



برآورد عملکرد بیومس گیاه مرزه تابستانه با استفاده از پارامترهای زودیافت خاک و شبکه

عصبی مصنوعی

حسین صبوری فرد¹ - عظیم قاسم نژاد^{2*} - خدایار همتی³ - ابوطالب هزارجریبی⁴ - محمودرضا بهرامی⁵ - فهیمه نصرتی⁶

تاریخ دریافت: 1393/02/15

تاریخ پذیرش: 1396/02/13

چکیده

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 آزمایشات 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. هدف از این پژوهش برآورد عملکرد بیومس گیاه مرزه تابستانه با استفاده از پارامترهای زودیافت خاک شامل: بافت خاک، مواد آلی، pH، EC، فسفر، پتاسیم، نیتروژن و درصد کربن با بهره‌گیری از شبکه عصبی مصنوعی می‌باشد. بدین منظور 53 نمونه از خاک زراعی شهرستان نیشابور جمع‌آوری و پس از انجام آزمایشات ویژگی‌های زودیافت خاک نتایج اولیه بدست آمد. بر پایه نتایج تجزیه حساسیت، کربن آلی، نیتروژن، فسفر، ماده آلی، پتاسیم، اسیدیته، شوری، رس، سیلت و شن به ترتیب به عنوان پارامترهای حساس در برآورد عملکرد بیومس بودند. در نهایت به منظور تخمین سریع و کم هزینه عملکرد بیومس، با استفاده از پارامترهای حساس، مدل‌های گوناگون طراحی شدند. نتایج نهایی مقایسه مدل‌ها نشان داد که بهترین مدل از نظر دقت و سرعت تخمین عملکرد بیومس مدلی بود که از ورودی با پارامتر بافت خاک و کربن آلی استفاده شد.

واژه‌های کلیدی: بافت خاک، فرآوری گیاهان دارویی، خصوصیات خاک

مقدمه

و میزان مواد موثره گیاه دارند، تغییر ایجاد نمود (12). لیکن روابط بین کمیت و کیفیت گیاهان دارویی در برابر خصوصیات فیزیکی و شیمیایی خاک بسیار پیچیده بوده و عمل تخمین تغییرات خصوصیات کیفی گیاهان دارویی تحت تاثیر پارامترهای خاک را با مشکل روبرو می‌کند. امروزه با ورود مدل‌های رگرسیون چند متغیره و مدل‌های شبکه مصنوعی در تحقیقات بسیار از روابط پیچیده موجود در طبیعت را پیدا شده است. به گونه‌ای که تخمین‌های قابل قبولی از یک پارامتر سخت یافت و پر هزینه از روی برخی از پارامترهای زودیافت ممکن شده است. 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 که ساختاری تهیه شود که همانند مغز قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد (9 و 13). در این گونه ساختارها هدف این است که با معرفی عملکرد یک سیستم دینامیکی، مدل را آموزش داده، نحوه عملکرد سیستم را در حافظه مدل ذخیره می‌گردد و از آن برای مواردی که قبلاً با آن مواجه نشده، استفاده شود. کاربرد این سیستم‌ها در ایران و به خصوص در علوم کشاورزی در آغاز راه است. اما به دلیل توانایی آن‌ها

در حال حاضر تقاضای روزافزونی برای داروهای با منشأ طبیعی وجود دارد که عمدتاً به دلیل طیف گسترده فواید زیست‌شناختی، بر خورداری این داروها از خاصیت امنیت غذایی بیشتر، سازگاری بهتر با بدن و قیمت ارزان‌تر آن‌ها نسبت به داروهای شیمیایی است. خصوصیات فیزیکی و شیمیایی، عناصر غذایی و اسیدیته خاک از جمله عوامل محیطی موثری هستند که در بیوسنتز متابولیت‌های ثانویه گیاهان دارویی از اهمیت والایی برخوردارند. لذا زمانی می‌توان روند افزایشی در کمیت و کیفیت گیاهان دارویی انتظار داشت که بتوان در میزان عناصر غذایی خاک که نقش موثری در رشد و نمو

1، 2 و 3 - به ترتیب دانش‌آموخته کارشناسی ارشد، استادیار و دانشیار گروه علوم

باغبانی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

* - نویسنده مسئول: (Email: Sabouri@tvu.ac.ir)

4 - استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

5- دانشجوی دکتری فیزیولوژی گیاهان زراعی، دانشگاه فردوسی مشهد

6- دانش‌آموخته کارشناسی ارشد، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

سازی عملکرد بیومس گیاه مرزه تابستانه انجام نشده است. این پژوهش به منظور تعیین حداقل پارامترهای ورودی موثر در تعیین عملکرد بیومس این گیاه با استفاده از شبکه عصبی مصنوعی و کاربرد این نوع شبکه‌ها برای برآورد عملکرد بیومس مرزه تابستانه با استفاده از پارامترهای زود یافت خاک صورت گرفته است.

مواد و روش‌ها

این پژوهش در سال 1391 در مزرعه تحقیقاتی دانشکده کشاورزی نیشابور و بصورت طرح کاملاً تصادفی و در سه تکرار و بصورت گلدانی انجام شد. از مناطق مختلف شهرستان نیشابور 53 نمونه خاک در سه تکرار تهیه شده و پس از انجام آزمایشات مختلف خاکشناسی در آنها گیاه مرزه کاشته شد. برای اندازه‌گیری پارامترهای زودیافت خاک، مقادیر فراوانی نسبی اندازه ذرات خاک به روش هیدرومتری (4)، کرن آلی از روش تیتراسیون (5)، میزان فسفر قابل جذب از روش السن¹، میزان پتاسیم قابل جذب با استفاده از دستگاه فلیمفومتر، ازت کل از روش کجلدال (3)، میزان اسیدیته و شوری خاک به ترتیب از دستگاه pH متر و EC سنج استفاده شد.

کشت و عملیات داشت و برداشت: بذور مرزه تابستانه از مرکز تحقیقات کشاورزی نیشابور تهیه و پس از ضدعفونی خاک‌های جمع‌آوری شده با قارچ کش بنومیل 2 درصد در هر گلدان 5 عدد بذر کشت شد. پس از عملیات آبیاری به روش بارانی در مرحله 4 برگی تنک کردن انجام شد و یک بوته قوی تر نگه داشته شد. نمونه‌گیری از گیاهان تیمارهای مختلف در شرایط یکسان، 90 روز پس از کاشت صورت گرفت. به منظور تعیین وزن تر و خشک از ترازوی دیجیتال 0/001 استفاده شد و برای خشک‌نمودن نمونه‌ها جهت اندازه‌گیری وزن خشک آن‌ها از دمای 40 درجه سانتی‌گراد در آون بمدت 24 ساعت استفاده شد.

طراحی شبکه: در نهایت رابطه‌های بین عملکرد بیومس گیاه مرزه و پارامترهای زودیافت خاک با تجزیه شبکه عصبی مصنوعی مشخص شد. قبل از آموزش شبکه عصبی، داده‌های ورودی به آن استاندارد شدند. برای استاندارد نمودن داده‌ها از رابطه 1 استفاده شده است:

$$X_n = 0.5 + 0.5 \left(\frac{X - X_{\text{mean}}}{X_{\text{max}} - X_{\text{min}}} \right) \quad \text{رابطه 1}$$

که در آن: X_n معرف داده نرمال شده، X معرف داده‌ی مشاهده-ای، X_{mean} ، X_{min} و X_{max} به ترتیب معرف داده‌های مشاهده‌ای میانگین، حداکثر و حداقل می‌باشند. سپس پارامترهای زودیافت خاک به عنوان پارامترهای ورودی و عملکرد بیومس به عنوان خروجی شبکه در نظر گرفته شد. 60 درصد داده‌ها (53 نمونه خاک) جهت

در مدل‌سازی فرآیندهای بسیار پیچیده که تعداد عوامل تاثیرگذار زیادی دارند، امکان استفاده گسترده از آن در علوم کشاورزی وجود دارد. اغلب مطالعات شبکه مصنوعی در زمینه تخمین عملکرد در گیاهان استراتژیک همچون گندم انجام شده است به عنوان مثال شاپ و همکاران (15) بیان کردند که یکی از مزیت‌های استفاده از شبکه‌های عصبی مصنوعی نسبت به مدل‌های قدیمی این است که نیازمند تعیین یک تابع خاص برای بیان رابطه میان داده‌های ورودی و خروجی نیست. وو و یین (18) نیز از دو روش شبکه‌های عصبی مصنوعی و رگرسیون چندمتغیره برای پیش‌بینی عملکرد گندم در ارتباط با مصرف کود ازته استفاده کردند و نشان دادند که استفاده از شبکه‌های عصبی مصنوعی روش جایگزین مناسبی برای تجزیه و تحلیل رگرسیونی می‌باشد. اسمیت و همکاران (16) مشاهده کردند که عملکرد پیش‌بینی شده گندم در مرحله طویل شدن ساقه 46 درصد تغییرات عملکرد واقعی را توضیح داد درحالی‌که عملکرد پیش‌بینی شده در مرحله گرده افشانی 56 درصد این تغییرات را توضیح می‌داد. به عبارتی دیگر با پیشرفت دوره رشد و وارد شدن تعداد بیشتری از عوامل موثر بر عملکرد درمدل، دقت مدل پیش‌بینی در پیش‌بینی عملکرد افزایش یافت. پژوهش‌ها نشان می‌دهند که در شرایط دیم؛ عوامل جوی تعیین‌کننده عملکرد می‌باشند، اما لوبل و همکاران (8) با استفاده از روش‌های رگرسیونی چندمتغیره نشان دادند که در شرایط کشت گندم آبی مدیریت زراعی عامل اصلی تعیین‌کننده عملکرد گندم بود. دراموند و همکاران (4) جهت تعیین روابطی میان خصوصیات خاک، توپوگرافی و عملکرد غلات در منطقه میسوری آمریکا مطالعاتی را انجام دادند و مشاهده نمودند که روش شبکه‌های عصبی مصنوعی نسبت به روش‌های رگرسیونی دارای خطای کمتری می‌باشد. کاول و همکاران (7) و آوارز (1) شبکه‌های عصبی مصنوعی را جهت تعیین بازده گیاه گندم در منطقه پامپاس آرژانتین به کار برد. وی نسبت بارندگی به تبخیر و تعرق پتانسیل محصول را به عنوان مهمترین فاکتور آب و هوایی موثر بر بازده این محصول معرفی نمود. نوروزی (11) از شبکه‌های عصبی و مصنوعی به منظور پیش‌بینی عملکرد گندم دیم در مناطق نیمه‌خشک و کوهستانی غرب ایران استفاده نمودند و بیان داشتند که شاخص انتقال رسوب مهمترین عامل توپوگرافی بر میزان عملکرد این گیاه بوده و میزان پروتئین موجود در دانه‌ها تحت تاثیر میزان نیتروژن کل خاک می‌باشد. کاول و همکاران (7) به بررسی کارایی مدل‌های شبکه عصبی در تخمین ذرت علوفه‌ای و سویا در منطقه مریلند پرداختند. نتایج این تحقیق نشان داد که مدل‌های شبکه‌عصبی نسبت به مدل‌های رگرسیونی از دقت بیشتری برخوردارند. کاربرد این مدل‌ها برای تخمین میزان محصول در گیاه ذرت علوفه‌ای و سویا در اقلیم منطقه مریلند مناسب ارزیابی شد. تاکنون مطالعه‌ای در زمینه کاربرد مدل‌های شبکه عصبی مصنوعی در شناسایی حداقل پارامترهای ورودی مورد نیاز برای شبیه

جدول 1- توصیف آماری خصوصیات شیمیایی و فیزیکی خاکها

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

پارامتر	حداقل	حداکثر	میانگین	ضریب تغییرات	چولگی
Parameter	Minimum	Maximum	Average	Coefficient of variation	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

تجزیه حساسیت: بعد از مدل سازی عملکرد بیومس با 10 پارامتر بوسیله شبکه عصبی مصنوعی و بدست آوردن بهترین شبکه از نظر پارامترهای آماری، برای بدست آوردن حساس ترین پارامترها، تجزیه حساسیت به روش ضریب بدون بعد حساسیت (6) انجام شد. جدول 2 نتایج تجزیه حساسیت را نشان می دهد. هیل (6) در پژوهش های خود بیان می کند که اگر مقدار ضریب حساسیت پارامتری از 0/1 بیشتر باشد، آن پارامتر جز پارامترهای حساس مدل محسوب می شود. بر طبق نتایج هیل (6)، در این پژوهش، عملکرد بیومس به همه پارامترها حساس می باشد. اما از آنجایی که هدف این پژوهش تخمین سریع عملکرد بیومس (با حداقل تعداد آزمایش و پارامترهای مورد نیاز) بود، بنابراین حساس ترین پارامترها در عملکرد بیومس مشخص و با آن ها مدل سازی انجام شد. از پارامتر سیلت به بعد، ضریب حساسیت تغییر چندانی نکرد. از این رو پارامترهای کربن آلی، نیتروژن، فسفر، ماده آلی، پتاسیم، اسیدیته، شوری، رس، سیلت و شن به ترتیب به عنوان حساس ترین پارامترها انتخاب گردید.

جدول 2- نتایج تجزیه حساسیت پارامترهای زود یافت خاک

Table 3- Analysis of sensitivity of soil readily available

پارامتر	ضریب حساسیت نسبی
Parameter	Relative sensitivity
C	1
N	0.866
P	0.807
OM	0.804
K	0.711
PH	0.677
EC	0.656
Clay	0.646
Silt	0.602
Sand	0.600

طراحی مدل های مختلف شبکه عصبی مصنوعی با پارامترهای

آموزش مدل، 20 درصد داده ها (10 پارامتر خاک) جهت انجام فرآیند اعتبارسنجی مدل و 20 درصد (10 پارامتر خاک) به عنوان داده های آزمون مدل انتخاب گردید. به منظور آموزش شبکه عصبی، از نرم افزار Matlab7.9 شبکه MLP استفاده شد. در این پژوهش برای انجام تجزیه حساسیت مدل از ضریب بدون بعد حساسیت (6) استفاده گردید. همچنین برای ارزیابی و مقایسه عملکرد مدل های مختلف، از ضریب تبیین (R^2) و جذر میانگین مربعات خطا (RMSE) بین داده های اندازه گیری شده و پیش بینی شده استفاده شد. بیان ریاضی آماره RMSE به صورت رابطه 2 می باشد.

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

که در آن، t و a به ترتیب مقدار پیش بینی و اندازه گیری شده پارامتر بیومس و N تعداد داده ها است.

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

نتایج و بحث

توصیف آماری ویژگی های فیزیکی و شیمیایی خاکها در جدول 1 خلاصه شده است. تغییر پذیری خاک، عنصر کلیدی در مدیریت ویژه مکانی خاک است و اطلاعات ارزشمندی در زمینه ذات و سرشت خصوصیات خاک درون مزرعه در اختیار ما قرار می دهد (2). همان گونه که در جدول 1 مشاهده می شود، در بین متغیرهای شیمیایی، pH دارای کمترین ضریب تغییرات (0/04 درصد) می باشد. در عین حال ضریب تغییرات P در بین متغیرهای شیمیایی از همه بالاتر و برابر 0/93 است. مقادیر ضریب چولگی ارائه شده در جدول 1 موید این مطلب است که تمامی متغیرها به جز پارامتر فسفر از توزیع نرمال برخوردارند و ضریب چولگی بین -1 و +1 قرار دارد. پارامترهای مذکور دارای توزیع لوگ نرمال بودند.

مدل سازی شبکه عصبی مصنوعی: در مدل سازی عملکرد بیومس با 10 پارامتر برای 53 نمونه خاک، بهترین آرایش لایه پنهان با الگوریتم آموزشی لونیگ-مارکوارت به صورت یک لایه پنهان، 58 نرون، تابع آستانه Logsig برای لایه پنهان و Tansig برای لایه خروجی انتخاب گردید. مقادیر R^2 برای مراحل آموزش، اعتبارسنجی، آزمون و کل به ترتیب برابر 0/710، 0/700، 0/694 و 0/708 می باشد. بالا بودن مقادیر R^2 و پایین بودن مقادیر RMSE یاد شده بیانگر نزدیک بودن داده های پیش بینی با داده های اندازه گیری و دقت بالای مدل در برآورد عملکرد بیومس گیاه مرزه تابستانه است.

برخوردارند به ترتیب با افزایش تعداد پارامترهای ورودی و افزایش تعداد آزمایش انجام شده، مدل‌های شبکه عصبی مصنوعی مختلفی به صورت جدول 3 ایجاد شد.

حساس: همان‌طور که از قبل اشاره شد، هدف از انجام این پژوهش برآورد عملکرد بیومس گیاه مرزه تابستانه با پارامترهای ورودی کمتر و در دسترس‌تر و همچنین هزینه کم‌تر است. بنابراین با 10 پارامتر زود یافت خاک که در برآورد عملکرد بیومس از حساسیت بیشتری

جدول 3- طراحی مدل‌های مختلف شبکه عصبی مصنوعی بر اساس نتایج تجزیه حساسیت و حداقل تعداد آزمایش

Table 3- 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 1 Model 1	بافت خاک soil texture	1
مدل 2 Model 2	کربن Carbon	1
مدل 3 Model 3	بافت خاک + کربن Soil texture + carbon	2
مدل 4 Model 4	بافت خاک + کربن + نیتروژن Soil texture + carbon + nitrogen	3
مدل 5 Model 5	بافت خاک + کربن + ماده آلی + pH Soil texture + carbon + organic matter + pH	3
مدل 6 Model 6	بافت خاک + کربن + ماده آلی + نیتروژن + pH Soil texture + carbon + organic matter + nitrogen + pH	4
مدل 7 Model 7	EC + بافت خاک + کربن + ماده آلی + pH EC + soil texture + carbon + organic matter + pH	4
مدل 8 Model 8	EC + بافت خاک + کربن + ماده آلی + پتاسیم + pH EC + soil texture + carbon + organic matter + potassium + pH	5
مدل 9 Model 9	EC + بافت خاک + کربن + نیتروژن + فسفر + ماده آلی + پتاسیم + pH EC + soil texture + carbon + nitrogen + phosphorus + organic matter + potassium + pH	6

پارامترهای ورودی به مدل‌ها (مدل 1 به مدل 9)، 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 لوبنبرگ مارکوف‌آدرات به صورت یک لایه پنهان، تابع آستانه Logsig و برای لایه پنهان و Tansig برای لایه خروجی انتخاب گردید. نتایج مدل‌ها در جدول 5 آمده است. در شکل 1 خط برازش داده شده بین داده‌های پیش‌بینی شده در مقابل داده‌ها اندازه‌گیری شده عملکرد بیومس در مرحله آزمون برای مدل‌های 1 تا 9 نشان داده شده است.

مقایسه نتایج مدل‌های طراحی شده با پارامترهای حساس: بررسی نتیجه‌های جدول 5 نشان می‌دهد که اضافه شدن پارامترهای ورودی، باعث افزایش مقدار R^2 و کاهش مقدار RMSE در مراحل آموزش، اعتبارسازی و آزمون در عملکرد بیومس می‌شود که حاکی از بهبود دقت مدل، با افزایش تعداد پارامترهای ورودی در تخمین عملکرد بیومس می‌باشد که امری کاملاً بدیهی است. این نتیجه در تحقیقات شاپ و همکاران (15)، شاپ و لیچ (14)، مؤذن‌زاده و همکاران (10)

در مدل (1) با زود یافت‌ترین پارامترها (درصد شن، رس و سیلت) که از آزمایش بافت خاک بدست می‌آید مدل شبکه عصبی مصنوعی مختلفی ایجاد می‌گردد.

در مدل (2) با توجه به حداکثر بودن ضریب حساسیت کربن آلی فقط پارامتر کربن آلی بعنوان مدل شبکه عصبی مصنوعی ایجاد می‌گردد.

در مدل (3) علاوه بر پارامترهای بافت خاک، کربن آلی نیز به مدل (1) اضافه می‌شود.

در مدل (4) پارامتر نیتروژن، به مدل (3) افزوده شد.

در مدل (5) پارامتر ماده آلی و اسیدیته به مدل (3) افزوده شد.

در مدل (6) پارامتر نیتروژن به مدل (5) اضافه شد.

در مدل (7) پارامتر شوری به مدل (5) افزوده و مورد بررسی قرار گرفت.

در مدل (8) پتاسیم به مدل (7) اضافه شد.

در مدل (9) پارامترهای نیتروژن و فسفر به مدل (8) افزوده و مدل جدیدی از شبکه ایجاد شد.

انتظار کلی از مدل‌های 1 تا 9 این است که با افزایش تعداد


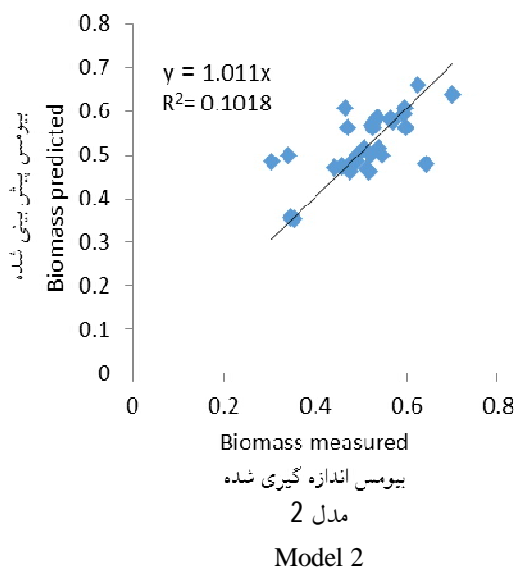
نیز مشاهده می‌شود. مدل‌های 1 و 2 برای برآورد بیومس دارای عملکردی ضعیف می‌باشند. با افزایش تعداد آزمایشات مورد نیاز از 1 به 2، عملکرد شبکه عصبی مدل 3 به یکباره بهبود قابل توجهی می‌یابد. لیکن همچنان نیازمند عملکرد بهتری می‌باشیم.


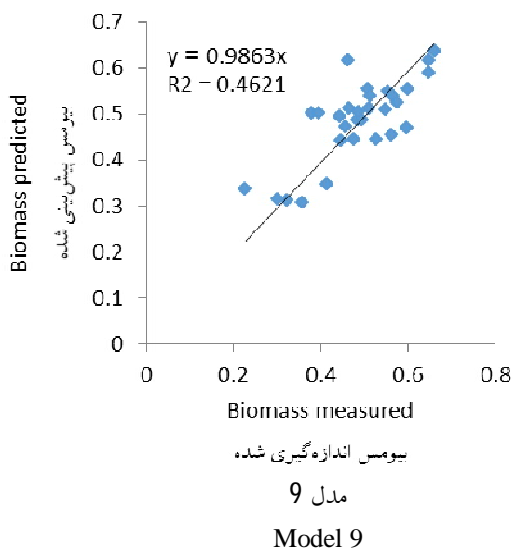



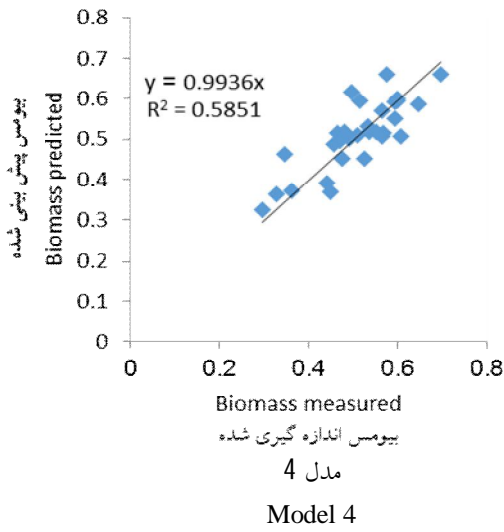
جدول 5- پارامترهای آماری محاسبه شده برای مراحل آموزش و آزمون
Table 5- Statistical parameters calculated for the training and testing stages

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 1 Model 1	45	0.713	0.046	0.119	0.075
مدل 2 Model 2	45	0.388	0.065	0.101	0.068
مدل 3 Model 3	50	0.633	0.057	0.584	0.062
مدل 4 Model 4	45	0.63	0.054	0.58	0.053
مدل 5 Model 5	45	0.65	0.068	0.59	0.079
مدل 6 Model 6	50	0.67	0.056	0.60	0.057
مدل 7 Model 7	45	0.65	0.054	0.59	0.053
مدل 8 Model 8	50	0.68	0.049	0.061	0.068
مدل 9 Model 9	45	0.61	0.051	0.46	0.064

بودن کاربرد شبکه عصبی در برآورد عملکرد بیومس با استفاده از پارامترهای خاک بوده ولی همچنان جهت دسترسی به نتایج قطعی ادامه تحقیقات مشابه در این خصوص پیشنهاد می‌گردد.

مدل‌های 3 تا 9 دارای عملکرد تقریباً مشابهی می‌باشند. لیکن مدل شماره 3 با یک دید کلی بعنوان یک مدل بهینه انتخاب می‌گردد زیرا با تعداد پارامتر ورودی حداقل دارای عملکردی نزدیک به سایر مدل‌ها با تعداد پارامتر بیشتر بود. بررسی نتایج حاکی از امیدبخش





نتیجه گیری کلی

کربن و عناصر غذایی خاک بستگی دارد. در این تحقیق نشان داد که پارامترهای بافت خاک و کربن به ترتیب بعنوان مهمترین فاکتورهای موثر بر عملکرد بیومس در منطقه نیشابور هستند. نتایج بدست آمده در این مطالعه تنها برای منطقه مورد مطالعه و دیگر مناطق مشابه از نظر توپوگرافی، اقلیم، خاک و عملیات مدیریتی قابل استفاده است. هر چند که می توان نظیر چنین مطالعه ای با استفاده از شبکه های عصبی مصنوعی در مناطق دیگر نیز انجام داد.

نتایج نشان داد که روش شبکه عصبی مصنوعی دقت بالایی در برآورد عملکرد بیومس گیاه مرزه تابستانه دارد، به گونه ای که 80 درصد (ضریب تبیین در مرحله آزمون) تغییر پذیری عملکرد بیومس در منطقه مورد مطالعه را با استفاده از 10 خصوصیت زودیافت خاک نشان می دهد. عملکرد بیومس گیاه مرزه تا حد زیادی به بافت خاک، ماده آلی،

منابع

- 1- Alvarez, A. 2009. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *Eur J. Agron.* 30: 70-77.
- 2- Ayoubi S., Khormali F., and Sahrawat K. 2009. Relation of barley biomass and grain yields to soil properties within a field in the arid region: Use of factor analysis. *Acta. Agr. Scand.* 59(2):107-117.
- 3- 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 (pp. 595-624). Madison, Wisconsin.
- 4- Drummond S.T., Sudduth K.A., Joshi A., Birrell S.L., and Kitchen N.R. 2003, *Statistical and Neural Methods for Site-specific Yield Prediction*, *Transactions of the American Society of Agricultural Engineering*, 46(1): 5-14.
- 5- Gee G.W., and Bauder J.W. 1986. Particle size analysis. P 383-411, In: *Methods of soil analysis. Part 1.* 2nd ed. Klute, A. (Ed). *Agron. Monogr. 9.* ASA. Madison. WI.
- 6- Hill M. 1998. *Methods and guidelines for effective model calibration.* U.S. Geological survey Water- Resources Investigations Rep. 98-4005.
- 7- Kaul M., Hill R.L., and Walthall C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agriculture Systems*, 85:1-18.
- 8- Lobell D.B., Ortiz-Monasterio J.I., Addams C.L., and Asner G.P. 2002. Soil, climate, and management impacts on regional wheat productivity in Mexico from remote sensing. *Agricultural and Forest Meteorology*, 114: 31-43.
- 9- Menhaj M.B. 2001. *Computational intelligence, fundamentals of neural networks.* 2nd d., Amir Kabir University of Technology, Tehran: Iran. (in Persian)
- 10- Moazen zadeh 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 and Soil.* 23: 3. 57-70. (in Persian)
- 11- Norouzi M., 2009. Prediction of rainfed wheat yield using artificial neural network in Ardal district of Chaharmahal and Bakhtiari province. M.Sc. Thesis, Collage of iculture, Isfahan University of Technology, Isfahan, Iran, 112 p. (in Persian)
- 12- Omidbaigi R. 2005. *Production and processing of medicinal plants Vol. 2* Astane Quds Publ. Tehran, 438p. (in Persian)
- 13- Rao V., and Rao H. 1996. *C++ Neural networks and fuzzy logic*, BPB, New Dehli, India, pp: 380-381.
- 14- Schaap M., and Leij F. 1998. Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil and Till Res.* 47: 37-42.
- 15- Schaap M.G., and Bouten W. 1996. Modelling water retention curves of sandy soils using neural networks. *Water Resou. Res.* 32:3033-3040.
- 16- Smith R.C.G., Adams J., Stephens D.J. and Hick P.T. 1995. Forecasting wheat yield in a Mediterranean-type environment from the NOAA satellite. *Australian Journal of Agricultural Research*, 46(1): 113-125.
- 17- Walkley A., and Black I.A. 1934. An examination of the Degtjareff method for determining soil organic matter and a proposed modification of the chromic acid titration method. *Soil Sci.* 37: 29-39.
- 18- Wu F.Y., and Yen K. K. 1992. Application of neural network in regression analysis. *Computers and Industrial Engineering.* 23: 93-95.



Assessment of Summe Savory (*satureja hortensis* L.) Biomass by Easily-Attainable Soil Parameters and Artificial Network

H. Sabourifard¹ - A. Ghasemnezhad² - Kh. Hemmati³ - A. Hezarjeribi⁴, M.R. Bahrami⁵ - F. Nosrati⁶

Received: 05-05-2014

Accepted: 03-05-2017

Introduction: One of the most important requirements in planning production and processing of medicinal plants in order to obtain high yield and high-quality is the initial assessment of the physical and chemical properties of soil, which reduces the production cost by avoiding the use of unnecessary soil analysis. Summer savory (*Satureja hortensis* L.) is one of the most widely used medicinal plants that quality index of plant is related to the quantity and the constituent of its essential oil content. Understanding the relations between the quantity and quality of medicinal plants with the very physical and chemical properties of soil is very complex and the estimation of parameters changes of medicinal plants affect by soil quality characteristics is more difficult. Today, with the arrival of multivariable regression models and artificial lattice models in the research, many complex relationships found in nature is understandable. Hence the need for estimation the biomass yield of savory using fast, cheap and with acceptable accuracy is feeling.

Materials and Methods: The present study was performed at the Agricultural Research Station Neyshabur as pot experiment based on a completely randomized design with three replications. Around 53 soil samples were collected from different parts of Neyshabur city, and soil texture, organic matter, pH, salinity, phosphorus, potassium, nitrogen and carbon content were selected as the easily available parameters. Before planting the parameters were measured in laboratory. Approximately 90 days after planting seeds in pots containing soil samples, the sampling of plants was done based on the treatments. For drying, samples were placed for 24 hours in an oven at 40 °C. Finally, the relationship between the biomass yield and easily available soil parameters was determined using artificial neural network by Matlab7.9 software.

Results and Discussion: The results showed that soil variability, is a key element in the management of valuable information on soil properties within a field and valuable information on soil properties within a field nature puts at our disposal. In yield modeling with 10 parameters for 53 soil samples, the best makeup hidden layer with Levenberg-Marquardt algorithm training as a hidden layer, 58 neurons, logsig threshold function for hidden layer and Tansig for the output layer were selected. High values of R² and low levels of RMSE mentioned the proximity of the forecast data with measurement data and high accuracy of the model in summer savory biomass yield estimation. To obtain the most sensitive parameters, the sensitivity analysis was calculated using no-sensitive coefficient. So that, if the coefficient of a sensitive parameter is more than 1.0, the mentioned parameter, is one of the critical parameters of model. Accordingly, the parameters of organic carbon, nitrogen, phosphorus, organic matter, potassium, pH, salinity, clay, silt and sand respectively were selected as the most sensitive parameters. The addition of input parameters increases the value of R² and reduces the RMSE during training, validation and test stages. This represents an increasing in the accuracy of model in estimation of biomass yield via increasing the input parameters. Models 1(soil texture) and 2(carbon) are not enough strong for biomass yield estimation. With increasing the experiment from 1 to 2, the potency of the neural network model 3(soil texture + carbon) significantly increased. Thus with an overview, the model No. 3 suggested as an improved model because with the minimum number of imputes produced equal output comparing the models with more inputs.

Conclusions: Based on the obtained results, it seems that with the improvement of artificial neural network models and determining appropriate parameters, results to understanding the soil factors involved in the formation of savory plant biomass and better planning. Till leads to a cheaper and better product. Also, results showed that the artificial neural network has high accuracy in estimating the biomass plant Summer Savory. So that, the 80% of yield variability of the study area, presents by using the data of 10 readily available properties of the soil. Yield biomass of savory, largely depends on the soil texture, organic matter, carbon and the minerals of

1, 2 and 3- MSc, Assistant Professor and Associated Professor in Horticultural Sciences, Gorgan University of Agricultural Science and Natural Resources

(*- Corresponding Author Email: Sabouri@tvu.ac.ir)

4- Assistant Professor in Hydrology, Gorgan University of Agricultural Science and Natural Resources

5- PhD student of Physiology, Ferdowsi University of Mashhad

6- MSc in Hydrology, Gorgan University of Agricultural Science and Natural Resources

the soil. Since, this study is the first work to estimate the biomass of medicinal plants using artificial neural network, therefore recommended to use this method to estimate the yield and essential oil of other medicinal plants.

Keywords: Summer savory, Artificial neural network, Easily accessible soil parameters