

پیش‌بینی عملکرد زعفران با استفاده از داده‌های هواشناسی به وسیله شبکه عصبی مصنوعی در استان‌های خراسان رضوی و جنوبی

ناهید نکوئی^۱، محمدعلی بهدانی^۲ و عباس خاشعی سیوکی^{۳*}

۱- دانشجوی کارشناسی ارشد اگرواکولوژی، دانشکده کشاورزی، دانشگاه بیرجند، ایران

۲- دانشیار گروه پژوهشی زعفران دانشکده کشاورزی، دانشگاه بیرجند، ایران

۳- استادیار گروه مهندسی آب دانشکده کشاورزی، دانشگاه بیرجند، ایران

*- نویسنده مسئول: E-mail: abbaskhashei@birjand.ac.ir

نکوئی، ن.، بهدانی، م.ع.، و خاشعی سیوکی، ع.، ۱۳۹۳. پیش‌بینی عملکرد زعفران با استفاده از داده‌های هواشناسی به وسیله شبکه عصبی مصنوعی در استان‌های خراسان رضوی و جنوبی، ایران. نشریه پژوهش‌های زعفران. ۲(۱): ۳۳-۱۵.

تاریخ دریافت: ۱۳۹۲/۰۵/۰۳

تاریخ پذیرش: ۱۳۹۲/۰۸/۰۷

چکیده

زعفران یکی از مهم‌ترین محصولات کشاورزی ایران به ویژه در استان‌های خراسان رضوی و جنوبی می‌باشد. پیش‌بینی عملکرد محصولات با استفاده از داده‌های موجود تأثیرات مهمی در مسایل اجتماعی- اقتصادی و تصمیم‌گیری‌های سیاسی در مقیاس منطقه‌ای دارد. اخیراً کاربرد شبکه‌های عصبی مصنوعی به عنوان ابزاری قوی که قادر به محاسبه معادلات پیچیده و تحلیل عددی با مناسب‌ترین تقریب می‌باشد در کشاورزی مرسوم شده است. این پژوهش به منظور سنجش توانایی تکنولوژی شبکه عصبی مصنوعی (ANN) برای پیش‌بینی عملکرد زعفران (*Corcus sativus*) براساس اطلاعات روزانه هواشناسی و داده‌های سالانه کشاورزی است. داده‌های هواشناسی مورد استفاده شامل داده‌های ۲۰ ساله ایستگاه‌های سینوپتیک استان و شامل تبخیر- تعرق، دما (حداکثر، حداقل)، میانگین رطوبت نسبی و بارندگی می‌باشد. به این منظور ابتدا با بهره‌گیری از نرم‌افزار wingamma داده‌ها و پارامترهای موجود مورد تجزیه و تحلیل قرار گرفت و بهترین ترکیب‌های ورودی به مدل تعیین گردید. کارایی مدل چند لایه پرسپترون (MLP) شبکه عصبی، برای پیش‌بینی عملکرد محصول مورد ارزیابی قرار گرفت. مدل MLP با استفاده از شاخص‌های آماری مقایسه شد. که در مدل MLP شبکه عصبی هنگامی که از داده‌های حداکثر دما، بارندگی، تبخیر و تعرق و رطوبت نسبی فصل پاییز و عملکرد سال قبل، به عنوان متغیرهای مستقل در پیش‌بینی عملکرد محصول استفاده شد ($R^2=0.8832$ و $RMSE = 0.689 \text{ kg.ha}^{-1}$ و $MAE= 0560 \text{ kg.ha}^{-1}$) بیشترین کارایی بدست آمد.

واژه‌های کلیدی: آزمون گاما، هوش مصنوعی، مدل چند لایه پرسپترون

مقدمه

کراور و روش (Cravener & Roush, 2001) شبکه‌های عصبی مصنوعی و رگرسیون خطی را برای پیش‌بینی مقدار اسیدهای آمینه در علوفه دامی مورد بررسی قرار دادند و گزارش کردند که شبکه‌های عصبی مصنوعی با کارایی بالاتری رابطه بین اسیدهای آمینه و سایر اجزای تغذیه‌ای را نشان می‌دهند. وو و یین (Wu & Yen, 1992) نیز از دو روش شبکه‌های عصبی مصنوعی و رگرسیون چند متغیره برای پیش‌بینی عملکرد گندم در ارتباط با مصرف کود نیتروژنه استفاده کردند و نشان دادند که استفاده از شبکه‌های عصبی مصنوعی روش جایگزین مناسبی برای تجزیه و تحلیل رگرسیونی می‌باشد.

رحمانی و همکاران (Rahmani et al., 2008) با استفاده از داده‌های اقلیمی مثل بارندگی و شاخص‌های خشکسالی در ایستگاه‌های هواشناسی تبریز و میانه به روش شبکه‌های عصبی مصنوعی عملکرد جو را در استان آذربایجان شرقی تخمین زدند و مدل‌های بهینه بین عملکرد محصول جو با پارامترهای هواشناسی و شاخص‌های خشکسالی را به دست آوردند. از بین مدل‌های شبکه عصبی، مدل چندمتغیره بین پارامترهای متوسط دمای حداقل، تعداد ساعات آفتابی، شاخص ناهنجاری بارش، شاخص ترانسو تغییر یافته و شاخص استاندارد شده بارش ۲۴ ماهه مربوط به ایستگاه تبریز با دوره آماری ۳۰ سال به عنوان بهترین مدل برای پیش‌بینی عملکرد جو دیم در منطقه شناخته شد. این تحقیق همچنین نشان داد که به دلیل بالا بودن ضریب تبیین مدل بهینه، روش شبکه عصبی در پیش‌بینی عملکرد از کارایی قابل قبولی برخوردار است.

همچنین رحمانی و همکاران (Rahmani et al., 2008) با استفاده از پارامترهای هواشناسی و شاخص‌های خشکسالی به بررسی کمی تأثیر خشکسالی بر میزان عملکرد جو در آذربایجان شرقی به روش رگرسیونی چند متغیره پرداختند و مشخص شد که برای پیش‌بینی عملکرد محصول روش‌های چند متغیره بهتر از یک متغیره می‌باشند و نتایج مشابه تحقیق بالا به دست آوردند.

صفا و همکاران (Safa et al., 2003) با استفاده از شبکه عصبی، عملکرد گندم را بر اساس پارامترهای میانگین حداقل دمای روزانه، بیشترین مقدار دمای حداکثر روزانه، جمع مقادیر بارش روزانه، تعداد روزهای بارانی، جمع ساعات آفتابی روزانه،

زعفران (*Corcus sativus*) گیاهی از تیره زنبقیان است که یکی از گران‌ترین ادویه‌های جهان به شمار می‌آید و ارزش غذایی و دارویی فراوانی دارد (Leffingwell, 2008) و به عنوان یک محصول استراتژیک در ایران به شمار می‌آید که سابقه زراعت آن به بیش از ۲۵۰۰ سال قبل برمی‌گردد (Shariff Moghaddasi, 2010) همچنین زعفران ارزشمندترین گیاه بومی ایران بوده و قدمت کشت آن در مناطق جنوبی و مرکزی خراسان به بیش از ۷۵۰ سال می‌رسد (Sadeghi, 1992). بررسی روند سی سال گذشته نشان می‌دهد که سطح زیر کشت زعفران حدود ۱۶ برابر افزایش یافته در حالی که میزان متوسط عملکرد در واحد سطح در حال حاضر حدود ۶۸ درصد سی سال قبل است که این موضوع جای بررسی و کنکاش دارد (Behdani, 2004).

در سال‌های اخیر با توجه به کمبود شدید منابع آبی با کیفیت، رشد یا کشت گیاهان و محصولات زراعی در مناطق مختلف جهان و به ویژه در مناطق خشک و نیمه خشک براساس قابلیت دسترسی به منابع آبی طراحی و اجرا می‌شود که اصولاً در بسیاری از موارد کارایی تولید به ازای مترمکعب آب مصرفی محاسبه می‌شود (Koozegaran, 2010). علی‌رغم تحمل پذیری بالای گیاه زعفران به شرایط کم آبی، تغییرات اقلیمی سال‌های اخیر در مناطق مختلف دنیا رشد و عملکرد گیاهان را به شدت تحت تأثیر قرار داده است.

اثر تغییر اقلیم در بسیاری از نقاط دنیا برای گیاهان زراعی مختلف مشخص شده است (Antel, 1996; Rosenzweig & Parry, 1994). این تأثیر مربوط به سه عامل غلظت CO₂، بارندگی و درجه حرارت می‌باشد (Holden et al., 2003).

نتایج بررسی‌های انجام شده در خصوص ارتباط داده‌های اقلیمی با عملکرد و سطح زیرکشت گیاهان زراعی بیانگر اثر تغییرات درجه حرارت و بارندگی بر میانگین و واریانس عملکرد گیاهان زراعی می‌باشد؛ به طوری که متوسط عملکرد گیاهان زراعی با بارندگی بیشتر افزایش و بالعکس با درجه حرارت‌های بالاتر کاهش می‌یابد و یا به عبارت دیگر می‌توان گفت، افزایش بارندگی باعث کاهش تغییرپذیری عملکرد گیاهان و افزایش درجه حرارت موجب افزایش تغییرپذیری عملکرد گیاهان زراعی می‌شود (Adams, 2000).

از جمله موارد کاربرد شبکه‌های عصبی در علوم کشاورزی می‌توان به پیش‌بینی تبخیر و تعرق توسط کومار و همکاران (Kumar et al., 2003) و پیش‌بینی جریان CO₂ در اکوسیستم‌ها توسط ملیسه وهانلی (Melesse & Hanley, 2005) و محاسبه هدایت هیدرولیکی اشباع خاک توسط تاماری و همکاران (Tamari et al., 1996) نوایان و همکاران (Navabiyan et al., 2004) اشاره کرد.

مقدم‌نیا و همکاران (Moghadamnia et al., 2009) در تحقیقی در راستای تخمین تبخیر به روش‌های ANN و ANFIS از آزمون گاما جهت انتخاب بهترین ترکیب داده‌های ورودی و تعیین تعداد داده‌ی مورد نیاز برای کالیبراسیون مدل استفاده نمودند. در واقع با این آزمون اعتبار داده‌ها سنجیده شد.

پیری و همکاران (Piri et al., 2009) با استفاده از مدل ANN به پیش‌بینی تبخیر در یک ناحیه گرم و منطقه چاه‌نیمه زابل پرداختند. در این مقاله بر اساس آزمون گاما متغیرهای سرعت باد، رطوبت نسبی و نقصان فشار بخار اشباع بهترین ترکیب گزارش شد. و در نهایت، با استفاده از این آزمون اهمیت نسبی تمامی متغیرهای ورودی تعیین گردید.

ریمسان^۱ و همکاران (Remesan et al., 2009) اولین بار در مقاله‌ای در مدل‌سازی شبکه عصبی، یکی از اجزای کلیدی هیدرولوژیکی، به عنوان مثال، تابش خورشیدی را جهت پیش‌بینی مدل استفاده نمودند. این مطالعه با هدف رفع سؤالات در مورد اهمیت نسبی متغیرهای ورودی و تعیین تعداد بهینه‌ی داده‌های مورد نیاز برای ساخت یک مدل مطمئن در حوضه آبریز برو^۲ در انگلستان انجام گرفت. در واقع نتایج این مطالعه نشان‌دهنده اهمیت این آزمون در توسعه مدل و انتخاب داده‌های ورودی می‌باشد.

با توجه به اهمیت زعفران از نظر اقتصادی، صادرات، اشتغال‌زایی و کاربردهای دارویی، پیش‌بینی عملکرد دقیق‌تر آن از اهمیت زیادی برخوردار بوده و امکان تصمیم‌گیری متناسب توسعه‌ای براساس پتانسیل‌های منطقه‌ای را فراهم می‌آورد که پیش‌بینی اعتبار لازم جهت خرید تضمینی این محصول و یا فراهم آوردن تمهیدات لازم جهت تأمین نیروی کارگری مورد

میانگین سرعت باد روزانه، حداکثر مطلق سرعت باد روزانه، میانگین سرعت باد روزانه، میانگین رطوبت نسبی روزانه و جمع نیاز آبی روزانه که برای هر یک از مراحل مختلف فنولوژیکی تعیین شده بود، تخمین زدند.

در مطالعه‌ای توانایی تکنولوژی شبکه عصبی مصنوعی (ANN^۱) و سیستم استنتاج فازی (ANFIS^۲) با استفاده از داده‌های هواشناسی و داده‌های سالانه کشاورزی برای پیش‌بینی عملکرد گندم در استان خراسان مورد بررسی قرار گرفت (Khashei et al., 2011). براساس نتایج حاصله در مدل ANFIS هنگامی که از داده‌های دمایی (حداکثر، حداقل و نقطه شبنم) به عنوان متغیرهای مستقل برای پیش‌بینی گندم دیوم استفاده شد بیشترین کارایی حاصل گردید. در این تحقیق مدل‌های ورودی به صورت سالانه در نظر گرفته شده است، در صورتی که مطالعات دیگر نشان دادند که پارامترهای ماهانه نیز تغییرات عملکرد را پیش‌بینی می‌نماید (Khashei et al., 2011).

در مطالعه‌ای دیگر در منطقه ماریلند آمریکا و با استفاده از شبکه عصبی مصنوعی، عملکرد سویا و ذرت، براساس داده‌های عملکرد این دو محصول در سالیان گذشته مورد بررسی قرار گرفت و نتایج نشان داد که همواره مدل شبکه عصبی مصنوعی برآورد دقیق‌تری را از پیش‌بینی عملکرد نسبت به مدل‌های رگرسیونی نشان می‌دهد (Kaul et al., 2005).

اکبرپور و همکاران (Akbarpoor et al., 2013) نیز با استفاده از پارامترهای اقلیمی مثل بارندگی، دما و رطوبت کارایی شبکه عصبی را بر عملکرد زعفران در بیرجند مورد بررسی قرار داده و دریافتند که شبکه عصبی پیشنهادی با ضریب همبستگی ۰/۹۵ میانگین قدرمطلق خطا ۰/۰۷ و میانگین مربعات خطا ۰/۲ از دقت مناسبی در تخمین عملکرد گیاه زعفران برخوردار است و عملکرد محصول بیشترین حساسیت را به عامل بارندگی سپس دما و در نهایت، رطوبت دارد، ولی آنها تنها از داده‌های شهر بیرجند استفاده کردند و تنوع داده‌های کل مناطق کشت زعفران دیده نشد که با توجه به دقت و نوع داده‌های ورودی نتایج مدل نیز متفاوت خواهد بود.

1- Remesan
2- Brue

¹ Artificial Neural Network
² Adaptive neuro-fuzzy inference system

در آن هر نرون با نرون‌های لایه‌ای بعدی در ارتباط است. هر یک از نرون‌های لایه ورودی در وزنی ضرب می‌شوند. مقدار این وزن همانند عملکرد تقاطعات سیناپتیک در نرون‌های زیستی، تعیین کننده تأثیر هر متغیر بر میزان عملکرد لایه ورودی است (Taherhoseini et al., 2007). متداول‌ترین شبکه‌ها در پیش-بینی و حل مسائل غیرخطی، شبکه‌های موسوم به چند لایه پرسپترون (MLP)^۵ است که سه لایه دارد. که در این تحقیق از یک لایه مخفی در مدل MLP استفاده شد، زیرا (1999 Coulibaly et al.,) ثابت کردند که شبکه‌های دارای یک لایه مخفی قادر به حل مسائل می‌باشند.

امروزه با استفاده از این سیستم‌ها مطالعات زیادی در عرصه علوم مختلف انجام شده است. کاربرد این سیستم‌ها در ایران به خصوص در علوم کشاورزی در آغاز راه است اما به دلیل توانایی در مدل‌سازی فرآیندهای بسیار پیچیده که تعداد عوامل تأثیرگذار در آنها زیاد باشد، امکان استفاده گسترده را در علوم کشاورزی فراهم کرده است (Taherhoseini et al., 2007).

آزمون گاما^۶

از توانایی‌های مدل‌های هوشمند می‌توان به درک درست آنها از مسائل غیرخطی و پیچیده بدون اطلاع قبلی از مدل اشاره نمود، اما تعیین و انتخاب مهم‌ترین و مؤثرترین پارامترهای یک تابع غیرخطی و ناشناخته در مدل‌های شبیه‌ساز یکی از مشکل‌ترین مراحل توسعه مدل است. در این راستا از روشی نوین به‌عنوان آزمون گاما بدین منظور استفاده شده است.

این آزمون به‌عنوان ابزاری قدرتمند در جهت یافتن بهترین ترکیب ورودی در مدل‌سازی غیرخطی است که ایجاد یک مدل هموار قبل از ایجاد مدل را بررسی می‌نماید. با استفاده از این ترکیب اهمیت پارامترهای ورودی، بهترین ترکیب ممکن لازم برای آموزش مدل را می‌توان به‌دست آورد. از آن جا که در حالت کلی آزمون گاما مستلزم وجود و قبول فرضیاتی درباره جامعه مورد مطالعه نیست، از روش‌های آماری ناپارامتری می‌باشد و از نتایج آن، صرف نظر از روش‌های خاص، برای ساخت مدل استفاده می‌شود (Jones et al., 2002). اساساً این آزمون نشان‌دهنده آن قسمت از واریانس خروجی است که آن را با هر

نیاز به ویژه در فصل برداشت زعفران از مهم‌ترین این موارد می‌باشد. از طرف دیگر، پیش‌بینی دقیق‌تر عملکرد زعفران، تضمین‌کننده منافع کلیه دست اندرکاران این صنعت بوده و در نهایت، توانسته منافع ملی کشور را تأمین کند.

از آنجا که تاکنون در خصوص پیش‌بینی عملکرد زعفران از سایر روش‌های مرسوم و استفاده از شبکه عصبی مصنوعی به گونه‌ای متفاوت با کار این تحقیق استفاده شده در این مطالعه عملکرد زعفران با استفاده از سیستم‌های عصبی مصنوعی پیش‌بینی شود. با توجه به تنوع نوع داده‌های ورودی و کارایی مناسب این سیستم‌ها سعی بر آن است که برآورد دقیق‌تری از عملکرد زعفران در مناطق زعفران‌کاری به دست آید.

مواد و روش‌ها

شبکه عصبی مصنوعی ANN

شبکه عصبی مصنوعی در واقع تقلیدی از مغز و شبکه اعصاب انسان است و هدف آن تهیه ساختاری همانند مغز انسان می‌باشد که قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد (Rao & Rao, 1966). شبکه عصبی مصنوعی یکی از انواع سیستم‌های دینامیکی هوشمندی هستند که مبتنی بر داده‌های تجربی بوده و با پردازش داده‌ها، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند (Rahmani et al., 2008). شبکه‌های عصبی به طور کلی، سیستم‌های ریاضی یادگیر غیرخطی هستند (Khashei et al., 2011). این سیستم‌های مبتنی بر هوش محاسباتی سعی در مدل‌سازی ساختار نرو-سیناپتیک مغز بشر دارند. ایده اصلی این روش بر مبنای شبیه‌سازی عملکرد مغز انسان بوده و می‌تواند در مقیاس خیلی کوچک مانند شبکه‌های زیستی، یادگیری داشته باشد و این یادگیری را تعمیم دهد. مهم‌ترین بخش یک شبکه زیستی نرون^۱ است. نرون‌ها سلول‌های تشکیل‌دهنده شبکه عصبی مغز انسان هستند. هر شبکه عصبی مصنوعی از لایه‌های ورودی^۲، پنهان^۳ و خروجی^۴ تشکیل شده است. در هر لایه یک یا چند نرون وجود دارد که عملکرد آنها مانند عملکرد نرون‌های مغز انسان است. یک شبکه عصبی مجموعه‌ای از نرون‌هایی است که

- 1- Neuron
- 2- Input layer
- 3- Hidden layer
- 4- Output layer

⁵ Multi Layers Perspetron
⁷- Gamma Test


این تحقیق براساس داده‌های اقلیمی مربوط به استان‌های خراسان رضوی و جنوبی به عنوان مهمترین نواحی کشت زعفران در ایران در سال ۱۳۹۱ انجام شد.

در شکل ۱ موقعیت شهرهای مختلف مورد مطالعه در دو استان نشان داده شده است. داده‌های ۲۰ ساله در این مطالعه از ایستگاه‌های هواشناسی و سازمان جهاد کشاورزی استان خراسان اخذ گردید. داده‌های هواشناسی مورد استفاده در این تحقیق شامل: مجموع حداقل دمای روزانه، مجموع حداکثر دمای روزانه، مجموع رطوبت نسبی روزانه، مجموع بارندگی و تبخیر - تعرق بودند که به عنوان ورودی مدل و اطلاعات عملکرد محصول نیز که از سازمان‌های جهاد کشاورزی و آمارنامه‌های وزارت جهاد کشاورزی تهیه شد و به عنوان خروجی مدل مورد استفاده قرار گرفتند.

مدل هموار بر ورودی‌ها نمی‌توان محاسبه کرد. پس می‌توان گفت محاسبه گاما شکل ساده‌ای از انحراف خطا به شمار می‌آید که مقدار خطای برآورد شده (واریانس خطا) را با توجه به داده‌های واقعی نشان می‌دهد. این برآورد، آماره گاما (Γ) نامیده می‌شود. دلایل مختلفی مسبب خطاهای موجود در مجموعه‌ی داده‌های اندازه‌گیری شده هستند. از جمله این دلایل که در ذیل به مهمترین آن‌ها اشاره شده است (Jones et al., 2002):

- عدم دقت در اندازه‌گیری
- رابطه بین داده‌های ورودی و داده‌های خروجی هموار نمی‌باشد.
- همه عوامل اثرگذار بر خروجی در ورودی در نظر گرفته نمی‌شود.

منطقه مورد مطالعه



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

جدول ۱- دامنه و خصوصیات آماری داده‌های جمع آوری شده
Table 1- Range and statistical characteristics of collected data set

ردیف Row	پارامتر Parameter	STDEV انحراف از معیار	Max حداکثر	Min حداقل	Average میانگین
1	Tmin total°C مجموع دما (درجه سانی گراد)	785.05	5138.1	1850.7	3383.79
2	Tmax total°C مجموع دمای حداکثر (درجه سانی گراد)	1771.005	10445.4	2866.2	7987.27
3	Pr total (mm) مجموع پارانگی (میلیمتر)	77.5534	390	14	189.47
4	ET total (mm.day ⁻¹) مجموع تبخیر تعرق (میلیمتر بر روز)	322.4995	2316.95	208.7	1508.06
5	RH total% مجموع رطوبت نسبی (درصد)	5023.393	23193.6	1900.28	13779.55
6	Yield (kg.ha ⁻¹) عملکرد (کیلوگرم بر هکتار)	2.162	6.94	0.3	3.843

P_{sp} : مجموع بارندگی در فصل بهار، P_{su} : مجموع بارندگی در فصل تابستان، P_{au} : مجموع بارندگی در فصل پاییز، P_{wi} : مجموع بارندگی در فصل زمستان، P_{total} : مجموع بارندگی در سال، ET_{sp} : مجموع تبخیر و تعرق در فصل بهار، ET_{su} : مجموع تبخیر و تعرق در فصل تابستان، ET_{au} : مجموع تبخیر و تعرق در فصل پاییز، ET_{wi} : مجموع تبخیر و تعرق در فصل زمستان، ET_{total} : مجموع تبخیر و تعرق در سال، RH_{sp} : مجموع رطوبت نسبی در فصل بهار، RH_{su} : مجموع رطوبت نسبی در فصل تابستان، RH_{au} : مجموع رطوبت نسبی در فصل پاییز، RH_{wi} : مجموع رطوبت نسبی در فصل زمستان، RH_{total} : مجموع رطوبت نسبی در فصل بهار، $T_{min\ sp}$: مجموع دمای حداقل در فصل بهار، $T_{min\ su}$: مجموع دمای حداقل در فصل تابستان، $T_{min\ au}$: مجموع دمای حداقل در فصل پاییز، $T_{min\ wi}$: مجموع دمای حداقل در فصل زمستان، $T_{min\ aban}$: مجموع دمای حداقل در ماه آبان، $T_{min\ azar}$: مجموع دمای حداقل در

در جدول ۱ دامنه و خصوصیات آماری برای عوامل مختلف هواشناسی مثل مجموع دمای حداقل (T_{min})، دمای حداکثر (T_{max})، تبخیر و تعرق (ET) بارندگی (Pr)، رطوبت نسبی (RH) و همچنین عملکرد زعفران ($Yield$) محاسبه گردید.

مرحله پیش پردازش آزمون گاما

در این مرحله، با استفاده از پارامترهای هواشناسی موجود (T_{min} , T_{max} , P , ET , RH) و با در نظر گرفتن تمامی پارامترها در ترکیب‌ها، ۸۶ ترکیب ورودی مختلف به طور تصادفی انتخاب شده و برای نرم‌افزار WinGamma تعریف گردید. در این تحقیق سعی گردید پارامترهای هواشناسی به صورت فصلی و در بعضی از موارد به صورت ماهانه در نظر گرفته شوند.

حداکثر در ماه بهمن، $T_{maxesfand}$: مجموع دمای حداکثر در ماه اسفند و $T_{maxtotal}$: مجموع دمای حداکثر در سال می‌باشد. در جدول ۲ تمامی ترکیب‌های مورد آزمون قرار گرفته شده معرفی گردیده‌اند. این مرحله مقادیر آماره گاما، خطای استاندارد و شیب خط رگرسیون برآورد گردید. واضح است که در بین ترکیب‌های ممکن برخی ترکیب‌ها با داشتن پارامترهای اثرگذارتر بر عملکرد زعفران دارای اهمیت بیشتری خواهند بود.

ماه آذر، $T_{min\ dey}$: مجموع دمای حداقل در ماه دی، $T_{min\ bahman}$: مجموع دمای حداقل در ماه بهمن، $T_{min\ esfand}$: مجموع دمای حداقل در ماه اسفند، $T_{mintotal}$: مجموع دمای حداقل در سال، T_{maxsu} : مجموع دمای حداکثر در فصل بهار، T_{maxsp} : مجموع دمای حداکثر در فصل تابستان، $T_{maxmehr}$: مجموع دمای حداکثر در ماه مهر، $T_{maxaban}$: مجموع دمای حداکثر در ماه آبان، $T_{maxazar}$: مجموع دمای حداکثر در ماه آذر، T_{maxdey} : مجموع دمای حداکثر در ماه دی، $T_{maxbahman}$: مجموع دمای

جدول ۲- ترکیب‌های مورد آزمون قرار گرفته در آزمون گاما

Table 2- combination tested in gammatest

پارامترها Parameters	شماره ترکیب‌ها Numbers of combination
$P_{sp}-P_{su}-P_{au}-P_{wi}$	1
$P_{sp}-P_{su}-P_{au}-P_{wi}-y$	2
$ET_{SP}-ET_{su}-ET_{au}-ET_{wi}$	3
$ET_{SP}-ET_{su}-ET_{au}-ET_{w}-y$	4
$RH_{sp}-RH_{su}-RH_{au}-RH_{wi}$	5
$RH_{sp}-RH_{su}-RH_{au}-RH_{wi}-y$	6
$T_{min\ total}-T_{max\ total}-P_{total}-ET_{total}-RH_{total}$	7
$T_{min\ total}-T_{max\ total}-P_{total}-ET_{total}-RH_{total}-y$	8
$P_{sp}-P_{su}-P_{au}-P_{wi}-RH_{sp}-RH_{su}-RH_{au}-RH_{wi}$	9
$P_{sp}-P_{su}-P_{au}-P_{wi}-RH_{sp}-RH_{su}-RH_{au}-RH_{wi}-y$	10
$ET_{SP}-ET_{su}-ET_{au}-ET_{wi}-RH_{sp}-RH_{su}-RH_{au}-RH_{wi}$	11
$ET_{SP}-ET_{su}-ET_{au}-ET_{wi}-RH_{sp}-RH_{su}-RH_{au}-RH_{wi}-y$	12
$T_{min\ total}-T_{max\ total}-P_{total}-ET_{total}$	13
$T_{min\ total}-T_{max\ total}-P_{total}-ET_{total}-y$	14
$P_{total}-ET_{total}$	15

$P_{total}-ET_{total}-y$	16
$P_{sp}-P_{su}-P_{au}-P_{wi}-ET_{SP}-ET_{su}-ET_{au}-ET_{wi}$	17
$P_{sp}-P_{su}-P_{au}-P_{wi}-ET_{SP}-ET_{su}-ET_{au}-ET_{wi}-y$	18
$P_{total}-ET_{total}-RH_{total}$	19
$P_{total}-ET_{total}-RH_{total}-y$	20
$T_{min\ sp}-T_{min\ su}-T_{max\ sp}-T_{max\ su}-P_{sp}-P_{su}$	21
$T_{min\ sp}-T_{min\ su}-T_{max\ sp}-T_{max\ su}-P_{sp}-P_{su}-y$	22
$P_{sp}-P_{su}-ET_{SP}-ET_{su}$	23
$P_{sp}-P_{su}-ET_{SP}-ET_{su}-y$	24
$P_{sp}-P_{su}-RH_{sp}-RH_{su}$	25
$P_{sp}-P_{su}-RH_{sp}-RH_{su}-y$	26
$P_{sp}-P_{su}-ET_{SP}-ET_{su}-RH_{sp}-RH_{su}$	27
$P_{sp}-P_{su}-ET_{SP}-ET_{su}-RH_{sp}-RH_{su}-y$	28
$T_{min\ sp}-T_{min\ su}-ET_{SP}-ET_{su}$	29
$T_{min\ sp}-T_{min\ su}-ET_{SP}-ET_{su}-y$	30
$T_{max\ sp}-T_{max\ su}-P_{sp}-P_{su}-RH_{sp}-RH_{su}$	31
$T_{max\ sp}-T_{max\ su}-P_{sp}-P_{su}-RH_{sp}-RH_{su}-y$	32
$ET_{SP}-ET_{su}-RH_{sp}-RH_{su}$	33
$ET_{SP}-ET_{su}-RH_{sp}-RH_{su}-y$	34
$ET_{au}-ET_{wi}-RH_{au}-RH_{wi}$	35
$ET_{au}-ET_{wi}-RH_{au}-RH_{wi}-y$	36
$T_{min\ sp}-T_{max\ sp}-P_{sp}-ET_{SP}-RH_{sp}$	37
$T_{min\ sp}-T_{max\ sp}-P_{sp}-ET_{SP}-RH_{sp}-y$	38
$T_{min\ su}-T_{max\ su}-P_{su}-ET_{su}-RH_{su}$	39

$T_{\min su} - T_{\max su} - P_{su} - ET_{su} - RH_{su} - y$	40
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar}$	41
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - y$	42
$T_{\min mehr} - T_{\min dey} - T_{\min bahman} - T_{\max mehr} - T_{\max dey} - T_{\max bahman}$	43
$T_{\min mehr} - T_{\min dey} - T_{\min bahman} - T_{\max mehr} - T_{\max dey} - T_{\max bahman} - y$	44
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - P_{au}$	45
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - P_{au} - y$	46
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - ET_{au}$	47
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - ET_{au} - y$	48
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - RH_{au}$	49
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - RH_{au} - y$	50
$T_{\min mehr} - T_{\min dey} - T_{\max mehr} - T_{\max dey} - P_{au} - P_{wi}$	51
$T_{\min mehr} - T_{\min dey} - T_{\max mehr} - T_{\max dey} - P_{au} - P_{wi} - y$	52
$T_{\min mehr} - T_{\min bahman} - T_{\min esfand} - T_{\max mehr} - T_{\max bahman} - T_{\max esfand} - P_{wi}$	53
$T_{\min mehr} - T_{\min bahman} - T_{\min esfand} - T_{\max mehr} - T_{\max bahman} - T_{\max esfand} - P_{wi} - y$	54
$T_{\max mehr} - T_{\max dey} - P_{au} - P_{wi} - ET_{au} - ET_{wi}$	55
$T_{\max mehr} - T_{\max dey} - P_{au} - P_{wi} - ET_{au} - ET_{wi} - y$	56
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - P_{au} - P_{wi} - ET_{au} - ET_{wi}$	57
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - P_{au} - P_{wi} - ET_{au} - ET_{wi} - y$	58
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - P_{au} - P_{wi} - RH_{au} - RH_{wi}$	59
$T_{\min aban} - T_{\min azar} - T_{\max aban} - T_{\max azar} - P_{au} - P_{wi} - RH_{au} - RH_{wi} - y$	60
$T_{\min bahman} - T_{\min esfand} - T_{\max bahman} - T_{\max esfand} - P_{sp} - ET_{sp} - RH_{sp}$	61
$T_{\min bahman} - T_{\min esfand} - T_{\max bahman} - T_{\max esfand} - P_{sp} - ET_{sp} - RH_{sp} - y$	62
$T_{\min mehr} - T_{\min aban} - T_{\max mehr} - T_{\max aban} - P_{sp} - P_{su}$	63
$T_{\min mehr} - T_{\min aban} - T_{\max mehr} - T_{\max aban} - P_{sp} - P_{su} - y$	64

$T_{\max} \text{ bahman} - T_{\max} \text{ esfand} \quad T_{\min} \text{ bahman} - T_{\min} \text{ esfand} - ET_{wi} - RH_{wi}$	65
$T_{\max} \text{ bahman} - T_{\max} \text{ esfand} \quad T_{\min} \text{ bahman} - T_{\min} \text{ esfand} \quad ET_{wi} - RH_{wi} - y$	66
$T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - P_{au} - RH_{au}$	67
$T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - P_{au} - RH_{au} - y$	68
$T_{\max} \text{ mehr} - T_{\max} \text{ aban} - T_{\max} \text{ azar} - P_{au} - RH_{au} - ET_{au}$	69
$T_{\max} \text{ mehr} - T_{\max} \text{ aban} - T_{\max} \text{ azar} - P_{au} - RH_{au} - ET_{au} - y$	70
$T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand} - P_{wi} - RH_{wi}$	71
$T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand} - P_{wi} - RH_{wi} - y$	72
$T_{\max} \text{ dey} - T_{\max} \text{ bahman} - T_{\max} \text{ esfand} - RH_{wi}$	73
$T_{\max} \text{ dey} - T_{\max} \text{ bahman} - T_{\max} \text{ esfand} - P_{wi} - RH_{wi} - y$	74
$T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand}$	75
$T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand} - y$	76
$T_{\max} \text{ mehr} - T_{\max} \text{ aban} - T_{\max} \text{ azar} - T_{\max} \text{ dey} - T_{\max} \text{ bahman} - T_{\max} \text{ esfand}$	77
$T_{\max} \text{ mehr} - T_{\max} \text{ aban} - T_{\max} \text{ azar} - T_{\max} \text{ dey} - T_{\max} \text{ bahman} - T_{\max} \text{ esfand} - y$	78
$T_{\min} \text{ sp} - T_{\min} \text{ su} - T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand}$	79
$T_{\min} \text{ sp} - T_{\min} \text{ su} - T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand} - y$	80
$T_{\max} \text{ sp} - T_{\max} \text{ su} - T_{\max} \text{ mehr} - T_{\max} \text{ aban} - T_{\max} \text{ azar} - T_{\max} \text{ dey} - T_{\max} \text{ bahman} - T_{\max} \text{ esfand}$	81
$T_{\max} \text{ sp} - T_{\max} \text{ su} - T_{\max} \text{ mehr} - T_{\max} \text{ aban} - T_{\max} \text{ azar} - T_{\max} \text{ dey} - T_{\max} \text{ bahman} - T_{\max} \text{ esfand} - y$	82
$T_{\min} \text{ sp} - T_{\min} \text{ su} - T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand} - P_{au}$	83
$T_{\min} \text{ sp} - T_{\min} \text{ su} - T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - T_{\min} \text{ dey} - T_{\min} \text{ bahman} - T_{\min} \text{ esfand} - P_{au} - y$	84
su	
$T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - P_{au} - RH_{au} - ET_{au}$	85
$T_{\min} \text{ mehr} - T_{\min} \text{ aban} - T_{\min} \text{ azar} - P_{au} - RH_{au} - ET_{au} - y$	86

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad \text{معادله (۴)}$$

که در این معادلات، N : تعداد مشاهدات، P_i : مقادیر تخمین زده شده و O_i : مقادیر مشاهده شده است؛ در حالی که \bar{O} و \bar{P} : به ترتیب میانگین‌های O_i و P_i هستند.

بعد از تعیین مدل دقیق با استفاده از جعبه ابزار ANN در نرم افزار MATLAB نسخه ۲۰۰۸ محاسبات لازم انجام شد.

نتایج و بحث

آزمون گاما و انتخاب ترکیب‌های مناسب

آزمون گاما برای تمام ترکیب‌های موجود در جدول ۲ محاسبه گردید. بهترین ترکیب‌ها بر اساس مقدار آماره گاما و نیز ترکیب‌هایی با مقادیر آماره‌ی گامای نزدیک به هم در جدول ۳ آورده شده‌اند.

در این مطالعه، مبنای انتخاب ترکیب بهینه، کمترین مقدار آماره گاما می‌باشد. با توجه به نتایج به‌دست آمده از آزمون گاما در جدول ۳ ترکیب ۱۱ با داشتن کمترین مقدار آماره گاما نشان‌دهنده تأثیر زیاد مجموع رطوبت نسبی و تبخیر و تعرق چهار فصل سال به عنوان ورودی سناریو بر روی خروجی یعنی عملکرد زعفران است.

بررسی معیارهای ارزیابی

در شبکه استفاده شده داده‌ها به سه بخش تقسیم گردید که ۶۰ درصد داده‌ها برای آموزش شبکه، و ۲۰ درصد جهت اعتبار سنجی که نرم افزار برای کالیبره کردن مدل شبکه عصبی به کار می‌برد و ۲۰ درصد جهت آزمون و ارزیابی مدل مورد استفاده قرار گرفت (Khashei et al., 2011). به منظور تبدیل داده‌ها و قرار گرفتن آنها بین صفر و یک این داده‌ها نرمال سازی شدند. زیرا در این پژوهش برای عناصر پردازش‌گر (نرون‌ها) لایه مخفی تابع آستانه زیگموئیدی^۱ انتخاب گردید. خروجی این تابع اعدادی بین صفر تا یک می‌باشد و شکل داده‌های ورودی به آن در یادگیری شبکه نقش مهمی ایفاء می‌کند (Menhaj, 1998). بدین‌منظور، از معادله (۱) برای نرمال سازی داده‌ها استفاده گردید.

معادله (۱) $X_{norm} = [X - X_{min} / X_{max} - X_{min} \times 0.8 + 0.1]$ که در این معادله، X_{norm} : مقدار نرمال شده داده، X : مقدار اصلی داده و X_{min} و X_{max} : به ترتیب حداقل و حداکثر داده‌ها می‌باشند. بنابراین، براساس فرض اولیه نرمال بودن پارامترهای مورد استفاده در شبکه عصبی مصنوعی، ابتدا تمامی پارامترهای هواشناسی و عملکردهای زعفران جهت نرمال بودن مورد بررسی قرار گرفتند. سپس برای ارزیابی عملکرد و صحت سنجی مدل از شاخص‌های آماری، ضریب همبستگی (R^2) ، ریشه میانگین مربعات خطا (RMSE) و میانگین کامل خطا (MAE^۴) استفاده گردید.

$$R^2 = \frac{\left[\sum_{i=1}^N (P_i - \bar{P}) (O_i - \bar{O}) \right]^2}{\sum_{i=1}^N (P_i - \bar{P})^2 \sum_{i=1}^N (O_i - \bar{O})^2} \quad \text{معادله (۲)}$$

$$RMSE = \left[N^{-1} \sum_{i=1}^N (P_i - O_i)^2 \right]^{0.5} \quad \text{معادله (۳)}$$

- 1- Sigmoid
- 2- Determination coefficient
- 3- Root Mean Square Error
- 4- Mean Absolute Error

جدول ۳- نتایج آزمون گاما برای تعیین مدل‌های بهینه جهت پیش‌بینی عملکرد محصول

Table 3- Gamma test results to determine the optimal model to predict product performance result of gama test for detected

پارامترها Prameters	آماره گاما Gama parameter	شماره ترکیب Number of combination
$ET_{SP}-ET_{su}-ET_{au}-ET_{wi}-RH_{sp}-RH_{su}-RH_{au}-RH_{wi}$	0.008764	11
$T_{min bahman}-T_{min esfand}-T_{max bahman}-T_{max esfand}-P_{sp}-ET_{sp}-RH_{sp}-y$	0.00967	62
$T_{maxsp}-T_{maxsu}-T_{maxmehr}-T_{maxaban}-T_{maxazar}-T_{maxdey}-T_{maxbahman}-T_{maxesfand}$	0.010949	81
$T_{min aban}-T_{min azar}-T_{max aban}-T_{max azar}-P_{au}-P_{wi}-RH_{au}-RH_{wi}$	0.011454	59
$T_{min aban}-T_{min azar}-T_{max aban}-T_{max azar}-P_{au}-P_{wi}-RH_{au}-RH_{wi}-y$	0.012785	60
$T_{min mehr}-T_{min aban}-T_{max mehr}-T_{max aban}-P_{sp}-P_{su}$	0.013507	63
$T_{max mehr}-T_{max aban}-T_{max azar}-P_{au}-RH_{au}-ET_{au}-y$	0.013751	70
$T_{maxsp}-T_{maxsu}-T_{maxmehr}-T_{maxaban}-T_{maxazar}-T_{maxdey}-T_{maxbahman}-T_{maxesfand}-y$	0.01449	82
$P_{sp}-P_{su}-P_{au}-P_{wi}-ET_{SP}-ET_{su}-ET_{au}-ET_{wi}-y$	0.015436	18
$T_{min mehr}-T_{min aban}-T_{min azar}-P_{au}-ET_{au}-RH_{au}$	0.018415	85

ارزیابی عملکرد شبکه عصبی مصنوعی در تعیین عملکرد محصول

جدول ۴ انواع مدل‌های ورودی به شبکه که براساس آزمون گاما انتخاب گردید و دارای مقدار آماره گاما پایین‌تری نسبت به سایر ترکیب‌ها می‌باشد و بهترین تعداد لایه‌های مخفی و تعداد تکرار برای دقت شبکه عصبی برای هر مدل در شبکه را نشان می‌دهد. همان‌طور که مشاهده می‌شود بهترین تعداد لایه مخفی برای اکثر مدل‌ها یک لایه بوده است و نتایج حاصل از بررسی ۱۰ سناریو مختلف با شبکه عصبی مصنوعی در شکل ۲ ارائه شده است که برای ارزیابی عملکرد مدل شبکه عصبی، نتایج حاصل از این مدل (عملکرد پیش‌بینی شده) در برابر داده‌های اندازه‌گیری شده (عملکرد مشاهده شده)، ترسیم و با برازش بهترین خط عبوری از میان آن‌ها، مقادیر ضریب

همبستگی و شیب بهترین خط عبوری محاسبه و نشان داده شد. بدیهی است هرچه ضریب همبستگی داده‌ها بالاتر باشد و نیز شیب بهترین خط عبوری از آن‌ها به یک نزدیک‌تر باشد دقت پیش‌بینی مدل بیشتر است. مقادیر عملکرد پیش‌بینی شده توسط مدل شبکه عصبی و مقادیر اندازه‌گیری شده عملکرد برای الگوهای ورودی مختلف به مدل نشان داده است که از بین سناریوهای ورودی سناریوی I (مجموع دمای حداکثر سه ماه مهر و آبان و آذر و بارندگی و تبخیر و تعرق و رطوبت نسبی فصل پاییز و عملکرد سال قبل) دارای بهترین ضریب همبستگی و شیب خط ($R^2=0.8832$ و $RMSE=0.689$ و $kg.ha^{-1}$ و $MAE=0.56kg.ha^{-1}$) و این بیانگر این امر است که دمای حداکثر و بارندگی و تبخیر و تعرق و رطوبت نسبی در ماه پاییز ارتباط نزدیکی با عملکرد زعفران داشته است.

R^2 و $RMSE = 1.78 \text{ kg.ha}^{-1}$ و $MAE = 0.595 \text{ kg.ha}^{-1}$ که ترکیب دماها و بارندگی در فصل پاییز است نیز از ضریب همبستگی بالایی برخوردار است که این با نتایج هنیزو و ریچارد (Heinzow & Richard, 2002) که دریافتند که ترکیب مختلف داده‌های هواشناسی (T_{mean} , T_{dew} and P) برای یولاف و T_{mean} , T_{max} and P : برای جو بهاره و T_{mean} and P : برای ذرت) دارای بهترین نتیجه برای پیش‌بینی عملکرد است مطابقت دارد.

از مقایسه دو سناریو C با ($R^2 = 0.8499$ و $RMSE = 0.730 \text{ kg.ha}^{-1}$) و سناریو B ($MAE = 0.55 \text{ kg.ha}^{-1}$ و $RMSE = 0.7961$) و $MAE = 0.5761 \text{ kg.ha}^{-1}$ و $RMSE = 0.746 \text{ kg.ha}^{-1}$ و $R^2 = 0.730$ که تفاوت این دو سناریو فقط در یک پارامتر ورودی است در می‌یابیم، که سناریو C که عملکرد سال قبل هم به عنوان ورودی سناریو قرار گرفته باعث افزایش ضریب همبستگی شده است.

از مقایسه دو سناریو J ($R^2 = 0.8282$ و $RMSE = 0.766$) و سناریو A ($MAE = 0.60 \text{ kg.ha}^{-1}$ و $RMSE = 0.6256$) و $MAE = 0.64 \text{ kg.ha}^{-1}$ و $RMSE = 0.796 \text{ kg.ha}^{-1}$ که نسبت به سایر سناریوها تأثیر کمتری داشتند، سناریو A نیز نسبت به J از تأثیر کمتری برخوردار است که می‌توان دریافت که تبخیر و تعرق و رطوبت نسبی از اهمیت کمتری برای پیش‌بینی عملکرد نسبت به دما و بارندگی برخوردار هستند.

به طور کلی، با مقایسه شاخص‌های آماری R^2 و $RMSE$ بین سناریوها ترتیب اولویت آن‌ها به صورت I, G, C, J, B, E, H, F و D, A (از چپ به راست) است که می‌توان نتیجه گرفت بارندگی و درجه حرارت، به خصوص درجه حرارت حداقل و حداکثر و بارندگی در فصل پاییز بیشترین تأثیر را روی عملکرد زعفران می‌گذارند، زیرا گیاه زعفران بیشترین تطابق را با الگوی بارندگی دارد و مکان‌هایی که ۳۰۰-۴۰۰ میلی‌متر بارندگی دارند و در طول فصل زمستان پوشیده از برف می‌باشند برای کشت زعفران مناسب هستند. فعالیت این گیاه با شروع بارندگی‌های پاییزه آغاز و با اتمام بارندگی‌های بهاره خاتمه می‌یابد در نتیجه بارندگی یا به عبارتی نزولات جوی بیشترین تأثیر را بر رشد این گیاه دارد (Behdani, 2005) و از آنجایی که زعفران برعکس بسیاری از گیاهان دارای رژیم حرارتی

همچنین سناریو G (مجموع دمای حداقل سه ماه مهر و آبان و آذر و بارندگی و تبخیر و تعرق و رطوبت نسبی فصل پاییز) بعد از سناریو I با ($R^2 = 0.853$ و $RMSE = 0.705 \text{ Kg.ha}^{-1}$) و $MAE = 0.5715 \text{ Kg.ha}^{-1}$ در رتبه دوم قرار دارد و بیشتر بودن ضریب همبستگی در سناریو I نسبت به سناریو G می‌تواند به علت وجود عملکرد سال قبل به عنوان ورودی در سناریو I باشد، اما به طور کلی، از این دو سناریو می‌توان نتیجه گرفت که دمای حداقل و حداکثر، بارندگی، تبخیر و تعرق و رطوبت نسبی در فصل پاییز تأثیر بیشتری بر روی عملکرد دارند و این با نتایج کوزه‌گران و همکاران (Koozehgaran et al., 2011) که نشان دادند درجه حرارت حداقل و حداکثر در ماه‌های مهر، آبان، آذر و دی تأثیرگذارتر بر عملکرد نسبت به سایر ماه‌ها می‌باشند، مطابقت دارد. همچنین سناریو C (حداکثر دمای ماه‌های پاییز، زمستان و بهار و تابستان و عملکرد سال قبل) با ($R^2 = 0.8499$ و $RMSE = 0.730 \text{ kg.ha}^{-1}$) در رتبه سوم قرار دارد که این هم تأثیر بیشتر درجه حرارت را نسبت به بارندگی بر روی عملکرد زعفران نشان می‌دهد.

از بین سناریوهای ورودی سناریو A (مجموع رطوبت نسبی و تبخیر و تعرق فصل بهار، تابستان، پاییز و زمستان) با ($R^2 = 0.6256$ و $RMSE = 0.796 \text{ kg.ha}^{-1}$ و $MAE = 0.64 \text{ kg.ha}^{-1}$) دارای کمترین ضریب همبستگی است که می‌توان نتیجه گرفت تبخیر و تعرق و رطوبت نسبی به تنهایی کمتر از سایر پارامترها بر روی عملکرد تأثیر داشته‌اند.

سناریو J (مجموع بارندگی و تبخیر و تعرق فصل بهار، تابستان، پاییز و زمستان و عملکرد سال قبل) با ($R^2 = 0.8282$ و $RMSE = 0.766 \text{ kg.ha}^{-1}$ و $MAE = 0.60 \text{ kg.ha}^{-1}$) بعد از سناریو C در رتبه چهارم قرار گرفته است که این نشان دهنده این است که تأثیر بارندگی بعد از درجه حرارت بر روی عملکرد قرار دارد و این یافته‌ها با نتایج حسینی و همکاران (Hosseini et al., 2008) که دریافتند کاهش عملکرد زعفران استان خراسان به طور قابل توجهی تحت تأثیر درجه حرارت و بارندگی است، اما تأثیر بارندگی در مقایسه با درجه حرارت کمتر بوده مطابقت دارد.

سناریو E (مجموع دمای حداقل و حداکثر ماه آبان و بارندگی پاییز و رطوبت نسبی پاییز و عملکرد سال قبل) با ($R^2 = 0.7864$)

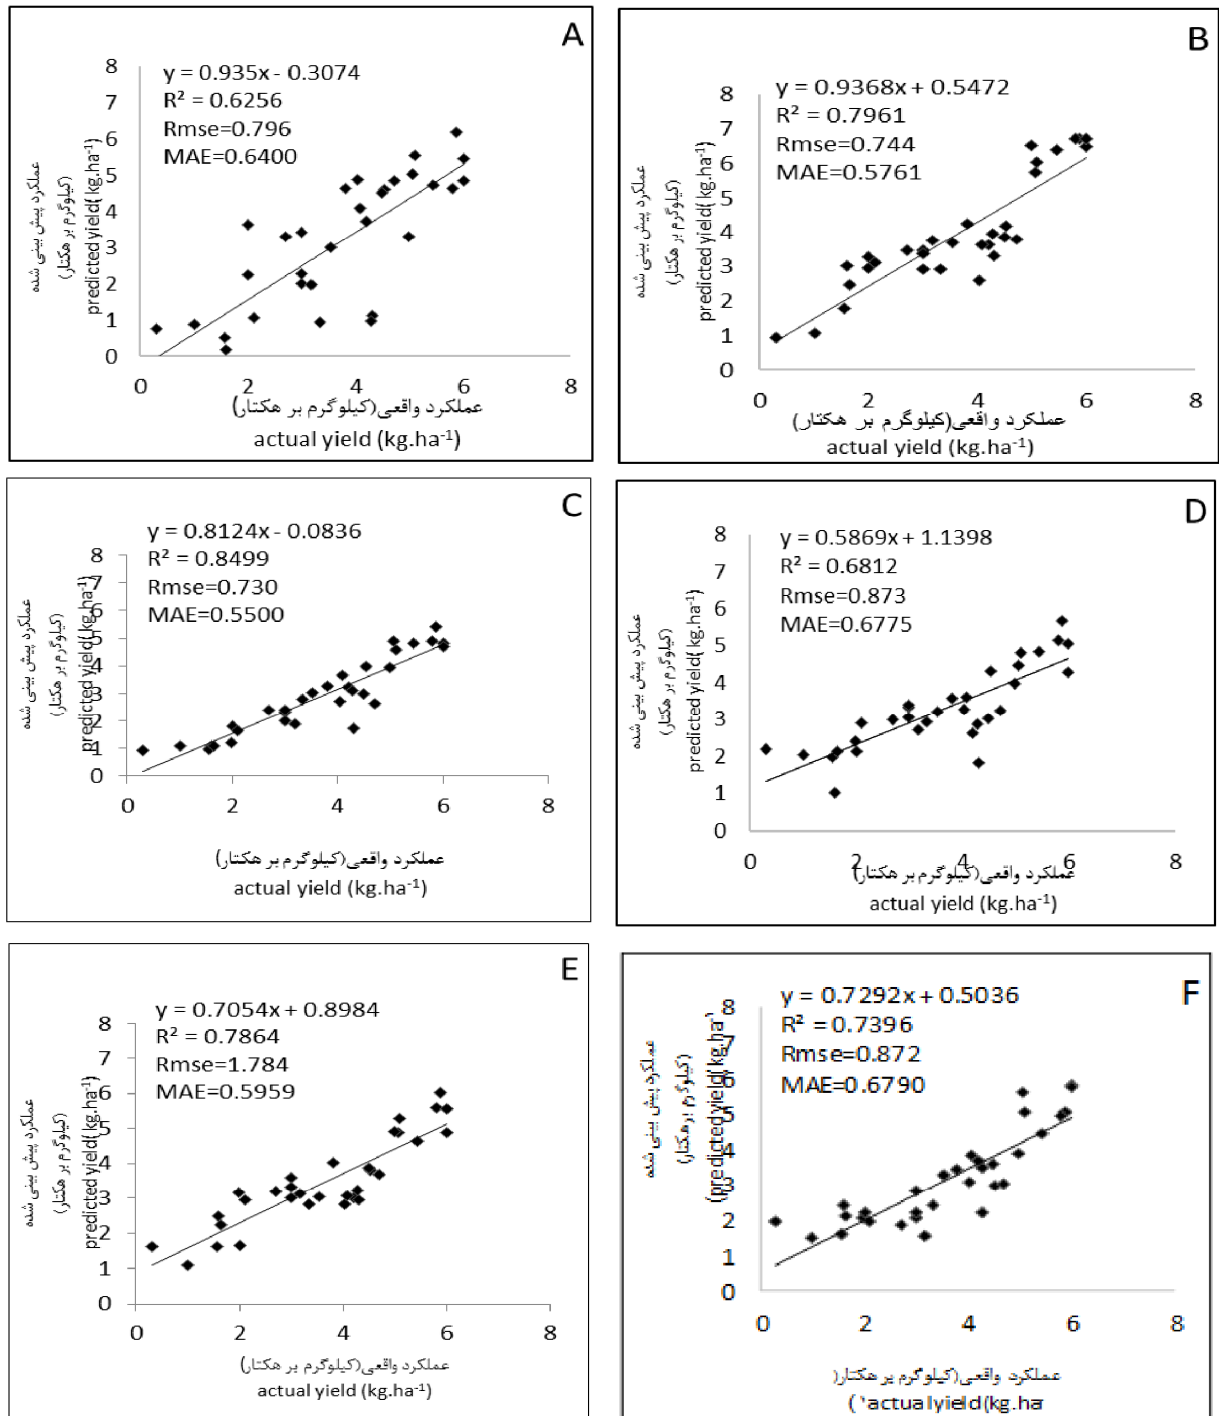
بارندگی، دما و یا ترکیبی از این دو پارامتر اقلیمی در فصل پاییز استفاده شده بیشترین R^2 و کمترین RMSE (بهترین نتیجه) حاصل شده است.

متفاوتی است و معمولاً آغاز فعالیت این گیاه با شروع فصل سرما همراه است، دما مهمترین عامل در تنظیم گل‌های پیاز زعفران می‌باشد و تغییرات دمای روزانه به عنوان عامل محیطی نشان دهنده زمان گلدهی است. که در سناریوهای I,G که

جدول ۴- نمایش آماری مدل‌های MLP جهت تخمین عملکرد زعفران

Table 4- Performance statistics of the MLP models for dryland saffron yield estimation

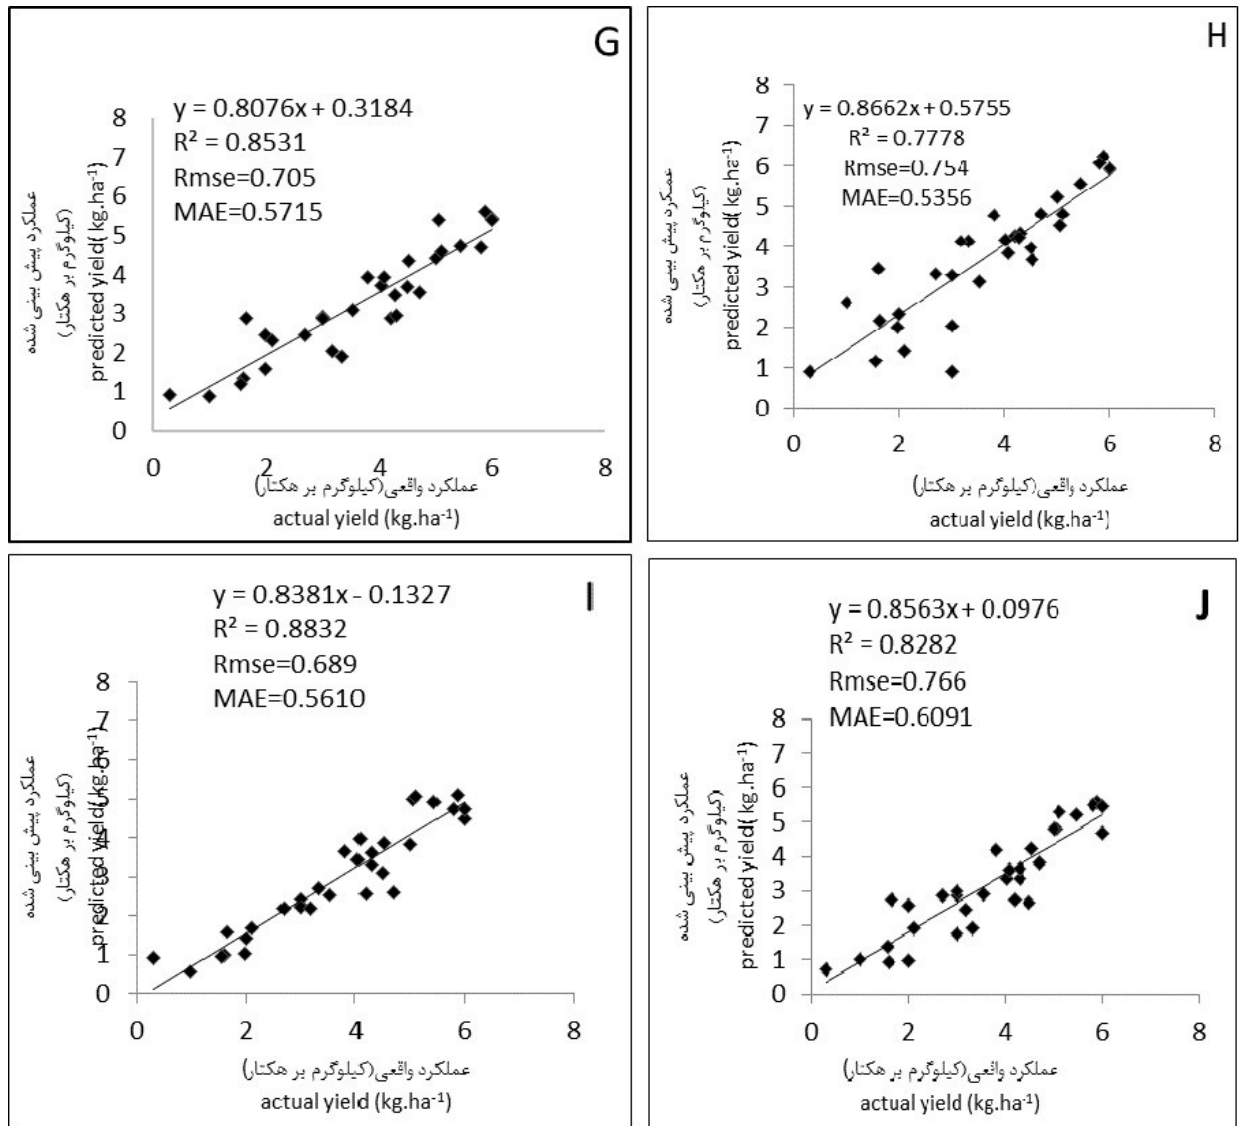
بهرترین تعداد لایه‌های مخفی Optimum number of hidden layers	تکرار Iteration	پارامترهای ورودی Input parameters	نوع سناریو type of senario
3	18	$ET_{SP}-ET_{su}-ET_{au}-ET_{wi} - RH_{sp}-RH_{su}-RH_{au}-RH_{wi}$	A
3	184	$T_{maxsp}-T_{maxsu} -T_{maxmehr} -T_{maxaban} -T_{maxazar}-T_{maxdey}-T_{maxbahman} -T_{maxesfand}$	B
1	16	$T_{maxsp}-T_{maxsu} -T_{maxmehr} -T_{maxaban} -T_{maxazar}-T_{maxdey}-T_{maxbahman} -T_{maxesfand}-y$	C
1	33	$T_{min aban}-T_{min azar}-T_{max aban}-T_{maxazar}- P_{au}- P_{wi} RH_{au}-RH_{wi}$	D
1	186	$T_{min aban}-T_{min azar}-T_{max aban}-T_{maxazar}- P_{au}- P_{wi} RH_{au}-RH_{wi}-y$	E
1	91	$T_{min mehr}-T_{min aban}-T_{max mehr}-T_{max aban}- P_{sp}- P_{su}$	F
1	18	$T_{min mehr} -T_{min aban}- T_{min azar} - P_{au} - ET_{au} RH_{au}$	G
1	19	$T_{min bahman}-T_{min esfand}-T_{max bahman}-T_{max esfand}.P_{sp}-ET_{sp}-RH_{sp} -y$	H
1	33	$T_{max mehr}-T_{max aban}- T_{max azar} P_{au} RH_{au} ET_{au} y$	I
1	15	$P_{sp}- P_{su}- P_{au}-P_{wi}- ET_{SP}-ET_{su}-ET_{au}-ET_{wi}-y$	J



شکل ۲- مقایسه عملکرد مشاهده شده و پیش‌بینی شده زعفران (کیلوگرم بر هکتار) برای داده‌های مورد آزمون در مدل‌های مختلف

(A,B,C,D,E,F,G,H,I,J) MLP

Fig. 2-Scatter plot of observed versus estimated values of crop yield for the testing data set of MLP for different models of (A,B,C,D,E,F,G,H,I)



شکل ۲- مقایسه عملکرد مشاهده شده و پیش‌بینی شده زعفران (کیلوگرم بر هکتار) برای داده‌های مورد آزمون در مدل‌های مختلف MLP (A,B,C,D,E,F,G,H,I,J)
 Fig. 2- Scatter plot of observed versus estimated values of saffron yield (kg.h⁻¹) for the testing data set of MLP for different models of (A,B,C,D,E,F,G,H,I,J)

نتیجه‌گیری

این دقت بالای شبکه عصبی باعث شده که از این مدل‌ها در زمینه‌های مختلف زمان‌بندی، طراحی، سیاسی و استفاده شوند و از آنجایی که اندازه‌گیری بارندگی کار آسانی است و در تمام نقاط کشور ایستگاه‌های باران‌سنجی مختلف وجود دارد و عملکرد زعفران نیز شدیداً به بارندگی وابسته است می‌توان به راحتی عملکرد زعفران را در مناطق مختلف زعفران کاری کشور بر اساس داده‌های موجود در این ایستگاه‌ها با استفاده از شبکه‌های عصبی مصنوعی تخمین زد.

هدف از انجام این تحقیق پیش‌بینی عملکرد زعفران و ارزیابی و کارایی شبکه عصبی مصنوعی است که با توجه نتایج بالا می‌توان دریافت که شبکه عصبی مصنوعی مقدار عملکرد زعفران را با دقت بالایی پیش‌بینی می‌کند و همچنان که مشاهده می‌شود ضرایب همبستگی و شیب خط‌های عبوری بسیار به یک نزدیک است و این نشان می‌دهد که مقادیر پیش‌بینی شده دارای حداکثر انطباق با مقادیر مشاهده شده می‌باشد که این مطلب دقت بالای شبکه عصبی را به اثبات می‌رساند.

منابع

- Adams, R.M., 2000. Climate variability and climate change: Implications for agriculture. IRI Proceedings. Oregon State University, USA
- Akbarpour, A., Khorashadzadeh, O., Shahidi, A., Ghochanian, E., 2013. Performance evaluation of artificial neural network models in estimate production of yield saffron based on climate parameters. Journal of Saffron Research. 1(1): 27-35. In Persian with English Summary
- Antle, J.M., 1996. Meteorological issues in assessing potential impacts of climate change on agriculture. Agricultural and Forest Meteorology. 80, 67-85
- Behdani, M. A., 2005. Ecological mapping and monitoring of changes in Khorasan saffron. Ph.D. dissertation, Department of Agriculture, Faculty of Agriculture, Ferdowsi University of Mashhad.
- Cravener, T.L., Roush, W.B., 2001. Prediction of amino acid profiles in feed ingredients: genetic algorithm calibration of artificial neural networks. Animal Feed Science and Technology. 90, 131-141
- Coulibaly, P., Anctil, F., Bobee, B., 1999. Provision Hydrologique par Reseaux de Neurons Artificiels. Canadian Journal of Civil Engineering. 26(3), 293-304.
- J.Jones, A., Evans, D., Margetts, S.J., Durrant P., 2002. the GAMMATEST, Idea Group Publishing.
- Heinzow, T., Richard, T., 2002. Prediction of Crop Yields Across Four Climate Zones in Germany: an Artificial Neural Network Approach. Working Paper FNU-34 Centre for Marine and Climate Research, Hamburg University, Germany.
- Holden, N.M., Brereton, A.J., Fealy, R., Sweeney, J., 2003. Possible change in Irish climate and its impact on barely and potato yields. Agricultural and Forest Meteorology. 116: 181-196
- Hosseini, M., Mollafilabi. A., Nassiri, M., 2008. Spatial and temporal patterns in Saffron (*Crocus sativus* L.) yield of Khorasan province and their relationship with long term weather variation. Journal of Agriculture Research. 6(1), 79-86. [in Persian with English Summary]
- Kaul, M., Hill, R. L., Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. Agricultural System. 85, 1-18
- Khashei-Siuki, A., Kouchakzadeh, M., Ghahraman, B., 2011. Predicting dryland wheat yield from meteorological data using expert system, Khorasan Province. Iran J. Agr. Sci. Tech. 13, 627-640.
- Koozehgaran, S., Mousavi Baygi, M., Sanaeinejad, S.H., Behdani, M.A., 2011. Study of the minimum, average and maximum temperature in south khorasan to identify relevant areas for saffron cultivation using GIS. Journal of Water and Soil. 25(4), 892-904. In Persian with English Summary
- Kumar, M., Raghuwanshi, N.S., Singh, R., Wallender, W.W., Pruitt, W.O., 2002. Estimating evapotranspiration using artificial neural network. Journal of Irrigation and Drainage Engineering. 128(4), 224-233.
- Leffingwell, J., 2008. Saffron. Leffingwell Reports. 2(5), 1-6.

- Menhaj, M.B., 1998. Foundations of Neural Networks. First edition, Evolution Center Professor Farsi.
- Melesse, A.M., Hanley, R.S., 2005. Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modeling*. 189, 305-314
- Moghaddamnia, A., Ghafari Gousheh, M., Piri, J., Amin, S., Han, D., 2009. Evaporation estimation using artificial neural networks and adaptive neurofuzzy Inference system techniques. *Journal of Advanced Water Resource*. 32, 88-97.
- Navabian, M., Liaghat, A.M., Homayi, M., 2004. Fast calculation of hydraulic conductivity of saturated soil using artificial neural networks. *Soil and Water Resources Conference Student*. [in Persian]
- Piri, J., Amin, S., Moghadamnia, A., Keshavarz, A., Han, D., Remesan, R., 2009. Daily pan evaporation modeling in a hot and dry climate. *Hydrologic Engineering*. 14(8), 803-811.
- Rahmani, A., Khalili, A., Liyaghat, A., 2008. Quantitative Survey of Drought Effects on Barley Yield in East Azerbaijan multiple regression method. *Journal of Science and Technology of Agriculture and Natural Resources*. 44, 25-36. [In Persian].
- Rao, V., Rao, H., 1996. C⁺⁺ Neural network and fuzzy logic, BPB, New Delhi, India, 380-381.
- Remesan, R., Shamim, M.A., Han, D., 2008. Model data selection using gamma test for daily solar radiation estimation. *Hydrological Processes*. 22, 4301-4309.
- Rosenzweig, C., Parry, M.L., 1994. Potential impacts of climate change on world food supply. *Nature*. 367, 133-138.
- Sadeghi, B., 1993. Effect of corm weight on saffron flower collection. *Publication of Scientific Research- Technology Research Center of Khorasan*. In Persian with English Summary
- Safa, B., Khalili, A., Liaghat, A., Teshnehlab, M., 2003. Application of artificial neural networks for wheat yield prediction using climatic data. *Royal Meteorological Society Conference 2003*. Sept. 1-5, 2003. UEA, Norwich, England.
- Sharrif-Moghaddasi, M., 2010. *Journal of Medicinal Plants Research*. 4(6), 427-430.
- Wu, F. Y., Yen, K.K., 1992. Application of neural network in regression analysis. *Computer and Industrial Engineering*. 23, 93-95
- Taher Hosseini, M.T., Siosemarde, A., Fathi, P., Siosemarde, M., 2007. Application of artificial neural network (ANN) and multiple regression for estimating the performance of dry farming wheat yield in Ghorveh region, Kurdistan Province. *Journal of Agriculture Research: Water, Soil and Plant in Agriculture*. 7(1), 41-54. [In Persian with English Summary]
- Tamari, S., Wosten, J.H.M., Ruiz Suarez, J.C., 1996. Testing an artificial neural network for predicting soil hydraulic conductivity. *SSSAJ*. 60(6), 1732-1741.

Predicting saffron yield from meteorological data using expert system, Razavi and South Khorasan Provinces

Nahid Nekouei¹, Mohammad Ali Behdani² and Abbas Khashei-Siuki^{3*}

1- MSc student in Agroecology, Agriculture Faculty, University of Birjand, Iran

2- Associate Professor, Saffron Research Group, University of Birjand, Iran

3- Assistant Professor of Water engineering, Dpt. University of Birjand, Iran

*: Corresponding author E-mail: abbaskhashei@birjand.ac.ir

Nekouei, N., Behdani, M.A., and Khashei-Siuki, A., 2014. Predicting saffron yield from meteorological data using expert system, Razavi and South Khorasan Provinces. *Journal of Saffron Research*. 2(1): 15-33.

Submitted: 25-07-2013

Accepted: 29-10-2013

Abstract

Khorasan Province is one of the most important provinces of Iran, especially as regards agricultural product. The prediction of crop yield with available data has important effects on socio-economic and political decisions at the regional scale. Recently, the application of Artificial Neural Network (ANN) has been developed as a powerful tool which enables to solve accurately the most complicated equations and to perform appropriate numerical analysis. This study shows the ability of Artificial Neural Network (ANN) technology for the prediction of saffron (*Corcus sativus*) yield, based on the available daily weather and yearly agricultural data. Evapotranspiration, temperature (max, min, and dew temperatures), precipitation and daily average relative humidity for 20 years at synoptic stations were the weather data used. The potential of ANN and Multi-Layered Preceptron (MLP) methods were examined to predict saffron yield. The MLP models of Artificial Neural Networks and regression using maximum temperature, precipitation, evapotranspiration and relative humidity of autumn and last year yield, as independent variables in predicting the crop yield ($R^2=0.8832$, $RMSE= 0.689 \text{ kg.ha}^{-1}$, $MAE= 0.560 \text{ kg.ha}^{-1}$), the most efficiency was achieved.

Keywords: Expert System, Gammatest, Multi-layered perceptron.