

# Application of artificial neural network models in estimating nectarine crop yield under two-sided furrow irrigation

Somayeh Emami<sup>1,\*</sup>, Hosein Dehghanisani<sup>2</sup>, Milad Rezaie<sup>3</sup>

<sup>1</sup>Ph.D. Candidate, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

<sup>2</sup>Associate Professor, Agricultural Engineering Research Institute (AERI), Agricultural Research Education, and Extension Organization (AREEO), Karaj, Iran

<sup>3</sup>M.Sc. Student, Department of Water Engineering, Faculty of Agriculture, University of Urmia, Urmia, Iran

## Abstract

### Introduction

Due to the lack of rainfall, Iran is one of the arid countries in the world where most irrigation systems are done as surface irrigation. Due to the high costs of pressurized irrigation systems, improvement and modification of surface irrigation methods such as land leveling, the correct choice of irrigation method, proper design and thus increase efficiency is significant. If surface irrigation is properly designed and implemented, it is one of the most suitable methods for farmers due to the lack of complex equipment and devices. Researchers use artificial neural networks to simulate and estimate parameters such as weekly evaporation rate, daily evaporation, water capacity, and permeability coefficient have been used.

### Materials and Methods

Perceptrons are arranged in layers, with the first layer taking in inputs and the last layer producing outputs. The middle layers have no connection with the external world and hence are called hidden layers. Each perceptron in one layer is connected to every perceptron on the next layer. Hence information is constantly "fed forward" from one layer to the next. There is no connection among perceptrons in the same layer.

Radial basis function (RBF) networks have three layers: an input layer, a hidden layer with a non-linear RBF activation function, and a linear output layer. The input can be modeled as a vector of real numbers. The output of the network is then a scalar function of the input vector, and is given by where is the number of neurons in the hidden layer, is the center vector for neuron, and is the weight of neuron functions in the linear output neuron. Functions that depend only on the distance from a center vector are radially symmetric about that vector.

### Results and Discussion

The best results were calculated using the average savings in the treatment section compared to the observed section, 31.7%. It also shows water consumption in the treatment section and the control is calculated as 5793 and 6566.9 m<sup>3</sup>/ha, respectively, which indicates an 11.8% decrease in water consumption reduction (733.9 m<sup>3</sup>/ha) of the treatment compared to the control. According to the obtained results and after comparing the results of RBF and GFF networks, RBF networks (function with radial base) with parameters of different irrigation levels as input were recognized as the best network. The R<sup>2</sup> is equal to 0.92 and the square root of the RMS is equal to 0.035.

### Conclusion

It can be stated that the method of two-sided furrow irrigation, in addition to reducing water consumption, increased crop yield. Also, there was the highest water loss in the first irrigation. The average efficiency of water application efficiency in the treatment and control sections was calculated to be 2.24 and 1.52 kg/m<sup>3</sup>, respectively, with the majority of losses being deep penetration. The RBF model had better results in predicting than the GFF neural network model. RBF neural networks with the parameter of different irrigation levels as input were recognized as the best network.

**Keywords:** Surface irrigation, Urmia Lake, Water use efficiency, Irrigation time management.

**Article Type:** Research Article

\*Corresponding Author, E-mail: somayehemami70@gmail.com

**Citation:** Emami, S., Dehghanisani, H., & Rezaie, M. (2021). Application of artificial neural network models in estimating nectarine crop yield under two-sided furrow irrigation. *Water and Soil Management and Modeling*, 1(2), 47-59.

DOI: 10.22098/mmws.2021.9090.1019

DOR: 20.1001.1.27832546.1400.1.2.5.5

Received: 20 June 2021, Accepted: 03 August 2021

*Water and Soil Management and Modeling*, Year 2021, Vol. 1, No. 2, pp.47-59

Publisher: University of Mohaghegh Ardabili

© Author(s)





## کاربرد مدل های شبکه عصبی مصنوعی در تخمین عملکرد محصول شلیل مغان تحت آبیاری شیاری دوطرفه

سمیه امامی<sup>۱\*</sup>، حسین دهقانی سانجی<sup>۲</sup>، میلاد رضایی<sup>۳</sup>

<sup>۱</sup>دانشجوی دکتری سازه های آبی، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران  
<sup>۲</sup>دانشیار، موسسه تحقیقات فنی و مهندسی کشاورزی، سازمان تحقیقات آموزش و ترویج کشاورزی، کرج، ایران  
<sup>۳</sup>دانشجوی کارشناسی ارشد سازه های آبی، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

### چکیده

حوضه آبریز دریاچه ارومیه به دلیل استفاده بی رویه از منابع آب به ویژه در بخش کشاورزی و کاهش نزولات جوی در تأمین نیازهای اکولوژیک خود با بحران روبه رو شده است. لذا، بهبود سیستم های آبیاری سطحی موجود می تواند راه کار مناسبی در کاهش مصرف و استفاده بهینه از منابع آب در این حوضه باشد. در همین راستا، به منظور بررسی و مقایسه تأثیر رویکرد آبیاری شیاری دوطرفه بر عملکرد و کارایی مصرف آب در محصول شلیل رقم مغان مورد پژوهش در سال زراعی ۹۹-۱۳۹۸ در اراضی شهرستان میان دو آب واقع در جنوب دریاچه ارومیه اجرا و عملکرد محصول از طریق مدل های شبکه تابع پایه شعاعی (RBF) و شبکه پیش خور تعمیم یافته (GFF) برآورد شد. برای این منظور، یک مجموعه داده شامل ۱۴۰ داده در دو سطح آبیاری کرتی T<sub>1</sub> (شاهد) و آبیاری شیاری دوطرفه T<sub>2</sub> (تیمار) و مشخصات خاک منطقه به عنوان پارامترهای ورودی استفاده شد. ۸۰ درصد (۱۱۲ داده) برای آموزش و ۲۰ درصد (۲۸ داده) برای آزمایش شبکه استفاده شد. در این پژوهش روش مدیریت زمان آبیاری نیز در نظر گرفته شد. به نحوی که در هر آبیاری، میزان آب مورد نیاز در هر دو بخش شاهد و تیمار بر اساس نیاز آبی شلیل مغان و فواصل آبیاری تعیین شد. نتایج نشان داد که رویکرد آبیاری شیاری دوطرفه و نیز اعمال تیمار برنامه ریزی آبیاری زمان واقعی موجب افزایش بهره وری آب (۰/۷۲ کیلوگرم بر مترمکعب) در این مزرعه شد. هم چنین نتایج مدل سازی نشان داد که مدل RBF با آموزش Levenberg Marquardt و چهار لایه پنهان پتانسیل بالایی در تخمین عملکرد محصول شلیل مغان دارد. در مجموع، با اعمال پارامتر سطوح آبیاری به عنوان ورودی، مدل شبکه عصبی مصنوعی می تواند تخمین مطلوب تری (RMSE = 0.035) از عملکرد محصول شلیل مغان ارائه دهد.

**واژه های کلیدی:** آبیاری سطحی، دریاچه ارومیه، کارایی مصرف آب، مدیریت زمان آبیاری

نوع مقاله: پژوهشی

\*مسئول مکاتبات، پست الکترونیکی: somayhemami70@gmail.com

**استناد:** امامی، س.، دهقانی سانجی، ح.، و رضایی، م. (۱۴۰۰). کاربرد مدل های شبکه عصبی مصنوعی در تخمین عملکرد محصول شلیل مغان تحت آبیاری شیاری دوطرفه. *مدل سازی و مدیریت آب و خاک*، ۱(۲)، ۴۷-۵۹.

DOI: 10.22098/mmws.2021.9090.1019  
DOR: 20.1001.1.27832546.1400.1.2.5.5

تاریخ دریافت: ۱۴۰۰/۰۳/۳۰، تاریخ پذیرش: ۱۴۰۰/۰۳/۳۰

*مدل سازی و مدیریت آب و خاک*، سال ۱۴۰۰، دوره ۱، شماره ۲، صفحه ۴۷ تا ۵۹

© نویسندگان

ناشر: دانشگاه محقق اردبیلی



## ۱- مقدمه

کشور ایران به دلیل کمبود نزولات جوی یکی از کشورهای خشک در جهان است که بیش‌تر سیستم‌های آبیاری به صورت آبیاری سطحی انجام می‌گیرد. لذا، مدیریت آبیاری بیش از پیش دارای اهمیت است. از مزیت‌های آبیاری سطحی می‌توان به پایین بودن هزینه سرمایه‌گذاری اولیه، هزینه تأمین انرژی و همچنین سهولت عملیات تعمیر و نگهداری اشاره نمود. به دلیل امتیازهای ویژه و با وجود توسعه سیستم‌های آبیاری تحت فشار، آبیاری سطحی هنوز هم در بیش از نه درصد از اراضی آبی جهان کاربرد دارد (Talebi, 2018). جهت نیل به عملکرد بالا در این نوع سیستم‌ها، پایش و ارزیابی دائمی ضروری می‌نماید. مشکل اصلی روش‌های آبیاری سطحی، پایین بودن راندمان آبیاری است که ناشی از ضعف مدیریت آبیاری است. با توجه به هزینه‌های بالای سیستم‌های آبیاری تحت فشار، بهبود و اصلاح روش‌های آبیاری سطحی از جمله، تسطیح اراضی، انتخاب صحیح روش آبیاری، طراحی مناسب و در نتیجه افزایش راندمان قابل توجه است (Talebi, 2018). چنان‌چه آبیاری سطحی به درستی طراحی و اجرا شود، به دلیل عدم نیاز به وسایل و دستگاه‌های پیچیده، یکی از روش‌های مناسب برای زارعین به‌شمار می‌رود. ولی چنان‌چه به‌خوبی اجرا نشود، موجب تلفات آب، عدم یک‌نواختی توزیع آب و کاهش محصول می‌شود. آبیاری سطحی بسته به وضعیت توپوگرافی و نوع محصول با روش‌های مختلفی از جمله روش نواری، شیبی و کرتی انجام می‌شود. در طول سال‌های اخیر، آبیاری شیبی به دلیل سازگاری بیش‌تر با توسعه کشاورزی مکانیزه، مورد توجه پژوهش‌گران قرار گرفته است. آبیاری شیبی رایج‌ترین شیوه برای آبیاری محصولات زراعی ردیفی است. در مقایسه با سایر روش‌های آبیاری، در این روش آب روی تمام سطح خاک جریان نمی‌یابد، بلکه درون شیارهایی که بین دو ردیف گیاه کاشته شده قرار گرفته‌اند، جریان دارد. آب به تدریج در کف و کناره‌های شیار نفوذ کرده و خاک را مرطوب می‌کند (Fathi-Torshizi, 2012).

در کنار استفاده از روش‌های بهینه آبیاری، در دهه‌های اخیر، برخی از پژوهش‌گران تلاش نموده‌اند تا با به‌کارگیری روش‌های نوین هم‌چون فن‌آوری‌های زمین‌آمار، مدل‌های ترکیبی شبکه عصبی-ژنتیک و شبکه‌های عصبی مصنوعی در کنار روش‌های کلاسیک آماری مانند رگرسیون چندمتغیره به مدل‌سازی و تخمین عملکرد محصولات زراعی و باغی اقدام نمایند. در این میان روش‌های شبکه عصبی مصنوعی به دلیل دقت و کارایی بالای خود در زمینه مدل‌سازی گسترش روز افزونی را داشته‌اند. در واقع شبکه‌های عصبی مصنوعی، رونوشتی از ساختار مغز و شبکه عصبی انسان هستند. در این

شبکه‌ها سعی بر این است تا ساختاری تهیه شود که همانند مغز، قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد. ایده اصلی این روش‌ها بر مبنای شبیه‌سازی عملکرد مغز انسان است که می‌تواند در مقیاس خیلی کوچک، قدرت یادگیری و تعمیم‌دهی داشته باشد (Gershenfeld, 1999). پژوهش‌گرانی هم‌چون Landaras et al. (2006)، Merdun et al. (2009)، Piri et al. (2009) و Smith et al. (2009) از شبکه‌های عصبی مصنوعی در شبیه‌سازی و تخمین پارامترهایی هم‌چون میزان تبخیر-تعرق هفتگی، تبخیر روزانه، قابلیت نگهداشت آب و ضریب آب‌گذری استفاده نموده‌اند. Seiler et al. (2004) به قابلیت بالای روش شبکه عصبی مصنوعی در برآورد عملکرد محصول ذرت اشاره نمودند. Kaul et al. (2005) به پیش‌بینی عملکرد ذرت و سویا در منطقه مریلند با استفاده از شبکه‌های عصبی مصنوعی پرداخته و گزارش کردند که مدل شبکه عصبی مصنوعی در مقایسه با مدل‌های رگرسیونی دارای دقت بالاتری است. Alvarez (2009) بازده گیاه گندم در منطقه پامپاس آرژانتین را به کمک شبکه‌های عصبی مصنوعی تعیین نمودند. ایشان نسبت بارندگی به تبخیر-تعرق پتانسیل محصول (R/CPET) را به‌عنوان مهم‌ترین عامل آب و هوایی مؤثر بر بازده این محصول معرفی نمود. سپس، Taghizadeh et al. (2016) با استفاده از مدل برنامه‌ریزی ژنتیک به مدل‌سازی عملکرد گندم آبی پرداختند و عنوان داشتند که استفاده از یک ساختار مشخص در مدل‌سازی، عاملی در کاهش دقت مدل است، گرچه می‌تواند با دقت قابل قبولی عملکرد را پیش‌بینی نماید. Rahmani et al. (2008) اقدام به تخمین عملکرد محصول جو با استفاده از پارامترهای هواشناسی و شاخص‌های خشکسالی به روش شبکه عصبی نمودند. نتایج نشان داد به دلیل بالا بودن ضریب تبیین مدل بهینه، روش شبکه عصبی در پیش‌بینی عملکرد از کارایی بالایی برخوردار بوده است و این روش را برای خشکسالی کشاورزی و پیش‌بینی عملکرد محصول جو توصیه کردند. علاوه بر این، Bagheri et al. (2012) عملکرد ذرت علوفه‌ای را در شهرستان ورامین با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی نمودند. ایشان بیان داشتند که با کاربرد سه پارامتر آب آبیاری، کود نیتروژنی و درجه روز رشد به‌عنوان ورودی به مدل شبکه عصبی مصنوعی، این مدل عملکرد ماده خشک ذرت علوفه‌ای را با دقت بالایی پیش‌بینی می‌نماید. هم‌چنین، Esmailzadeh-Kordkheili (2012) عملکرد برنج را با استفاده از روش‌های زمین‌آمار، شبکه‌های عصبی مصنوعی و رگرسیون چندگانه در شالیزارهای لشت نشاء استان گیلان برآورد کردند. نتایج مطالعه وی نشان داد که مدل نوین شبکه‌های عصبی مصنوعی کارایی بیش‌تری

نسبتاً گرم و زمستان‌های بسیار سرد است. متوسط بارش سالیانه ۲۵۰ میلی‌متر و میانگین دمای سالانه آن ۱۰/۹ درجه سانتی‌گراد است. خاک‌های منطقه از نوع خاک سیلت رسی با مقادیر متوسط اسیدیته ۸/۱۴، مواد آلی ۱/۰۳۵ درصد، شوری ۰/۸۵۸ دسی‌زیمنس بر متر و آهک ۱۱/۸ درصد بوده است. تیمارهای آبیاری، شامل آبیاری کرتی (شاهد)  $T_1$  و آبیاری شیاری دو طرفه (تیمار)  $T_2$  بودند. بعد از مراحل آماده‌سازی زمین (شخم عمقی و شخم سطحی) و بر اساس آزمایش خاک، طبق پیشنهاد آزمایشگاه آب و خاک و بررسی خاک مزرعه، مقدار پنج تن کود حیوانی، ۵۰ کیلوگرم سولفات آمونیوم، ۶۰ کیلوگرم کود فسفات و ۱۰۰ کیلوگرم سولفات پتاسیم برای یک هکتار کشت باغی توصیه شد. درختان سه ساله و آبیاری به‌روش کرتی بوده است. فواصل درختان  $۳ \times ۴/۵$  در نظر گرفته شدند. نیاز آبی محصول شلیل رقم مغان با استفاده از سنجش رطوبت قبل آبیاری و با توجه به داده‌های هواشناسی ایستگاه میاندوآب به‌دست آمده و روش مدیریت زمان آبیاری نیز در نظر گرفته شد. با استفاده از مدل CROPWAT میزان تبخیر-تعرق، بارش مؤثر و نیاز آبی محاسبه شد. برای محاسبه نیاز آبی گیاه در این مدل، داده‌های دمای حداقل و حداکثر، رطوبت نسبی، میانگین ساعات آفتابی و سرعت باد، برای محاسبه تبخیر و تعرق به روش پنمن مانیتیت (FAO, 1992)، داده‌های بارش برای محاسبه بارش مؤثر بر اساس روش ASCE، اطلاعات جغرافیایی منطقه مورد مطالعه، نوع گیاه و ضرایب تعیین شده توسط فائو برای آن‌ها در دوره‌های مختلف رشد، مشخص نمودن نوع و خصوصیات خاک مورد نیاز است. در نهایت می‌توان با ضرب تبخیر و تعرق گیاه در ضریب گیاهی تعیین شده از سوی فائو و تفاضل آن با بارش مؤثر، نیاز آبیاری را محاسبه نمود. منبع تأمین آب مزرعه چاه بوده و دبی بخش تیمار و شاهد توسط فلوم WSC تیپ ۴ اندازه‌گیری شد. در این پژوهش، تمام عوامل زراعی از جمله آماده‌سازی زمین، روش کاشت، تقویم زراعی و تاریخ کاشت و برداشت، رقم محصول، نوع و میزان مصرف سموم و کودها، روش مبارزه با علف‌های هرز، سایر مدیریت‌های زراعی و آبیاری توسط مسئولین طرح تعیین و با نظارت کارشناسان آب کشاورزان ملزم به انجام آن بودند. پس از رسیدن کامل محصول، برداشت در تاریخ ۳۱ مرداد ۱۳۹۹ انجام شد. قبل از انجام پژوهش، تحلیل شیمیایی و فیزیکی خاک در عمق (۰-۹۰ سانتی‌متری از سطح زمین انجام شد (جدول‌های ۱ و ۲)).

راندمان کاربرد آب بیان‌گر تلفات موجود در مزرعه به‌صورت نفوذ عمقی و رواناب انتهایی مزرعه بوده و از رابطه ۱ به‌دست می‌آید.

در تخمین مکانی عملکرد برنج نسبت به روش رگرسیون چندگانه دارد. در ادامه، (Zareh-Abianeh (2012) به ارزیابی روش‌های شبکه عصبی مصنوعی و زمین‌آمار در برآورد توزیع مکانی عملکرد گندم آبی و دیم در خراسان رضوی پرداخت. نتایج مطالعه وی نشان داد که در بین روش‌های زمین‌آمار، روش کریجینگ ساده با نیم تغییرنمای دایره‌ای در پیش‌بینی عملکرد گندم دیم با مجذور میانگین مربعات خطای نرمال نسبت به روش‌های دیگر مورد استفاده مناسب‌تر بود. (Adab et al. (2013) نقشه عملکرد محصول کلزای پاییزه را با استفاده از شبکه عصبی پرسپترون را در شهرستان سبزوار تهیه نمودند. نتایج نشان از عدم وجود تفاوت بین مقادیر واقعی و پیش‌بینی شده در سطح معناداری ۰/۰۵ بود. Akbarpour et al. (2013) کارایی مدل‌های شبکه عصبی مصنوعی را در تخمین عملکرد محصول زعفران بر اساس پارامترهای اقلیمی ارزیابی کردند. نتایج نشان داد شبکه عصبی پیشنهادی با ضریب هم‌بستگی ۰/۹۵، میانگین قدر مطلق خطای ۰/۰۷ و میانگین مربعات خطای ۰/۲ از دقت مناسبی در تخمین عملکرد گیاه زعفران برخوردار بود. هم‌چنین، (Bariklo et al. (2017) به تخمین عملکرد گندم آبی با استفاده از روش الگوریتم ترکیبی شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک پرداختند. نتایج نشان داد مدل هیبریدی می‌تواند به‌عنوان یک ابزار قدرتمند در تخمین عملکرد گندم باشد.

با توجه به مطالعات صورت گرفته، در مورد تأثیر روش آبیاری شیاری دوطرفه در کاهش میزان آب آبیاری و نیز مدل‌سازی عملکرد محصول شلیل رقم مغان، مطالعات موثقی گزارش نشده است. لذا با توجه به شرایط طرح استقرار کشاورزی پایدار در حوضه دریاچه ارومیه، در پژوهش حاضر ابتدا به بررسی تأثیر رویکرد آبیاری شیاری دوطرفه بر عملکرد و کارایی مصرف آب در محصول شلیل رقم مغان و سپس با بهره‌گیری از دو مدل RBF و GFF شبکه عصبی مصنوعی به پیش‌بینی عملکرد محصول شلیل رقم مغان پرداخته شده است.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

جهت کاربرد روش شبکه عصبی مصنوعی برای پیش‌بینی عملکرد محصول شلیل رقم مغان، اراضی کشاورزی روستای دولت‌آباد واقع در شهرستان میاندوآب در استان آذربایجان غربی و جنوب شرقی دریاچه ارومیه با مختصات جغرافیایی مابین مدار ۵۹ درجه و ۱۱ دقیقه طول شرقی و ۴۰ درجه و ۴۳ دقیقه عرض شمالی در ارتفاع ۱۳۱۴ متر از سطح دریا انتخاب شده است (شکل ۱). آب و هوای منطقه متغیر بوده، دارای تابستان‌های



شکل ۱- موقعیت منطقه مورد مطالعه  
Figure 1- Location of the study area

جدول ۱- تحلیل شیمیایی و فیزیکی خاک قبل از انجام پژوهش در عمق ۰-۹۰ سانتی متری از سطح زمین

Table 1- Chemical and physical analysis of soil before conducting research at a depth of 0-90 cm from the ground surface

وزن مخصوص	PWP (سانتی متر مکعب بر سانتی متر مکعب)	FC (سانتی متر مکعب بر سانتی متر مکعب)	کربن آلی (درصد)	آهک TNV (درصد)	درصد رطوبت اشباع (حجمی) $\theta_s$	اسیدیته pH	بافت	شوری EC (دسی زیمنس بر متر)	سیلت (درصد)	شن (درصد)	رس (درصد)	عمق (سانتی متر)
1.25	0.14	0.328	1.12	9.6	43	8.13	Sic	0.908	52	13	35	0-30
1.25	0.149	0.331	0.95	9.2	55	8.06	Sic	0.545	48	11	41	30-60
1.25	0.144	0.328	-	16.6	43	8.24	Sic	0.822	52	13	35	60-90

جدول ۲- مشخصات فیزیکی و شیمیایی خاک

Table 2- Physical and chemical characteristics of soil

مساحت (هکتار)	الگو کشت	نوع واریته	بذر مصرفی (کیلوگرم بر هکتار)	تاریخ کاشت	تاریخ برداشت	نیترژن (درصد)	فسفر ppm	پتاسیم ppm	نیترژن مورد نیاز (کیلوگرم بر هکتار)	فسفر مورد نیاز (کیلوگرم بر هکتار)	پتاسیم مورد نیاز (کیلوگرم بر هکتار)
1.3	شلیل	مغان	-	3 ساله	-	8.5	5.4	292	50	60	100

ادامه جدول ۲- الف) نوع و مقادیر کودهای مصرفی

Table 2- a) Type and amounts of fertilizers used


نوع کود	مقدار و زمان مصرف
دی آمونیوم فسفات	100 گرم برای هر اصله درخت (چالکود)
سولفات پتاسیم	150 گرم برای هر اصله درخت (چالکود)
سولفات روی	100 گرم برای هر اصله درخت (چالکود)
سولفات آهن یا کلات آهن	200 گرم برای هر اصله درخت (چالکود)
گوگرد کشاورزی	350 گرم برای هر اصله درخت (چالکود)
باکتری تیوباسیلوس	2 کیلوگرم برای کل کودها مخلوط شده
سولفات پتاس	25 کیلوگرم در مرحله فندقی شدن

## ادامه جدول ۲- ب) کودهای مصرفی و تاریخ مصرف

Table 2- b) Fertilizers and date of use

زمان مصرف	مقدار مصرف (کیلوگرم در هکتار)	نوع کود
2020/03/26	60 کیلوگرم	دی‌آمونیم فسفات
2020/03/26	50 کیلوگرم	سولفات آمونیوم
2020/03/26	100 کیلوگرم	سولفات پتاسیم
2020/03/26	30 کیلوگرم	سولفات روی
2020/03/26	50 کیلوگرم	سولفات آهن یا کلات آهن
2020/03/26	100 کیلوگرم	گوگرد کشاورزی
	5 کیلوگرم برای کل کودها مخلوط شده	باکتری تیوباسیلیوس
	5 تن	کود حیوانی

از پرکاربردترین معماری شبکه‌های عصبی، شبکه‌های چند لایه پیش‌خور است. شبکه‌های پیش‌خور تعمیم یافته (GFF) حالت خاصی از شبکه‌های چندلایه MLP می‌باشد که در آن ارتباطات می‌توانند از یک و یا چند لایه پرش داشته باشند. شبکه‌های MLP بدون توجه به نوع مسأله، به تعداد سیکل‌های آموزشی و مدت زمان بیش‌تری نسبت به شبکه‌های GFF نیاز دارند. به‌طور کلی حالات در نظر گرفته شده برای توابع فعالیت و الگوریتم‌های آموزش در شبکه GFF دقیقاً شبیه به شبکه‌های MLP است. در شبکه‌های عصبی پیش‌خور عمومی نورون‌ها در لایه‌هایی که در آن‌ها اطلاعات از لایه ورودی به لایه خروجی به‌صورت یک لایه عبور می‌کنند، سازمان‌دهی شده‌اند.



شکل ۲- نمایشی از شبکه عصبی مصنوعی  
Figure 2- Artificial neural network structure

## ۲-۲-۲ مدل RBF

شبکه‌های با تابع مدار شعاعی به‌طور گسترده‌ای برای تخمین غیرپارامتریک توابع چندبعدی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به کار می‌رود. شبکه‌های عصبی شعاعی به واسطه آموزش سریع و فراگیر، بسیار جالب و مفید هستند و مورد توجه خاصی قرار گرفته‌اند (Nourani and Babakhani, 2012).

شبکه‌ای با تابع مدار شعاعی تقریب سازهای بسیار قدرتمندی هستند به‌طوری‌که با داشتن تعداد نرون‌های کافی در لایه مخفی، قادر به تقریب‌سازی هر تابع پیوسته و با هر درجه

$$E_a = \left( \frac{d_1}{d_2} \right) \times 100 \quad (1)$$

که در این رابطه،  $d_1$  عمق آب ذخیره شده در ناحیه ریشه گیاه و  $d_2$  عمق آب داده شده به جویچه‌هاست. مقادیر  $d_1$  با استفاده از رابطه ۲ و مقدار  $d_2$  به‌وسیله فلوام اندازه‌گیری می‌شود.

$$d_1 = (\theta_1 - \theta_2) \cdot \rho_b \cdot R_z \quad (2)$$

که در آن،  $\theta_1$  و  $\theta_2$  رطوبت وزنی خاک قبل و پس از آبیاری،  $\rho_b$  جرم مخصوص ظاهری خاک و  $R_z$  عمق توسعه ریشه است. برای اندازه‌گیری رطوبت خاک قبل و پس از آبیاری از منطقه توسعه ریشه‌ها نمونه‌برداری و پس از توزین و خشک کردن آن‌ها در آون و به‌دست آوردن وزن خاک خشک، میزان رطوبت خاک از سه نقطه ابتدا، وسط و انتهای مزرعه (در اعماق ۰-۹۰ سانتی‌متری) قبل و ۲۴ تا ۴۸ ساعت بعد از آبیاری تعیین شد.

## ۲-۲ مدل‌سازی عملکرد محصول شلیل مغان

تمامی مسائل بهینه‌سازی شامل دو مرحله مدل‌سازی و برنامه‌ریزی است که به‌ترتیب شامل تشکیل تابع هدف، قیود و محدودیت‌ها (مرحله اول، مدل‌سازی) و تعیین شرایط بهینه در رسیدن به جواب ایده‌آل (مرحله دوم، برنامه‌ریزی) می‌باشند. شبکه عصبی مصنوعی متشکل از مجموعه‌ای از نرون‌ها با ارتباطات داخلی بین یک‌دیگر است که قادر است بر اساس اطلاعات و داده‌های ورودی، جواب‌های خروجی را تهیه نماید. شبکه‌های عصبی معمولاً به‌صورت لایه لایه و منظم ایجاد می‌شوند. اولین لایه که اطلاعات و داده‌های ورودی به آن وارد می‌شوند لایه ورودی است. لایه‌های میانی لایه‌های مخفی و آخرین لایه که جواب‌های خروجی از مدل را فراهم می‌نماید، لایه خروجی است (Menhaj, 1998).

## ۲-۲-۱ مدل GFF

می‌توان کارایی مدل آموزش داده شده را بررسی نمود. پس از آموزش شبکه و صحت‌سنجی آن، شبکه قادر خواهد بود تا در مقابل داده‌های جدید قرار گیرد و خروجی مناسب را ارائه نماید.

### جدول ۳- مشخصات آماری پارامترهای ورودی و خروجی

Table 3- Statistical characteristics of input and output parameters

پارامترهای ورودی	پارامترهای خروجی
دبی متوسط ورودی (لیتر بر ثانیه)	راندمان کاربرد (درصد)
مدت آبیاری (دقیقه)	عملکرد محصول (کیلوگرم بر هکتار)
عمق آبیاری (میلی‌متر)	-
نیاز خالص آبیاری (میلی‌متر)	-

### ۲-۳- شاخص‌های ارزیابی

جهت مقایسه مدل‌ها با یکدیگر و ارزیابی آن‌ها نیاز به شاخص‌هایی است که بتواند کارکرد مدل‌ها را در کل مجموعه داده‌ها در مقایسه با نتایج تجربی، مورد قضاوت قرار دهد. در پژوهش حاضر از شاخص‌های ضریب هم‌بستگی ( $R^2$ )، میانگین قدر مطلق خطا (MAE) و جذر متوسط مربعات خطا (RMSE) برای این منظور استفاده شد (Ghorbani et al., 2017).

$$R^2 = \left[ \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n \sqrt{(x_i - \bar{x})^2} \sum_{i=1}^n \sqrt{(y_i - \bar{y})^2}} \right]^2 \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i) \quad (6)$$

$Y_i$  میانگین داده‌های مشاهداتی،  $n$  تعداد کل زوج داده‌های مشاهداتی و محاسباتی،  $X_i$  داده‌های تخمین زده شده، میانگین  $X$  و میانگین  $Y$  هاست. مقدار ایده‌آل برای  $R^2$  برابر یک است. بر اساس تعریف، قدرت پیش‌بینی مدل در صورتی که مقدار RMSE کم‌تر از ۱۰ درصد باشد، عالی، بین ۱۰ تا ۲۰ درصد باشد، خوب، بین ۲۰ تا ۳۰ درصد باشد، متوسط و اگر بالاتر از ۳۰ درصد باشد، ضعیف برآورد می‌شود (Tavassoli, 2014).

از آنجایی که وارد کردن داده‌ها به‌صورت خام باعث کاهش سرعت و دقت مدل می‌شود؛ بنابراین، ورودی‌ها و خروجی‌ها باید بین صفر و یک استاندارد شوند، از این‌رو داده‌های مورد استفاده به مدل به‌صورت رابطه ۷ استاندارد شدند.

$$X_n = \frac{1}{2} + \left\{ \frac{1}{2} \left( \frac{X_i - X_{mean}}{X_{max} - X_{min}} \right) \right\} \quad (7)$$

دقت است. نکته بسیار جالب آن است که این شبکه‌ها تنها با داشتن یک لایه مخفی، دارای چنین خاصیتی هستند. شبکه‌های تابع مدار شعاعی بیش‌ترین الهام را از تکنیک‌های آماری طبقه‌بندی الگوها گرفته‌اند که اساساً به‌عنوان گونه‌ای از شبکه‌های عصبی، حیاتی نو یافته‌اند و مزیت عمده آن‌ها طبقه‌بندی الگوهای است که دارای فضای غیرخطی هستند. معماری اصلی شبکه RBF متشکل از یک شبکه سه لایه است. لایه ورودی فقط یک لایه ورودی است و در آن هیچ پردازشی صورت نمی‌گیرد. لایه دوم یا لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولاً با بعد بزرگ‌تر برقرار می‌کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک‌پذیر خطی دارد. سرانجام لایه سوم، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند.

شکل کلی ریاضی نرون‌های خروجی در شبکه RBF به شکل معادله زیر است:

$$C_j(x) = \sum_{i=1}^k W_{ij} \Phi(\|x - \mu_i\|; \sigma_i) \quad (3)$$

که در این معادله،  $C_j(x)$  تابع وابسته به زمین واحد خروجی و ترکیب خطی از  $k$  تابع پایه شعاعی  $\Phi()$  با مرکز  $\mu_i$  و پهنای باند  $\sigma_i$  و هم‌چنین وزن وابسته به زمین کلاس و  $i$  امین کلاس و  $i$  امین مرکز است. تابع  $\Phi(\|x - \mu_i\|)$  تابع پایه شعاعی نامیده می‌شود.

روش RBF برای معادلات مشتقات جزئی ارائه شده است. از رایج‌ترین توابع شبکه RBF می‌توان روش‌های conical، Multiquadric (MQ)، Gaussian (Gs) را نام برد. از میان روش‌های مختلف آموزش به روش پس انتشار خطا، الگوریتم لوبنرگ-ماکورات، به دلیل هم‌گرایی سریع‌تر در آموزش شبکه‌های با اندازه متوسط، برای استفاده در پژوهش حاضر انتخاب شده است.

### ۲-۲-۳- مجموعه داده‌ها

جهت مدل‌سازی و پیش‌بینی با روش شبکه عصبی مصنوعی ابتدا از خصوصیات خاک از عمق ۰-۹۰ سانتی‌متری باتوجه به چندساله بودن محصول انتخابی نمونه‌برداری انجام شد. سپس ویژگی‌های خاک مزرعه (جدول ۱) و دو سطح آبیاری کرتی و آبیاری شیری دوطرفه به‌عنوان پارامترهای مورد نیاز به‌عنوان ورودی و عملکرد محصول شلیل مغان به‌عنوان خروجی مدل در نظر گرفته شد (جدول ۳). بر این اساس، از مجموعه داده گردآوری شده شامل ۱۴۰ داده، ۸۰ درصد داده‌های موجود به‌منظور آموزش شبکه و ۲۰ درصد داده‌ها برای آزمون دو مدل RBF و GFF استفاده شد. با استفاده از صحت‌سنجی داده‌ها،

(جدول ۵). مقادیر بهره‌وری برآورد شده در بخش تیمار و شاهد به ترتیب ۲/۲۴ و ۱/۵۲ کیلوگرم بر مترمکعب محاسبه گردید. به این ترتیب اعمال تیمار برنامه‌ریزی آبیاری زمان واقعی موجب افزایش بهره‌وری آب (حدود ۰/۷۲ کیلوگرم بر مترمکعب) در این مزرعه شد (جدول ۶). هم‌چنین با توجه به مقدار بارش مؤثر (بر اساس رابطه ASCE) که در طی فصل رشد محصول سیب در سال زراعی ۹۹-۱۳۹۸ (شهرستان میاندوآب) ۶۱۰ میلی‌متر بوده، مقادیر بهره‌وری با لحاظ بارش مؤثر نیز محاسبه و مقدار افزایش آن در بخش تیمار نسبت به شاهد ۳۱/۵ درصد برآورد گردید.

### ۳-۳- نتایج مدل‌سازی

عملکرد شبکه عصبی مصنوعی برای برگزیدن بهترین جواب، توسط پارامترهای آماری ضریب تعیین ( $R^2$ )، RMSE و MAE بر روی هر دو مجموعه داده آموزش و آزمون کنترل گردید تا پس از سعی و خطای بسیار، بهینه‌ترین شبکه از لایه ورودی به میانی و میانی به خروجی به دست آمد. در جدول‌های ۷ و ۸ به ترتیب وزن‌های ارتباطی و ثابت‌های بین لایه ورودی به میانی و هم‌چنین لایه میانی به خروجی را برای مدل بهینه انتخاب شده با ۵ نرون در لایه میانی ارائه شده است. با استفاده از این ضرایب و ثابت‌ها و تابع انتقال به کار رفته در شبکه، به راحتی می‌توان شبکه عصبی مصنوعی را شبیه‌سازی و از آن برای پیش‌بینی عملکرد شلیل تنها با انجام محاسبات ساده، استفاده کرد.

### ۳-۴- تعیین بهترین توپولوژی (تعداد گره آموزشی و نرون، تعداد لایه، تابع مناسب آموزشی)

برای تعیین توپولوژی شبکه، از محاسبه ضریب رگرسیون و تحلیل خطا استفاده گردید (جدول ۹). بهترین توپولوژی انتخاب و به همراه نمودار مقایسه مقادیر مشاهداتی و پیش‌بینی شده و جدول تحلیل رگرسیون و خطا برای عملکرد دانه محصول شلیل ارائه شده است. بهترین توپولوژی، تابع تانژانت سیگموئید خطی با ۱۰۰۰ تکرار آموزشی حاصل شد (جدول ۱۰). نتایج حاصل نشان‌دهنده دقت شبکه‌های عصبی مصنوعی در پیش‌بینی عملکرد محصول شلیل با توجه به خطای پایین پیش‌بینی و ضریب رگرسیون بین مقادیر اندازه‌گیری و پیش‌بینی شده بالای ۹۰ درصد ( $R^2=0.95$ ) است.

در این رابطه،  $X_n$  مقادیر استاندارد شده،  $X_i$  مقادیر مشاهداتی،  $X_{min}$  حداقل مقادیر مشاهداتی و  $X_{max}$  حداکثر مقادیر مشاهداتی است.

### ۳- نتایج و بحث

#### ۳-۱- نتایج پایش میدانی

در مزرعه پایش، کلیه پارامترها جهت ارزیابی کامل آبیاری، برداشت شد. در این مزرعه روش مدیریت زمان آبیاری در نظر گرفته شد. دبی تیمار و شاهد توسط فلوم WSC اندازه‌گیری شد. خلاصه نتایج عمق آبیاری، متوسط دبی جریان، مدت آبیاری، عمق خالص مورد نیاز، راندمان کاربرد آبیاری اول تا پنجم در جدول ۴ ارائه شده است. مدت آبیاری، عمق آبیاری و نیاز خالص آبیاری به ترتیب بر اساس، مدت زمانی که طول می‌کشد تا کرت یا شیار مورد نظر آبیاری شود و حجم ورودی بر مساحت قطعه مورد نظر محاسبه شدند.

با توجه به نتایج به دست آمده، آبیاری اول به دلیل خشکی سطح مزرعه و نیز تأثیر عملیات خاک‌ورزی بر خاک مزرعه و در نتیجه کندی حرکت آب در طول شیارها دارای پائین‌ترین راندمان کاربرد آب است. نفوذپذیری خوب خاک مزرعه موجب افزایش تلفات به صورت نفوذ عمقی شده است. در مجموع می‌توان نتیجه گرفت که استفاده از روش آبیاری شیار دوطرفه و مدیریت زمان آبیاری موجب افزایش راندمان کاربرد در این مزرعه شده است.

مقادیر عمق آبیاری در بخش‌های تیمار و شاهد طی کل دوره رشد و میزان کاهش مصرف آب در بخش تیمار در مقایسه با بخش شاهد در طی پنج نوبت آبیاری در شکل ۳ نشان داده شده است. بر اساس نتایج حاصله متوسط کاهش آب آبیاری در بخش تیمار نسبت به بخش شاهد، ۳۱/۷ درصد محاسبه شد. هم‌چنین میزان مصرف آب در بخش تیمار و شاهد به ترتیب ۵۷۹۳ و ۶۵۶۶/۹ مترمکعب بر هکتار محاسبه شد که بیان‌گر کاهش ۱۱/۸ درصدی در میزان مصرف آب (۷۳۳/۹ مترمکعب بر هکتار) تیمار نسبت به شاهد است.

#### ۳-۲- عملکرد محصول و بهره‌وری آب

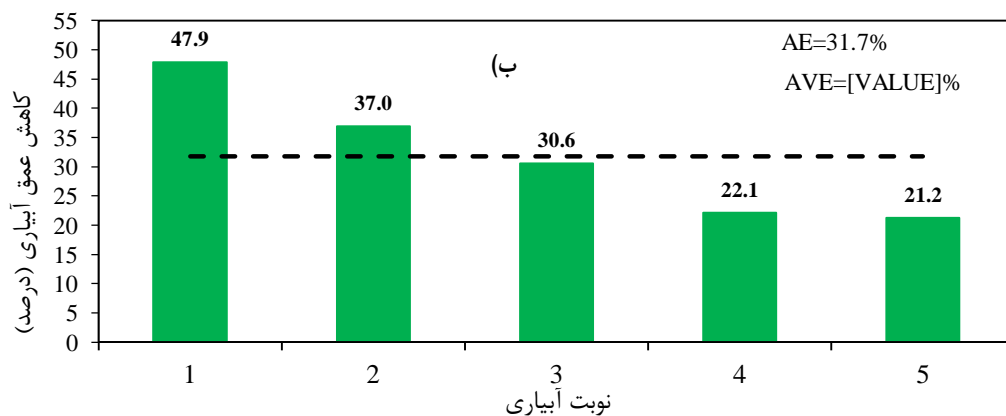
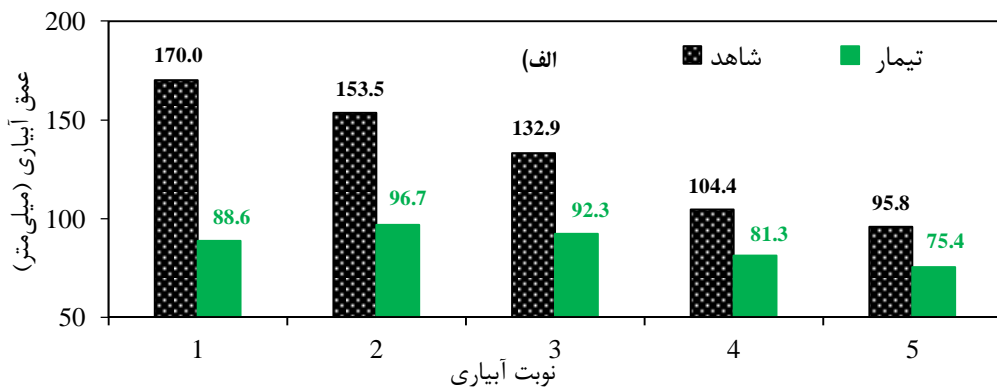
بر اساس نتایج، میزان عملکرد برآورد شده در بخش‌های تیمار و شاهد به ترتیب ۱۳۰۰۰ و ۱۰۰۰۰ کیلوگرم در هکتار به دست آمد و میزان عملکرد تیمار نسبت به شاهد ۲۳ درصد افزایش یافت



جدول ۴- مقادیر متوسط عمق آبیاری، دبی ورودی جریان، نیاز خالص آبیاری و راندمان کاربرد

Table 4- Average values of irrigation depth, inlet flow, net irrigation requirement and application efficiency

راندمان کاربرد (درصد)	نیاز خالص آبیاری (میلی‌متر)		عمق آبیاری (میلی‌متر)		مدت آبیاری (دقیقه)		دبی متوسط ورودی (لیتر بر ثانیه)		نوبت آبیاری	
	شاهد	تیمار	شاهد	تیمار	شاهد	تیمار	شاهد	تیمار		
23.2	45.4	22.2	36.9	170	88.6	195	110	8.72	7.25	آبیاری اول
34.3	46.6	52.6	45.1	153.5	86.7	176	94	8.72	9.26	آبیاری دوم
48.8	53.7	64.8	49.6	132.9	92.3	156	90	8.52	9.23	آبیاری سوم
25.5	46.9	26.6	38.1	104.4	81.3	120	80	8.70	9.15	آبیاری چهارم
23.9	45	22.9	33.5	95.8	75.4	110	73	8.71	9.30	آبیاری پنجم



شکل ۳- مقایسه مقادیر عمق آبیاری (الف) و کاهش آب آبیاری (ب) تیمار و شاهد طی آبیاری‌های مختلف

Figure 3- Comparison of irrigation depth values (a) and reduction of irrigation water (b) of treatment and control during different irrigations

جدول ۵- مقادیر عملکرد محصول و بهره‌وری آب در تیمار و شاهد

Table 5- Crop yield and water productivity values in treatment and control

عملکرد برآوردی (کیلوگرم بر مترمکعب)		بهره‌وری آب مصرفی (کیلوگرم بر مترمکعب)		بهره‌وری با لحاظ بارش مؤثر (کیلوگرم بر مترمکعب)	
شاهد	تیمار	شاهد	تیمار	شاهد	تیمار
10000	13000	1.52	2.24	1.39	2.03

جدول ۶- مقایسه مقادیر بهره‌وری آب مصرفی در بخش‌های تیمار و شاهد

Table 6- Comparison of water-use efficiency values in treatment and control sections

کاهش آب مصرفی (درصد)	افزایش بهره‌وری برآوردی (کیلوگرم بر مترمکعب)	افزایش بهره‌وری برآوردی (درصد)	افزایش بهره‌وری با لحاظ بارش مؤثر (درصد)
11.8	0.72	47.7	45.7

جدول ۷- وزن‌های ارتباطی مدل ANN

Table 7 - Communication weights of ANN model

وزن‌های ارتباطی			لایه پنهان
تعداد داده‌ها	آبیاری کرتی	آبیاری شیاری دوطرفه	
-3.1	-2.45	-0.39	
0.032	0.25	-0.34	1
0.00	-0.102	-1.11	2
0.22	0.84	0.94	3
-0.081	-0.75	-0.46	4
0.026	-0.78	-1.00	5

جدول ۸- ثابت‌های مدل ANN

Table 8 - ANN model constants

Bias				
خروجی	نرون‌های پنهان			
1	1	2	3	2
-2.20	3.65	1.80	-0.31	-0.25
				0.91

جدول ۹- تحلیل خطای بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برای عملکرد محصول شلیل

Table 9 - Error analysis between measured and predicted values for nectarine crop yield

مقدار	معیار
2.18	MAE
3.74	Min Abs Error
0.13	Max Abs Error
0.95	R <sup>2</sup>

جدول ۱۰- تحلیل خطای بین مقادیر اندازه‌گیری شده و پیش‌بینی شده برای عملکرد محصول شلیل

Table 10 - Error analysis between measured and predicted values for nectarine crop yield

بهبودترین تابع آموزش	تعداد لایه	تعداد گره آموزشی	ضریب رگرسیون
تانزانته سیگموئید خطی	1	1000	0.951
سیگموئید خطی	2	5000	0.920

الف) نتایج حاصل از مرحله آموزش و آزمون مدل شبکه عصبی در این پژوهش، پارامترهای مشخصات خاک مزرعه و سطوح آبیاری (آبیاری کرتی و شیاری دوطرفه)، به‌عنوان پارامترهای ورودی در هر دو مدل شبکه عصبی مورد بررسی قرار گرفت. پارامتر خروجی، عملکرد محصول شلیل بود. پس از بررسی‌ها، تعداد ۱۰۰۰ سیکل و تعداد یک لایه پنهان برای پارامتر عملکرد محصول مناسب به‌نظر آمد. بهترین نتایج به‌دست آمده برای هر یک از مدل‌های شبکه عصبی مصنوعی در جدول ۱۱ ارائه شده است.

نتایج حاصل از پژوهش حاضر با نتایج پژوهش‌گرانی هم‌چون Seiler et al. (1998)، Tiscareno-Lopez et al. (2003) و Rahmani et al. (2008) که مدل بهینه اجرا شده توسط آنان دارای ضریب تبیین کم‌تر و یا مساوی ۰/۹ بود، هم‌خوانی داشته و حتی نتایج مطالعات آن‌ها را بهبود بخشید.

۳-۵- مقایسه دو مدل RBF و GFF در پیش‌بینی عملکرد محصول شلیل

جدول ۱۱- مقایسه شبکه‌های مختلف در پیش‌بینی عملکرد محصول شلیل  
Table 11 - Comparison of different networks in predicting nectarine crop yield

نوع شبکه	تابع انتقال	الگوریتم آموزش	مرحله آموزش شبکه		مرحله آزمایش شبکه	
			RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>
RBF	SigmoidAxon	Momentum	0.026	0.95	0.035	0.92
GFF	SigmoidAxon	Momentum	0.041	0.89	0.042	0.85

با نرون‌های متفاوت مورد آموزش و آزمایش واقع شدند و پس از اعمال الگوهای مختلف و آموزش شبکه، بهترین الگو از بین الگوهای برگزیده انتخاب شد (جدول ۱۲). پس از اعمال مجموعه آزمایش به شبکه‌های آموزش داده شده برگزیده، تعمیم‌دهی شبکه‌ها مورد بررسی قرار گرفت و در نهایت شبکه‌ای که بهترین تعمیم‌دهی را در مجموعه آزمون نشان داد، به‌عنوان شبکه مطلوب برای پیش‌بینی عملکرد محصول شلیل انتخاب شد.

با توجه به نتایج حاصله و پس از مقایسه نتایج دو شبکه RBF و GFF، شبکه‌های از نوع RBF (تابع با پایه شعاعی) با پارامترهای سطوح مختلف آبیاری به‌عنوان ورودی، بهترین شبکه شناخته شد. ضریب هم‌بستگی به دست آمده برابر ۰/۹۲ و جذر میانگین مربعات خطا برابر ۰/۰۳۵ است.


ب) انتخاب بهترین مدل داده‌های سطوح مختلف آبیاری توسط شبکه‌های عصبی RBF و GFF با الگوریتم‌های آموزش مختلف با یک و دو لایه مخفی و

جدول ۱۲- الگوهای برگزیده آزمون از بین الگوهای پیشنهادی برای تخمین عملکرد محصول شلیل  
Table 12- Selected test patterns from the proposed patterns for estimating nectarine crop yield

R <sup>2</sup> مجموعه	MSE صحت‌سنجی	R <sup>2</sup> مجموعه	تعداد نرون‌های لایه مخفی دوم	تعداد نرون‌های لایه مخفی اول	نوع آموزش شبکه	نوع شبکه
0.82	0.098	0.85	-	4		
0.83	0.081	0.86	10	8	Momentum	
0.87	0.050	0.91	-	8		
0.88	0.067	0.87	8	5	Conjugate Gradient	GFF
0.86	0.062	0.091	10	9		
0.88	0.058	0.97	-	2	Levenberg Marquardt	
0.87	0.064	0.97	4	2		
0.90	0.053	0.91	-	5		
0.91	0.044	0.90	-	6	Momentum	
0.93	0.60	0.90	-	8		
0.85	0.069	0.87	4	4		
0.92	0.045	0.91	-	5		
0.92	0.034	0.91	-	10		
0.89	0.057	0.93	8	5	Conjugate Gradient	RBF
0.88	0.076	0.91	5	6		
0.93	0.043	0.99	-	5		
0.95	0.032	0.99	-	4	Levenberg Marquardt	
0.90	0.049	0.98	5	5		
0.89	0.053	0.99	9	7		

میزان عملکرد محصول شلیل نقش به‌سزایی دارد. در واقع میزان و نوع آبیاری، بر توسعه برگ‌ها و نمو زایشی گیاه تأثیر داشته و نیز از طریق اثر بر تعادل عرضه و تقاضای آب بر میزان عملکرد محصول مؤثر است. بنابراین، پس از حصول نتایج بهینه مدل RBF، نسبت عملکرد محاسبه شده به نسبت تغییرات سطوح آب آبیاری با استفاده از این مدل پیش‌بینی شد (شکل ۴).

با توجه به نتایج ارائه شده در جدول ۱۲، شبکه RBF با آموزش شبکه Levenberg Marquardt و تعداد ۲ لایه مخفی بهترین نتایج را ارائه داد. بر اساس مطالعات انجام شده توسط سایر پژوهش‌گران (Kaul et al., 2005; Bagheri et al., 2012)، پارامتر آب قابل دسترس یکی از پارامترهای اساسی در تخمین عملکرد محصولات کشاورزی است. تحلیل حساسیت در این پژوهش نیز مشخص کرد که پارامتر سطوح آب آبیاری در برآورد



شکل ۴- نسبت عملکرد محاسبه شده توسط شبکه عصبی RBF در تیمارهای مورد پژوهش  
Figure 4- Performance ratio calculated by RBF neural network in research treatments

شیارها با توجه به خصوصیات خاک و شیب زمین و نیز تسطیح و یکپارچه‌سازی اراضی، انتخاب دبی ورودی مناسب به شیارها و مانع از ایجاد رواناب در انتهای شیارها، از عوامل اصلی در افزایش راندمان کاربرد در روش پیشنهادی است. در ادامه، پس از اجرای مدل‌ها، نتایج نشان داد که شبکه عصبی مصنوعی مدل RBF (تابع با پایه شعاعی) در پیش‌بینی مقدار عملکرد، نتایج بهتری نسبت به مدل GFF شبکه عصبی دارا بوده است. پس از مقایسه نتایج شبکه‌های مختلف، شبکه‌های عصبی از نوع تابع با پایه شعاعی (RBF) با پارامتر سطوح مختلف آبیاری به‌عنوان ورودی، بهترین شبکه شناخته شد.

#### ۴- نتیجه‌گیری

بر اساس نتایج حاصله از پژوهش حاضر می‌توان بیان کرد که روش آبیاری شیاری دوطرفه علاوه بر کاهش میزان آب مصرفی باعث افزایش عملکرد محصول شد. همچنین بر اساس نتایج، بیش‌ترین تلفات آب در آبیاری اول وجود داشت. کارایی متوسط مقدار کارائی کاربرد آب به‌ترتیب در بخش تیمار و شاهد، ۲/۲۴ و ۱/۵۲ کیلوگرم بر مترمکعب محاسبه شد که بخش عمده تلفات به‌صورت نفوذ عمقی بوده است. با توجه به نتایج حاصله مدیریت زمان آبیاری، انتخاب زمان شروع آبیاری، مقدار آب آبیاری متناسب با نیاز آبی محصول، انتخاب طول، عرض و عمق مناسب

#### منابع

- زارع ایبانه، ح. (۱۳۹۱). ارزیابی روش‌های شبکه عصبی مصنوعی و زمین آمار در برآورد توزیع مکانی عملکرد گندم دیم و آبی (مطالعه موردی: خراسان رضوی). *پژوهش‌های جغرافیایی طبیعی*، ۴۴(۴)، ۲۳-۴۲.
- طالبی، ح. (۱۳۹۷). کالیبراسیون و بهبود شاخص‌های عملکرد آبیاری شیاری (مطالعه موردی: کشاورزی، صنعت و دامداری مغان). پایان‌نامه کارشناسی ارشد، دانشگاه محقق اردبیلی.
- فتحی ترشیزی، م. (۱۳۹۱). ارزیابی میدانی مدل‌های آبیاری سطحی تحت آبیاری با آب شور (مطالعه موردی آبیاری شیاری). پایان‌نامه کارشناسی ارشد، دانشگاه فردوسی مشهد.

- اسمعیل‌زاده کردخیلی، س. (۱۳۹۱). برآورد عملکرد برنج با استفاده از روش‌های زمین آماری، شبکه‌های عصبی مصنوعی و رگرسیون چندگانه در شالیزارهای لشت نشای استان گیلان. پایان‌نامه کارشناسی ارشد، دانشگاه ولی عصر رفسنجان.
- رحمانی، ا.، لیاقت، ع.، و خلیلی، ع. (۱۳۸۷). تخمین عملکرد محصول جو در آذربایجان شرقی با استفاده از پارامترهای هواشناسی و شاخص‌های خشک‌سالی به روش شبکه عصبی مصنوعی. *تحقیقات آب و خاک ایران (علوم کشاورزی ایران)*، ۳۹(۱)، ۴۷-۵۶.

## References

- Akbarpour, A., Khorashadizadeh, A., Shahidi, A., & Ghochanian, A. (2013). Evaluation of artificial neural network model in estimation of Saffron crop performance based on climate parameters. *Saffron Research Journal*, 1(1), 27-35.
- Alvarez, A. (2009). Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *European Journal of Agronomy*, 30, 70-77.
- Bagheri, S., Gheisari, M., Aubi, Sh. A., & Lavaie, N. (2012). Prediction of forage maize yield using artificial neural networks. *Journal of Plant Production Research (JOPPR)*, 19(4), 77-94.
- Bariklo, A., Alamdari P., Moravaj K., & 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.
- Esmailzadeh-KordKheili, S. (2012). Estimation of rice yield using statistical methods, artificial neural network and multi-regression methods in Giullan. M.Sc. Thesis, Vali-Asr University, Rafsanjan (in Persian).
- FAO. (1992). CROPWAT a computer program for irrigation planning and management, by M. Smith. FAO Irrigation and Drainage Paper No. 46. Rome.
- Fathi Tarshizi, M. (2012). Field evaluation of surface irrigation models under irrigation with saline water (Case study of furrow irrigation). M.Sc. Thesis, Ferdowsi University of Mashhad, Mashhad (in Persian).
- Gershenfeld, N. A., & Gershenfeld, N. (1999). The nature of mathematical modeling. Cambridge university press.
- Ghorbani, M. A., Shahabboddin, Sh., Zare Haghi, D., Azani, A., Bonakdari, H., & Ebtehaj, I. (2017). Application of Firefly algorithm-based support vector machines for prediction of filed capacity and permanent wilting point. *Soil and Tillage Research*, 172, 32-38.
- Kaul, M., Hill, R.L., & Walthall, C. (2005). Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems*, 85, 1-18.
- Landeras, G., Ortiz-Barredo, A., & López, J. (2009). Forecasting weekly evapotranspiration with ARIMA and artificial neural network models. *Irrigation and Drainage Engineering, ASCE*, 135, 323-334.
- Merdun, H., Çınar, Ö., Meral, R., & Apan, M. (2009). Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil and Tillage Research*, 90, 108-116.
- Nourani, V., & Babakhani, A. (2012). Integration of artificial neural networks with radial basis function interpolation in earthfill dam seepage modeling. *Journal of Computing in Civil Engineering*, 27(2), 183-195.
- Piri, J., Amin, S., Moghaddamnia, A., Keshavarz, A., Han, D., & Remesan, R. (2009). Daily pan evaporation modeling in a hot and dry climate. *Journal of Hydrologic Engineering, ASCE*, 15(8), 803-811.
- Rahmani, E., Liaghat, A., & Khalili, A. (2008). Estimating barley yield in eastern azerbaijan using drought indices and climatic parameters by artificial neural network (ANN). *Iranian Journal of Soil and Water Research*, 39(1), 47-56 (in Persian).
- Smith, B.A., Hoogenboom, G., & McClendon, R.W. (2009). Artificial neural networks for automated year-round temperature prediction. *Computers and Electronics in Agriculture*, 68(1), 52-61.
- Seiler, R.A., & Kogan, F. (1998). AVHRR-based vegetation and temperature condition indices for drought detection in Argentina. *Advances in Space Research*, 21(3), 481-484.
- Taghizadeh Mehrjerdi, R., Seyedjalali, S.A., & Sarmadian, F. (2016). Prediction of corn spatial yield by soil digital mapping in Gotend region (Khuzestan Province, Iran). *Journal of plant production*, 19 (4), 70-96.
- Talebi, H. (2018). Calibration and improvement of furrow irrigation performance indices (case study: Moghan Agriculture, Industry and Animal Husbandry). M.Sc. Thesis, Mohaghegh Ardabili University, Ardabil (in Persian).
- Zareh-Abyaneh, H. (2012). Evaluation of Artificial Neural Network and Geostatistical Methods in Estimating the Spatial Distribution of Irrigated and Dry Wheat Yield (Case Study: Khorasan Razavi). *Physical Geography Research Quarterly*, 44 (4), 23-42 (in Persian).