقابل ذرات سیلت و شن به دلیل عدم چسبندگی، ایجاد منافذ درشت و نداشتن خاصیت آماس، دارای ضریب همبستگی مثبت و معنی‌دار در سطح احتمال یک درصد با نفوذ آب به خاک می‌باشند. مثبت بودن همبستگی مواد آلی با ویژگی نفوذ آب به خاک می‌تواند ناشی از بهبود ساختمان خاک و در نتیجه افزایش نفوذ آب به خاک باشد. با این وجود در این تحقیق هیچ‌گونه همبستگی بین مقدار آهک و نفوذ آب به خاک وجود مشاهده نشد لذا در مدل-سازی از درصد آهک به‌عنوان ورودی صرف‌نظر شد. Jarvis et al. (2002) برای تخمین هدایت هیدرولیکی اشباع از ویژگی‌های توزیع اندازه ذرات خاک، میانگین هندسی قطر ذرات، جرم مخصوص ظاهری، مقدار مواد آلی و تخلخل مؤثر استفاده کردند و نتایج آن‌ها نیز نشان داد که ویژگی تخلخل مؤثر و توزیع اندازه ذرات از مهم‌ترین متغیرهای پیش‌بینی کننده هدایت هیدرولیکی اشباع هستند.

در جدول (۲) ارائه شده است. از آنجایی که توانمندی تخمین مدل‌های فراکوشی در انتخاب صحیح به ورودی‌ها در لایه اول بستگی دارد، بنابراین با ارائه ماتریس همبستگی ارتباط بین ویژگی‌های فیزیکی و شیمیایی خاک (متغیر مستقل) و نفوذ آب به خاک (متغیر وابسته) مشخص شد. نتایج جدول (۲) مؤید این مطلب است که بدون توجه به علامت، کمترین ضریب همبستگی به درصد سنگریزه و آهک (۰/۱۲ و ۰/۰۷۶) تعلق دارد. به نظر می‌رسد یکی از دلایل پایین بودن ضریب همبستگی درصد آهک با نفوذ آب به خاک می‌تواند ناشی از تاثیر منفی مقدار آن (جدول ۲)، بر نفوذ آب به خاک باشد. به طوری که درصد آهک در مقادیر اندک سبب افزایش هم‌آوری ذرات و در نتیجه افزایش نفوذ آب به خاک در مقادیر زیاد سبب تشکیل سخت لایه‌ها و کاهش نفوذ آب به خاک می‌گردد. بیشترین مقدار همبستگی بین متغیرهای وابسته با متغیر مستقل مربوط به ویژگی تخلخل و ماده آلی به مقدار ۰/۶۷ و ۰/۶۵ در سطح احتمال یک درصد است. اهمیت کربن آلی به دلیل داشتن سطح ویژه زیاد و پویایی آن در سامانه خاک، همگام با تغییرات درونی خاک و تغییرات بیرونی اتمسفر است (Zhang and McGrath, 2004). به همین ترتیب همبستگی عامل درصد ذرات شن با نفوذ آب به خاک در مقایسه با سایر عامل‌ها، منفی ولی در سطح احتمال یک درصد معنی‌دار است. همچنین از آنجایی که گاهی رس خاک عاملی برای بسته

جدول ۲ - ضرایب همبستگی پیرسون بین ویژگی‌های خاکی با نفوذ آب به خاک

شن	سیلت	رس	سنگریزه	تخلخل	ماده آلی	آهک	نفوذ آب به خاک
۱							
سیلت	-۰/۹۹						
رس	-۰/۸۶**	-۰/۴۱**					
سنگریزه	-۰/۰۴۷	-۰/۲۴*	۰/۱۶				
تخلخل	-۰/۰۸۴**	۰/۱۱۲	۰/۷۲**	۰/۰۹۲			
ماده آلی	-۰/۰۸۶**	-۰/۱۱	۰/۷۳**	۰/۰۵۷	۰/۹۸**		
آهک	-۰/۱۱۲	۰/۰۹۲	۰/۰۴۸	۰/۰۲۵	۰/۱۵	۰/۱۱	
نفوذ آب به خاک	-۰/۰۵۴**	۰/۰۵۹**	۰/۰۲	۰/۰۷۶	۰/۰۶۷**	۰/۱۲	۱

** همبستگی در سطح احتمال ۰/۰۱، * همبستگی در سطح احتمال ۰/۰۵

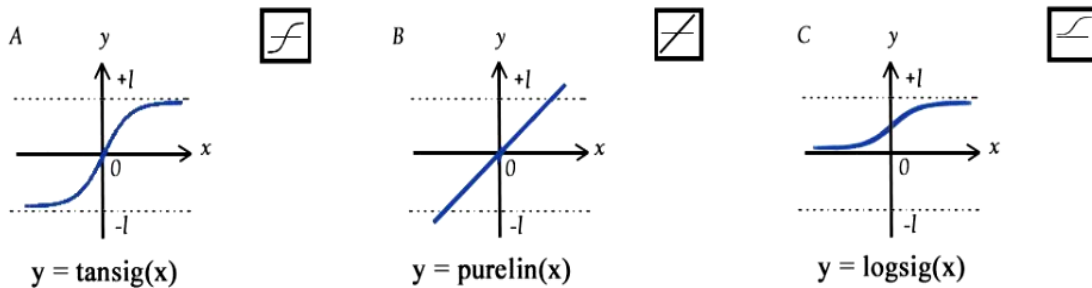
عصبی نوع خاصی از روابط لازم نیست و با ایجاد رابطه مناسب بین داده‌های ورودی و خروجی می‌توان به نتایج مناسب دست پیدا کرد (Amini et al., 2005). Pachepsky et al. (1996) نیز با استفاده از آماره‌های R^2 و RMSE به بررسی شبکه عصبی مصنوعی و آنالیز رگرسیون پرداختند. نتایج نشان داد که شبکه عصبی مصنوعی تخمینی مناسب با خطای کمتری، بر اساس داده‌های زود یافت خاک دارد.

مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی

نهایتاً برای نرون‌های میانی و خروجی به ترتیب از تانژانت سیگموئیدی و محرک خطی (شکل ۴) که نسبت به سایر ترکیب-ها دارای بالاترین ضریب تبیین و کمترین جذر میانگین مربعات خطای استاندارد شده بود، استفاده شد. سپس با تغییر تعداد نرون‌ها از دو تا ده مناسب‌ترین مدل تخمین نفوذ آب به خاک انتخاب گردید. جانچه که قال استنباط است در طراحی شبکه‌های

سیگموئیدی و محرک خطی و با تعداد پنج نرون دارای مناسب-ترین عملکرد می‌باشد. به طوری که بهترین شبکه طراحی شده به ترتیب دارای R^2 و NRMSE برابر ۰/۸۸ و ۷/۹ درصد در بخش آزمون می‌باشد.

جدول (۳) آماره‌های محاسبه شده برای دقت و صحت-سنجی مدل تخمین نفوذ آب به خاک را برای تعداد نرون‌های متفاوت با مناسب‌ترین توابع محرک نشان می‌دهد. شبکه طراحی شده با توابع محرک میانی و خروجی به ترتیب تانژانت



شکل ۴- توابع محرک رایج در شبکه‌های عصبی مصنوعی و موجود در جعبه‌افزار MATLAB

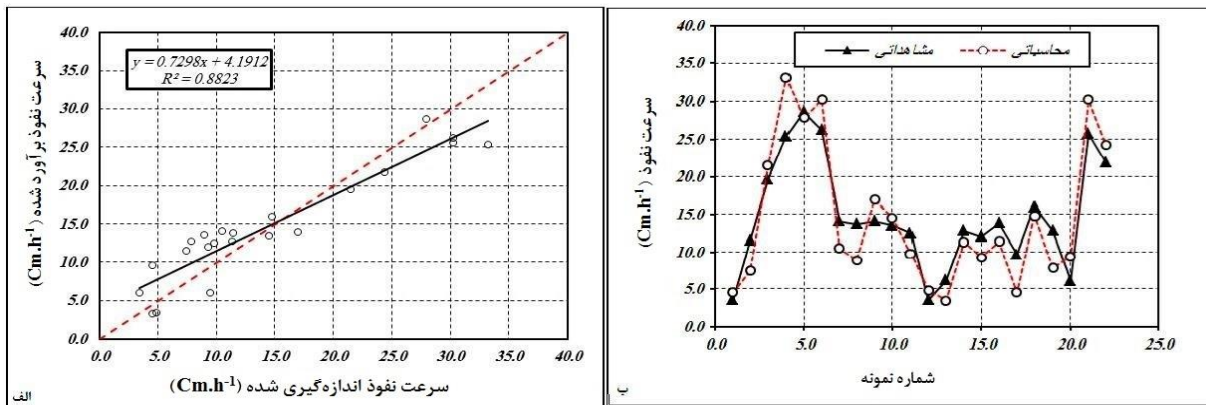
جدول ۳- مقادیر آماره‌های تابع محرک انتخابی برای تعداد نرون‌های متفاوت در بخش‌های آموزش، آزمون و اعتبارسنجی

اعتبارسنجی		آزمون		آموزش		تعداد نرون	توابع محرک
R^2	NRMSE (%)	R^2	NRMSE (%)	R^2	NRMSE (%)		
۰/۸۲	۱۱/۱	۰/۸۱	۱۱/۲	۰/۷۹	۱۲/۳	۲	
۰/۸۳	۱۰	۰/۸۱	۱۰/۶	۰/۸۰	۱۰/۹	۳	
۰/۸۵	۸/۳	۰/۸۴	۹/۱	۰/۸۳	۹/۸	۴	
۰/۸۸	۷/۹	۰/۸۷	۸/۲	۰/۸۴	۸/۵	۵	لایه میانی تانژانت
۰/۸۶	۹/۱	۰/۸۵	۹/۳	۰/۸۲	۹/۷	۶	سیگموئیدی و
۰/۸۱	۹/۱	۰/۷۹	۹/۴	۰/۷۷	۹/۹	۷	لایه خروجی
۰/۷۸	۱۰/۲	۰/۷۷	۱۰/۳	۰/۷۷	۱۰/۸	۸	محرک خطی
۰/۷۶	۱۱/۹	۰/۷۵	۱۲/۱	۰/۷۵	۱۲/۷	۹	
۰/۷۵	۱۳/۴	۰/۷۳	۱۳/۷	۰/۷۲	۱۴/۱	۱۰	
۰/۷۵	۷/۹	۰/۷۳	۸/۲	۰/۷۲	۸/۵		حداقل
۰/۸۸	۱۳/۴	۰/۸۵	۱۳/۷	۰/۸۴	۱۴/۱		حداکثر

شبکه عصبی مصنوعی بیش از حد آموزش می‌بیند و قادر به برآزش مناسب بر روی داده‌های جدید نمی‌باشد (Sarmadian et al., 2011).

شکل (۵) رابطه و تغییرات بین نفوذ آب به خاک برآورد شده و اندازه‌گیری شده با استفاده از شبکه‌های عصبی مصنوعی در بخش آزمون مدل را نشان می‌دهد. نتایج مؤید این مطلب است که مدل شبکه‌های عصبی مصنوعی دارای دقت نسبتاً بالایی بوده به طوری که در مرحله آزمون ۸۸ درصد تغییرات نفوذ آب به خاک بستگی به متغیرهای انتخابی و بقیه مربوط به عوامل کنترل نشده دارد. در ضمن میانگین انحراف مربعات خطای نرمال شده ۷/۹ درصد برآورد گردید که حاکی از دقت بالای مدل است.

با توجه به شکل (۳) ملاحظه می‌شود که حداقل مقدار NRMSE مربوط به شبکه با پنج نرون در لایه میانی می‌باشد. تغییرات RMSE دارای روند مشخصی نبوده، چراکه شبکه عصبی مصنوعی یک مدل جعبه سیاه بوده و وزن‌ها به طور تصادفی انتخاب می‌شوند و نمی‌توان روند موجود را به طور کامل تحت کنترل قرار داد. فقط باید با سعی و خطا مناسب‌ترین ساختار را محاسبه نمود. مقادیر NRMSE برای ویژگی نفوذ آب به خاک ۷/۹ درصد محاسبه شد که با افزایش تعداد نرون‌ها عملکرد مدل‌ها کاهش می‌یابد. از طرفی تعداد لایه میانی نیز از یک تا ده مدل‌سازی و ملاحظه شد که حداقل مقدار NRMSE مربوط به شبکه با یک لایه میانی می‌باشد. چون با پیچیده‌تر شدن مدل

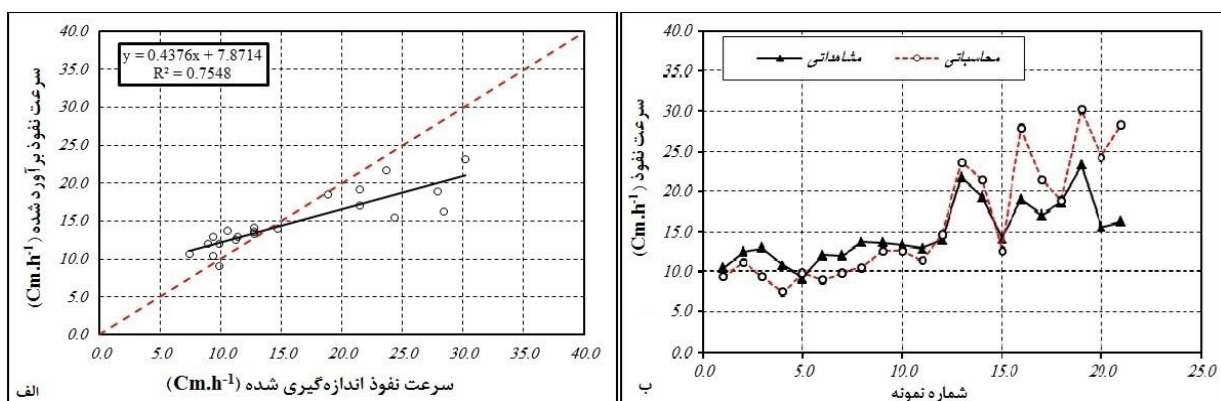


شکل ۵- مقادیر نفوذ آب به خاک برآوردشده و اندازه‌گیری شده (شکل الف) و تغییرات نفوذ آب به خاک برآوردشده و اندازه‌گیری شده (شکل ب) با استفاده از روش شبکه‌های عصبی مصنوعی

مدل سازی با استفاده از برنامه‌ریزی بیان ژن (Jarrett, 2013 and). در این مطالعه چند گروه مختلف عملگرهای ریاضی شامل جمع، تفریق، ضرب، تقسیم؛ توان، رادیکال و توابع مثلثاتی و عملگرهای پیش فرض نرم‌افزار برای تخمین نفوذ آب به خاک استفاده گردید و مدل طراحی شده با استفاده از عمل‌گرهایی که مناسب‌ترین تخمین را از نظر آماره‌های موردبررسی داشت انتخاب و از ذکر مدل‌های ناکارآمد امتناع شد. نتایج ارزیابی متقابل مدل نشان داد که آماره‌های R^2 و NRMSE برای مناسب‌ترین مدل تخمین زنده نفوذ آب به خاک با استفاده از مدل برنامه‌ریزی بیان ژن به ترتیب ۰/۷۶ و ۱/۳ محاسبه شد. شکل (۶)، رابطه و تغییرات بین نفوذ آب به خاک برآورد شده و اندازه‌گیری شده با استفاده از مدل برنامه‌ریزی بیان ژن را نشان می‌دهد. نتایج نشان‌دهنده دقت کمتر برنامه‌ریزی بیان ژن نسبت به سایر مدل‌های مورد ارزیابی می‌باشد. بر اساس شکل (۶) روند تخمین نفوذ آب به خاک نیز دارای دقت کافی نیست به طوری که انطباق خیلی کمی بین داده‌های برآورد شده و اندازه‌گیری شده وجود دارد و مدل موردنظر در بخشی از داده‌ها دارای کم برآوردی و در بخشی دیگر دارای بیش‌برآوردی است.

مدل سازی با استفاده از برنامه‌ریزی بیان ژن

پارامترهای بهینه مدل برنامه‌ریزی بیان ژن به ترتیب اندازه سر ۷، تعداد کروموزوم‌ها ۳۰، تعداد ژن‌ها در هر کروموزوم ۳، جهش ۰/۴۴، وارون‌سازی ۰/۱، نرخ ترکیب تک نقطه‌ای ۰/۳، نرخ ترکیب دو نقطه‌ای ۰/۳، نرخ ترکیب ژن ۰/۱، نرخ ترانسپس درج متوالی ۰/۱، نرخ ترانسپس ریشه درج متوالی ۰/۱، نرخ ترانسپس ژن ۰/۱ و تابع پیوند جمع (+) انتخاب شد. همچنین *Ahmadi et al.* (2018) در پژوهشی تحت عنوان برآورد هدایت هیدرولیکی اشباع خاک با استفاده از برنامه‌ریزی بیان ژن و رگرسیون ریج از ویژگی‌هایی مشابه استفاده کردند. نتایج نشان داد وقتی که تعداد ژن و طول سر به ترتیب بزرگتر از ۳ و ۷ شود عملکرد مدل برنامه‌ریزی بیان ژن به طور قابل توجهی در مراحل آموزش و آزمون مدل طراحی شده بهبود نمی‌یابد. تعداد کروموزوم‌ها نیز از ۳۰ تا ۵۰ متغیر بود. مناسب‌ترین تعداد ۳۰ کروموزوم بر اساس تحقیقات قبلی می‌باشد (Ferrier and Guisan, 2006). همچنین در این مطالعه از تابع پیوند جمع (+) استفاده شد این تابع پیوند در مقایسه با اپراتورهای دیگر نتایج بهتری ارائه داد (Azamathulla

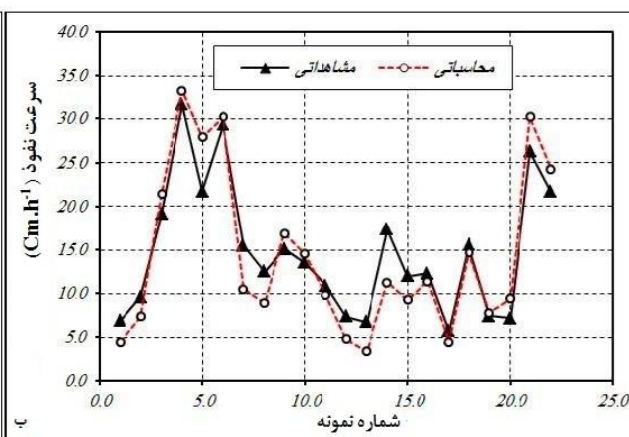
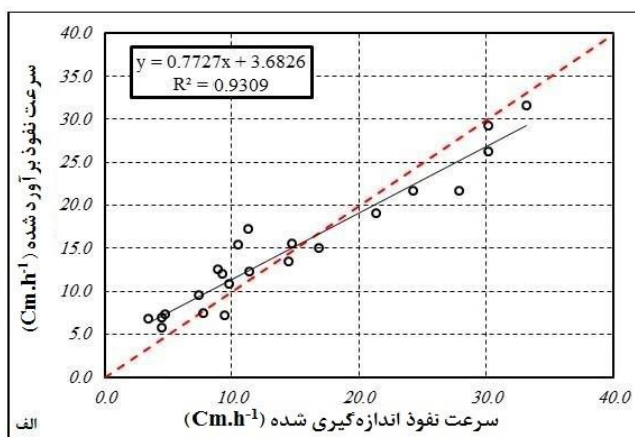


شکل ۶- مقادیر نفوذ آب به خاک برآورد شده و اندازه‌گیری شده (شکل الف) و تغییرات نفوذ آب به خاک برآورد شده و اندازه‌گیری شده (شکل ب) با استفاده از روش برنامه‌ریزی بیان ژن

داده‌های آزمون که دارای تغییرات ساختاری در فرآیند نفوذ آب به خاک هستند مناسب‌تر عمل نموده و در بیشتر نواحی توانسته مدل موفق‌تری در تخمین ویژگی دیریافت انتخابی (نفوذ آب به خاک) باشد. در مجموع این مدل به دنبال کم‌ترین خطای تخمین است. در نتیجه، مقایسه ضرایب مدل‌های خطی به‌دست-آمده نشان می‌دهد مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک با بالاتر بودن ضریب تعیین ($R^2=0/93$) و پایین-تر بودن جذر میانگین مربعات خطای نرمال شده ($6/1$) نسبت به مدل شبکه‌های عصبی مصنوعی و برنامه‌ریزی بیان ژن مدل کاراتری است. این مدل شیب خط مناسب‌تری ($0/77$) نیز نسبت به مدل شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن داشته است. به عبارت دیگر بیشتر بودن شیب خط نشان‌دهنده مطلوب بودن یک مدل است (Zare Abyaneh et al., 2010).

روند مدل‌سازی با استفاده از مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک

پارامترهای تعداد جمعیت، نرخ جهش، نرخ تقاطع و حداکثر تکرار فرایند یادگیری بهینه مربوط به الگوریتم ژنتیک در مدل ترکیبی به ترتیب برابر ۱۰۰، ۰/۳۵، ۰/۴ و ۱۰۰۰ می‌باشد. این پارامترها بر اساس روش سعی و خطا تا حصول مناسب‌ترین نتیجه بر اساس آماره‌های مورد ارزیابی حاصل شد. Barikloo et al. (2017) در تخمین عملکرد گندم آبی با استفاده از مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک از شبکه طراحی شده با مقادیر پارامترهای الگوریتم ژنتیک به ترتیب ۱۵۰، ۰/۳۵، ۰/۵ و ۱۰۰۰ استفاده نمودند و بیان داشتند که مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک کارایی مناسبی در برآورد عملکرد محصول دارد. شکل (۷) روند مدل‌سازی با استفاده از الگوریتم ترکیبی را نشان می‌دهد. مدل ANNGA برای نواحی خاصی از



شکل ۷- مقادیر نفوذ آب به خاک برآورد شده و اندازه‌گیری شده (شکل الف) و تغییرات نفوذ آب به خاک برآورد شده و اندازه‌گیری شده (شکل ب) با استفاده از مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک

نشان‌دهنده برتری مدل ترکیبی می‌باشد. دقت بیشتر روش ANN-GA در مقایسه با ANN در برآورد تبخیر و تعرق توسط Zare Abyaneh et al. (2010) و در برآورد توزیع مکانی توسعه سطح آب زیرزمینی توسط Maroofpour et al. (2017) نیز گزارش شده است. نتایج نشان داد که برنامه‌ریزی بیان ژن به-تنهایی نه تنها سبب بهبود نتایج نشد، بلکه از دقت و کارایی آن نیز کم کرد که به عدم امکان اصلاحات در ساختار صلب درختی این الگوریتم مرتبط است. با این حال می‌توان نتیجه گرفت که برنامه‌ریزی بیان ژن در بهترین حالت خود تا حدودی توانسته نفوذ آب به خاک منطقه مورد مطالعه را پیش‌بینی کند. Ghezalbash et al. (2015) نیز چنین نتیجه‌ای را در مورد ضریب یکنواختی توزیع آب در آبیاری بارانی گزارش نمودند که روش ANN نسبت

نهایتاً می‌توان چنین عنوان کرد که مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک با ترکیب الگوریتم ژنتیک که توانایی جستجوگری در فضاهای بزرگ به منظور یافتن نقطه بهینه مسائل پیچیده غیرخطی را دارد و شبکه عصبی مصنوعی به‌علت خطای شبکه کمتر، می‌تواند به‌عنوان مدلی کارا معرفی گردد.

کارایی مدل‌های توسعه یافته در تخمین نفوذ آب به خاک

مدل ترکیبی شبکه‌های عصبی مصنوعی-الگوریتم ژنتیک کارایی بیشتری از دو مدل شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در تخمین نفوذ آب به خاک را داشت. مقادیر R^2 و NRMSE برای مدل ترکیبی به ترتیب برابر با ۰/۹۳ و ۶/۱ درصد و مقادیر این شاخص‌ها برای مدل عصبی و برنامه‌ریزی بیان ژن به ترتیب برابر با ۰/۸۸، ۷/۹ و ۰/۷۵، ۱۱/۳ شد که

این تحقیق ایجاد مدلی مناسب در تخمین نفوذ آب به خاک به- عنوان یک ویژگی هیدرولیکی و فیزیکی مهم خاک در اراضی زراعی پایاب سد خداآفرین بود. براساس ماتریس همبستگی پیرسون بین ویژگی نفوذ آب به خاک و سایر ویژگی‌های فیزیکی و شیمیایی اندازه‌گیری شده، نفوذ آب به خاک‌های مطالعاتی بیشتر تحت تأثیر چهار ویژگی درصد شن، سیلت، تخلخل و ماده آلی خاک می‌باشد. به‌نظر می‌رسد با افزایش ماده آلی وضعیت ساختمان خاک بهبود، اندازه خاکدانه‌ها بزرگتر شده و حجم منافذ ریز درون خاکدانه‌ای افزایش، جرم مخصوص ظاهری خاک کاهش و میزان حجم آب در رطوبت‌های بالا افزایش می‌یابد و در نتیجه باعث افزایش حرکت آب در خاک می‌شود. بنابراین نفوذ آب به خاک، همان‌گونه که نتیجه‌های آنالیز حساسیت در این پژوهش نیز نشان داد به‌طور مستقیم و غیرمستقیم تحت تأثیر بافت خاک، مواد آلی و تخلخل کل خاک است. نتایج نشان داد که مدل ترکیبی عصبی-ژنتیک از دقت بالاتری در برآورد نفوذ آب به خاک برخوردار می‌باشد که آماره‌های ضریب تبیین و ریشه میانگین مربعات خطا (۰/۹۳ و ۲/۴۵) در مرحله آزمون مؤید این مطلب است. با این حال کاربرد سایر مدل‌های فراکوشی مانند ازدهام ذرات، کرم شبتاب و غیره با تعداد ورودی‌های کمتر، تحقیقی جدید در راستای مدل‌سازی هرچه بهتر میزان نفوذ آب به خاک با دقت و صحت مناسب‌تر می‌طلبد.

REFERENCES

- Ahmadi O, 2018. (2018). Determination of optimal land use for garden construction in Khodafarin region by MicroLESE DSS. M.Sc. Thesis, Soil Science and Engineering Department, University of Zanjan. (IN Farsi).
- Ahmadi, A., Palizvan zand, P. and Palizvan zand, H. (2018). Estimation of saturated hydraulic conductivity by using gene expression programming and ridge regression (A case study in East Azerbaijan province). *Iranian Journal of Soil and Water Research*, 48(5): 1087-1095. (In Farsi)
- Alvisi, S., Mascellani, G., Franchini, M. and Bardossy, A. (2005) Water level forecasting through fuzzy logic and artificial neural network approaches. *J. Hydrol. Earth Sys. Sci*, 2, 1107-1145.
- 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 Journal of Soil Science*, 56(4), 551-559.
- Argyrokastritis, I and Kerkides, P. (2003). A note to the variable sorptivity infiltration equation. *Water Resource. Management*, 17:133-145.
- Aytek, A, and Kisi, O. (2008). A genetic programming approach to suspended sediment modeling. *Journal of Hydrology*, 351: 288-298.
- Azamathulla, H. M. and Jarrett, R. D. (2013) Use of gene-expression programming to estimate Manning's roughness coefficient for high gradient streams. *Water Resources Management*, 27, 715-729.
- Barikloo, A., Alamdari, P., Moravej, K. and Servati, M. (2017). Prediction of Irrigated Wheat Yield by using Hybrid Algorithm Methods of Artificial Neural Networks and Genetic Algorithm. *J. Water and Soil*, 30: 3. 715-726. (In Farsi)
- Ferrier, S. and Guisan, A. (2006). Spatial modelling of biodiversity at the community level. *J. Applied ecology*, 43(3): 393-404.
- Ge G. W. and Or D. (2002) Particle-size analysis. In: Warren, A.D. Eds. Methods of Soil Analysis. Part 4. Physical Methods. (pp.255-295). *Soil Sci. Soc. Am. Inc.*
- Ghezelbash, Z., Zakerinia, M., Hezarjaribi, A., and Dehghani, A.A. (2015). Performance comparison of gene expression programming and artificial neural network methods to estimate water distribution uniformity in sprinkler irrigation. *J. Water and Soil Conservation*, 21(6): 95-114. (In Farsi).
- Goldberg D.E. (1989). Genetic algorithm in search, optimization and machine learning. Addison-Wesley, Reading, MA, 412p.

به GEP نتایج مناسب‌تری ارائه می‌کند ولی GEP قادر به ارائه رابطه صریح برای تخمین ضریب آبیاری است.

برای ارزیابی کارایی سه مدل توسعه‌یافته، با مدل‌های نفوذ فیلپ و کوستیاکف-لونیس مقایسه گردید که بر اساس تحقیقات نسبت به سایر توابع انتقالی دیگر نتایج بهتری نشان داده بودند (Singh and Yu., 1990). NRMSE و R^2 محاسبه‌شده برای روش فیلپ به ترتیب ۱۷/۷ درصد و ۰/۷۴ و برای مدل کوستیاکف-لونیس ۱۴/۶ درصد و ۰/۷۹ محاسبه شد. شایان ذکر است که رنج داده‌های نفوذ با مدل‌های فیلپ و کوستیاکف-لونیس به ترتیب ۳/۲ تا ۳۱/۷ و ۴/۴ تا ۳۵/۵ محاسبه گردید. با این نتایج روش‌های هوش مصنوعی از دقت و صحت بیشتری برخوردار بوده و مدل‌سازی با آن‌ها آسانتر است.

نتیجه‌گیری کلی

به‌دلیل تغییرپذیری زمانی و مکانی نفوذ آب به خاک، اندازه‌گیری مستقیم آن نیاز به نمونه‌برداری دارد. از طرف دیگر، اندازه‌گیری مستقیم این فرآیند پرهزینه، مشکل و زمان‌بر است. بنابراین، استفاده از روشی غیر مستقیم به‌جای اندازه‌گیری مستقیم به-منظور دستیابی به تخمینی قابل قبول بسیار مفید است. تحقیقات نشان داده که روش‌های فراکوشی می‌تواند به‌عنوان ابزاری مؤثر و مفید برای مدل‌سازی فرآیندهای غیرخطی باشد. لذا هدف از

- Ghorbani Dashtaki, S. and Homaei, M. (2000). Pedotransfer Functions for parametric Predicting of unsaturated Soil Hydraulic conductivity function. *Agriculture engineering research*, 12(3): 1-16. (In Farsi)
- Green, W.H. and Ampt, G.A. (1911). Studies on soil physics: Part 1. The flow of air and water through soil. *J. Agriculture Sciences*, 4: 1-24.
- 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). *J. Water and Soil Conservation*, 18(2): 65-84. (In Farsi)
- Haykin, S. (1999). *Neural networks: A Comprehensive Foundation*, 2nd ed., Upper Saddle River, NJ: Prentice-Hall.
- Hong, Y. S. White., P. A. and Scott, D. M. (2005) Automatic rainfall recharge model induction by evolutionary computational intelligence. *Water Resour. Res.*, 41:W08422.
- Jarvis, N. J., Zavattaro, L. K., Reynolds, W. D., Olsen, P. A., McGechan, M., Mecke, M., Mohanty, B., Leeds-Harrison, P. B. and Jacques, D. (2002). Indirect estimation of near-saturated hydraulic conductivity from readily available soil information. *Geoderma*, 108, 1 -17.
- Kao, C.S. and Hunt. J.R. (1996). Prediction of wetting front movement during one-dimentional infiltration into soils. *Water Resour. Res.*, 9(2): 384-395.
- Kazman, Z., Shainberg, I, and Gal, M. (1983). Effect of low levels of exchangeable Na and applied phosphogypsum on infiltration rate of various soils. *Soil Science Society of America*, 135: 184-192.
- Khu, S. T., Liong, S. Y., Babovic, V., Madsen, H. and Muttill, N. (2001) Genetic programming and its application in real-time runoff forecasting1. *Journal of the American Water Resources Association*, 37, 439-451.
- Koza, J. (1992) *Genetic Programming: on the Programming of Computers by Means of Natural Selection*. MIT Press.
- Laurentiu, A., Bernard, P.A., and Faicual, L. (2002). Integrated Genetic Algorithm-Artificial Neural Network Strategy for Modeling Important Multiphase-Flow Characteristics. *Ind. Eng. Chem. Res.* 41: 2543-2551.
- Leij, F., M.G. Schaap and L.M. Arya. (2002). Water retention and storage: Indirect methods. PP. 1009–1045. In: J.H. Dane and G.C. Topp (Ed.), *Methods of Soil Analysis*. Part 4. SSSA Book Ser. No. 5. SSSA, Madison, W.
- Liong, S.Y., Gautam, T.R., Khu, S.T., Babovic, V., Keijzer, M., and Muttill, N. (2002). Genetic programming, A new paradigm in rainfall runoff modeling, *J. Am. Water Res. Asso*, 38(3), 705-718.
- Makkeasorn, A., Chang, N. B., Beaman, M., Wyatt, C. and Slater, C. (2006). Soil moisture estimation in a semiarid watershed using RADARSAT- 1 satellite imagery and genetic programming. *Water Resour. Res.*, 42, W09401.
- Maroofpour, S., Fakheri-Fard, A., and Shiri, J. (2017). Development and combination of soft computing and geostatistical models in estimation of spatial distribution of groundwater level. *J. Water and Soil Conservation resource*, 6(2): 17-28. (In Farsi).
- Merdun, H., Meral, O. C., and Apan, R. M. (2006). Comparison of artificial neural network and regression Pedotransfer functions for predict of water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, 90: 108-116.
- Minasny, B. J., Hopman, W.T., Harter, S.O., Eching, A. Toli., and M.A. Denton. (2004). Neural networks prediction of soil hydraulic functions for alluvial soils using multistep outflow data. *Soil Sci. Soc. Amer. J.*, 68: 417– 429.
- Nasseh, S., Mohebbi, A., Sarrafi, A., and Taheri, M. (2009). Estimation of pressure drop in venturi crubbers based on annular two-phase flow model, artificial neural networks and genetic algorithm. *J. Chemical Engineering*, 150: 1. 131-138.
- Nelson, D. W. and Sommer, L. E. (1982). Total carbon, organic carbon, and organic matter. In: Sparks, D. L., Page, A. L., Helmke, P. A., Loeppert, R. H., Soltanpour, P. N., Tabatabai, M. A., Johnston, C. T., Sumner, M. E. Eds. *Methods of soil analysis: part 3. chemical and microbiological properties*. pp. 539–579. Soc. Agron., Madison.
- Nelson, R.E. (1982). Carbonate and gypsum. Pp. 181-197. In: Page AL, Miller RH and Keeney DR (eds). *Methods of Soil Analysis. Part 2. Chemical and Microbiological Methods*. 2nd ed. Agron. Monogr. 9. *ASA and SSSA, Madison, WI*.
- Nestor, S. Y. (2006). Modelling the infiltration process multi-layer perceptron artificial network. *Hydrological Sciences Journal*, 51(1): 3-20
- Nosrati, H. and Eftekhari, M. (2014). A new approach for variable selection using fuzzy logic. *Computational Intelligence in Electrical Engineering*, 4, 71 -83.
- Pachepsky, Y. A., Timlin, D., and Várallyay, G. (1996). Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Science Society of America Journal*, 60(3), 727-733.
- Parasuraman, K., Elshorbagy, A. and Carey, S. K. (2007). Modeling the dynamics of the evapotranspiration process using genetic programming. *Hydrol. Sci. J*, 52, 563–578.
- Parvaresh Rizi, A., Koochak Zadeh, S., and Omid, M. (2006). Estimating moving hydraulic jump arameyters by means of ANN and the integration of ANN and GA. *Agricultural Sciences*, 37: 1. 187-196. (In Farsi)
- Prasad, R. and Mathur, S. (2007). Groundwater Flow and Contaminant Transport Simulation with Imprecise Parameters. *Irrigation and Drainage Engineering*, 133(1): 61-70.
- Sarmadian, F., Taghizadeh mehrjerdi, R A., Asgari, M. and Akbarzadeh A. (2011). Comparison of neuro

- fuzzy methods, neural network and multivariate regression in predicting some soil properties (Case study: Golestan province). *Iranian Journal of Soil and Water Research*, 41(2): 211-220. (In Farsi)
- Savic, D.A., Walters, G. A. and Davidson, J. W. (1999) Genetic programming approach to rainfall-runoff modelling. *Water Resour. Manage.* 13, 219-231.
- Singh, V.P. and YU, F.X. Derivation of Infiltration Equation Using Systems Approach. *Journal of Irrigation and Drainage Engineering*, 116: 6: 307-320.
- Sunli K., Sinha, M. and Wang, C. (2008). Artificial neural network prediction models for soil compaction and permeability. *Geotechnical and Geological Engineering*, 26: 47-64.
- Tsanis, I.K. (2006). Modeling leachate contamination and remediation of groundwater at a landfill site. *Water Resour Manage*, 20:109-132.
- Zare Abyaneh, H., Bayat Varkeshi, M., Marofi, S., and Amiri Chayjan, R. (2010). Evaluation of artificial neural network and adaptive neuro fuzzy inference system in decreasing of reference evapotranspiration parameters. *Water and Soil (Agr. Sci. and Thechnology)*, 24: 2. 297-305. (In Farsi)
- Zare Abyaneh, H., Ghasemi, A., Bayat varkeshi, M., and Marofi, S. (2009). Assessment of Artificial Neural Network (ANN) in prediction of garlic evapotranspiration (ETC) with lysimeter in Hamedan. *J. Water and Soil*, 23: 3. 176-185. (In Farsi)
- Zhang, C. S. and McGrath, D. (2004). Geostatistical and GIS analyses on soil organic carbon concentrations in grassland of southeastern Ireland from two different periods. *Geoderma*, 119(3-4): 261-275.