

Research Paper

Simulation Yield and Water Productivity of Cucumber Plant Using Artificial Neural Network

Sanaz shokri¹, Abdolrahim Hooshmand*², Mona Golabi³ Naser Alemzadeansari⁴ Dan Struve⁵

¹ . PhD Student, Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran sanaz.shokri66@yahoo.com

² . Associate Professor, Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran hooshmand_a@scu.ac.ir.

³ . Associate Professor, Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran mona_golabi@yahoo.com.

⁴ . Associate Professor, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran, Email: alemzadehansari@yahoo.com

⁵ . Professor, University of Ohio, USA struve.1@osu.edu.



10.22125/IWE.2023.173255

Received:
February 6, 2022
Accepted:
August 24, 2022
Available online:
June 25, 2023

Keywords:
Perceptron, Support Vector Machine, Neural Network, Sensitivity Analysis, Dehydration.

Abstract

Perceptron neural networks (MLP) and support vector machine (SVM) were used to simulate the yield and water productivity of cucumber (*Cucumis sativus* L.). For this purpose, an experiment was conducted in the form of a completely randomized block design with three irrigation levels of 100, 85 and 75% of the water requirement in two growing seasons. The amount of irrigation water, number of leaves on the plant, temperature, evaporation rate and relative humidity were selected as input data. The results showed that the MLP neural network has a greater ability to simulate the performance and efficiency of water consumption and the scenario with the input of the amount of irrigation water and the number of leaves is better. Also, the results of the sensitivity analysis showed that the model has a higher sensitivity to the irrigation water input parameters and the number of plant leaves.

1. Introduction

The increasing demand for agricultural products and the problems of obtaining field data show the necessity of using appropriate models to predict the performance of agricultural products, and computer models have made it possible to examine different management strategies. Today, neural networks can be used to predict and model processes in various sciences.

2. Materials and Methods

In order to implement this experimental design based on a completely randomized block design with 4 replications in the form of hydroponic cultivation in the greenhouse of the Faculty of Agriculture of Shahid Chamran University of Ahvaz during two growing seasons in 2017 and 2018. Irrigation treatments included normal irrigation at 100% of water requirement and low irrigation set at two levels of 75 and 85% of water requirement.

In order to obtain the water requirement of cucumber, this plant must be cultivated in an environment where its water balance can be

controlled. For this purpose, 3 microlysimeters were used and the amount of irrigation water was calculated as follows:

$$WU = W_I - W_D - \Delta W_L$$

WU = water used (grams)

W_I = weight of irrigation water in 24 hours before irrigation (grams)

ΔW_L = weight changes of microlysimeter (gram)

W_D = weight of sewage on the day of irrigation (gram)

In order to simulate water performance and productivity, perceptron neural networks and support vector machine method were used in MATLAB software environment to select and use the best and most efficient network by determining its error value. The input data included the amount of irrigation water, the number of leaves on the plant, temperature, evaporation rate and relative humidity, and the output data was the yield water productivity consumption, and the sampling was done after the plant was established in the pot with intervals of two weeks.

3. Results

In order to simulate, artificial neural network was used in MATLAB software environment and fruit yield parameter and water productivity were selected as output parameters of the model and were simulated by MLP and SVM neural networks. For this purpose, different scenarios were defined for each of the parameters, which are presented in tables 1.

Table 1: Scenarios of fruit yield and water productivity.

scenario	Input parameters
1	The amount of irrigation water, number of leaves, evaporation, average temperature, relative humidity
2	The amount of irrigation water, evaporation, average temperature, relative humidity
3	The amount of irrigation water, evaporation, relative humidity
4	amount of irrigation water, evaporation, average temperature
5	amount of irrigation water, number of leaves, evaporation
6	amount of irrigation water, number of leaves
7	amount of irrigation water, evaporation

Tables 2 and 3 show the overall training and validation results of MLP and SVM networks for performance parameters and water productivity.

Table 2: General results of training, validation and testing for fruit yield

	MLP (R ²)			SVM(R ²)		
	training	validation	test	training	validation	test
1	0.88	0.86	0.88	0.42	0.49	0.4
2	0.86	0.74	0.857	0.43	0.44	0.42
3	0.856	0.5	0.86	0.54	0.51	0.45
4	0.86	0.85	0.74	0.48	0.43	0.5
5	0.877	0.86	0.87	0.45	0.43	0.44
6	0.982	0.97	0.92	0.55	0.51	0.54
7	0.86	0.85	0.75	0.41	0.35	0.36

Table 3: General results of training, validation and testing for water productivity

	MLP (R ²)			SVM(R ²)		
	training	validation	test	training	validation	test
1	0.82	0.8	0.8	0.55	0.46	0.51
2	0.45	0.43	0.43	0.44	0.36	0.4
3	0.38	0.35	0.33	0.45	0.37	0.36
4	0.49	0.45	0.43	0.47	0.46	0.47
5	0.8	0.76	0.78	0.47	0.48	0.48
6	0.93	0.9	0.85	0.58	0.58	0.55
7	0.42	0.39	0.37	0.42	0.46	0.42

4. Discussion and Conclusion

According to the results, scenarios 6, 1, and 5 with the coefficient of explanation value of 0.85, 0.8, and 0.78 in the test stage can be considered as the best scenarios of the MLP network for simulating water productivity. The results show that the MLP network is relatively The SVM network simulates the water productivity of the cucumber plant and its fruit yield with higher accuracy, and the MIP network has a higher R2 than the SVM network in all scenarios. The results showed that the MLP neural network had a greater ability to simulate the performance and efficiency of water consumption, and scenario 6 with the input of the amount of irrigation water and the number of leaves had a higher ability. Also, the results of the sensitivity analysis showed that the model has a higher sensitivity to the irrigation water input parameters and the number of plant leaves.

5. Six important references

- 1) Bagheri, S., M. Gheysari, S. Ayoubi, and N. Lavaee. 2012. Silage maize yield prediction using artificial neural networks. *J. Pla. Prod. (J. Agric. Sci. Nat. Res.)*, 19(4): 77-95.
- 2) Ekwu, L.G., G.N. Nwokwu, and E.B. Utobo. 2010. Effect of mulching material and pruning on growth and yield of cucumber. *International Journal of Agriculture and Rural Development*, 15(2): 1014-1021.
- 3) Kaul, M., R. L. Hill, & C. Walthall. 2005 Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems* 85, 1-18.
- 4) Kucukonderi, H., S. Boyaci, and Adil. Akyuz. 2016. A modeling study with an artificial neural network: developing estimation models for the tomato plant leaf area. *Turkish Journal of Agriculture and Forestry*. (2016) 40: 203-212.
- 5) Najah, A., A. El-Shafie, O. A. Karim, O. Jaafar, and H. Amr. 2011. An application of different artificial intelligences techniques for water quality prediction. *International Journal of the Physical Sciences* Vol. 6(22):5298-5308.
- 6) Pelesco, V. A. and F.B. Alagao. 2014. Evapotranspiration Rate of Lettuce (*Lactuca sativa* L., Asteraceae) in a Non-Circulating Hydroponics System. *Journal of Society & Technology* 4:1-6.



شبیه‌سازی عملکرد و بهره‌وری آب گیاه خیار (*Cucumis sativus* L.) با استفاده از شبکه عصبی مصنوعی

ساناز شکری^۱، عبدالرحیم هوشمند^۲، منا گلابی^۳، ناصر عالم زاده انصاری^۴، Dan Struve^۵

تاریخ ارسال: ۱۴۰۰/۱۱/۱۷

تاریخ پذیرش: ۱۴۰۱/۰۶/۰۲

مقاله پژوهشی

چکیده

به منظور انجام شبیه‌سازی میزان عملکرد و بهره‌وری آب گیاه خیار (*Cucumis sativus* L.) آزمایشی در قالب طرح بلوک کاملاً تصادفی با سه سطح آبیاری ۱۰۰، ۸۵ و ۷۵ درصد نیازآبی در دو فصل کشت طی سال‌های ۱۳۹۷ و ۱۳۹۸ اجرا و از شبکه‌های عصبی پرسپترون (MLP) و روش ماشین بردار پشتیبان (SVM) استفاده گردید و در نهایت جهت انتخاب مدل مناسب و بهینه از شاخص‌های ضریب تبیین، میانگین مربعات خطا و میانگین مربعات خطای نرمال شده استفاده شد. میزان آب آبیاری، تعداد برگ روی بوته، دما، میزان تبخیر و میزان رطوبت نسبی به‌عنوان داده‌های ورودی انتخاب شدند و به ترتیب ۶۰، ۲۰ و ۲۰ درصد کل داده‌ها، به ترتیب برای آموزش، اعتبارسنجی و آزمون مدل اختصاص یافت. نتایج نشان داد که شبکه عصبی MLP با ورودی‌های میزان آب آبیاری و تعداد برگ به ترتیب با داشتن ضریب تبیین ۰/۹۲ و ۰/۸۶ دقت بیشتری در شبیه‌سازی میزان عملکرد میوه و بهره‌وری آب مصرفی در گیاه خیار داشت. نتایج آنالیز حساسیت حاکی از آن بود که پارامتر ورودی آب آبیاری به ترتیب با ضریب حساسیت ۰/۹ و ۰/۸۶ مهمترین پارامتر مؤثر بر مدل بهره‌وری آب مصرفی و عملکرد میوه خیار می‌باشد.

واژه‌های کلیدی: پرسپترون، ماشین بردار پشتیبان، شبکه عصبی، آنالیز حساسیت، کم‌آبیاری.

^۱ دانشجوی دکترا، گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران sanaz.shokri66@yahoo.com

^۲ دانشیار، گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران hooshmand_a@scu.ac.ir

^۳ دانشیار، گروه آبیاری و زهکشی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران mona_golabi@yahoo.com

^۴ دانشیار، گروه باغبانی، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران alemzadehansari@yahoo.com

^۵ استاد، دانشگاه اوهایو، آمریکا، struve.1@osu.edu



مقدمه

خيار از جمله سبزی‌هایی است که به صورت وسیع کشت و کار می‌شود. خيار مانند سایر اعضای خانواده کدوئیان یک سبزی فصل گرم است و امکان کاشت آن در مرزعه در طی فصول مختلف سال وجود ندارد. پیشرفت علم و تکنولوژی و همچنین کوتاه بودن دوره رشد خيار امکان کاشت آن را در شرایط مختلف آب و هوایی فراهم آورده و در حال حاضر یکی از مهم‌ترین محصولات گلخانه‌ای در ایران به حساب می‌آید (ایکوا^۱ و همکاران، ۲۰۱۰). طبق آمار نامه کشاورزی در سال ۱۳۹۳، سطح زیر کشت خيار گلخانه‌ای حدود ۵۷۳۴ هکتار با تولید ۱۴۳۴۱۰۰/۷ تن و عملکرد ۲۵۰ تن در هکتار است. که استان خوزستان با ۳/۱۵ هکتار و ۲۹۸۶ تن با عملکرد ۲۰ کیلوگرم در متر مربع، در کشور رتبه دوازدهم را کسب کرده است (آمارنامه کشاورزی، ۱۳۹۴).

افزایش روزافزون تقاضای محصولات کشاورزی و مشکلات دستیابی به داده‌های صحرائی، ضرورت استفاده از مدل‌های مناسب برای پیش‌بینی عملکرد محصولات کشاورزی را نمایان می‌سازد و مدل‌های کامپیوتری امکان بررسی استراتژی‌های مختلف مدیریتی را فراهم کرده‌اند (باقری و همکاران، ۲۰۱۲). امروزه از شبکه‌های عصبی برای پیش‌بینی و مدل‌سازی فرآیندها در علوم مختلف می‌توان استفاده کرد (سروش همکاران، ۱۳۹۳). شبکه‌های عصبی مصنوعی برای تخمین، کارایی و انعطاف پذیری بسیار بالایی از خود نشان داده‌اند. گستره کاربرد این مدل‌های ریاضی بر گرفته از عملکرد مغز انسان، بسیار وسیع می‌باشد. شبکه عصبی بدون در نظر گرفتن فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه قادر به پیدا کردن رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (کائول^۲ و همکاران، ۲۰۰۵). بسیاری برای تعیین عملکرد محصولات کشاورزی از شبکه عصبی مصنوعی استفاده کرده‌اند. در تحقیقی اکبر^۳ و همکاران (۲۰۱۸) میزان عملکرد روغن زردچوبه را با استفاده از شبکه عصبی در هند

شبیه‌سازی کردند. میزان pH، کربن آلی خاک، نیتروژن خاک، فسفر خاک، پتاسیم خاک، حداقل دمای هوا، حداکثر دما هوا، متوسط بارندگی، حداقل رطوبت نسبی، حداقل رطوبت نسبی و ارتفاع گیاه به عنوان داده‌های ورودی انتخاب شدند. نتایج نشان داد شبکه عصبی مصنوعی به خوبی قادر به شبیه‌سازی عملکرد می‌باشد.

کین^۴ و همکاران (۲۰۱۷) به شبیه‌سازی فتوسنتز در گیاه خيار با استفاده از شبکه عصبی مصنوعی پرداختند. برای این منظور از اطلاعات مربوط به محتوای کلروفیل، دما، غلظت دی‌اکسید کربن، شدت نور و رطوبت نسبی به عنوان داده‌های ورودی استفاده کردند. نتایج نشان داد که شبکه عصبی با دقت خوبی قادر به شبیه‌سازی فتوسنتز می‌باشد.

کوکوندیری^۵ و همکاران (۲۰۱۶) شبیه‌سازی سطح برگ گوجه فرنگی را با استفاده از شبکه عصبی مصنوعی تحت شرایط گلخانه‌ای انجام دادند. برای این منظور از ۴۲۰ نمونه استفاده کردند و میزان طول و عرض برگ را به عنوان داده‌های ورودی مورد استفاده قرار دادند. نتایج نشان داد که شبکه ANN نسبت به مدل رگرسیونی از دقت بیشتری برای پیش‌بینی میزان سطح برگ برخوردار است.

وردی‌نژاد و همکاران (۱۳۹۵) به مدل‌سازی تبخیر تعرق گیاه مرجع، خيار و گوجه فرنگی با استفاده از رگرسیون خطی، غیرخطی و شبکه عصبی مصنوعی در گلخانه پرداختند. نتایج نشان داد بهترین عملکرد شبکه عصبی مصنوعی در تخمین تبخیر و تعرق هر در محصول خيار و گوجه فرنگی مدل با ۵ پارامتر ورودی کمبود فشار بخار اشباع، دما، تعداد روز پس از کشت، رطوبت نسبی و تشعشع گلخانه‌ای می‌باشد.

بررسی‌های انجام شده نشان داد تاکنون پژوهشی در زمینه ارزیابی شبکه عصبی مصنوعی در شبیه‌سازی عملکرد و بهره‌وری آب مصرفی در گیاه خيار انجام نشده است. لذا در تحقیق حاضر به بررسی کارایی شبکه‌های عصبی SVM و MLP در شبیه‌سازی عملکرد و بهره‌وری آب مصرفی در گیاه خيار پرداخته می‌شود.

³ - Akbar.

⁴ - Xin.

⁵ - Kucukonderi.

¹ - Ekwu.

² - Kaul

W_I = وزن آب آبیاری در ۲۴ ساعت قبل از آبیاری (گرم)

ΔW_L = تغییرات وزن میکرو لایسیمتر (گرم)

W_D = وزن زهاب در روز انجام آبیاری (گرم)

پس از رسیدگی فیزیولوژیکی محصول هر گلدان به صورت دستی برداشت و عملکرد و بهره‌وری آب مصرفی اندازه‌گیری شد.

جدول (۱): ترکیب محلول غذایی مورد استفاده خیار گلخانه‌ای،

رش (۲۰۰۵)

عناصر پر مصرف	غلظت عنصر ppm	عناصر کم مصرف	غلظت عنصر ppm
نیتروژن	۱۴۰	منگنز	۰/۸
فسفر	۵۰	روی	۰/۰۷
پتاسیم	۳۵۰	مس	۰/۱
منیزیم	۵۰	مولیبدن	۰/۳
کلسیم	۲۰۰	آهن	۳
گوگرد	۱۵۰	بر	۰/۰۳

جهت شبیه‌سازی عملکرد و بهره‌وری آب از شبکه‌های عصبی پرسپترون و روش ماشین بردار پشتیبان در محیط نرم‌افزار متلب استفاده گردید تا بهترین و کاراترین شبکه با تعیین مقدار خطای آن انتخاب و مورد استفاده قرار گیرد. داده‌های ورودی شامل میزان آب آبیاری، تعداد برگ روی بوته، دما، میزان تبخیر و میزان رطوبت نسبی و داده خروجی میزان عملکرد و بهره‌وری آب مصرفی بود و نمونه‌برداری‌ها بعد از استقرار گیاه در گلدان با فواصل دو هفته در میان انجام شد.

شبکه‌های عصبی مصنوعی جهت طراحی و آموزش نیازمند یک سری داده‌های ورودی و خروجی هستند تا با تجزیه و تحلیل منطقی که بین این داده‌ها به عنوان نمونه صورت می‌گیرد، بتواند روابط غیر خطی آن‌ها را استخراج نموده و کار شبیه‌سازی را برای موارد احتمالی مشابه انجام دهند. مدل‌های شبکه عصبی مصنوعی جهت طراحی نیازمند سه دسته داده آموزشی، اعتبارسنجی و آزمون^۳

مواد و روش‌ها

به منظور اجرای این طرح آزمایشی بر پایه طرح بلوک کاملاً تصادفی با ۴ تکرار به صورت کشت هیدروپونیک در گلخانه دانشکده کشاورزی دانشگاه شهید چمران اهواز طی دو فصل کشت در سال‌های ۱۳۹۷ و ۱۳۹۸ انجام شد. از محلول غذایی (رش^۱، ۲۰۰۵) شامل عناصر کم مصرف و پرمصرف مورد نیاز گیاه به عنوان کود استارتر خیار گلخانه‌ای استفاده شد (جدول ۱)، به گونه‌ای که در هفته اول از نسبت ۱/۴، در هفته دوم از نسبت ۱/۲، در هفته سوم از نسبت ۳/۴ غلظت از این محلول و بعد از آن از محلول کامل آن استفاده شد. بدین منظور محلول استوک هر نمک بصورت جداگانه تهیه شد و سپس با نسبت مشخص در منبع اصلی با همدیگر مخلوط و با استفاده از سیستم تحت فشار توسط لوله‌های رابط و قطره‌چکان با میزان مساوی پای بوته‌ها منتقل گردید. جهت زمانبندی پمپاژ محلول از یک تایمر استفاده شد و زمان دفعات آبیاری در هر روز با توجه به نوع تیمار و نیاز آبی روزانه تعیین شد. برای کل تیمارها تا قبل از مرحله استقرار گیاه (۴-۶ برگی شدن) آبیاری معمولی انجام گردید. سپس بعد از مرحله استقرار گیاه در گلدان تیمارهای کم آبیاری اعمال گردید. تیمارهای آبیاری شامل آبیاری معمولی به میزان ۱۰۰٪ نیاز آبی و همچنین کم آبیاری تنظیم شده در دو سطح ۷۵ و ۸۵ درصد نیاز آبی بود.

جهت به دست آوردن نیاز آبی خیار بایستی این گیاه در محیطی کشت گردد که بتوان بیلان آبی آن را تحت کنترل داشت. برای این منظور از ۳ عدد میکرو لایسیمتر استفاده گردید. جهت تعیین زمان آبیاری میکرو لایسیمترها از روش وزنی استفاده (پلسکو و آلاگائو^۲، ۲۰۱۴) و میزان آب آبیاری به صورت زیر محاسبه شد:


$$WU = W_I - W_D - \Delta W_L \quad (1)$$

WU = آب مصرفی (گرم)

³- Training, validation and test data

¹ - Resh

² - Pelesco and Alagao.



شکل (۱): تصویر شماتیک شبکه پرسپترون چند لایه

ساختار شبکه الگوریتم پس انتشار خطا، وزن های شبکه و مقادیر بایاس را در جهتی تغییر می دهد که تابع عملکرد با سرعت بیش تری کاهش یابد. الگوریتم پس انتشار خطا را می توان به شکل زیر نشان داد (علایی و همکاران، ۱۳۸۹):

$$x_{k+1} = x_k - \alpha_k g_k \quad (2)$$

که در آن x_k بردار وزن ها و بایاس در تکرار k ام، α_k

نرخ آموزش در تکرار k ام، g_k گرادیان در تکرار k ام می باشد

روش ماشین بردار پشتیبان (SVM)^۲

این روش براساس نظریه یادگیری آماری بنا نهاده شده که به سال ۱۹۶۰ برمی گردد و یک روش آماری غیرپارامتریک نظارت شده است. در این روش با استفاده از همه باندها و یک الگوریتم بهینه سازی، نمونه هایی که مرزهای کلاس ها را تشکیل می دهند به دست می آید و با استفاده از آن ها یک مرز تصمیم گیری خطی بهینه برای جدا کردن کلاس ها محاسبه می شود. این نمونه ها را بردارهای پشتیبان می گویند. در شکل (۲) بردارهای پشتیبان نشان داده شده اند.

هستند. از داده های آموزشی به منظور پیدا کردن رابطه بین ورودی ها و خروجی های مشاهده ای، استفاده می گردد. از داده های صحت سنجی به منظور کنترل و نظارت بر یادگیری صحیح شبکه استفاده می شود و از داده های آزمون برای ارزیابی عملکرد شبکه پیشنهادی استفاده می گردد. در این پژوهش ۶۰، ۲۰ و ۲۰ درصد کل داده ها، به ترتیب برای آموزش، اعتبارسنجی و آزمون مدل اختصاص یافت.

شبکه های پرسپترون چند لایه (MLP)^۱

شبکه های چند لایه پیش خور یکی از مهم ترین ساختارهای شبکه های عصبی مصنوعی می باشند. به طور معمول این شبکه ها شامل مجموعه ای از واحدهای حسی (نرون های پایه) می باشند که تشکیل دهنده لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می باشند. سیگنال ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می شود. این نوع شبکه معمولاً با عنوان پرسپترون چند لایه (MLP) نامیده می شود. شکل (۱) تصویر شماتیک این نوع شبکه عصبی را نشان می دهد. طی چند دهه اخیر، تلاش های قابل ملاحظه ای برای مدل کردن یک نرون طبیعی که قادر به توصیف خصوصیات یک سیستم بیولوژیک باشد و شبکه های عصبی زیستی را همانندسازی کند، صورت گرفته است. شبکه های مدل شده با نام الگوهای شبکه عصبی شناخته شده و گسترش یافتند. مشخصات اساسی شبکه عصبی را می توان توسط ساختار آن ها و خصوصیات عملیاتی و دینامیکی آن شناسایی کرد. شبکه عصبی پرسپترون با یک لایه ورودی آغاز می شوند و شار اطلاعات را به سمت لایه خروجی هدایت می نمایند. میان این دو لایه نیز ممکن است چندین لایه مخفی وجود داشته باشد. لازم به ذکر است تعداد این لایه ها و همچنین تعداد گره ها در هر لایه مخفی معمولاً به روش آزمون و خطا تعیین می گردد.

² - Support Vector Machine.

¹ - Multi Layer Perceptron.

جلوگیری نمود. همچنین این کار به این علت صورت می‌گیرد که داده‌ها به اعدادی مابین ۰ و ۱ تبدیل گردند، زیرا خروجی اکثر توابع آستانه اعدادی مابین ۰ و ۱ می‌باشند و شکل داده‌های ورودی به آن نقش مهمی در یادگیری شبکه ایفا می‌کند. برای استاندارد کردن داده‌ها از رابطه زیر استفاده شده است:


$$X_n = 0.5 + 0.5 \left(\frac{X - X_{mean}}{X_{max} - X_{min}} \right) \quad (3)$$

ارزیابی مدل

شبکه‌های عصبی مصنوعی با وجود این‌که با سیستم عصبی طبیعی قابل مقایسه نیستند، ویژگی‌هایی دارند که آن‌ها را در بعضی از کاربردها مانند تفکیک الگو و یا هرجا که نیاز به یادگیری با یک نگاهت خطی و یا غیرخطی باشد، ممتاز می‌نمایند. از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی به مواردی هم‌چون قابلیت یادگیری و تطبیق‌پذیری با اطلاعات موجود، قابلیت تعمیم‌دهی، پردازش موازی ورودی‌های شبکه و در نتیجه افزایش سرعت پردازش، تحمل‌پذیری بالای خطاها و غیره می‌توان اشاره کرد. به منظور ارزیابی و مقایسه دقت مدل به کار برده شده در شبیه‌سازی عملکرد و بهره‌وری آب از معیارهای میانگین مربعات خطا (MSE)، میانگین مربعات خطای نرمال شده (NMSE) و ضریب تبیین (R^2) استفاده می‌شود. بهترین مقدار برای MSE و NMSE برابر صفر و برای R^2 یک می‌باشد و مقادیر آن‌ها به صورت روابط زیر محاسبه می‌شود.

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (4)$$

$$R^2 = \frac{\left[\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P}) \right]^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2} \quad (5)$$



شکل (۲): بردارهای پشتیبان به همراه مرز و حاشیه بهینه همانطور که در شکل (۲) دیده می‌شود به نمونه‌های مرزی، بردارهای پشتیبان می‌گویند و برای محاسبه مرز تصمیم‌گیری دو کلاس کاملاً جدا از هم، از روش حاشیه بهینه استفاده می‌شود. این حاشیه به گونه‌ای محاسبه می‌شود که تمام نمونه‌های کلاس +۱ در یک طرف مرز و تمام نمونه‌های کلاس -۱ در طرف دیگر مرز واقع شوند و مرز تصمیم‌گیری به گونه‌ای می‌باشد که فاصله نزدیکترین نمونه‌های آموزشی هر دو کلاس از هم در راستای عمود بر مرز تصمیم‌گیری تا جایی که ممکن است حداکثر شود. اگر بخواهیم مرز تصمیم‌گیری را به طور موازی توسط دو خط از دو طرف گسترش دهیم تا از بین نزدیکترین نمونه‌های دو کلاس بگذرد مرز تصمیم‌گیری بهینه به وجود می‌آید که مرزی است که بیشترین فاصله بین نمونه‌های دو کلاس وجود دارد. آن دو خط موازی را مرز حاشیه‌ای می‌نامیم (مختاری و نجفی، ۱۳۹۴).

نرمال‌سازی داده‌ها

اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب از چنین شرایطی و همچنین به منظور یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی، داده‌های ورودی به آن بایستی استاندارد شوند. این کار مانع کوچک شدن بیش از حد وزن‌ها می‌گردد. و در عین حال با تنظیم داده‌های ورودی در یک محدوده خاص می‌توان نرون‌ها را در محدوده مطلوب قرار داده و از اشباع زود هنگام نرون‌ها

نتایج

به منظور شبیه‌سازی از شبکه عصبی مصنوعی تحت نرم‌افزار متلب استفاده شد و پارامتر عملکرد میوه و بهره‌وری مصرف آب به‌عنوان پارامتر خروجی مدل انتخاب و توسط شبکه‌های عصبی MLP و SVM مورد شبیه‌سازی قرار گرفتند. به این منظور سناریوهای مختلفی برای هرکدام از پارامترها تعریف شد که در جداول (۲) ارائه شده است. جداول (۳) الی (۶) نتایج کلی آموزش و صحت‌سنجی شبکه‌های MLP و SVM را برای پارامترهای عملکرد و بهره‌وری آب مصرفی نشان می‌دهند.

با توجه به جدول (۳) به ترتیب سناریوهای ۶، ۱، ۵، ۳، ۲، ۷ و ۴ دارای بیشترین مقدار ضریب تبیین در مرحله آزمون و کمترین مقدار MSE و NMSE می‌باشند. همچنین با توجه به جدول (۴) می‌توان بیان کرد که سناریو ۶ نسبت به سناریوهای دیگر دارای بیشترین مقدار ضریب تبیین در مرحله آزمون و کمترین مقدار MSE و NMSE می‌باشد. مقایسه نتایج جدول (۳) و (۴) نشان می‌دهد که در تمام سناریوها شبکه MLP دارای ضریب تبیین بیشتر در مراحل آموزش، اعتبارسنجی و آزمون نسبت به شبکه SVM می‌باشد و می‌توان بیان کرد که شبکه MLP نسبت به شبکه SVM قابلیت بیشتری برای شبیه‌سازی میزان عملکرد گیاه خیار داشته است زیرا شبکه MLP نسبت به شبکه SVM در تمام سناریوها میزان R^2 بیشتر و میزان MSE و NMSE کمتری در بخش‌های آموزش، اعتبارسنجی و آزمون داشته است و با تغییر تعداد پارامترهای ورودی میزان R^2 ، MSE و NMSE متغیر خواهد بود به طوری که به ترتیب سناریوهای ۶، ۱، ۵، ۳، ۲، ۷ و ۴ بیشترین میزان R^2 و کمترین میزان MSE و NMSE را در مرحله آزمون داشتند. نتایج نشان می‌دهد که شبکه MLP میزان عملکرد را با دقت بالاتری شبیه‌سازی می‌کند.

$$NMSE = \frac{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2}{V} \quad (6)$$

که در این معادلات O_i و P_i به ترتیب مقادیر مشاهداتی و شبیه‌سازی شده، \bar{O} و \bar{P} به ترتیب مقادیر میانگین داده‌های مشاهداتی و میانگین داده‌های شبیه‌سازی شده، n تعداد داده‌ها و V واریانس خروجی مورد نظر می‌باشد (نجاح^۱ و همکاران، ۲۰۱۱).

آنالیز حساسیت

شبکه عصبی مصنوعی قادر است درصد تأثیرگذاری پارامترهای ورودی را بر خروجی (بهره‌وری آب و عملکرد محصول) تعیین نماید که در پژوهش حاضر تحلیل حساسیت مدل با ۱۰ درصد افزایش و کاهش پارامترهای ورودی و مشاهده درصد تغییر خروجی‌های مدل انجام شد و درصد تأثیر گذاری یا آنالیز حساسیت داده‌های ورودی نیز تعیین شد.

طبقه‌بندی حساسیت پارامترهای مدل با استفاده از شاخص حساسیت مدل انجام گردید. این شاخص عبارت است از:

$$SI = \frac{(O_2 - O_1) / \bar{O}}{(I_2 - I_1) / \bar{I}} \quad (7)$$

که در آن SI شاخص حساسیت، O_1 میزان اولیه پارامتر خروجی، O_2 میزان ثانویه پارامتر خروجی، I_1 میزان اولیه پارامتر ورودی، I_2 میزان ثانویه پارامتر ورودی، \bar{O} متوسط پارامتر خروجی و \bar{I} متوسط پارامتر ورودی می‌باشد. برطبق این روش، حساسیت خروجی‌های مدل نسبت به پارامترهای ورودی به چهار گروه حساس، نیمه حساس، با حساسیت کم و غیرحساس تقسیم‌بندی می‌شود. اگر میزان این شاخص بین ۰/۵-۱ باشد مدل به آن پارامتر ورودی نیمه حساس است و در صورتی که بین ۰/۵-۰ باشد مدل به آن پارامتر ورودی حساسیت کمی دارد (گیونتن^۲، ۱۹۹۴).

2- Quinton

1 - Najah.



جدول (۲): سناریوهای عملکرد میوه و بهره‌وری مصرف آب

سناریو	پارامترهای ورودی
۱	میزان آب آبیاری، تعداد برگ، تبخیر، متوسط دما، رطوبت نسبی
۲	میزان آب آبیاری، تبخیر، متوسط دما، رطوبت نسبی
۳	میزان آب آبیاری، تبخیر، رطوبت نسبی
۴	میزان آب آبیاری، تبخیر، متوسط دما
۵	میزان آب آبیاری، تعداد برگ، تبخیر
۶	میزان آب آبیاری، تعداد برگ
۷	میزان آب آبیاری، تبخیر

و (۶) نشان می‌دهد که سناریو ۶ دقت بیشتری در شبیه‌سازی میزان بهره‌وری آب مصرفی در گیاه خیار داشته است. با توجه به معادلات خطوط برازش و ضریب تبیین در شکل (۴) می‌توان دریافت که شیب خط مربوط به مدل MLP در سناریو ۷ برابر ۰/۸۸ و عرض از مبدأ آن ۰/۰۶۵۲ می‌باشد. نتایج نشان می‌دهد که سناریو ۶ مدل بهتری برای شبیه‌سازی میزان عملکرد میوه و بهره‌وری آب مصرفی ارائه می‌دهد. با توجه به شکل (۴) مدل رگرسیون خطی چندگانه دارای ضریب R^2 و شیب خط مناسبی می‌باشد. همچنین این شکل‌ها بیان می‌کنند که تراکم نقاط در معادله خط $X=Y$ مناسب می‌باشد و نزدیک به خط مربوطه است که بیانگر نزدیکی مقادیر اندازه‌گیری شده عملکرد نسبت به مقادیر شبیه‌سازی شده است.

مقایسه نتایج این تحقیق با تحقیقات فرج زاده ذوالبین و همکاران (۱۳۹۹)، باقری و همکاران (۱۳۹۱) و صبوری نژاد و قاسم‌نژاد (۱۳۹۲) در زمینه شبیه‌سازی پارامترهای گیاهی با استفاده از مدل‌های شبکه عصبی مصنوعی مؤید این مطلب می‌باشد که شبکه‌های عصبی مصنوعی دقت و توانایی مناسبی جهت شبیه‌سازی و پیش‌بینی پارامترهای عملکرد و بهره‌وری آب مصرفی گیاه دارند.

آنالیز حساسیت

برطبق این روش، حساسیت خروجی‌های مدل نسبت به پارامترهای ورودی به چهار گروه حساس، نیمه حساس، با حساسیت کم و غیرحساس تقسیم بندی می‌شود. اگر میزان این شاخص بین ۰/۵-۱ باشد مدل به آن پارامتر ورودی نیمه حساس است و در صورتی که بین ۰/۰-۰/۵ باشد مدل به آن پارامتر ورودی حساسیت کمی دارد. با توجه به نتایج جداول (۷) و (۸) پارامتر ورودی آب آبیاری به ترتیب با ضریب حساسیت ۰/۹ و ۰/۸۶ مهمترین پارامتر مؤثر بر مدل بهره‌وری آب مصرفی و عملکرد میوه خیار می‌باشد. شکل‌های (۵) و (۶) حساسیت مدل را نسبت به تغییرات ۱۰ درصدی هر یک از پارامترهای ورودی را نشان می‌دهد. با توجه به شکل‌های (۵) و (۶) می‌توان بیان کرد که مدل نسبت به پارامترهای ورودی آب آبیاری و تعداد برگ بوته دارای حساسیت بالاتری است. سادراس و

نتایج جداول (۳) و (۴) نشان می‌دهد که سناریوی ۶ دقت بیشتری در شبیه‌سازی میزان عملکرد میوه در گیاه خیار داشته است. معادلات خطوط برازش و ضریب تبیین حاصل از مقایسه مقادیر مشاهده‌ای و شبیه‌سازی عملکرد در مرحله آزمون توسط شبکه MLP (شکل (۳)) نشان می‌دهد که شیب خط در سناریو ۶ برابر ۰/۹۲۱۹ و عرض از مبدأ ۰/۰۱۶۹ و ۰/۰۴۱۴ می‌باشد و مدل رگرسیون خطی چندگانه دارای ضریب R^2 و شیب خط مناسبی می‌باشد. همچنین این شکل‌ها بیان می‌کنند که تراکم نقاط در معادله خط $X=Y$ مناسب می‌باشد و نزدیک به خط مربوطه است که بیانگر نزدیکی مقادیر اندازه‌گیری شده عملکرد نسبت به مقادیر شبیه‌سازی شده است.

با توجه به جدول (۵) به ترتیب می‌توان سناریوهای ۶، ۱ و ۵ با مقدار ضریب تبیین ۰/۸۵، ۰/۸ و ۰/۷۸ در مرحله آزمون را بهترین سناریوهای شبکه MLP برای شبیه‌سازی بهره‌وری مصرف آب دانست. با توجه به جدول (۶) به ترتیب سناریوهای ۶، ۱ و ۵ دارای بیشترین مقدار ضریب تبیین در مرحله آزمون و کمترین مقدار MSE و NMSE می‌باشند.

جداول (۵) و (۶) نشان می‌دهد که شبکه MLP نسبت به شبکه SVM میزان بهره‌وری آب مصرفی گیاه خیار را با دقت بالاتری شبیه‌سازی می‌کند و شبکه MIP نسبت به شبکه SVM در تمام سناریوها میزان R^2 بیشتر و میزان MSE و NMSE کمتری داشته است. نتایج جداول (۵)

برداشت شده از سفره‌های آب زیرزمینی در بخش کشاورزی به مصرف می‌رسد، هدف اصلی این تحقیق مدلسازی بهره‌وری آب مصرفی و عملکرد خیار بود. نتایج نشان داد که شبکه عصبی MLP قابلیت بیشتری برای شبیه‌سازی عملکرد و بهره‌وری آب مصرفی داشته و سناریوی ۶ با ورودی میزان آب آبیاری و تعداد برگ از قابلیت بالاتری برخوردار بود. همچنین نتایج آنالیز حساسیت نشان داد که مدل نسبت به پارامترهای ورودی آب آبیاری و تعداد برگ بوتله دارای حساسیت بالاتری می‌باشد.

کالوینو^۱ (۲۰۰۱) تعیین نمودند که ۹۰ درصد از تغییرات عملکرد سویا و ۷۶ درصد تغییرات عملکرد ذرت به کمبود آب مرتبط است. همچنین کائول و همکاران (۲۰۰۵) اظهار داشتند که پارامتر آب قابل دسترس یکی از فاکتورهای اساسی در تخمین عملکرد محصولات کشاورزی می‌باشد.

نتیجه‌گیری

با توجه به این که در دو دهه اخیر کشت‌های گلخانه‌ای مورد توجه و استقبال کشاورزان ایرانی قرار گرفته و با توجه به وضعیت بحرانی سطوح آب زیرزمینی در اکثر دشت‌های ایران، و با لحاظ این نکته که قسمت عمده آب



جدول (۳): نتایج کلی آموزش، اعتبارسنجی و آزمون شبکه‌های MLP برای عملکرد.

شماره سناریو	R^2		MSE		NMSE	
	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی
۱	۰/۸۸	۰/۸۶	۰/۰۰۰۴	۰/۰۰۰۴۵	۰/۰۳۲۰	۰/۰۳۹
۲	۰/۸۶	۰/۷۴	۰/۰۰۰۹	۰/۰۰۰۲۵	۰/۰۸۳	۱/۱۲
۳	۰/۸۵۶	۰/۸۵	۰/۰۰۰۹۲	۰/۰۰۰۳۸	۰/۰۸۲	۰/۰۸۵
۴	۰/۸۶	۰/۸۵	۰/۰۰۰۹	۰/۰۰۰۴۲	۰/۰۷۶	۰/۰۹۱
۵	۰/۸۷۷	۰/۸۶	۰/۰۰۰۴	۰/۰۰۰۴۵	۰/۰۲۹	۰/۰۴۱
۶	۰/۹۸۲	۰/۹۷	۰/۰۰۰۴	۰/۰۰۰۳	۰/۰۲۴	۰/۰۳۵
۷	۰/۸۶	۰/۸۵	۰/۰۰۰۹	۰/۰۰۰۴۱	۰/۰۷۵	۰/۰۹۸



جدول (۴): نتایج کلی آموزش، اعتبارسنجی و آزمون شبکه‌های svm برای عملکرد.

شماره سناریو	R^2		MSE		NMSE	
	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی
۱	۰/۴۲	۰/۴۹	۰/۴۹	۰/۵۶	۳/۲۳	۳/۲۴
۲	۰/۴۳	۰/۴۴	۰/۴۶	۰/۶۳	۳/۱۲	۳/۳
۳	۰/۵۴	۰/۵۱	۰/۴۲	۰/۷۲	۲/۶۲	۳/۵
۴	۰/۴۸	۰/۴۳	۰/۵۹	۱/۱۵	۱/۰۵	۹/۱
۵	۰/۴۵	۰/۴۳	۰/۸۴	۰/۸۳	۴/۹	۵/۹
۶	۰/۵۵	۰/۵۱	۰/۴۱	۰/۵۲	۲/۳	۱/۴
۷	۰/۴۱	۰/۳۵	۰/۹۵	۱/۱	۱۲/۶	۸/۹

¹ . Sadras & Calviño.



شکل (۳): نتایج حاصل از شبیه سازی و مقادیر نرمال شده مشاهده‌ای عملکرد در مرحله آزمون توسط شبکه MLP برای سناریو ۶



شکل (۴): نتایج حاصل از شبیه سازی و مقادیر نرمال شده مشاهده‌ای بهره‌وری آب مصرفی در مرحله آزمون توسط شبکه MLP برای سناریو ۶.



جدول (۵): نتایج کلی آموزش، اعتبارسنجی و آزمون شبکه‌های MLP برای بهره‌وری مصرف آب.

شماره سناریو	R^2		MSE		NMSE	
	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی
۱	۰/۸۲	۰/۸	۰/۰۲۷	۰/۰۲۱	۰/۳۲	۰/۳۶
۲	۰/۴۵	۰/۴۳	۰/۰۸۵	۰/۰۸۹	۰/۹۱	۰/۸
۳	۰/۳۸	۰/۳۵	۰/۰۷۲	۰/۰۹۲	۰/۹۲	۰/۸۹
۴	۰/۴۹	۰/۴۵	۰/۰۶۸	۰/۰۸۸	۰/۸۹	۰/۷۹
۵	۰/۸۰	۰/۷۶	۰/۰۴	۰/۰۵۴	۰/۴۹	۰/۳۵
۶	۰/۹۳	۰/۹	۰/۰۳۸	۰/۰۰۹	۰/۳۱	۰/۳۲
۷	۰/۴۲	۰/۳۹	۰/۰۹۸	۰/۱۱	۰/۹۵	۰/۸۶

جدول (۶): نتایج کلی آموزش، اعتبارسنجی و آزمون شبکه‌های svm برای بهره‌وری مصرف آب.

شماره سناریو	R^2		MSE		NMSE	
	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی
۱	۰/۵۵	۰/۴۶	۰/۱۱۸	۰/۲۵	۰/۸۹	۰/۸۱۸
۲	۰/۴۴	۰/۳۶	۰/۱۲۵۱	۰/۵۸	۱/۲	۰/۹۷
۳	۰/۴۵	۰/۳۷	۰/۴	۰/۷۴	۱/۱	۱/۳
۴	۰/۴۷	۰/۴۶	۰/۲۴	۰/۴۴	۱/۳	۱/۶۵
۵	۰/۴۷	۰/۴۸	۰/۴	۰/۴۲	۱/۱۲	۰/۷
۶	۰/۵۸	۰/۵۸	۰/۱۱	۰/۱۸	۰/۹۱	۰/۷۲
۷	۰/۴۲	۰/۴۶	۱/۲۳	۰/۶۹	۱/۹	۱/۸


جدول (۷): نتایج آنالیز حساسیت برای بهره‌وری آب مصرفی

حساسیت	پارامتر ورودی بهره‌وری
۰/۹	آب آبیاری
۰/۱۴	متوسط دما
۰/۱	متوسط رطوبت نسبی
۰/۳۲	تبخیر
۰/۷	تعداد برگ




جدول (۸): نتایج آنالیز حساسیت برای مدل میزان عملکرد میوه

پارامتر ورودی عملکرد	حساسیت
آب آبیاری	۰/۸۶
متوسط دما	۰/۰۲۱
متوسط رطوبت نسبی	۰/۰۱
تبخیر	۰/۱۴
تعداد برگ	۰/۵



شکل (۵): حساسیت مدل بهره‌وری آب مصرفی به پارامترهای ورودی



شکل (۶): حساسیت مدل میزان عملکرد میوه به پارامترهای ورودی

منابع

- آمارنامه کشاورزی، ۱۳۹۴. چاپ دوم، انتشارات تهران. وزارت جهاد کشاورزی، معاونت برنامه‌ریزی و اقتصادی، مرکز فناوری اطلاعات و ارتباطات.
- باقری، س.، ش. ایوبی، م.، قیصری. و ن. لوائی. ۱۳۹۱. پیش بینی عملکرد ذرت علوفه‌ای با استفاده از شبکه‌های عصبی مصنوعی. مجله پژوهش‌های تولید گیاهی، جلد نوزدهم، شماره چهارم. ص ۷۷-۹۶.
- سروش، م.، م. عاشوری. و ا. امیری. ۱۳۹۳. 'تأثیر محلول‌پاشی روی و نیتروژن بر عملکرد و اجزای عملکرد سویا'. مجله علمی - پژوهشی اکوفیزیولوژی گیاهی، ۶(۱۹)، ص ۱۸-۲۹.
- صبوری فرد، ح. و قاسم نژاد، ع. ۱۳۹۲. پیش‌بینی عملکرد بیومس و اسانس و برخی از شاخص‌های رشدی گیاه مرزه *hortensis* Satureia با استفاده از خصوصیات فیزیکی و شیمیایی خاک و شبکه عصبی مصنوعی. پایان نامه دانشکده تولیدات گیاهی، دانشگاه کشاورزی و منابع طبیعی گرگان.
- علایی، ا.، ح. بانژاد. م.، ت. صمدی. ع.، ر. رحمانی. و م. ح. ساقی. ۱۳۸۹. ارزیابی کارایی شبکه عصبی مصنوعی در پیش‌بینی شاخص‌های کیفی (BOD و DO) آب رودخانه دره مراد بیک همدان. مجله دانش آب و خاک. جلد ۲۰/۱ شماره ۳.
- فرج زاده ذوالبین، ط.، م. عابدینی. و ن. صبور مقدم. ۱۳۹۹. بررسی تأثیر کاربرد سالیسیلیک اسید در تخفیف تنش شوری گیاه گندم با استفاده از شبکه عصبی مصنوعی. پایان نامه کارشناسی ارشد رشته زیست شناسی گیاهی. دانشگاه پیام نور تبریز.
- مختاری، م. ح. و ا. نجفی. ۱۳۹۴. مقایسه روش‌های طبقه‌بندی ماشین بردار پشتیبان و شبکه عصبی مصنوعی در استخراج کاربری‌های اراضی از تصاویر ماهواره‌های لندست TM. مجله علوم و فنون کشاورزی و منابع طبیعی، علوم آب و خاک. ۱۹(۷۲): ۳۵-۴۴.
- وردی‌نژاد، و.، ر.، م. شبانیان اصل. و س. بشارت ۱۳۹۵. مدلسازی تبخیر تعرق با استفاده از رگرسیون خطی، غیرخطی و شبکه عصبی مصنوعی در گلخانه (مطالعه موردی گیاه مرجع، خیار و گوجه فرنگی). نشریه آب و خاک (علوم و صنایع کشاورزی). ۳۰(۵): ۱۳۴۶-۱۳۳۴.
- Akbar, A., A. Kuanar, J. Patnaik, A. Mishra, and S. Nayak. 2018. Application of Artificial Neural Network modeling for optimization and prediction of essential oil yield in turmeric (*Curcuma longa* L.). *Computers and Electronics in Agriculture*. 148 (2018) 160-178.
- Bagheri, S., M. Gheysari, S. Ayoubi, and N. Lavaee. 2012. Silage maize yield prediction using artificial neural networks. *J. Pla. Prod. (J. Agric. Sci. Nat. Res.)*, 19(4): 77-95.
- Ekwu, L.G., G.N. Nwokwu, and E.B. Utobo. 2010. Effect of mulching material and pruning on growth and yield of cucumber. *International Journal of Agriculture and Rural Development*, 15(2): 1014-1021.
- Kaul, M., R. L. Hill, & C. Walthall. 2005 Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems* 85, 1-18.
- Kucukonderi, H., S. Boyaci, and Adil. Akyuz. 2016. A modeling study with an artificial neural network: developing estimation models for the tomato plant leaf area. *Turkish Journal of Agriculture and Forestry*. (2016) 40: 203-212.
- Najah, A., A. El-Shafie, O. A. Karim, O. Jaafar, and H. Amr. 2011. An application of different artificial intelligences techniques for water quality prediction. *International Journal of the Physical Sciences* Vol. 6(22):5298-5308.
- Pelesco, V. A. and F.B. Alagao. 2014. Evapotranspiration Rate of Lettuce (*Lactuca sativa* L., Asteraceae) in a Non-Circulating Hydroponics System. *Journal of Society & Technology* 4:1-6.
- Quinton, J. 1994. The validation of physically based erosion models. PhD. Thesis, Silsoe College, Cranfield University.
- Resh, H.M. 2005. *Hydroponic Food Production*. Woodbrign Press, Santa Barrs, CA 288.
- Sadras, V.O., and Calviño, P.A. 2001. Quantification of grain yield response to soil depth in soybean, maize, sunflower, and wheat. *Agron J.* 93: 577-583.



Xin, P.P., J. Hu, H.H. Zhang, J. Zhao, L.N. Wang. and H.P. Guo. 2017. An improved photosynthesis prediction model based on artificial neural networks intended for cucumber growth control. ASABE, Spokane, Washington July 16 - July 19, 2017. doi:10.13031/aim.201700251.



Simulation of Yield and Water Productivity of Cucumber Plant Using Artificial Neural Network

Sanaz shokri¹, Abdolrahim Hooshmand*², Mona Golabi³, Naser Alemzadeansari⁴ & Dan Struve⁵

Abstract

In order to simulate the yield and water productivity of cucumber plant (*Cucumis sativus* L.), an experiment was conducted in the form of a completely randomized block design with three irrigation levels of 100, 85 and 75% of the water requirement in two growing seasons during 2017 and 2018 and using perceptron neural networks (MLP) and support vector machine (SVM) methods were used and finally, to select the appropriate and optimal model, the indices of explanatory coefficient, mean squared error and normalized mean squared error were used. The amount of irrigation water, number of leaves on the plant, temperature, evaporation rate and relative humidity were selected as input data and 60%, 20% and 20% of the total data were allocated for training, validation and testing of the model, respectively. The results showed that the MLP neural network with the inputs of irrigation water and number of leaves was more accurate in simulating fruit yield and water productivity in cucumber plants with an explanation coefficient of 0.92 and 0.86, respectively. The results of the sensitivity analysis indicated that the irrigation water input parameters are the most important effective parameters on the water consumption efficiency model and cucumber fruit yield with sensitivity coefficients of 0.9 and 0.86, respectively.

Keywords: Perceptron, Support Vector Machine, Neural Network, Sensitivity Analysis, Dehydration.

¹ . PhD Student, Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran Email: sanaz.shokri66@yahoo.com.

² . Associate Professor, Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran Email: hooshmand_a@scu.ac.ir.

³ . Associate Professor, Department of Irrigation and Drainage, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran Email: mona_golabi@yahoo.com.

⁴ . Associate Professor, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran Email: naser_alemzadeansari@yahoo.com

⁵ . Professor, University of Ohio, USA Email: struve.1@osu.edu.