

Research Article

Agricultural Engineering., 44(1) (2021) 81-95
DOI: 10.22055/AGEN.2021.35343.1588

ISSN (P): 2588-526X

ISSN (E): 2588-5944

Modeling wheat yield using some soil properties at the field scale (Case study: Sistan dam research farm, university of Zabol)

A.R. Dahmardeh,¹ A. Shahriari,^{2*} M. Pahlavan-Rad,³ A. Shabani,⁴ and M. Ghorbani⁴

1. Graduated MSc Student, Soil Science Department, Faculty of Water and Soil, University of Zabol, Zabol, Iran
2. Assistant Professor of Soil Science Department, Faculty of Water and Soil, University of Zabol, Zabol, Iran
3. Assistant Professor, Soil and Water Research Department, Golestan Agricultural and Natural Resources Research and Education Center, AREEO, Iran
4. Academic Staff, Soil Science Department, Faculty of Water and Soil, University of Zabol, Zabol, Iran

Received: 8 October 2020

Accepted: 29 April 2021

Abstract

Introduction Crop yield modeling is an important part of ecological modeling because it makes possible plant production prediction and increase understanding of how it works. In other words, plant and crop growth simulation and yield modeling are mathematical expressions of plant growth stages and processes under the influence of environmental and managerial factors. Wheat is one of the key crops grown worldwide and is a source of nourishment for millions of people around the world. Therefore, studying this strategic crop is very importance. On the other hand, more than 70% of wheat and 84% of barley in Sistan and Baluchestan province were produced in Sistan plain and wheat has the highest area under cultivation among different crops, in this arid region. So, the aim of this study was modeling wheat yield with some soil characteristics and determination of the most important soil factors affecting wheat yield in the Sistan plain.

Materials and Methods This research was done in the educational and research farm of University of Zabol. Topsoil (0-30 cm) sampling of 100 soil sample was done randomly. Clay, silt, sand abundances and soil texture class, soil pH, electrical conductivity, apparent electrical conductivity of soil, organic carbon, phosphorus, potassium and nitrogen were measured by conventional methods. Wheat plant samples were taken from a one m² plot and the grain weight, 1000-grain weight and total weight were measured. Performance modeling was performed by three methods of multi-linear regression (MLR), multi-layer perceptron (MLP) and support vector machines (SVMs) by two kernels types linear (SVM-L) and radial basic function (SVM-RBF). It should be noted, before modeling, 80% of the data were selected for modeling (or training) and 20% for testing (or validation) of the models. These data (training and validation) were the same for all models. Coefficient of determination (R²) and the root mean square error (RMSE) were the criteria for comparing the models. Sensitivity analysis was used to determine the most important soil factors affecting wheat yield.

Results and Discussion The results of soil properties analyses showed that the soil of this area is non-saline and alkaline soil, has a medium to coarse soil texture and the soil fertility conditions are poor to moderate. The results of comparing the models showed that the highest R² and the lowest RMSE in estimating all three wheat yield indices were related to the MLP method (grain weight with R²= 0.61, 1000-grain weight with R²= 0.64 and total yield with R²= 0.76). After MLP, with less difference, the SVMs method with two kernels types of linear (grain weight with R²= 0.54, 1000-grain weight with R²= 0.44 and total yield with R²= 0.65) and radial basic function (grain weight with R²= 0.48, 1000-grain weight with R²= 0.58 and total yield with R²= 0.67) showed the better modeling and finally the MLR (grain weight with R²= 0.20, 1000-grain weight with R²= 0.27 and total yield with R²= 0.40) showed the lowest accuracy in modeling the yield components of wheat. The results of sensitivity analysis of wheat yield components showed that total soil nitrogen, clay, silt and soil organic matter had the highest on wheat yield components (grain weight: nitrogen, clay and organic matter; 1000-grain weight: nitrogen, silt and clay; and total yield: clay, organic matter and nitrogen) and soil pH had the least effect on it, maybe because of its low variation.

Conclusion Due to harsh environmental conditions in the arid regions, the study of crops yield is very important for the optimal management of facilities and resources. Investigating the application of several wheat yield modeling methods using some soil characteristics in the arid region of Sistan showed that the perceptron neural network (MLP) performed better in predicting the yield components of wheat than other models. Also, some chemical and physical properties of soil that affect the soil fertility and water storage conditions in the soil (soil nitrogen, organic matter, clay and silt contents), were the most affecting factors on the yield of wheat in this arid region. It is important to note that attention to other soil properties as well as climatic parameters and studies and monitoring wheat yield for several years can lead to more accurate modeling of this strategic crop and thus optimal farm management.

Keywords: *Wheat yield prediction, Multi-linear regression (MLR), Multi-layer perceptron (MLP), Support vector machines (SVMs), Sensitivity analysis, Arid regions*

مدلسازی عملکرد گندم با استفاده از برخی خصوصیات خاک در مقیاس مزرعه (مطالعه موردی: مزرعه تحقیقاتی سد سیستان، دانشگاه زابل)

علیرضا دهمرده^۱، علی شهریاری^{۲*}، محمد رضا پهلوان راد^۳، اسماء شعبانی^۴ و مریم قربانی^۴

۱- فارغ التحصیل کارشناسی ارشد رشته علوم خاک دانشگاه زابل، دانشکده آب و خاک، دانشگاه زابل، زابل، ایران

۲- استادیار گروه علوم خاک، دانشکده آب و خاک، دانشگاه زابل، زابل، ایران

۳- استادیار بخش تحقیقات خاک و آب، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی گلستان، سازمان تحقیقات، آموزش و ترویج کشاورزی، گرگان، ایران

۴- مربی گروه علوم خاک، دانشکده آب و خاک، دانشگاه زابل، زابل، ایران

تاریخچه مقاله

دریافت: ۹۹/۰۷/۱۷

پذیرش نهایی: ۱۴۰۰/۰۲/۰۹

کلمات کلیدی:

گندم

رگرسیون خطی چندمتغیره

شبکه عصبی مصنوعی پرسپترون

چند لایه

ماشین‌های بردار پشتیبان

آنالیز حساسیت

* عهده دار مکاتبات:

Email: shahriari.ali@uoz.ac.ir

چکیده

مدل‌های گیاهان زراعی از بخش‌های مهم مدلسازی‌های اکولوژیک می‌باشد زیرا این مدل‌ها امکان پیش‌بینی سیستم‌های گیاهی و افزایش فهم درباره چگونگی عملکرد آنها را فراهم می‌آورد. گندم یکی از محصولات زراعی کلیدی است که در سراسر جهان کشت می‌شود، لذا مطالعه این محصول استراتژیک اهمیت ویژه‌ای دارد و این تحقیق با هدف مدلسازی عملکرد گندم با برخی خصوصیات خاک و مشخص نمودن مهم‌ترین فاکتورهای خاکی موثر در عملکرد گندم در مزرعه آموزشی و تحقیقاتی دانشگاه زابل انجام شد. نمونه‌برداری از خاک سطحی (۰-۳۰ سانتی‌متری) صورت گرفت و بافت خاک، واکنش خاک، هدایت الکتریکی، هدایت الکتریکی ظاهری خاک، کربن آلی، فسفر، پتاسیم و ازت خاک با روش‌های استاندارد در نمونه‌ها اندازه‌گیری شدند. نمونه‌های گیاه گندم از پلات یک مترمربع برداشت شد و وزن دانه، وزن کل و وزن هزار دانه اندازه‌گیری شد. مدلسازی عملکرد به سه روش رگرسیونی خطی چندمتغیره، شبکه عصبی مصنوعی پرسپترون و ماشین‌های بردار پشتیبان انجام شد. برای تعیین مهم‌ترین فاکتورهای خاک موثر در عملکرد گندم در این پژوهش از آنالیز حساسیت استفاده شد. نتایج مقایسه مدل‌های مورد استفاده در پیش‌بینی اجزاء عملکرد گندم با استفاده از ویژگی‌های خاک نشان داد که بالاترین ضریب تبیین و کمترین ریشه میانگین مربع‌های خطا در تخمین هر سه شاخص عملکرد گندم مربوط به روش شبکه عصبی پرسپترون بود (وزن دانه با ضریب تبیین برابر ۰/۶۱، وزن هزار دانه با ضریب تبیین برابر ۰/۶۴ و عملکرد کل با ضریب تبیین برابر ۰/۷۶). نتایج مربوط به آنالیز حساسیت اجزاء عملکرد گندم نشان داد که در مجموع نیتروژن، رس و ماده آلی و سیلت خاک دارای بیشترین و واکنش خاک کمترین تاثیرگذاری بر اجزاء عملکرد گندم را داشته‌اند، دارد.

مقدمه

گندم یکی از غلات کلیدی است که در سراسر جهان کشت می‌شود و منبع تغذیه برای میلیون‌ها نفر از مردم جهان می‌باشد (۵). در بین همه غلات گندم از نظر سطح زیر کشت و تولید سالیانه، در درجه اول اهمیت قرار داشته و در مقایسه با دیگر غلات از نظر کیفیت نیز در سطح بالاتری است و تاکنون امکان جایگزینی آن به‌وسیله سایر غلات وجود نداشته است (۸).

مدل‌های گیاهان زراعی از بخش‌های مهم مدل‌سازی‌های اکولوژیکی می‌باشد زیرا این مدل‌ها امکان پیش‌بینی سیستم‌های گیاهی و افزایش فهم درباره چگونگی عملکرد آنها را فراهم می‌آورد (۱۸). به عبارت دیگر مدل‌های شبیه‌سازی رشد گیاهان و محصول در واقع بیان ریاضی مراحل و فرآیندهای رشد گیاه تحت تاثیر عوامل محیطی و مدیریتی است. این مدل‌ها برای هدف‌های مختلفی ایجاد شده و هر کدام نیازمند دانستن جزئیات فرآیندهای رشد گیاه و نیز حساسیت این فرآیندها به محیط در مدیریت‌های مختلف می‌باشد (۲۳). از سوی دیگر در مناطق خشک شناسایی خصوصیات خاک کلیدی موثر بر عملکرد گیاهان، می‌تواند در جهت‌دهی به هزینه‌های مورد نیاز برای افزایش عملکرد با استفاده از بهبود کیفیت خاک ضروری می‌باشد (۱۷). از این رو محققان زیادی اقدام به مدل‌سازی عملکرد گندم نموده‌اند.

شعبانی و همکاران (۳۰) به بررسی تاثیر ویژگی‌های خاک و پستی و بلندی در عملکرد گندم دیم در منطقه سیسب (در مرز اقلیمی خشک و نیمه خشک)، شمال شرق ایران با استفاده از مدل‌سازی رگرسیون چند متغیره و شبکه عصبی مصنوعی پرداختند. همچنین نوروزی و همکاران (۲۶) به منظور پیش‌بینی عملکرد کل، عملکرد دانه و همچنین پروتئین دانه گندم با استفاده از

خصوصیات خاک و زمین نما از مدل شبکه عصبی استفاده در منطقه اردل استان چهارمحال و بختیاری کردند.

در مطالعات اخیر روش‌های نوین مدل‌سازی مورد توجه قرار گرفته‌اند. باریکلو و همکاران (۴) طی پژوهشی که در شهرستان تبریز به منظور تخمین عملکرد گندم آبی شبکه با استفاده از روش الگوریتم ترکیبی شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک انجام دادند، دریافتند که مدل هیبریدی می‌تواند به یک ابزار قدرتمند در تخمین عملکرد گندم باشد. همچنین تقی‌زاده مهرجردی و همکاران (۳۴) از مدل برنامه ریزی ژنتیک جهت مدل‌سازی عملکرد گندم آبی استفاده کردند و استفاده از یک ساختار مشخص در مدل‌سازی را عاملی در کاهش دقت مدل عنوان نمودند، با این حال گزارش نمودند که می‌تواند با دقت قابل قبولی عملکرد را پیش‌بینی نماید.

پانتازی و همکاران (۲۸) در پژوهشی تحت عنوان پیش‌بینی عملکرد گندم از طریق روش‌های یادگیری ماشینی به تخمین عملکرد درون مزرعه ای گندم با استفاده از داده‌های لحظه‌ای چندلایه خاک و تصاویر ماهواره‌ای مرتبط با خصوصیات رشدی گیاه در مقیاس کوچک و با استفاده از شبکه‌های عصبی مصنوعی پس انتشار و شبکه‌های ترکیب XY و شبکه‌های با نظارت کوهونن پرداختند. زرینی بهار و همکاران (۳۷) اقدام به پیش‌بینی مکانی عملکرد گندم دیم در شهرستان قروه استان کردستان با استفاده از مدل‌های شبکه عصبی مصنوعی، تحلیل درخت تصمیم و آنالیز تشخیصی میان‌گیری نزدیک ترین همسایه K نمودند. نیدبالا و کوزلوسکی (۲۵) در مطالعه خود به مدل‌سازی عملکرد

3 Barikloo *et al.*4 Taghizadeh-Mehrjerdi *et al.*5 Pantazi *et al.*6 Zarrini Bahador *et al.*

7 Niedbala. and Kozlowski

1 Shabani *et al.*2 Norouzi *et al.*

می‌باشد. این تحقیق در مزرعه آموزشی و تحقیقاتی دانشگاه زابل (موسوم به سد سیستان)، انجام شده است.

نمونه برداری

در اواخر اردیبهشت ماه در مجموع ۱۰۰ نقطه به صورت تصادفی در مزرعه سد سیستان که تحت کشت گندم (به صورت کشت آبی) بودند (حدود ۲۹ هکتار) انتخاب شد. نمونه های گیاه گندم از پلات های یک مترمربعی همزمان با نمونه های خاک برداشت شد و پس از خشک کردن در هوای آزاد وزن دانه، وزن هزار دانه و وزن کل اندازه گیری شد. نمونه برداری از خاک سطحی (۳۰ - ۰ سانتی متری) انجام شد. بافت خاک، واکنش خاک، هدایت الکتریکی، کربن آلی، فسفر، پتاسیم و ازت خاک با روش های معمول در نمونه ها اندازه گیری شدند. هدایت الکتریکی ظاهری خاک با دستگاه القاء گر الکترومغناطیس EM38-MK2 اندازه گیری شد.

مدل سازی و آنالیز حساسیت

در این تحقیق جهت به دست آوردن مدل رگرسیونی خطی چندمتغیره (MLR) برای عملکرد گندم با استفاده از متغیرهای مستقل (خصوصیات خاک)، از روش گام به گام ورود متغیرها (Stepwise) استفاده شد. پس از استاندارد سازی داده ها مدل سازی شبکه عصبی مصنوعی با استفاده از شبکه پرسپترون چند لایه (MLP) در نرم افزار Matlab انجام شد. همچنین مدل سازی ماشین های بردار پشتیبان (SVMs) با دو نوع کرنل خطی^۴ و شعاعی (RBF) نیز با بکارگیری نرم افزار Matlab انجام شد. جهت مدل سازی نرمال بودن داده ها بررسی و برای استاندارد کردن داده ها از رابطه زیر (معادله ۱) استفاده شده است:

گندم با استفاده از شبکه های عصبی مصنوعی پرسپترون در یک بازه هفت ساله و با در نظر گرفتن متغیرهای اقلیمی و حاصلخیزی خاک پرداختند.

دشت سیستان تولید کننده بیش از ۷۰ درصد گندم و ۸۴ درصد جو در استان سیستان و بلوچستان می باشد. میانگین سطح زیر کشت گندم در این منطقه از سال زراعی ۸۶-۸۵ تا ۹۵-۹۴ حدود ۴۰۰۰۰ هکتار بوده است که بیشترین سطح زیر کشت بین محصولات مختلف را دارد (۱۷). مقدار پایین میانگین عملکرد گندم در واحد سطح در منطقه سیستان به دلایل کمبود آب، پایین بودن حاصلخیزی خاک و عدم مدیریت صحیح می باشد (۱۷)، لذا مطالعه بر روی این محصول استراتژیک در منطقه دارای اهمیت ویژه ای است و این تحقیق با هدف بررسی رابطه و مدل سازی عملکرد گندم با برخی خصوصیات خاک و مشخص نمودن مهم ترین فاکتورهای خاک موثر در عملکرد گندم در مزرعه آموزشی و تحقیقاتی سد سیستان دانشگاه زابل انجام شد.

مواد و روش ها

موقعیت منطقه

دشت سیستان بر روی دلتای رودخانه هیرمند (دشت سیلابی) در شرق ایران و در شمال استان سیستان و بلوچستان واقع شده است. ارتفاع متوسط منطقه از سطح دریا ۴۸۵ متر، متوسط بارندگی سالیانه ۵۵ میلی متر و تبخیر و تعرق سالانه در این منطقه ۴۵۰۰ الی ۵۰۰۰ میلی متر می باشد که بسیار بالا است (۲۰). بادهای نیرومند ۱۲۰ روزه در این منطقه منحصر به فرد بوده و یکی از مهمترین عوامل دخیل در مقدار بالای تبخیر و تعرق علاوه بر دمای بالای منطقه، است. رژیم رطوبتی و دمای خاک منطقه به ترتیب اریدیک و هایپرترمیک می باشد. کاربری زمین های منطقه شامل کشاورزی، مرتع و همچنین زمین های غیرقابل استفاده می باشند. منطقه مسطح (دشت سیلابی) با شیب کم، حدود ۱-۲ درصد

- 1- Multi-Linear Regression
- 2- Multi-Layer Perceptron
- 3- Support Vector Machines
- 4- Linear
- 5- Radial Basic Function

برای تعیین مهم‌ترین فاکتورهای خاک موثر در عملکرد گندم در این پژوهش از آنالیز حساسیت استفاده شد. فرآیند آنالیز حساسیت اطلاعات ارزشمندی درباره میزان حساسیت مدل به متغیرهای ورودی آن را در اختیار پژوهشگر قرار می‌دهد. با شناسایی میزان تاثیر متغیرهای ورودی بر دقت پیش‌بینی مدل، می‌توان متغیرهای کم‌اثر را از شبکه حذف و مدل ساده‌تری را بسط و توسعه داد. در این پژوهش برای انجام آنالیز حساسیت مدل از روش هیل (۱۲) استفاده شد. در این روش هر بار یکی از پارامترهای ورودی به میزان ۱۰ درصد افزایش و یا کاهش یافته و با ثابت نگاه داشتن مقادیر بقیه پارامترها، مقدار تغییرات با استفاده از شبکه عصبی آموزش یافته محاسبه می‌گردد. سپس با توجه به اختلاف مقادیر محاسبه شده با مقادیر اندازه‌گیری شده، ضریب نسبی آنالیز حساسیت محاسبه می‌گردد. شایان ذکر است که آنالیز حساسیت پس از مشخص شدن بهترین مدل، تنها برای آن مدل انجام شد.

(معادله ۱)

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

که در آن: X_n معرف داده نرمال شده، X معرف داده‌ی مشاهده‌ای، X_{mean} ، X_{min} و X_{max} به ترتیب معرف داده‌های مشاهده‌ای میانگین، حداکثر و حداقل می‌باشند.

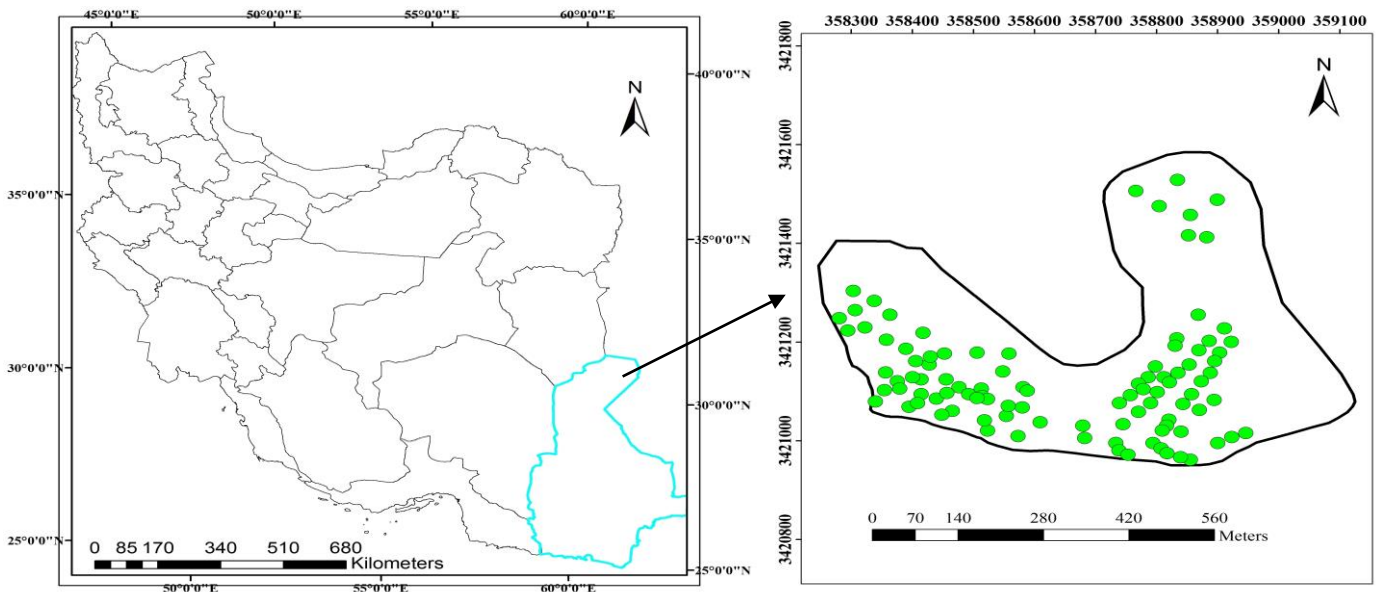
قبل از انجام مدل‌سازی ۸۰ درصد داده‌ها به منظور مدل‌سازی (یا آموزش) و ۲۰ درصد برای آزمون (یا اعتبارسنجی) مدل‌ها گزینش شدند. این داده‌ها (آموزش و اعتبارسنجی) برای کلیه مدل‌ها یکسان بودند. در انجام فرآیند آزمون از معیارهای ضریب تبیین (R^2) و ریشه میانگین مربع‌های خطا (معادلات ۲ و ۳) برای انتخاب بهترین مدل و مقایسه مدل‌ها استفاده شد.

(معادله ۲)

$$R^2 = 1 - \frac{\sum_{i=1}^n (z^* - z)^2}{\sum_{i=1}^n (z - z_m)^2}$$

(معادله ۳)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z - Z^*)^2}$$



شکل (۱) موقعیت مکانی منطقه و نقاط نمونه‌برداری در مزرعه سد سیستان
Figure (1) Location of sampling points in Sistan Dam farm

نتایج و بحث

نتایج بررسی خصوصیات آماری فاکتورهای خاکی مورد مطالعه نشان داد که خاک منطقه مورد مطالعه به لحاظ میانگین هدایت الکتریکی و واکنش خاک غیر شور و قلیا، دارای بافت متوسط تا درشت است (جدول ۱). به لحاظ فاکتورهای حاصلخیزی خاک نیز عمدتاً ضعیف تا متوسط بود. نتایج بدست آمده در خصوص هدایت الکتریکی، شن، سیلت و رس با نتایج تحقیق دلبری و همکاران^۳(۹) در مزرعه سد سیستان مطابقت دارد.

نتایج صحت سنجی مدل در پیش‌بینی عملکرد گندم با برخی خصوصیات خاک با استفاده از معادلات مدل رگرسیونی خطی چندمتغیره (MLR) در جدول ۲ نشان داده شده است. بالاترین، ضریب تبیین مربوط به عملکرد کل بود و توانسته ۴۰ درصد عملکرد کل و ۲۷ درصد هزار دانه گیاه گندم را تبیین نماید. این مدل عملکرد دانه را نیز با ضریب تبیین ۰/۲ توانست پیش‌بینی کند.

نتایج صحت مدل در پیش‌بینی عملکرد گندم با برخی خصوصیات خاک با استفاده از شبکه عصبی نوع پرسپترون چندلایه با الگوریتم لوبنرگ مارکوارت با ۱۰۰۰ اپوک که دارای ۱۶ نورون پنهان در جدول ۲ نشان داده شده است. مجدداً بالاترین ضریب تبیین مربوط به عملکرد کل بود و توانسته ۷۶ درصد عملکرد کل و ۶۴ درصد هزار دانه گیاه گندم را تبیین نماید. این مدل عملکرد دانه را نیز با ضریب تبیین ۰/۶۱ توانست پیش‌بینی کند.

نتایج صحت سنجی مدل در پیش‌بینی عملکرد گندم با برخی خصوصیات خاک با استفاده از مدل ماشین بردار پشتیبان با دو کرنل خطی و شعاعی در جدول ۲ نشان داده شده است. بالاترین، ضریب تبیین مربوط به شاخص عملکرد کل توسط مدل ماشین بردار پشتیبان شعاعی بود و توانسته ۶۷ درصد عملکرد کل و ۵۸ درصد وزن هزار دانه گیاه گندم را تبیین نماید. مدل ماشین بردار پشتیبان خطی شاخص عملکرد دانه را نیز با ضریب تبیین ۰/۵۴ توانست پیش‌بینی کند.

مقایسه مدل‌های مورد استفاده در پیش‌بینی عملکرد کل، دانه و وزن هزار دانه با استفاده از ویژگی‌های خاک طبق جدول ۲ مشخص شده و نتایج نشان می‌دهد که بالاترین ضریب تبیین و کمترین ریشه میانگین مربع‌های خطا در تخمین هر سه شاخص عملکرد گندم مربوط به روش شبکه عصبی پرسپترون بود. شبکه‌های عصبی از مهمترین تکنیک‌ها در مدلسازی فرآیندهای غیرخطی بوده و جستجوی نقطه بهینه و عدم تحمیل فرم تبعی خاص از نقاط قوت شبکه‌های عصبی می‌باشند. پس می‌توان نتیجه گرفت که مدل شبکه عصبی درمقایسه با مدل رگرسیون در پیش‌بینی عملکرد گندم دارای عملکرد بالاتری می‌باشد. بر اساس بهترین مدل نقشه‌های عملکرد نیز تهیه شد (شکل ۲).

برخی مطالعات مدلسازی مرتبط با علوم محیطی برتری روش ماشین بردار پشتیبان بر روش رگرسیون چندمتغیره (۶) و (۲۴) و شبکه‌های عصبی مصنوعی (۷، ۱۰، ۲۲ و ۳۱) را نشان داده‌اند ولی همانطور که ملاحظه می‌شود، در پژوهش حاضر با اندکی اختلاف شبکه عصبی مصنوعی پرسپترون مدلسازی بهتری را نشان داد.

در همین راستا شعبانی و همکاران (۳۰) در بررسی که به منظور پیش‌بینی عملکرد گندم دیم به کمک شبکه‌های عصبی مصنوعی در منطقه سیسب استان خراسان شمالی داشتند بیان کردند که شبکه عصبی مصنوعی می‌تواند ۹۲ درصد تغییرات در عملکرد کل و عملکرد دانه گندم را توضیح دهد. همچنین نوروزی و همکاران (۲۶) به منظور پیش‌بینی عملکرد کل و عملکرد دانه گندم با استفاده از خصوصیات خاک و زمین نما از مدل شبکه عصبی استفاده کردند. مدل‌های توسعه یافته آنها به ترتیب توانستند ۹۵ و ۹۳ درصد از تغییرات عملکرد کل و دانه گندم را در منطقه اردل استان چهارمحال و بختیاری توجیه کنند. در مطالعات متعددی نشان داده شده است که شبکه عصبی پرسپترون در پیش‌بینی عملکرد گندم بهتر از سایر مدل‌ها عمل می‌کند (۲۵، ۲۸، ۳۲ و ۳۳). دقت کمتر نتایج بدست آمده در این تحقیق نسبت به مطالعات گذشته می‌تواند به دلیل اثرگذاری سایر خصوصیات غیر خاکی بر عملکرد گیاهان زراعی نظیر اقلیم در مناطق خشک باشد. پژوهش‌های


مختلفی که بر اساس نقش خصوصیات اقلیمی در مدل‌سازی و نتایج مربوط به آنالیز حساسیت در شکل ۳ ارائه شده پیش‌بینی عملکرد گندم انجام شده است، مویید این موضوع است. می‌باشد (۱، ۱۴، ۲۵ و ۳۶).

جدول (۱) توصیف آماری خصوصیات خاکی مورد مطالعه
Table (1) Statistical description of studied soil properties




چولگی (Skewness)	کشیدگی (Kurtosis)	انحراف معیار (Standard deviation)	میانگین (Average)	بیشترین (Maximum)	کمترین (Minimum)	
0.109	-0.178	1.63	2.27	10.4	0.21	هدایت الکتریکی (dS/m) EC
3.074	10.989	0.22	8	8.7	7.56	واکنش خاک pH
0.603	0.181	0.43	1.49	2.5	0.62	ماده آلی (%) OM
0.48	0.73	9.82	46.07	77	27	شن (%) Sand
-1.003	1.856	9.58	43.02	60	4	سیلت (%) Silt
0.674	0.522	3.83	10.91	23	3	رس (%) Clay
1.639	3.961	0.01	0.05	0.08	0.02	نیترژن (%) N
0.084	-0.925	4.71	6.12	28	0.8	فسفر (mg/kg) P
0.031	0.19	26.89	129.58	226	84	پتاسیم (mg/kg) K
2.654	7.932	48.6	70.23	279	22	هدایت الکتریکی ظاهری-حالت عمودی (mS/m) ECa-v
0.711	0.139	0.917	1.635	4.25	0.21	وزن دانه Grain weight (ton/ha)
0.297	-0.527	3.114	7.203	15.58	1.48	وزن کل Total Yeild (ton/ha)

جدول (۲) مقایسه مدل‌های مورد استفاده در پیش‌بینی عملکرد کل، دانه و وزن هزار دانه گندم (تن بر هکتار)
 Table (2) Comparison of models used in predicting total yield, grain and 1000-grain weight of wheat (ton/ha)

معیار مقایسه (Comparison criteria)	وزن هزار دانه (1000-grain weight)	وزن دانه (Grain weight)	عملکرد کل (Total yield)	
RMSE	0.03	0.61	1.62	رگرسیون خطی چند متغیره (MLR)
R ²	0.27	0.2	0.4	
RMSE	0.02	0.41	0.96	شبکه عصبی پرسپترون (MLP)
R ²	0.64	0.61	0.76	
RMSE	0.02	0.49	1.52	ماشین بردار پشتیبان خطی (SVM-L)
R ²	0.44	0.54	0.65	
RMSE	0.02	0.5	1.31	ماشین بردار پشتیبان شعاعی (SVM-RBF)
R ²	0.58	0.48	0.67	



شکل (۲) نقشه الف. عملکرد دانه و ب. عملکرد کل بر اساس بهترین مدل
 Figure (2) a. Grain yield and, b. total yield maps based on the best model



شکل (۳) نتایج آنالیز حساسیت در روش MLP خصوصیات خاکی مورد مطالعه در ارتباط با اجزاء عملکرد گندم: الف:

عملکرد کل، ب: وزن دانه، پ: وزن هزار دانه

Figure (3) Results of sensitivity analysis of MLP method of studied soil properties in relation to wheat yield components: a: total yield, b: grain weight, c: 1000-grain weight

نتایج این پژوهش نیز نشان از اهمیت فاکتورهای حاصلخیزی نیتروژن و ماده آلی و همچنین رس که منشا CEC خاک هستند دارد. جنت صادقی و همکاران^۴ (۱۴) نیز کاربرد کودهای ازته را در بهبود عملکرد گندم و مدلسازی آن موثر می‌دانند. کل (۱۹) بیان نمود که افزایش ماده آلی خاک به دلایل ذیل باعث افزایش عملکرد گیاهان زراعی می‌شود و مرز میزان کربن آلی خاک مناسب و اثرگذار بر عملکرد برای خاک‌های زراعی به مقدار بیش از ۲ درصد است. افزایش ماده آلی خاک اولاً باعث افزایش آب قابل دسترس گیاه بخصوص در خاک‌های درشت بافت می‌شود و همچنین در خاک‌هایی که مقادیر نیتروژن کمی دارند باعث افزایش فراهمی نیتروژن می‌شود. ثانیا افزایش ماده آلی می‌تواند کودهی و آبیاری را تحت پوشش قرار دهد و این عملیات‌های را بهبود دهد. مطالعات متعددی هم نشان دادند که افزایش ماده آلی خاک باعث افزایش نیتروژن، عناصر غذایی و آب قابل دسترس گیاه می‌شود (۱۱ و ۲۷). البته شایان ذکر است که شونینگ و همکاران^۵ (۲۹) در این خصوص توجه به کیفیت مواد آلی را موثر بودن در افزایش عملکرد گیاهان زراعی ضروری دانسته‌اند.

از سویی دیگر رس و سیلت که بر خصوصیات فیزیکی خاک مانند ظرفیت نگهداری آبی، ساختمان خاک و ... موثرند، نیز دارای اهمیت بالایی بودند. آشنونیتیس و همکاران^۶ (۲) نیز با مطالعه ۲۰ ساله عملکرد گندم دریافتند که مقدار رس بیشترین تاثیر را بر خصوصیات فیزیکوشیمیایی خاک (بخصوص با CEC) و میانگین عملکرد در منطقه مورد مطالعه داشته‌اند و اظهار نمودند روابط بین خصوصیات خاک و عملکرد گندم، روابطی غیرخطی است. در برخی از مطالعات برای اصلاح خصوصیات فیزیکوشیمیایی و بیولوژیک خاک و همچنین افزایش عملکرد گیاهان زراعی رس و سیلت را به

نتایج آنالیز حساسیت عملکرد دانه، عملکرد هزار دانه و عملکرد کل بر اساس متغیرهای خاکی مورد مطالعه نشان داد که عملکرد دانه بیشترین تاثیرپذیری را از نیتروژن، رس و ماده آلی خاک دارد و کمترین ارتباط را با pH خاک دارد (شکل ۳).

در خصوص وزن هزار دانه نیتروژن، سیلت و رس خاک و کمترین اثرگذاری را pH خاک نشان داد (شکل ۳). در نهایت رس، ماده آلی و نیتروژن خاک مهمترین فاکتورها در مدلسازی عملکرد کل گندم بودند و مجدداً pH خاک کمترین اثرگذاری را دارا بود.

به نظر می‌رسد به علت تغییرات کم مقادیر pH خاک در منطقه مورد مطالعه، این فاکتور کمترین اثر را روی مدلسازی و پیش‌بینی عملکرد گندم در منطقه داشته است. در راستای نتایج تحقیق بوشوک و راسپر^۱ (۸) طی پژوهشی استفاده از روش شبکه عصبی مصنوعی الگوریتم ژنتیک انجام دادند و بیان نمودند که نیتروژن کل خاک به عنوان موثرترین ویژگی در کیفیت و کمیت عملکرد گندم و ویژگی‌های خاک می‌باشد که با نتایج پژوهش حاضر همخوانی دارد. ایوبی و همکاران^۲ (۳) فسفر، ماده آلی، نیتروژن، پتاسیم و ظرفیت تبادل کاتیونی خاک (CEC) از مهمترین و موثرترین فاکتورهای خاکی در پیش‌بینی گندم می‌دانند. نوروزی و همکاران (۲۶) نیز در پیش‌بینی عملکرد گندم دیم در مناطق نیمه‌خشک غرب ایران بیان داشتند که میزان پروتئین موجود در دانه‌ها تحت تأثیر میزان نیتروژن کل خاک بوده و یک پارامتر تاثیرگذار است. جاهوس و همکاران^۳ (۱۵) در بررسی ده ساله عملکرد گیاهان زراعی در لهستان دریافتند که در سال‌های خشک، سدیمی شدن، شور شدن، بافت خاک و مقدار عناصر غذایی، و در سال‌های پر باران (مرطوب) موقعیت توپوگرافی، ماده آلی و میزان عناصر غذایی از اصلی‌ترین عوامل محدود کننده عملکرد هستند.

4- Janat sadeghi et al.
5- Schjonning et al.
6- Aschonitis et al.

1- Bushuk. and Rasper
2- Ayoubi et al.
3- Juhos et al.

خصوصیات خاک و همچنین پارامترهای اقلیمی و مطالعات و پایش چندین ساله می‌تواند به مدل‌سازی دقیقتر این محصول استراتژیک و در نتیجه مدیریت بهینه مزرعه بیانجامد.

سپاس‌گزاری

این مطالعه با حمایت مالی (شماره پژوهانه: UOZ-GR-9618-80) دانشگاه زابل انجام شده است. بدین وسیله، نویسندگان مراتب سپاس خود را از معاونت پژوهش و فناوری دانشگاه زابل برای حمایت مالی انجام شده اعلام می‌دارند. همچنین نویسندگان مراتب سپاس خود از جناب آقای مهندس سوداگری مدیر عامل محترم شرکت «سیستان اساکادا» جهت انجام اندازه‌گیری هدایت الکتریکی ظاهری در راستای انجام این پژوهش اعلام می‌دارند.

عنوان اصلاحگر به خاک‌های شنی افزوده و نتایج خوبی حاصل شده است (۱۳ و ۱۶ و ۳۵).

واضح است که در مناطق خشک فاکتورهایی که بر رطوبت خاک اثر گذارند، می‌توانند در مدل‌سازی عملکرد گیاهان نقش ویژه‌ای داشته باشند. همانطور که برخی از پژوهش‌های اهمیت رطوبت چه به صورت فاکتور اقلیمی بارندگی و چه خصوصیات نگهداری آب خاک را در پیش‌بینی عملکرد گندم بسیار مهم ارزیابی نموده اند (۱۴، ۲۵ و ۳۶). به عنوان مثال مُجید و همکاران^۱ (۲۱) در بررسی اثر بافت‌های خاک مختلف و اصلاحگرها آلی بر رشد و عملکرد گندم دریافتند با ریزتر شدن بافت خاک به‌علت افزایش تخلخل خاک و بهبود ساختمان خاک، خصوصیات فیزیکوشیمیایی خاک بهبود یافته و در نتیجه رشد و عملکرد گیاه گندم افزایش یافته است. همچنین این محققان دریافتند با افزایش ماده آلی خاک و رطوبت دردسترس گیاه، رشد ریشه‌ها افزایش یافته و گیاه عملکرد بهتری و بالاتری را نشان داده است.

نتیجه‌گیری

در مناطق خشک به دلیل شرایط سخت محیطی مطالعه بر روی محصولات زراعی در جهت مدیریت بهینه امکانات و منابع دارای اهمیت ویژه‌ای است. این پژوهش به بررسی کاربرد چند روش مدل‌سازی عملکرد گندم با استفاده از برخی خصوصیات خاک در منطقه خشک سیستان پرداخت. نتایج نشان داد که شبکه عصبی پرسپترون (MLP) در پیش‌بینی اجزاء عملکرد گندم بهتر از سایر مدل‌ها عمل کرد. همچنین برخی خصوصیات شیمیایی و فیزیکی خاک که موثر بر حاصلخیزی و شرایط نگهداری آب در خاک هستند، از فاکتورهای موثر بر مدل‌سازی عملکرد گندم در منطقه بودند. مهمترین این خصوصیات شامل نیتروژن، ماده آلی، رس و سیلت خاک می‌باشند. اشاره به این نکته ضروری است که توجه به سایر

1- Mojid et al.

References

1. Abhari, A. 2019. Predicting factors affecting on grain number of wheat. *Journal of Plant Ecophysiology*, 11(37): 63-73.
2. Aschonitis, V. G., Lithourgidis, A. S., Damalas, C. A. and Antonopoulos, V. Z. 2013. Modelling yields of non-irrigated winter wheat in a semi-arid Mediterranean environment based on drought variability. *Expl Agric.*, 49 (3): 448-460 C. doi:10.1017/S001447971300015X.
3. Ayoubi, S., Mohammad zamani, S., and Khormali, F. 2010. Wheat Yield Prediction through Soil Properties Using Principle Component Analysis. *Iranian Journal of Soil and Water Research*, 40(1): 51-57.
4. Barikloo, A., Alamdari, P., Moravej, K., and Servati, M. 2017. Prediction of Irrigated Wheat Yield by using Hybrid Algorithm Methods of Artificial Neural Networks and Genetic Algorithm. *Journal of Water and Soil*, 31(3): 715-726.
5. Becker-Reshef, E., Vermote, A., Lindeman, M. and Justice, C. 2010. A generalized regressionbased model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sensing of Environment*, 114: 1312- 1323.
6. Besalatpour, A. A., Shirani, H., and Eafandiyarpour, E. 2015. Modeling of Soil Aggregate Stability using Support Vector Machines and Multiple Linear Regression. *Journal of Water and Soil*, 29(2): 406-417.
7. Boroghani, M., Soltani, S., Fathabadi, H., Ghezelseflu, N. and Pourhashemi, S. 2017. The Modeling of Splash Erosion Produced in Rain-Simulator Using Three Methods of Artificial Neural Network, Neuro-fuzzy, and Support Vector Machine. *Iranian Journal of Watershed Management Science and Engineering*, 10 (35): 65-72.
8. Bushuk, W. and V. F. Rasper. 1994. *Wheat production, properties and quality*. Blackie academic and professional. Grait Britain.
9. Delbari, M., Afrasiab, P., Gharabaghi, B., Amiri, M., Salehian, A. 2019. Spatial variability analysis and mapping of soil physical and chemical attributes in a salt-affected soil. *Arabian Journal of Geosciences*, 12: 68. <https://doi.org/10.1007/s12517-018-4207-x>
10. Fathizad, H., Safari, A., Bazgir, M., and Khosravi, G. 2017. Evaluation of SVM with Kernel method (linear, polynomial, and radial basis) and neural network for land use classification. *Iranian Journal of Range and Desert Research*, 23(4), 729-743.
11. Ghaley, B.B., Wösten, H., Olesen, J.E., Schelde, K., Baby, S., Karki, Y.K., Børgesen, C.D., Smith, P., Yeluripati, J., Ferrise, R., Bindi, M., Kuikman, P., Lesschen, J. P., and Porter, J.R. 2018. Simulation of soil organic carbon effects on long-term winter wheat (*Triticum aestivum*) production under varying fertilizer inputs. *Frontiers in Plant Science*, 9: 1158.
12. Hill, M. C. 1998. *Methods and guidelines for effective model calibration*. U.S. Geological survey Water-Resources Investigations Rep. 98-4005.
13. Ismail, S. M., and Ozawa, K. 2013. Improvement of crop yield, soil moisture distribution and water use efficiency in sandy soils by clay application. *Applied Clay Science*, 37: 81-89.
14. Janat sadeghi, M., Shahnoushi Foroushani, N., Daneshvar kakhki, M., Dourandish, A., and Mohammadi, H. 2018. Assessing the Effective Factors on the Yield of Strategic Agricultural Products (wheat and barley) in Khorasan Razavi Province. *Agricultural Economics*, 12(2): 111-134.
15. Juhos, K., Szabó, S., and Ladányi, M. 2015. Influence of soil properties on crop yield: a multivariate statistical approach. *Int. Agrophys.*, 29: 433-440. doi: 10.1515/intag-2015-0049

16. Kadam, P.D., Vaidya, P.H., Dhawan, A.S., and Aundhakar, A.V. 2016. Effect of tank silt and organic manures on growth, quality, yield and yield attributes of Okra (*Abelmoschus esculentus* L.). *Progressive Research*, 11 (Special-VI): 4219-4221.
17. Keykha, G. 2017. Agricultural water productivity document of Sistan and Baluchestan province (northern part of the province - Sistan plain). Final report. Sistan Agricultural Research and Training Center and Natural Resources. Sistan and Baluchestan Agricultural Jihad Organization. 191 p.
18. Khavari, F., Soltani, A., Akram Ghaderi, F., Gazanchian, GH. and Arabameri, R. 2012. Modeling leaf production and senescence in wheat. *Journal of Crop Production*, 1(3): 17-32.
19. Lal, R. 2020. Soil organic matter content and crop yield. *Journal of Soil and Water Conservation*, 75 (2): 27A-32A. DOI: <https://doi.org/10.2489/jswc.75.2.27A>
20. Mirakzehi, K., Pahlavan-Rad, M. R., Shahriari, A., & Bameri, A. 2018. Digital soil mapping of deltaic soils: A case of study from Hirmand (Helmand) river delta. *Geoderma*, 313, 233-240.
21. Mojid, M. A., Syed, M., and Guido, W. 2010. Growth, yield and water use efficiency of wheat in silt loam-amended loamy sand. *Journal of The Bangladesh Agricultural University*. 7. 10.3329/jbau.v7i2.4753.
22. Mokhtari, M., and Najafi, A. 2015. Comparison of Support Vector Machine and Neural Network Classification Methods in Land Use Information Extraction through Landsat TM Data. *Journal of Water and Soil Science*, 19 (72):35-45.
23. Mousavi Zadeh, S., Honar, T., and Rahmati, H. 2017. Simulation of Seed Yield and Dry Matter of Canola Under The Condition of Water Stress Using SWAP Model. *Irrigation Sciences and Engineering*, 40(1-1): 153-165.
24. Nazariyat, S., Hodaji, M., and Besalatpour, A. 2017. Modeling the Pb Distribution Using Support Vector Machines in Surface Soil of the Lands Surrounding the Dezful-Ahvaz Road. *Iranian Journal of Soil Research*, 31(1): 143-153.
25. Niedbala, G. and Kozłowski, R. J. 2019. Application of Artificial Neural Networks for Multi-Criteria Yield Prediction of Winter Wheat. *Journal of Agricultural Sciences and Technology*, 21: 51-61.
26. Norouzi, M., Ayoubi, S., Jalalian, A., Khademi, H., Dehghani, A.A. 2010. Predicting rainfed wheat quality and quantity by artificial neural network using terrain and soil characteristics. *Acta Agriculturae Scandinavica, Section B — Soil & Plant Science*, 60 (4), 341– 352.
27. Oldfield, E., Bradford, M., and Wood, S. 2019. Global meta-analysis of the relationship between soil organic matter and crop yields. *Soil*, 5: 15–32.
28. Pantazi X.E. et al. 2016. Wheat yield prediction using machine learning and advanced sensing techniques, *Computers and Electronics in Agriculture*, 121: 57-65.
29. Schjonning, P., Jensen, J. L., Bruun, S., Jensen, L. S., Christensen, B. T., Munkholm, L. J., Oelofse, M., Baby, S., and Knudsen, L. 2018. The Role of Soil Organic Matter for Maintaining Crop Yields: Evidence for a Renewed Conceptual Basis. *Advances in Agronomy*, 150: 35-79. doi.org/10.1016/bs.agron.2018.03.001.
30. Shabani, A., Haghnia, G., Karimi, A., and Ahmadi, M. 2012. Influence of Topography and Soil Characteristics on the Rainfed Wheat Yield in Sisab Region, Northeastern Iran. *Journal of Water and Soil*, 26(4): 922-932.
31. Shahrivand, M., Akhoondzadeh Hanzaei, M., and Souri, A. 2015. Comparison of Support Vector Machine, Artificial Neural Network and Decision Tree Classifiers for Dust Detection in Modis Imagery. *Journal of Geomatics Science and Technology*, 4 (3):131-144.

32. Sitharam, T.G., Samui, P., and Anbazhagan, P. 2008. Spatial variability of rock depth in temperate forests. *Geotechnical and Geological Engineering* . 26:5 .503-517.
33. Sudduth K.A., Drummond S.T., Birrell S.J., and Kitchen, N.R. 1996. Analysis of spatial factors influencing crop yield, in Proc. 3rd Int. Conf. On Precision Agriculture, P.C. Robert et al. (ed.), pp. 129-140.
34. Taghizadeh-Mehrjerdi, R., Seyed-jalali S.A., and Sarmadian F. 2016. Prediction of Corn Spatial yield by soil digital mapping in Gotend region (Khuzestan Province, Iran). *Journal of plant production*, 19 (4): 70-9.
35. Tahir, S., and Marschner, P. 2016. Clay addition to sandy soil - effect of clay concentration and ped size on microbial biomass and nutrient dynamics after addition of low C/N ratio residue. *Journal of Soil Science and Plant Nutrition*, 16 (4): 864-875.
36. Tatari, M., Koocheki, A., and Nassiri Mahallati, M. 2009. Dryland wheat yield prediction using precipitation and edaphic data by applying of regression models. *Iranian Journal of Field Crops Research*, 7(2): 357-365.
37. Zarrini Bahador, M., Givi, J., and Taghizadeh Mehrjerdi, R. 2018. Digital Spatial Prediction of Rainfed Wheat Yield (Case Study: Badr Watershed, Qorveh, Kurdistan Province). *Journal of Agricultural Engineering*, 41 (3): 113-125.



© 2021 by the authors. Licensee SCU, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-Non Commercial 4.0 International (CC BY-NC 4.0 license) (<http://creativecommons.org/licenses/by-nc/4.0/>).