



تخمین هدایت هیدرولیکی اشباع خاک به کمک روشهای شبکه عصبی مصنوعی، ادغام شبکه عصبی مصنوعی - الگوریتم ژنتیک و رگرسیون

سید مصطفی عمادی و حدیثه نادری

۱- استادیار گروه علوم خاک دانشکده علوم زراعی دانشگاه علوم کشاورزی و منابع طبیعی ساری، ۲- دانشجوی کارشناسی دانشکده علوم زراعی دانشگاه علوم کشاورزی و منابع طبیعی ساری

چکیده

هدایت هیدرولیکی اشباع خاک از مهم‌ترین ویژگی‌های فیزیکی خاک است. با توجه به پژوهش‌های پرشمار که پیرامون اندازه گیری مستقیم هدایت هیدرولیکی اشباع صورت گرفته است، برآورد هدایت هیدرولیکی اشباع با استفاده از روش‌هایی سریع، کم هزینه و با وقتی قابل قبول ضروری است. در این خصوص در این مطالعه، از شبکه عصبی مصنوعی، ادغام شبکه عصبی مصنوعی و الگوریتم ژنتیک و همچنین رگرسیون به منظور تخمین هدایت هیدرولیکی اشباع خاک با استفاده از پایگاه داده UNSUDA، استفاده شده است که از ۱۴۶ داده اندازه گیری شده به عنوان داده های آموزش و ۶۱ داده دیگر به عنوان داده های تست استفاده شد. پس از تخمین هدایت هیدرولیکی اشباع با استفاده از روش‌های شبکه عصبی مصنوعی و رگرسیون، مشاهده شد که روش شبکه عصبی برآورد مناسب‌تری نسبت به رگرسیون و ادغام آن با الگوریتم ژنتیک داشته است. همچنین مقادیر ME ، $RMSE$ ، CCC و R به ترتیب $۵۶۸/۰$ ، $۱۱۶/۰$ ، $۰/۰$ و $۶۴۳/۰$ برای روش شبکه عصبی مصنوعی تابع شعاعی بدست آمد. واژه های کلیدی: هدایت هیدرولیکی اشباع، شبکه عصبی، رگرسیون، الگوریتم ژنتیک.

مقدمه

هدایت هیدرولیکی اشباع خاک (K_s)، از مهم‌ترین ویژگی‌های فیزیکی خاک است. با توجه به مشکلات موجود در اندازه گیری مستقیم هدایت هیدرولیکی اشباع، روش‌های غیرمستقیم در سال‌های اخیر مورد توجه قرار گرفته‌اند. از جمله مدل‌های برآورد کننده هدایت هیدرولیکی اشباع خاک شامل مدل‌های رگرسیونی و شبکه های عصبی مصنوعی می‌باشند (Johnston and ME, ۱۹۹۶). در سال‌های اخیر از شبکه عصبی مصنوعی به منظور شبیه سازی، تشخیص الگو، کلاس بندی و بهینه سازی در علوم مختلف مهندسی به طور گسترده استفاده شده است (Menhaj, ۲۰۰۰). قابلیت‌های مدل شبکه عصبی این مدل را به ابزاری مناسب برای مدلسازی خصوصیات هیدرولیکی خاک تبدیل کرده است (Minasny & McBratney, ۲۰۰۲). مدل‌های آماری یا معادلات رگرسیونی تابعی از فرضیات و ملاحظات ذاتی آزمایش‌ها در تحلیل است. در روش‌های آماری واقعیت پدیده به کمک یک معادله‌ی جبری بیان می‌شود که فرضیات اصلی مساله در آن لحاظ شده است. از آنجا که برای پیش بینی پارامترهای هیدرولیکی در خاک چندین متغیر ورودی و خروجی موثرند، تحلیل آماری این نوع مسائل مستلزم ارائه تعدادی روابط ریاضی است، که اغلب برای استفاده و تفسیر دشوار است. اما امروزه، با توسعه سریع فناوری‌های پردازش رایانه ای و ایجاد نرم افزارهای مربوطه، از مزایای فناوری هوش مصنوعی مانند شبکه های عصبی برای مسائل مربوط به مدلسازی سیستم‌ها و فرآیندها استفاده می‌شود (تقی زاده و همکاران، ۱۳۸۷). شبکه عصبی شبیه سازی از دستگاه عصبی انسان است و مهم‌ترین بخش یک شبکه عصبی نرون است. هر شبکه عصبی مصنوعی از لایه های ورودی، پنهان و خروجی تشکیل شده است. یک شبکه عصبی مجموعه ای از نرون‌هایی است که در آن هر نرون با نرون‌های لایه بعدی مرتبط است. مهم‌ترین موضوع در مدل‌های شبکه عصبی، انتخاب ورودی‌های مناسب برای رسیدن به خروجی‌های مدنظر می‌باشد. با توجه به عدم استفاده از ادغام شبکه عصبی مصنوعی با الگوریتم ژنتیک در مطالعات گذشته و مقایسه آن‌ها با روش‌های شبکه عصبی و مدل‌های رگرسیونی، هدف از این مطالعه ارزیابی روش‌های شبکه عصبی مصنوعی (ANN)، ادغام شبکه عصبی مصنوعی و الگوریتم ژنتیک (ANN-GA) و روش رگرسیونی با استفاده از داده های UNSODA می‌باشد.

مواد و روش‌ها

در این تحقیق از پارامترهای درصد شن، سیلت، رس و ماده آلی با استفاده از پایگاه داده هیدرولیکی غیر اشباع خاک (UNSODA; Leij et al., ۱۹۹۶) استفاده شد. از ۱۴۶ داده به عنوان داده آموزش و ۶۱ داده به عنوان داده تست در این تحقیق بکار گرفته شد. ابتدا داده های مورد نیاز به نرم افزار SPSS انتقال داده شد. سپس با استفاده از این نرم افزار، همبستگی داده های تست و آزمون بدست آمد. در ادامه مقادیر خطای میانگین (ME^*)، میانگین مجذور خطا ($RMSE^y$)، ضریب همبستگی انطباق (CCC^A) را با

*۱-Mean error

۲- Root mean square error

۳-Lin's concordance correlation coefficient



چهاردهمین کنگره علوم خاک ایران - فیزیک خاک و رابطه آب، خاک و گیاه

توجه به فرمول های زیر برای مدل های رگرسیونی، ادغام شبکه عصبی مصنوعی و الگوریتم ژنتیک و شبکه عصبی مصنوعی دستاورد شده:

$$\frac{1}{n} \sum_{i=1}^n (O_i - y^{\wedge}_i = ME) \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - y^{\wedge}_i)^2} \quad (2)$$

$$\frac{2\rho\sigma_x\sigma_y}{\sigma_x^2 + \sigma_y^2 + (\mu_x - \mu_y)^2} = CCC \quad (3)$$

ME تخمین بایاس از پیش بینی ها را ارائه می دهد، در حالی که RMSE مربوط به دقت پیش بینی هاست. یک مدل خوب می بایست برای ME و RMSE مقداری نزدیک به صفر داشته باشد. CCC نشان می دهد که مقدار اندازه گیری شده و تجزیه ای در زاویه ۴۵ درجه در یک مدار مختصلاً، چه مقدار باهم، هم خوانی دارد.

نتایج و بحث

جدول ۱ همبستگی داده های آموزش را نشان می دهد. مقدار Ks از توزیع لگاریتمی پیروی کرده است، بنابراین تخمین و آنالیز با لگاریتمگیری در پایه نپر از آن انجام شد.

جدول ۱: خلاصه آماری و جدول همبستگی داده های آموزش (n=۱۴۶)

آماره ها	لگاریتم Ks	ماده آلی	چگالی ظاهری	شن	سیلت	رس
حداقل	-۰/۹۲	۰/۰۸	۰/۷۱	۱/۸	۱/۰۱	۱/۰۱
حداکثر	۹/۱	۱۰/۳	۱/۸	۹۶	۹۰	۶۳
میان	۴۷/۳۹	۱۰۶/۲۱	۱۵/۸۴	۶۶/۹۹	۶۰/۵۸	۸۱/۰۶
میانگین	۴/۳۶	۱/۹۲	۴۴/۶۸	۴۴/۶۸	۳۶/۴۷	۱۸/۸۳
انحراف معیار	۲/۰۶	۲/۰۴	۲۹/۹۳	۲۹/۹۳	۲۲/۰۹	۱۵/۲۶
چولگی	-۰/۳۰	۱/۶۲	۰/۲۴	۰/۲۴	۰/۱۸	۱/۲۲

همبستگی						
رس	۱					
سیلت	۰/***۲۵۶	۱				
شن	**۰/۷۰۰-	**۰/۸۷۰-	۱			
چگالی ظاهری	**۰/۳۸۸-	۰/۱۴۰-	۰/***۳۰۱	۱		
ماده آلی	۰/***۴۱۲	۱۵۸/۰	**۰/۳۲۶-	**۰/۶۲۷-	۱	
لگاریتم Ks	**۰/۲۵۰-	**۰/۳۵۱-	۰/***۳۸۸	۰/۱۴۵-	۰/۱۹۷	۱

دو معادله رگرسیونی زیر برای داده های آموزش بدست آمد که در سطح ۵٪ معنی دار می باشد:

$$K1 = 3/161 - 0/27 \text{ Sand} \quad (1)$$

$$K2 = 20/91 - 0/035 \text{ Sand} - 0/0367 \text{ OM} \quad (2)$$

داده های ورودی های شبکه شامل درصد رس، شن، سیلت و کربن آلی بودند. مقادیر نرون لایه های پنهان که به این شبکه داده شد در دامنه ۴-۱۵ مورد بررسی قرار گرفت، که بهترین مقدار برای هر کدام از بین بقیه مقادیر بدست آمده، انتخاب شد. با توجه به مقادیر بدست آمده ملاحظه شد که با افزایش تعداد لایه های مخفی، عملکرد مدل ها ضعیف شدند. پس از بدست آمدن مقادیر Ks تخمینی برای روش شبکه عصبی از نوع پرسپترون چند لایه (MLP)، ادغام پرسپترون چند لایه و الگوریتم ژنتیک (MLPg^۱)

^۱۱- Multilayer Perceptron

^۱۲- Multilayer Perceptron integration and Genetic Algorithm



چهاردهمین کنگره علوم خاک ایران - فیزیک خاک و رابطه آب، خاک و گیاه

a)، روش شبکه عصبی از نوع تابع عملکرد شعاعی (RBF) و ادغام عملکرد شعاعی و الگوریتم ژنتیک (RBFga)، مقدار خطای میانگین، میانگین مجذور خطا و ضریب همبستگی انطباق برای هر کدام از آن‌ها در EXCEL بدست آورده شد که نتایج آن در جدول ۲ آمده است.

جدول ۲: خلاصه آماری و جدول همبستگی داده های تست (n=61)

اماره ها	لگاریتم Ks	ماده الی	چگالی ظاهری	شن	سیلت	رس
حداقل	۲/۷۳	۰/۰۱	۰/۵۹	۲/۳	۱/۰۱	۱/۸
حداکثر	۶/۷۶	۸/۳	۱/۷۲	۹۵/۸	۸۷/۲	۵۳/۲
میان	۴۸/۷۸	۱۱۷/۰۵	۱۴/۹۴	۶۳/۴۳	۶۶/۱۵	۷۳/۸۸
میانگین	۳/۸۱	۱/۲۶	۱/۴۶	۴۷/۳۷	۳۵/۶۷	۱۶/۹۱
انحراف معیار	۱/۸۶	۱/۴۸	۰/۲۲	۳۰/۰۴	۲۳/۶۷	۱۲/۴۹
چولگی	۰/۸۱-	۲/۴۲	۱/۹۱-	۰/۱۳	۰/۴۲	۱/۲۸

همبستگی						
رس	۱					
سیلت	۳۳۰/۰**	۱				
شن	**۰/۶۷۳-	**۰/۹۲۰-	۱			
چگالی ظاهری	**۰/۴۲۲-	۰/۱۸۹-	۳۲۳/۰**	۱		
ماده الی	*۰/۲۷۷	۰/۱۶	۰/۱۲۷-	**۰/۷۵۱-	۱	
لگاریتم Ks	۰/۲۳۳-	۰/۱۰۹-	۰/۱۸۰	*۰/۲۸۹-	۰۸۱/۰	۱

جدول ۳ نشان می‌دهد که شبکه عصبی مصنوعی کارایی بهتری نسبت به رگرسیون داشته است، زیرا برآورد بهتری از داده‌ها را نشان می‌دهد.

پاچیسکی و همکارانش (۱۹۹۷) با استفاده از آماره های ضریب همبستگی و ریشه میانگین مربعات خطا به بررسی شبکه عصبی مصنوعی و آنالیز رگرسیون پرداختند. آن‌ها نتیجه گرفتند که شبکه عصبی برآورد بهتر و با خطای کمتری بر اساس داده های زود یافت خاک دارد. نتایج مشابهی توسط تاماری و همکارانش (۱۹۹۷) بدست آمد، آن‌ها نیز مقدار RMSE کمتری از برآورد خصوصیات خاک با شبکه عصبی مصنوعی نسبت به رگرسیون خطی چندگانه بدست آوردند. در این تحقیق با استفاده از مدل های شبکه عصبی مصنوعی، ادغام شبکه عصبی مصنوعی و الگوریتم ژنتیک و رگرسیونی مقادیر ME و RMSE و CCC برآورد گردید. این بررسی نشان داد که در مورد مطالعه شده ANN-RBF نسبت به سایر روش‌ها کارایی بهتری داشته است.

جدول ۳ مقایسه مقادیر بدست آمده از طریق رگرسیون و شبکه عصبی

داده های تست				داده های آزمون				
ME	RMSE	ccc	R	ME	RMSE	ccc	R	مدلهای
۱۳/۲۶	۱۶۰/۲۱	۰/۰۵۳-	۰/۴۱۱	۱۳/۴۴	۱۰۶/۶۸	۰/۲۵	۰/۱۸۵	رگرسیون ۱
۳/۹۰	۴۷/۱۳	-۰/۰۸۵	۰/۳۸۸	۳/۴۳	۲۷/۱۹۸	۰/۱۲	۰/۱۸۰	رگرسیون ۲

۱۱۳- Radial function

۱۱۴- Integration of functions radial and Genetic Algorithm



چهاردهمین کنگره علوم خاک ایران - فیزیک خاک و رابطه آب، خاک و گیاه

۰/۰۱۰-	۰/۱۱۶	۰/۵۶۸	۰/۶۴۳	۰/۲۹۱-	۲/۲۷۳	۰/۲۰۹	۰/۴۹۹	RBF-ANN
۰/۰۰۸-	۰/۰۹۸	۰/۵۶۴	۰/۶۳۸	۰/۳۱۱-	۲/۴۲۷	۰/۲۲۷	۰/۲۴۱	RBF-GA
۰/۰۰۱-	۰/۰۱۷	۰/۶۲۲	۰/۸۸۴	۰/۳۸۰-	۲/۹۷۰	۰/۳۰	۰/۳۴۱	MLP-ANN
۰/۰۰۶-	۰/۰۷۵	۰/۵۸۶	۰/۶۶۷	۰/۴۴۰-	۳/۴۳۵	۰/۲۷۹	۰/۳۲۹	MLP-GA

منابع

تقی زاده مهرجردی، ر.، محمودی، ش.، حیدری، الف. و اکبرزاده، ع. ۱۳۸۷. پیش بینی ظرفیت تبادل کاتیونی خاک با استفاده از شبکه عصبی مصنوعی و رگرسیون چند متغیره در منطقه خضراباد یزد. مجله پژوهش در علوم کشاورزی، ص ۱۱-۱.

نصرتی، ف.، روشنی، ق. و دهقانی، الف. ۱۳۹۱. استفاده از شبکه های عصبی مصنوعی برای برآورد هدایت هیدرولیکی اشباع از ویژگی های زودیافت خاک. مجله مدیریت خاک و تولید پایدار.

قنبریان، ب.، لیاقت، ع. و سهرابی، س. ۱۳۸۷. کاربرد شبکه عصبی مصنوعی در پیش بینی هدایت هیدرولیکی اشباع با استفاده از پارامترهای فیزیکی خاک. مجله تحقیقات مهندسی کشاورزی، ص ۹۷-۱۱۲.

بیات، ح.، جره، م.، سنجانی، ع. و دوانگر، ن. ۱۳۹۱. برآورد گنجایش تبادل کاتیونی خاک با بهره گیری از پارامترهای فراکتالی توزیع اندازه ذرات به کمک مدل های رگرسیونی و شبکه عصبی مصنوعی. مجله مدیریت خاک، سال دوم، شماره دوم، ص ۳۱-۴۰.

نجفی، م. و گیوی، ج. ۱۳۸۴. ارزیابی پیش بینی وزن مخصوص ظاهری با استفاده از طول شبکه های مدل شبکه های عصبی مصنوعی و توابع انتقالی خاک. نهمین کنگره علوم خاک، ص ۶۸۱-۶۸۰.

منهاج، م. ۱۳۷۸. مبانی شبکه های عصبی و هوش مصنوعی (جلد ۱ و ۲). دانشگاه صنعتی امیرکبیر (پلی تکنیک تهران).