

# شبیه‌سازی اثر باکتری‌های محرک رشد بر ذرت با استفاده از شبکه عصبی مصنوعی

علیرضا رضایی<sup>۱\*</sup> (نویسنده مسئول)، معصومه نژادعلی<sup>۲</sup> و علی غفوریان<sup>۳</sup>

\*۱- کارشناسی‌ارشد، گروه علوم باغبانی، دانشکده کشاورزی، واحد گرمسار، دانشگاه آزاد اسلامی، گرمسار، ایران

Rezaei121.a@gmail.com

۲- استادیار، گروه زیست‌شناسی، واحد اسلامشهر، دانشگاه آزاد اسلامی، اسلامشهر، ایران

Ma\_Nejadali@yahoo.com

۳- استادیار، گروه مهندسی آب، دانشکده کشاورزی، واحد گرمسار، دانشگاه آزاد اسلامی، گرمسار، ایران

Ghafourian.ali@gmail.com

تاریخ پذیرش: بهمن ۱۳۹۶

تاریخ دریافت: آبان ۱۳۹۶

## Simulation of Growth Stimulating Bacteria on Corn using Artificial Neural Network

Alireza Rezaei<sup>1\*</sup>, Masoomeh Nejadali<sup>2</sup> and Ali Ghafourian<sup>3</sup>

1\* - MS.c, Department of Horticulture, Agriculture college, Garmsar Branch, Islamic Azad University, Garmsar, Iran, Rezaei121.a@gmail.com

2- Assistant Professor, Department of Biology, Islamshahr Branch, Islamic Azad University, Islamshahr, Iran, Ma\_Nejadali@yahoo.com

3- Assistant Professor, Department of water engineering, Agriculture college, Garmsar Branch, Islamic Azad University, Garmsar, Iran, Ghafourian.ali@gmail.com

\*Corresponding author: Ali Reza Rezaei

Received: October 2017

Accepted: Jaunary 2017

### Abstract

Many studies have been done to identify factors affecting the growth and development of crops such as corn. Considering the special position of maize, determining the effect of these factors is very important. Since the study of these studies in farms and laboratories is time consuming and costly, the use of artificial neural network is important as a quick and non-destructive way to simulate factors affecting crop production and predict experimental results. The purpose of this study was to assess the predictive power of growth stimulating bacteria on the yield of corn fodder using artificial neural network. After obtaining the required data from experimental studies, Each of the input and output parameters included independent variable (the effect of growth promoting bacteria and effective factors) and dependent variable (forage yield per hectare) data mining were data mining. Then a multilayered perceptron neural network (MLP) with a sigmoid transformation function was designed in the number of neurons 5, 10, 15, 20, 25 in the secret layer. The results showed that the network (MLP) with an error correlation training algorithm with a correlation coefficient ( $R=0.999$ ) and mean square error ( $MSE=0/000113$ ) With 10 neurons in the hidden layer as the optimum model was able to predict corn forage yield affected by growth-promoting bacteria. Also, in the simulation results with the new input parameters, there was very little difference between the actual output values and the predicted output. Therefore, the artificial neural network in this study has been able to estimate the effect of growth stimulating bacteria on corn, and the resulting neural network can be used to predict other influential factors.

**Keywords:** Artificial Neural Network, Corn, Growth Bacteria, Simulation.

فصلنامه زیست‌شناسی سلولی و مولکولی گیاهی

سال ۱۳۹۶، دوره ۱۲، شماره ۴، صص ۱۵-۵

### چکیده

مطالعات بسیاری در زمینه شناخت عوامل مؤثر بر میزان رشد و نمو گیاهان زراعی از جمله گیاه ذرت صورت گرفته است با توجه به جایگاه ویژه ذرت، تعیین اثر این عوامل از اهمیت بالایی برخوردار است از آنجائیکه بررسی این مطالعات در مزارع و آزمایشگاه‌ها بسیار زمان‌بر و پرهزینه می‌باشد استفاده از شبکه عصبی مصنوعی به عنوان یک روش سریع و غیرمخرب برای شبیه‌سازی عوامل تأثیرگذار بر محصولات کشاورزی و پیش‌بینی نتایج تجربی حائز اهمیت است، هدف از این تحقیق ارزیابی قابلیت پیش‌بینی اثر باکتری‌های محرک رشد بر عملکرد ذرت علوفه‌ای با استفاده از شبکه عصبی مصنوعی بوده که پس از کسب اطلاعات مورد نیاز از مطالعات تجربی، هر کدام از پارامترهای ورودی و خروجی شامل متغیر مستقل (اثر باکتری‌های محرک رشد و عوامل تأثیرگذار) و متغیر وابسته (عملکرد علوفه در هکتار) داده‌سازی شد سپس شبکه عصبی نوع پرسپترون چند لایه (MLP) با تابع تبدیل سیگموئید در تعداد نورون‌های ۵، ۱۰، ۱۵، ۲۰، ۲۵ در لایه مخفی طراحی گردید. نتایج نشان داد شبکه (MLP) با الگوریتم آموزشی پس انتشار خطا با ضریب همبستگی ( $R=0/999$ ) و میانگین مربعات خطای ( $MSE=0/000113$ ) با تعداد ۱۰ نورون در لایه مخفی به عنوان مدل مطلوب قادر به پیش‌بینی عملکرد ذرت تحت تأثیر باکتری‌های محرک رشد بود، همچنین در نتایج شبیه‌سازی با پارامترهای ورودی جدید، اختلاف بسیار اندکی بین مقادیر خروجی واقعی و خروجی پیش‌بینی شده مشاهده گردید. بنابراین شبکه عصبی مصنوعی در این پژوهش به خوبی توانست اثر باکتری‌های محرک رشد بر ذرت را تخمین و برآورد کند و می‌توان از شبکه عصبی حاصل برای پیش‌بینی سایر عوامل تأثیرگذار استفاده نمود.

**کلمات کلیدی:** باکتری‌های محرک رشد، شبیه‌سازی، ذرت، شبکه عصبی مصنوعی.

فصلنامه زیست‌شناسی سلولی و مولکولی گیاهی

سال ۱۳۹۶، دوره ۱۲، شماره ۴، صص ۱۵-۵

## مقدمه و کلیات

ذرت با نام علمی (*Zea mays* L.) یکی از مهمترین محصولات کشاورزی در ایران است که از نظر وزارت کشاورزی با توجه به ضرورت و اهمیت آن در تغذیه دام و طیور در گروه محصولات استراتژیک قرار می‌گیرد و به عنوان سومین محصول مهم و راهبردی زراعی در جهان پس از گندم و برنج می‌باشد، ذرت دارای اهمیت زیادی در سراسر جهان بوده و به عنوان فراهم کننده امنیت غذایی بویژه در کشورهای در حال توسعه می‌باشد (Hearn, 2013). عملکرد دانه در ذرت به شدت به مصرف کود وابسته و از نظر تغذیه‌ای یکی از گیاهان پرمصرف می‌باشد. اگر چه امروزه استفاده از کودهای شیمیایی به عنوان سریع‌ترین راه برای جبران کمبود عناصر غذایی خاک و عملکرد بالا، گسترش چشمگیری یافته است، اما در بسیاری موارد کاربرد این کودها موجب آلودگی‌های زیست محیطی و صدمات اکولوژیکی شده و هزینه تولید را افزایش می‌دهد (Salehi et al., 2014). در نیم قرن گذشته مصرف کودهای شیمیایی عملکرد بسیاری از محصولات زراعی را افزایش داده ولی ثبات زیست محیطی ناشی از مصرف بیش از حد این کودها و عدم واکنش اغلب این محصولات به مصرف مقادیر بیشتر کودها، تولیدات مواد غذایی را در دهه‌های آینده با مشکل مواجه خواهد ساخت توجه به کودهای زیستی به عنوان جایگزینی برای کودهای شیمیایی به منظور افزایش حاصلخیزی خاک در کشاورزی پایدار به عنوان رویکرد جدید مطرح شده است (Alikan et al., 2010). باکتری‌های محرک رشد گیاه به عنوان مکمل و جایگزین کودهای شیمیایی شناخته می‌شوند که می‌توانند سبب افزایش باروری و حاصلخیزی خاک گردند، استفاده از کودهای زیستی

باعث کاهش هزینه‌های تولید می‌شود (Mhnaz et al., 2010). این ریزجاندارن نظیر آزوسپیریلیوم و ازتوباکتر می‌توانند در قابل حل شدن و تأمین مواد معدنی ضروری برای گیاه، همکاری لازم را داشته باشند (Sekar and karmegam., 2010). تا کنون مطالعات بسیاری در زمینه شناخت عوامل مؤثر بر میزان رشد و نمو گیاهان زراعی از جمله گیاه ذرت صورت گرفته است. که در این میان می‌توان به مطالعات (Cicchino et al., 2010) اشاره نمود. با توجه به جایگاه ویژه گیاه ذرت علوفه‌ای در میان گیاهان، تعیین عوامل مؤثر بر رشد آن از اهمیت بالایی برخوردار است. یکی از روش‌های مدل‌سازی که در سال‌های اخیر مورد توجه بسیاری از محققین در علوم مختلف واقع شده است، مدل‌سازی به روش شبکه عصبی مصنوعی می‌باشد شبکه عصبی مصنوعی یک سیستم پردازنده غیرخطی اطلاعات است که طریق مطالعه سیستم‌های عصبی بیولوژیکی مغز انسان الهام گرفته شده است که هدف آن محاسبه و ایجاد رابطه بین مقادیر پارمترهای ورودی و مقادیر پارمترهای خروجی می‌باشد (Nasr et al., 2012). بطور گسترده شبکه‌های عصبی مصنوعی مدل‌هایی هستند که برای توضیح پردازش اطلاعات مکانیسم مغز مورد استفاده قرار می‌گیرند و شبکه توپولوژی نقش کلیدی و اساسی در عملکرد داده‌های این شبکه دارد (Erkaymaz et al., 2012). مزیت روش شبکه عصبی یادگیری مستقیم داده‌ها، بدون نیاز به برآورد مشخصات آماری آنهاست (Gholipoor et al., 2013). ویژگی دیگر شبکه عصبی تحمل‌پذیری در برابر خطاست (Rohani et al., 2011). در همین این راستا مطالعات متعددی در زمینه استفاده از شبکه‌های عصبی و مصنوعی در پیش‌بینی متغیرهای مختلف

پارامترهای متفاوت با روش میدانی و آزمایشگاهی زمان بر و پرهزینه و در پاره‌ای موارد تقریباً ناممکن می‌باشد، از سوی دیگر شبکه عصبی در همه شرایط نتایج دقیق‌تری نسبت به روابط تجربی متداول ارائه می‌کند و می‌تواند جایگزین مناسبی برای این روابط باشد (صنعتی‌نیا و همکاران ۱۳۹۴). هدف از انجام تحقیق حاضر عبارت است از:

- طراحی مدل مناسب جهت شبیه‌سازی و تخمین عملکرد علوفه در هکتار ذرت تحت تأثیر باکتری‌های محرک رشد.

- بررسی توانمندی شبکه عصبی مصنوعی در آموزش و پردازش اثر باکتری‌های محرک رشد بر عملکرد علوفه در هکتار ذرت.

- بررسی میزان دقت شبکه عصبی مصنوعی در شبیه‌سازی و پیش‌بینی اثر باکتری‌های محرک رشد بر عملکرد علوفه در هکتار ذرت.

### فرآیند پژوهش

**جمع‌آوری اطلاعات:** اطلاعات مورد نیاز این پژوهش از نتایج تجربی حمیدی و همکاران (۱۳۸۵) در پژوهشی با عنوان اثرات کاربرد باکتری‌های محرک رشد گیاه (PGPR) بر عملکرد ذرت علوفه‌ای استفاده شد این پژوهش در سال ۱۳۸۳ در مزرعه ۴۰۰ هکتاری موسسه تحقیقات اصلاح و تهیه نهال و بذر واقع در کرج به طول جغرافیایی ۵۱ درجه و ۶ دقیقه شرقی و عرض جغرافیایی ۳۵ درجه و ۵۹ دقیقه شمالی و ارتفاع ۱۳۳۱ متر از سطح دریا به اجرا درآمد میانگین دما و بارندگی محل اجرای آزمایش در طول دوره کاشت تا برداشت به ترتیب ۲۱/۸۸ درجه سانتی‌گراد و ۲۳۹/۹ میلی‌متر و میانگین بارندگی ۴۰ ساله ۲۵۶ میلی‌متر بود قبل از کاشت، بذرها در

صورت گرفته است باقر و همکاران (۱۳۹۱) در پژوهشی با استفاده از شبکه عصبی مصنوعی پیش‌بینی عملکرد ذرت علوفه‌ای پرداختند نتایج حاکی از آن بود مدل شبکه عصبی قادر به پیش‌بینی عملکرد ماده خشک ذرت علوفه‌ای با دقت بالا در حداقل سه پارامتر ورودی می‌باشد. در پژوهشی دیگر از Curvelo Santana و همکاران (۲۰۱۰) با استفاده از الگوریتم ژنتیک به بهینه‌سازی خشک کردن گیاه ذرت پرداختند. همچنین مختاریان و همکاران (۱۳۹۰) با استفاده از شبکه‌های عصبی مصنوعی به پیش‌بینی خواص فیزیکی پسته در طی فرآوری پرداختند. zarifneshat و همکاران (۲۰۱۱) در پژوهشی با عنوان پیش‌بینی میزان کبودی سیب با استفاده از شبکه عصبی مصنوعی پرداختند. نتایج حاکی از آن بود شبکه‌های عصبی به عنوان ابزار امیدوارکننده‌ای قادر به پیش‌بینی میزان کبودی سیب نسبت به رگرسیون می‌باشد. Saeidirad و همکاران (۲۰۱۳) در پژوهشی با عنوان پیش‌بینی رفتار ویسکو الاستیکی انار با استفاده از مدل‌های شبکه عصبی مصنوعی و ماکسول پرداختند که نتایج نشان داد هر دو مدل توانایی بالایی در پیش‌بینی دقیق و قابل اعتماد برای استرس دارند. در پژوهشی Rohani و همکاران (۲۰۱۱) از شبکه عصبی مصنوعی در پیش‌بینی هزینه‌های تعمیر و نگهداری استفاده نمود، طبق نتایج بدست آمده، شبکه عصبی مصنوعی را به عنوان ابزار امیدوارکننده‌ای جهت تخمین هزینه‌های تعمیر و نگهداری تراکتور معرفی نمودند. همچنین Menlik و همکاران (۲۰۱۰) با استفاده از شبکه عصبی مصنوعی میزان رطوبت و نسبت آن با خشک کردن برش‌های سیب، طی فرایند خشک کردن با انجاماد را مدل‌سازی نمودند. همانطور که مشاهده می‌شود. بررسی پاسخ گیاه مورد مطالعه در

آموزش، اعتبار سنجی و آزمون استفاده گردید و از ۲۰ درصد دیگر داده‌ها برای آزمایش شبیه‌سازی و پیش‌بینی شبکه استفاده شد شبکه عصبی با یک لایه مخفی و با تعدا کافی نورون در آن لایه قادر به تقریب هر تابع پیوسته دلخواه است (Rohani et al., 2011).

برکاربردترین معماری شبکه‌های عصبی، شبکه چند لایه پیشخور (Feed Forward) است که از قانون آموزش رو به جلو تبعیت می‌کند شبکه‌های چند لایه‌ای پرسپترون به طور اختصار MLP (Multi Layer Perceptron) می‌نامند. امامی و یثربی، ۱۳۹۳، در این نوع آموزش خروجی لایه اول، بردار ورودی برای لایه دوم و خروجی لایه دوم، بردار ورودی برای لایه سوم و این روند ادامه یافته تا در نهایت واکنش به لایه آخر برسد پس از ارائه تمامی مثال‌های آموزشی به شبکه، که در مجموع یک تکرار اپوک (Epoch) را تشکیل می‌دهد خروجی محاسبه شده با خروجی واقعی مقایسه می‌گردد و چنانچه اختلاف معنی‌داری بین دو عدد وجود داشته باشد الگوریتم آموزشی به عقب برگشت کرده و در مسیر برگشت وزن‌ها را اصلاح و مجدد رو به جلو حرکت می‌کند این عملیات می‌تواند چندین بار تکرار شود تا اینکه وزن‌های مناسب برای هر پرسپترون تعیین شود یک شبکه خوب آموزش یافته، شبکه‌ای است که بردارهای وزن آن به نحوی تعیین شود که خروجی محاسبه شده با خروجی واقعی، کمترین اختلاف را داشته باشد. به عبارت دیگر مقدار خطا در حداقل باشد (جورابیان و همکاران، ۱۳۸۸)

**الگوریتم پس انتشار خطا:** مزیت این الگوریتم شامل سهولت در تنظیم پارامترهای یادگیری شبکه به سبب پایین آوردن حساسیت شبکه به مقادیر آهنگ‌های یادگیری، کاهش زمان یادگیری از طریق پایین آوردن

مختلف با سه نوع باکتری محرک رشد تلقیح شده، پس از برداشت صفاتی نظیر عملکرد علوفه در هکتار، وزن تر هر بوته، تعداد برگ‌های بالای بلال در هر بوته، ارتفاع بوته و قطر ساقه، اندازه‌گیری شده بود نتایج بدست آمده از این پژوهش حاکی از آن بود که تمامی ویژگی‌های مورد بررسی تحت تأثیر تیمارهای آزمایش قرار گرفته عملکرد علوفه سیلویی در هکتار و سایر ویژگی‌های مورد بررسی تفاوت معناداری را نشان داده بودند.

**پیش پردازش داده‌ها:** کلیه اطلاعات به دو پارامتر ورودی و خروجی در صفحه گسترده اکسل بصورت ماتریس تفکیک و داده‌سازی شدند قبل از بکارگیری داده‌های خام اولیه در آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمالیزه شود، زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین به دلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی [۰/۱] به کار گرفته شده در لایه میانی، این امر ضروری به نظر می‌رسد در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و لذا نتایج مطلوب حاصل نمی‌شود زمانی که تابع فعالیت سیگموئید استفاده می‌شود، بهترین دامنه تبدیل داده‌ها [۰/۹ ۰/۱] می‌باشد (Rohani et al., 2011) برای تبدیل داده‌ها از روش نرمالیزاسیون خطی رابطه ۱ استفاده شد.

$$\text{رابطه ۱} \quad X_n = \frac{X - X_{\min}}{r_{\min}} (r_{\max} - r_{y\min}) + r_{\min}$$

در اینجا  $X$  داده خام اولیه،  $X_n$  داده نرمالیزه شده،  $X_{\max}$  و  $X_{\min}$  به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و  $r_{\max}$  و  $r_{\min}$  به ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است.

**شبکه عصبی مصنوعی:** برای آموزش شبکه از ۸۰ درصد داده‌ها بصورت کاملاً تصادفی در سه بخش

و بیشترین ضریب همبستگی را داشت (مسعودی و روحانی، ۱۳۹۳)

معیارهای ارزیابی عملکرد شبکه: از دو معیار میانگین مربعات خطا (Mse) ضریب همبستگی (R) مقادیر برآورد شده برای توقف روند آموزش شبکه و ارزیابی میزان دقت شبکه‌های عصبی استفاده شد آموزش شبکه و ارزیابی میزان دقت شبکه‌های عصبی استفاده شد MSE متوسط مجذور اختلافات بین خروجی واقعی و خروجی برآورد شده است و از رابطه ۲ بدست می‌آید

$$\text{رابطه ۲} \quad MSE = \frac{\sum_{i=1}^n (t_i - a_i)^2}{2a}$$

در این رابطه n تعداد نمونه‌های مقدار خطا، t خروجی هدف و y خروجی برآورد شده توسط شبکه عصبی است. داده‌های مورد نظر برای آزمون پیش‌بینی با مدل منتخب شبیه‌سازی و خروجی هدف با خروجی واقعی مقایسه گردید.

### نتایج و بحث

مدل مطلوب: نتایج نشان داد از مجموع تکرار آموزشی معماری شبکه با نرون‌های تعریف شده، کمترین میزان خطای آموزشی شبکه در بخش تعلیم مربوط به شبکه‌ای با تعداد ۱۰ نرون در لایه مخفی بدست آمد. بنابراین مدل به دست آمده برای برآورد عملکرد علوفه ذرت تحت تأثیر باکتری‌های محرک رشد مورد مطالعه مناسب است (جدول ۱).

جدول ۱- معیار ارزیابی شبکه‌های MLP با تعداد نوروهای مختلف در لایه پنهان

Table 1- The criteria for assessing MLP networks with the number of different neurons in the hidden layer

معیار ارزیابی شبکه					تعداد نرون در لایه مخفی
N25	N20	N15	N10	N5	
0.00017922	0.00019928	0.00011925	0.00011314	0.00011468	MSE
.99965	0.99952	0.99982	0.99998	0.99976	R

توضیحات: MSE میانگین مربعات خطا، R ضریب همبستگی، N<sub>n</sub> تعداد نرون

Description: (Mse) Mean Squared Error, (R) Correlation Coefficient, (Nn) Number of Neurons

اعتبارسنجی (Validation) آزمون (Test) محاسبه شدند و مقادیر خروجی حاصل از این مرحله با

تعداد تکرارهای مورد نیاز برای یادگیری و بهبود رفتار شبکه در طول آموزش است (Zarifneshat et al., 2012). کد کامپیوتری این الگوریتم در محیط برنامه‌نویسی متلب (Matlab) تهیه شد. اگر این تقسیم‌بندی به نتایج مطلوب منجر نشود، می‌توان این مرحله را دوباره تکرار کرد. برای تمامی ساختارها، سه ترکیب مختلف از الگوریتم آموزش و تابع انتقال برای لایه میانی و خروجی مورد آزمون قرار گرفت، این انتخاب بر اساس نتایج پژوهش‌های پیشین بود که نشان می‌دادند اگر از توابع فعالیت سیگموئیدی در لایه‌های مخفی و تابع فعالیت خطی در لایه خروجی استفاده شود عملکرد شبکه بهبود می‌یابد (Zarifneshat et al., 2012) اگر تعداد نرون‌ها در لایه مخفی کافی نباشد شبکه قادر به یادگیری خوب نخواهد شد ولی در تعداد بسیار زیاد آن هم مسئله بیش برآزش بوجود خواهد آمد که این منجر به تضعیف ویژگی تعمیم‌پذیری شبکه می‌شود (روحانی و همکاران، ۱۳۹۳) توپولوژی بهینه شبکه (تعداد نرون در لایه مخفی) با سعی و خطا بدست آمد در طول فرآیند آموزش آهنگ یادگیری، عامل ممتوم و حداکثر تعداد اپوک‌ها متغییر بود این فرآیند برای تعداد ۵، ۱۰، ۱۵، ۲۰، ۲۵ نرون در لایه مخفی انجام شد تا بهترین نتیجه برای تعداد نرون‌ها در لایه مخفی بدست آید و در نهایت شبکه‌ای انتخاب شد که کمترین مقدار میانگین مربعات خطا را در فاز آموزش

آموزش: وزن‌های شبکه عصبی به منظور پیش‌بینی عملکرد علوفه‌ای ذرت در سه فاز آموزش (Train)

عصبی است بنابراین مدل شبکه عصبی با استفاده از مجموعه داده‌هایی غیر از داده‌های آموزشی (داده‌های شبیه‌سازی) به منظور آزمایش مدل منتخب ارزیابی شدند نتایج مقادیر خروجی حاصل از شبیه سازی با مقادیر خروجی واقعی در جدول ۲ مقایسه شده‌اند، تفاوت بسیار کمی بین مقادیر پیش‌بینی شده و مقادیر واقعی ملاحظه می‌شود (روحانی و همکاران، ۱۳۹۳).

مقادیر واقعی مقایسه شدند اختلاف بین مقادیر دو خروجی بسیار اندک بود (جدول ۲)، (شکل ۱ و ۲) در اینجا تنها به آوردن نتایج حاصل از ارزیابی شبکه عصبی آموزش دیده که شامل داده‌های درصد جوانه زنی بذر مورد مطالعه است اکتفا می‌کنیم زیرا معتبر بودن این نتایج دال بر موفقیت آمیز بودن فاز آموزشی شبکه عصبی MLP می‌باشد (Ranjbar et al., 2010).  
شبیه‌سازی (Simulation): هدف از این مرحله ارزیابی ویژگی تعمیم‌پذیری و شایستگی مدل شبکه

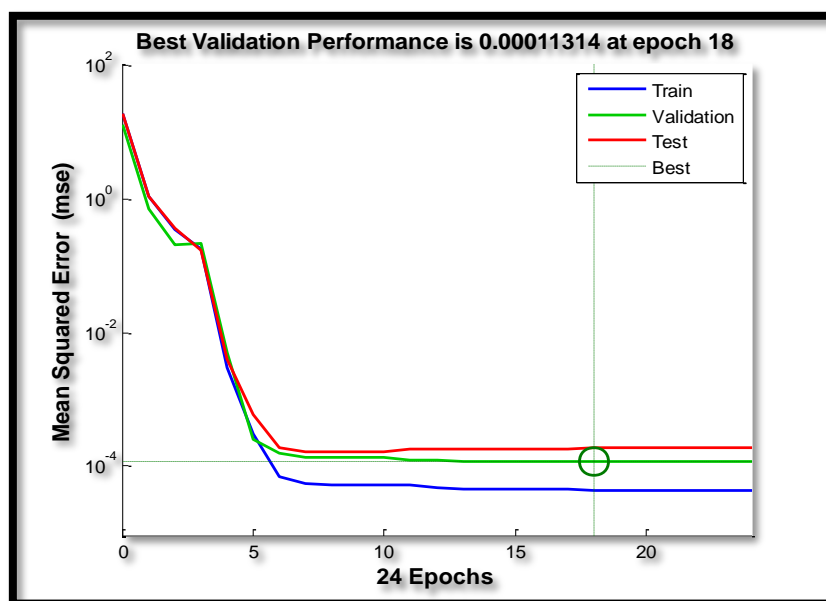
جدول ۲- مشخصه‌های آماری مقادیر واقعی و پیش‌بینی شده عملکرد علوفه در هکتار ذرت تحت اثر باکتری‌های محرک رشد

Table 2- The statistical characteristics of the actual and predicted values of forage yield per hectare of maize under the influence of growth-promoting bacteria

مرحله آموزش	مرحله شبیه سازی		
65696.78	65696.53	dv	عملکرد علوفه در هکتار
65696.77	65696.52	pv	

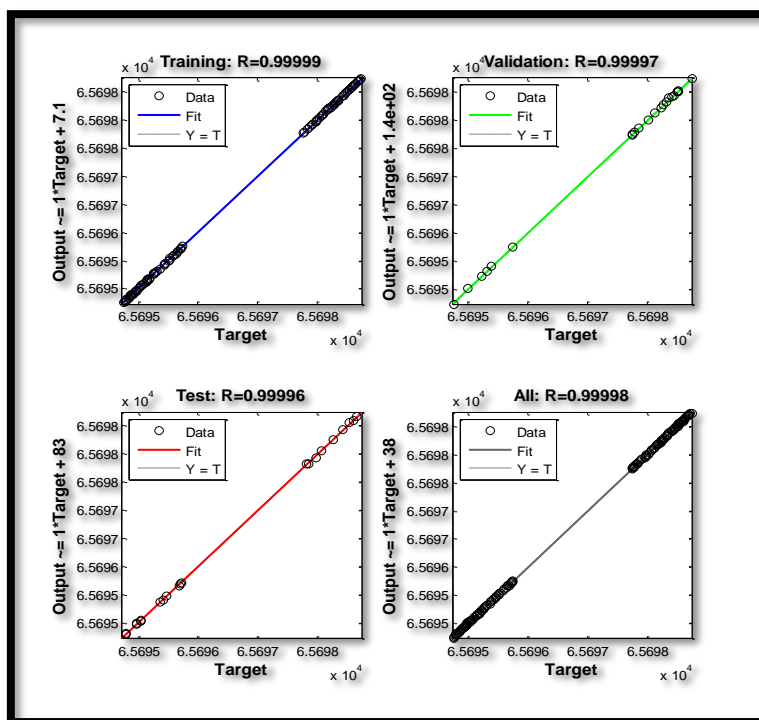
توضیحات: dv: مقادیر واقعی، pv: مقادیر پیش‌بینی شده

Description: dv: actual values, pv: predicted values



شکل ۱: روند تغییرات مقادیر میانگین مربعات خطا در فازهای مختلف پیاده‌سازی الگوریتم شبکه عصبی MLP

Fig 1: Trend of variations in mean square error values in different phases of MLP neural network algorithm implementation



شکل ۲: نمودارهای همبستگی مقادیر خروجی واقعی و پیش‌بینی شده در شبکه عصبی MLP

Fig 2: Correlation charts of real and predicted output values in the MLP neural network

شکل ۱ نمودار مربوط به روند تغییرات مقادیر میانگین مربعات خطای شبکه عصبی بهینه برای مجموعه‌های آموزش، اعتبارسنجی و آزمون را در مقیاس لگاریتمی نشان می‌دهد مقدار MSE با آموزش شبکه به سرعت کاهش می‌یابد بهبود عملکرد شبکه عصبی در طی آموزش و مقدار بهینه میانگین مربعات خطا در فاز اعتبارسنجی برابر  $0.000113$  در اپوک ۱۸ از این فاز بدست آمد که مقداری بسیار کوچک و قابل قبول است. شکل ۲ ضریب همبستگی بین مقادیر واقعی و پیش‌بینی شده توسط شبکه عصبی پرسپترون را نشان می‌دهد. بهترین نتایج بر اساس این شکل زمانی حاصل می‌شود که معادله خطی مابین مقادیر واقعی و پیش‌بینی شده توسط مدل، علاوه بر داشتن ضریب تبیین بالا دارای شیب نزدیک به یک باشد کاملاً واضح است که ضریب تبیین بین داده‌های واقعی و پیش‌بینی توسط شبکه، نسبتاً بالا باشد.

نتایج نشان داد مناسب‌ترین آرایش مدل برای شبیه‌سازی و تخمین اثر باکتری‌های محرک رشد بر عملکرد علوفه در هکتار ذرت مربوط به مدلی می‌باشد که با شبکه عصبی پرسپترون با تعداد ۱۰ نورون در لایه مخفی، الگوریتم آموزشی پس انتشار خطا و تابع تبدیل سیگموئید طراحی شده است با توجه به جدول شماره ۱ کمترین میزان میانگین مربعات خطا مربوط به همین مدل بوده بنابراین می‌توان اظهار نمود مدل حاضر به عنوان مدل مطلوب و توانمند برای شبیه‌سازی اثر باکتری‌های محرک رشد بر ذرت مناسب می‌باشد (شکل شماره ۱ و ۲). با توجه به نتایج جدول شماره ۲، مقایسه بین مقادیر عملکرد علوفه در هکتار در بردار خروجی واقعی و پیش‌بینی، در مرحله

### نتیجه‌گیری کلی

نتایج نشان داد مناسب‌ترین آرایش مدل برای شبیه‌سازی و تخمین اثر باکتری‌های محرک رشد بر عملکرد علوفه در هکتار ذرت مربوط به مدلی می‌باشد که با شبکه عصبی پرسپترون با تعداد ۱۰ نورون در لایه مخفی، الگوریتم آموزشی پس انتشار خطا و تابع تبدیل سیگموئید طراحی شده است با توجه به جدول شماره ۱ کمترین میزان میانگین مربعات خطا مربوط به همین مدل بوده بنابراین می‌توان اظهار نمود مدل حاضر به عنوان مدل مطلوب و توانمند برای شبیه‌سازی اثر باکتری‌های محرک رشد بر ذرت مناسب می‌باشد (شکل شماره ۱ و ۲). با توجه به نتایج جدول شماره ۲، مقایسه بین مقادیر عملکرد علوفه در هکتار در بردار خروجی واقعی و پیش‌بینی، در مرحله

سدیم با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک. مجله به زراعی کشاورزی، دوره ۱۵، شماره ۴، ص ۵۳-۶۴.

صنعتی‌نیا، س. هدهدی، م. حاجیان، ع. ۱۳۹۴. مروری بر کاربرد شبکه عصبی مصنوعی در زمینه‌ی طراحی ژنو تکنیکی شمع‌ها. دومین همایش ملی معماری، عمران و توسعه‌ی نوین شهری ارومیه، ص ۱۰-۱.

مسعودی، ح. روحانی، ع. ۱۳۹۳. تخمین جرم و حجم پرتقال از روی پارامترهای هندسی آن با استفاده از شبکه‌های عصبی مصنوعی اولین همایش ملی فناوری‌های نوین برداشت و پس از برداشت محصولات کشاورزی، ص، ۴۳۴-۴۲۵.

مسعودی، ح. روحانی، ع. ۱۳۹۵. پیش‌بینی جرم و حجم پرتقال رقم محلی دزفول با استفاده از شبکه‌های عصبی MLP، مجله علمی کشاورزی، دوره ۳۹، شماره ۲، ص ۱۴۲-۱۳۳.

مختاریان، م. توکلی‌پور، ح. کوشکی، ف. ۱۳۹۰. پیش‌بینی خواص فیزیکی پسته با استفاده از شبکه عصبی مصنوعی در طی فراوری، مجله علوم رفتاری و غذایی، دوره سوم، شماره ۳ (پیاپی ۹)، ص ۳۸-۲۵.

Alikhan, A. and Jilani, G. and Saleem A. and khtar, M. and Saqlan Naqvi, S. M. and Rasheed, M. 2009. Phosphorus solubilizing bacteria: Occurrence, mechanisms and thir role in crop production. Journal of. Agric. Boil. Sci. 1, 48-58.

Curvelo Santana, J. C. and Araújo, S. A. and Librantz, A. F. H. and Tambourgi, E. B. 2010. Optimization of Corn Malt Drying by Use of a Genetic Algorithm, Journal of Drying Technology, 28: 1236 – 1244.

Cicchino, M. and Rattalino Edreira, J. I. and Uribe Larrea M. and Otegui, M. E. 2010. Heat stress in field-grown maize: response of physiological determinants of grain yield. Crop Sci. 50:1438-1448.

Erkaymaz, O. and Ozer, E. and Yumusak, N. 2012. Performance Analysis Of A Feed-Forward Artificial Neural Network With Small World Topology, Journal of Procedia Technology, 1: 291-296.

Gholipoor M and Rohani A and Torani S. 2013. Optimization of traits to increasing barley grain yield using an artificial neural

آموزش و مرحله شبیه‌سازی اختلاف بسیار کمی به مقدار ۰/۰۱ مشاهده می‌شود، بنابراین نتایج حاکی از آن است شبکه عصبی مصنوعی قادر به پیش‌بینی متغیرهای پارامترهای ورودی اثر باکتری‌های محرک رشد بر ذرت می‌باشد.

## سپاسگزاری

این مقاله مستخرج از پایان‌نامه تحت عنوان "شبیه‌سازی اثر باکتری‌های محرک رشد بر ذرت با استفاده از شبکه عصبی مصنوعی" می‌باشد که از زحمات دانشگاه آزاد اسلامی واحد گرمسار تقدیر و تشکر دارم.

## منابع

امامی، م. یثربی، ش. ۱۳۹۳. کاربرد شبکه عصبی مصنوعی در تفسیر نتایج آزمایش پرسیمتری، مجله عمران مدرس. دوره ۱۴، ص ۲۵-۱۱.

باقری، س. قیصری، م. ۱۳۹۱. پیش‌بینی عملکرد ذرت علوفه‌ای با استفاده از شبکه‌های عصبی مصنوعی، مجله پژوهش‌های تولید گیاهی. دوره ۱۹، شماره ۴، ص ۹۶-۷۷.

حمیدی، آ. قلاوند، آ. دهقان‌شعار، م. ملکوتی، م. اصغرزاده، آ. چوکان، ر. ۱۳۸۵. اثرات کاربرد باکتری‌های محرک رشد گیاه (PGPR) بر عملکرد ذرت علوفه‌ای، مجله پژوهش و سازندگی در زراعت و باغبانی. دوره ۱۹، شماره ۱. ص ۱۶-۲۲.

جوراییان، م. زارع، ط. استوار، ا. ۱۳۸۸. شبکه‌های عصبی و مصنوعی. انتشارات دانشگاه شهید چمران اهواز، چاپ سوم، تعداد صفحه ۷۴۶.

روحانی، ع. ساعدی، ا. گرایلو، ه. آق‌خانی، م. ۱۳۹۳. پیش‌بینی حجم، سطح جانبی و ضریب کرویت انار با استفاده از شبکه عصبی مصنوعی MLP، مجله ماشین‌های کشاورزی. دوره ۵، شماره ۲، ص ۳۰۱-۲۹۲.

رضایی، م. روحانی، ع. ۱۳۹۲. مدل سازی و بهینه کردن مقاوت روزنه‌ای زیتون در شرایط تنش شوری ناشی از کلرید



- Sekar, K. R. and Karmegam, N. 2010. Earthworm casts as an alternate carrier material for biofertilizers: Assessment of endurance and viability of *Azotobacter chroococcum*, *Bacillus megaterium* and *Rhizobium leguminosarum*. *Journal of Scientia Horticulturae*, 124:286-289.
- Zarifneshat S. and Rohani, A. and Ghassemzadeh, H R. and Sadeghi, M. and Ahmadi, E. and Zarifneshat, M. 2012. Predictions of apple bruise volume using artificial neural network. *Journal of Computers and Electronics in Agriculture*, 82: 75-86.
- network. *International Journal of Plant Production*, 7: 1-17.
- Hearn, S. 2014. Maize for Food, Feed, Nutrition and Environmental Security Asian Maize Conference and Expert Consultation on, 1-485.
- Mehnaz, S. and Kowalik, T. and Reynolds, B. and Lazarovits, G. 2010. Growth promoting effects of corn (*Zea mays*) bacterial isolates under greenhouse and field conditions. *Journal of Soil Biology and Biochemistry*, 42:1848-1856.
- Menlik, T. and Özdemir M. B. and Kirmaci, V. 2010. Determination of freeze-drying behaviors of apples by artificial neural network. *Journal of Expert Systems with Applications*, 37: 7669-7677.
- Nasr, M. and Moustafa, M. and Seif, H. and El Kobrosy, G. 2012. Application of Artificial Neural Network (ANN) for the prediction of ELAGAMY wastewater treatment plant performance-EGYPT. *Journal of Alex Engineering*, 51: 37-43.
- Rohani, A. and Makarian, A. 2011. Weed management maps by Artificial neural network for using in precision agriculture. *Journal of agricultural machinery engineering*, 2:74-83.
- Rohani, A. and Abbaspour-Fard, M. and Abdolapour, S. 2011. Prediction of tractor repair and maintenance costs using artificial neural network. *Journal of Expert Systems with Applications*, 38:8999-9007.
- Ranjbar, I. and Abbaspour-Fard, M. H. and Ajabshirchi, Y. and A. Rohani. 2010. Prediction of John Deere tractor repair and maintenance costs by using two different structures of MLP artificial neural network. *Journal of Agriculture Economics & Development*, 22 (2): 87-96.
- Saeidirad, M. and Rohani, A. and Zarifneshat, S. 2013. Predictions of viscoelastic behavior of pomegranate using artificial neural network and Maxwell model. *Journal of Computers and Electronics in Agriculture*, 98:1-7.
- Salehi, A. and Seifollah, F. and Iranpour, R. and Souraki A. 2014. The effect of fertilizer use in combination with cow manure on growth, yield and yield components of Black-caraway (*Nigella sativa* L.). *Journal of Agroecology*, 6: 495-507.

- and root influences of chickpea to drought. 3rd International Crop Science Congress, Hamburg, Germany. pp17-22.
- Wang, Y. and N. Nil. 2000. Changes in chlorophyll, ribulose bi phosphate carboxylase Oxygenase, Glycine betaine content, photosynthesis and transpiration in amaranthus tricolor leaves during salt stress. The Journal of Horticultural Science and Biotechnology.75:623-627.

