

برآورد پارامترهای نفوذ آب به خاک با استفاده از شبکه‌های عصبی مصنوعی

شجاع قربانی دشتکی^۱ - مهدی همایی^{۲*} - محمدحسین مهدیان^۳

تاریخ دریافت: ۸۷/۷/۷

تاریخ پذیرش: ۸۷/۹/۱۸

چکیده

فرآیند نفوذ آب به خاک از مهمترین اجزای چرخه هیدرولوژی در طبیعت است. در سال‌های اخیر استفاده از شبکه‌های عصبی مصنوعی برای برآورد پدیده‌های هیدرولوژی افزایش چشمگیر داشته است. هدف از این پژوهش، بررسی امکان تخمین پارامترهای مدل‌های فیلیپ، کوستیاکوف، کوستیاکوف-لوییز و هورتون با استفاده از شبکه‌های عصبی مصنوعی بود. بدین منظور، نفوذپذیری خاک در ۱۲۳ نقطه از استان‌های اردبیل، زنجان، فارس، اصفهان و بوشهر به روش استوانه‌های مضاعف تعیین و پارامترهای مدل‌ها به روش حداقل مجموع مربعات خطا تعیین گردید. با حفر پروفیل در نزدیکی نقاط اندازه‌گیری نفوذ آب به خاک، لایه‌های پدوژنیک خاک مشخص و از دو افق بالایی نمونه‌برداری و ویژگی‌های رطوبت اولیه، جرم ویژه ظاهری، فراوانی نسبی ذرات، ماده آلی، درصد سنگریزه، آهک خاک، ظرفیت زراعی و رطوبت پژمردگی دائم اندازه‌گیری شد. شبکه‌های عصبی پرسپترون چند لایه برای برآورد پارامترهای نفوذ به کار گرفته شد. از ویژگی‌های زودیافت دو افق پدوژنیک خاک و پارامترهای نفوذ به ترتیب، به عنوان داده‌های لایه ورودی و خروجی شبکه‌های عصبی استفاده شد. در این تحقیق دو نوع شبکه عصبی پی‌ریزی شد. در گروه اول از ویژگی‌های زودیافت لایه اول به عنوان متغیرهای ورودی استفاده شد. در شبکه‌های عصبی پی‌ریزی شده گونه دوم، از ویژگی‌های زودیافت هر دو لایه پدوژنیک به روش تجزیه مولفه‌های اصلی به عنوان متغیرهای ورودی استفاده گردید. مقایسه عملکرد شبکه‌ها گونه نخست و گونه دوم، برتری شبکه‌های گونه نخست را در برآورد پارامترهای مدل‌های نفوذ نشان داد. بنابراین، به منظور برآورد منحنی تجمعی نفوذ آب به خاک تنها از شبکه‌های گونه نخست استفاده گردید. بهترین رتبه برآوردگری را شبکه‌های طراحی شده برای مدل دو پارامتری فیلیپ داشته است. اعتبارسنجی مدل‌های نفوذ نشان داد شبکه‌های ایجاد شده برای پارامترهای مدل فیلیپ با میانگین $RMSD$ معادل $6/644$ سانتی‌متر، دارای بهترین عملکرد در برآورد تجمعی آب به خاک بوده و شبکه‌های پی‌ریزی شده برای مدل‌های هورتون، کوستیاکوف-لوییز و کوستیاکوف به ترتیب در رتبه‌های دوم تا چهارم قرار گرفتند.

واژه‌های کلیدی: پرسپترون چندلایه، شبکه‌های عصبی مصنوعی، نفوذ آب به خاک، مدل‌های نفوذ

مقدمه

برابر آب رسیده به سطح خاک است. این پدیده تعیین کننده سرنوشت آب رسیده به سطح خاک بوده و مقدار تلفات بارش را نیز مشخص می‌کند. طی سالیان گذشته مدل‌های فیزیکی و تجربی فراوانی برای کمی کردن فرآیند نفوذ آب به خاک ارائه شده است (۱۰، ۱۳، ۱۴، ۱۵، ۱۸، ۲۴ و ۲۵). هرکدام از این مدل‌ها در شرایطی معین، مناسب‌ترین برآزش را با داده‌های تجربی داشته‌اند. در این پژوهش، مدل‌های فیلیپ (۲۶)، کوستیاکوف (۱۵)، کوستیاکوف-لوییز (۲۰) و هورتون (۱۳) برای بیان نفوذ آب به خاک به کار گرفته شدند. خلاصه‌ای از مدل‌های مورد استفاده و پارامترهای مربوطه در جدول (۱) ارائه شده است.

به منظور سادگی در محاسبه‌ی ضرایب، معادله‌ی هورتون به صورت زیر مورد استفاده قرار می‌گیرد:

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 گروه مد نظر قرار دادن نفوذپذیری است. شناخت کمی این پدیده، جلوگیری از تخریب اراضی و منابع خاک و آب را به همراه خواهد داشت. وضعیت نفوذپذیری خاک نشان‌دهنده چگونگی رفتار خاک در

۱- دانشجوی سابق دکتری دانشگاه تربیت مدرس (استادیار فعلی دانشگاه شهر کرد)

۲- استاد گروه خاکشناسی دانشگاه تربیت مدرس

(Email: mhomaee@modares.ac.ir)

* نویسنده مسئول:

۳- استادیار گروه آبیاری دانشگاه بین المللی قزوین

(جدول ۱) - مدل‌های نفوذپذیری به کار گرفته شده

معادله	پارامترها	نام مدل
$I = St^{\frac{1}{2}} + k_s t$	$(LT^{-1/2}) S$ ضریب جذبی خاک (تابع مکش خاک) و k_s ضریبی است که بیانگر هدایت هیدرولیکی منطقه انتقال بوده و مقدار آن کوچکتر مساوی هدایت هیدرولیکی اشباع خاک است.	فیلیپ
$I = kt^b$	$(LT^{-1}) i$ سرعت نفوذ، $(T) t$ زمان و $(-)$ b و $(-)$ k ضرایب تجربی معادله هستند.	کوستیاکوف
$I = k't^{b'} + At$	$(LT^{-1}) i_0$ سرعت اولیه نفوذ، $(-)$ k' ، $(-)$ b' و $(-)$ A ضرایب تجربی معادله هستند.	کوستیاکوف-لوییز
$I = i_f t + \frac{(i_0 - i_f)}{\beta} (1 - e^{-\beta t})$	$(LT^{-1}) i_f$ سرعت نفوذ نهایی، $(-)$ β ثابت تناسب و $(T) t$ زمان نفوذ می‌باشند.	مدل هورتون

فراوانی نسبی ذرات، شبکه‌های مورد نظر را طراحی نمودند. سپس به صورت سلسله‌وار ورودی‌های جدیدی به شبکه‌ها اضافه نمودند و در هر مرحله عملکرد شبکه‌های طراحی شده را مورد ارزیابی قرار دادند. نتایج این پژوهش نشان داد با ورود متغیرهای جدید به شبکه به عنوان برآورد کننده، عملکرد شبکه در برآورد پارامترهای یاد شده بهبود یافت. با این وجود، این پژوهشگران تفاوتی قابل ملاحظه بین مقادیر اندازه‌گیری شده و برآورد شده مشاهده نمودند.

مینسنی و مک‌برتنی برای برآورد پارامترهای مدل ون‌گنختن در خاک‌های استرالیا از شبکه‌های عصبی مصنوعی استفاده نمودند (۲۱). این پژوهشگران در طراحی شبکه عصبی مصنوعی تابع هدف جدیدی ارائه نمودند. در این پژوهش به جای این که تابع هدف مورد نظر را با استفاده از پارامترهای ون‌گنختن تعیین کنند، از مقدار رطوبت برآورد شده از مدل ون‌گنختن استفاده نمودند. نتایج این پژوهش نشان داد که تابع هدف ارائه شده اثری قابل قبول در بهبود عملکرد شبکه داشته است.

پاراسورامن و همکاران برای برآورد هدایت آبی اشباع در مقیاس مزرعه‌ای، دو گروه شبکه عصبی طراحی نمودند (۲۳). در گروه اول از ویژگی‌های مقدار رس، سیلت و شن به عنوان ورودی‌های شبکه استفاده گردید و در گروه دوم علاوه بر سه ویژگی یاد شده، جرم ویژه ظاهری نیز به عنوان ورودی مدل مورد استفاده قرار گرفت. نتایج این پژوهش نشان داد که شبکه‌های عصبی طراحی شده عملکردی بهتر در برآورد هدایت آبی اشباع در مقایسه با شبکه عصبی Rosetta داشته‌اند.

طی پژوهشی، مردون و همکاران با استفاده از توابع انتقالی و شبکه‌های عصبی مصنوعی پارامترهای مدل ون‌گنختن و هدایت آبی اشباع را برآورد نمودند (۱۹). در این پژوهش ۱۳۰ نمونه از داده‌ها برای پی‌ریزی مدل‌ها و ۶۵ نمونه باقی مانده برای ارزیابی مدل‌ها مورد استفاده قرار گرفت. نتایج این پژوهش نشان داد مدل‌های

$$I = ct + m[1 - \exp(-at)] \quad (۱)$$

که در آن: a ، c و m ضرایب معادله و همگی مثبت هستند و به روش بهینه‌سازی حداقل مجموع مربعات خطا بدست می‌آیند (۷).

برای تعیین پارامترهای مدل‌های یادشده، اندازه‌گیری فرآیند نفوذپذیری و یا دیگر ویژگی‌های هیدرولیکی خاک اجتناب ناپذیر است. از آنجا که نفوذ آب به خاک دارای تغییرپذیری بالایی است، برای شبیه‌سازی شرایط واقعی سطح خاک، اندازه‌گیری‌های زیادی لازم است. علاوه بر این، اندازه‌گیری نفوذ آب به خاک دشوار، وقت‌گیر و پرهزینه است. از راه‌های چیرگی بر این مشکل، استفاده از روش‌های غیرمستقیم در اندازه‌گیری نفوذ آب به خاک است. یکی از روش‌های غیرمستقیم در برآورد ویژگی‌های هیدرولیکی خاک، استفاده از شبکه‌های عصبی مصنوعی^۱ است (۲۱ و ۲۳).

هر چند مطالعات فراوانی برای تخمین منحنی رطوبتی و هدایت هیدرولیکی غیراشباع خاک با استفاده از شبکه‌های عصبی مصنوعی صورت گرفته، لیکن برای تخمین نفوذ آب به خاک پژوهشی در دست نیست. در اینجا بخشی از مهمترین پژوهش‌های انجام گرفته در ارتباط با استفاده از شبکه‌های عصبی مصنوعی در برآورد ویژگی‌های هیدرولیکی خاک ارائه شده است.

پچپسکی و همکاران با استفاده از داده‌های مربوط به ۲۳۰ نمونه خاک، پژوهشی برای بررسی قابلیت توابع انتقالی و شبکه‌های عصبی مصنوعی در برآورد منحنی رطوبتی خاک انجام دادند (۲۲). نتایج این پژوهش نشان داد که شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی، عملکردی مشابه در برآورد منحنی رطوبتی داشته‌اند. اسخاپ و لای با استفاده از شبکه‌های عصبی مصنوعی موفق به برآورد پارامترهای مدل‌های ون‌گنختن (۱۹۸۰) و گاردنر (۱۹۵۸) گردیدند (۲۷). این پژوهشگران در ابتدا با استفاده از ورودی‌های

$$a = 0.01 \sum_{i=1}^n f_i \ln M_i, d_g = \exp a \quad (2)$$

$$b = 0.01 \sum_{i=1}^n f_i \ln^2 M_i - a^2, \sigma_g = \exp b \quad (3)$$

که در آن: f_i درصد جرمی ذراتی از خاک با میانگین قطر M_i و n تعداد گروه‌های ذرات خاک است.

پی‌ریزی شبکه‌های عصبی مصنوعی

نخستین گام در پی‌ریزی شبکه‌های عصبی مصنوعی، انتخاب داده‌های ورودی وابسته است. از ویژگی‌های زودیاخت دو افق پدوژنیک خاک به عنوان داده‌های لایه ورودی استفاده شد. بر اساس این که از ویژگی‌های کدام افق برای برآورد پارامترهای نفوذ استفاده شود، دو نوع شبکه عصبی پی‌ریزی شد. در گروه اول از ویژگی‌های زودیاخت لایه اول به عنوان متغیرهای ورودی شبکه استفاده شد. در شبکه‌های عصبی پی‌ریزی شده گونه دوم از ویژگی‌های زودیاخت هر دو لایه پدوژنیک به عنوان متغیرهای ورودی استفاده گردید.

یکی از مراحل مهم پی‌ریزی شبکه‌های عصبی مصنوعی، پیش پردازش داده‌ها است. این عمل شامل انتخاب متغیرهای موثر، انتخاب الگوهای آموزش ده و آزمون، دسته‌بندی الگوها و استاندارد کردن داده‌ها می‌شود. هدف از استاندارد کردن، هم ارزش کردن تمامی عناصر موجود در یک الگو می‌باشد (۱۷). برای استاندارد کردن داده‌ها از رابطه زیر استفاده شده است:

$$X_n = 0.1 + 0.8 \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) \quad (4)$$

که در آن: X_n معرف داده نرمال شده، X معرف داده‌ی مشاهده‌ای و X_{\min} و X_{\max} به ترتیب معرف داده‌های مشاهده‌ای حداکثر و حداقل می‌باشند. این رابطه، داده‌ها را در بازه [۰/۱ و ۰/۹] تبدیل می‌کند. پس از انجام مراحل یادشده، داده‌ها به صورت تصادفی مخلوط شده و الگوهای آموزشی و آزمون به ترتیب به نسبت ۸۰ و ۲۰ درصد انتخاب گردیدند.

در طراحی شبکه‌های گونه نخست از روش سلسله‌ای^۶ استفاده شد. در این روش، شبکه‌ها به گونه‌ای ایجاد می‌شوند که در شبکه اول (ANN_1) تنها از ویژگی‌های فراوانی نسبی ذرات خاک به عنوان متغیرهای ورودی استفاده گردد. در شبکه دوم (ANN_2)، جرم ویژه ظاهری خاک به ورودی‌های شبکه ANN_1 اضافه گردید و شبکه ANN_2 را ایجاد نمود. به همین ترتیب بر اساس ویژگی‌های زودیاختی مورد استفاده در لایه‌ی ورودی، ۱۱ نوع شبکه پی‌ریزی گردید.

رگرسیون برآورد بهتری از پارامترهای مدل ون‌گنختن و مقدر رطوبت در نقاطی خاص از منحنی رطوبتی، نسبت به شبکه‌های عصبی مصنوعی داشته‌اند. با وجود این، تفاوت یاد شده در برآورد متغیرهای مورد نظر از نظر آماری معنی‌دار نبوده است.

با آنکه مطالعاتی فراوان به منظور گسترش و استفاده از شبکه‌های عصبی مصنوعی برای برآورد منحنی رطوبتی و هدایت هیدرولیکی غیراشباع خاک صورت گرفته، تاکنون این روش برای برآورد پارامتریک نفوذپذیری خاک به کار نرفته است. لذا، هدف از این پژوهش، پی‌ریزی شبکه‌های عصبی مصنوعی برای برآورد پارامترهای نفوذ آب به خاک و ارزیابی این شبکه‌ها در برآورد نفوذ آب به خاک بود.

مواد و روش‌ها

داده‌های مورد استفاده

این پژوهش بر روی داده‌های مربوط به سری خاک‌هایی از استان‌های اردبیل، زنجان، فارس، اصفهان و بوشهر انجام گردید. خاک‌های مورد مطالعه در رده‌های اربیدی سول^۱، اینسیتی سول^۲، انتی سول^۳ و مالی سول^۴ قرار داشته و نوع کاربری اراضی نیز شامل گندم، آیش و مرتع بوده است. رطوبت اولیه خاک‌ها نیز از خشک تا خیس متغیر بوده است.

داده‌های مربوط به نفوذپذیری خاک با استفاده از استوانه‌های مضاعف و با سه تکرار در ۱۲۳ نقطه به دست آمد. پارامترهای مدل‌های یادشده به روش حداقل مجموع مربعات خطا تعیین گردید. با حفر پروفیل در نزدیکی نقاط اندازه‌گیری نفوذ آب به خاک، لایه‌های پدوژنیک خاک مشخص و از دو افق پدوژنیک سطحی نمونه‌برداری و ویژگی‌های مورد نظر اندازه‌گیری شد. رطوبت اولیه به روش وزنی، جرم ویژه ظاهری خاک به روش سیلندری (۴)، فراوانی نسبی ذرات به روش هیدرومتر (۸)، ماده آلی به روش والکلی و بلک (۲۹)، درصد سنگریزه به روش حجمی و آهک خاک به روش کلسیمتری اندازه‌گیری شد. رطوبت ظرفیت مزرعه و رطوبت پژمردگی^۵ دایم با استفاده از دستگاه صفحات فشاری^۵ تعیین شد. پارامترهای هر یک از مدل‌های مورد بررسی به روش حداقل مجموع مربعات خطا تعیین گردید. میانگین هندسی قطر ذرات (d_g) و انحراف معیار هندسی قطر ذرات خاک (σ_g) با استفاده از روابط پیشنهادی توسط شیرازی و بورسما (۲۸) محاسبه شدند:

- 1- Aridisols
- 2- Inceptisols
- 3- Entisols
- 4- Mollisols
- 5- Pressure Plates

آموزش شبکه نیاز است. با توجه به این که تعداد داده‌های گردآوری شده در این پژوهش محدود بود، از روش تجزیه مولفه‌های اصلی^۲ به هنگام طراحی شبکه‌های گونه دوم استفاده شد. سپس از مولفه‌های اصلی به دست آمده به عنوان ورودی شبکه‌های عصبی مصنوعی برای برآورد پارامترهای نفوذ استفاده گردید.

یک شبکه عصبی پرسپترون پیش‌خور سه لایه قادر است هرگونه رابطه موجود بین لایه‌ی خروجی و ورودی را تشخیص دهد و مدل کند (۹ و ۲۱). با توجه به قابلیت‌های این نوع از شبکه‌های عصبی مصنوعی، در این پژوهش از آن برای برآورد پارامترهای مدل‌های نفوذ استفاده شد. به منظور تعیین معماری بهینه شبکه‌های عصبی مورد استفاده از یک آزمون و خطا، استفاده شد. با این روش، تعداد نرون‌های لایه پنهان و نوع تابع آستانه در هر لایه تعیین گردید. به همین منظور، برای هر کدام از پارامترهای نفوذ، شبکه‌هایی با ۳ تا ۲۰ نرون در لایه‌ی مخفی طراحی و مورد آزمون قرار گرفت. در صورتی که دو شبکه با معماری‌های مختلف دارای خطای یکسانی شدند، شبکه‌ای انتخاب گردید که دارای تعداد نرون کمتری است. از ترکیبات توابع آستانه‌ی tansig ، logsig (دو تابع سیگموئیدی) و purelin (تابعی خطی) به عنوان توابع آستانه‌ی شبکه‌های مصنوعی پی‌ریزی شده، استفاده شد. بر همین اساس و با توجه به عملکرد شبکه‌های ایجاد شده، بهترین تابع آستانه در هر لایه برای هر کدام از پارامترهای نفوذ تعیین گردید.

روش یادگیری شبکه، چگونگی تنظیم کردن وزن‌های شبکه را بیان می‌کند. یکی از مهمترین مشکلات استفاده از شبکه‌های پرسپترون، وراآموزی^۳ این نوع شبکه است. به منظور جلوگیری از وراآموزی شبکه‌های عصبی بهتر است پیچیدگی مدل به حداقل رسانده شود. به منظور جلوگیری از مشکل وراآموزی و بهبود قدرت تعمیم‌دهی شبکه از روش منظم کردن^۴ استفاده گردید.

در سازماندهی یا منظم کردن شبکه، معیار ارزیابی آموزش شبکه که به طور معمول مجموع مربعات خطای آموزش شبکه است، تغییر می‌یابد. تابع خطایی که به طور معمول در شبکه‌های پیش‌خور استفاده می‌شود، میانگین مجموع مربعات^۵ خطاهای شبکه است که به صورت زیر محاسبه می‌شود:

$$F = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad (5)$$

مطابق رابطه فوق و با اضافه کردن عبارتی که شامل میانگین مجموع مربعات وزن‌ها و تورش‌های^۶ شبکه است، می‌توان تعمیم‌دهی

لازم به ذکر است ترتیب ورودی و ویژگی‌های زودیافت به شبکه‌های متوالی بر اساس میزان سهل‌الوصول و در دسترس بودن ویژگی‌ها انجام شد. به این صورت که در شبکه‌های اولیه از داده‌هایی چون فراوانی نسبی ذرات، جرم ویژه‌ی ظاهری، میانگین و انحراف معیار هندسی قطر ذرات که معمولاً در اکثر مطالعات خاکشناسی اندازه‌گیری و محاسبه می‌شوند، به عنوان ورودی‌های شبکه استفاده شد. برای پی‌ریزی دیگر شبکه‌ها، علاوه بر ویژگی‌های قبلی، ویژگی‌هایی چون مقدار ماده آلی، آهک، رطوبت اولیه، رطوبت در نقطه پتانسیلی ۳۰۰- کیلوپاسکال و ۱۵۰۰- کیلوپاسکال نیز مورد استفاده قرار گرفت. به طور کلی با افزایش تعداد متغیرهای ورودی به شبکه‌ها، هزینه ایجاد هر شبکه نیز افزایش می‌یابد. جدول (۲) چگونگی و ترتیب ورودی متغیرها و طراحی شبکه‌های سلسله‌ای ایجاد شده را نشان می‌دهد. این جدول نشان می‌دهد برای پی‌ریزی اولین شبکه (ANN_1) تنها از مقادیر شن، رس و سیلت به عنوان ورودی‌های شبکه استفاده شد. در پی‌ریزی شبکه‌ی دوم (ANN_2) افزون بر متغیرهای استفاده شده در ANN_1 ، جرم ویژه ظاهری خاک نیز مورد استفاده قرار گرفت. به همین ترتیب، با افزون شدن ویژگی‌های زودیافت جدید به لایه‌ی ورودی شبکه، ۱۱ نوع شبکه به صورتی که در جدول ۲ آمده است، پی‌ریزی گردید.

(جدول ۲) - شبکه‌های سلسله‌ای پی‌ریزی شده با استفاده از داده‌های

افق سطحی	
شبکه‌ی ایجاد شده	ورودی‌های شبکه
ANN_1	شن+سیلت+رس
ANN_2	ANN_1 +جرم ویژه ظاهری
ANN_3	ANN_2 +میانگین هندسی قطر ذرات
ANN_4	ANN_3 +انحراف معیار هندسی قطر ذرات
ANN_5	ANN_4 +تخلخل خاک
ANN_6	ANN_5 +سنگریزه
ANN_7	ANN_6 +رطوبت اولیه
ANN_8	ANN_7 +کربن آلی
ANN_9	ANN_8 +آهک
ANN_{10}	ANN_9 +رطوبت ظرفیت زراعی
ANN_{11}	ANN_9 +رطوبت پژمردگی دایم

برای پی‌ریزی گروه دوم از شبکه‌های عصبی مصنوعی، از ویژگی‌های زودیافت هر دو لایه به طور همزمان برای برآورد پارامترهای نفوذ استفاده شد. چنانچه تعداد ورودی‌های شبکه زیاد گردند، در طراحی شبکه نفرین ابعادی^۱ مشکلی ایجاد می‌گردد (۳ و ۵). همچنین، با افزایش ورودی‌های شبکه به تعداد داده بیشتری برای

2- Principal Component Analysis

3- Over fitting

4- Regularization

5- Mean Sum of Squares

6- Mean of Sum of the Network Weights and Biases

1- Curse of Dimensionality

شبکه را بهبود بخشید:

$$msereg = \gamma mse + (1 - \gamma) msw \quad (6)$$

که در آن: γ نسبت عملکرد^۱ و $w_j^2 = \frac{1}{n} \sum_{j=1}^n w_j^2$ است.

استفاده از این تابع عملکرد باعث می‌شود تا شبکه دارای مقادیر وزنی و تورش کوچکتری شده و پاسخ شبکه در حین آموزش از مقادیری که نشان از حفظ کردن شبکه باشد، دور شود. در این پژوهش برای تعیین مقدار γ ، روش بیزین که توسط مک‌کی (۱۶) ارایه شده، به کار گرفته شد. این الگوریتم در صورتی متوقف می‌شود که مقادیر مجموع مربعات خطا و مجموع مربعات وزن‌ها به مقداری ثابت طی چندین تکرار متوالی رسیده باشد.

به منظور ارزیابی کارایی شبکه‌های پی‌ریزی شده در برآورد پارامترهای نفوذ، از جذر میانگین مربعات خطا ($RMSE$)^۲ استفاده گردید. با استفاده از آماره $RMSE$ ، بهترین شبکه‌ها برای هر یک از پارامترهای نفوذ آب به خاک تعیین گردید. سپس، مقادیر برآورد شده پارامترهای مورد نظر به مدل‌های نفوذ انتقال داده شد. منحنی‌های نفوذ اندازه‌گیری شده و برآورد شده با استفاده از پارامترهای خروجی از شبکه‌های عصبی مصنوعی، مورد مقایسه و ارزیابی قرار گرفت.

اعتبار شبکه‌های ایجاد شده در برآورد نفوذ آب به خاک با محاسبه آماره‌های میانگین خطا (MD)^۳، ریشه مربعات خطا ($RMSD$)^۴، انحراف معیار $RMSD$ ($SDRMSD$)^۵ و ضریب همبستگی پیرسون^۶ (r) تعیین گردید (۱). یکی دیگر از آماره‌هایی که برای ارزیابی شبکه‌ها به کار رفت، میانگین قدر مطلق میانگین خطاهای ($MAMD$) خاک‌های مختلف می‌باشد. تفاوت این آماره با میانگین MD ‌ها (MMD) آن است که اشتباه ناشی از سرشکن شدن خطاهای برآورد در خاک‌های مختلف وارد چرخه‌ی ارزیابی شبکه‌ها نمی‌شود و مقدار آن متأثر از مقادیر مثبت و منفی خطای برآورد در تک تک خاک‌ها نیست. در صورت نزدیک بودن مقدار قدر مطلق میانگین MD ‌ها و میانگین AMD ‌ها، یکسان بودن عملکرد شبکه‌های پی‌ریزی شده در یکایک خاک‌ها از نظر بیش یا کم برآوردی به اثبات خواهد رسید.

به منظور بررسی شبکه‌های پی‌ریزی شده در برآورد نفوذ تجمعی آب به خاک از نتایج بخش آزمون شبکه‌ها استفاده گردید. داده‌های مورد استفاده در بخش آزمون، داده‌هایی بودند که در مراحل طراحی شبکه‌های به کار گرفته نشده بود. بنابراین، در این مرحله قابلیت تعمیم‌دهی شبکه‌های پی‌ریزی شده در برآورد منحنی تجمعی نفوذ

بررسی گردید. به عبارت دیگر، در این مرحله آزمون اعتباریابی^۷ بر روی شبکه‌های پی‌ریزی شده انجام شد. در مرحله نخست، پارامترهای مدل‌های یادشده نفوذ با استفاده از شبکه‌های مربوطه برآورد گردید. سپس، منحنی‌های تجمعی نفوذ اندازه‌گیری شده و برآورد شده مورد مقایسه و ارزیابی قرار گرفت.

نتایج و بحث

شکل ۱ توزیع فراوانی نسبی ذرات خاک‌های مورد استفاده در پی‌ریزی شبکه‌های عصبی را نشان می‌دهد. مقایسه این شکل با مثلث بافت خاک نشان می‌دهد خاک‌های مورد مطالعه در کلاس‌های بافتی لوم شنی، لوم، لوم سیلتی، لوم رسی - سیلتی، لوم رسی و رس سیلتی قرار می‌گیرند. برخی ویژگی‌های فیزیکی خاک‌های مورد مطالعه بر اساس نوع کاربری اراضی در جدول ۳ ارایه شده است. همان گونه که ملاحظه می‌شود، مقدار کمینه آهک در همه خاک‌ها حدود ۵ درصد است و این مقدار تا ۶۵ درصد نیز رسیده است. دامنه تغییرات کربن آلی در خاک‌های مورد مطالعه از ۰/۰۷ تا ۳/۵ درصد و میانگین ۰/۷۲ درصد و انحراف معیار ۰/۶۵ است.

شبکه‌های عصبی گونه نخست

در این گروه از شبکه‌ها، به منظور برآورد هر کدام از پارامترهای مدل‌های یاد شده نفوذ، ۱۱ نوع شبکه با تعداد گره‌های مختلف طراحی گردید. این شبکه با نام‌های ANN_i معرفی شده که زیرنگاره‌ی i ، بیانگر نوع شبکه‌ی طراحی شده و تعداد متغیرهای ورودی آن منهای ۱ است. با توجه به تعداد گره‌های استفاده شده در لایه‌ی میانی هر ANN_i (از ۳ تا ۲۰ گره)، تعداد شبکه‌های طراحی شده برای یکی از ANN_i ‌ها برابر با ۱۸ شبکه است. هر کدام از این شبکه‌ها، ۵ بار در برنامه Matlab اجرا گردید و میانگین خطا و داده‌های برآورد شده به عنوان عملکرد شبکه در نظر گرفته شد. در طراحی شبکه‌ها از چهار نوع ترکیب در توابع آستانه ($tansig$ -) $purelin$ ، $purelin$ ، $purelin$ ، $logsig$ ، $logsig$ ، $purelin$ و $purelin$ - $purelin$) استفاده شد. بنابراین، برای برآورد هر کدام از پارامترهای مدل‌های یادشده ۳۹۶۰ شبکه ($4 \times 5 \times 1 \times 18$) آموزش یافته و مورد آزمون قرار گرفت. برای هر کدام از پارامترهای مدل‌های گفته شده، شبکه‌های جداگانه پی‌ریزی شد. در مجموع ۳۹۶۰۰ شبکه مورد بررسی قرار گرفت.

عملکرد شبکه‌های طراحی شده در بخش آموزش و آزمون، با استفاده از آماره میانگین مربعات خطا ($RMSE$) مورد کاوش قرار گرفت. سپس از بین شبکه‌های طراحی شده برای هر ANN_i ،


- 1- Performance Ratio
- 2- Root Mean Square Errors
- 3- Mean Difference
- 4- Root of the Mean Square Difference
- 5- Standard Deviation of RMSD
- 6- Pearson Correlation

در مدل کوستیاکوف، با ورود متغیر جرم ویژه ظاهری به ANN_1 ، مقدار RMSE آزمون کاهش یافت. حال آنکه، در ANN_3 با ورود متغیر میانگین هندسی قطر ذرات به ANN_2 خطای آزمون افزایش یافت.

شبکه‌ای که دارای بهترین قدرت تعمیم‌دهی بود، انتخاب گردید. نتایج نشان داد ورود متغیر جدید (در ANN_n) به شبکه‌های ساخته شده (ANN_{n-1}) لزوماً باعث بهبود اعتبار شبکه‌ی عصبی ایجاد شده، نشده است. به عنوان مثال در شبکه‌های طراحی شده برای برآورد پارامتر k

(جدول ۳) - بازه داده‌های اندازه‌گیری شده در کاربری‌های مختلف

کاربری	آهک (%) (بیشینه-کمینه)	کربن آلی (%) (میانگین)	جرم ویژه‌ی ظاهری ($g.cm^{-3}$) (بیشینه-کمینه)	رس (%) (بیشینه-کمینه)	سیلت (%) (بیشینه-کمینه)	شن (%) (بیشینه-کمینه)
گندم	۵-۶۵	۰/۶۲	۱/۲۰-۱/۶۸	۱۶-۴۷	۳۲-۶۳	۵-۵۰
مرتع	۵-۵۷	۱/۰۲	۱/۲۰-۱/۶۶	۳-۴۷	۲۱-۷۶	۱۱-۶۳
آبش	۵-۶۲	۰/۵	۱/۲۰-۱/۶۲	۱۵-۴۳	۲۸-۶۷	۱۰-۴۷
مجموع	۵-۶۵	۰/۷۲	۱/۲۰-۱/۶۸	۳-۴۷	۲۱-۷۶	۵-۶۳



(شکل ۱) - توزیع بافتی داده‌های مورد استفاده در پی‌ریزی شبکه‌های عصبی مصنوعی

گردید.

جدول ۵ بهترین شبکه‌های پی‌ریزی شده گونه نخست را برای برآورد پارامترهای نفوذ نشان می‌دهد. در این جدول اگر تعداد ورودی‌های هر معماری منهای ۲ گردد، نوع شبکه‌ی ANN_i مشخص می‌شود. به عنوان مثال، معماری (۱-۴-۵) نمایانگر شبکه‌ی ANN_3 است که در آن از فراوانی نسبی ذرات، جرم ویژه ظاهری و میانگین هندسی قطر ذرات به عنوان ورودی شبکه استفاده شده است.

عملکرد شبکه‌های پی‌ریزی شده با کمترین و در دسترس‌ترین ویژگی‌های افق سطحی نیز بررسی شد. این ویژگی‌ها شامل فراوانی نسبی ذرات، جرم ویژه ظاهری، میانگین و انحراف معیار هندسی قطر ذرات، تخلخل خاک، درصد سنگریزه و رطوبت اولیه خاک می‌باشد. ویژگی‌های فراوانی نسبی ذرات، جرم ویژه ظاهری، درصد سنگریزه و رطوبت اولیه خاک در بیشتر مطالعات خاک‌شناسی اندازه‌گیری می‌شوند. میانگین و انحراف معیار هندسی قطر ذرات و تخلخل خاک نیز از روابط موجود قابل محاسبه هستند. بنابراین، این ویژگی‌ها

جدول ۴ شبکه‌های عصبی گزینش شده برای برآورد پارامتر a مدل هورتون را نشان می‌دهد. این جدول نشان می‌دهد مقدار خطای بخش آزمون شبکه‌ها همواره کمتر از مقدار آن در بخش آموزش بوده است. بررسی‌ها نشان داد در صورتی که شبکه‌ها به گونه‌ای آموزش یابند که خطای آموزش کمتر از مقادیر آن در این جدول گردد، شبکه به سمت وراآموزی پیش می‌رود. بنابراین، می‌توان نتیجه گرفت شبکه‌های گزینش شده به خوبی آموزش دیده و از قدرت تعمیم‌دهی مناسبی برخوردار هستند.

این جدول نشان می‌دهد بهترین شبکه طراحی شده برای برآورد پارامتر a مدل هورتون با استفاده از متغیرهای مقدار شن، سیلت و رس (ANN_3)، شبکه‌ای بود که در آن از ۱۴ گره در لایه پنهان استفاده شد. در این شبکه، توابع آستانه لایه‌ها پنهان و خروجی به ترتیب purelin و purelin بوده است. در مرحله‌ی بعد، شبکه‌های گزینش شده ANN_1 تا ANN_{11} مورد مقایسه قرار گرفتند و از بین آنها بهترین شبکه برای برآورد هر کدام از پارامترهای نفوذ تعیین

همواره در دسترس بوده یا این که اندازه‌گیری آن‌ها کم‌هزینه و جزو کارهای روزمره آزمایشگاهی است. در این نوع ارزیابی، ابتدا از بین شبکه‌های $ANN_1, ANN_2, ANN_3, ANN_4, ANN_5, ANN_6$ و ANN_7 شبکه‌ای که دارای بهترین عملکرد در برآورد هر یک از پارامترهای نفوذ بود، انتخاب گردید. شبکه‌های انتخاب شده به این روش در جدول ۶ ارایه شده است.

(جدول ۴) - شبکه‌های عصبی گزینش شده در برآورد پارامتر a در معادله هورتون

نوع شبکه	معماری انتخابی	توابع آستانه	RMSE آزمون	RMSE آموزش
ANN_1	۳-۱۴-۱	purelin-purelin	۰/۰۲۷۴۲۷	۰/۰۸۵۰۴۶
ANN_2	۴-۵-۱	logsig-purelin	۰/۰۲۶۹۹۶	۰/۰۸۵۹۸۲
ANN_3	۵-۳-۱	tansig-purelin	۰/۰۲۶۹۸۱	۰/۰۸۵۹۹۲
ANN_4	۶-۳-۱	logsig-purelin	۰/۰۲۶۹۷۱	۰/۰۸۵۹۸۴
ANN_5	۷-۳-۱	logsig-purelin	۰/۰۲۴۳۶۴	۰/۰۸۵۰۲۷
ANN_6	۸-۱۹-۱	tansig-purelin	۰/۰۲۵۴۹۳	۰/۰۸۴۹۵۹
ANN_7	۹-۱۸-۱	logsig-purelin	۰/۰۲۶۹۸۲	۰/۰۸۵۹۹۰
ANN_8	۱۰-۱۶-۱	logsig-purelin	۰/۰۲۶۹۸۳	۰/۰۸۵۹۸۹
ANN_9	۱۱-۸-۱	tansig-purelin	۰/۰۲۶۲۹۸	۰/۰۸۴۶۱۸
ANN_{10}	۱۲-۷-۱	tansig-purelin	۰/۰۲۴۵۱۱	۰/۰۸۵۱۰۲
ANN_{11}	۱۳-۳-۱	tansig-logsig	۰/۰۲۳۶۳۳	۰/۰۲۳۹۴۷

در این میان، تنها خطای شبکه‌های گزینش شده برای پارامتر k مدل فیلیپ در دو گروه یاد شده از شبکه‌ها تفاوتی زیاد داشت. بنابراین، می‌توان ادعا کرد عملکرد شبکه‌های پی‌ریزی شده با استفاده از در دسترس‌ترین ویژگی‌های افق سطحی و شبکه‌های پی‌ریزی شده به کمک تمامی ویژگی‌های افق سطحی که در این پژوهش اندازه‌گیری شد، یکسان بوده است.

مقایسه خطاهای بخش آزمون در جداول ۵ و ۶ نشان می‌دهد بهترین شبکه‌های گزینش شده با استفاده از همه ویژگی‌های افق سطحی برای پارامترهای m هورتون، k' و b' مدل کوستیاکوف-لوییز با بهترین شبکه‌های انتخاب شده از بین ANN_1 تا ANN_7 یکسان بوده است. این جدول‌ها نشان می‌دهد در این دو گروه از شبکه‌ها، مقدار خطای بخش آزمون برای پارامترهای a هورتون، k فیلیپ، b و k کوستیاکوف و A کوستیاکوف-لوییز بسیار به هم نزدیک بوده است.

(جدول ۵) - بهترین شبکه‌های پی‌ریزی شده با استفاده از ویژگی‌های زودیافت افق سطحی

مدل	پارامتر	توابع آستانه	معماری	RMSE آزمون	RMSE آموزش
هورتون	C	logsig-purelin	۱۳-۳-۱	۰/۱۱۱۸۶	۰/۱۲۴۷۲
	m	logsig-purelin	۵-۱۲-۱	۰/۰۸۱۷۹۵	۰/۱۰۳۹۱۵
	a	tansig-logsig	۱۳-۳-۱	۰/۰۲۳۶۳۳	۰/۰۲۳۹۴۷
فیلیپ	S	tansig-logsig	۱۳-۲۰-۱	۰/۰۹۴۷۷۴	۰/۱۲۴۶۰۰
	k	logsig-purelin	۱۳-۱۴-۱	۰/۱۲۶۴۲۵	۰/۱۲۵۰۱۵
کوستیاکوف-لوییز	k'	tansig-logsig	۶-۷-۱	۰/۰۶۵۴۱۸	۰/۰۹۷۳۷۷
	b'	tansig-logsig	۶-۱۶-۱	۰/۰۸۲۱۵۷	۰/۰۹۹۹۶۲
	A	tansig-purelin	۱۳-۵-۱	۰/۱۶۷۲۱۰	۰/۱۵۴۵۱۰
	k	tansig-logsig	۱۳-۳-۱	۰/۰۵۹۶۴۷	۰/۰۳۶۲۱۸
کوستیاکوف	b	tansig-logsig	۱۳-۱۳-۱	۰/۱۴۹۸۱۵	۰/۱۵۰۰۰۵

مورد نظر برای برآورد پارامترهای مدل‌های نفوذ، پی‌ریزی شد. بدین منظور، برای هر پارامتر، شبکه‌هایی با چهار ترکیب از توابع آستانه یاد شده و تعداد گره‌های متفاوت لایه‌ی پنهان طراحی شد. با توجه به تعداد گره‌های استفاده شده در لایه‌ی میانی هر شبکه (از ۳ تا ۲۰ گره)، تعداد شبکه‌های طراحی شده برای یکی از پارامترها برابر با ۱۸

شبکه‌های عصبی گونه دوم

شبکه‌های پی‌ریزی شده در این گروه با استفاده از مولفه‌های اصلی ایجاد گردید. بدین منظور ویژگی‌های زودیافت افق سطحی و زیرسطحی خاک انتخاب و مولفه‌های اصلی مورد تجزیه و تحلیل قرار گرفت. پس از تعیین بارزترین مولفه‌های اصلی، شبکه‌های عصبی

پارامترهای مدل‌های یادشده ۳۶۰ شبکه (۴×۵×۱۸) آموزش یافته و مورد آزمون قرار گرفت. برای هر کدام از پارامترهای مدل‌های گفته شده، شبکه‌هایی جداگانه پی‌ی‌زی شد و در مجموع ۳۶۰۰ شبکه مورد بررسی قرار گرفت.


شبکه است. هر کدام از این شبکه‌ها، ۵ بار در برنامه‌ی Matlab اجرا گردید و میانگین خطا و داده‌های برآورد شده به عنوان عملکرد شبکه در نظر گرفته شد. در طراحی شبکه‌ها از چهار نوع ترکیب در توابع آسـتانه (purelin-purelin, tansig-purelin, logsig-purelin, tansig-logsig) استفاده شد. بنابراین، برای برآورد هر کدام از

(جدول ۶) - بهترین شبکه‌های پی‌ی‌زی شده به کمک در دسترس‌ترین ویژگی‌های افقی سطحی

مدل	پارامتر	توابع آستانه	معماری	RMSE آزمون	RMSE آموزش
	C	logsig-purelin	۹-۱۴-۱	۰/۱۴۸۱۹	۰/۱۴۸۸۱
هورتون	m	logsig-purelin	۵-۱۲-۱	۰/۰۸۱۷۹۵	۰/۱۰۳۹۱۵
	a	logsig-purelin	۷-۳-۱	۰/۰۲۴۳۶۴	۰/۰۸۵۰۲۷
	S	tansig-logsig	۵-۱۶-۱	۰/۰۹۹۴۳۸	۰/۱۳۰۱۸۵
فیلیپ	k	tansig-logsig	۵-۳-۱	۰/۱۵۰۵۹۰	۰/۱۴۰۲۸۰
	k'	tansig-logsig	۶-۷-۱	۰/۰۶۵۴۱۸	۰/۰۹۷۳۷۷
کوستیاکوف-لوییز	b'	tansig-logsig	۶-۱۶-۱	۰/۰۸۲۱۵۷	۰/۰۹۹۹۶۲
	A	tansig-purelin	۵-۱۷-۱	۰/۱۷۸۷۶۰	۰/۱۷۹۵۶۵
	k	logsig-purelin	۴-۱۰-۱	۰/۰۷۱۴۷۳	۰/۰۸۳۲۱۵
کوستیاکوف	b	tansig-logsig	۳-۳-۱	۰/۱۵۵۴۸۰	۰/۱۶۱۴۱۰

مولفه‌های اصلی محاسبه شده را نشان می‌دهد. همان‌گونه که در این شکل آمده است، ۲۶ مولفه برای تمامی داده‌های زودیاقت اندازه‌گیری شده در این پژوهش، محاسبه گردید. برای بررسی اهمیت مولفه‌های اصلی، می‌توان از مقایسه واریانس آن‌ها (مقادیر ویژه) با واریانس متغیرهای اولیه استفاده کرد. بعد از استاندارد کردن متغیرهای اولیه، کلیه آنها دارای واریانس برابر یک خواهند بود. بنابراین، مقدار ویژه ۶/۹۱ در مولفه نخستین نشان‌دهنده این واقعیت است که واریانس این مولفه ۶/۹۱ برابر واریانس متغیرهای اصلی است. هر چه مقدار ویژه یک مولفه بیشتر باشد، مقداری از تغییرات کل واریانس داده‌ها که توسط آن توجیه می‌شود، بیشتر است (۶).

ویژگی‌های زودیاقت مورد استفاده برای تجزیه مولفه‌های اصلی دارای واحدهای متفاوت بودند. در این حالت برای انجام تجزیه مولفه‌های اصلی باید از ماتریس همبستگی استفاده نمود (۱۲). بنابراین به منظور جلوگیری از تاثیر زیاد یک متغیر بر مولفه‌های اصلی، داده‌ها استاندارد شد و ماتریس متقارن همبستگی داده‌ها (معادل با تعداد ویژگی‌های زودیاقت دو لایه) محاسبه شد. در مرحله بعد، بردارهای ویژه (ضرایب مولفه‌ها) و مقادیر ویژه (واریانس بردارهای ویژه) محاسبه گردیدند. سپس، با استفاده از مقادیر ویژه محاسبه شده، مولفه‌های اصلی تعیین گردید. شکل ۲ چگونگی توجیه واریانس داده‌ها (مقادیر ویژه) به کمک



(شکل ۲) - نمودار مقادیر ویژه محاسبه شده برای مولفه‌های اصلی

مدل‌های نفوذ استفاده گردید. بنابراین می‌توان گفت در این نوع از شبکه‌ها، از ویژگی‌های بارز افق‌های سطحی و زیرسطحی به طور هم‌زمان برای پی‌ریزی شبکه‌های اصلی استفاده شد.

برابر آنچه برای شبکه‌ها گونه نخست ارایه گردید، بهترین شبکه‌ها برای برآورد پارامترهای نفوذ به کمک مولفه‌های اصلی تعیین گردید. جدول ۷ بهترین شبکه‌های پی‌ریزی شده برای برآورد پارامترهای مدل‌های نفوذ را با استفاده از مولفه‌های اصلی نشان می‌دهد. در این شبکه‌ها از ۱۰ مولفه نخست استخراج شده به عنوان ورودی شبکه‌های برآوردکننده پارامترهای مدل‌های نفوذ استفاده شد.

جدول ۷- بهترین شبکه‌های پی‌ریزی شده با استفاده از مولفه‌های اصلی

مدل	پارامتر	توابع آستانه	معماری	RMSE آزمون	RMSE آموزش
	C	logsig-purelin	۱۰-۲۰-۱	۰/۱۱۸۷۳	۰/۱۲۹۰۹۳
هورتون	m	tansig-purelin	۱۰-۱۹-۱	۰/۰۸۷۱۵۳	۰/۱۱۷۲۸۷
	a	purelin-purelin	۱۰-۱۷-۱	۰/۰۲۳۷۶۸	۰/۰۸۲۸۲۸
	S	tansig-logsig	۱۰-۱۵-۱	۰/۰۹۹۳۷۸	۰/۱۳۰۰۶
فیلیپ	k	logsig-purelin	۱۰-۲۰-۱	۰/۱۳۱۲۴۷	۰/۱۲۷۳۳۷
	k'	tansig-logsig	۱۰-۳-۱	۰/۰۷۶۷۳۶	۰/۰۵۴۴۵۰
کوستیاکوف-لوییز	b'	purelin-purelin	۱۰-۱۵-۱	۰/۱۴۵۱۲	۰/۰۷۸۵۲۹
	A	logsig-purelin	۱۰-۱۸-۱	۰/۱۶۶۹۹۵	۰/۱۵۷۹۲۵
	k	tansig-logsig	۱۰-۱۵-۱	۰/۰۷۱۶۶۴	۰/۰۴۳۴۷۶
کوستیاکوف	b	purelin-purelin	۱۰-۱۹-۱	۰/۱۷۲۱۳۵	۰/۱۴۳۳۴

به کار گرفته شد. همان‌گونه که در جدول ۵ آمده است، در پی‌ریزی شبکه‌های عصبی برای پارامترهای m هورتون، k' و b' کوستیاکوف-لوییز به ترتیب از ۵، ۶ و ۴ ویژگی زودیافت افق سطحی استفاده شده است.

بنابر آنچه گفته شد برتری‌های شبکه‌های عصبی گونه نخست را می‌توان در ۳ مورد کلی بیان کرد. اولاً، ارزیابی این شبکه‌ها در برآورد هر یک از پارامترهای نفوذ نشان داد قدرت تعمیم‌دهی این شبکه‌ها بهتر از شبکه‌های گونه دوم است. ثانیاً، در پی‌ریزی این شبکه‌ها از تعداد متغیر کمتری استفاده شد، بنابراین کاربرد آنها آسان‌تر است. ثالثاً در شبکه‌های گونه نخست تنها از ویژگی‌های زودیافت افق سطحی استفاده شده که در بیشتر مطالعات خاک‌شناسی اندازه‌گیری می‌شوند.

دلایل این برتری را می‌توان به گونه زیر توجیه نمود. نخست اینکه، در پی‌ریزی شبکه‌های گونه دوم از مولفه‌های اصلی استفاده شد. در استخراج این مولفه‌ها که به عنوان ویژگی‌های بارز شناخته می‌شوند تنها همبستگی خطی بین داده‌ها در نظر گرفته می‌شود. بنابراین ویژگی‌های بارز استخراج شده ترکیب خطی متغیرهای اولیه بوده و ترکیبات غیرخطی متغیرها را بیان نمی‌کند (۲). حال آن که در شبکه‌های عصبی گونه نخست از متغیرهای اصلی استفاده گردید که ترکیبات غیرخطی داده‌ها در آنها حذف نشده است.

شکل ۲ نشان می‌دهد، ۱۰ مولفه نخست، حدود ۹۰ درصد از تغییرات داده‌ها را توجیه کردند. دیگر مولفه‌های اصلی به تنهایی نسبتی اندک از تغییرات داده‌ها را توجیه نمودند. با توجه به این که هدف از استفاده از تجزیه مولفه‌های اصلی، کاهش متغیرهای ورودی شبکه‌های عصبی بود، مولفه‌های ۱۰ به بعد که تنها ۱۰ درصد از کل تغییرات داده‌ها را بیان کرده‌اند، حذف گردیدند. بنابراین، ۱۰ مولفه نخست به عنوان مولفه‌های اصلی برای استفاده در لایه ورودی شبکه‌های عصبی انتخاب شدند. در شبکه‌های عصبی گونه دوم از مولفه‌ها اصلی به عنوان ورودی شبکه‌ها برای برآورد پارامترهای

مقایسه شبکه‌ها گونه نخست و گونه دوم

به منظور مقایسه عملکرد شبکه‌های پی‌ریزی در گونه نخست و گونه دوم از مقادیر RMSE بخش آزمون استفاده شد. بدین جهت، یافته‌هایی که در جدول‌های ۵ و ۷ هستند، به کار گرفته شدند. مقایسه RMSE های آزمون در این جدول‌ها نشان داد شبکه‌های عصبی گونه نخست عملکردی مناسب‌تر در برآورد پارامترهای مدل‌های نفوذ داشته‌اند. این مقادیر نشان داد به جز در شبکه‌های طراحی شده برای پارامتر A مدل کوستیاکوف-لوییز، تمامی شبکه‌های گونه نخست دارای RMSE کمتری در بخش آزمون بوده‌اند. البته در برخی موارد از جمله شبکه‌های طراحی شده برای پارامترهای C و a هورتون و A کوستیاکوف لوییز، عملکرد هر دو گونه شبکه تقریباً یکسان بود. نتایج نشان داد به طور میانگین شبکه‌های گونه نخست در بخش آموزش نیز الگوی مناسب‌تری از تغییرات پارامترهای مدل‌های نفوذ را برآورد نمودند.

در مقایسه بین دو گونه شبکه، در صورت برابری خطای آموزش دو گونه شبکه، شبکه‌های گونه نخست بر گونه دوم برتری دارند. زیرا، در پی‌ریزی شبکه‌های گونه نخست حداکثر از ۱۳ ویژگی زودیافت افق سطحی استفاده شد. حال آنکه در پی‌ریزی شبکه‌های گونه دوم، ویژگی‌های زودیافت افق‌های سطحی و زیرسطحی به طور هم‌زمان

برآورد نیز در این گونه خاک‌ها زیاد شده است.

مقایسه مقادیر MRMSD نشان می‌دهد شبکه‌های عصبی برآورد کننده‌ی پارامترهای مدل کوستیاکوف دارای بیشترین خطا بودند. بهترین رتبه برآوردگری را شبکه‌های طراحی شده برای مدل فیلیپ با MRMSD معادل ۶/۶۴۴ سانتی‌متر داشته است. با توجه به این که مقدار انحراف معیار RMSD ها بیانگر پراکنش خطای برآورد حول میانگین RMSD ها است، از این نظر مقدار این آماره نشان می‌دهد که هر مدل با چه پراکنشی نفوذ آب به خاک را برآورد می‌کند. نگاهی به این آماره نشان می‌دهد شبکه‌های پی‌ریزی شده برای مدل کوستیاکوف بیشترین انحراف از میانگین RMSD ها را داشتند. در رابطه با این آماره، شبکه‌های پی‌ریزی شده برای مدل هورتون رتبه اول را داشته‌اند.

به منظور تعیین رتبه شبکه‌های ایجاد شده، میانگین رتبه به‌دست آمده از آماره‌های میانگین قدر مطلق میانگین خطاها (MAMD)، میانگین ریشه میانگین مربعات خطا (MRMSD)، میانگین ضریب همبستگی پیرسون (MPearson) و انحراف معیار RMSD ها (SDRMSD) مورد بررسی قرار گرفت. ارزیابی اعتبار مدل‌های نفوذ نشان می‌دهد شبکه‌های ایجاد شده برای پارامترهای مدل فیلیپ دارای بهترین عملکرد در برآورد نفوذ تجمعی آب به خاک بوده و شبکه‌های پی‌ریزی شده برای مدل‌های هورتون، کوستیاکوف-لویز و کوستیاکوف به ترتیب در رتبه دوم تا چهارم قرار گرفتند. البته مقادیر آماره‌های به‌دست آمده در این جدول نشان می‌دهد عملکرد شبکه‌های پی‌ریزی شده برای مدل‌های فیلیپ و هورتون بسیار به هم نزدیک بوده است.

آزمون اعتباریابی این شبکه‌ها نشان داد خطای مدل کوستیاکوف در برآورد نفوذ تجمعی آب به خاک با دیگر مدل‌ها اختلاف چشمگیری داشت. این اختلاف در مورد همه آماره‌های محاسبه شده صادق بود. دلیل بالا بودن خطای این مدل در صورت استفاده از پارامترهای برآورد شده با شبکه‌های پی‌ریزی شده را می‌توان در دو نکته دانست. نخست خطای بالای برآورد پارامترهای این مدل توسط شبکه‌های عصبی پی‌ریزی شده و دیگر دو پارامتری بودن مدل کوستیاکوف و در نتیجه حساسیت زیاد این مدل به تغییرات پارامترهای آن؛ به‌ویژه پارامتر b که به صورت توان در آن به کار رفته است.

مقادیر خطای بخش آزمون در جدول ۵ نشان می‌دهد بیشترین خطا را شبکه‌های پی‌ریزی شده برای برآورد پارامتر b کوستیاکوف دارا بوده است. مدل کوستیاکوف، مدلی دو پارامتری بوده و پارامتر b به‌صورت توان در آن به کار رفته است. مقادیر نفوذ تجمعی برآورد شده به وسیله این مدل حساسیتی بالا به تغییرات پارامتر b دارد. با توجه به این که پارامتر برآورد شده b به کمک شبکه‌های عصبی دارای خطایی زیاد بود، منحنی نفوذ برآورد شده به وسیله مدل کوستیاکوف

دیگر دلیل نقصان شبکه‌های گونه دوم این است که در این شبکه‌ها به منظور جلوگیری از نفرین ابعادی از تمامی مولفه‌ها استفاده نشد. در این شبکه‌ها تنها از ۱۰ مولفه نخست استفاده گردید. همان گونه که شکل ۲ نشان می‌دهد، ۱۰ مولفه نخست تنها ۹۰ درصد از تغییرات داده‌های ورودی را نشان می‌دهد. بنابراین، ۱۰ درصد از تغییرات کل داده‌ها که در دیگر مولفه‌ها نهفته است از دست رفته است.

برای رفع کاستی‌های استفاده از ویژگی‌های بارز، پیشنهاد می‌گردد از دیگر روش‌های استخراج ویژگی‌های بارز مانند الگوریتم ژنتیک^۱ استفاده گردد. همچنین، در صورتی که تعداد داده‌های مورد استفاده در پی‌ریزی شبکه‌های گونه دوم زیادتر گردد، می‌توان از تعداد بیشتری از مولفه‌های اصلی، بدون وجود مشکلات ناشی از نفرین ابعادی استفاده نمود. با اعمال این شرایط شاید بتوان عملکرد شبکه‌های عصبی گونه دوم را بهبود بخشید.

عملکرد شبکه‌های پی‌ریزی شده در برآورد نفوذ تجمعی آب به خاک


با توجه به اینکه مقایسه عملکرد شبکه‌های گونه نخست و گونه دوم، برتری شبکه‌های گونه نخست را در برآورد پارامترهای مدل‌های نفوذ نشان داد، بنابراین به منظور برآورد منحنی تجمعی نفوذ آب به خاک، تنها از شبکه‌های گونه نخست استفاده گردید.

جدول ۸ آماره‌های محاسبه شده برای ارزیابی اعتبار شبکه‌های عصبی ایجاد شده با استفاده از تمامی ویژگی‌های افق سطحی را برای برآورد نفوذ نشان می‌دهد. اعداد داخل پرانتز نشان دهنده رتبه شبکه‌های برآوردکننده پارامترهای هر مدل برای آماره مربوطه می‌باشند. در ستون رتبه، عملکرد کلی هر شبکه در برآورد منحنی نفوذ تجمعی آمده است. مقادیر متوسط میانگین خطاها (MMD) نشان می‌دهد همه شبکه‌های عصبی پی‌ریزی شده، مقدار نفوذ را کمتر از مقدار واقعی آن برآورد نموده‌اند. مقایسه مقدار قدر مطلق میانگین MD ها و میانگین AMD ها نشان می‌دهد هیچکدام از شبکه‌های ایجاد شده به‌طور سیستماتیک، بیش یا کم برآوردگر نبوده‌اند. این نکته در شکل ۳ نیز به خوبی دیده می‌شود.

شکل ۳ نشان می‌دهد خطای برآورد شبکه‌های عصبی پی‌ریزی شده به‌صورت کم برآوردی بوده است. مطابق با این شکل، خطای برآورد نفوذ در خاک‌هایی بیشتر بوده که مقدار نفوذ اندازه‌گیری شده در آن‌ها در مقایسه با دیگر خاک‌ها بسیار زیادتر بوده است. علت نفوذ زیاد آب در این خاک‌ها وجود منافذ بسیار درشت و در نتیجه جریان ترجیحی می‌باشد. از آنجا که در بین ویژگی‌های زودیافت مورد استفاده، کمیتی برای بیان جریان ترجیحی وجود نداشته است، خطای

نیست. با طولانی شدن زمان نفوذ آب به خاک اثر خطای ناشی از بیش یا کم برآوردی پارامتر b بیشتر می‌شود.

نیز از خطایی زیاد برخوردار است. زیرا میزان انحراف نفوذ برآورد شده تابعی از خطای ناشی از برآورد این پارامتر است. بنابراین، بالا بودن خطای موجود در برآورد نفوذ تجمعی آب به خاک دور از انتظار




(شکل ۳) - مقادیر نفوذ تجمعی اندازه‌گیری شده و برآورد شده به وسیله شبکه‌های عصبی گزینش شده (ارایه شده در جدول (۵))

(جدول ۸) - شاخص‌های ارزیابی شبکه‌های گزینش شده در برآورد نفوذ تجمعی


رتبه	SDRMSD	MPearson	MRMSD	MAMD	MMD	مدل
۲	۷/۶۲۸(۱)	۰/۸۹(۱)	۶/۶۴۴(۲)	۵/۷۰۰(۲)	-۲/۰۶۲	هورتون
۱	۸/۰۴۰(۲)	۰/۸۹(۱)	۶/۳۳۲(۱)	۵/۴۳۴(۱)	-۱/۲۷۳	فیلیپ
۳	۸/۶۸۷(۳)	۰/۸۲(۲)	۸/۷۶۸(۳)	۷/۶۰۶(۳)	-۳/۵۹۲	کوستیاکوف-لوییز
۴	۱۱/۴۱۳(۴)	۰/۷۲(۳)	۱۱/۹۹۰(۴)	۱۰/۴۴۴(۴)	-۰/۱۷۱	کوستیاکوف

زیاد ($k+50\%$) برآورد شده باشد را نشان می‌دهد. مقایسه این دو شکل این واقعیت که مدل کوستیاکوف به تغییرات پارامتر b حساسیتی بیشتر نسبت به پارامتر k دارد را نمایان می‌سازد. شکل ۴ نشان می‌دهد خطای برآورد نفوذ تجمعی در اثر بیش برآورد شدن پارامتر b ، بسیار بیشتر از حالتی است که این پارامتر کمتر از مقدار واقعی برآورد شده باشد. حال آنکه بیش یا کم برآوردی پارامتر k اثری یکسان بر انحراف منحنی نفوذ تجمعی آب به خاک از مقدار واقعی داشته است.

همچنین در صورتی که شبکه‌های پی‌ریزی شده، مقدار پارامتر b را بیشتر از مقدار واقعی برآورد کنند، خطای ایجاد شده در برآورد نفوذ تجمعی بیش از زمانی است که پارامتر b به همان نسبت کمتر از مقدار واقعی برآورد گردد. حساسیت مدل کوستیاکوف به تغییرات پارامترهای b و k در شکل‌های ۴ و ۵ ارایه شده است. شکل ۴ میزان انحراف منحنی نفوذ تجمعی از مقدار واقعی آن در حالتی که پارامتر b به اندازه ۵۰٪ مقدار واقعی آن کم ($b-50\%$) یا زیاد ($b+50\%$) برآورد شده باشد را نشان می‌دهد. شکل ۵ نیز حساسیت منحنی نفوذ تجمعی در حالتی که پارامتر k به اندازه ۵۰٪ مقدار واقعی آن کم ($k-50\%$) یا



(شکل ۴) - تاثیر بیش یا کم برآوردی پارامتر b کوستیاکوف در برآورد نفوذ تجمعی



(شکل ۵) - تاثیر بیش یا کم برآوردی پارامتر k کوستیاکوف در برآورد نفوذ تجمعی

منابع

- ۱- قربانی دشتکی، ش. و همایی. م. ۱۳۸۶. برآورد پارامترهای برخی مدل‌های نفوذ آب به خاک با استفاده از توابع انتقالی. مجله آبیاری و زهکشی ایران، ۱(۱): ۲۱ تا ۳۹.
- ۲- مقدم، م.، محمدی شوطی، س. و آقایی. م. ۱۳۷۳. آشنایی با روش‌های آماری چند متغیره. انتشارات پیش‌تاز علم، تبریز، ایران. ۲۰۸ صفحه.
- 3- Bishop, C.M. 1995. Neural Networks for Pattern Recognition Oxford University Press, Oxford, pp. 482.
- 4- Blake, G.R. and Hartge. K.H. 1986. Bulk density. In: Klute, A. (Ed), Methods of soil analysis. Part 1. 2nd ed. Agron. Monogr. 9. ASA. Madison. WI. pp. 363-375.
- 5- Burnham, K.P. and Anderson. D.R. 2002. Model selection and multimodel inference: A practical information-theoretic approach. Springer, New York, NY, pp. 488.
- 6- Camdevyren, H., Demyr, N. Kanik A. and Keskin. S. 2005. Use of principal component scores in multiple linear regression models for prediction of Chlorophyll-a in reservoirs. Ecol Model., 181: 581-589.

- 7- Davidoff, B. and Selim. H.M. 1986. Goodness of fit for eight water infiltration models. *Soil Sci. Soc. Am. J.*, 50: 759-764.
- 8- Gee, G.W. and Bauder. J.W. 1986. Particle size analysis. In: *Methods of soil analysis. Part 1.* 2nd ed. Klute, A. (Ed). Agron. Monogr. 9. ASA. Madison. WI. pp. 383-411.
- 9- Govindaraju, R.S. and Ramachandra A. Rao. 2000. *Artificial neural networks in hydrology.* Kluwer academic publishers, the Netherlands. p. 329.
- 10- Green W.H. and Ampt. G.A. 1911. Studies on soil physics: Part 1. The flow of air and water through soil. *Journal of Agriculture Sciences*, 4: 1-24.
- 11- Haykin, S. 1999. *Neural networks: A comprehensive foundation*, Prentice Hall, NJ.
- 12- Hocking, R.R. 2003. *Methods and applications of linear models.* New Jersey: Wiley. 741 pp.
- 13- Horton, R.E. 1940. Approach toward a physical interpretation of infiltration capacity. *Soil Sci. Soc. of Am. J.*, 5:339-417.
- 14- Kao, C.S. and Hunt. J.R. 1996. Prediction of wetting front movement during one-dimensional infiltration into soils. *Water Resour. Res.*, 9(2): 384-395.
- 15- Kostiakov A.V. 1932. On the dynamics of the coefficient of water percolation in soils and on the necessity for studying it from a dynamics point of view for purposes of amelioration. *Transactions of the Sixth Commission of International Society of Soil Science*, part A, pp. 17-21.
- 16- Mackay, D.J.C. 1992. Bayesian interpolation. *Neural Computation*, 4(3): 415-447.
- 17- Maier, H.R. and Dandy. G.C. 2000. Application of artificial neural networks to forecasting of surface water quality variables: Issues, applications and challenges. In: *Artificial neural networks in hydrology.* 287-309. Govindaraju, R.S. and A. Ramachandra Rao (Eds). Kluwer academic publishers, the Netherlands.
- 18- Mein, R.G. and Larson. C.L. 1973. Modeling infiltration during a steady rain. *Water Resour. Res.*, 9(2):384-395.
- 19- Merdun H., Cınar, 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.
- 20- Mezencev, V.J. 1948. Theory of formation of the surface runoff (In Russian). *Meteorolgia I gidrologia*, 3:33-46.
- 21- Minasny, B. and McBratney. A.B. 2002. The Neuro-m method for fitting neural network parametric pedotransfer functions. *Soil Sci. Soc. Am. J.*, 66:352-361.
- 22- Pachepsky, Y.A., Timlin D.J. and Varallyay. G. 1996. Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Sci. Soc. Am. J.*, 60: 727-773.
- 23- Parasuraman, K., Elshorbagy A. and Si. B.C. 2006. Estimating saturated hydraulic conductivity in spatially variable field using neural network ensembles. *Soil Sci. Soc. Am. J.*, 70: 1851-1859.
- 24- Philip, J.R. 1957a. The theory of infiltration: 1. The infiltration equation and its solution. *Soil Sci.*, 83: 345-357.
- 25- Philip, J.R. 1957b. The theory of infiltration: 2. The profile at infinity. *Soil Sci.*, 83: 435-448.
- 26- Philip, J.R. 1969. Theory of infiltration. *Adv. In Hydrosoci.*, 5: 215-296.
- 27- Schaap, M.G. and Leij. F.J. 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil and Tillage Research*, 47:37-42 .
- 28- Shirazi, M.A. and Boersma. L. 1984. A unifying quantitative analysis of soil texture. *Soil Sci. Soc. Am. J.*, 48: 142-147.
- 29- Walkley, A. and Black. I.A. 1934. An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Sci.*, 37: 29-39.

Estimating soil water infiltration parameters using Artificial Neural Networks

Sh. Ghorbani Dashtaki¹ - M. Homae^{*2} - M.H. Mahdian³

Abstract

Infiltration is a significant process which controls the fate of water in the hydrologic cycle. The direct measurement of infiltration is time consuming, expensive and often impractical because of the large spatial and temporal variability. Artificial Neural Networks (ANNs) are used as an indirect method to predict the hydrological processes. The objective of this study was to develop and verify some ANNs to predict the infiltration process. For this purpose, 123 double ring infiltration data were collected from different sites of Iran. The parameters of some infiltration models were then obtained; using sum squares error optimization method. Basic soil properties of the two upper pedogenic layers such as initial water content, bulk density, particle-size distributions, organic carbon, gravel content, CaCO₃ percent and soil water contents at field capacity and permanent wilting point were obtained for each sampling point. The feedforward multilayer perceptron was used for predicting the infiltration parameters. Two ANNs types were developed to estimate infiltration parameters. The developed ANNs were categorized into two groups; type 1 and type 2 ANNs. For developing type 1 ANNs, the basic soil properties of the first upper soil horizon were used as inputs, hierarchically. While for developing type 2 ANNs the basic soil properties of the two upper soil horizons were used as inputs, using principal component analysis technique. Evaluation results of these two types ANNs showed the better performance of type 1 ANNs in predicting the infiltration parameters. Therefore, this type of ANNs was used for predicting the cumulative infiltration. The reliability test indicated that the developed ANNs for Philip model have the best performance to predict cumulative infiltration with a mean RMSE of 6.644 cm. The developed ANNs for Horton, Kostiakov-Lewis and Kostiakov have the next best ranks, respectively.

Keywords: Multilayer Perceptron, Artificial Neural Networks, Infiltration Models, Soil Infiltration

1- Former PhD student of Tarbiat Modares University

2- Associated Prof., Department of Soil Science, Tarbiat Modares University

(*- Corresponding author Email: mhomae@modares.ac.ir)

3- Assistant Prof., Soil Conservation and Watershed Management Research Institute, Iran, respectively