



تحلیل دقت و عدم قطعیت مدل شبکه عصبی مصنوعی در پیش‌بینی عملکرد زعفران در خراسان جنوبی مبتنی بر داده‌های اقلیمی

حسین ریاحی مدورا^{۱*}، عباس خاشعی سیوکی^۲ و اکرم سیفی^۱

تاریخ پذیرش: ۲۲ بهمن ۱۳۹۴

تاریخ دریافت: ۷ مرداد ۱۳۹۴

ریاحی، ح.، خاشعی، ع.، و سیفی، ا. ۱۳۹۶. تحلیل دقت و عدم قطعیت مدل شبکه عصبی مصنوعی در پیش‌بینی عملکرد زعفران در خراسان جنوبی مبتنی بر داده‌های اقلیمی. زراعت و فناوری زعفران، ۵(۳): ۲۷۱-۲۵۵.

چکیده

با توجه به حساسیت عملکرد زعفران و تأثیرپذیری آن از پارامترهای اقلیمی و خاصیت غیرخطی توابع عملکرد گیاهی، در این تحقیق پیش‌بینی و تحلیل عدم قطعیت مدل شبکه عصبی مصنوعی در تخمین عملکرد زعفران انجام شد. بردار ورودی مدل از بین ۳۷ مؤلفه مختلف، بر اساس استراتژی همبستگی و تحلیل تورم واریانس بهینه‌سازی شد و مدل با معماری ۱-۲-۴-۱۱ با تابع فعال‌سازی سیگموئید در مراحل سه‌گانه آموزش و آزمایش و ارزیابی عملکرد برتری را نشان داد. مقادیر پارامترهای MAE و RMSE مدل شبکه عصبی مصنوعی در مرحله یادگیری برابر ۰/۳ و ۰/۵ و در مرحله آزمایش به ترتیب ۰/۷ و ۱ حاصل شد. نتایج تحلیل عدم قطعیت مونت کارلو بر مبنای ۱۰۰۰ نمونه‌گیری بدون جایگذاری، بر اساس فاکتورهای R^2 ، 95% PPU، d-factor، بیانگر پهنای باند اطمینان مطلوب پیش‌بینی‌ها بود و الگوهای عمومی و کلی تغییرات عملکرد زعفران را به خوبی پیش‌بینی نمود. متوسط ضریب R^2 مدل در مرحله آموزش و آزمایش بر اساس ۱۰۰۰ شبیه‌سازی مونت کارلو به ترتیب ۰/۹۲ و ۰/۵۸ بود که برای مدل‌های عملکرد گیاهی مبتنی بر داده‌های اقلیمی دارای معنی-داری در سطح ۱٪ است. با این حال در شرایط حدی و مرزی، احتمال بروز وقایعی خارج از باند پیش‌بینی ۹۵ درصد وجود داشته و لزوم توجه به شرایط مدیریت تغذیه، کود، خاک و آب مزارع در مدل‌های هوشمند پیش‌بینی عملکرد را نشان می‌دهد. بر اساس نتایج پژوهش حاضر برنامه‌ریزان به‌جای مواجهه با یک رقم به‌عنوان پیش‌بینی، ترکیب این رقم و باند اطمینان را در اختیار داشته و می‌توانند تصمیمات واقع-بینانه‌تری اتخاذ نمایند.

کلمات کلیدی: پارامترهای اقلیمی، تحلیل عدم قطعیت، شبکه عصبی مصنوعی، شبیه‌سازی مونت کارلو، عملکرد زعفران.

۱- استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ولیعصر (عج) رفسنجان

۲- دانشیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه بیرجند

*- نویسنده مسئول: (h.riahi@vru.ac.ir)

مقدمه

ایران بزرگ‌ترین تولیدکننده و صادرکننده زعفران در جهان است به طوری که بیش از ۶۵ درصد تولید جهانی این محصول گران‌بها به ایران اختصاص دارد، ولی عملکرد در واحد سطح ایران در مقایسه سایر کشورهای تولیدکننده این محصول کمتر است (Akrami et al., 2014) و علیرغم قدمت کشت زعفران و ارزش افزوده این محصول، تولید آن عمدتاً بر دانش بومی متکی است (Sanaeinejad et al., 2010). زعفران از مهم‌ترین محصولات کشاورزی ایران در استان‌های خراسان رضوی و جنوبی می‌باشد (Nekouei et al., 2014) و قدمت کاشت آن در این استان‌ها به ۷۵۰ سال می‌رسد (Sadeghi, 2012). آنالیز روند سطح زیرکشت زعفران بیانگر افزایش ۱۶٪ در سطح زیرکشت این محصول ولی کاهش عملکرد به میزان ۶۸ درصد عملکرد سی سال گذشته است (Behdani et al., 2005) و نشان‌دهنده تأثیرپذیری عملکرد زعفران از شرایط اقلیمی و مدیریتی کشاورزی است. اقلیم از طریق تغییر در مقادیر CO_2 ، درجه حرارت و بارندگی بر عملکرد محصولات کشاورزی تأثیر می‌گذارد. ارتباط داده‌های اقلیمی با عملکرد و سطح زیرکشت گیاهان زراعی وجود ارتباط دو سویه بین بارندگی و درجه حرارت با عملکرد و سطح زیرکشت را نشان داده است (Adams et al., 2001). نتایج پژوهش‌ها در منطقه خراسان نشان‌دهنده کاهش مداوم عملکرد زعفران در یک دهه گذشته به واسطه تغییرات شاخص‌های آب و هوایی است، به طوری که کاهش ۳۱ تا ۶۶ درصدی عملکرد زعفران با دو عامل درجه حرارت و رطوبت قابل توصیف است. زعفران کاران فردوس با استفاده از کود دامی فراوان و آب کافی به عملکردی برابر ۴۰ کیلوگرم در هکتار دست یافته‌اند (Koocheki, 2014) و این مسئله لزوم توجه به شرایط مدیریت کشاورزی آب و خاک در توسعه مزارع زعفران را نشان می‌دهد.

پیش‌بینی عملکرد و میزان تولید محصولات کشاورزی در شرایط اقلیمی و هواشناسی مختلف براساس داده‌های قابل‌دستیابی، به دلیل اهمیتی که در برنامه‌ریزی اقتصادی دارند از دیر باز مورد توجه پژوهشگران بوده است. در این میان مدل‌های کامپیوتری مبتنی بر داده‌های سهل‌الوصول امکان بررسی استراتژی‌های مختلف مدیریتی را فراهم آورده‌اند. در زمینه پیش‌بینی عملکرد گیاهی با مدل‌های هوش مصنوعی می‌توان به مواردی از قبیل: ارزیابی کارایی شبکه عصبی مصنوعی جهت پیش‌بینی مؤلفه‌های عملکرد گندم (Norouzi et al., 2008)، پیش‌بینی عملکرد گندم به کمک شبکه‌های عصبی مصنوعی تحت تأثیر ویژگی‌های خاک و توپوگرافی، شبکه‌های عصبی مصنوعی و موجکی در پیش‌بینی درصد شکستگی جو در کمابین برداشت (Shabani et al., 2011)، پیش‌بینی انرژی خروجی (عملکرد محصول) در تولید سیب‌زمینی با رویکرد شبکه‌های عصبی مصنوعی و منطق فازی (Pasandi et al., 2015)، تخمین عملکرد محصول جو به روش شبکه عصبی مصنوعی (Rahmani et al., 2008)، کارایی مدل‌های شبکه عصبی مصنوعی در محاسبه عملکرد و بهره‌وری آب گندم (Alvarez, 2009)، شبیه‌سازی پاسخ عملکرد گیاه آفتابگردان به شرایط خاک و شوری با استفاده از شبکه عصبی مصنوعی (Dai et al., 2011)، برآورد عملکرد و خوشه‌بندی ارقام نخود با استفاده از تکنیک محاسبات نرم شبکه‌های عصبی مصنوعی و منطق فازی (Khazaei et al., 2008)، پیش‌بینی کمیت و کیفیت گندم با استفاده از مدل شبکه عصبی مصنوعی (Norouzi et al., 2010) اشاره کرد. تحلیل حساسیت مدل‌ها نشان‌دهنده بیشترین حساسیت عملکرد محصول به عامل بارندگی سپس دما و در نهایت رطوبت می‌باشد (Akbarpour et al., 2013). با توجه به اینکه شرایط رشد و توسعه و نهایتاً عملکرد گیاه تابع شرایط مختلف گیاهی، اقلیمی، مدیریت آبیاری و مدیریت

حداکثر درست‌نمایی و استنتاج بیزین و روش مونت کارلو پیشنهاد شده توسط مارس و همکاران (Marce et al., 2004) را نام برد. در تحقیق حاضر روش مارس و همکاران (Marce et al., 2004) به دلیل جدید بودن و عملکرد مناسب گزارش شده، از آن استفاده شده است. این تحقیق تأثیر عدم قطعیت و خطاها در ورودی‌های مدل‌های هوش مصنوعی پیش‌بینی عملکرد گیاه با رویکرد شبیه‌سازی مونت کارلو بررسی می‌نماید. با توجه به ارزش استراتژیکی زعفران در استان‌های خراسان رضوی و جنوبی و اینکه تاکنون تحلیل عدم قطعیت مدل شبکه‌های عصبی مصنوعی در پیش‌بینی عملکرد زعفران انجام نشده است این تحقیق با هدف تحلیل دقت و عدم قطعیت شبکه عصبی مصنوعی در پیش‌بینی عملکرد زعفران مبتنی بر داده‌های اقلیمی در استان خراسان جنوبی بر اساس داده‌های اقلیمی ۲۰ ساله انجام شده است.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده

منطقه مورد مطالعه در این تحقیق استان خراسان جنوبی است. در شکل ۱ موقعیت شهرهای استان نشان داده شده است. آمار و اطلاعات مربوط به عملکرد زعفران و پارامترهای اقلیمی و هواشناسی به ترتیب از سازمان جهاد کشاورزی و ایستگاه‌های هواشناسی تهیه شده است. مجموعه متغیرهای هواشناسی مورد استفاده در این تحقیق عبارتند از: مجموع حداقل و حداکثر دما در فصل‌ها و سال‌های مختلف، بارندگی فصلی و سالیانه، تبخیر و تعرق فصلی و سالیانه، متوسط رطوبت نسبی فصلی و سالیانه که بر اساس مقادیر روزانه داده‌ها و اطلاعات محاسبه شده‌اند و همچنین متغیر خروجی نیز عملکرد محصول زعفران بر حسب کیلوگرم بر هکتار است. در جدول ۱ محدوده تغییرات، میانگین و انحراف معیار کلیه پارامترها ارائه شده است.

تغذیه و کود و خاک است و از روابط پیچیده غیرخطی پیروی می‌کند، پیش‌بینی عملکرد گیاه نیازمند استفاده از مدل‌های غیرخطی است به همین دلیل از مدل‌های داده محور مبتنی بر شبکه‌های عصبی مصنوعی بدین منظور استفاده می‌شود. در اغلب مطالعات مدل‌سازی عملکرد گیاهی، نااطمینانی در پیش‌بینی‌های بهینه مدل‌های تخمین‌گر وجود دارد. در واقع، در فرآیند مدل‌سازی اغلب نااطمینانی به‌طور ذاتی و اجتناب‌ناپذیری تحت تأثیر وجود عدم قطعیت و خطا در متغیرهای مستقل ورودی مدل، پارامترها، ضرایب و ساختار مدل است (Riahi et al., 2011).

در روش عمومی عدم قطعیت تشابهات در تحلیل‌ها با فرض عدم وجود پارامترهای بهینه منحصر به فرد با استفاده از روش شبیه‌سازی مونت کارلو چندین سری پارامترهای مختلف ایجاد شده، نتایج حاصل از سری‌های مختلف براساس نسبت اعتماد آن‌ها وزن گرفته و سپس از این وزن‌ها برای تعیین توزیع احتمالاتی پیش‌بینی استفاده می‌شود (Shafiei et al., 2013). اگرچه تحلیل‌های عدم قطعیت در مطالعات منابع آب در دو دهه گذشته استفاده شده است ولی در زمینه مدل‌های گیاهی و مدل‌های عملکرد گیاهی موضوع نسبتاً جدیدی محسوب می‌شود. برخی از مهم‌ترین چالش‌ها در این زمینه استنتاج منابع اصلی خطای مؤثر بر پیش‌بینی‌های مدل و استنتاج روش‌های محاسباتی مناسب برای کمی‌سازی این عدم قطعیت‌ها است. یکی از موارد مهمی که بر خلاف مدل‌های آماری در مدل‌های شبکه‌های عصبی مصنوعی پیش‌بینی عملکرد گیاهی به آن‌ها کمتر پرداخته شده است، تحلیل عدم قطعیت در هنگام ارائه نتایج می‌باشد (Riahi et al., 2011).

بررسی تحقیقات پیشین مرتبط با تحلیل عدم قطعیت مدل‌های هوش مصنوعی بیان‌گر این است که روش‌هایی برای تعیین عدم قطعیت در این مدل‌ها توسعه یافته که از جمله می‌توان روش‌های تخمین‌زننده ساندویچ (Tibshirani, 1994)،

مدل‌سازی شبکه عصبی مصنوعی

مدل‌های شبکه‌های عصبی (ANNs) قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم را توسط شبکه‌ای از گره‌ها که همگی به هم متصل هستند، تعیین نمایند که در آن میزان فعالیت هر یک از این اتصالات توسط اطلاعات تاریخی ثبت شده تنظیم می‌شود (فرآیند یادگیری) و در نهایت مدل قادر خواهد بود قوانین مرتبط میان ورودی‌ها و خروجی‌ها را کشف نماید، هرچند این قوانین غیرخطی و پیچیده باشند (Riahi et al., 2011). در ANN، نرون‌ها در دسته‌هایی که لایه نام دارند، مرتب می‌شوند که تعداد این لایه‌ها و تعداد نرون موجود در هر یک از لایه‌ها معماری شبکه را تعریف می‌کند. معماری معمول شبکه عصبی متشکل از سه لایه است: لایه ورودی، لایه پنهان و لایه خروجی. طراحی معماری ANNs عموماً بر

مبنای روش سعی و خطا بنا شده است وزی آن با استفاده از ارقام مختلف لایه‌های پنهان و نرون‌های مربوط، می‌توان ابعاد مناسب شبکه را تعیین نمود.

در ساختار ANNs اطلاعات رسیده از نرون‌های قبلی (x_i) تا x_j به نرون i ام در وزن‌های مربوط به هر کدام (w_{ij} تا w_{i1}) ضرب و سپس جمع می‌شوند. برای جلوگیری از صفر شدن مقدار ورودی نرون، یک مقدار آستانه نیز به مقدار قبلی اضافه گردیده (b_i) و بدین ترتیب مقدار ورودی نرون (net_i) تعیین می‌گردد. وزن‌ها مبین شدت اتصال نرون‌ها به هم می‌باشند و طی فرآیند یادگیری اوزان و آستانه بهینه می‌گردند. در ادامه مقادیر ورودی در تابع عضویت نرون قرار گرفته و خروجی به لایه بعد انتقال می‌یابد (Maier & Dandy, 2000).



شکل ۱- نقشه موقعیت منطقه مورد مطالعه

Figure 1- Location of the studied area.

جدول ۱- مشخصات متغیرهای مورد استفاده در تحقیق

Table 1- Range and statistical characteristics of collected data set

ردیف Row	پارامتر Parameter	میانگین Average	محدوده Range	انحراف معیار STDEV
1	مجموع دمای حداقل T _{min} Total (°C)	3490.736	1850.7-5138.1	888.04
2	مجموع دمای حداکثر T _{max} Total (°C)	8959.144	7684.8-10445.4	671.430
3	مجموع بارندگی Pr Total (mm)	143.689	14255.3	54.145
4	رطوبت نسبی RH Total (%)	10629.43	1900.3-18538	5179.011
5	مجموع تبخیر - تعرق (mm.day ⁻¹) ET Total	1691.198	1170.932-2255.715	201.761
6	عملکرد Yield (kg.ha ⁻¹)	3.883	0.92-7.94	1.805

یکسان به متغیرهای مختلف در زمان آموزش شبکه عصبی، داده‌ها قبل از ورود به مدل طبق پیشنهاد سانکومار و همکاران (Sanjkhumar & Thandaveswara, 1999) به صورت تصادفی استاندارد شدند. نوع شبکه عصبی انتخابی در این تحقیق از نوع شبکه پرسپترون چندلایه با قانون یادگیری پس-انتشار خطا به علت قابلیت بارز آن در مسائل پیچیده مهندسی است. کارکرد اصلی این نوع شبکه در شناسایی روابط ذاتی بین متغیرهای مستقل و وابسته است که در این تحقیق نگاشت بین متغیرهای ورودی اقلیمی و متغیر خروجی عملکرد زعفران را انجام داده است. در این تحقیق معماری شبکه به روش تکرار خودکار با یک برنامه که با شروع از یک لایه مخفی و تعداد نرون‌های متغیر بین یک تا ۲۰ نرون، در لایه مخفی انجام شد. ابتدا تعداد نرون‌های بهینه در شبکه با یک لایه مخفی تعیین و در مرحله بعد دو لایه مخفی استفاده و مجدداً تعداد نرون‌های بهینه لایه مخفی دوم نیز تعیین شد و به همین صورت تعداد لایه‌های مخفی یکی افزایش یافت و فرآیند تا دستیابی به ساختار بهینه شبکه عصبی ادامه یافت. در نهایت از بین مدل‌های مختلف آموزش یافته شبکه عصبی مصنوعی مدلی که بهترین پیش‌بینی‌ها را داشت به عنوان مدل بهینه انتخاب شد. برای هر حالت بعد از آموزش شبکه، مقدار میانگین مربعات خطای آن ثبت شد. مقایسه مقادیر خطاها نشان داد که شبکه با

اولین مرحله و در عین حال از مهم‌ترین مراحل در ساخت مدل‌های ANNs، انتخاب ورودی‌های مؤثر از بین اطلاعات موجود می‌باشد. انتخاب ورودی‌های مناسب به دلایل زیر مهم می‌باشد (Bowden et al., 2005: الف) با افزایش تعداد متغیرهای ورودی پیچیدگی محاسباتی و حافظه مورد نیاز مدل به سرعت افزایش می‌یابد، ب) با ورود متغیرهای زیاد، آموزش مدل مشکل و ناکارآمد می‌شود و ج) ورود متغیرهای پرت سبب افزایش تعداد حداقل‌های محلی در سطح خطا گردیده که این امر می‌تواند باعث کاهش همگرایی و در نتیجه دقت پایین مدل گردد. در ابتدا پالایش گرافیکی روی داده‌ها انجام شد و متغیرها یا سال‌هایی که متغیرها غیرمعقول و یا گم‌شده بودند از مدل‌سازی‌ها حذف گردید. به منظور انتخاب متغیرهای بهینه ورودی از تحلیل همبستگی و تحلیل تورم واریانس بین عملکرد زعفران و کلیه متغیرهای اقلیمی استفاده شده و متغیرهایی که بالاترین همبستگی را با توجه به ضریب R² محاسباتی داشتند به عنوان ورودی‌های مدل شبکه عصبی مصنوعی انتخاب شده‌اند و در نهایت متغیرهای ورودی با بهترین نتایج، به عنوان متغیرهای ورودی نهایی به مدل انتخاب شدند.

در فرآیند توسعه مدل شبکه عصبی مصنوعی ۵۰٪ داده‌ها برای آموزش، ۲۵٪ برای نظارت بر آموزش و ۲۵٪ برای صحت‌سنجی مورد استفاده قرار گرفت. به منظور اطمینان از توجه

در عدم تکرار یک الگو در یک نمونه می‌باشد. در این روش، ابتدا از اطلاعاتی که برای کالیبراسیون مدل در نظر گرفته شده‌اند به دفعات زیاد معمولاً ۱۰۰۰۰ بار (Aqil et al., 2007) و بدون تکرار نمونه‌گیری می‌شود به نحوی که تعداد داده‌های آموزش و نظارت بر آموزش در هر نمونه یکسان باشد و برای هر نمونه عملیات کالیبراسیون مدل انجام می‌شود. در نتیجه پارامترهای مدل به دفعات زیاد و هر بار بر اساس نمونه‌ای از وقایع اتفاق افتاده در گذشته به دست می‌آیند.

انجام این مراحل به تخمین عدم قطعیت در پارامترهای مدل و نتیجتاً خروجی مدل، عدم اریب بودن میانگین خروجی مدل و تعیین حدود اطمینان مقادیر پیش‌بینی شده می‌انجامد (Marce et al., 2004). در نتیجه با استفاده از این تکنیک محاسباتی حجیم به جای پیش‌بینی یک عدد مطلق مطابق با آنچه در تحقیقات مشابه انجام گرفته، محدوده‌ای از خروجی که نتیجه عدم قطعیت مدل ساخته شده می‌باشد، حاصل خواهد شد. این روش بر مبنای قرارگیری مدل‌ها در قالب یک پروسه نمونه-گیری تصادفی مونت کارلو می‌باشد که اولین بار برای برآورد میزان خروج سالانه مواد معدنی مغذی محلول در رودخانه از حوضه با استفاده از مدل نروفازی به کار گرفته شد (Aqil et al., 2007). چهار شاخص آماری متداول ضریب همبستگی (R)، میانگین خطای مطلق (MAE)، ریشه میانگین مربعات خطا (RMSE) و درصد میانگین خطای نسبی (MAPE) برای سنجش خطای مدل‌ها به کار گرفته شد.

برای بررسی عدم قطعیت حدود اطمینان ۹۵٪ (95PPU) برای پیش‌بینی‌ها مد نظر قرار گرفت که طریقه به دست آوردن آن تعیین حدود ۲/۵٪ (X_L) و ۹۷/۵٪ (X_U) توزیع تجمعی احتمال تجربی به دست آمده از ۱۰۰۰۰ پیش‌بینی انجام شده می‌باشد. حدود اطمینان مناسب حدودی هستند که بالای ۸۰٪ از مقادیر مشاهده شده در آن حدود قرار گرفته باشند و دارای عرض

۲ لایه پنهان و ۴ نرون در لایه پنهان اول و ۲ نرون در لایه پنهان دوم با تابع فعال‌سازی سیگموئیدی کمترین خطا را داشته و بهترین ساختار برای شبکه عصبی در شرایط مورد نظر می‌باشد. بعد از انتخاب ساختار شبکه عصبی، حالت‌های مختلفی برای توابع آستانه نرون‌های لایه مخفی و خروجی در نظر گرفته شد و در نهایت تابع سیگموئید به عنوان تابع بهینه انتخاب گردید. سایر مشخصات شبکه عصبی مصنوعی به صورت سعی و خطا و بر اساس مقادیر پیش فرض متلب انتخاب شدند. بعد از تعیین ساختار نهایی و بهینه شبکه عصبی مصنوعی اقدام به آموزش نهایی مدل گردید و وزن‌های نهایی نرون‌ها تعیین گردید و سپس از مدل نهایی آموزش یافته برای شبیه‌سازی و تحلیل مونت کارلو و برآورد عدم قطعیت پیش‌بینی‌ها استفاده شد.

برآورد عدم قطعیت در پیش‌بینی‌ها

همان‌طور که ذکر شد، هدف اصلی این تحقیق بررسی و تخمین عدم قطعیت در خروجی مدل‌های شبکه عصبی مصنوعی می‌باشد که بدین منظور اصول روش پیشنهادی مارس و همکاران (Marce et al., 2004) مبنای قرار داده شد. در این روش مدل‌های شبکه عصبی مصنوعی در قالب یک نمونه‌گیری مونت کارلو به کار گرفته شدند. مبنای روش شبیه‌سازی مونت کارلو بر پایه استفاده از اعداد تصادفی و دستیابی به تابع توزیع احتمالاتی خروجی یک مدل است. بدین صورت که متغیرها (ورودی به مدل) با استفاده از تابع توزیع احتمالاتی مناسب به طور تصادفی تولید شده، سپس خروجی معادل آن‌ها از مدل مورد نظر به دست می‌آید و این عمل بارها تکرار می‌شود. سپس عدم قطعیت خروجی (تابع) از طریق محاسبه شاخص‌های آماری و یا تعیین تابع توزیع احتمالاتی برآورد می‌شود. تفاوت روش مورد بحث در این تحقیق با تعریف بالا، استفاده از نمونه‌های تصادفی گرفته شده به جای اعداد تصادفی ساخته شده می‌باشد. این روش بسیار به روش نمونه‌گیری دودویی شباهت داشته و تنها فرق آن

فرآیند آموزش مدل شبکه عصبی مصنوعی استفاده شد. در این تحقیق، داده‌ها و اطلاعات مربوط به پارامترهای هواشناسی مختلف در مقیاس ماهانه، فصلی و سالیانه گردآوری شده و سپس اقدام به بازبینی و پالایش داده‌های گردآوری شده گردید و با دو رویکرد تحلیل همبستگی و تحلیل تورم واریانس به ترتیب به منظور انتخاب مؤثرترین متغیرها بر عملکرد زعفران و انتخاب متغیرهای ورودی ناهمبسته اقدام شد.

نتایج مربوط به تحلیل همبستگی بین متغیرهای ورودی ۳۷ متغیر ورودی و متغیر خروجی عملکرد زعفران در جدول ۲ ارائه شده است. مطابق نتایج تحلیل همبستگی مشاهده می‌شود که بیشترین ضریب تعیین R^2 بین دمای حداکثر و دمای حداقل بهار با عملکرد زعفران به ترتیب برابر ۰/۴۹ و ۰/۴۶ مشاهده شد و این دو پارامتر به عنوان مؤثرترین پارامترها بر عملکرد زعفران محسوب می‌شوند. در مرتبه بعدی به ترتیب پارامترهای دمای حداقل تابستان با همبستگی ۰/۳۸، دمای حداقل پاییز با همبستگی ۰/۳۶، دمای حداکثر مهر با همبستگی ۰/۳۴، دمای حداکثر سالیانه با همبستگی ۰/۳۴، دمای حداقل سالیانه با همبستگی ۰/۳۳، بارش بهار با همبستگی ۰/۳۲، دمای حداکثر تابستان با همبستگی ۰/۲۷، بارش سالیانه با همبستگی ۰/۱۷، تبخیر تعرق بهار با همبستگی ۰/۱۷، تبخیر تعرق مهر با همبستگی ۰/۱۶، دمای حداکثر زمستان با همبستگی ۰/۱۶، بارش شهریور با همبستگی ۰/۱۵، تبخیر-تعرق شهریور با همبستگی ۰/۱۴، بارش مهر با همبستگی ۰/۱۴، تبخیر تعرق تابستان با همبستگی ۰/۱۳، تبخیر-تعرق سالیانه با همبستگی ۰/۱۳، رطوبت نسبی شهریور با همبستگی ۰/۱۳، رطوبت نسبی مهر با همبستگی ۰/۱۲، تابش مهر با همبستگی ۰/۱۲ و تابش شهریور با همبستگی ۰/۱۱ قرار دارند. همان‌گونه که مشاهده می‌شود بیشترین تأثیرپذیری عملکرد زعفران از پارامترهای اقلیمی مربوط به مقادیر و شرایط در فصل‌های تابستان و پاییز و

متوسط قابل قبولی باشند. برای سنجش عرض متوسط باند اطمینان، شاخص فاکتور عرض باند مطابق زیر پیشنهاد شده است (Abbaspour et al., 2007):

$$d.factor = \frac{\bar{d}_x}{\sigma_x} \quad (1)$$

که در آن σ_x انحراف استاندارد مشاهده شده و \bar{d}_x عرض متوسط باند اطمینان می‌باشد و به صورت زیر تعریف می‌شود:

$$\bar{d}_x = \frac{1}{n} \sum_{i=1}^k (X_U - X_L)_i \quad (2)$$

که مقدار فاکتور عرض باند کوچکتر از ۱ مناسب به حساب می‌آید (Abbaspour et al., 2007). درصد داده‌های قرار گرفته در باند اطمینان ۹۵٪ نیز به صورت زیر محاسبه می‌شود:

$$Bracketed\ by\ 95PPU = \frac{1}{n} count(Q|X_L \leq Q \leq X_U) \times 100 \quad (3)$$

در این تحقیق کلیه مراحل توسعه و انتخاب معماری بهینه مدل شبکه عصبی مصنوعی و شبیه‌سازی مونت کارلو و تحلیل عدم قطعیت با برنامه‌نویسی و استفاده از قابلیت‌های و ابزارهای موجود در نرم‌افزار MATLAB R2011 انجام شد.

نتایج و بحث

استراتژی انتخاب متغیرهای ورودی بهینه

برای تعیین و انتخاب متغیرهای بهینه ورودی به مدل شبکه عصبی مصنوعی از دو روش تحلیل مدل آزاد و روش دوم مبتنی بر نتایج مدل‌سازی استفاده شد. در روش مدل آزاد از تکنیک‌های مبتنی بر سنجش وابستگی هم‌چون تحلیل همبستگی استفاده می‌شود که اقدام به شناسایی متغیرهای ورودی ناهمبسته مستقل و همچنین تعیین مؤثرترین متغیرهای ورودی بر خروجی می‌کند. در روش مبتنی بر تحلیل مدل‌سازی، برای دستیابی به بهترین ترکیب متغیرهای ورودی از شاخص‌های آماری از قبیل شاخص‌های هموارسازی منفرد محاسباتی در طی

شهریور، رطوبت نسبی شهریور، رطوبت نسبی مهر، تبخیر و تعرق شهریور و تبخیر و تعرق مهر. این متغیرها از مجموعه ورودی‌های مدل شبکه عصبی حذف و در نهایت مدل شبکه عصبی برای پیش‌بینی عملکرد زعفران استان خراسان جنوبی با ۱۰ متغیر ورودی دمای حداقل پائیز، دمای حداقل زمستان، تبخیر و تعرق تابستان، دمای حداکثر بهار، دمای حداکثر تابستان، دمای حداکثر پائیز، دمای حداکثر زمستان، بارش بهار، بارش سالیانه، تبخیر و تعرق بهار به‌عنوان مدل بهینه پیش‌بینی عملکرد زعفران استفاده و اقدام به آموزش و ارزیابی و در نهایت تحلیل عدم قطعیت نتایج آن شد.

شیردلی و توسلی (Shirdeli & Tavassoli, 2015) طبق نتایج تحقیقات مشاهده شده است که عملکرد زعفران بیشترین حساسیت را به پارامترهای بارندگی و ساعات آفتابی دارد و مهم‌ترین پارامترها در برآورد عملکرد از طریق شبکه عصبی، بارندگی، دما و رطوبت نسبی هستند به طوری که با حذف این پارامترها از روند پیش‌بینی، تغییرات زیادی در ضرایب همبستگی ایجاد می‌شود (Akbarpour et al., 2015). همچنین بیشترین کارایی مدل ANN در پیش‌بینی عملکرد زعفران را با داده‌های دمای حداکثر، بارندگی، تبخیر-تعرق و رطوبت نسبی به‌دست آمده است (Nekouei et al., 2014).

نتایج مدل شبکه عصبی مصنوعی

در شکل ۲ معماری مدل بهینه انتخابی با ۲ لایه مخفی، در لایه اول ۴ نرون و در لایه دوم ۲ نرون ارائه گردیده است و همچنین در اشکال ۳ و ۴ نتایج مرحله توسعه مدل شبکه عصبی مصنوعی ارائه شده است. در شکل ۳ مشاهده می‌شود که با توجه به معیار توقف بیش برآزش مورد استفاده در آموزش و یادگیری مدل شبکه عصبی مصنوعی، در نهایت بهترین نتایج مربوط به تکرار ۲۱ بود.

همچنین ماه‌های شهریور و مهرماه است. سایر پارامترهای هواشناسی طبق جدول زیر و آزمون احتمال فیشر همبستگی کمتر از ۰/۱ داشتند و از تحلیل‌ها حذف شدند. تعداد ۲۵ پارامتر ذکر شده در بالا به‌عنوان مؤثرترین پارامترها در پیش‌بینی عملکرد زعفران انتخاب شدند و ۱۱ پارامتر دیگر حذف شدند. در مرحله بعدی برای حذف پارامترهای وابسته از متغیرهای ورودی و انتخاب پارامترهای ورودی ناهمبسته از تحلیل شاخص تورم واریانس استفاده شد.

شاخص تورم واریانس به‌صورت زیر محاسبه می‌شود (Kroll & Song, 2013):

$$VIF = \frac{1}{1 - R^2} \quad (4)$$

در این روش همبستگی هر متغیر توضیحی با سایر متغیرهای توضیحی محاسبه شده و در نهایت متغیرهایی که دارای ضریب VIF

بالا هستند به‌عنوان متغیرهای ورودی که همبسته می‌باشند شناخته شده و از فرآیند مدل‌سازی حذف می‌شوند. مقدار آستانه حذف متغیرهای چندخطی ورودی برای VIF عدد ۱۲ است (Kroll & Song, 2013).

در جدول ۳ نتایج محاسبه شاخص VIF برای ۲۵ پارامتر انتخاب شده در تحلیل همبستگی ارائه شده است. بنابراین با توجه به نتایج تحلیل تورم واریانس مشاهده می‌شود که از بین ۲۵ متغیر انتخابی در مرحله تحلیل همبستگی، متغیرهای تابش شهریور با VIF برابر ۱۲۱۳/۹ و تابش مهر با VIF برابر ۱۲۱۹/۱ بیشترین وابستگی را با سایر متغیرهای ورودی دارند و نمی‌توانند به‌عنوان متغیر مستقل وارد مدل پیش‌بینی عملکرد زعفران شوند. به همین طریق سایر متغیرهایی که VIF بزرگ‌تر از ۱۲ به‌عنوان آستانه ناهمبستگی دارند عبارتند از دمای حداقل بهار، دمای حداقل تابستان، دمای حداقل سالیانه، تبخیر-تعرق سالیانه، دمای حداکثر شهریور، دمای حداکثر مهر، بارش

جدول ۲- نتایج تحلیل همبستگی متغیرهای مؤثر بر عملکرد


Table 2- Correlation analysis of effective parameters on yield

ردیف Row	متغیر Variable	همبستگی Correlation	ردیف Row	متغیر Variable	همبستگی Correlation
1	دمای حداقل بهار Tmin-Spring	0.46*	20	تبخیر تعرق سالیانه Et-Total	0.13*
2	دمای حداقل تابستان Tmin-Summer	0.38*	21	رطوبت نسبی بهار RH-Spring	0.005
3	دمای حداقل پائیز Tmin-Autumn	0.36*	22	رطوبت نسبی تابستان RH-Summer	0.003
4	دمای حداقل زمستان Tmin-Winter	0.13*	23	رطوبت نسبی پائیز RH-Autumn	0.04
5	دمای حداقل سالیانه Tmin Total	0.34*	24	رطوبت نسبی زمستان RH-Winter	0.017
6	دمای حداکثر بهار Tmax-Spring	0.49*	25	رطوبت نسبی کل RH-Total	0.008
7	دمای حداکثر تابستان Tmax-Summer	0.27*	26	دمای حداقل شهریور Tmin-Aug-Sep	0.04
8	دمای حداکثر پائیز Tmax-Autumn	0.14*	27	دمای حداقل مهر Tmin-Sep-Oct	0.06
9	دمای حداکثر زمستان Tmax-Winter	0.16*	28	دمای حداکثر شهریور Tmax- Aug-Sep	0.33*
10	دمای حداکثر سالیانه Tmax Total	0.34*	29	دمای حداکثر مهر Tmax- Sep-Oct	0.34*
11	بارش بهار Pr-Spring	0.32*	30	بارش شهریور Pr- Aug-Sep	0.15*
12	بارش تابستان Pr-Summer	0	31	بارش مهر Pr- Sep-Oct	0.14*
13	بارش پائیز Pr-Autumn	0	32	رطوبت نسبی شهریور RH- Aug-Sep	0.13*
14	بارش زمستان Pr-Winter	0.03	33	رطوبت نسبی مهر RH- Sep-Oct	0.12*
15	بارش سالیانه Pr-Total	0.17*	34	تابش شهریور Ra- Aug-Sep	0.11*
16	تبخیر تعرق بهار Et-Spring	0.17*	35	تابش مهر Ra- Sep-Oct	0.12*
17	تبخیر تعرق تابستان Et-Summer	0.13*	36	تبخیر تعرق شهریور ET- Aug-Sep	0.14*
18	تبخیر تعرق پائیز Et-Autumn	0.009	37	تبخیر تعرق مهر ET- Sep-Oct	0.16*
19	تبخیر تعرق زمستان Et-Winter	0.04			


جدول ۳- نتایج تحلیل تورم واریانس متغیرهای مؤثر

Table 3- VIF analysis of effective parameters

ردیف Row	متغیر Variable	تورم واریانس VIF	ردیف Row	متغیر Variable	VIF
1	دمای حداقل بهار Tmin-Spring	139.9	14	تبخیر تعرق تابستان Et-Summer	3.5
2	دمای حداقل تابستان Tmin-Summer	116.1	15	تبخیر تعرق سالیانه Et-Total	820.3
3	دمای حداقل پائیز Tmin-Autumn	5.8	16	دمای حداکثر شهریور Tmax- Aug-Sep	48.8
4	دمای حداقل زمستان Tmin-Winter	4.33	17	دمای حداکثر مهر Tmax- Sep-Oct	657.9
5	دمای حداقل سالیانه Tmin Total	644.3	18	بارش شهریور Pr- Aug-Sep	613.9
6	دمای حداکثر بهار Tmax-Spring	10.7	19	بارش مهر Pr- Sep-Oct	650.2
7	دمای حداکثر تابستان Tmax-Summer	11.9	20	رطوبت نسبی شهریور RH- Aug-Sep	57.7
8	دمای حداکثر پائیز Tmax-Autumn	5.3	21	رطوبت نسبی مهر RH- Sep-Oct	60.4
9	دمای حداکثر زمستان Tmax-Winter	7.5	22	تابش شهریور Ra- Aug-Sep	1213.9
10	دمای حداکثر سالیانه Tmax Total	47	23	تابش مهر Ra- Sep-Oct	1219.1
11	بارش بهار Pr-Spring	2.2	24	تبخیر تعرق شهریور ET- Aug-Sep	371.7
12	بارش سالیانه Pr-Total	2.6	25	تبخیر تعرق مهر ET- Sep-Oct	144.4
13	تبخیر تعرق بهار Et-Spring	3.9			



شکل ۲- معماری و لایه‌های مدل نهایی
Figure 2- Structure and ANN model layers



شکل ۳- روند تغییرات خطا و همگرایی مدل شبکه عصبی
Figure 3- Error trend in ANN model.

مصنوعی به ترتیب در مرحله آموزش و آزمایش ارائه شده است و مجدداً دقت مطلوب مدل شبکه عصبی مصنوعی در برآورد مقادیر حداکثر و حداقل عملکرد زعفران تأیید شد. مقادیر پارمترهای MAE و RMSE مدل شبکه عصبی مصنوعی در مرحله یادگیری برابر $0/3$ و $0/5$ و در مرحله آزمایش به ترتیب $0/7$ و 1 بود. در تحقیق شیردلی و توسلی (Shirdeli & Tavassoli, 2015) پیش‌بینی عملکرد زعفران با ساختار ۲ لایه پنهان و ۸ نرون انجام گردید و حصول مقادیر پارمترهای ضریب تبیین، RMSE و MSE به ترتیب برابر با $0/97$ ، $2/78$ درصد و

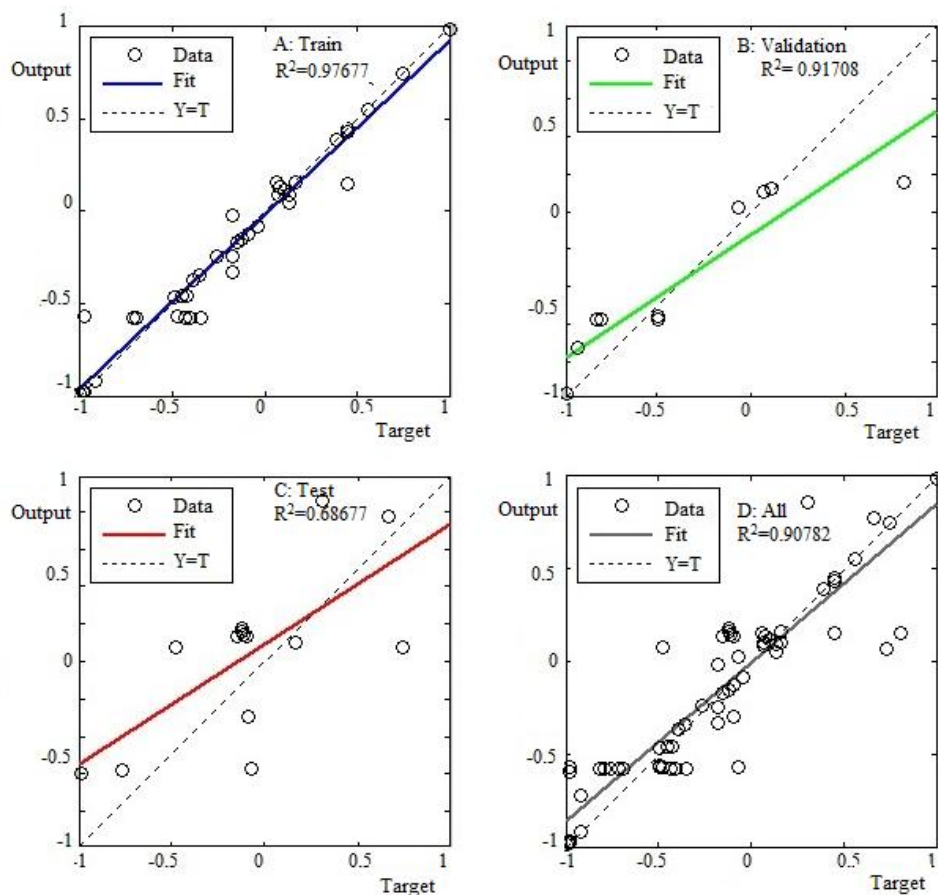
که ضرایب این تکرار در پیش‌بینی‌ها استفاده شدند. طبق نتایج در شکل ۴ مشاهده می‌شود که مدل بهینه طراحی شده در مراحل مختلف آموزش، آزمایش و ارزیابی دقت مطلوبی در پیش‌بینی عملکرد زعفران بر اساس مؤثرترین پارامترهای هواشناسی غیرمستقل داشته است که با استفاده از آن می‌توان به سهولت و براساس پارامترهای هواشناسی سهل‌الوصول عملکرد محصول زراعی زعفران را پیش‌بینی نمود. همچنین در شکل- ۵ و ۶ نیز نتایج با مقایسه مقادیر پیش‌بینی و مقادیر مشاهداتی عملکرد زعفران به همراه خطای مدل شبکه عصبی

مختلف یادگیری، ارزیابی و آزمایش تأیید شد. در این قسمت نتایج تحلیل عدم قطعیت مدل طراحی شده با رویکرد شبیه-سازی مونت کارلو و نمونه‌گیری ۱۰۰۰ مرتبه بدون جایگذاری ارائه شده است. در این مرحله انتخاب و آموزش مدل شبکه عصبی مصنوعی با معماری بهینه طراحی شده در مرحله قبل به صورت تصادفی و خودکار با نمونه‌گیری ۱۰۰۰ مرتبه بدون جایگذاری انجام شده است.

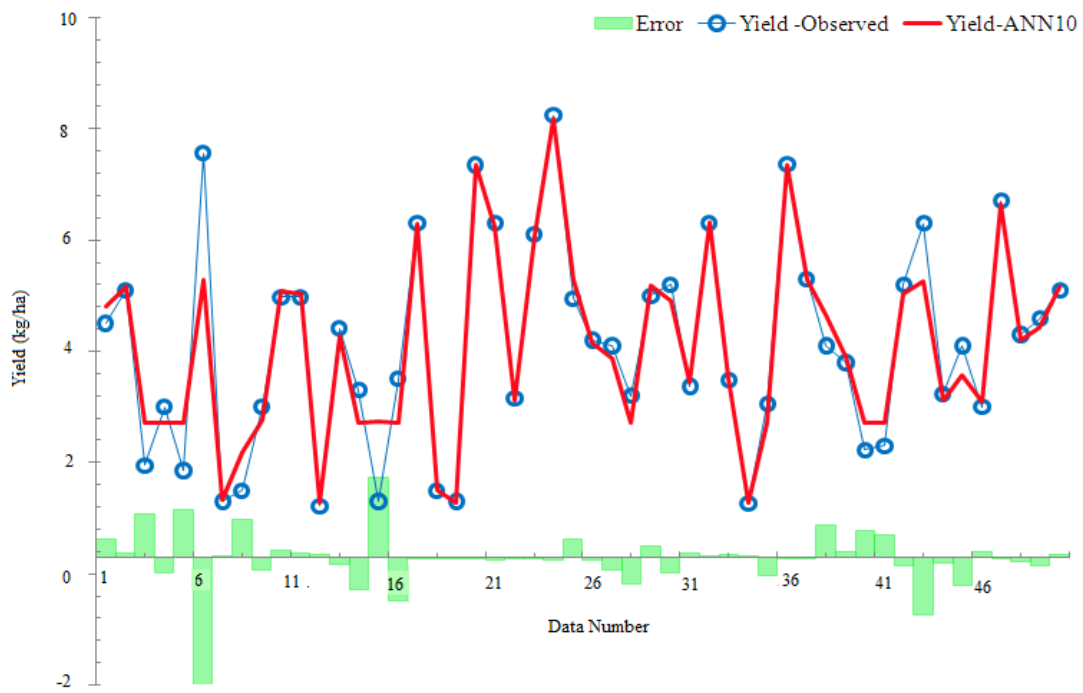
۰/۰۰۴ دلیلی بر توانایی مدل شبکه عصبی مصنوعی در پیش-بینی عملکرد بیان شد.

نتایج تحلیل عدم قطعیت

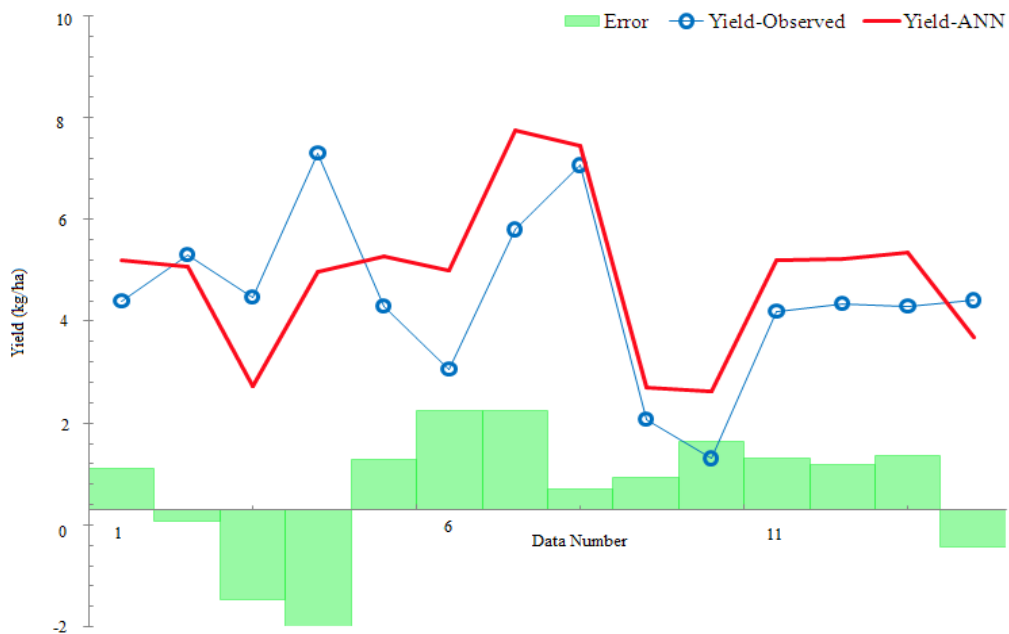
در قسمت قبلی نتایج مدل شبکه عصبی مصنوعی در پیش-بینی عملکرد زعفران براساس استراتژی انتخاب متغیرهای ورودی مستقل غیرهمبسته ارائه شد و دقت آن در مراحل



شکل ۴- نتایج مدل شبکه عصبی مصنوعی در مراحل مختلف. الف) آموزش، ب) آزمایش، ج) ارزیابی، ج) برای کلیه داده‌ها
Figure 4 -ANN model results in A) train, B) test, C) verification stage and D) All.



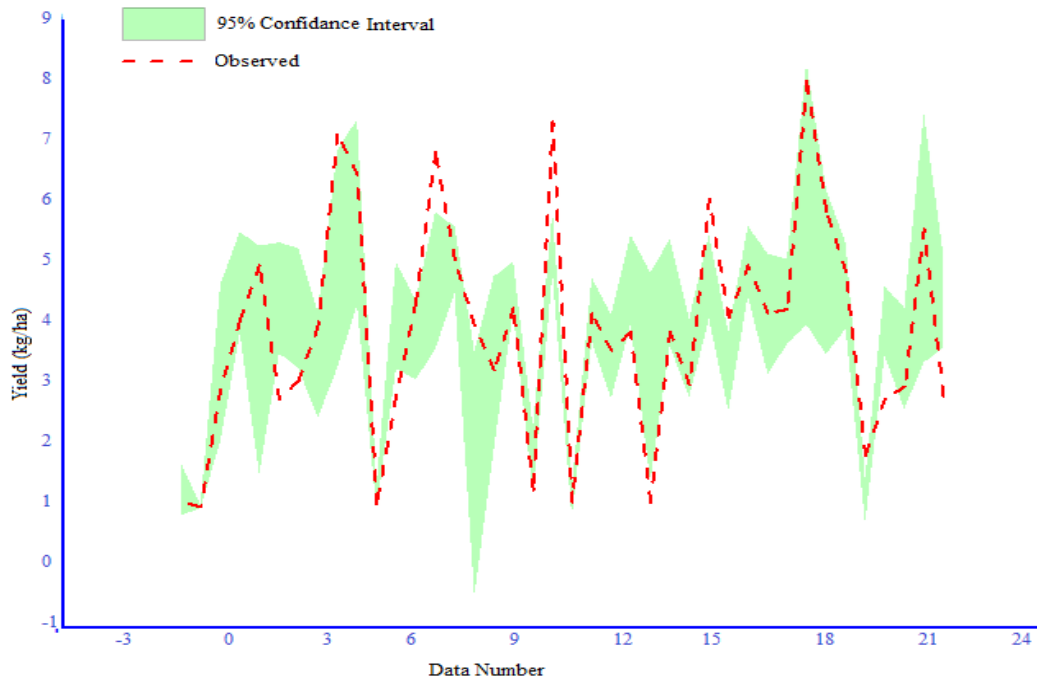
شکل ۵- روند پیش بینی‌ها و خطای مدل شبکه عصبی در مرحله یادگیری
 Figure 5- Prediction trends and error of ANN in train stage.




شکل ۶- روند پیش بینی‌ها و خطای مدل شبکه عصبی در مرحله آزمایش
 Figure 6- Prediction trends and error of ANN in test stage.

مصنوعی در باند اطمینان ۹۵٪ حاصله از ۱۰۰۰ شبیه‌سازی مونت کارلو قرار می‌گیرند. حدود ۳۸٪ پیش‌بینی‌های مدل شبکه عصبی که خصوصاً برای مقادیر حدی حداکثر و حداقل است خارج از باند اطمینان ۹۵٪ پیش‌بینی‌ها قرار دارند و بنابراین در شرایطی احتمال رخداد عملکردهای خارج از محدوده پیش‌بینی مدل شبکه عصبی مصنوعی وجود دارد. همچنین عرض باند اطمینان عدم قطعیت در مرحله آموزش ۰/۶ و در مرحله آزمایش ۰/۹۹ به دست آمد که به علت اینکه عرض آن از ۱ کمتر است از مطلوبیت خوبی برخوردار است و مقادیر d-factor عدم قطعیت در محدوده قابل قبول قرار دارند. همچنین متوسط ضریب R^2 مدل در مرحله آموزش و آزمایش براساس ۱۰۰۰ شبیه‌سازی مونت کارلو به ترتیب ۰/۹۲ و ۰/۵۸ بود که برای مدل‌های عملکرد گیاهی مبتنی بر داده‌های اقلیمی دارای معنی-داری در سطح ۹۹٪ است. طبق نتایج این تحقیق ملاحظه می‌شود که مدل شبکه عصبی مصنوعی در صورتی که متغیرهای ورودی آن بر اساس استراتژی‌های مطلوبی انتخاب شوند، به صورتی که هم مؤثرترین متغیرها بر عملکرد زعفران انتخاب شوند و هم متغیرهای انتخابی ناهمبسته باشند، دقت مطلوبی در پیش‌بینی‌ها براساس اطلاعات کاربردی دارد و محدوده عدم قطعیت نتایج آن نیز قابل‌پذیرش است. هرچند در مواقعی که عملکرد به مقادیر مرزی و حدی خود در سمت حداکثر یا حداقل‌ها می‌رسد، مدل شبکه عصبی علیرغم توانایی مطلوب در پیش‌بینی روند و الگوی کلی و عمومی تغییرات عملکرد زعفران، دچار عدم قطعیت‌های محسوسی خواهد شد که این مسئله نشان‌دهنده شدت حساسیت عملکرد زراعی گیاه زعفران به مدیریت تغذیه و کودی خاک می‌باشد. بنابراین لازم است در مدل‌های پیش‌بینی عملکرد زراعی به شرایط رطوبتی، تغذیه و کودی خاک نیز توجه شود و اطلاعات و پارامترهای معرف مربوطه مستندسازی شده و وارد مدل‌های پیش‌بینی شوند تا قابلیت و قطعیت مدل‌های هوشمند را افزایش داد.

نظارت بر آموزش در مدل شبکه عصبی به صورت توقف آموزش پس از افزایش خطای اطلاعات نظارتی اعمال شده است. حداکثر تعداد تکرار الگوریتم آموزش برای تصحیح پارامترها در شبکه عصبی ۳۰۰ و خطای هدف مدل ۴-۱۰ قرار داده شد و ساختار بهینه مدل که در مرحله قبل طراحی شده بود، انتخاب گردید. عدم قطعیت و وجود نا اطمینانی در برآوردها از مشخصات جدائی‌ناپذیر در ساختار مدل‌های پیش‌بینی، داده‌های ورودی و پارامترهای مدل است. به همین دلیل تخمین پارامترهای مدل یا واسنجی به خصوص در برخی مدل‌هایی که روابط بین پارامترهای آن‌ها به شدت غیرخطی است، همانند مدل‌های شبکه‌های عصبی مصنوعی که یکی از مهم‌ترین پارامترهای عدم قطعیت ساختاری آن‌ها مربوط به وزن اتصالات و ضرایب اریبی در ساختار نرون‌ها است و به سادگی تعیین مقادیر بهینه وزن‌ها امکان‌پذیر نبوده و یافتن یک مجموعه پارامتر بهینه ممکن نیست. استفاده از روش‌های تحلیل عدم قطعیت و شبیه‌سازی مونت کارلو بدون جای‌گذاری در شبکه‌های عصبی مصنوعی این امکان را فراهم می‌کند که بتوان اطلاعات بیشتری در مورد خروجی‌های مدل پیش‌بینی تحت شرایط آموزشی مختلف به دست آورد و خطاهای موجود در مدل‌سازی را به صورت بازه‌های اطمینان ارائه نمود (شفیعی و همکاران، ۲۰۱۴). در این تحقیق عدم قطعیت فرآیند یادگیری و بهینه‌سازی وزن‌ها در پیش‌بینی‌های عملکرد زعفران مبتنی بر پارامترهای هواشناسی با محاسبات حدود اطمینان و عرض باندها تعیین شد. حدود اطمینان ۹۵٪ برای پیش‌بینی عملکرد مدل شبکه عصبی مصنوعی از طریق تعیین مقادیر ۲/۵٪ و ۹۷/۵٪ توزیع احتمالاتی تجربی به دست آمده، مشخص گردید. حدود اطمینان ۹۵٪ مدل پیش‌بینی شبکه عصبی مربوط به مراحل آموزش و ارزیابی به ترتیب در شکل‌های ۷ و ۸ و شاخص‌های عدم قطعیت در جدول ۴ ارائه شده‌اند. مطابق نتایج عدم قطعیت ملاحظه می‌شود که در مرحله آموزش ۶۵٪ و در مرحله آزمایش ۶۲/۵٪ پیش‌بینی‌های مدل شبکه عصبی



شکل ۷- عرض باند اطمینان ۹۵ درصد در مرحله یادگیری مونت کارلو مدل شبکه عصبی
 Figure 7- 95% confidence bounds in train of ANN by Monte Carlo.



شکل ۸- عرض باند اطمینان ۹۵ درصد در مرحله آزمایش و ارزیابی مونت کارلو مدل شبکه عصبی
 Figure 8- 95% confidence bounds in test and verification of ANN by Monte Carlo.

جدول ۴- نتایج تحلیل عدم قطعیت مدل شبکه عصبی مصنوعی
Table 4- Uncertainty analysis results of ANN model

پارامتر Parameter	مرحله یادگیری Train	مرحله آزمایش و ارزیابی Test and verification
Bracketed by 95 PPU(%) درصد داده‌های در باند اطمینان ۹۵% d-factor فاکتور پهنای باند R ² over 1000 simulation ضریب تعیین در ۱۰۰۰ شبیه‌سازی	65 0.6 0.92	62.5 0.99 0.58

نتیجه‌گیری

امروزه زعفران به‌عنوان یکی از محصولات استراتژیک کشور ایران در شرایط بحران آب و خشکسالی‌های متوالی نقش خود را در مزیت نسبی صادراتی و توان رقابتی به‌خوبی نشان داده است. با توجه به این که یکی از وظایف مهم متخصصان اقتصادی پس از بررسی شرایط روزمره و تحلیل این شرایط، پیش‌بینی شرایط آینده می‌باشد، این مسئله لزوم بررسی وضعیت گیاه زعفران را در شرایط آینده فراهم می‌کند تا سیاست‌گذاران علاوه بر ارایه راهکارها و سیاست‌های مناسب در این راستا توان رقابتی این گیاه را در بازارهای جهانی حفظ کرده و توسعه داده و آن را به یکی از نقاط قوت بخش کشاورزی تبدیل کنند. به‌همین دلیل در این تحقیق قابلیت‌های مدل شبکه عصبی مصنوعی در پیش‌بینی عملکرد زعفران در استان خراسان جنوبی براساس داده‌های اقلیمی مورد بررسی قرار گرفته است. انتخاب ۱۱ متغیر ورودی بهینه از بین مجموعه ۳۷ متغیر مختلف هواشناسی، براساس دو استراتژی تحلیل همبستگی و تورم واریانس انجام شد. سپس مدل بهینه با معماری ۱-۲-۴-۱۱ با تابع فعال‌سازی سیگموئید شناسایی گردید. نتایج مدل، علیرغم محدود بودن تعداد داده‌های در دسترس بیان‌گر دقت مطلوب آن در پیش‌بینی عملکرد در سه مرحله یادگیری، ارزیابی و آزمایش بود. در مرحله بعدی تحلیل

عدم قطعیت با شبیه‌سازی مونت کارلو بدون جایگذاری برای ۱۰۰۰ مرتبه انجام شد. نتایج این مرحله نشان دادند که عدم قطعیت در یک برآورد عملکرد زعفران به‌طور یکنواخت در طول دامنه محاسباتی توزیع شده نیست و در محدوده و باند تغییرات متغیرهای مؤثر بر عملکرد، مناطق مستعد ابتلا به عدم اطمینان بالاتر یا پایین‌تر وجود دارد. با این حال عدم قطعیت مدل در حالت کلی و عمومی مطلوب بوده و نتایج شبیه‌سازی‌ها بیان‌گر کارآئی مدل شبکه عصبی مصنوعی در تخمین عملکرد گیاه زعفران براساس پارامترهای اقلیمی است. روش‌شناسی انجام این تحقیق به نحو مطلوبی بحث عدم قطعیت را در مدل‌های گیاهی مبتنی بر ANN وارد نموده و با توجه به نتایج مناسب و منطقی به‌دست آمده، استفاده از این روش در تحقیقات مشابه توصیه می‌شود. مطالعات انجام‌شده در این پژوهش می‌تواند مکمل طرح‌های تحقیقاتی پیش‌بینی در صنعت کشت و برداشت زعفران کشور باشد. به‌طوری‌که برنامه‌ریزان به‌جای مواجهه به یک رقم به‌عنوان پیش‌بینی، ترکیب این رقم و باند اطمینان را در اختیار داشته و می‌توانند تصمیمات واقع‌بینانه‌تری اتخاذ نمایند.

منابع

- Abbaspour, K.C., Yang, J., Maximov, I., Siber, R., Bogner, K., Mieleitner, J., Zobrist, J., and Srinivasan, R. 2007. Modelling hydrology and water quality in the pre-alpine/alpine Thur watershed using SWAT. *Journal of Hydrology* 333 (2): 413-430.
- Adams, R.M., AKA, C., McCarl, B.A., and Schimmelpfennig, D. 2001. Climate variability and climate change: implications for agriculture. *Advances in the Economics of Environmental Resources* 3: 115-148.
- Akbarpour, A., Khorashadizadeh, O., Shahidi, A., and 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).
- Akrami, M.R., Malakouti, M.J., and Keshavarz, P. 2014. Study of flower and stigma yield of saffron as affected by potassium and zinc fertilizers in Khorasan Razavi Province. *Journal of Saffron Research* 2 (1): 85-96. (In Persian with English Summary).
- Aqil, M., Kita, I., Yano, A., and Nishiyama, S. 2007. A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff. *Journal of Hydrology* 337 (1): 22-34.
- Alvarez, R. 2009. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *European Journal of Agronomy* 30 (2): 70-77.
- Behdani, M.A., Koocheki, A.R., Nassiri Mahallati, M., and Rezvani Moghaddam, P. 2005. Evaluating the relationships between revenue and consumption of nutrients in *Crocus sativus*. *Iranian Journal of Field Crops Research* 3 (1): 1-14. (In Persian with English Summary).
- Bowden, G.J., Dandy, G.C., and Maier, H.R. 2005. Input determination for neural network models in water resources applications. Part 1—background and methodology. *Journal of Hydrology* 301 (1): 75-92.
- Dai, X., Huo, Z., and Wang, H. 2011. Simulation for response of crop yield to soil moisture and salinity with artificial neural network. *Field Crops Research* 121 (3): 441-449.
- Khazaei, J., Naghavi, M.R., Jahansouz, M.R., and Salimi Khorshidi, G. 2008. Yield estimation and clustering of chickpea genotypes using soft computing techniques. *Agronomy Journal* 100 (4): 1077-1087.
- Koocheki, A. 2014. Research on production of saffron in Iran: Past trend and future prospects. *Saffron Agronomy and Technology* 1 (1): 3-21. (In Persian with English Summary).
- Kroll, C.N., and Song, P. 2013. Impact of multicollinearity on small sample hydrologic regression models. *Water Resources Research* 49 (6): 3756-3769.
- Maier, H.R., and Dandy, G.C. 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental modelling and software* 15 (1): 101-124.
- Marce, R., Comerma, M., García, J.C., and Armengol, J. 2004. A neuro-fuzzy modeling tool to estimate fluvial nutrient loads in watersheds under time-varying human impact. *Limnology and Oceanography: Methods* 2 (11): 342-355.
- 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. (In Persian with English Summary).
- Norouzi, M., Ayoubi, S., Jalalian, A., Khademi,

- H., and Dehghani, A.A. 2010. Predicting rainfed wheat quality and quantity by artificial neural network using terrain and soil characteristics. *Acta Agriculturae Scandinavica Section B–Soil and Plant Science* 60 (4): 341-352.
- Norouzi, M., Ayyoubi, Sh., Jalalian, A., and Khadami, H. 2008. Performance assement of ANN in prediction of wheat yield using DEM model. In 2th Fuzzy and intelligence conference. Mashhad, Iran, 28-30 November 2008, p. 112-119. (In Persian).
- Pasandi, A.A., Shirchi, Y., and Ebrahimi, S. 2015. Energy predicyion in potato production using ANN and fuzzy. In 9th conference in agricultural machines, Tehran, Iran, 2-3 May 2015. (In Persian).
- Rahmani, A., Khalili, A., and Liyaghat, A. 2008. Quantitative survey of drought effects on barley yield in east Azerbaijan by multiple regression method. *Journal of Science and Technology of Agriculture and Natural Resources* 44: 25-36. (In Persian).
- Riahi, H., Ayyoubzadeh, S.A., Namin, M.M., and Seifi, A. 2011. Uncertainty analysis of quasi-two-dimensional flow simulation in compound channels with overbank flows. *Journal of Hydrology and Hydromechanics* 59 (3): 171–183.
- Sadeghi, B. 2012. Effect of corm weight on Saffron (*Crocus sativus* L.) flowering (Research II). In 4th international saffron symposium. Kashmir, India, 22-25 October 2012.
- Sanaeinejad, S.H., Salajegheh, M., Hosseini, S.N., and Araghizadeh, M. 2010. The effects of weather on saffron yield in southern Khorasan province by experimental method. In First International Conference on Plant, Water, Soil and Weather Modeling. Kerman, Iran, 14-15 November 2010. (In Persian with English Summary).
- Sanjhkumar, N., and Thandaveswara, B.S. 1999. A non-linear rainfall-runoff model using an artificial neural network. *Journal of Hydrology* 216 (1): 32-55.
- Shabani, A., Haghnia, G.H., Karimi, A., and Ahmadi, M.M. 2011. Prediction on wheat yield using ANN in Sisab zone of North Khorasan. In 12th soil congers of Iran. Tabriz, Iran, 09-12 March 2011. (In Persian).
- Shafiei, M., Ansari, H., Davari, K., and Ghahreman, B. 2013. Calibration and uncertainty analysis of a semi-distributed model of soil water in a semi arid region. *Water and Soil Science Journal* 17 (44): 137-149. (In Persian with English Summary).
- Shirdeli, A., and Tavassoli, A. 2015. Predicting yield and water use efficiency in saffron using models of artificial neural network based on climate factors and water. *Saffron Agronomy and Technology* 3 (2): 121-131. (In Persian with English Summary).
- Tibshirani, R. 1994. A comparison of some error estimates for neural network models. *Neural Computation* 8 (1): 152-163.

Accuracy and uncertainty analysis of artificial neural network in predicting saffron yield in the south Khorasan province based on meteorological data

Hossien Riahi Modavar^{1*}, *Abbas Khashei Siuki*² and *Akram Seifi*¹

Submitted: 29 July, 2015

Accepted: 11 February, 2016

Riahi Modavar, H., Khashei-Siuki, A., and Seifi, A. 2017. Accuracy and uncertainty analysis of artificial neural network in predicting saffron yield in the south Khorasan province based on meteorological data. *Saffron Agronomy & Technology* 5(3): 255-271.

Abstract

Because of saffron yield sensitivity and the effects of climate on its performance, and also due to the nonlinear nature of crop yield functions, the Artificial Neural Network (ANN) model is employed in this study for prediction and uncertainty analysis of saffron yield in the South Khorasan province based on 20 years of data. The input vector of the ANN model was optimized from 37 parameters through correlation and variance inflation. The optimum architecture of the model was derived as 1-2-4-11 with a sigmoidal activation function based on the results at three stages of training, testing and verification. The root mean square error (RMSE) and mean absolute error (MAE) were equal to 0.3 and 0.5 in the training step and 0.7 and 1 in the test step, respectively. These results indicate that the ANN is a suitable model for predicting saffron yield. Uncertainty analysis based on R², d-factor and 95%PPU showed that despite use of inadequate data, model prediction showed acceptable prediction bounds and predicted a satisfactorily saffron yield trend. The R² values were equal to 0.92 and 0.58 in the training and test steps, respectively, which are statistically significant at the P<0.01 level. However, the model results under extreme values of max-min yield values indicated partial uncertainties which highlight the necessity of considering soil, fertility and water management parameters in the ANN model input vector. Overall, this study indicated that decision makers and agricultural developers should consider confidence intervals in the prediction in order to make more realistic policies instead of using unique yield value. Also, it can be concluded that the Monte-Carlo uncertainty analysis combined with artificial neural network can provide uncertainty bounds for black box prediction models and it can be used for more realistic decision making.

Keywords: Artificial Neural Network, Climatological Data, Saffron Yield, Uncertainty Analysis.

1 - Assistant Professor of Water Engineering, Vali-e-asr University of Rafsanjan, Iran

2- Associated Professor of Water engineering, Dpt. University of Birjand, Iran

(*-Corresponding Author Email: h.riahi@vru.ac.ir)

DOI: 10.22048/jsat.2017.31901.1100