



دانشگاه گرجان و منابع طبیعی

نشریه پژوهش‌های تولید گیاهی

جلد بیست و ششم، شماره دوم، ۱۳۹۸

۴۷-۵۸

<http://jopp.gau.ac.ir>

DOI: 10.22069/jopp.2019.14351.2288

ارزیابی کارآیی مدل‌های شبکه عصبی مصنوعی در برآورد عملکرد اسانس گیاه مرزه تابستانه بر اساس ویژگی‌های زودیاخت خاک

حسین صبوری فرد^۱، *عظیم قاسم‌نژاد^۲، خدایار همتی^۲، ابوظالب هزارجریبی^۳ و محمودرضا بهرامی^۴
^۱دانش آموخته کارشناسی ارشد گروه علوم باغبانی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران، ^۲دانشیار گروه علوم باغبانی،
دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران، ^۳دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان،
گرگان، ایران، ^۴مدرس گروه مهندسی تولیدات گیاهی، دانشکده کشاورزی، دانشگاه فنی و حرفه‌ای خراسان رضوی، ایران
تاریخ دریافت: ۹۶/۰۹/۱۳؛ تاریخ پذیرش: ۹۷/۱۰/۱۱

چکیده

سابقه و هدف: یکی از نیازهای مهم در برنامه‌ریزی تولید و فرآوری گیاهان دارویی به منظور حصول عملکرد بالا و با کیفیت مطلوب، ارزیابی اولیه خصوصیات فیزیکی و شیمیایی خاک منطقه است که می‌توان با اجتناب از کاربرد غیرضروری آزمایش‌های متنوع خاکشناسی، هزینه تولید را به حداقل کاهش داد. مرزه تابستانه (*Satureja hortensis* L.) از جمله گیاهان دارویی پرکاربرد است که میزان اسانس و ترکیبات آن شاخص کیفی گیاه محسوب می‌شود. امروزه با ورود مدل‌های رگرسیونی چندمتغیره و مدل‌های شبکه مصنوعی در پژوهش‌ها، بسیاری از روابط پیچیده موجود در طبیعت قابل درک است. از این رو ضرورت برآورد عملکرد اسانس گیاه مرزه با استفاده از روش‌های سریع، کم‌هزینه و با دقتی قابل قبول احساس می‌گردد.

مواد و روش‌ها: این پژوهش به صورت طرح کاملاً تصادفی، در سه تکرار و به صورت گلدانی انجام شد. از مناطق مختلف شهرستان نیشابور ۵۳ نمونه خاک تهیه و پارامترهای زودیاخت آن که شامل ۱- درصد شن، ۲- درصد سیلت، ۳- درصد رس، ۴- مواد آلی، ۵- اسیدیته، ۶- شوری، ۷- فسفر، ۸- پتاسیم، ۹- نیتروژن، ۱۰- درصد کربن می‌باشد، در آزمایشگاه اندازه‌گیری و نتایج اولیه به دست آمد. تقریباً ۹۰ روز پس از کشت بذور در گلدان‌های حاوی نمونه‌های مختلف خاکی، نمونه‌گیری از آن‌ها صورت گرفت. سپس نمونه‌ها به مدت ۲۴ ساعت در آون ۴۰ درجه سانتی‌گراد قرار گرفتند تا خشک شوند. در نهایت رابطه‌های بین عملکرد اسانس گیاه مرزه و پارامترهای زودیاخت خاک با تجزیه شبکه عصبی مصنوعی و با استفاده از نرم‌افزار Matlab 7.9 مشخص گردید. برای به دست آوردن حساس‌ترین متغیرها، تجزیه حساسیت به روش ضریب بدون بعد حساسیت محاسبه گردید. به طوری که اگر مقدار ضریب حساسیت متغیری از ۰/۱ بیشتر باشد، آن متغیر جز متغیرهای حساس مدل محسوب شد.

یافته‌ها: شبکه عصبی مصنوعی از الگوی شبکه عصبی مصنوعی انسان شبیه‌سازی شده است، به گونه‌ای که می‌تواند پس از آموزش، متغیرهای خروجی موردنظر را با اعمال متغیرهای ورودی برآورد نماید. در این پژوهش، از ساختار شبکه عصبی پرسپترون با الگوریتم آموزشی مارکوآت لونبرگ استفاده شد تا عملکرد اسانس از متغیرهای زودیاخت خاک همچون بافت خاک، مواد آلی و عناصر پرمصرف برآورد شود. بالا بودن مقادیر R^2 و پایین بودن مقادیر RMSE یاد شده بیانگر نزدیک بودن داده‌های

* مسئول مکاتبه: aghasemnajad@hotmail.com

پیش‌بینی با داده‌های اندازه‌گیری و دقت بالای مدل در برآورد عملکرد اسانس گیاه مرزه تابستانه است. بر این اساس متغیرهای بافت خاک (درصد شن، سیلت و رس) و کربن آلی، ماده آلی، شوری، پتاسیم و اسیدپته خاک به ترتیب به‌عنوان حساس‌ترین متغیرها انتخاب گردید.

نتیجه‌گیری: نتایج نشان داد که مدل‌های عصبی ایجاد شده قادر نبودند عملکرد اسانس در گیاه مرزه تابستانه را با حداکثر دقت ($R^2=0/50$) برآورد نمایند. از بین ۸ مدل برازش‌یافته یک مدل مبتنی بر متغیرهای مستقل EC + بافت + کربن + ماده آلی + پتاسیم + pH عملکرد بهتری داشت، با این وجود تعداد بالای عوامل ورودی این مدل محدودیت تلقی می‌شود. از آنجایی که این پژوهش جزء اولین بررسی‌ها در مورد برآورد عملکرد اسانس گیاهان دارویی بود، بنابراین ادامه پژوهش و بررسی در این خصوص و همچنین پیش‌بینی عملکرد سایر گیاهان دارویی به این روش پیشنهاد می‌گردد.

واژه‌های کلیدی: بافت خاک، زیست‌توده، عملکرد، گیاهان دارویی

مقدمه

که ساختاری تهیه شود که همانند مغز قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد (۴ و ۱۰). از جمله موارد کاربرد شبکه‌های عصبی مصنوعی در علوم کشاورزی می‌توان به تخمین عملکرد زعفران بر اساس پارامترهای اقلیمی با استفاده از مدل‌های شبکه عصبی مصنوعی اشاره نمود (۱).

نخعی (۲۰۰۵) تخمین هدایت هیدرولیکی اشباع را با استفاده از منحنی توزیع اندازه ذرات بررسی کرد. بدین‌منظور از ۵ نوع بافت خاک مختلف شنی لومی، شن، لوم‌شنی، لوم‌رس شنی و لوم‌رس سیلتی که منحنی توزیع ذرات متفاوتی داشتند، استفاده کرده و هدایت هیدرولیکی را با استفاده از سطوح مختلف درصد عبور ذرات برآورد نمود (۷).

شبکه عصبی مصنوعی با ساختار پرسپترون چندلایه: ANN^۱ مدلی ریاضی است که توانایی مدل‌سازی و ایجاد روابط ریاضی غیرخطی برای درون‌یابی را دارد. این مدل با ساختار پرسپترون^۲ چندلایه به‌طورکلی از سه لایه و هر لایه از تعدادی واحد پردازشگر به‌نام نرون^۳ (سلول، واحد یا گره) تشکیل شده است (شکل ۱). اولین لایه هر شبکه را لایه


بشر از دیرباز فرآورده‌های دارویی با منشاء گیاهی را به‌عنوان عوامل مؤثر در التیام دردهای خویش به‌کار برده است. اما گیاهان متابولیت‌های ثانویه را به‌عنوان ابزار سازگاری بر اوضاع و پدیده‌های مختلف محیط‌زیست برای حفاظت از خود تولید می‌نماید. به همین دلیل زمانی که گیاه در وضعیت بوم‌شناسی متفاوتی قرار می‌گیرد کمیت و کیفیت متابولیت‌های ثانویه موجود در پیکر خود را در جهت سازگاری به این وضعیت‌ها تغییر می‌دهد. تأثیر عوامل محیطی بر گیاه و متابولیت‌های آن می‌تواند به دو صورت تدریجی (سیر تکامل) و آنی باشد. تغییرات آنی در مواد شیمیایی گیاهان، تحت‌تأثیر عوامل زنده و غیرزنده (آب، خاک و هوا) امری مسلم است و تأثیر این عوامل در درازمدت می‌تواند به صفات موروثی و قابل انتقال به نتایج تبدیل شود. در بین عوامل محیطی مؤثر در تولید متابولیت‌های ثانویه، خصوصیات فیزیکی و شیمیایی، عناصر غذایی و pH خاک از اهمیت بالایی برخوردار هستند (۸).

شبکه عصبی مصنوعی شبیه‌سازی از دستگاه عصبی انسان است و در واقع تقلیدی از مغز و شبکه اعصاب انسان است. در این شبکه سعی بر آن است

1- Artificial Neural Network
2- Preceptron
3- Neuron

طی فرآیند آزمون و خطا به دست می‌آیند. به طور معمول، نرون‌های هر لایه به همه نرون‌های لایه مجاور از طریق یک رابط 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.

ورودی گویند که در آن بردار داده‌های ورودی موردنظر 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




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

Fig. 1. Nerve network with multilayer perceptron structure.

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

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).

$$Net_j = \sum w_{ij} x_i + b_i \quad (1)$$



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

Fig. 2. Specifications of a neuron with its input and output vectors.

1- Bias

حد امکان کل فضای داده‌ها را پوشش دهند. بدیهی است که تعداد بیش‌تر الگوهای آموزشی قابلیت تعمیم شبکه را بالا می‌برد. هر چند آموزش، فرآیندی است که در طی زمان طولانی انجام می‌پذیرد، ولی پس از تعمیم به سرعت می‌تواند به‌ازای هر ورودی، خروجی متناظر با آن را ارائه نماید. به‌طورکلی 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 چندلایه و آموزش با سرپرستی استفاده گردیده است. آموزش با سرپرستی به دلیل موجود بودن متغیر خروجی (عملکرد اسانس گیاه مرزه)، انتخاب گردید.

آموزش شبکه‌های عصبی بر اساس ساختار پرسپترون چندلایه: مبنای آموزش شبکه‌های عصبی، تغییر وزن اتصالات شبکه جهت تولید خروجی مطلوب می‌باشد. شیوه عمل پرسپترون چندلایه 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^۹ به این علت انتخاب شده است.

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

که در آن، E_p مقدار خطاری الگوی P ، o_{pj} خروجی مطلوب و y_{pj} خروجی واقعی در j گره است.

نرون‌ها برای محاسبه خروجی خود (y_i) ، ورودی دریافتی را از یک تابع فعال‌سازی^۱ (آستانه) عبور می‌دهند. توابع فعال‌سازی دارای انواع مختلفی مانند توابع باینری^۲، سیگموئیدی^۳، تانژانت هیپربولیک^۴، خطی^۵ و گوسی^۶ می‌باشند. مرسوم‌ترین توابع در این زمینه تابع سیگموئیدی است که به‌صورت زیر می‌باشد.

$$y_i = f(\text{Net}_j) = \frac{1}{1 + \exp(-\text{Net}_j)} \quad (۲)$$

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 به‌ترتیب برابر با تعداد بردارهای ورودی و خروجی آن 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 به‌گون‌های 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. 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^۷ و الگوی آزمونی^۸ تقسیم می‌نمایند. الگوهای آموزشی باید تا

- 1- Activation function
- 2- Binary function
- 3- Sigmoid function
- 4- Tangent hyperbolic
- 5- Linear function
- 6- Gauss function
- 7- Train
- 8- Test

9- Back - Propagation

کشاورزی منطقه مطابق با تقسیم‌بندی دومارتن، خشک بیابانی سرد می‌باشد. متوسط دمای سالانه در دوره بلندمدت ۲۸ ساله، ۱۴/۴ درجه سانتی‌گراد و متوسط حداقل دما در سردترین ماه سال، ۳/۵- درجه سانتی‌گراد و میانگین بارندگی سالیانه ۲۳۲/۶ میلی‌متر و متوسط میزان تبخیر سالانه، ۲۱۲۲ میلی‌متر است. این طرح به صورت کاملاً تصادفی و در سه تکرار و به صورت گلدانی انجام شد. تیمار موردنظر خاک زراعی ۵۳ منطقه مختلف از شهرستان نیشابور بود که پس از انجام آزمایش‌های مختلف خاکشناسی در سه تکرار به گلدان‌های چهارکیلوگرمی منتقل شدند. برای اندازه‌گیری پارامترهای زودیافت خاک، مقادیر فراوانی نسبی ۱- اندازه ذرات خاک به روش هیدرومتری، ۲- کربن آلی از روش تیتراسیون، ۳- میزان فسفر قابل‌جذب از روش السن^۴، ۴- میزان پتاسیم قابل‌جذب با استفاده از دستگاه فلیم‌فوتومتر، ۵- ازت کل از روش کج‌لدال، ۶- میزان اسیدیته و ۷- شوری خاک به ترتیب از دستگاه pH متر و EC سنج استفاده شد (۲، ۶ و ۹).

کشت و عملیات داشت و برداشت: بذور مرزه تابستانه از مرکز تحقیقات کشاورزی تهیه شده و پنج عدد بذر در هر گلدان حاوی خاک ضدعفونی‌شده با قارچ‌کش بنومیل ۲ درصد کاشته شد. پس از عملیات آبیاری به روش بارانی در مرحله ۴ برگی تنک‌کردن انجام شد و یک بوته قوی‌تر نگه داشته شد. نمونه‌گیری از گیاهان تیمارهای مختلف در شرایط یکسان، ۹۰ روز پس از کاشت و در حالی که بیش از ۸۰ درصد بوته‌ها در مرحله گلدهی بودند، صورت گرفت.

اسانس‌گیری و تعیین درصد اسانس: نمونه‌های تهیه شده با دستگاه خردکن خرد شد. اسانس‌گیری با دستگاه کلونجر و با روش تقطیر با آب در شرایط کاملاً یکسان به مدت دو ساعت انجام شد. برای این

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^۱): این روش از پرکاربردترین 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 گرادین‌های مزدوج (gdm^۲): 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-لونیبرگ (LM^۳): اساس این روش حداقل کردن تابع خطا بر مبنای پارامترهای شبکه می‌باشد. از خصوصیات مهم این روش، سرعت همگرایی فوق‌العاده آن می‌باشد و تا به امروز جزء سریع‌ترین الگوریتم‌های آموزشی شبکه‌های عصبی شناخته شده است. در این پژوهش تلاش بر این است تا مدل شبکه عصبی‌ای برای برآورد عملکرد اسانس گیاه مرزه ارائه شود.

مواد و روش‌ها

پژوهش در مزرعه تحقیقاتی دانشکده کشاورزی نیشابور واقع در مدار ۳۶ درجه و ۱۵ دقیقه و طول جغرافیایی ۵۸ درجه و ۴۹ دقیقه می‌باشد. اقلیم

- 1- Steepest Descent
- 2- Conjugate Gradient
- 3- Marquardt Lovenberg

که در آن، X_n معرف داده نرمال شده، X معرف داده مشاهده‌ای، X_{mean} ، X_{min} و X_{max} به ترتیب معرف داده‌های مشاهده‌ای میانگین، حداکثر و حداقل می‌باشند. سپس پارامترهای زودیافت خاک به‌عنوان پارامترهای ورودی و عملکرد اسانس به‌عنوان خروجی شبکه در نظر گرفته شد. ۶۰ درصد داده‌ها (۳۱ نمونه خاک) جهت آموزش مدل، ۲۰ درصد داده‌ها (۱۰ پارامتر خاک) جهت انجام فرآیند اعتبارسنجی مدل و ۲۰ درصد (۱۰ پارامتر خاک) به‌عنوان داده‌های آزمون مدل انتخاب گردید. به‌منظور آموزش شبکه عصبی، از نرم‌افزار Matlab 7.9 شبکه MLP استفاده شد. فرآیند تجزیه و تحلیل حساسیت اطلاعات ارزشمندی درباره میزان حساسیت مدل به متغیرهای ورودی به آن در اختیار طراح و معمار مدل قرار می‌دهد. با شناسایی میزان تأثیر متغیرهای ورودی بر دقت پیش‌بینی مدل، می‌توان متغیرهای کم اثر را از شبکه حذف و مدل ساده‌تری را بسط و توسعه داد. به‌عبارتی دیگر برای آن‌که مشخص گردد که مقدار میزان اسانس از کدامیک از متغیرهای ۱۰ گانه (شامل درصد رس، سیلت و شن، مواد آلی، ...) تأثیر بیشتری پذیرفته و تغییر آن از حساسیت بیشتری برخوردار است، از تجزیه و تحلیل حساسیت استفاده می‌شود. در این پژوهش برای انجام تجزیه حساسیت مدل از ضریب بدون بعد حساسیت استفاده گردید (۳). همچنین برای ارزیابی و مقایسه عملکرد مدل‌های مختلف، از ضریب تبیین (R^2) و جذر میانگین مربعات خطا (RMSE) بین داده‌های اندازه‌گیری شده و پیش‌بینی شده استفاده شد. بیان RMSE به‌صورت رابطه ۵ می‌باشد.

$$RMSE = \frac{\sqrt{\sum (t-a)^2}}{N} \quad (5)$$

که در آن، a و t به ترتیب مقدار پیش‌بینی و اندازه‌گیری شده متغیر اسانس و N تعداد داده‌ها است.

منظور به‌ازای هر ۵۰ گرم از گیاه خشک پودر شده مرزه تابستانه مربوط به هر تیمار به همراه ۳۰۰ سی‌سی آب به بالن ۵۰۰ میلی‌لیتری اضافه شد، در اثر حرارت فشار بخار آب افزایش یافته و غده‌های حاوی اسانس شکسته شده و اسانس همراه با بخار آب وارد مبرد می‌شود. به‌علت سبک بودن اسانس نسبت به آب، آب و اسانس تشکیل دو فاز جداگانه داده و اسانس بالاتر از آب قرار می‌گیرد. برای جدا کردن آب از اسانس ابتدا آب تا حدی که قابل کنترل باشد تخلیه گردید و سپس اسانس داخل ظرف‌های شیشه‌ای ۵ میلی‌لیتری تخلیه شد، جهت تخلیه کامل اسانس ۲۰ دقیقه شیشه‌های حاوی اسانس زیر دستگاه قرار داده شدند تا اسانس به‌طور کامل تخلیه گردد و سپس آب اضافی اسانس توسط سرنگ برداشته شد و بلافاصله ظرف‌های شیشه‌ای حاوی اسانس به‌منظور جلوگیری از تابش نور فویل‌پیچی شدند و در یخچال قرار داده شدند. به‌منظور تعیین درصد اسانس از روش وزنی استفاده شد به این ترتیب که ابتدا ظرف شیشه‌ای کوچک و تمیز که در آن به وزن ثابت رسیده بود وزن شد و سپس ظرف‌های حاوی اسانس رطوبت‌زدایی شده دوباره توزین شدند و از تفاوت وزن ظرف خالی و ظرف حاوی اسانس، وزن اسانس به‌دست آمد، که به‌صورت درصد وزنی درصد گرم ماده خشک بیان شد (۸).

طراحی شبکه: در نهایت رابطه‌های بین عملکرد اسانس گیاه مرزه و پارامترهای زودیافت خاک با تجزیه شبکه عصبی مصنوعی مشخص شد. قبل از آموزش شبکه عصبی، داده‌های ورودی به آن باید استاندارد شوند. برای استاندارد کردن داده‌ها از رابطه ۴ استفاده شد:

$$X_n = 0.5 + 0.5 \left(\frac{X - X_{mean}}{X_{max} - X_{min}} \right) \quad (4)$$

درصد) می‌باشد. در عین حال ضریب تغییرات P در بین متغیرهای شیمیایی از همه بالاتر و برابر ۰/۹۳ است. مقادیر ضریب چولگی ارائه شده در جدول ۱ بیانگر این مطلب است که تمامی متغیرها به جز فسفر و ماده آلی و تا حدی EC و شن از توزیع نرمال برخوردارند و ضریب چولگی بین -۱ و +۱ قرار دارد. پارامترهای مذکور دارای توزیع لوگ نرمال بودند.

شبکه عصبی مصنوعی برای همه مدل‌ها، با الگوریتم آموزشی لونیگ مارکوآدرات به صورت یک لایه پنهان، تابع آستانه Logsig و برای لایه پنهان و Tansig برای لایه خروجی انتخاب گردید.

نتایج و بحث

توصیف آماری ویژگی‌های فیزیکی و شیمیایی خاک‌ها در جدول ۱ خلاصه شده است. همان‌گونه که در جدول ۱ مشاهده می‌شود، در بین متغیرهای شیمیایی، pH دارای کم‌ترین ضریب تغییرات (۰/۰۴)

جدول ۱- توصیف آماری خصوصیات شیمیایی و فیزیکی خاک‌ها.

Table 1. Statistical describe the chemical and physical properties of soils.

پارامتر Parameter	حداقل Minimum	حداکثر Maximum	میانگین Average	ضریب تغییرات Coefficient of variation	چولگی Skew
OM	0.11	3	0.9	0.61	1.45
C	0.01	1.6	0.57	0.56	0.32
EC	0.22	4.58	0.31	0.75	1.08
pH	7.1	8.5	7.6	0.04	0.65
N	0.002	0.15	0.05	0.47	0.95
P	0.55	33.6	5.73	0.93	2.58
K	144.5	600	383	0.27	-0.25
Clay	6	24	12	0.29	1.2
Silt	9	26	16	0.23	0.21
Sand	61	76	72	0.05	-1.02

پایین‌بودن مقادیر RMSE، بیانگر نزدیک بودن داده‌های پیش‌بینی با داده‌های اندازه‌گیری و دقت بالای مدل در برآورد عملکرد اسانس گیاه مرزه تابستانه است.

مدل‌سازی شبکه عصبی مصنوعی: در مدل‌سازی عملکرد اسانس با ۱۰ پارامتر برای ۵۳ نمونه خاک، مقادیر R² برای مراحل آموزش، اعتبارسنجی، آزمون و کل به ترتیب برابر ۰/۷۱، ۰/۷۲، ۰/۵۷۳ و ۰/۷۰۶ می‌باشد. مطابق جدول ۲، بالا بودن مقادیر R² و


جدول ۲- پارامترهای آماری محاسبه شده برای مراحل آموزش، اعتبارسازی، آزمون و کل در مدل ۱۰ پارامتره برای عملکرد اسانس.

Table 2. Statistical parameters calculated for the training, validation, test, and total stages in the 10-parameter model for essential oil performance.

مرحله stage	R ²	RMSE
آموزش Education	0.72	0.0441
اعتبارسازی Validation	0.72	0.0308
آزمون Test	0.573	0.0308
کل Total	0.706	0.0425

می‌دهد که این مدل هم نتیجه به نسبت خوبی در دقت دارد.

شکل ۳ شیب خط برازش داده شده و ضریب تبیین در مرحله آزمون برای عملکرد اسانس نشان



شکل ۳- مقادیر عملکرد اسانس اندازه‌گیری شده و پیش‌بینی شده توسط شبکه عصبی مصنوعی در مرحله آزمون مدل ۱۰ پارامتره.

Fig. 3. The essential oil yields measured and predicted by the artificial neural network at the test stage of the 10-parameter model.

جدول ۳ نتایج تجزیه حساسیت را نشان می‌دهد. هیل (۱۹۹۸) در پژوهش‌های خود بیان می‌کند که اگر مقدار ضریب حساسیت پارامتری بیش‌تر از ۰/۱ باشد، آن پارامتر جز پارامترهای حساس مدل محسوب می‌شود (۳). بر طبق نتایج هیل (۱۹۹۸)، در این

تجزیه حساسیت: بعد از مدل‌سازی عملکرد اسانس با ۱۰ پارامتر به وسیله شبکه عصبی مصنوعی و به دست آوردن بهترین شبکه از نظر پارامترهای آماری، برای به دست آوردن حساس‌ترین پارامترها، تجزیه حساسیت به روش ضریب بدون بعد حساسیت انجام شد (۳).

پارامترهای کربن آلی، نیتروژن، فسفر، ماده آلی، پتاسیم، اسیدیته، شوری، رس، سیلت و شن به ترتیب به عنوان حساس ترین پارامترها انتخاب گردید و چون عملکرد اسانس آزمایش هزینه بر و دشوار است از این رو تخمین با آسان ترین و کم هزینه ترین پارامتر (آزمایش) شروع شد و به تدریج برای این که دقت تخمین بالا برود پارامترها (آزمایش) بیش تر شد.

پژوهش، عملکرد اسانس به همه پارامترها حساس می باشد (۳). اما از آنجایی که هدف این پژوهش تخمین سریع عملکرد اسانس (با حداقل تعداد آزمایش و پارامترهای مورد نیاز) بود، بنابراین حساس ترین پارامترها در عملکرد اسانس مشخص و با آنها مدل سازی انجام شد. از پارامتر سیلت به بعد، ضریب حساسیت تغییر چندانی نکرد. از این رو

جدول ۳- نتایج تجزیه حساسیت پارامترهای زود یافت خاک.

Table 3. Analysis of sensitivity of soil readily available.

پارامتر Parameter	ضریب حساسیت نسبی Relative sensitivity
Silt	1
OM	0.9994
Sand	0.9947
PH	0.9945
C	0.9944
P	0.9938
K	0.9935
EC	0.9935
Clay	0.9932
N	0.9931

برخوردارند به ترتیب با افزایش تعداد پارامترهای ورودی و افزایش تعداد آزمایش انجام شده، مدل های شبکه عصبی مصنوعی مختلفی به صورت جدول ۴ ایجاد شد.

طراحی مدل های مختلف شبکه عصبی مصنوعی با پارامترهای آسان تر و روتین تر و کم هزینه تر: نظر به اهمیت بهره مندی از پارامترهای ورودی کم تر و در دسترس تر و هزینه های کم در این پژوهش برای برآورد عملکرد اسانس، از ۱۰ پارامتر زود یافت خاک که در برآورد عملکرد اسانس از حساسیت بیش تری

جدول ۴- طراحی مدل‌های مختلف شبکه عصبی مصنوعی بر اساس نتایج تجزیه حساسیت و حداقل تعداد آزمایش.

Table 4. Design an artificial neural network models based on sensitivity analysis results and minimum testing.

مدل Model	پارامتر ورودی Input parameter	تعداد آزمایش Number of tests
مدل ۱ Model 1	بافت خاک soil texture	1
مدل ۲ Model 2	کربن Carbon	1
مدل ۳ Model 3	بافت خاک + کربن Soil texture + carbon	2
مدل ۴ Model 4	بافت خاک + کربن + نیتروژن Soil texture + carbon + nitrogen	3
مدل ۵ Model 5	بافت خاک + کربن + ماده آلی + pH Soil texture + carbon + organic matter + pH	3
مدل ۶ Model 6	بافت خاک + کربن + ماده آلی + نیتروژن + pH Soil texture + carbon + organic matter + nitrogen + pH	4
مدل ۷ Model 7	EC + بافت خاک + کربن + ماده آلی + pH EC + soil texture + carbon + organic matter + pH	4
مدل ۸ Model 8	EC + بافت خاک + کربن + ماده آلی + پتاسیم + pH EC + soil texture + carbon + organic matter + potassium + pH	5
مدل ۹ Model 9	EC + بافت خاک + کربن + نیتروژن + فسفر + ماده آلی + پتاسیم + pH EC + soil texture + carbon + nitrogen + phosphorus + organic matter + potassium + pH	6

به صورت یک لایه پنهان، تابع آستانه Logsig و برای لایه پنهان و Tansig برای لایه خروجی انتخاب گردید. نتایج مدل‌ها در جدول ۵ آمده است. در شکل ۱ خط برازش داده شده بین داده‌های پیش‌بینی شده در مقابل داده‌ها اندازه‌گیری شده عملکرد اسانس در مرحله آزمون برای مدل‌های ۱ تا ۹ نشان داده شده است.

برآورد کلی از مدل‌های ۱ تا ۹ این است که با افزایش تعداد پارامترهای ورودی به مدل‌ها (مدل ۱ به مدل ۹)، مقادیر R^2 و RMSE در یک دید کلی دارای روند رو به بهبودی باشند بدین منظور که میزان R^2 افزایش و RMSE کاهش یافته است. در مدل‌سازی با شبکه عصبی مصنوعی، بهترین آرایش لایه پنهان با الگوریتم آموزشی لوببرگ مارکوف آدرات

جدول ۵- پارامترهای آماری محاسبه شده برای مراحل آموزش و آزمون.

Table 5. Statistical parameters calculated for the training and testing stages.

مدل Model	تعداد نرون Number of neurons	R^2 آموزش R^2 training	RMSE آموزش RMSE Training	R^2 آزمون R^2 test	RMSE آزمون RMSE test
مدل ۱ Model 1	45	0.69	0.041	0.138	0.089
مدل ۲ Model 2	45	0.299	0.066	0.253	0.068
مدل ۳ Model 3	50	0.551	0.057	0.344	0.064
مدل ۴ Model 4	45	0.56	0.052	0.36	0.067
مدل ۵ Model 5	45	0.58	0.067	0.38	0.085
مدل ۶ Model 6	50	0.60	0.062	0.45	0.065
مدل ۷ Model 7	45	0.58	0.048	0.39	0.079
مدل ۸ Model 8	50	0.62	0.051	0.50	0.056
مدل ۹ Model 9	45	0.48	0.061	0.31	0.055

عملکرد ضعیفی در برآورد اسانس از خود بروز داده و مدل ۸ نسبت به سایر مدل‌ها عملکرد بهتری از خود نشان داده است، ولی به دلیل تعداد پارامترهای ورودی زیاد مورد نیاز مدل ۸ پیشنهاد نمی‌گردد و بر لزوم ادامه پژوهش‌ها و بررسی‌های مشابه در این خصوص تاکید می‌گردد.

نتیجه‌گیری کلی

اگرچه استفاده از شبکه‌های عصبی مصنوعی دشوارتر از معادلات رگرسیونی است، ولی می‌توان با ایجاد برنامه‌های نرم‌افزاری به اصطلاح ساده، مشکل استفاده کاربران را حل نمود. از فرضیات اولیه

مقایسه نتایج مدل‌های طراحی شده با پارامترهای حساس: بررسی نتیجه‌های جدول ۴ نشان می‌دهد که اضافه شدن پارامترهای ورودی، باعث افزایش مقدار R^2 و کاهش مقدار RMSE در مراحل آموزش، اعتبارسازی و آزمون در عملکرد اسانس می‌شود که بیانگر بهبود دقت مدل، با افزایش تعداد پارامترهای ورودی در تخمین عملکرد اسانس می‌باشد که امری کاملاً بدیهی است. این نتیجه در پژوهش‌های شاپ و همکاران (۱۹۹۸)، شاپ و لیچ (۱۹۹۸)، موزن‌زاده و همکاران (۲۰۰۹) نیز مشاهده می‌شود (۵، ۱۱ و ۱۲). در نگاه کلی به مقایسه مدل‌های برآورد اسانس نیز براساس نتایج جدول ۵ بیان نمود که بیش‌تر مدل‌ها

هدف، یعنی برآورد عملکرد اسانس گیاه مرزه با پارامترهای حساس بیان شده میسر نبوده و بنابراین بررسی‌های پیش‌تر در این زمینه می‌تواند مفید واقع گردد. هر چند که می‌توان مانند چنین مطالعه‌ای با استفاده از شبکه‌های عصبی مصنوعی در مناطق دیگر و بر روی برآورد عملکرد سایر گیاهان دارویی دیگر نیز انجام داد.

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 نرمال‌شده و غیرهم‌راستا می‌باشد. در این پژوهش نخست همه عوامل، مورد بررسی قرار گرفتند و با توجه به مدل‌های ایجاد شده در شبکه عصبی، در یک جمع‌بندی کلی مشخص گردید که رسیدن به

منابع

1. Akbarpour, A., Khorashadizadeh, O., Shahidi, A. and Ghochanian, E. 2013. Performance evaluation of artificial neural network models in estimate production of yield saffron based on climate parameters. *J. Saff. Res.* 1: 1. 27-35.
2. Bremner, J.S. and Mulvaney, C.S. 1982. Nitrogen-total. In: A.L. Page (Ed.), *Methods of Soil Analysis, Part 2.* American Society of Agronomy. Madison, Wisconsin, Pp: 595-624.
3. Hill, M. 1998. *Methods and guidelines for effective model calibration.* U.S. Geological survey Water- Resources Investigations Rep. 98-4005.
4. Menhaj, M.B. 2001. *Computational intelligence, fundamentals of neural networks.* 2nd d., Amir Kabir University of Technology, Tehran: Iran. (In Persian)
5. Moazenzadeh, R., Ghahraman, B., Fathalian, F. and Khoshnoodyazdi, A.A. 2009. Effect of type and number of input variables on moisture retention curve and saturated hydraulic conductivity prediction. *J. Water. Soil.* 23: 3. 57-70. (In Persian)
6. Movahedi Naiini, A. 2008. *Soil physics (foundations and applications).* Gorgan University of Agricultural Sciences and Natural Resources. Press, 304p. (In Persian)
7. Nakhaei, M. 2005. Estimating the saturated hydraulic conductivity of granular material, using Artificial Neural Network, based on grain size distribution curv. *Sci. I. R. Iran. J.* 16: 1. 55-62.
8. Omidbaigi, R. 2005. *Production and processing of medicinal plants.* Astane Quds Publ. Tehran, 438p. (In Persian)
9. Page, A., Miller, R. and Keeney, D. 1982. *Methods of Soil Analysis.* 2th ed. Part 2: Chemical and biological properties. Soil. Sci. Soc. Am. Inc. Publisher.
10. Rao, V. and Rao, H. 1996. *C⁺⁺ Neural networks and fuzzy logic.* BPB, New Dehli, India, Pp: 380-381.
11. Schaap, M. and Leij, F. 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil. Till. Res.* 47: 37-42.
12. Schaap, M., Leij, F. and Van Genuchten, M. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *Soil Sci. Soc. Am. J.* 62: 847-855.