

سومین کارگاه فنی زهکشی

۲۳ مهر ماه ۱۳۸۳

برآورد سریع هدایت آبی اشباع خاک با استفاده

از شبکه عصبی مصنوعی

مریم نوابیان^۱، عبدالمجید لیاقت^۲، مهدی همایی^۳

چکیده

هدایت آبی اشباع مهمترین ویژگی فیزیکی خاک است که در طراحی و امکان‌پذیر بودن فنی و اقتصادی پروژه‌های زهکشی زیرزمینی نقش عمده‌ای به عهده دارد. لیکن، اندازه‌گیری مستقیم این ویژگی چه به صورت صحرایی و چه در آزمایشگاه بسیار وقت‌گیر و پرهزینه می‌باشد. همچنین، به دلیل تغییرات زیاد زمانی - مکانی خاکها، اندازه‌گیری‌های نقطه‌ای نمی‌توانند نماینده واقعی این ویژگی خاک باشند، مگر آنکه تعدادی بسیار زیاد نمونه‌برداری صورت پذیرد. در سالهای اخیر استفاده از شبکه‌های عصبی مصنوعی به عنوان راهکاری که ویژگی‌های فیزیکی خاک را از پارامترهای زودیافت خاک برآورد می‌کند، مورد توجه قرار گرفته است. شبکه عصبی مصنوعی از الگوی شبکه عصبی انسان شبیه‌سازی شده است، به گونه‌ای که می‌تواند پس از آموزش، پارامترهای خروجی مورد نظر را با اعمال پارامترهای ورودی برآورد نماید. در این پژوهش، از ساختار شبکه عصبی پرسپترون با الگوریتم آموزشی مارکوات لورنبرگ استفاده شد تا هدایت آبی اشباع از پارامترهای زودیافت خاک همچون جرم ویژه ظاهری، تخلخل مؤثر، میانگین هندسی قطر ذرات و انحراف معیار آنها برآورد شود. نتایج نشان داد که نمونه‌های عصبی ایجاد شده قادرند هدایت آبی اشباع را با دقت بالا ($R^2=0.83$) برآورد نمایند. همچنین، در مقایسه با معادلات رگرسیونی موجود، مدل‌های شبکه عصبی ارائه شده عملکردی مناسب‌تر دارند.

واژه‌های کلیدی: پارامترهای زودیافت خاک، شبکه عصبی مصنوعی، هدایت آبی اشباع.

۱- دانشجوی دکتری گروه آبیاری و آبادانی دانشکده کشاورزی دانشگاه تهران-@ma_navabian@yahoo.com

۲- استادیار گروه آبیاری و آبادانی دانشکده کشاورزی دانشگاه تهران-@aliaghat@ut.ac.ir

۳- استادیار گروه خاکشناسی دانشکده کشاورزی دانشگاه تربیت مدرس

مقدمه

اندازه‌گیری مستقیم هدایت آبی اشباع چه در آزمایشگاه و چه در صحرا غالباً هزینه‌بر و وقت‌گیر است. به همین دلیل، پژوهشگران بر آن شده‌اند تا با استفاده از روشهای غیر مستقیم با صرفه‌جویی در زمان و هزینه و دقت برآوردی مناسب، پارامترهای دیریافت خاک را از پارامترهای زودیافت آن برآورد نمایند. شبکه عصبی مصنوعی یک تابع انتقالی است که از روی شبکه عصبی بیولوژیکی شبیه‌سازی شده به طوری که همانند شبکه عصبی موجودات زنده قادر است روابط منطقی موجود میان پارامترهای ورودی و خروجی را بیان نماید.

از مهمترین تحقیقات صورت گرفته به منظور ایجاد مدل‌های شبکه عصبی مصنوعی برای برآورد خصوصیات هیدرولیکی خاک و هدایت آبی اشباع می‌توان به مطالعات اسخاپ و بوتن (Schaap and Bouten, 1996)، پاچپسکی و همکاران (Pachepsky et al., 1996)، تاماری و همکاران (Tamari et al., 1996)، اسخاپ و همکاران (Schaap et al., 1998) و اسخاپ و همکاران (Schaap et al., 2001) اشاره کرد. نتایج این پژوهش‌ها نشان داده که چنانچه پارامترهای ورودی دارای خطای کمی باشند، مدل‌های شبکه عصبی مصنوعی نسبت به معادلات رگرسیونی چندگانه خطی و غیرخطی عملکردی مناسب‌تر دارند.

در این پژوهش تلاش بر این است تا مدل شبکه عصبی‌ای برای برآورد هدایت آبی اشباع ارائه شود. همچنین، تأثیر پارامترهای جدید همچون میانگین هندسی قطر ذرات و انحراف معیار هندسی آنها بر K_s مورد بررسی قرار گیرد.


شبکه عصبی مصنوعی با ساختار پرسپترون چند لایه

ANN^۱ مدلی ریاضی است که توانایی مدل‌سازی و ایجاد روابط ریاضی غیرخطی برای درونیابی را دارد. این مدل با ساختار پرسپترون^۲ چند لایه بطور کلی از سه لایه و هر لایه از تعدادی واحد پردازشگر بنام نرون^۳ (سلول، واحد و یا گره) تشکیل شده است (شکل ۱). اولین لایه هر شبکه را لایه ورودی گویند که در آن بردار داده‌های ورودی مورد نظر قرار می‌گیرد. در این لایه، هیچگونه پردازشی انجام نخواهد شد. لایه آخر هر شبکه لایه خروجی است که در آن بردارهای خروجی نگاشت استقرار می‌یابند. همچنین هر پرسپترون از تعدادی لایه میانی که لایه‌های پنهان نامیده می‌شوند، تشکیل شده است. تعداد این لایه‌ها و تعداد نرون‌ها در هر لایه، توسط طراح و طی فرآیند آزمون و خطا بدست می‌آیند. بطور معمول، نرون‌های هر لایه به کلیه نرون‌های لایه مجاور از طریق یک رابطه جهت‌دار مرتبط می‌باشند. اطلاعات بین نرون‌ها از طریق این اتصالات منتقل می‌شوند. هر یک از این اتصالات دارای مشخصه‌ای (وزن) مختص به خود هستند که در اطلاعات انتقال یافته از یک نرون به نرون دیگر ضرب می‌گردد.

1- Artificial Neural Network

2- Preceptron

3- Neuron




شکل ۱ - نمای کلی شبکه عصبی با ساختار پرسپترون چندلایه.

هر نرون، خروجی‌های وزن شده $(W_{ij} X_i)$ را از نرون‌های لایه قبلی دریافت و مجموع آنها، ورودی نرون (Net_j) را تولید می‌کند (شکل ۲).

$$Net_j = \sum w_{ij}x_i + b_i \tag{۱}$$

که در آن W_{ij} وزن اتصال بین گره‌های i و j ، X_i خروجی از گره i و b_i بایاس^۱ گره i نامیده می‌باشد.



شکل ۲ - جزئیات یک نرون با بردارهای ورودی و خروجی آن.

نرون‌ها برای محاسبه خروجی خود (y_i) ، ورودی دریافتی را از یک تابع فعال‌سازی^۲ (آستانه) عبور می‌دهند. توابع فعال‌سازی دارای انواع مختلفی نظیر توابع باینری^۳، سیگموئیدی^۴، تانژانت هیپربولیک^۵، خطی^۶ و گوسی^۷ می‌باشند. مرسوم‌ترین توابع در این زمینه، تابع سیگموئیدی است که بصورت زیر می‌باشد.

$$y_i = f(Net_j) = \frac{1}{1 + \exp^{-(Net_j)}} \tag{۲}$$

1-Bias

2- Activation function

3-Bainary function

4- Sigmoid function

5- Tangent hyperbolic

6- Linear function

7- Gauss function

منظور از آموزش در شبکه‌های عصبی مصنوعی، محاسبه وزن اتصالات مختلف آن است. برای آموزش یک شبکه، از تعدادی الگوی آموزشی که هر الگو شامل یک بردار ورودی و یک بردار خروجی متناظر با آن می‌باشد، استفاده می‌شود. تعداد نرون‌های لایه‌های ورودی و خروجی به ترتیب برابر با تعداد بردارهای ورودی و خروجی است. از آنجا که رابطه‌ای خاص برای محاسبه تعداد لایه‌های پنهان و نرون‌های مربوطه وجود ندارد، چاره‌ای جز آزمون ساختارهای مختلف نمی‌باشد. در آموزش شبکه، وزن‌های اتصالات شبکه به گونه‌ای محاسبه می‌شود که با اعمال هر بردار ورودی از الگوی آموزشی، شبکه بتواند خروجی متناظر با آن را با میزان خطایی مشخص که توسط طراح مشخص می‌گردد، تولید نماید. آنچه در آموزش شبکه مهم می‌باشد آن است که شبکه بتواند به ازای یک بردار ورودی که با آن آموزش ندیده است، خروجی مرتبط با آن را ارائه نماید. شبکه‌های عصبی عموماً از قدرت برون‌یابی خوبی برخوردار نیستند. به همین دلیل، در انتخاب الگوهای آموزشی باید این نکته مد نظر قرار گیرد. برای این منظور، پیش از آغاز کار با شبکه عصبی، الگوها را به دو دسته الگوی آموزشی (train) و الگوی آزمونی (test) تقسیم می‌نمایند. الگوهای آموزشی بایستی تا حد امکان کل فضای داده‌ها را پوشش دهند. بدیهی است که تعداد بیشتر الگوهای آموزشی قابلیت تعمیم شبکه را بالا می‌برد. هرچند آموزش، فرآیندی است که در طی زمانی طولانی انجام می‌پذیرد، ولیکن پس از تعمیم به سرعت می‌تواند به ازای هر ورودی، خروجی متناظر با آن را ارائه نماید.

بطور کلی آموزش شبکه‌های عصبی به دو طریق صورت می‌گیرد. آموزش تحت سرپرستی که در آن خروجی معینی به هر ورودی نسبت داده می‌شود و آموزش بدون سرپرستی که دارای خروجی از قبل مشخص نمی‌باشد. در این پژوهش از شبکه عصبی با ساختار پرسپترون چند لایه و آموزش با سرپرستی استفاده گردیده است. آموزش با سرپرستی به دلیل موجود بودن پارامتر خروجی (هدایت آبی اشباع)، انتخاب گردید.

آموزش شبکه‌های عصبی بر اساس ساختار پرسپترون چند لایه

مبنای آموزش شبکه‌های عصبی، تغییر وزن اتصالات شبکه جهت تولید خروجی مطلوب می‌باشد. شیوه عمل پرسپترون چند لایه بدین صورت است که نخست الگویی به شبکه عرضه شده و سپس خروجی آن محاسبه می‌گردد. با مقایسه خروجی شبکه با خروجی مطلوب، میزان خطا برای اصلاح وزن‌های شبکه (W_{ij}) از طریق رابطه زیر محاسبه می‌گردد و آن را به عقب از یک لایه به لایه قبل منتشر می‌سازد. عبارت پس‌انتشار^۱ به این علت انتخاب شده است.

$$E_p = \frac{1}{2} \sum_j (o_{pj} - y_{pj})^2 \quad (۳)$$

در رابطه^۳، E_p مقدار خطای الگوی p ، o_{pj} خروجی مطلوب و y_{pj} خروجی واقعی در j گره است.

از آنجا که انتخاب نوع روش آموزش بر سرعت یادگیری و دقت شبکه مؤثر می‌باشد، روش‌هایی مختلف برای آموزش شبکه‌های عصبی پیشنهاد گردیده که به سه روش اصلی اشاره می‌شود.

الف (الگوریتم پس‌انتشار خطای بیشترین شیب (sd): این روش از پر کاربردترین روشها در آموزش‌های تحت سرپرستی در شبکه‌های عصبی می‌باشد. مهمترین اشکال این روش سرعت کم همگرایی و به دام افتادن پارامترهای شبکه در نقاط حداقل محلی است که برای رفع این مشکل تلاش می‌شود با اضافه کردن جمله اندازه حرکت در رابطه محاسبه خطا، از وقوع آن جلوگیری کرد.

ب (الگوریتم پس‌انتشار گرادیان‌های مزدوج (gdm): این الگوریتم برای حل مسائل مربوط به بهینه‌سازی مورد استفاده قرار می‌گیرد. در این روش، بردار وزن‌ها در هر مرحله از آموزش در جهت عمود بر مرحله قبل بهنگام‌سازی می‌شوند و به این ترتیب در بسیاری از حالت‌ها باعث افزایش سرعت همگرایی می‌گردد.

ج (الگوریتم پس‌انتشار مارکوآرت - لورنبرگ (LM): اساس این روش حداقل کردن تابع خطا بر مبنای پارامترهای شبکه می‌باشد. از خصوصیات مهم این روش، سرعت همگرایی فوق العاده آن می‌باشد و تا به امروز جزء سریعترین الگوریتم‌های آموزشی شبکه‌های عصبی شناخته شده است.

روند آموزش شبکه‌های عصبی

روند آموزش شبکه‌های عصبی با روش‌های آموزش که در قبل آورده شد، متفاوت می‌باشد. بطور کلی، دو روند آموزش برای شبکه‌های عصبی وجود دارد:

۱ - آموزش الگو به الگو (Epochs): در این روش به ازای هر بار اعمال الگوی ورودی به شبکه، پارامترهای شبکه در مسیر رفت محاسبه می‌گردند. سپس با توجه به تابع خطا، میزان تغییرات پارامترهای شبکه مشخص گردیده و در مسیر برگشت، پارامترها تصحیح می‌گردند.

۲ - آموزش گروهی (Batch): در این روش به ازای هر بار اعمال الگوی ورودی به شبکه پارامترهای شبکه در مسیر رفت محاسبه و با توجه به تابع خطا، میزان تغییرات پارامترهای شبکه مشخص می‌گردند. ولیکن، مرحله تصحیح پارامترها انجام نمی‌گیرد، بلکه در ازای تمام تکرارها الگوهای ورودی، میزان تغییر پارامترها محاسبه و در پایان مرحله آموزش پارامترها اصلاح می‌شوند.

مواد و روش‌ها

تعداد ۴۵ نمونه خاک با استفاده از نقشه‌های بافت خاک منطقه کرج انتخاب گردید. نمونه‌ها در ۹ کلاس بافت خاک در دامنه محدودی از مقدار آهک (۱۱-۶ درصد) جهت یکسان نمودن اثر آن بر هدایت آبی اشباع در نظر گرفته شدند. اندازه‌گیری هدایت آبی اشباع نمونه‌ها در عمق ۳۰ سانتیمتری و بر روی سری بافت‌های،

2- Steepest Descent

2- Conjugate Gradient

3 - Marquardt Lovenberg

Silty Clay Clay, Sandy Loam, Loam, Loam Sandy, Sandy Clay Loam, Loamy Clay Sandy, و Silty Clay Loam صورت گرفت.

از آنجا که هدف این پژوهش برآورد هدایت آبی اشباع با استفاده از ویژگی‌های زودیافتی مانند جرم ویژه ظاهری، جرم ویژه حقیقی، توزیع فراوانی ذرات، رطوبت ظرفیت نگهداری، داده‌های منحنی دانه‌بندی و میانگین هندسی قطر ذرات و انحراف معیار آنها بود، روش‌های زیر برای اندازه‌گیری پارامترهای فوق به کار گرفته شد.

برای اندازه‌گیری صحرایی هدایت آبی اشباع از دستگاه نفوذسنج گلف مدل KI - 2800 استفاده شد. این دستگاه بر مبنای قانون ایجاد بار ثابت در چاهک ساخته شده است. این مدل دارای قابلیت‌های فراوانی نظیر حمل و نقل آسان، استفاده از یک کاربر، زمان اندازه‌گیری کم و نیاز به آب کم می‌باشد. برای اندازه‌گیری جرم ویژه ظاهری و حقیقی، به ترتیب از روشهای کلوخه و پیکنومتر استفاده گردید که دامنه مقادیر آنها $1/9-1/3$ و $2/71-2/31$ گرم بر سانتیمترمکعب بود. فراوانی نسبی ذرات خاک به روش هیدرومتری، رطوبت ظرفیت زراعی به وسیله دستگاه صفحات فشاری^۱ و قطر ذرات به روش دانه‌بندی الک خشک تعیین شد. میانگین هندسی قطر ذرات (d_g) و انحراف معیار هندسی آنها (δ_g) از روابط زیر محاسبه شد (Shiozawa and Campbell, 1991):

$$d_g (\text{mm}) = \exp(5.756 - 3.454(m_t) - 7.712(m_y)) \quad (4)$$

$$\delta_g (\text{mm}) = \exp\left\{\left[33.14 - 27.84(m_t) - 29.31(m_y) - (\ln(d_g))^2\right]^{1/2}\right\} \quad (5)$$

که در آن m_t و m_y به ترتیب درصد سیلت و رس می‌باشند.

آنالیز حساسیت به منظور تعیین اثر پارامترهای فوق بر روی هدایت آبی اشباع صورت گرفت. نتایج نشان داد که پارامترهای جرم ویژه ظاهری، تخلخل مؤثر ($\theta_e = \left(1 - \frac{\rho_b}{\rho_s} - \theta_{ic}\right)$)، میانگین هندسی قطر ذرات و انحراف معیار آنها بیشترین تأثیر را بر هدایت آبی اشباع دارند.

برای ایجاد مدل‌های شبکه عصبی مصنوعی از نرم‌افزار Neural Network استفاده شد. الگوریتم آموزشی پس‌انتشار مارکوات لورنبرگ برای آموزش شبکه عصبی، تابع آستانه سیگموئیدی برای محدود سازی دامنه داده‌های خروجی از هر نرون و روند آموزش الگو به الگو به عنوان جزئیات مراحل پیاده‌سازی آموزشی شبکه انتخاب و بکارگرفته شدند.

نتایج و بحث

اساس آموزش شبکه‌های عصبی، بر مبنای روش حدس و خطا می‌باشد تا بهترین آرایش لایه پنهان با تغییر تعداد لایه پنهان و نرون‌های آنها، نوع تابع متحرک، الگوریتم آموزشی و تعداد تکرار مرحله آموزش جهت برآورد پارامتر خروجی موردنظر ارائه شود. معیار مناسب بودن آرایش لایه پنهان را می‌توان با

1 - Pressure plate

اعمال رگرسیون خطی میان مقادیر اندازه‌گیری و برآورد شده و محاسبه ضریب تبیین بیان کرد. ضریب تبیین بالا ($R^2 \sim 1$) به معنای دست یافتن به آرایشی مناسب‌تر جهت برآورد پارامتر خروجی می‌باشد. در این پژوهش سه مدل شبکه عصبی با استفاده از پارامترهای مؤثر شناخته شده از آنالیز حساسیت مورد بررسی قرار گرفتند.

- مدل (۱): پارامترهای لایه ورودی این مدل را میانگین هندسی قطر ذرات، انحراف معیار هندسی قطر ذرات و تخلخل مؤثر تشکیل می‌داد.
- مدل (۲): پارامترهای لایه ورودی این مدل شامل جرم ویژه ظاهری، تخلخل مؤثر و میانگین انحراف معیار هندسی قطر ذرات خاک بود.
- مدل (۳): لایه ورودی این مدل را پارامترهای تخلخل مؤثر و میانگین هندسی انحراف معیار قطر ذرات خاک تشکیل می‌داد.

پارامتر خروجی همگی این مدلها، هدایت آبی اشباع بود. از میان ۴۵ نمونه خاک، ۳۵ نمونه (۸۰ درصد داده‌ها)، برای آموزش شبکه و ۱۰ نمونه (۲۰ درصد داده‌ها)، برای آزمون شبکه عصبی آموزش دیده بکارگرفته شد.

از میان آرایش‌های متفاوت آزمایش شده در ۳ مدل فوق، آرایش یک لایه پنهان همراه با ۷ نرون و ۳۵۰۰ تکرار برای مدل ۱ (جدول ۱)، آرایش دو لایه پنهان همراه با ۹ نرون در هر لایه و ۴۶۰۰ تکرار برای مدل ۲ (جدول ۲) و آرایش یک لایه پنهان با ۷ نرون و ۲۹۰۰ تکرار برای مدل ۳ (جدول ۳)، مناسب‌ترین آرایش‌ها با دقت برآوردی مناسب برای برآورد هدایت آبی اشباع شدند.

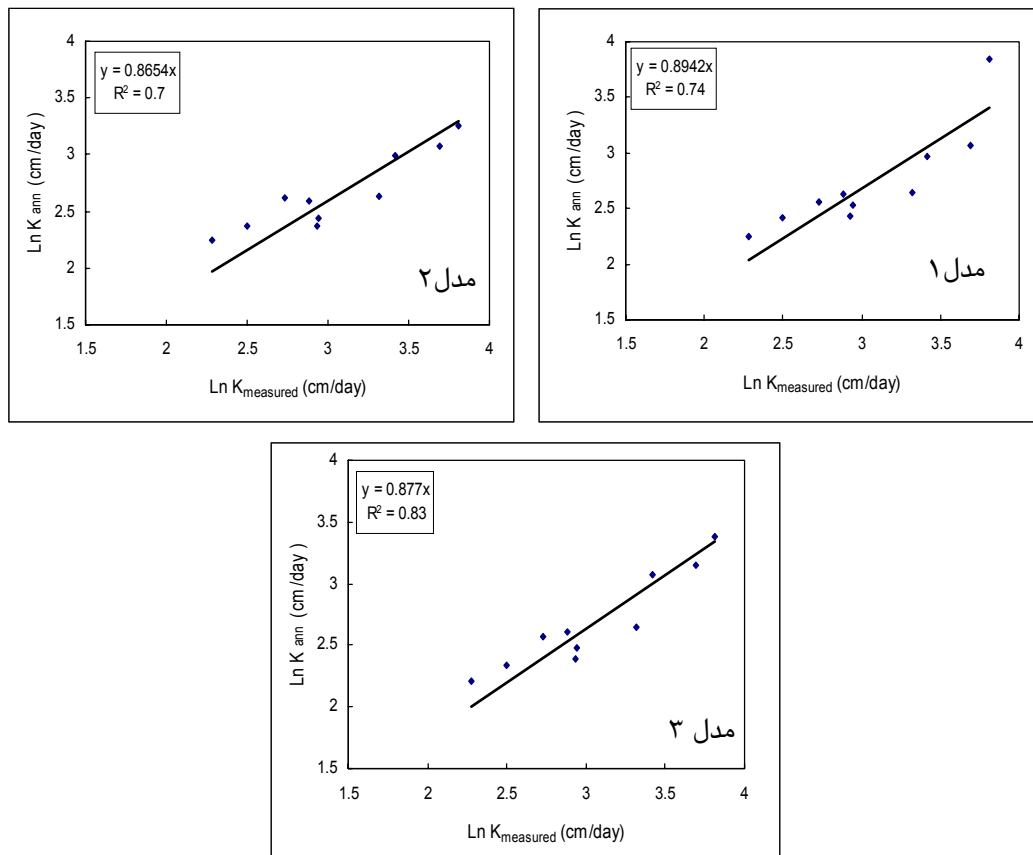
جدول ۱ - آرایش‌های متفاوت لایه پنهان در مدل ۱ جدول ۲ - آرایش‌های متفاوت لایه پنهان در مدل ۲

آرایش لایه پنهان				آرایش لایه پنهان			
			K_s				K_s
شماره	تعداد لایه	تعداد نرون	R^2	شماره	تعداد لایه	تعداد نرون	R^2
1	1	3	0.54	1	1	3	0.7
2	1	5	0.52	2	1	5	0.65
3	1	7	0.6	3	1	7	0.74
4	1	9	0.51	4	1	9	0.73
5	1	11	0.52	5	1	11	0.72
6	1	13	0.57	6	1	13	0.73
7	2	3	0.46	7	2	3	0.65
8	2	5	0.57	8	2	5	0.67
9	2	7	0.68	9	2	7	0.72
10	2	9	0.7	10	2	9	0.71
11	2	11	0.67	11	2	11	0.72
12	2	13	0.69	12	2	13	0.74

جدول ۳ - آرایش‌های متفاوت لایه پنهان در مدل ۳

شماره	آرایش لایه پنهان		K_s R^2
	تعداد لایه	تعداد نزون	
1	1	3	0.8
2	1	5	0.79
3	1	7	0.83
4	1	9	0.81
5	1	11	0.78
6	1	13	0.79
7	2	3	0.73
8	2	5	0.79
9	2	7	0.77
10	2	9	0.78
11	2	11	0.79
12	2	13	0.77

دقت برآورد مدل‌های ارائه شده با معیار ضریب تبیین 0.74 برای مدل ۱، ضریب تبیین 0.7 برای مدل ۲ و 0.83 برای مدل ۳ به دست آمد (شکل ۳). هر سه مدل ارائه شده به عنوان مثال نسبت به مدل‌های شبکه عصبی ارائه شده در برنامه نرم‌افزاری ROSETTA (Schaap et al., 2001) که بالاترین ضریب همبستگی مدل‌های ارائه شده در آن 0.7 برای مدل شامل پارامترهای ورودی درصد شن، سیلت و رس، جرم ویژه ظاهری و رطوبت در مکش 33 کیلو پاسکال می‌باشد، دارای دقت برآوردی مناسب‌تری بودند.



شکل ۳ - نمایش همبستگی داده‌های برآورد و اندازه‌گیری شده در مدل‌های ۱، ۲ و ۳.

روش رایج ایجاد توابع انتقالی، استفاده از رگرسیون خطی و غیرخطی چندگانه می‌باشد. در پژوهش دیگر (نوابیان و همکاران، ۱۳۸۲)، چند معادله رگرسیونی با استفاده از پارامترهای ورودی مشابه با مدل‌های شبکه عصبی فوق بدست آمد.

$$K_s(\text{estimated}) = 2.3 \exp(3.52 + 0.423 \log d_g - 2.19 \log \delta_g + 1.42 \log \theta_e) - 4.89 \quad R^2=0.73 (۶)$$

$$K_s(\text{estimated}) = 1.02 \exp(3.36 + 75.4/\delta_g^2 - 4.75 BD/\theta_e) - 0.21 \quad R^2=0.68 (۷)$$

$$K_s(\text{estimated}) = 2.85 \exp(4.45 - 2.25 \log \delta_g + 0.572 \ln \theta_e) - 10.76 \quad R^2=0.61 (۸)$$

مقایسه نتایج مدل‌های شبکه عصبی ارائه شده و معادلات رگرسیونی نشان می‌دهد که مدل‌های شبکه عصبی دارای عملکرد مناسب‌تری برای برآورد هدایت آبی اشباع می‌باشند. علت عملکرد مناسب‌تر شبکه عصبی را می‌توان به هوشمند بودن نحوه تجزیه و تحلیل داده‌ها نسبت داد. به طوری که طی روند آموزش، شبکه عصبی قادر خواهد بود روابط منطقی میان نگاشت‌های ورودی و خروجی را آموزش ببیند و از آن برای برآورد داده‌هایی که در آموزش شبکه بکارنرفته است، استفاده نماید. در حالی که تجزیه و تحلیل رگرسیونی تنها برقراری یک سری مفاهیم ریاضی و آماری میان داده‌ها می‌باشد.

نتیجه گیری

اگرچه استفاده از شبکه‌های عصبی مصنوعی دشوارتر از معادلات رگرسیونی است، لیکن می‌توان با ایجاد برنامه‌های نرم‌افزاری به اصطلاح ساده، مشکل استفاده کاربر را حل نمود. از فرضیات اولیه معادلات رگرسیونی، نرمال بودن و غیرهم‌راستایی داده‌های مورد استفاده در آن است. در حالی که برتری شبکه‌های عصبی مصنوعی در عدم نیاز آنها به داده‌های نرمال شده و غیرهم‌راستا می‌باشد. پیشنهاد می‌شود که در تحقیقات بعدی از مقدار داده‌های بیشتری در کلاس‌های بافتی تقریباً نزدیک به هم استفاده کرده و برای هر گروه یا کلاس خاک، مدل‌هایی خاص ارائه شود. از آنجا که پارامترهایی نظیر ماده آلی، مقدار آهک و نیز دیگر پارامترهایی که بیان‌کننده ساختمان هر خاک باشند تأثیر فراوانی بر هدایت آبی اشباع دارند، لذا بررسی‌های بیشتر در این زمینه می‌تواند مفید واقع گردد.

فهرست منابع

- ۱ - البرزی، م. ۱۳۸۰. آشنایی با شبکه‌های عصبی. انتشارات دانشگاه صنعتی شریف. ۱۳۷ صفحه.
- ۲ - منهاج، م. ب. ۱۳۷۷. کاربرد هوش محاسباتی در کنترل. انتشارات دانشگاه صنعتی امیرکبیر، جلد دوم. ۲۳۶ صفحه.
- ۳ - منهاج، م. ب. ۱۳۸۱. مبانی شبکه‌های عصبی هوش محاسباتی. انتشارات دانشگاه صنعتی امیرکبیر، جلد اول. ۵۰۲ صفحه.
- ۴ - نوابیان، م. ع. ا. لیاقت و م. همایی. ۱۳۸۲. تخمین هدایت هیدرولیکی اشباع با استفاده از توابع انتقالی. (در حال بررسی).
- 4- Pachepsky, Ya. A., D. Timlin and G. Varallyay. 1996. Artificial Neural Networks to estimate soil water retention from easily measurable data Soil Sci. Soc. Am. J. 60:727-733.
- 5- Schaap, M. G. and W. Bouten. 1996. Modeling water retention curves of sandy soil using neural networks. Water Resour. Res. 32:3033-3040.
- 6- Schaap, M. G., F.J. Leij and M. Th. Van Genuchten. 1998a. Neural network analysis for hierarchical prediction of soil water retention and saturated hydraulic Conductivity. Soil Sci. Soc. Am. J. 62-847-855.
- 7- Schaap Marcel G. Feike J. Leij and Martinus Th. Van Genuchten. 2001. ROSETTA: a computer program for estimating soil hydraulic parameters with hierarchial pedotransfer functions. Journal of Hydrology. 251.pp 163-176.
- 8- Shiozawa. S, G. S. Campbell . 1991 . On the calculation of mean particle diameter and standard deviation from sand , silt and clay fractions. Soil Sci. Vol 152 , No.6.PP 427-431.
- 9- Tamari, S., J. H. M. Wosten and J. C. Ruzi-Suarez. 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. Soil Sci. Soc. Am. J. 60:1732-1741.

Neural network for fast estimation of saturated hydraulic conductivity

M. Navabian, A. Liaghat, M. Homaei

ABSTRACT

The saturated hydraulic conductivity is the most important soil physical property that is needed for design subsurface-drainage projects and their feasibilities in term of technical and economical issues. The direct measurements of this property in the field or in the lab is time consuming and costly. In addition due to high temporal and spatial variability of saturated hydraulic conductivity, the point measurements can not be reliable representative of this property unless; a huge number of soil samples or measurements are made. In recent year, attention has been made on neural network application for estimating soil physics property using easily soil parameters. Neural network similar to human Neuron reticulation, that can estimate output parameters from input parameters after training. In this study, Perceptron structure with training algorithm, Marquardt - Levenberg was used to estimate saturated hydraulic conductivity from easily parameter such as bulk density, frequency particle distribution, effective porosity, geometric mean diameter of soil particle and their standard deviation. The Results indicated that the models of neural network can estimate saturated hydraulic conductivity with good correlation coefficient ($R^2=0.83$). Also compare to regression functions, these models have better accuracy.

Key words: Easily soil parameter, Neural network, Saturated hydraulic conductivity

