

مدل‌سازی پارامترهای موثر بر دقت سامانه‌های اندازه‌گیری هدایت الکتریکی خاک به روش شبکه عصبی RBF در شرایط آزمایشگاهی

جلال برداران مطیع^۱ - محمد حسین آق‌خانی^{۲*} - عباس روحانی^۳ - امیر لکزیان^۴

تاریخ دریافت: ۱۳۹۶/۰۵/۰۹

تاریخ پذیرش: ۱۳۹۶/۰۶/۲۷

چکیده

از جمله سامانه‌هایی که در تهیه نقشه هدایت الکتریکی خاک مزارع به کار می‌روند، سامانه‌های مبتنی بر روش تماس مستقیم الکتروود با خاک می‌باشند. در این تحقیق با علم به اینکه علاوه بر شوری پارامترهای فیزیکی و شیمیایی خاک نیز در هدایت‌پذیری الکتریکی خاک تاثیرگذارند، به کمک روش شبکه عصبی RBF در طرح آماری باکس-بنکن به بررسی تاثیر پارامترهای اثرگذار بر نتایج روش تماس مستقیم در اندازه‌گیری هدایت الکتریکی ظاهری خاک پرداخته و مدلی جهت تخمین هدایت الکتریکی واقعی خاک با داشتن هدایت الکتریکی ظاهری، دما، درصد رطوبت و چگالی توده تعیین شد. اندازه‌گیری همزمان پارامترهای موثر می‌تواند مرحله کالیبراسیون را حذف کند. مدل شبکه عصبی به دست آمده توانست به خوبی با ضریب تبیین EC_e ۰۰/۹۹ را تخمین بزند. ضمن بررسی الگوریتم‌های مختلف آموزش شبکه عصبی عملکرد الگوریتم آموزشی بی‌زین بهتر از سایر الگوریتم‌ها تشخیص داده شد. نتایج تحلیل حساسیت شبکه نشان داد به ترتیب متغیرهای EC_a ، رطوبت، دما و چگالی توده بیشترین تاثیر را در تخمین مقدار EC_e خاک دارند، به طوری که با حذف آنها از مدل ضریب تبیین از ۰/۹۹ به ترتیب به ۰/۳۰، ۰/۳۵، ۰/۵۶ و ۰/۶۳ کاهش می‌یابد. پس از مرحله مدل‌سازی، مدل شبکه عصبی به دست آمده با یک گروه داده مزرعه‌ای مورد اعتبارسنجی قرار گرفت. نتایج اعتبارسنجی مدل ضریب تبیین ۰/۹۸۶ بین خروجی مدل و مقادیر EC_e اندازه‌گیری شده در آزمایشگاه را نشان داد. بدین ترتیب با استفاده از این مدل ضمن اندازه‌گیری همزمان پارامترهای ذکر شده همراه با هدایت الکتریکی می‌توان دقت سامانه‌های اندازه‌گیری هدایت الکتریکی ظاهری خاک در تخمین و تهیه نقشه‌های شوری خاک افزایش داد. همچنین با توجه به عدم نیاز به داده‌برداری مجدد جهت کالیبراسیون سامانه‌ها، استفاده از این مدل زمان تحلیل داده‌ها و هزینه تهیه نقشه هدایت الکتریکی خاک را کاهش می‌دهد.

واژه‌های کلیدی: شبکه عصبی RBF، شوری خاک، هدایت الکتریکی ظاهری، هدایت الکتریکی واقعی

مقدمه

تولید محصولات کشاورزی و طبیعت پویا و وابسته به زمان و مکان آن، اندازه‌گیری سریع و پایش گسترش زمانی و مکانی شوری خاک، بخش مشکل تهیه اطلاعات برای کشاورزی دقیق است. از جمله مواردی که می‌تواند برآوردی از میزان شوری خاک فراهم آورد، اندازه‌گیری هدایت الکتریکی^۵ خاک می‌باشد. شوری در نتیجه وجود مواد غیرآلی حل شده در فاز آبی خاک شامل نمک‌های محلول و آماده حل، (یون‌های باردار Na^+ ، K^+ ، Mg^{+2} ، Ca^{+2} ، Cl^- ، HCO_3^- ، NO_3^- ، SO_4^{-2})، مواد غیر یونی و یون‌هایی که با هم ترکیب شده و جفت یون به وجود آورده‌اند، ایجاد می‌شوند. موادی که باعث ایجاد شوری در خاک می‌شوند هادی الکتریسیته بوده و می‌توان آنها را با عبور جریان الکتریکی شناسایی کرد (Rhoades et al., 1999).

برداشت بیش از حد ظرفیت از منابع آب زیرزمینی در مناطق خشک و نیمه‌خشک طی سال‌های اخیر موجب افزایش میزان نمک‌های محلول و شوری برخی مزارع شده است. از طرفی به جهت حفظ کیفیت و حاصلخیزی خاک‌های کشاورزی لازم است برنامه‌هایی به جهت مدیریت شوری خاک مزارع در دستور کار قرار گیرد (Nazari et al., 2017). یکی از اهداف مدیریت شوری، تعیین مقدار و گستردگی مکانی شوری در خاک می‌باشد. به دلیل تاثیر شوری بر

۱، ۲ و ۳- به ترتیب دانشجوی دکتری، استاد و استادیار، گروه مهندسی بیوسیستم، دانشگاه فردوسی مشهد

۴- استاد، گروه مهندسی علوم خاک، دانشگاه فردوسی مشهد

(Email: Aghkhani@um.ac.ir

*) نویسنده مسئول:

DOI: 10.22067/jam.v9i1.66489

سیفی و همکاران (Seifi et al., 2010) توسعه دادند، نمی‌تواند الزاماً بیانگر تغییرات شوری خاک باشد. زیرا علاوه بر شوری سایر پارامترها نظیر رطوبت و دما و غیره نیز بر نتایج هدایت الکتریکی ظاهری موثرند. از دیدگاه دیگر هدف از این تحقیق تعیین دقیق‌تر میزان هدایت الکتریکی واقعی خاک با استفاده از اندازه‌گیری هدایت الکتریکی ظاهری می‌باشد. هرچند که از هدایت الکتریکی ظاهری خصوصیات دیگری نیز می‌توان به‌دست آورد.

تاکنون محققان زیادی از جمله Sudduth و همکاران (۲۰۰۰)، اقدام به توسعه سامانه‌های اندازه‌گیری هدایت الکتریکی خاک مزارع بر پایه روش تماس مستقیم کرده‌اند و برخی از این سامانه‌ها مانند دستگاه VerisTech3100 و LandMapper به‌صورت تجاری عرضه می‌شوند اما در این دستگاه‌های پارامترهایی مانند رطوبت و دما هم‌زمان با هدایت الکتریکی اندازه‌گیری نمی‌شود (Seifi et al., 2010; Baradaran et al., 2010; Pan et al., 2014; Olteanu et al., 2008). سامانه توسعه‌یافته توسط برادران مطیع و همکاران (۲۰۱۰) توانست نقشه هدایت الکتریکی ظاهری کالیبره شده را با ضریب همبستگی $0/61$ با EC_e ‌های اندازه‌گیری شده در آزمایشگاه به‌دست آورد. در این تحقیق به علت عدم اعمال تاثیر عواملی نظیر، درصد رس، دما، رطوبت و فشردگی، همبستگی نتایج هدایت الکتریکی ظاهری با هدایت الکتریکی واقعی (عصاره اشباع) مناسب نبود. Lund و همکاران (۱۹۹۹) در تحقیقی با عنوان استفاده از نقشه‌های هدایت الکتریکی خاک و عملکرد محصول در استنتاج میزان تولید، همبستگی بین عملکرد محصول و مقدار هدایت الکتریکی را در مزرعه سویا به‌دست آوردند. نتایج آنها نشان داد که مقدار هدایت الکتریکی در خاک‌هایی که شور نیستند وابسته به بافت خاک و میزان رطوبت آن است. در تحقیق‌های مشابهی در مورد نوع جریان الکتریکی عبور داده شده از الکترودها، فرکانس ۵۰ هرتز و ۴۰۰ هرتز در حالت ایستا و فرکانس صفر هرتز (جریان مستقیم) در حالت متحرک به دلیل داشتن بیشترین همبستگی با هدایت الکتریکی آزمایشگاهی، پیشنهاد شده است (Olteanu et al., 2008). Ehsani و Sullivan (۲۰۰۲) در پژوهشی به معرفی روش‌های اندازه‌گیری هدایت الکتریکی خاک پرداختند و در آن پارامترهای مؤثر در هدایت الکتریکی را معرفی نموده‌اند. این پارامترها عبارتند از: تخلخل، محتوی رطوبتی، دما، شوری و ظرفیت تبادل کاتیون‌ها. Sudduth و همکاران (۲۰۰۳) در مقایسه‌ای که بین روش مغناطیسی و روش تماس مستقیم بیان داشتند که هدایت الکتریکی ظاهری اندازه‌گیری شده در کمتر از ۱۰ درصد موارد با هدایت الکتریکی عصاره اشباع، رطوبت و مقدار شدن خاک همبستگی مستقیم داشته است. که این مطلب بیانگر اثرات متقابل این پارامترها بر روی هدایت الکتریکی ظاهری می‌باشد. Lilienthal و همکاران (۲۰۰۵) مقایسه‌ای بین انواع تکنیک‌های الکتریکی تعیین خواص خاک انجام دادند. آنها بیان

عملاً هدایت الکتریکی خاک را از عصاره محلول آبی خاک^۱ به‌دست می‌آورند. به دلیل زمان‌بر بودن تهیه عصاره خاک و هزینه عملیات آزمایشگاهی در مقیاس وسیع، تلاش‌ها به سمت تعیین هدایت الکتریکی (EC) از توده خاک متمایل شده است که آن را هدایت الکتریکی ظاهری^۲ یا هدایت الکتریکی توده^۳ (EC_a) می‌نامند. هدایت الکتریکی ظاهری در روش تماس مستقیم با عبور جریان الکتریکی از درون توده خاک اندازه‌گیری می‌گردد. جریان الکتریکی عبوری از خاک از سه مسیر ذرات جامد، آب درون منافذ و فضاهای خالی امکان عبور دارد. آب درون منافذ خاک به‌صورت محلولی از یون‌ها و نمک‌های درون توده خاک است. به‌طور کلی EC_a در خاک‌هایی که به اندازه کافی رطوبت دارند متأثر از نمک‌های محلول موجود در آب درون حفره‌ها و منافذ می‌باشد، در نتیجه اندازه‌گیری هدایت الکتریکی ظاهری خاک رابطه نزدیکی با شوری خاک دارد (Rhoades et al., 1999) اما همچنان هدایت الکتریکی عصاره اشباع (EC_e) معیار استاندارد مورد استفاده در مطالعات شوری خاک است. جهت تبدیل هدایت الکتریکی ظاهری به هدایت الکتریکی عصاره اشباع لازم است تا رابطه بین EC_e و EC_a مشخص شود. بدین منظور تحقیقات گسترده‌ای جهت توسعه مدل‌های قابل اطمینان و مؤثر برای تبدیل EC_a به EC_e انجام شده است (Sudduth et al., 1999; Rhoades et al., 2013). هدایت الکتریکی ظاهری تابعی از خصوصیات فیزیکی و شیمیایی خاک نظیر شوری، درصد اشباع، محتوی رطوبتی، چگالی توده، دما و درصد رس موجود در نمونه خاک است (Corwin and Lesch, 2003; Baradaran Motie et al., 2010).

امروزه با به‌کارگیری حسگرهای در حرکت^۴ اندازه‌گیری هدایت الکتریکی خاک، هزینه و زمان دستیابی به نقشه‌های گسترده‌ی مکانی هدایت الکتریکی خاک بسیار کاهش یافته است (Sudduth et al., 2003). با توجه به تحقیقات انجام شده، هدایت الکتریکی ظاهری که به‌صورت در حرکت اندازه‌گیری شد و علاوه بر شوری (نمک‌های محلول در خاک)، متأثر از دمای خاک، رطوبت، وزن مخصوص ظاهری و بافت خاک و دیگر عوامل موجود در خاک نیز است (Sudduth et al., 2001). به‌عنوان مثال در زمین‌های کم شور، مانند اکثر زمین‌های زراعی هدایت الکتریکی ظاهری اندازه‌گیری شده، بیشتر از آن که تحت تاثیر شوری خاک باشد تحت تاثیر رطوبت است (Lund et al., 2000)، بنابراین خروجی دستگاه‌های رایج تهیه نقشه هدایت الکتریکی ظاهری مانند Veris3100 و LandMapper یا آنچه برادران و همکاران (Baradaran Motie et al., 2010) و

۱- هدایت الکتریکی عصاره اشباع EC_e

2- Apparent soil electrical conductivity

3- Bulk electrical conductivity

4- On the go

مدل‌سازی کردند. نتایج آنان نشان داد شبکه عصبی با دو لایه مخفی نسبت به شبکه عصبی با یک و سه لایه مخفی و همچنین نسبت به روش‌های رگرسیونی ضریب همبستگی بالاتر (۰/۹۲) و مقدار خطای کمتری (۵/۰۲) در پیش‌بینی EC به کمک امواج ماکروویو دارد.

هدف از این تحقیق به‌دست آوردن رابطه‌ای جهت برآورد هدایت الکتریکی واقعی خاک (EC_e) بر اساس پارامترهای دما، رطوبت، وزن مخصوص ظاهری و هدایت الکتریکی ظاهری خاک (EC_a) به کمک روش شبکه عصبی مصنوعی RBF است. بدین ترتیب، با تخمین EC_e بخشی از هدایت الکتریکی ظاهری قابل محاسبه خواهد بود که بیشترین وابستگی را به شوری و نمک‌های محلول خاک داشته و مورد نیاز خاک‌شناسان و مدیران مزرعه می‌باشد. روش شبکه عصبی RBF با داشتن یک لایه پنهان در عین سادگی محاسبات با دقت بالایی می‌تواند روابط بین لایه ورودی (پارامترهای اندازه‌گیری شده) و لایه خروجی (هدایت الکتریکی واقعی) را به‌دست آورد.

سامانه‌های تهیه نقشه شوری خاک تنها هدایت الکتریکی ظاهری خاک را اندازه‌گیری کرده و سایر پارامترهای موثر به‌طور همزمان اندازه‌گیری نمی‌شود. در این دستگاه‌ها در مرحله کالیبراسیون داده‌های خام به‌دست آمده از مزرعه در چند نقطه (۱۰ الی ۵۰) نسبت به هدایت الکتریکی واقعی خاک کالیبره می‌شوند، که این فرآیند مستلزم صرف زمان و هزینه است. اندازه‌گیری هم‌زمان هدایت الکتریکی ظاهری خاک و دیگر پارامترهای موثر بر آن (نظیر رطوبت، دما، چگالی ظاهری و غیره) در کنار استفاده از مدل آماری با ضرایب ثابت، می‌تواند ضمن حذف مرحله داده‌برداری مجدد (کالیبراسیون) موجب بهبود دقت نتایج شود. بدین معنی که نتایج به‌دست آمده به هدایت الکتریکی واقعی خاک (EC_e) نزدیک‌تر شده و در نتیجه گستردگی مکانی شوری در مزرعه را می‌توان دقیق‌تر به‌دست آورد.

مواد و روش‌ها

در این تحقیق هدایت الکتریکی ظاهری خاک به روش تماس مستقیم یا ونر^۱ اندازه‌گیری شد. این روش سرعت بالایی داشته و در سامانه‌های در حرکت داخل مزرعه مورد استفاده قرار می‌گیرد. بدین منظور جریان الکتریکی مشخصی از خاک عبور داده شده و سپس به کمک اندازه‌گیری ولتاژ و جریان می‌توان مقاومت ویژه خاک و هدایت الکتریکی ظاهری را محاسبه کرد (Loke, 2013). این روش علاوه بر اینکه به‌صورت میدانی در مزرعه قابل اجرا است، نسبت به روش نمونه‌گیری و تهیه عصاره اشباع، حجم خاک بیشتری را مورد بررسی قرار داده و به مقیاس واقعی زراعی نزدیک‌تر است. همچنان که برخی نمونه‌های تجاری دستگاه‌های اندازه‌گیری هدایت الکتریکی ظاهری

کردند، روش اندازه‌گیری الکترومغناطیسی EC، همبستگی زیادی با بافت خاک دارد اما مواد فلزی موجود در خاک می‌توانند دقت نتایج را تحت تاثیر قرار دهند. همچنین روش تماس مستقیم^۱ همبستگی ناچیزی با pH خاک نشان داد. Bai و همکاران (۲۰۱۳) اثر خواص فیزیکی خاک بر هدایت الکتریکی را در خاک‌های لاتریت^۲ مورد بررسی قرار دادند. مشاهدات آنها نشان داد که هدایت الکتریکی ظاهری خاک با افزایش دما افزایش می‌یابد و همچنین با افزایش رطوبت و چگالی توده از یک مقدار مشخص، روند افزایشی هدایت الکتریکی خاک متوقف می‌شود.

پیش‌بینی خصوصیات الکتریکی نمونه خاک یک چالش مهم است. مدل‌های مختلفی به‌منظور پیش‌بینی هدایت الکتریکی توده خاک بر اساس خصوصیات و اجزای سازنده آن معرفی شده‌اند. اولین کسانی که در مورد اندازه‌گیری هدایت الکتریکی خاک و سنگ نظریه‌پردازی کردند افرادی به نام‌های ونر، اسمیت و رز و آرچی بودند که تحقیقات خود را در دهه‌های دوم و سوم قرن بیستم ارائه نمودند. در ادامه زمین‌شناسان دیگری تحقیقات و مدل‌های پیشین را بهبود بخشیدند که از بین آن‌ها می‌توان واکس من و اسمیت، فانکوخ، رادز، کلی، سیلوا و بسیونی و توملین و تورز اشاره کرد (Waxman and Smits, 1968; Pfannkuch, 1972; Kelly, 1994; Silva and Bassiouni, 1988; Rhoades et al., 1989; Toumelin and Torres-Verdin, 2005). این مدل‌ها در تحقیقات قدیمی به‌صورت مدل‌های تحلیلی و ریاضی و در تحقیقات جدیدتر به شکل مدل‌های تجربی ارائه شدند.

از طرفی کاربرد شبکه‌های عصبی در پیش‌بینی خصوصیات خاک نظیر نفوذپذیری، هدایت هیدرولیکی، برآورد رسوبات و غیره توسط محققان بررسی شده و برتری آن نسبت به روش‌های رگرسیونی از نظر سرعت و دقت به اثبات رسیده است (Kashiet al., 2013; Rezai Arshad et al., 2012; Khazaei, et al., 2013).

Mahrooghy و همکاران (۲۰۱۶) در تحقیقی به کمک تصویربرداری هوایی به کمک رادار روزنه مصنوعی (نوعی رادار که تصاویر دو بعدی از سطح زمین تهیه می‌کند SAR)، هدایت الکتریکی خاک به روش شبکه عصبی را تخمین زدند. نتایج آنها نشان داد استفاده هم‌زمان بازخوردهای تصاویر رادار، به‌همراه پارامترهایی نظیر میانگین و انحراف معیار داده‌ها در محدوده‌های کوچک می‌تواند دقت پیش‌بینی شبکه عصبی BPNN را بهبود ببخشد. حداکثر مقدار ضریب همبستگی مقادیر پیش‌بینی شده مدل با مقادیر واقعی ۰/۶۹ به‌دست آمد.

Phonphan و همکاران (۲۰۱۴) هدایت الکتریکی خاک را از روی ضریب بازپخش امواج ماکروویو به روش شبکه عصبی مصنوعی

1- Direct contact method

2- Laterite

عمق نفوذ موثر جریان الکتریکی برابر با فاصله بین الکترودها است. مقاومت الکتریکی ویژه به دست آمده را مقاومت ویژه ظاهری خاک می‌نامند. هدایت الکتریکی ظاهری خاک به طور میانگین تا عمق a از رابطه (۲) به دست می‌آید.

$$EC_a = \frac{1}{\rho} \quad (2)$$

عوامل متعددی بر مقدار اندازه‌گیری شده هدایت الکتریکی ظاهری خاک، تاثیرگذار است. در این پژوهش اثر چهار عامل که به نظر می‌رسد بیشترین تاثیر را داشته باشند در نظر گرفته شد. این چهار عامل عبارتند از: هدایت الکتریکی واقعی (هدایت الکتریکی عصاره اشباع)، رطوبت، چگالی توده و دما (Baradaran *et al.*, 2010). اگرچه میزان درصد رس و یا به عبارتی درصد ذرات ریزدانه خاک نیز جزء عوامل تاثیرگذار است اما در یک زمین زراعی معمولاً مقدار نسبتاً ثابتی دارد، از طرفی اندازه‌گیری آن در مزرعه مشکل و وقت‌گیر است، لذا آزمایشات برای خاک با درصد رس مشخص انجام پذیرفت. آزمایشات بر روی یک نمونه خاک زراعی از مزارع شهر مشهد، استان خراسان رضوی انجام گردید. مشخصات خاک مورد استفاده در جدول ۱ آمده است.

خاک بر اساس روش تماس مستقیم نیز در برخی مناطق استفاده می‌شود (وریس ۳۱۰۰ و لندمپر).

در روش وئر چهار الکترود به فواصل مساوی a از یکدیگر بروی خط مستقیم به عمق b در خاک قرار داده می‌شوند. این الکترودها در مدل‌های دستی بر روی یک پایه عایق (از جنس پلاستیک، تفلون یا چوب) و در مدل‌های پشت تراکتوری بر روی شاسی نصب می‌شود. در مدل پشت تراکتوری به جهت سهولت حرکت در خاک الکترودها به شکل تیغه‌ای و یا دیسکی ساخته می‌شود. از بین این چهار الکترود، جریان الکتریکی I به دو الکترود بیرونی اعمال می‌شود، با در نظر گرفتن خاک به عنوان یک هادی الکتریسته در بین دو الکترود میانی اختلاف پتانسیلی القا و قابل اندازه‌گیری بود و ولتاژ (V) بین جفت الکترود میانی اندازه‌گیری می‌گردد. وئر برای محاسبه مقاومت الکتریکی ویژه (ρ) در خاک‌های همگن با مقاومت الکتریکی R رابطه (۱) را از تحلیل میدان الکتریکی درون بلوک خاک برای الکترودهای میله‌ای توسعه داده است (Wenner, 1915).

$$\rho = \frac{4\pi aR}{1 + \frac{2a}{\sqrt{a^2 + 4b^2}} - \frac{a}{\sqrt{a^2 + b^2}}} \quad (1)$$

رابطه (۱) در مورد چهار الکترود با نوک‌های کوچک که در عمق b قرار گرفته‌اند صادق است. طبق مطالعات انجام شده توسط وئر،

جدول ۱ - مشخصات خاک مورد آزمایش

Fig. 1. Specification of used soil

رس %	سیلت %	شن %	بافت	Ece (ms.cm ⁻¹)
Clay %	Silt %	Sand %	Pattern	
20	54	26	Silt-Loam	0.5

یک از متغیرهای مستقل بدین ترتیب انتخاب شدند: هدایت الکتریکی واقعی EC_e (۰/۵ تا ۶ دسی‌زیمنس بر سانتی‌متر)، رطوبت (۵ تا ۲۵ درصد)، چگالی توده (۱ تا ۱/۸ گرم بر سانتی‌متر مکعب) و دمای خاک (۲ تا ۳۷ درجه سلسیوس). مطابق با طرح آزمایشی، سه سطح رطوبتی (۵، ۱۵ و ۲۵ درصد)، سه سطح شوری (۰/۵، ۳/۲۵ و ۶ میلی‌زیمنس بر سانتی‌متر)، سه سطح دمایی (۲، ۱۹ و ۳۷ درجه سلسیوس) و سه سطح فشردگی با چگالی توده‌های (۱، ۱/۴ و ۱/۸ گرم بر سانتی‌متر مکعب) در ۲۷ آزمون با ترتیب مشخص، توسط روش باکس بنکن با سه تکرار تعیین شد.

به منظور آماده‌سازی سطوح رطوبت با توجه به وزن نمونه و درصد رطوبت مطلوب، مقدار لازم آب به آن اضافه شد. اندازه‌گیری درصد رطوبت به روش خشک کردن در آون در دمای ۱۰۵ درجه سلسیوس انجام شد. تغییر در میزان شوری نمونه‌های خاک به وسیله مخلوط کردن نمونه خاک با آب شور تهیه شده از نهر شور گناباد (ایران،

به منظور تعیین برنامه آزمایشات و سطوح فاکتورها از روش سطح پاسخ^۱ استفاده شد. این روش با معیار قرار دادن تعداد متغیرها و حدود بیشینه و کمینه تعیین شده برای هر متغیر، ماتریس آزمایش را طراحی می‌کند. بدین ترتیب تعداد آزمون‌ها و سطوح هر متغیر در هر آزمون مشخص شد. زمانی که تعداد متغیرها زیاد باشد، این روش در مقایسه با روش‌های پرحجمی مانند فاکتوریل کامل، ارجحیت دارد (Montgomery, 2009). روش‌های مرکب مرکزی^۲، باکس بنکن^۳ و دهلرت^۴ سه روش اصلی طراحی سطح پاسخ می‌باشند. در این تحقیق از روش باکس بنکن استفاده شد. با توجه به شرایط موجود در خاک‌های زراعی استان خراسان رضوی مقادیر بیشینه و کمینه هر

- 1- Response surface method
- 2- Central Composite Design
- 3- Box-Behnken
- 4- Doehlert

کلرید سدیم ارجح است زیرا به شرایط طبیعی آبیاری مزارع با آب شور نزدیک‌تر می‌باشد. پس از آماده‌سازی نمونه، میزان شوری خاک به کمک هدایت‌سنج AZ-8361 به روش عصاره اشباع ۱:۱ پس از عبور از کاغذ صافی اندازه‌گیری شد.

خراسان رضوی، گناباد) که با نسبت مورد نیاز با آب مقطر رقیق گردید، انجام شد (Hashemi Nejad *et al.*, 2012). مشخصات آب شور مورد استفاده در جدول ۲ آمده است. استفاده از آب شور طبیعی به علت دارا بودن نمک‌های محلول، نسبت به استفاده از محلول

جدول ۲- مشخصات آب شور مورد استفاده در تهیه سطوح شوری نمونه های خاک

Table 2- The characteristics of saline water used for soil sample preparation with various salinity levels

مشخصه	مقدار	مشخصه	مقدار
Characteristic	Value	Characteristic	Value
EC(mS.cm ⁻¹)	118	PH	7.7
PO ₄ ⁻³ (meq.lit ⁻¹)	0.03	Salinity (ppt)	86.2
Total water hardness (mg.lit ⁻¹)	15400	NO ₃ ⁻² (meq.lit ⁻¹)	2

آزمایشی، الکترودها به درون استوانه نفوذ داده شد. جفت الکتروده بیرونی پس از اتصال به یک آمپر متر، به منبع تغذیه ۳۰ ولت DC متصل و جفت الکتروده درونی به یک ولت‌متر DC متصل شد. با برقراری جریان الکتریکی، مقادیر ولتاژ و جریان عبوری قرائت و ثبت گردید. بدین ترتیب از هر نمونه سه قرائت برداشت و مقادیر EC_a با استفاده از روابط (۱) و (۲) محاسبه شد. میانگین سه قرائت به‌عنوان EC_a نمونه مورد نظر ثبت گردید.

در این پژوهش هدایت الکتریکی ظاهری خاک به‌عنوان متغیر وابسته و هدایت الکتریکی واقعی به‌عنوان متغیر مستقل انتخاب گردید. اما در پایش‌های مزرع‌ای به‌منظور تهیه نقشه‌های خاک، هدایت الکتریکی واقعی خاک حائز اهمیت بوده و در نتیجه لازم است با اندازه‌گیری هدایت الکتریکی ظاهری، دما، رطوبت و چگالی توده به یک تخمین دقیق از هدایت الکتریکی واقعی (EC_e) دست یافت. به منظور تخمین هدایت الکتریکی واقعی ECE به کمک داده‌های هدایت الکتریکی ظاهری EC_e، دما، رطوبت و چگالی توده از روش شبکه عصبی RBF^۷ استفاده شد.

شبکه عصبی RBF

شبکه‌های عصبی با تابع پایه شعاعی به‌طور گسترده برای تخمین غیرپارامتریک توابع چندبعدی از طریق مجموع‌های محدود از اطلاعات آموزشی به کار می‌روند. شبکه‌های عصبی شعاعی با آموزش سریع و فراگیر، بسیار جالب و کارآمد هستند و به آن توجه خاصی شده است (Khanjani *et al.*, 2016). Hartman و همکاران در سال ۱۹۹۰ میلادی اثبات کردند که شبکه‌های با تابع پایه شعاعی، تقریب‌سازهای بسیار قدرتمندی هستند؛ به‌طوری که با داشتن تعداد نرون‌های کافی در لایه مخفی، قادر به تقریب زدن هر تابع پیوسته و با هر درجه دقت هستند. نکته بسیار جالب آن است که این شبکه‌ها

به‌منظور ایجاد تراکم مورد نیاز در خاک و همچنین اندازه‌گیری هدایت‌الکتریکی ظاهری نمونه‌های خاک، از استوانه‌های پلاستیکی با یک انتهای بسته استفاده شد (Liaghat, 1993). مشخصات استوانه‌های نمونه در جدول ۳ آمده است. اطراف استوانه‌ها به‌منظور قرارگیری الکترودها در نمونه خاک، سه گروه چهارتایی سوراخ به قطر ۴ میلی‌متر و فاصله ۵۰ میلی‌متر از هم ایجاد شد. به جهت حفظ تقارن، گروه‌های چهارتایی سوراخ در زاویه‌ای ۱۲۰ درجه نسبت به هم ایجاد شدند. بدین ترتیب از هر استوانه نمونه، امکان اندازه‌گیری سه قرائت وجود داشت که میانگین سه قرائت به‌عنوان هدایت الکتریکی ظاهری نمونه در نظر گرفته شد (شکل ۱).

برای رسیدن به سطوح مورد نظر چگالی توده، با توجه به حجم استوانه‌ها، میزان خاکی که باید درون آن قرار داده می‌شد، محاسبه گردید. مقدار مشخص شده خاک به‌وسیله ترازوی دیجیتال AND-GF6000 با دقت ۰/۰۱ گرم توزین و به کمک چکش تراکم ۱۰ پوندی (۴/۵۴ کیلوگرم) درون استوانه به‌صورت یکنواخت فشرده شد. به‌منظور دستیابی به سطوح دمایی، از اتاقک کنترل دما استفاده شد. بدین ترتیب پس از آماده‌سازی سطوح رطوبت و شوری، نمونه‌ها با توجه به سطوح چگالی توده، درون استوانه‌ها فشرده شدند. سپس استوانه‌ها درون محفظه کنترل دما قرار داده شد تا به‌صورت یکنواخت به دمای مورد نظر برسد.

اندازه‌گیری هدایت الکتریکی ظاهری

برای اندازه‌گیری EC_a چهار الکتروده مطابق با آرایش و نر درون نمونه خاک قرار داده شد. الکترودها مطابق جدول ۳ انتخاب و بر روی یک پایه از جنس تفلون ثابت شدند. نوک الکترودها به‌منظور نفوذ بهتر و عدم ایجاد بهم ریختگی در ساختمان نمونه تیز شد. پس آماده‌سازی نمونه‌های خاک از نظر فاکتورها و سطوح

2- Radial basis function network

1- ASTM standard D1557


طبقه‌بندی الگوها گرفته‌اند و مزیت عمده آنها، طبقه‌بندی الگوهایی است که فضای غیرخطی دارند.

تنها با داشتن یک لایه مخفی، دارای چنین خاصیتی هستند. شبکه‌های تابع پایه شعاعی بیشترین الهام را از تکنیک‌های آماری

جدول ۳- مشخصات استوانه‌های آزمون نمونه خاک و الکترودها

Table 3- Specification of sampling cylinders and electrodes

استوانه نمونه Cylinders		الکترود Electrodes	
قطر Diameter (cm)	10	قطر Diameter (mm)	3
طول Length (cm)	24	طول Length (mm)	70
جنس Material	PVC Pipe	عمق نفوذ در خاک Penetration depth (mm)	50
فاصله بین سوراخ‌ها Interspacing of holes (cm)	5	جنس Material	Steel




شکل ۱- استوانه نمونه خاک و الکترودهای نفوذ کرده در آن حین اندازه‌گیری هدایت الکتریکی ظاهری خاک

Fig. 1. Soil sample cylinder and positioning of penetrated electrodes in soil

یک خروجی خطی تولید می‌کند. خصوصیت منحصر به فرد این شبکه، پردازشی است که در لایه پنهان انجام می‌شود. رابطه (۳) تابع مورد استفاده در لایه پنهان شبکه عصبی را نشان می‌دهد. در این رابطه W_j ها وزن‌های مربوط به هر نرون و z_j ها مراکز ثقل تابع هر نرون هستند.

معماری شبکه عصبی RBF شامل لایه ورودی، لایه خروجی و یک لایه پنهان می‌باشد. لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولاً با بُعد بزرگتر برقرار می‌کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک‌پذیر خطی دارد. لایه خروجی، جمع وزنی الگوهای خطی شده را به همراه



شکل ۲. ساختار شبکه عصبی RBF

Fig.2. RBF artificial neural network structure

می‌باشد. مراحل اصلی حل هر مسئله توسط شبکه عصبی شامل آموزش و آزمون است. آموزش، فرآیند یادگیری مجموعه داده‌های ورودی به منظور تشخیص الگوهای آن توسط شبکه می‌باشد زیرا شبکه RBF از نوع با معلم است. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون‌ها از طریق قانون یادگیری در طول فاز آموزش اصلاح می‌شوند. اساس الگوریتم‌های آموزش کمینه کردن انحراف خروجی شبکه از مقدار واقعی می‌باشند. فاز آزمون، ارزیابی قابلیت تعمیم‌پذیری شبکه آموزش دیده در شرایط کاملاً جدید توسط مجموعه داده‌های غیر از داده‌های آموزش است (Zarif Neshat *et al.*, 2012). تعداد ۱۳ الگوریتم آموزشی رایج در محیط نرم‌افزار Matlab جهت آموزش شبکه به منظور یافتن الگوریتم بهینه بررسی شد (جدول ۴). در طراحی لایه ورودی شبکه در این مطالعه از ترکیب دو روش طرح آزمایش بلوک‌های کامل تصادفی و روش تقاطعی k-fold استفاده شد. به روش تقاطعی k-fold، بیست مجموعه داده مختلف برای آموزش و آزمایش شبکه عصبی RBF تولید شد.

$$f(x) = \sum_{j=1}^p w_j \varphi(\|x - u_j\|) \quad (3)$$

شبکه عصبی با تابع شعاعی نیز مانند هر شبکه عصبی دیگر، دو مد عملکردی آموزش و مرجع دارد. در طی مد آموزش، پارامترهای تعدیل‌پذیر شبکه و ماتریس وزن لایه خروجی چنان تغییر می‌کند که خطای میانگین بین خروجی‌های شبکه در یک مجموعه آموزشی و مقادیر واقعی به حداقل برسد. در مد مرجع، شبکه آموزش دیده با ارائه بردارهای ورودی جدید به شبکه، بردارهای خروجی را به دست می‌آورد.

طراحی شبکه عصبی

برای تخمین هدایت الکتریکی واقعی (EC_e) برحسب چهار متغیر هدایت الکتریکی ظاهری، دمای خاک، رطوبت خاک و چگالی توده از شبکه عصبی تابع پایه شعاعی (RBF) استفاده شد. یکی از پارامترهای بسیار مهم در طراحی شبکه عصبی RBF نوع الگوریتم آموزش

جدول ۴- الگوریتم‌های آموزشی بررسی شده در طراحی شبکه عصبی

Table 4- Educational algorithms investigated in design of the neural network

نام الگوریتم (انگلیسی) Name (English)	نام الگوریتم (فارسی) Name (Farsi)	نام اختصاری Abbreviation	کد الگوریتم Code
Levenberg-Marquardt backpropagation	لونبرگ-مارکوآت	Trainlm	T1
Bayesian regularization backpropagation	بیزین	Trainbr	T2
Scaled conjugate gradient backpropagation	گرادیان توام مقیاس شده	Trainscg	T3
Resilient backpropagation	پس‌انتشار انعطاف پذیر	Trainrnp	T4
Gradient descent with momentum and adaptive learning rate backpropagation	گرادیان نزولی با مومنتوم و سرعت یادگیری متغیر	Traingdxd	T5
Gradient descent with momentum backpropagation	گرادیان نزولی با مومنتوم	Traingdm	T6
Gradient descent with adaptive learning rate backpropagation	شبکه با سرعت یادگیری متغیر	Traingda	T7
Gradient descent backpropagation	گرادیان نزولی	Traingd	T8
BFGS quasi-Newton backpropagation	پس‌انتشار نیوتن - گوسی	Trainbfg	T9
Conjugate gradient backpropagation with Powell-Beale restarts	گرادیان مزدوج با راه‌اندازی مجدد پاول - بیل	Traincgb	T10
Conjugate gradient backpropagation with Fletcher-Reeves updates	گرادیان مزدوج با به‌روزرسانی فلچر-ریوز	Traincgf	T11
Conjugate gradient backpropagation with Polak-Ribière updates	گرادیان مزدوج با به‌روزرسانی پولاک-ریبری	Traincgp	T12
One-step secant backpropagation	پس‌انتشار تک مرحله‌ای	Trainoss	T13

اعتبارسنجی مدل

مزرعه‌ای، تعداد ۶۰ داده میدانی جمع‌آوری شده از سطح مزارع شامل رطوبت، چگالی توده، دما و هدایت الکتریکی ظاهری مورد استفاده قرار گرفت. هدایت الکتریکی ظاهری این مجموعه داده به روش تماس مستقیم توسط دستگاه پشت‌تراکتوری اندازه‌گیری و سپس با نمونه‌گیری سایر پارامترها مانند رطوبت، دما، چگالی توده و هدایت

با توجه به اینکه داده‌های ورودی به مدل در شرایط کنترل‌شده آزمایشگاهی به دست آمده بود، به جهت اعتبارسنجی و بررسی توانمندی مدل در تخمین هدایت الکتریکی واقعی خاک در شرایط

مجموعه داده در هر دو مرحله آموزش و آزمایش کمتر از ۰/۰۱ شده است. بنابراین عملکرد تخمینی مدل RBF وابسته به نوع مجموعه داده‌های آموزش و آزمایش است.

نتایج مقایسه میانگین ضریب تبیین بین دو مجموعه داده واقعی و پیش‌بینی شده در دو مرحله آموزش و آزمایش به روش حداقل اختلاف معنی‌دار در شکل‌های ۳ و ۴ نشان داده شده است. همانطور که نتایج نشان می‌دهد، بین الگوریتم‌های مختلف اختلاف معنی‌داری در سطح ۵ درصد وجود دارد. این اختلاف‌ها در مراحل آموزش و آزمایش تقریباً متفاوت از یکدیگر شده‌اند. مثلاً در مرحله آموزش بین دو الگوریتم T1 و T2 اختلاف معنی‌داری وجود ندارد ولی در مرحله آزمایش نتایج متفاوتی حاصل شده است.

الکتریکی عصاره اشباع در آزمایشگاه اندازه‌گیری شد. این داده‌ها به‌عنوان ورودی به مدل شبکه عصبی وارد شد. خروجی مدل که EC_e خاک است با مقادیر EC_e اندازه‌گیری شده نمونه‌ها مقایسه و نتایج آن در شکل ۶ آورده شده است.


نتایج و بحث

نتایج تجزیه واریانس ضریب تبیین بین دو مجموعه داده واقعی و پیش‌بینی شده توسط RBF در جدول ۵ آورده شده است. همانطور که ملاحظه می‌شود، اثر نوع الگوریتم آموزش بر مقدار ضریب تبیین در هر دو مرحله آموزش و آزمایش معنی‌دار شده است. بنابراین عملکرد پیش‌بینی مدل RBF در تخمین هدایت الکتریکی وابسته به نوع الگوریتم آموزش دارد. همچنین مقدار P-value اثر بلوک یا نوع

جدول ۵ - تجزیه واریانس معیارهای عملکردی شبکه عصبی RBF به کمک طرح RCBD^۱
Table 5- ANOVA analysis of RBF neural network parameters using RCBD design

منبع (Source)	فاز آموزش Train phase				فاز آزمایش Test phase		
	DF	SS	MS	P-Value	SS	MS	P-Value
الگوریتم آموزشی* Learning algorithm	12	3.44	0.28	0.00	11.34	0.95	0.00
بلوک Block	19	2.26	0.11	0.00	6.00	0.32	0.00
خطا Error	228	1.08	0.005		10.21	0.04	
مجموع Total	259	6.79			27.55		

*تیمارها هر کدام از الگوریتم‌های آموزشی و بلوک‌ها هر کدام از K-fold ها می‌باشد.
 Treatments are the learning algorithms and block are the each K-folds.




شکل ۱ - نتیجه مقایسه میانگین ضریب تبیین الگوریتم‌های آموزش در مرحله آموزش

Fig. 3. The result of the comparison of the average coefficient of explanation of training algorithms in the learning stage

عصبی عملکرد الگوریتم آموزشی trainbr (T2) بهتر از سایر الگوریتم‌ها تشخیص داده شد. عملکرد بهتر الگوریتم آموزشی بیزین (trainbr) نسبت به سایر الگوریتم‌ها در پیش‌بینی مقدار مولفه‌های خاک، توسط سایر محققان نیز تأیید شده است (Rezaei Arshad *et al.*, 2012).

بنابراین باید در انتخاب الگوریتم آموزش به نتایج هر دو مرحله آموزش و آزمایش توجه کرد. علاوه بر این، مقدار انحراف معیار ضریب تبیین الگوریتم آموزش T2 نسبت به سایر الگوریتم‌های آموزش بسیار کمتر است. هرچه مقدار انحراف معیار کمتر باشد، توانایی الگوریتم در یادگیری از مجموعه داده‌های مختلف بیشتر است. با در نظر گرفتن تمام جوانب، از میان ۱۳ الگوریتم آموزش شبکه



شکل ۴. نتایج مقایسه میانگین ضریب تبیین الگوریتم‌های آموزش در مرحله آزمایش

Fig. 4. The result of the comparison of the average coefficient of explanation of training algorithms in the experimental stage

آورده شده است. نتایج آزمون معنی‌داری نشان می‌دهد که اثرات مستقیم و اثرات متقابل دو عامل S و L2 بر مقدار ضریب تبیین مدل RBF در هر دو مرحله آموزش و آزمایش در سطح یک درصد معنی‌دار شده است؛ بنابراین باید در انتخاب مقدار بهینه آنها به هر دو پارامتر توجه شود.

در مرحله قبلی بهترین نوع الگوریتم آموزش RBF انتخاب شد. دو عامل تعداد نرون‌ها در لایه مخفی (L2) و پارامتر گسترده‌گی (S) نیز بر عملکرد پیش‌بینی شبکه عصبی RBF تأثیرگذار هستند. نتایج تجزیه واریانس طرح آزمایشی فاکتوریل بر پایه بلوک‌های کامل تصادفی برای انتخاب بهترین مقدار دو عامل S و L2 در جدول ۶

جدول ۶- نتایج تجزیه واریانس معیارهای عملکرد شبکه به کمک الگوریتم آموزش T2 و طرح فاکتوریل بلوک‌های کامل تصادفی

Table 6- Analysis of variance of network performance criteria using T2 training algorithm and factorial design based on randomized complete blocks

منبع (Source)	فاز آموزش Train phase				فاز آزمایش Test phase		
	DF	SS	MS	P-Value	SS	MS	P-Value
بلوک Block	4	0.76	0.19	0.02	3.09	0.77	0.00
L ₂ (لایه مخفی) Hidden layer	9	3.92	0.43	0.00	3.79	0.42	0.00
S (گسترده‌گی) Spread	9	19.49	2.16	0.00	22.48	2.49	0.00
L ₂ ×S	81	10.81	0.13	0.00	10.03	0.12	0.01
خطا Error	396	25.84	0.06		34.66	0.08	
مجموع Total	499	60.83			74.06		

تیمارها هر کدام از الگوریتم‌های آموزشی و بلوک‌ها هر کدام از K-foldها می‌باشد.

Treatments are the learning algorithms and block are the each K-folds.

۰/۹۹ شده است. اما از نظر بزرگی ترتیب در هر دو مرحله آموزش و آزمایش متفاوت می‌باشند. با توجه به اهمیت مرحله آزمایش $L2=9$ و $S=0.1$ به‌عنوان مقادیر بهینه در نظر گرفته شد.

نتایج مقایسه میانگین R^2 مدل RBF برای هر دو مرحله آموزش و آزمایش در نتیجه به‌کارگیری برخی از ترکیبات دو عامل $L2$ و S به شکل اثرات متقابل در جدول ۷ آورده شده است. همان‌طور که دیده می‌شود، مقدار ضریب تبیین همه آنها بدون اختلاف معنی‌دار برابر با



جدول ۷- نتایج مقایسه میانگین R^2 در دو مرحله آموزش و آزمایش بر حسب اثرات متقابل $L2 \times Spread$

Table 7- Results of comparison of R^2 in training and experimentation based on the interaction effects of $L2 \times Spread$

فاز آموزش Training phase			فاز آزمایش Test phase		
L2	S	میانگین Mean	L2	S	میانگین Mean
8	0.1	0.99 ^a	9	0.1	0.99 ^a
10	0.1	0.99 ^a	6	0.1	0.99 ^a
11	0.1	0.99 ^a	8	0.1	0.99 ^a
9	0.1	0.99 ^a	12	0.1	0.99 ^a
6	0.1	0.99 ^a	10	0.1	0.99 ^a

آموزش و آزمایش، افزایشی است. اما در مورد پارامتر گستردگی این روند تا مقدار ۰/۵ کاهشی و سپس روند افزایش به‌خود می‌گیرد. بیشترین مقدار R^2 برای $S=0.1$ به‌دست آمده است (۵-ب). اما در مرحله آموزش بیشترین R^2 با مقدار $S=10$ به‌دست آمد.

شکل ۵، چگونگی تغییرات R^2 مدل RBF برای دو مرحله آموزش و آزمایش برای اثرات اصلی و متقابل تعداد نرون‌ها را در لایه مخفی و پارامتر گستردگی نشان می‌دهد. همان‌طور که دیده می‌شود، همواره با افزایش تعداد نرون‌ها روند تغییرات R^2 در هر دو مرحله



شکل ۵- اثرات متقابل تعداد نرون در لایه مخفی و گستردگی بر R^2 در دو مرحله آموزش (a) و آزمایش (b)

Fig. 5. The interactions between the number of neurons in the hidden layer and the spread on R^2 in two stages of training (a,c) and test phase (b,d)

داد که نوع مجموعه داده‌ها تاثیر معنی‌داری بر عملکرد شبکه عصبی دارد. بنابراین از صد مجموعه داده مختلف به کمک روش تقاطعی k -fold برای ارزیابی خاصیت تعمیم‌پذیری شبکه عصبی RBF استفاده گردید. در جدول ۸، میانگین و انحراف معیار سه شاخص عملکردی مدل RBF شامل RMSE، MAPE و R^2 در دو مرحله

تا این مرحله برای طراحی شبکه عصبی در مرحله آموزش از ۸۰ درصد کل داده‌ها به شکل تصادفی استفاده شد. اما بهترین مدل شبکه عصبی زمانی به‌دست می‌آید که بتواند با تعداد داده‌های کمتری تخمین‌های بهتری داشته باشد و یا به عبارت دیگر دارای خاصیت تعمیم‌پذیری خوبی باشد. از طرف دیگر نتایج جدول‌های ۶ و ۷ نشان

به تخمین‌های خوبی از هدایت الکتریکی خاک می‌باشد. البته این نتایج مؤید آن است که اگر بتوان مجموعه داده‌های وسیع‌تری فراهم کرد آنگاه می‌توان به تخمین‌های هدایت الکتریکی خاک توسط مدل RBF در شرایط جدید بیشتر اطمینان داشت.

آموزش و آزمایش آورده شده است. همانطور که ملاحظه می‌شود هر چه اندازه مجموعه آموزش (TS) از ۹۰ درصد کل داده‌ها کمتر شده و مجموعه آموزش کوچکتر می‌شود، میزان دقت تخمین شبکه عصبی RBF برای هدایت الکتریکی واقعی خاک نیز روند نزولی پیدا می‌کند. ولی تا حدود اندازه ۷۰ درصد برای مجموعه آموزش مدل RBF قادر

جدول ۸- عملکرد تعمیم‌پذیری مدل RBF در تخمین هدایت الکتریکی واقعی خاک

Table 8- The generalizability function of the RBF model in estimating the soil electrical conductivity

TS (%)	Train phase			Test phase		
	RMSE	MAPE	R ²	RMSE	MAPE	R ²
90	0.01±0.001	0.01±0.001	0.99±0.001	0.01±0.001	0.01±0.001	0.99±0.001
80	0.01±0.001	0.01±0.001	0.99±0.001	0.01±0.001	0.01±0.001	0.99±0.001
70	0.06±0.31	4.36±21.84	0.96±0.20	0.09±0.45	7.56±38.50	0.97±0.13
60	0.19±0.54	14.42±42.22	0.92±0.21	0.20±0.59	15.25±46.81	0.92±0.23
50	0.22±0.58	18.58±51.18	0.89±0.28	0.26±0.67	18.29±49.55	0.89±0.28

هدایت الکتریکی خاک با گزارشات سایر محققین نیز مطابقت دارد (Corwin and Lesch, 2003; Lund *et al.*, 1999) زیرا به ترتیب حذف هر یک از آنها بیشترین تا کمترین تاثیر منفی بر شاخص‌های عملکردی پیش‌بینی مدل RBF را دارد. به‌عنوان مثال حذف متغیر هدایت الکتریکی ظاهری خاک از مجموعه متغیرهای ورودی مدل باعث کاهش تقریباً ۷۰ درصدی ضریب تبیین در هر دو مرحله آموزش و آزمایش می‌شود.

برای بررسی اثرات هر یک از چهار متغیر مستقل هدایت الکتریکی ظاهری، دمای خاک، رطوبت خاک و چگالی توده بر مقدار تخمینی هدایت الکتریکی واقعی خاک توسط مدل RBF از تحلیل حساسیت استفاده شد. نتایج تحلیل حساسیت مدل RBF در جدول ۹ برای دو مرحله آموزش و آزمایش نشان داده شده است. همانطور که نتایج نشان می‌دهند، به ترتیب متغیرهای هدایت الکتریکی ظاهری، رطوبت، چگالی توده و دمای خاک بیشترین تاثیر را در تخمین مقدار هدایت الکتریکی واقعی خاک دارند. بیشتر بودن اثر رطوبت در اندازه‌گیری

جدول ۹- تحلیل حساسیت مدل RBF در تخمین هدایت الکتریکی واقعی خاک

Table 9- Sensitivity analysis of the RBF model in estimating soil electrical conductivity

Model inputs	Train phase			Test phase		
	RMSE	MAPE	R ²	RMSE	MAPE	R ²
All	0.01±0.001	0.01±0.001	0.99±0.001	0.01±0.001	0.01±0.001	0.99±0.001
All-Temp	1.18±0.23	67.03±29.06	0.58±0.20	1.24±0.55	80.50±73.20	0.56±0.20
All-B.D.	1.06±0.27	55.73±29.77	0.61±0.31	1.05±0.57	58.87±56.65	0.63±0.32
All-Moisture	1.60±0.19	112.44±21.55	0.36±0.24	1.70±0.45	129.02±89.21	0.35±0.21
All-ECa	1.82±0.09	130.52±21.88	0.31±0.20	1.77±0.53	140.93±93.04	0.30±0.19

تطابق بین مقادیر واقعی و پیش‌بینی شده هدایت الکتریکی خاک توسط مدل RBF را با ضریب تبیین ۰/۹۸۶ نشان می‌دهد.


اعتبارسنجی مدل با داده‌های میدانی

نتایج مقایسه آماری داده‌های ورودی مدل در مرحله اعتبارسنجی با داده‌های خروجی از مدل در جدول ۱۰ آمده است همچنین شکل ۶

جدول ۱۰- مقایسه آماری داده‌های مورد استفاده برای اعتبارسنجی مدل

Table 10- Statistical results of validation process

	تعداد Number	حداقل Minimum	حداکثر Maximum	میانگین Mean	ضریب تغییرات Std. Deviation	چولگی Skewness
Measured ECe (mS.cm ⁻¹)	60	0.02	3.39	1.8343	.98343	-.416
Predicted ECe (mS.cm ⁻¹)	60	0.02	3.09	1.6379	.88724	-.373



شکل ۶- تطابق مقادیر واقعی و پیش‌بینی شده هدایت الکتریکی واقعی خاک توسط شبکه عصبی RBF
Fig. 6. Match the real and predicted soil electrical conductivity by the RBF neural network

طی مرحله‌ای جداگانه کالیبره می‌کنند، لذا در این تحقیق سعی شد ضمن اندازه‌گیری همزمان پارامترهای موثر بر ECa، مستقیماً مقادیر ECe خاک بدون نیاز به مرحله کالیبراسیون (صرف وقت و هزینه) برآورد شود. با تهیه یک مدل شبکه عصبی چند متغیره با ورودی‌های، هدایت الکتریکی ظاهری، دما، رطوبت و چگالی توده خاک، هدایت الکتریکی ECe با ضریب تبیین ۰/۹۹ تخمین زده شد. همچنین الگوریتم آموزشی بیزین به‌عنوان بهترین الگوریتم جهت آموزش این شبکه عصبی معرفی گردید. همچنین این مدل با استفاده از داده‌های میدانی مزرعه‌ای، مورد اعتبارسنجی قرار گرفت. به‌طوری‌که نتایج آن بسیار قابل قبول بود. بدین ترتیب می‌توان نقشه‌های تغییرات EC خاک را با دقت بالاتری جهت برآورد گستردگی مکانی شوری در مزارع تهیه کرد. نتایج این تحقیق نشان داد به ترتیب متغیرهای هدایت الکتریکی ظاهری، رطوبت، چگالی توده و دمای خاک بیشترین تاثیر را در تخمین مقدار هدایت الکتریکی واقعی خاک دارند.

این نتایج مؤید آن است که مدل شبکه عصبی RBF توانسته است به خوبی مقدار هدایت الکتریکی واقعی خاک را تخمین بزند. R^2 به دست آمده در این مرحله (۰/۹۸۶) از R^2 به دست آمده در حین آزمایش مدل RBF (۰/۹۹) با داده‌های آزمایشگاهی (مرحله قبل) کمتر است، که اختلاف جزئی بین مقادیر پیش‌بینی شده و مقادیر اندازه‌گیری شده در این مرحله در اثر شرایط متغیر خاک در مزرعه، وجود خطای آزمایشی و همچنین احتمال عدم یکنواختی دما، چگالی و رطوبت در هنگام اندازه‌گیری مزرعه‌ای است.

نتیجه‌گیری

در این تحقیق بر روی افزایش دقت اندازه‌گیری هدایت الکتریکی واقعی خاک بر اساس پارامترهای زودیافت (هدایت الکتریکی ظاهری، دما، رطوبت و چگالی توده) تمرکز شد. به دلیل آنکه در سامانه‌های مرسوم تهیه نقشه تغییرات هدایت الکتریکی خاک در مزارع، تنها هدایت الکتریکی ظاهری خاک را اندازه‌گیری کرده و سپس داده‌های به دست آمده را بر اساس هدایت الکتریکی واقعی در

References

1. ASTM Standard D1557. 2009. Standard Test Methods for Laboratory Compaction Characteristics of Soil Using Modified Effort, ASTM International, West Conshohocken, PA, DOI: 10.1520/D1557-09.
2. Bai, W., L. Kong, and A. Guo. 2013. Effects of physical properties on electrical conductivity of compacted lateritic soil. *Journal of Rock Mechanics and Geotechnical Engineering* 5 (5): 406-411.
3. Baradaran Motie, J., M. H. Aghkhani, M. H. Abbaspour-fard, and A. Lakzian. 2010. Determining soil EC based on Wenner method with plate type probes as a component of precision farming, First international conference of soil and root relationship (LANDCON1005), 24-26 May 2010, Ardabil, Iran.
4. Baradaran Motie, J., M. H. Aghkhani, M. H. Abbaspour-fard, and A. lakzian. 2011. Design,

- Construction and Assessment of Soil Electrical Conductivity Mapper. *Journal of Agricultural Machinery Engineering* 1 (1): 25-33. (In Farsi).
5. Corwin, D. L., and S. M. Lesch. 2003. Application of Soil Electrical Conductivity to Precision Agriculture: Theory, Principles, and Guidelines. *Agronomy Journal* 95 (3): 455-471.
 6. Ehsani, R., and M. Sullivan. 2002. Soil Electrical Conductivity (EC) Sensors. Ohio state university. Extension factsheet. Food, Agricultural and Biological Engineering, AEX-565-02.
 7. Hartman, E., J. D. Keeler, and J. M Kowalski. 1990. Layered neural networks with Gaussian hidden units as universal approximations, *Neural Computation* 2 (2): 210-215.
 8. Hashemi Nejad, Y., M. Gholami, and V. Soltani. 2012. Optimize water consumption through precise control of soil salinity in a lasting environment. *Journal of Soil and Water Conservation* 1 (3): 59-67. (In Farsi).
 9. Kashi, H., S. Emamghoi zadeh, H. Ghorbani, and S. Hashemi. 2013. Estimation of Soil Infiltration in Agricultural and Pasture Lands using Artificial Neural Networks and Multiple Regressions. *Quarterly Journal of Environmental Erosion Research* 3: 19-34. (In Farsi).
 10. Kelly, B. F. J. 1997. Electrical Properties of Sediments and the Geophysical Detection of Groundwater Contamination, The University of New South Wales Sydney.
 11. Khanjani, T., M. Ataei, and P. Moallem. 2016. Wind Speed Prediction Based on Chaos Theory using RBF Neural Networks. *Computational Intelligence in Electrical Engineering* 7 (3): 87-96. (In Farsi).
 12. Khazaii, M., S. H. Sadeghi, and S. K., Mirnia. 2013. Application of Artificial Neural Network and Regression Models in Sediment Yield in Plots Located in Disturbed and Undisturbed Plots in Educational and Research Forest Watershed of Tarbiat Modares University, Iran. *Iranian Journal of Watershed Management Science and Engineering* 7 (21): 13-20. (In Farsi).
 13. Liaghat, A. 1993. Effect of clay type and clay content on moisture content and bulk soil electrical conductivity as measured using time domain reflectometry, Master of Science thesis, Department of agricultural engineering, macdonald campus of Mc-Gill University, Canada.
 14. Lilienthal, H., Ch. Iiter, J. Rogasik, and E. Schnug. 2005. Comparison of different geo-electric measurement techniques to detect in-field variability of soil parameter. *LandbauforschungVölkenrode* 55 (4): 237-243.
 15. Loke, M. H., J. E. Chambers, D. F. Rucker, O. Kuras, and P. B. Wilkinson. 2013. Recent developments in the direct-current geoelectrical imaging method. *Journal of Applied Geophysics* 95: 135-156.
 16. Lund, E. D., C. D. Christy, and P. E. Drummond. 1999. Practical applications of soil electrical conductivity mapping, 2nd European Conference on Precision Agriculture. July 1999.
 17. Lund, E. D., C. D. Christy, and P. E. Drummond. 2000. Using yield and soil electrical conductivity (EC) maps to derive crop production performance information. In *Proceedings of the 5th International Conference on Precision Agriculture*, Bloomington, Minnesota, USA, 16-19 July, 2000 (pp. 1-10). American Society of Agronomy.
 18. Mahrooghy, M., J. Aanstoos, R. A. Nobrega, K. Hasan, and N. H. Younan. 2016. A Neural Network Approach to Soil Electrical Conductivity Estimation on Earthen Levees Using Spaceborne X-band SAR Imagery. *Photogrammetric Engineering & Remote Sensing* 82 (7): 509-519.
 19. Montgomery, Douglas C. Design and analysis of experiments. Hoboken, NJ: Wiley, 2009.
 20. Nazari, P., Sh. Mahmoudi, and A. Pazira. 2017. Study of salinity changes in parts of Turkman Sahra lands using interpolation methods. *Journal of Soil and Water Conservation* 6 (3): 89-98. (In Farsi).
 21. Olteanu, C., C. Turcu, F. Olteanu, S. Zamfira, G. Oltean, and B. Braun. 2008. Mechatronic system for measuring and tracking of maps concerning soil agro-productive parameters, 6th International DAAAM Baltic Conference Industrial Engineering 24-26 April 2008, Tallinn, Estonia.
 22. Pan, L., V. I. Adamchuk, S. Prasher, R. Gebbers, R. S. Taylor, and M. Dabas. 2014. Vertical soil profiling using a galvanic contact resistivity scanning approach. *Sensors* 14 (7): 13243-13255.
 23. Pfannkuch, H. O. 1972. On the Correlation of Electrical Conductivity Properties of Porous Systems with Viscous Flow Transport Coefficients in Fundamentals of Transport Phenomena in Porous Media. *Developments in Soil Science* 2: 42-54.
 24. Phonphan, W., N. K. Tripathi, T. Tipdecho, and A. Eiumnoh. 2014. Modelling electrical conductivity of soil from backscattering coefficient of microwave remotely sensed data using artificial neural network. *Geocarto International* 29 (8): 842-859.
 25. Rezae Arshad, R., Gh. Sayyad, M. Mazloom, M. Shorafa, and A. Jafarnejady. 2012. Comparison of

- Artificial Neural Networks and Regression Pedotransfer Functions for Predicting Saturated Hydraulic Conductivity in Soils of Khuzestan Province. *Journal of Water and Soil Science* 16 (60): 107-118. (In Farsi).
26. Rhoades, J. D., D. L. Corwin, and S. M. Lesch. 1999. Geospatial measurements of soil electrical conductivity to assess soil salinity and diffuse salt loading from irrigation. *Assessment of non-point source pollution in the vadose zone*: 197-215.
 27. Rhoades, J. D., N. A. Manteghi, P. J. Shouse, and W. J. Alves. 1989. Soil electrical conductivity and soil salinity: New formulations and calibrations. *Soil Science Society of America Journal* 53 (2): 433-439.
 28. Seifi, M. R., R. Alimardani, and A. Sharifi. 2010. Design and development of a portable soil electrical conductivity detector. *Asian Journal of Agricultural Sciences* 2 (4): 168-173.
 29. Silva, P. L., and Z. Bassiouni. 1988. Hydrocarbon Saturation Equation in Shaly Sands According to the S-B Conductivity Model. *SPE Formation Evaluation* 3 (03): 503-509.
 30. Sudduth, K. A., S. T. Drummond, and N. R. Kitchen. 2001. Accuracy issues in electromagnetic induction sensing of soil electrical conductivity for precision agriculture. *Computers and Electronics in Agriculture* 31 (3): 239-264.
 31. Sudduth, K. A., N. R. Kitchen, G. A. Bollero, D. G. Bullock, and W. J. Wiebold. 2003. Comparison of electromagnetic induction and direct sensing of soil electrical conductivity. *Agronomy Journal* 95 (3): 472-482.
 32. Sudduth, K. A., D. B. Myers, N. R. Kitchen, and S. T. Drummond. 2013. Modeling soil electrical conductivity–depth relationships with data from proximal and penetrating ECa sensors. *Geoderma* 199: 12-21.
 33. Sudduth, K. S., J. W. Hummel, N. R. Kitchen, and S. T. Drummond. 2000. Evaluation of a soil conductivity sensing penetrometer. Presented at the 2000 ASAE Annual International Meeting, Paper No.00 1043, American Society of Agricultural Engineers. 2950 Niles Road, St. Joseph, MI 49085-9659, USA.
 34. Toumelin, E., and C. Torres-Verdin. 2005. Influence of oil saturation and wettability on rock resistivity measurements: a uniform pore-scale approach. In *SPWLA 46th Annual Logging Symposium*. Society of Petrophysicists and Well-Log Analysts.
 35. Waxman, M. H., and L. J. M. Smits. 1968. Electrical conductivities in oil-bearing shaly sands. *Society of Petroleum Engineers Journal* 8 (02): 107-122.
 36. Wenner, F. 1915. A method for measuring earth resistivity. *Journal of the Washington Academy of Sciences* 5 (16): 561-563.
 37. Zarif Neshat, S., A. Rohani, M. Etefagh, and M. H. Saedi Rad. 2012. Predictions of apple bruise volume by using RBF artificial neural network and comparison it with regression. *Journal of Food Processing and Preservation* 4 (2): 45-65. (In Farsi).

Modeling the Effective Parameters on Accuracy of Soil Electrical Conductivity Measurement Systems Using RBF Neural Network

J. Baradaran Motie¹- M. H. Aghkhani^{2*}- A. Rohani³- A. Lakzian⁴

Received: 31-07-2017

Accepted: 18-09-2017

Introduction

Presently, the loss of ground water levels and the increase in dissolved salts have given importance to the determination of salinity and the management of their variations in irrigated farms. Soil electrical conductivity is an indirect method to measure soil salts. The direct electrode contact method (Wenner method) is one of the widely used methods to rapidly measure soil EC_a in farms. However, soil scientists prefer soil actual electrical conductivity (saturated extract electrical conductivity) (EC_e) as an indicator of soil salinity, though its measurement is only possible in the laboratory. The aim of this study was to find a relationship between the prediction of soil actual electrical conductivity (EC_e) in terms of temperature, moisture, bulk density and apparent electrical conductivity of soil (EC_a). Thereby, the estimation of EC_e would allow the partial calculation of EC_a that is dependent upon soil salinity and dissolved salts.

Materials and Methods

This study used RBF neural network in Box-Behnken statistical design to explore the impacts of effective parameters on direct contact method in the measurement of soil EC_a and provided a model to estimate EC_e from EC_a , temperature, moisture content and bulk density. In this study soil apparent electrical conductivity (EC_a) was measured by direct contact (Wenner) method. The present study considered four most effective factors: EC_a (saturated paste extract EC), moisture, bulk density, and temperature (Baradaran Motie *et al.*, 2010). Given the characteristics of farming soils in Khorasan Razavi Province (Iran), the maximum and minimum of each independent variable were assumed as 0.5-6 $mS.cm^{-1}$ for EC_e , 5-25% for moisture content, 1-1.8 $g.cm^{-3}$ for bulk density, and 2-37°C for soil temperature. Considering the experimental design, three moisture levels (5, 15 and 25%), three salinity levels (0.5, 3.25 and 6 $mS.cm^{-1}$), three temperature levels (2, 19 and 37°C) and three compaction levels with bulk densities of 1, 1.4 and 1.8 $g.cm^{-3}$ were assumed in 27 trials with predetermined arrangement on the basis of Box-Behnken technique. 13 common algorithms were explored in MATLAB software package for the training of the artificial neural network in order to find the optimum algorithm (Table 4). The input layer of the network designed by integrating a Randomized Complete Block Design (RCBD) with k-fold cross-validation. Using k-fold cross-validation, 20 different datasets were generated for training and validation of RBF neural network.

Results and Discussion

A combination of an RCBD and k-fold cross-validation was used. The results of both training and validation phases should be considered in the selection of training algorithm. In addition, R^2 of T1 training algorithm had a much lower standard deviation than other training algorithms. The lower standard deviation is, the more capable the algorithm would be in learning from different datasets. Considering all aspects, trainbr (T2) training algorithm was found to have the best performance among all 13 training algorithms of the neural network. Table 7 tabulates the results of means comparison for R^2 of RBF model for both training and validation phases resulted from the application of some combinations of S and L2 factors as interaction. As can be observed, $R^2 = 0.99$ for all of them with no significant difference. However, the magnitude of order differed between training and validation phases. Given the importance of the training phase, L2=9 and S=0.1 were regarded as the optimum

1- Phd Candidate Mechanic of Agriculture Machinery, Ferdowsi University of Mashhad

2- Professor, Mechanic of Biosystems Engineering, Ferdowsi University of Mashhad

3- Assistant Professor, Mechanic of Biosystems Engineering, Ferdowsi University of Mashhad

4- Professor, Soil Science, Ferdowsi University of Mashhad

(*- Corresponding Author Email: Aghkhani@um.ac.ir)

values.

The sensitivity analysis of the network revealed that soil EC_a, moisture, bulk density, and temperature had the highest to lowest impact on the estimation of soil EC_e, respectively. This model can improve the precision of soil EC_a measurement systems in the estimation and preparation of soil salinity maps. Furthermore, this model can save in time of data analysing and soil EC mapping because it does not need data recollection for the calibration of systems. A validation prose was done with a 60 field collected data set. The results of validation show $R^2=0.986$ between predicted and measured EC_a.

Conclusions

The present research focused on improving the precision of soil EC_e measurement on the basis of easily accessible parameters (EC_a, temperature, moisture, and bulk density). In conventional methods of soil EC mapping, the systems only measure soil EC_a and then calibrate it to EC_e by collecting some samples and using statistical methods. In this study, Soil EC_e was estimated with $R^2 = 0.99$ by a multivariate artificial neural network model with the inputs, including EC_a, temperature, moisture, and bulk density of soil without any need to collect further soil samples and calibration process. The Bayesian training algorithm was introduced as the best training algorithm for this neural network. Thereby, soil EC variation maps can be prepared with higher precision to estimate the spatial spread of salinity in farms. Also, the results imply that soil EC_a, moisture, bulk density and temperature have the highest to lowest effectiveness on the estimation of soil EC_e, respectively.

Keywords: Apparent electrical conductivity, Extract electrical conductivity, RBF neural network, Soil salinity