

عملکرد مدل‌های شبکه عصبی پرسپترون چندلایه و توابع با پایه شعاعی در برآورد میزان محصول نیشکر

سینا شریفی^۱، نسیم منجزی^{۲*}، نگار حافظی^۱

تاریخ دریافت: ۹۸/۱۲/۳ تاریخ پذیرش: ۹۹/۵/۲۱

۱- دانشجوی دکتری مکانیزاسیون کشاورزی، گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران

۲- استادیار گروه مهندسی بیوسیستم، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، اهواز، ایران

*مسئول مکاتبه: Email: n.monjezi@scu.ac.ir

چکیده

اهداف: با توجه به اهمیت بالای تولید پایدار محصولات کشاورزی در واحدهای کشت و صنعت نیشکر، باید از سیستم‌های هوشمند مانند شبکه‌های عصبی مصنوعی جهت مدیریت واحدهای مزرعه استفاده کرد. بدین منظور، هدف اصلی تحقیق، مقایسه عملکرد مدل‌های شبکه عصبی پرسپترون چندلایه و توابع پایه شعاعی به منظور مدل‌سازی و پیش‌بینی عملکرد نیشکر و بررسی عوامل موثر بر آن بود.

مواد و روش‌ها: این تحقیق از نوع تحلیلی بوده و پایگاه داده‌های آن ماتریسی به ابعاد $[1010 \times 10]$ درایه بود. داده‌های مورد نیاز این تحقیق طی سال‌های زراعی ۱۳۹۵ تا ۱۳۹۸ از واحد کشت و صنعت نیشکر دعبل خزاعی به دست آمد. متغیرهای ورودی مدل و واحدهای آنان به ترتیب شامل میزان هدایت الکتریکی خاک (دسی‌زیمنس بر متر)، مقدار کود شیمیایی فسفات و نیتروژن (کیلوگرم بر هکتار)، مقدار آب مصرفی (مترمکعب بر هکتار)، همچنین، تعداد دفعات آبیاری، ماه برداشت محصول، سن گیاه، واریته گیاه، و بافت خاک (بدون ابعاد) بودند. متغیر خروجی، میزان عملکرد (تن بر هکتار) بود. تجزیه و تحلیل توسط نرم‌افزار متلب ۲۰۱۷ انجام شد.

یافته‌ها: با مقایسه پارامترهای خطای میانگین درصد خطای مطلق و جذر میانگین مربعات خطا و با توجه به شاخص‌های ضریب تبیین و بازده مدل، مدل توابع پایه شعاعی به ترتیب با داشتن $0/064494$ (درصد)، $0/037686$ ، $0/07576$ و $0/800409$ (بدون ابعاد) در مرحله اعتبارسنجی به عنوان مدل برتر انتخاب شد. همچنین، مدل توابع پایه شعاعی، متغیرهای واریته گیاه و میزان هدایت الکتریکی خاک را مهم‌ترین عامل موثر بر میزان عملکرد محصول نیشکر بیان کرد.

نتیجه‌گیری: با انتخاب واریته مناسب گیاه نیشکر و کنترل میزان هدایت الکتریکی خاک می‌توان عملکرد در واحد سطح را افزایش داد و سبب بهره‌وری بیشتر از نهاده‌ها و تولید پایدارتری شد.

واژه‌های کلیدی: توابع پایه شعاعی، شبکه، عملکرد، مدل‌سازی، نیشکر

Performance of Multilayer Perceptron Neural Network Models and Radial-Based Functions in Estimation of Sugar-cane Crop Yield

Sina Sharifi¹, Nasim Monjezi^{2*}, Negar Hafezi¹

Received: February 22, 2020 Accepted: August 11, 2020

1-PhD Student of Agricultural Mechanization, Dept. of Biosystems Engineering, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahwaz, Iran

2- Assist. Prof., Biosystems Engineering Dept., Faculty of Agriculture, Shahid Chamran University of Ahvaz, Ahvaz, Iran.

*Corresponding Author Email: n.monjezi@scu.ac.ir

Abstract

Background and objective: According to the high importance of sustainable crop production in the agro-industry units, intelligent systems such as artificial neural networks should be used to manage farm units. Therefore, the main purpose of this study was to compare the performance of MLP (Multi-Layer Perceptron) and RBF (Radial Basis Functions) neural network models in order to modeling and estimating of the sugarcane crop yield and investigate the factors affecting it.

Materials and Methods: The study was analytical and its database contained of a matrix [1010 × 10] elements. Required data for this research were obtained from the Debel Khazaei sugar cane agro-industry farm during the years 2016 to 2019. The input variables and their units were soil electrical conductivity (dS.m^{-1}), Phosphate and Nitrogen chemical fertilizer (kg.ha^{-1}), water consumption ($\text{m}^3.\text{ha}^{-1}$), also, irrigation times, month of harvest, age of crop, sugarcane variety, soil texture (non-dimensional), respectively. The analysis was performed by MATLAB 2017 software.

Results: By comparing the error parameters of RMSE (Root Mean Square Error) and the MAPE (Mean Absolute Percentage Error), and according to indexes of R^2 (coefficient of determination) and the EF (Model Efficiency) and, in the validation phase the RBF model was the best model with 0.064494 (%), 0.037686, 0.7576 and 0.800409 (non-dimensional) respectively. Also, the RBF model indicated that the sugarcane variety and soil electrical conductivity were the most important factors affecting the sugar-cane yield.

Conclusion: By selecting the appropriate variety of sugarcane and controlling the amount of electrical conductivity of the soil, the yield per unit area can be increased, resulting in greater productivity of the inputs and more sustainable production.

Keywords: Modeling, Network, Radial Basis Functions, Sugar-cane, Yield

مقدمه

نیشکر با نام علمی *Saccharum officinarum* گیاه چند ساله از خانواده Poaceae، که هدف اصلی از کشت آن تولید شکر می‌باشد. اکثر نیشکر جهان در مناطق نیمه گرمسیری و گرمسیری کشت داده می‌شود. در حال حاضر ۹۷/۶۹ درصد از اراضی سطح زیر کشت نیشکر کشور در استان خوزستان قرار دارد و با توجه به اینکه کل نیاز کشور به شکر حدود ۲,۱۰۰,۰۰۰ تن است، از این مقدار ۱,۴۰۰,۰۰۰ تن آن در داخل کشور تولید می‌شود و سهم کشت و صنعت‌های هفتگانه استان خوزستان ۵۰ درصد می‌باشد (مرعشی و همکاران ۲۰۱۹). همچنین، سطح زیرکشت نیشکر در استان خوزستان، ۱۳۵ هزار هکتار است. محصول نیشکر در فرآیند تولید به دلیل اهمیت زیادی که در زمینه انتخاب و بهره‌گیری از نهاده‌های مصرفی در شرایط مختلف کشت برخوردار است، همواره مورد توجه مدیران واحدها بوده است. بنابراین بهینه‌سازی و مدل‌سازی عملکرد محصول نیشکر بسیار حائز اهمیت می‌باشد (ذکی دیزجی و همکاران ۲۰۱۸). امروزه مدل‌های هوش محاسباتی مانند شبکه‌های عصبی مصنوعی^۱ (ANN) به دلیل انعطاف‌پذیری بالا و توانایی تخمین دقیق روابط غیرخطی بدون نیاز به فرضیات و محدودیت‌های مدل‌های کلاسیک آماری به رویکردی غالب در مسائل پیش‌بینی، مدل‌سازی و بهینه‌سازی تبدیل شده‌اند. از محدودیت‌های روش‌های کلاسیک آماری می‌توان به وجود خطای قابل توجه، به دلیل در نظر گرفتن توزیعی پیش‌فرض مانند توزیع نرمال برای متغیرهای پاسخ، خطی بودن رابطه پیشنهادی، یکسان بودن واریانس خطاها اشاره کرد، در حالی که شبکه‌های عصبی هیچ فرض اولیه‌ای بر توزیع داده‌ها تحمیل نمی‌کند و نیز هیچ محدودیتی نیز برای شکل

تابعی بین رابطه‌ی متغیرهای مستقل و وابسته اعمال نمی‌کند (سدهی و همکاران ۲۰۰۹).

به طور کلی ساختار شبکه‌های عصبی را می‌توان به دو دسته کلی شبکه‌های پیش‌خور^۲ (FNN) و شبکه‌های پس‌خور^۳ (RNN) تقسیم‌بندی نمود. شبکه‌های پیش‌خور دارای انواع متفاوتی هستند که از مهم‌ترین آن‌ها می‌توان به شبکه پرسپترون چند لایه^۴ (MLP) و شبکه با توابع پایه شعاعی^۵ (RBF) اشاره کرد (ساندرمیر و همکاران ۲۰۱۳، هاشمی فتح و همکاران ۲۰۱۸). ابه و شانگودوئین (۲۰۱۰) طی تحقیق خود با هدف پیش‌بینی عملکرد نیشکر در کشور نیجریه به این نتیجه دست یافتند که ANN توسعه داده شده با دو لایه پنهان متشکل شده از چهار نورون با داشتن ۸۷/۵ درصد دقت پیش‌بینی، بهترین عملکرد را دارا بود. تحقیق دیگر با همان هدف در کشور هندوستان نشان داد بهترین ANN توسعه داده شده با یک لایه پنهان شامل ۱۰ نورون می‌تواند کمترین جذر میانگین مربعات خطا^۶ (RMSE) را داشته باشد (کومار و همکاران ۲۰۱۵). علاوه بر این، اسامه و همکاران (۲۰۱۵) از ANN چند لایه‌ی پیش‌خور به منظور بررسی ارتباط عملکرد محصول چند واریته‌ی نیشکر با متغیر شرایط اقلیمی استفاده کردند (طاهری قزوینی و همکاران ۲۰۱۸). همچنین، در کشور برزیل، کوئلیو و همکاران (۲۰۱۹) به منظور پیش‌بینی درجه‌ی پارایزاسیون شربت نیشکر به کمک ANN، به این نتیجه دست یافتند که ANN با داشتن ضریب تبیین^۷ (R^2) و RMSE مطلوب، جایگزین مناسبی برای روش‌های استاندارد تحلیل است. نتایج تحقیق مکپیروآپ و سایتانو (۲۰۱۹) نشان داد که مدل شبکه‌ی عصبی MLP با کمترین میزان RMSE، نسبت به مدل شبکه‌ی عصبی RBF، دقت به نسبت بالاتری به منظور برآورد میزان محصول نیشکر در شرق کشور تایلند داشت. همچنین وانگ و

^۵ Radial Basis Function Network

^۶ Root Mean Square Error

^۷ Coefficient of determination

^۱ Artificial Neural Network

^۲ Feed Forward Neural Network

^۳ Recurrent Neural Network

^۴ Multilayer Perceptron Network

۳۱° تا ۱۰' ۳۱° شمالی و طول جغرافیایی ۳۶' ۴۸° تا ۴۵° شرقی واقع شده است (شکل ۱). این شرکت دارای هفت واحد جداگانه شامل کشت و صنعت‌های امام خمینی (ره)، دهخدا، امیرکبیر، میرزا کوچک خان، فارابی، سلمان فارسی و دعبل خزاعی است و ۸۴ هزار هکتار از اراضی استان خوزستان را به زیر کشت نیشکر برده است (افشارنیا و مرزبان ۲۰۱۹، بیگدلی و یوسف عقیلی ۲۰۰۵). مساحت هر واحد ۱۴۰۰۰ هکتار و پتانسیل سطح زیر کشت آن حدود ۱۲۰۰۰ هکتار می‌باشد و مابقی کانال، جاده، ساختمان و کارخانه می‌باشد. هر واحد دارای ۴۸۰ مزرعه ۲۵/۵ هکتاری می‌باشد. در مجموع، تعداد رکوردهای بدست آمده از ۱۴۴۰ مزرعه بود که به دلیل ناقص بودن و عدم ثبت دقیق اطلاعات ۴۳۰ مزرعه از روند تحقیق کنار گذاشته شدند. بنابراین، جامعه‌ی آماری تحقیق، ۱۰۱۰ مزرعه بود.

بخش اعظم خاک منطقه دارای شوری بالای چهار دسی‌زیمنس بر متر است و میانگین دمای خاک در عمق ۵ سانتی‌متر، ۲۱/۲ درجه سلسیوس است. منطقه دارای میانگین بارندگی سالیانه ۱۴۷/۱ میلی‌متر، میانگین دمای روزانه هوا ۲۵ درجه سلسیوس، و دارای میانگین ارتفاع ۷ متر از سطح دریا می‌باشد (ذکی دیزجی و همکاران ۲۰۱۸، دیانی و همکاران ۲۰۱۱). میانگین حداکثر دمای سالیانه هوا، ۳۴/۶۴ درجه سلسیوس، میانگین حداقل دمای سالیانه هوا، ۱۶/۰۲ درجه سلسیوس، همچنین حداقل رطوبت نسبی، ۳۱/۳۳ درصد و حداکثر رطوبت نسبی، ۷۱/۸۷ درصد است. همچنین منطقه دارای میانگین بارندگی سالیانه ۱۴۷/۱ میلی‌متر می‌باشد.

گردآوری اطلاعات

به منظور دسترسی به منابع داده‌ای خام از جمله، واریته و زمان کاشت محصول، شرایط خاک، آبیاری و کوددهی محصول در زمان داشت، طول دوره رشد و میزان عملکرد محصول نیشکر ابتدا، با انجام مصاحبه با کارکنان و کارشناسان واحد تولیدی و بازدید از

همکاران (۲۰۱۰) از ANN و روش طیف‌سنجی مادون قرمز نزدیک برای تعیین درجه بریکس و درجه‌ی پلاریزاسیون شربت نیشکر، و ریبریو و اولیویرا (۲۰۱۱) از مدل ترکیبی ANN برای برآورد قیمت مواد اولیه مورد نیاز بخش تولید الکل و شکر استفاده کردند. علاوه بر این، بوگاته و سرسانتاگل (۲۰۱۳) و بوکا و رودگوئز (۲۰۱۶) به مدل‌سازی برآورد تولید محصول نیشکر بوسیله ANN، تانکائه‌وسینگ و همکاران (۲۰۱۵) از ANN برای تعیین الگوریتم زمان‌بندی برداشت محصول نیشکر و سیلوا و همکاران (۲۰۱۹) به مدل‌سازی برآورد قیمت محصولات جانبی نیشکر پرداختند.

مدل‌های شبکه عصبی مصنوعی در مواردی که سیستم دارای روابط غیر خطی و چند متغیره باشند، و متغیرهای ورودی دارای روابط داخلی پیچیده‌ای باشند، توانایی مطابقت با پیچیدگی را داشته و دقت و صحت مدل‌ها با افزایش هرچه بیشتر داده‌های ورودی، افزایش می‌یابد (حق وردی و همکاران ۲۰۱۲). از میان مدل‌های ANN، مدل MLP ویژگی تعمیم‌پذیری بالاتری دارد (سرپرنده و هزارخانی ۲۰۱۷)، و مدل RBF سرعت آموزش بالاتری در مقایسه با شبکه‌ی عصبی MLP دارد (وو و همکاران ۲۰۱۲). با توجه به کارایی مناسب ANN هدف اصلی از این مطالعه مدل‌سازی، تحلیل حساسیت و مقایسه دو شبکه‌ی RBF و MLP در برآورد میزان عملکرد محصول نیشکر در استان خوزستان بود و هر کدام از این شبکه‌ها به‌طور جداگانه در این مطالعه مورد بررسی قرار گرفته است.

مواد و روش‌ها

موقعیت منطقه‌ی مورد پژوهش

این پژوهش در مزارع کشت و صنعت دعبل یکی از واحدهای هفت‌گانه شرکت کشت و صنعت نیشکر و صنایع جانبی استان خوزستان در سه سال پیاپی زراعی ۱۳۹۵-۱۳۹۸ انجام شد. این واحد در کیلومتر ۲۵ جاده اهواز-آبادان در جنوب اهواز دارای عرض جغرافیایی



شکل ۱- موقعیت کشت و صنعت مورد مطالعه

مدیریت‌های واحد تولید کشاورزی کشت و صنعت پرداخته شد، سپس به بررسی، ارزیابی و جمع‌بندی کلیه اطلاعات منابع ورودی مرتبط با عملکرد محصول نیشکر صورت گرفت.

شبکه‌های عصبی مصنوعی

نقطه قوت شبکه‌های عصبی پردازش موازی داده‌های اطلاعات است. این‌گونه شبکه‌ها به هیچ‌گونه پیش‌فرضی در مورد شکل مدل در فرآیند مدل‌سازی، نیاز ندارد و به طور کلی یک مدل مبتنی بر داده‌اند (پیوری و همکاران ۲۰۱۶). اما در ابتدا بایستی به منظور افزایش دقت، سرعت و تعمیم‌پذیری مدل شبکه‌ی عصبی، نرمال‌سازی داده‌های اولیه صورت گیرد که در پژوهش حاضر با استفاده از رابطه‌ی [۱]، فرآیند نرمال‌سازی داده‌های اولیه انجام شد و داده‌ها به دامنه صفر تا ۱ نگاشت شدند (بهرامی و همکاران ۲۰۱۷، تاکی و همکاران ۲۰۱۸).

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad \text{[رابطه ۱]}$$

در رابطه‌ی [۱]، X_n داده‌ی نرمال شده، x داده‌ی اولیه، X_{\max} و X_{\min} به ترتیب مقادیر بیشینه و کمینه داده

های اولیه می‌باشند. در طراحی مدل ANN به کمک نرم‌افزار MATLAB R2017a، پیش از شروع شبیه‌سازی داده‌ها، به منظور جلوگیری از آموزش بیش از اندازه و تصمیم‌گیری در مورد زمان متوقف ساختن آموزش، داده‌ها به سه مجموعه‌ی، داده‌های ۶۰ درصد از مجموع داده‌ها به بخش آموزش، ۲۰ درصد به بخش آزمون و ۲۰ درصد به بخش اعتبارسنجی تقسیم‌بندی شدند. اطلاعات ورودی مزارع، ماتریسی به ابعاد $[1010 \times 10]$ برای نه صفت شامل متغیرهای میزان هدایت الکتریکی خاک، مقدار کود شیمیایی فسفات و نیتروژن، تعداد دفعات آبیاری، مقدار آب مصرفی، ماه برداشت محصول، سن گیاه، واریته گیاه، و بافت خاک به عنوان متغیرهای ورودی مدل‌ها و میزان عملکرد محصول نیشکر به عنوان متغیر هدف مدل‌ها برای ۱۰۱۰ مزرعه تعریف شدند.

شبکه‌های پرسپترون چند لایه (MLP)

شبکه‌ی پرسپترون چند لایه یکی از مهمترین ساختارهای ANN می‌باشد. به طور معمول این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نورون‌های پایه^۱) می‌باشند که متشکل از یک


^۱ Basic neurons

برای هر نورون، مقدار ورودی به ترتیب طبق روابط [۲] تا [۵] محاسبه شدند (ایوبی و لیل سحروات ۲۰۱۱).

$$\text{net}_i^n = \sum_{j=1}^m w_{ji}^n \cdot o_j^{n-1} \quad \text{[رابطه ۲]}$$

در رابطه‌ی [۲]، net_i^n برابر است با مقدار ورودی - i امین نورون در n -امین لایه؛ w_{ji}^n بیانگر وزن ارتباطی بین i -امین نورون در n -امین لایه و j -امین نورون در لایه‌ی $n-1$ و $n-1$ و n معادل $n-1$ امین نورون خروجی در لایه‌ی $n-1$ و m تعداد نورون‌های لایه‌ی $n-1$ می‌باشند. در شکل (۲)، ساختمان شبکه‌ی MLP نشان داده شده است. O_i ، O_j و O_k نورون‌های ورودی، net_i نورون خروجی، W_{ij} وزن‌های اتصالی و θ بایاس می‌باشد؛ X ها متغیرهای ورودی بودند.

لایه‌ی ورودی، یک یا چند لایه‌ی پنهان و یک لایه‌ی خروجی می‌باشند؛ هر لایه شامل تعدادی نورون یا گره است. تمام اتصالات بین لایه‌ی ورودی و لایه‌ی پنهان ماتریس وزن ورودی و تمام اتصالات بین لایه‌ی پنهان و لایه‌ی خروجی، ماتریس وزن خروجی را تشکیل می‌دهد (پتن ۲۰۱۷). بین نورون‌های لایه‌های مختلف اتصالاتی وجود دارد که هر کدام دارای وزن‌هایی می‌باشند؛ طی فرآیند آموزش این وزن‌ها و مقادیر ثابتی که با آنها جمع می‌شود و در اصطلاح بایاس^۱ نامیده می‌شود، به طور پی‌درپی تغییر می‌کنند تا خطای بین مقادیر تخمین زده شده و مقادیر واقعی به حداقل مقدار خود برسد (طاهرپور و همکاران، ۲۰۰۹، پیمان و همکاران ۲۰۱۲). سیگنال ورودی در چهارچوب شبکه‌ی پیشخور و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود (صیادی و همکاران ۲۰۰۹).



شکل ۲_ طرح‌واره شبکه عصبی مصنوعی (MLP) با یک لایه ورودی، یک لایه پنهان، و یک لایه خروجی

^۱ Bias

شبکه‌های با تابع پایه‌ی شعاعی (RBF)

شبکه‌های عصبی RBF نیازمند نورون‌های بیشتری نسبت به شبکه‌های عصبی MLP با الگوریتم پس‌انتشار خطا می‌باشند ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه‌تر آموزش داد (مارکوپولوس و همکاران ۲۰۱۶). در این شبکه‌ها سه لایه که شامل لایه ورودی، لایه‌ی پنهان با تابع محرک شعاعی غیرخطی و یک لایه‌ی خروجی خطی بکارگرفته شده است. برخلاف شبکه‌های عصبی MLP که دارای توابع محرک عمومی هستند؛ توابع محرک در این شبکه‌ها، از نوع محلی می‌باشند. در آموزش این شبکه‌ها، علاوه بر تنظیم وزن‌ها، نیاز به تنظیم مرکز توابع فعالیت نیز هست. بدین منظور از روش GD بر مبنای کمترین مجموع مربعات خطا استفاده شد. میانگین خطای مربعات و سطح گسترش تابع شعاع مداری، با مقادیر پیش فرض صفر و یک در نظر گرفته شد. در ابتدا تعداد نورون‌ها در لایه میانی برابر با تعداد ورودی‌های شبکه لحاظ گردید. سپس در هر بار طراحی شبکه به اندازه پنج نورون به تعداد نورون‌های لایه میانی افزوده شد تا زمانی که شروط توقف برنامه برقرار شوند؛ یعنی میزان خطا از حد تعیین شده کمتر شود یا تعداد نورون‌های لایه میانی به بیشترین مقدار تعیین شده ($n=100$) برسد. تعداد تکرار الگوریتم یادگیری برابر با ۲۰ در نظر گرفته شد. در طراحی این نوع شبکه‌ی عصبی از تابع فعالیت Radbas برای انتقال نورون‌های بین لایه ورودی و میانی و از تابع Purelin برای انتقال نورون‌ها به لایه خروجی و محاسبه ضرایب مربوط به اوزان شبکه استفاده شد.

تعیین ساختار یا تعداد نورون‌های لایه‌ی مخفی یکی از مراحل مهم در طراحی شبکه‌های عصبی RBF است (سیفوی و همکاران ۲۰۰۹). خروجی شبکه با استفاده از مجموع وزن‌دار خطی پاسخ‌های لایه‌ی پنهان در هر یک از گره‌های خروجی توسط رابطه‌ی [۶] به دست

مقدار محاسبه شده برای نورون‌ها که از رابطه‌ی [۲] بدست آمده توسط تابع محرک سیگموئیدی (tansig) رابطه‌ی [۳] موجود بین لایه‌ی ورودی و لایه‌ی پنهان به سطح فعال منتقل شدند تا خروجی مربوطه را تولید کنند (جعفری و همکاران ۲۰۱۳). همچنین بین لایه‌ی پنهان و لایه‌ی خروجی از تابع محرک خطی استفاده شد.

$$f(\text{net}_i^p) = \frac{2}{(1 + \exp(-2\text{net}_i^p)) - 1} \quad [\text{رابطه ۳}]$$

این شبکه بر مبنای تابع الگوریتم پس‌انتشار خطا^۱ (BP) آموزش داده شد. بدین ترتیب که خروجی‌های واقعی با خروجی‌های پیش‌بینی شده مقایسه شدند و وزن‌ها به وسیله الگوریتم پس‌انتشار، به صورت تحت نظارت تنظیم شده تا الگوی مناسب به وجود آید. برای الگوی ورودی p -ام، مربع خطای خروجی برای نورون‌های لایه‌ی خروجی شبکه به صورت رابطه‌ی [۴] می‌باشد.

$$E_p = \frac{1}{2}(d^p - y^p)^2 = \frac{1}{2} \sum_{j=1}^s (d_j^p - y_j^p)^2 \quad [\text{رابطه ۴}]$$

در رابطه‌ی [۴]، d_j^p خروجی پیش‌بینی برای j -امین نورون در لایه‌ی خروجی و y_j^p خروجی واقعی برای j -امین نورون در لایه‌ی خروجی، s ابعاد بردار خروجی، d^p بردار خروجی واقعی و y^p بردار خروجی پیش‌بینی بودند. مجموع خطای کل T برای p الگو به صورت رابطه‌ی [۵] بدست آمد (نریمانی و همکاران ۲۰۱۳).

$$E_T = \sum_{p=1}^p E_p = \frac{1}{2} \sum_{p=1}^p \sum_{j=1}^s (d_j^p - y_j^p)^2 \quad [\text{رابطه ۵}]$$

وزن‌ها با هدف کاهش تابع هزینه T به مقدار کمینه به روش گرادیان نزولی^۲ (GD) تنظیم شدند. روند یادگیری هنگامی متوقف می‌شود که مجموع کل خطا T برای p الگو از مقدار آستانه تعیین شده کمتر شود یا تعداد کل دوره‌ی آموزش به پایان برسد.

^۲ Gradient Descent

^۱ Back-propagation algorithm


آمد.

$$z_j(x) = \exp\left(-\frac{\|\vec{x} - c_j\|^2}{2\sigma_j^2}\right) \quad \text{[رابطه ۷]}$$

در رابطه‌ی [۷] و \vec{x} ماتریس ورودی به ابعاد $[1010 \times 10]$ درایه، شامل ۱۰۱۰ مزرعه برای نُه متغیر ورودی و یک متغیر خروجی، c_j مرکز تابع گاوسی در گره j -ام، $\|\cdot\|$ برابر نُرم اقلیدسی بین \vec{x} و c_j ، σ_j^2 عامل کنترل گسترده‌ی RBF می‌باشد که شاخص فاصله‌ی شعاعی از مرکز RBF است و مقدار تابع از صفر دارای اختلاف می‌باشد. در شکل (۳) ساختمان شبکه RBF نشان داده شده است.

$$y_k = \sum_{j=1}^N w_{kj} z_j(x) \quad \text{[رابطه ۶]}$$

در رابطه‌ی [۶]، N تعداد توابع پایه، z_j تابع غیرخطی واحد j -ام، w_{kj} نشان‌دهنده‌ی وزن متصل بین تابع پایه و لایه‌ی خروجی و \vec{x} بردار داده‌ی ورودی، که به طور معمول یک تابع گاوسی به صورت رابطه‌ی [۷] می‌باشد.



شکل ۳- طرح‌واره شبکه عصبی مصنوعی (RBF) با یک لایه ورودی، یک لایه پنهان، و یک لایه خروجی

در روابط [۸] تا [۱۱]، P_i ، A_i ، \bar{A}_i و \bar{P}_i به ترتیب مقادیر پیش‌بینی، واقعی، میانگین مقدار واقعی و میانگین مقدار پیش‌بینی برای i -امین مزرعه بود.

آنالیز حساسیت

آنالیز حساسیت مدل، مشخص می‌کند که خروجی مدل تا چه اندازه تحت تأثیر هر کدام از ورودی‌های مدل بوده است (نوروزیان عزیززی و همکاران ۲۰۱۷). بدین منظور مدل‌های MLP و RBF همگام با حذف هر یک از پارامترهای ورودی، آموزش داده شدند و خروجی نشان

به منظور ارزیابی توانایی شبکه‌ی عصبی پرسپترون چندلایه و تابع پایه شعاعی در پیش‌بینی عملکرد محصول نیشکر از معیارهای R^2 ، RMSE، میانگین درصد خطای مطلق^۱ (MAPE) و بازده مدل^۲ (EF) بین مقادیر پیش‌بینی شده و مقادیر واقعی شبکه استفاده شد. روابط [۸] تا [۱۱] چگونگی محاسبه این شاخص‌ها را نشان می‌دهند (قادرپور و همکاران ۲۰۱۷، تاکی و همکاران ۲۰۱۶). هرچه مقدار R^2 و EF بیشتر و به یک نزدیک‌تر باشد و مقدار RMSE و MAPE کمتر و به صفر نزدیک‌تر باشد بدان معناست که شبکه عملکرد بهتری داشته است.

^۲ Model Efficiency

^۱ Mean Absolute Percentage Error

داد که به ازای تغییر در ورودی‌ها، خروجی مدل چه مقدار تغییر کرده است.

نتایج و بحث

نتایج جدول (۱) نشان داد که اراضی سطح زیر کشت دارای هدایت الکتریکی خاک ۵/۵۹۷ دسی‌زیمنس بر متر بود. همین‌طور مقدار میانگین کود فسفات و نیتروژن

مورد استفاده در طول دوره‌ی رشد محصول در اکثر مزارع، به‌ترتیب، ۶۲/۰۶ و ۳۳۹/۱۳ کیلوگرم بر هکتار بود. مقدار آب مصرفی در هر نوبت آبیاری، حدود ۱۳۹۳ مترمکعب بود. آبیاری نیشکر به روش جوی و پشت‌ای با استفاده از لوله‌های هیدروفلوم دریاچه دار صورت پذیرفت. میانگین عملکرد محصول (ساقه) نیشکر ۶۹/۴ تن بر هکتار بود.

جدول ۱- توصیف متغیرهای پیوسته مدل

عنوان	واحد	کمترین مقدار	میانگین	بیشترین مقدار	انحراف معیار
الف) متغیرهای ورودی					
هدایت الکتریکی خاک	dS.m ⁻¹	۲/۱	۵/۵۹۷	۱۵/۱	۲/۰۹۷
کود شیمیایی (فسفات)	Kg.ha ⁻¹	۰	۶۲/۰۶	۲۵۰	۷۴/۳۵
کود شیمیایی (نیتروژن)	Kg.ha ⁻¹	۲۰۸/۱۷	۳۳۹/۱۳	۵۳۱/۳۳	۴۶/۶۶
تعداد دفعات آبیاری	-	۱۲	۲۱/۲۱	۳۰	۳/۵۱
مقدار آب مصرفی	m ³ .ha ⁻¹	۱۱۲۷/۲	۱۳۹۲/۸۲	۱۸۲۷/۵	۱۳۱/۸
ب) متغیر خروجی					
میزان عملکرد محصول	t.ha ⁻¹	۱۹/۲۸	۶۹/۴	۱۲۶/۲۲	۲۱/۲۵

ماخذ: یافته‌های تحقیق

همین‌طور نتایج جدول (۲) نشان داد که بیش از ۵۰ درصد برداشت در ماه‌های آذر و بهمن اتفاق افتاد و ۳۰/۵ درصد از مجموع برداشت محصول نیشکر از راتون سال اول بود. از بین ارقام مورد کشت، رقم CP69-1062، سهم

۶۱/۴۸ درصدی در جامعه‌ی آماری داشت. بیشترین بافت‌های خاک اراضی سطح زیر کشت، از نوع لوم، لوم رسی و لوم رسی سیلتی بودند (ویسی تبار و همکاران ۲۰۱۵، نعمتی و همکاران ۲۰۱۷).

جدول ۲- توصیف متغیرهای ورودی مدل

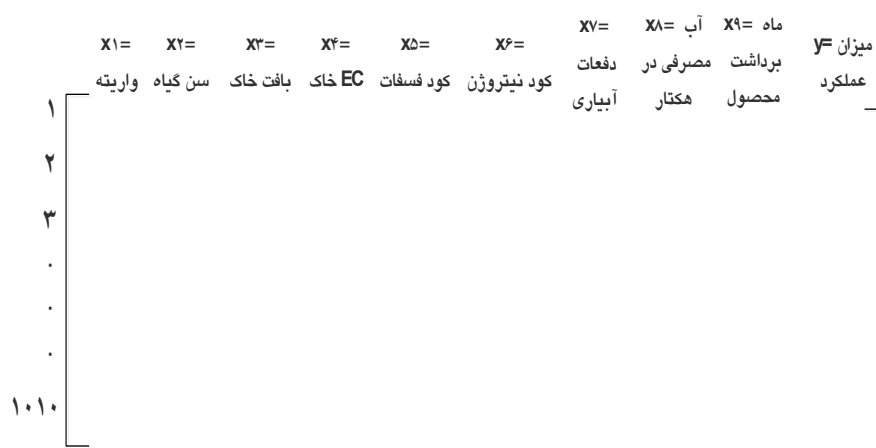
ماه برداشت محصول (درصد)	فروردین (۱/۶۸)	اردیبهشت (۱)	مهر (۶/۹۳)	آبان (۱۵/۶۴)
سن گیاه (سطح زیر کشت به درصد)	آذر (۲۹/۹۳)	دی (۱۱)	بهمن (۲۱/۵۸)	اسفند (۱۲/۲۴)
واریته گیاه (سطح زیر کشت به درصد)	کشت اول (۲۸/۷۱)	بازروی اول (۳۰/۵)	بازروی دوم (۲۴/۳۵)	بازروی سوم (۱۶/۴۴)
	CP57-614 (۱۵/۲۴)	CP69-1062 (۶۱/۴۸)	SP70-1143 (۲۳/۲۸)	
بافت خاک (درصد)	لوم رسی (۲۵/۴۴)	لوم (۳۵/۸۴)	لوم رسی شنی (۳/۱۶)	
	لوم شنی (۱۰)	رس سیلتی (۴/۶۵)	لوم رسی سیلتی (۲۰/۹۱)	

ماخذ: یافته‌های تحقیق

بررسی مدل‌های شبکه عصبی مصنوعی

به منظور مدل‌سازی عملکرد محصول نیشکر براساس متغیرهای ورودی ۱۰۱۰ مزرعه کشت نیشکر از مدل‌های شبکه عصبی مصنوعی MLP و RBF استفاده شده که در ادامه به ارائه و بررسی نتایج پرداخته شده است. در این تحقیق، یک الگوریتم یادگیری پسانتشار خطا به منظور ایجاد مدل‌های پیش‌بینی انتخاب شد. جهت دستیابی به بهترین ساختار شبکه‌ی MLP، در ابتدا تعداد مختلفی از ساختارها با یک و دو لایه در نظر گرفته شد و شبکه با تعداد بیشینه ۲۰ نورون در لایه‌ی مخفی

آموزش داده شد. اطلاعات ورودی مزارع، ماتریسی به ابعاد $[1010 \times 10]$ برای نه صفت شامل متغیرهای میزان هدایت الکتریکی خاک، مقدار کود شیمیایی فسفات و نیتروژن، تعداد دفعات آبیاری، مقدار آب مصرفی، ماه برداشت محصول، سن گیاه، واریته گیاه، و بافت خاک به عنوان متغیرهای ورودی مدل‌ها و میزان عملکرد محصول نیشکر به عنوان متغیر هدف مدل‌ها برای ۱۰۱۰ مزرعه تعریف شدند. همچنین صفات ماه برداشت محصول، سن و واریته گیاه، و بافت خاک به صورت بدون واحد بودند. ساختار ماتریس ورودی به شبکه عصبی در شکل ۴ آمده است.




شکل ۴- طرح‌واره ماتریس ورودی به شبکه عصبی


پیش‌بینی شده مربوط به مدل MLP در شکل (۵) آورده شده است.

نتایج شکل (۵) نشان داد که تطابق بین مقادیر واقعی و پیش‌بینی شده در مرحله‌ی اعتبارسنجی بیشتر است ($R^2 = 0.71$)؛ زیرا ضریب تبیین خط رگرسیونی در مرحله‌ی مذکور از مراحل آموزش و آزمون بیشتر بود؛ معمولاً دقت مدل‌های هوش مصنوعی در مرحله‌ی آموزش بیشتر از آزمون می‌باشد؛ این امر به دلیل تطبیق مدل و داده‌های آموزش است. نمودارهای پراکنندگی بین مقادیر واقعی و مقادیر پیش‌بینی شده مربوط به مدل RBF نیز در شکل (۶) آمده است

نتایج نشان داد که بهترین مدل MLP شامل یک لایه ورودی با نه پارامتر ورودی، یک لایه پنهان با ۱۵ نورون و یک لایه خروجی با یک پارامتر خروجی (ساختار ۱-۹-۱۵) بود. برای بررسی همبستگی بین مقادیر واقعی و پیش‌بینی شده از معادله خط رگرسیون چند جمله‌ای از نوع درجه دو با بیشترین مقدار همبستگی ($Y = a + (b_1 X) + (b_2 X^2)$) بین آن‌ها استفاده شد. بر اساس این معیار، بهترین حالت زمانی است که شیب خط نزدیک به یک ($X \cong 1$) و عرض از مبدا آن نزدیک به صفر ($a \cong 0$) باشد. نمودارهای پراکنندگی بین مقادیر واقعی و مقادیر



شکل ۵- پراکندگی داده‌های واقعی در برابر عملکرد محصول پیش‌بینی شده با استفاده از مدل MLP به ترتیب با ۸۰، ۴۰، ۴۰ نقطه برای بخش‌های آموزش، آزمون و اعتبارسنجی



شکل ۶- پراکندگی داده‌های واقعی در برابر عملکرد محصول پیش‌بینی شده با استفاده از مدل RBF به ترتیب با ۸۰، ۴۰، ۴۰ نقطه برای بخش‌های آموزش، آزمون و اعتبارسنجی

بهترین ساختار لایه پنهان بود؛ نتایج تاکی و همکاران (۲۰۱۸)، این امر را تایید کردند.

عملکرد شبکه‌های عصبی MLP و RBF برحسب معیارهای خطا (RMSE و MAPE) و EF به منظور برآورد میزان نیشکر تولیدی در سه مرحله اعتبارسنجی، آزمون و آموزش در جدول (۳) ارائه شده است.

همان‌طور که در شکل (۶) مشاهده شد، مقدار R^2 در مدل RBF با بیشترین مقدار برازش ($R^2 = 0.7886$) بین داده‌های پیش‌بینی و داده‌های واقعی در مرحله آموزش، عملکرد بهتری نسبت به مدل MLP داشته باشد. افزایش در مقدار R^2 به دلیل افزایش در تعداد نورون‌ها در

جدول ۳. عملکرد شاخص‌های دو مدل شبکه عصبی MLP و RBF توسط الگوریتم گرادیان نزولی

مدل	اعتبارسنجی			آزمون			آموزش		
	RMSE*	MAPE (%)	EF*	RMSE	MAPE (%)	EF	RMSE	MAPE (%)	EF
MLP	۰/۰۵۳۸۹۵	۰/۰۹۲۴۱۴	۰/۶۱۹۹۲۸	۰/۰۵۶۵۰۷	۰/۰۹۰۴۰۱	۰/۶۰۶۹۵۲	۰/۰۵۴۱۶۷	۰/۰۹۱۱۸۷	۰/۶۳۱۹۳۹
RBF	۰/۰۳۷۶۸۶	۰/۰۶۴۴۹۴	۰/۸۰۰۴۰۹	۰/۰۳۹۳۳۲	۰/۰۶۶۳۶۲	۰/۷۸۳۵۳۳	۰/۰۳۹۵۲۵	۰/۰۶۸۳۵۵	۰/۷۹۷۱۴۳

* دو شاخص RMSE و EF در سه مرحله و در دو مدل، non-dimensional (بدون ابعاد) بودند.

بهترین ساختار شبکه، که به ترتیب تعداد نورون‌های لایه ورودی، پنهان و خروجی را نشان می‌دهد، (۱-۱۶-۵) بود که در این ساختار، مقادیر شاخص‌های R^2 ، RMSE و MAPE به ترتیب ۰/۸۸، ۰/۱۵ و ۶/۲۳ درصد بودند (سفیدپری و همکاران ۲۰۱۳). نتایج مقایسه‌ی شبکه‌ی عصبی RBF و شبکه‌ی پسرانتشار خطای توسعه یافته به منظور پیش‌بینی سطوح ناهموار قطعات صنعتی حاکی از آن بود که شبکه‌ی عصبی RBF با یک لایه پنهان و ساختار شبکه‌ی (۱-۲۱-۴)، نسبت به شبکه‌ی پسرانتشار خطای توسعه یافته، معیار خطای آموزش (۲۰⁻) $MSE=8/85 \times 10$ بسیار کمتر و عملکرد مطلوب‌تری داشت (مارکوپولوس و همکاران ۲۰۱۶)، که بیانگر دقت بسیار بالا این نوع مدل در اندازه‌گیری‌های دقیق بود. همین‌طور نتایج مدل‌سازی و تخمین انرژی تولیدی در کشت گندم دیم و آبی نشان داد که مدل شبکه‌ی عصبی RBF دقیق‌تر از مدل شبکه‌ی عصبی MLP و مدل رگرسیون فرآیند گاوسی است و می‌تواند به طور مؤثر برای مدل‌سازی و پیش‌بینی انرژی‌های خروجی بر اساس انرژی‌های ورودی و به ازای اندازه‌های مختلف

معیار مقایسه در روش‌های هوش مصنوعی، دقت مدل‌های شبکه عصبی در مرحله اعتبارسنجی است. زیرا در الگوریتم یادگیری ماشین معمولاً از روی دو سوم داده‌ها، فرآیند یادگیری (آموزش) انجام می‌شود و از مابقی داده‌ها می‌توان برای ارزیابی مدل (آزمون و اعتبارسنجی) و تعیین میزان دقت آن در قیاس با داده‌های واقعی استفاده نمود. براساس جدول (۳) برای تخمین محصول نیشکر، عملکرد شبکه‌ی عصبی RBF براساس سه شاخص ارزیابی MAPE، RMSE و EF در مرحله اعتبارسنجی، نسبت به شبکه‌ی عصبی MLP مطلوب‌تر بود که نشان از دقت بالاتر مدل RBF داشت. همین‌طور مدل RBF در دوره آزمون به ترتیب با داشتن معیارهای خطای $RMSE=0.39332$ و $MAPE=0.66362$ نسبت به مدل MLP توانایی برازش بیشتری با داده‌های واقعی داشت. سه شاخص ارزیابی در بخش آموزش، نشان‌گر عملکرد بهتر الگوریتم آموزشی در مدل RBF نسبت به مدل MLP بود.


همچنین در تحقیق دیگر، به منظور مدل‌سازی انرژی شیر گاوداری استان تهران به کمک شبکه‌ی عصبی MLP،

در شبکه‌ی عصبی RBF و MLP بالاترین حساسیت را در میان ورودی‌ها برای تولید محصول نیشکر دارا بودند. این نتیجه، با نتایج تحقیق ذکی دیزجی و همکاران (۲۰۱۸) همخوانی داشت. این بدان معنا بود که به ازای افزایش استفاده در هر کیلوگرم بر هکتار کود شیمیایی نیتروژن، عملکرد محصول ۰/۰۲۳۳ تن بر هکتار افزایش یافت. از طرف دیگر متغیر واریته بیشترین سهم تاثیرگذار بر افزایش عملکرد را داشت. متغیر هدایت الکتریکی خاک نیز در هر دو شبکه عصبی مصنوعی دارای نقش تعیین‌کننده در میزان تولید محصول نیشکر بود. متغیر کود فسفات در شبکه‌ی عصبی RBF از حساسیت بالاتری بر عملکرد محصول نیشکر نسبت به متغیر کود نیتروژن برخوردار بود. تاثیر متغیرهای میزان آب مصرفی، بافت خاک و سن گیاه بر میزان نیشکر تولیدی در مدل‌های MLP و RBF تقریباً برابر بود. همچنین متغیر ماه برداشت محصول در شبکه‌ی عصبی MLP نسبت به شبکه‌ی عصبی RBF و تعداد دفعات آبیاری در شبکه‌ی عصبی RBF نسبت به شبکه‌ی عصبی MLP تاثیر بیشتری بر افزایش عملکرد محصول نیشکر داشت.

زمین‌های زراعی مورد استفاده قرار گیرد (تاکا و همکاران ۲۰۱۸).

تحلیل حساسیت

تجزیه و تحلیل حساسیت به منظور بررسی امکان اعتبارسنجی و پیش‌بینی به کمک بهترین شبکه‌ی برازش شده در هر دو مدل انجام شد (شکل ۷). آموزش مدل‌های MLP و RBF همگام با حذف پارامترهای ورودی میزان هدایت الکتریکی خاک، مقدار کود شیمیایی فسفات و نیتروژن، تعداد دفعات آبیاری، مقدار آب مصرفی، ماه برداشت محصول، سن گیاه، واریته گیاه و بافت خاک درحالی‌که تغییری در پارامترهای مربوط به الگوهای دیگر صورت نمی‌گرفت، به کمک نرم افزار متلب انجام شد. با این نوع تحلیل، امکان قضاوت اینکه طی اجرای شبکه‌ی عصبی MLP و RBF مطلوب، کدام پارامتر دارای بیشترین معناداری (با حساسیت نزدیک به ۱) و کمترین معناداری (با حساسیت نزدیک به صفر) است، وجود داشت (عمید و همکاران ۲۰۱۶). براساس نتایج می‌توان گفت، متغیر ورودی واریته گیاه و کود نیتروژن به ترتیب



شکل ۷- تحلیل حساسیت متغیرهای ورودی نسبت به متغیر هدف

گردید. پایگاه داده‌ها به سه بخش آموزش، اعتبارسنجی و آزمایش تقسیم شدند. از شاخص‌های R^2 ، RMSE، MAPE و EF به منظور مقایسه دقت و بازده دو مدل MLP و RBF استفاده گردید. در نهایت مدل RBF به دلیل

نتیجه‌گیری کلی

در این تحقیق داده‌های ۱۰۱۰ مزرعه شرکت کشت و صنعت دعبل خزاعی با هدف اصلی مدل‌سازی به کمک شبکه‌های عصبی مصنوعی MLP و RBF جمع‌آوری

تولید محصول نیشکر بوده است که به تبع آن لزوم توجه بیش از پیش سیاست‌گذاران بخش نیشکر و سایر بخش‌های مرتبط با شناسایی و توسعه واریته پرمحصول، در کنار توجه به رعایت اصول پیش از کاشت، کاشت و داشت، برداشت و پس از برداشت، همچنین اجرای کشاورزی هوشمند به منظور تولید حداکثری محصول، کاهش واردات و حتی لزوم صادرات فرآورده‌های نیشکر با توجه پتانسیل‌های فراوان منطقه در امر تولید پایدار را می‌طلبد.

عملکرد مطلوب‌تر و دقیق‌تر به سبب دارا بودن RMSE، MAPE کمتر در سه مرحله‌ی آزمایش، اعتبارسنجی و آموزش، همین‌طور داشتن ضریب تبیین، توضیح و توجیه مطلوب داده‌های پیش‌بینی شده و واقعی در سه مرحله و EF بهتر نسبت به مدل MLP، مدل مطلوب‌تر انتخاب شد. همین‌طور تحلیل حساسیت مدل RBF به عنوان مدل برتر، متغیر واریته گیاه را در برآورد تولید محصول نیشکر مؤثرترین متغیر ورودی تشخیص داد؛ به این معنا که دارای بیشترین نقش تاثیرگذار در میزان

منابع مورد استفاده

- Afsharnia F, and Marzban A. 2019. Risk analysis of sugarcane stem transportation operation delays using the FMEA-ANP hybrid approach. *Journal of Agricultural Machinery*, 9(2): 455-467. (In Persian).
- Amid S, Mesri Gunddoshmian T, and Shahghgoli. 2016. Comparison of MLP and RBF neural networks performance for estimation of broiler output energy. *Iranian Journal of Biosystems Engineering*, 47(2): 319-328. (In Persian).
- Ayoubi S, and Lal Sahrawat K. 2011. Comparing multivariate regression and artificial neural network to predict barley production from soil characteristics in northern Iran. *Archives of Agronomy and Soil Science*, 57(5): 549-565.
- Bahrami M, Amiri MJ, Rezaei Maharluei F, and Ghaffari KA. 2017. Data pre-processing effects on the artificial neural network performance to predict monthly rainfall (Case study: Abadeh county). *Iranian Journal of Ecohydrology*, 4(1): 29-37. (In Persian).
- Bigdeli Z, and Yousef Aghli N. 2005. Investigating the motivations of the goals and database used by the experts of the sugar cane development company and the related industries of Khuzestan province and investigation of their problems for accessing their required information. *Journal of Education*, 12 (2): 91-112. (In Persian).
- Bocca FF, and Rodrigues LHA. 2016. The effect of tuning, feature engineering, and feature selection in data mining applied to rainfed sugarcane yield modelling. *Computers and Electronics in Agriculture*, 128, 67-76.
- Bugate O, and Seresangtakul P. 2013. Sugarcane production forecasting model of the northeastern by artificial neural network. *Khon Kaen University Science Journal*, 41(1): 213-225.
- Coelho AP, Bettiol JVT, Dalri AB, Fischer Filho JA, Faria RTD, and Palaretti, LF. 2019. Application of artificial neural networks in the prediction of sugarcane juice Pol. *Brazilian Journal of Agricultural and Environmental Engineering Open Access*, 23, 9-15.
- Dayani M, Jafari S, Khalilmoghadam B, and Dehghani AA. 2011. Saline and sodic mapping using geostatistics theory (A case study in western Karoon river land of Khuzestan). *Watershed Management Research (Pajouhesh & Sazandegi)*. 94, 86-95. (In Persian).
- Ghaderpour O, Rafiee S, and Sharifi M. 2017. Life cycle assessment of alfalfa production and prediction of emissions using multi-layer adaptive neuro-fuzzy inference system in Bukan township. *Journal of Agricultural Machinery*, 8(1): 119-136. (In Persian).

- Haghverdi A, Cornelis WM, and Ghahraman B. 2012. A pseudo-continuous neural network approach for developing water retention pedotransfer functions with limited data. *Journal of Hydrology*, 442, 46-54.
- Hashemi Fath A, Madanifar F, and Abbasi M. 2018. Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems. *Petroleum*. In Press, Corrected Proof.
- Jafari M, Vafakhah M, and Abghari H. 2013. Performance comparison of two activation functions namely Sigmoid and Hyperbolic Tangent in Artificial Neural Networks for storm runoff coefficient forecasting (Case Study: Barariyeh Watershed, Neishabour). *Journal of Water and Soil Conservation*, 20(2): 85-104. (In Persian).
- Kumar S, Kumar V, and Sharma RK. 2015. Sugarcane yield forecasting using artificial neural network models. *International Journal of Artificial Intelligence & Applications*, 6(5): 51-68.
- Marashi F, Jafarzadeh Haghighi fard N, Khorasani N, and Monavari S. 2019. Life cycle assessment of the sugar industry: A Case study of Amir Kabir sugar cane industry. *Iranian Journal of Biosystems Engineering*, 49(4): 597-608. (In Persian).
- Markopoulos AP, Georgiopoulos S, and Manolakos DE. 2016. On the use of back propagation and radial basis function neural networks in surface roughness prediction. *Journal of Industrial Engineering International*, 12, 389-400.
- Mekparyup J, and Saithanu K. 2019. Forecasting sugar cane yield in the eastern area of Thailand with ANN technique. *Australian Journal of Basic and Applied Sciences*, 13(1): 112-116.
- Narimany R, Hakimipour, AllahRezaee A. 2013. An application of value at risk based on artificial neural networks and heteroscedasticity models. *Quarterly Journal of Financial Economics (Financial Economics and Development)*, 7(24): 101-137. (In Persian).
- Nemati Z, Hemmat A, and Mosaddeghi M R. 2017. Effect of adding sugarcane bagasse and filter cake and wetting and drying cycles on pre-compaction stress of soil. *Journal of Agricultural Machinery*, 8(1): 55-66. (In Persian).
- Norouzian Azizi Z, Ghajar Sepanlou M, Emadi S, and Sadeqzade F. 2017. Evaluation of regression and artificial neural network models to estimate the saturated hydraulic conductivity in Mazandaran province. *Iranian Journal of Soil Research*, 31(1): 75-87. (In Persian).
- Obe OO, and Shangodoyin DK. 2010. Artificial neural network based model for forecasting sugar cane production. *Journal of Computer Science*, 6(4): 439-445.
- Osama K, Mishra BN, and Somvanshi P. 2015. Machine learning techniques in plant biology. Pp. 731-754. In: Barh D, Sarwar Khan M, Davies E. (eds). *PlantOmics: The Omics of plant science*. Springer- New Delhi, India.
- Patan K. 2019. Neural Networks. Pp. 9-58. In: Patan, K. (eds). *Neural Networks Robust and Fault-Tolerant Control Neural-Network-Based Solutions*. Springer- Cham, Switzerland.
- Peyman L, Mahmoudi A, Abdollahpor S, Moghaddam M, and Ranabonab B. 2012. Controlling spray particle size using artificial neural networks. *Journal of Agricultural Science and Sustainable Production*, 21(4): 75-84. (In Persian).
- Ribeiro CO, and Oliveira S. 2011. A hybrid commodity price-forecasting model applied to the sugar-alcohol sector. *Australian Journal of Agricultural and Resource Economics*, 55(2): 180-198.
- Sarparandeh M, and Hezarkhani A. 2017. Studying distribution of rare earth elements by classifiers, Se-Chahun iron ore, Central Iran. *Acta Geochim*, 36, 232-239.
- Sayyadi H, Oladghaffari A, Faalian A, and Sadraddini A. 2009. Comparison of RBF and MLP neural networks performance for estimation of reference crop evapotranspiration. *Water and Soil Science*, 19(1): 1-12. (In Persian).

- Sedehe M, Mehrabi Y, Kazemnejad A, Hadaegh F. 2009. Comparison of artificial neural network, logistic regression and discriminant analysis methods in prediction of metabolic syndrome. *Iranian Journal of Endocrinology and Metabolism*, 11(6): 638-646. (In Persian).
- Sefeedpari P, Rafiee S, and Akram A. 2013. Application of artificial neural network to model the energy output of dairy farms in Iran. *International Journal of Energy Technology and Policy*, 9(1): 82-91.
- Sifaoui A, Abdelkrim A, Alouane S, and Benrejeb M. 2009. On new RBF neural network construction algorithm for classification. *Studies in Informatics and Control*, 18(2): 103-110.
- Silva N, Siqueira I, Okida S, Steven SL, and Siqueira H. 2019. Neural network for predicting prices of sugarcane derivatives. *Sugar Technology*, 21(3): 514-523.
- Sundermeyer M, Oparin I, Gauvain JL, Freiberg B, Schlüter R, and Ney H. 2013. Comparison of feedforward and recurrent neural network language models. *Proceedings of 38th IEEE International Conference on Acoustics, Speech and Signal Processing*. May, Vancouver, BC, Canada .Pp. 8430-8434.
- Taherei Ghazvinei P, Hassanpour Darvishi H, Mosavi A, Yusof K b W, Alizamir M, Shamshirband S, and Chau K-w. 2018. Sugarcane growth prediction based on meteorological parameters using extreme learning machine and artificial neural network. *Engineering Applications of Computational Fluid Mechanics*, 12(1): 738-749.
- Taherpoor H, Shahnoushi N, Danshvar M, and Mohebi M. 2009. Investigation on technical efficiency of agronomy and horticulture sub sectors products in Khorasan Razavi province: Application of integrated neural network and fuzzy clustering approach. *Journal of Agricultural Science and Sustainable Production*, 20(4): 37-51. (In Persian).
- Taki M, Ajabshirchi Y, Ranjbar SF, Rohani A, Matloobi M. 2016. Modeling and experimental validation of heat transfer and energy consumption in an innovative. *Information Processing in Agriculture*, 3(3): 157-174.
- Taki M, Rohani A, Soheili-Fard F, and Abdeshahi A. 2018. Assessment of energy consumption and modeling of output energy for wheat production by neural network (MLP and RBF) and Gaussian process regression (GPR) models. *Journal of Cleaner Production*, 172, 3028-3041.
- Thuankaewsing S, khmjian S, Piewthongngam K, Pathumnakul S. 2015. Harvest scheduling algorithm to equalize supplier benefits: a case study from the Thai sugar cane industry. *Computers and Electronics in Agriculture*, 110, 42-55.
- Veisitarab A, Hemmat A, and Mosaddeghi MR. 2015. Soil compaction assessment in sugarcane fields under different planting conditions using soil bulk density, relative bulk density and cone index. *Quarterly Water and Soil Science (Journal of Science and Technology of Agriculture and Natural Resources)*, 19 (72): 93-106. (In Persian).
- Wang X, Xia A, and Wang J. 2010. Determination of brix and POL in sugar cane juice by using near infrared spectroscopy coupled with BP-ANN. *Spectroscopy and Spectral Analysis*, 30, 1759-1762.
- Wu Y, Wang H, Zhang B, and Du K-L. 2012. Using Radial Basis Function Networks for Function Approximation and Classification. *International Scholarly Research Notices Applied Mathematics*, 1-34.
- Zaki dizaji H, Monjezi N, and Sheikhdavoodi J. 2018. Investigating effective factors on sugarcane production performance to increase the production of sugarcane using data mining. *Iranian Journal of Biosystems Engineering*, 49(3): 501-511. (In Persian).