



پیش‌بینی عملکرد و کارآیی مصرف آب زعفران با استفاده از مدل‌های شبکه عصبی مصنوعی بر مبنای فاکتورهای اقلیمی و آب

عظیم شیردلی^{۱*} و ابوالفضل توسلی^۲

تاریخ پذیرش: ۱۶ خرداد ۱۳۹۴

تاریخ دریافت: ۱۲ اسفند ۱۳۹۳

چکیده

با پدید آمدن تکنیک‌های آماری قوی و شبکه‌های عصبی، مدل‌های پیش‌بینی کننده عملکرد محصولات زراعی به سرعت رو به توسعه است. بدین منظور آزمایشی در منطقه تربت حیدریه با هدف پیش‌بینی عملکرد و کارآیی مصرف آب زعفران با استفاده از مدل شبکه عصبی مصنوعی انجام گرفت. واسنجی و اعتباریابی مدل‌ها نیز با استفاده از آمار عملکرد محصول و پارامترهای اقلیمی سال ۹۱-۱۳۹۰ صورت پذیرفت. ارزیابی مدل‌ها نیز با شاخص‌های آماری ضریب تبیین (R²)، جذر میانگین مربعات خطا نرمال شده (RMSEn) و میانگین مربعات خطا (MSE) انجام شد. نتایج تحقیق نشان داد که شبکه عصبی پیشنهادی (مدل شماره ۹) با داشتن ۲ لایه پنهان، ۸ نورون و ضریب تبیین ۰/۹۷ برای عملکرد و ۱ لایه پنهان، ۷ نورون و ضریب تبیین ۰/۹۰ برای کارآیی مصرف آب، برازش خوبی برای این دو صفت داشت. همچنین مطابق با شاخص‌های آماری RMSEn و MSE در مدل پیشنهادی (مدل شماره ۹) که به ترتیب برابر بود با ۲/۷۸ درصد و ۰/۰۴۰ برای عملکرد و ۵/۴۱ درصد و ۰/۰۷۳ برای کارآیی مصرف آب، بالاترین دقت برای پیش‌بینی صفات فوق مشاهده شد. تحلیل حساسیت مدل‌ها نیز نشان داد که عملکرد و کارآیی مصرف آب محصول زعفران، بیشترین حساسیت را به عامل آبیاری، سپس بارندگی و در نهایت ساعات آفتابی دارد. به‌طور کلی، کاربرد شبکه عصبی پیشنهادی در این تحقیق می‌تواند زمینه ارتقاء محصول زعفران را در منطقه تربت فراهم نماید.

کلمات کلیدی: تربت حیدریه، شبیه‌سازی، کالاه، مدل.

مقدمه

نوبت کاشت، سازگاری بالا، بازار فروش داخلی و خارجی مناسب، آن را به‌عنوان انتخاب نخست کشاورزان در شهرهای دارای بازار مناسب مطرح کرده است (Daneshvar Kakhki & Farahmand Gelyan, 2012). به‌طوری‌که در کشور سطح زیر کشت زعفران در سال ۱۳۹۰ بالغ بر ۷۲۱۶۲ هکتار گزارش شده است که بیش از ۷۰۰۰۰ هکتار آن در دو استان خراسان رضوی و جنوبی (۵۷۰۰۰ هکتار خراسان رضوی و ۱۳۰۰۰ هکتار

زعفران (*Crocus sativus* L.) گیاهی دارویی است که در ایران از قدمت چندین هزارساله برخوردار می‌باشد. ویژگی‌های خاص این محصول از جمله امکان بهره‌برداری چندساله در یک

۱- استادیار گروه آبیاری، دانشکده کشاورزی، دانشگاه زنجان، ایران.

۲- استادیار گروه کشاورزی، دانشگاه پیام نور، ایران.

(Abolfazl202060@yahoo.com)

*- نویسنده مسئول:

مستقیم از روی داده‌ها، بدون نیاز برآورد مشخصات آماری آن‌هاست (Vakil-Baghmisheh, 2002). شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (Torrecilla et al., 2004). ویژگی دیگر شبکه عصبی تحمل‌پذیری در مقابل خطا می‌باشد (Azadeh et al., 2006). شبکه‌های عصبی شامل تعدادی نرون‌های متصل به هم هستند. مراحل اصلی حل هر مسئله توسط شبکه عصبی شامل آموزش و آزمایش می‌باشد (Gupta et al., 2003). امروزه از این تکنیک می‌توان در پیش‌بینی عملکرد (Drummond et al., 2003) و کارایی مصرف آب گیاهان (Montazer et al., 2009) با دقت بسیار بالا استفاده نمود.

با توجه به جایگاه ویژه زعفران به‌عنوان یک گیاه زراعی و اقتصادی مهم، مدل‌سازی عملکرد این گیاه و تعیین عوامل مؤثر بر رشد آن از اهمیت بالایی برخوردار است. یکی از روش‌های مدل‌سازی که در سال‌های اخیر مورد توجه بسیاری از محققین به‌منظور تخمین عملکرد واقع شده است، مدل‌سازی به روش شبکه عصبی مصنوعی می‌باشد. آلوارز (Alvarez, 2009) شبکه‌های عصبی مصنوعی را جهت تعیین بازده گیاه گندم در منطقه پامپاس آرژانتین به کار برد. وی نسبت بارندگی به تبخیر-تعرق پتانسیل محصول (R/CPET) را به‌عنوان مهم‌ترین فاکتور آب و هوایی مؤثر بر بازده این محصول معرفی نمود. کول و همکاران (Kaul et al., 2005) از قابلیت شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد ذرت و سویا در منطقه مریلند استفاده نموده و بیان کردند که مدل شبکه عصبی مصنوعی در مقایسه با مدل‌های رگرسیونی دارای دقت بالاتری می‌باشد. آن‌ها از پارامترهای میزان بارندگی و خصوصیات خاک به‌عنوان

خراسان جنوبی) بوده است (Jehade Keshavari Khorasan Razavi, 2012). مقدار تولید زعفران در سال ۱۳۹۰ در کل کشور ۲۵۴ تن گزارش شده که در سال ۱۳۹۱، ۱۳۳/۵ تن آن به ارزش ۴۰۵ میلیون دلار صادر شده است (Koocheki, 2013). یکی از فاکتورهای اصلی در زراعت مطلوب زعفران در مناطق تحت کشت تأمین آب آبیاری در مواقع نیاز این محصول است (Behdani et al., 2008). آب به‌عنوان مهم‌ترین نهاده در تولید محصولات کشاورزی محسوب می‌شود و از این‌رو کمبود آب عمده‌ترین عامل بازدارنده توسعه زراعت آبی محسوب می‌شود. با توجه به بحران فزاینده مرتب بر کیفیت منابع آبی در ایران و جهان، انتخاب استراتژی‌های مناسب به‌منظور بیشینه کردن میزان بهره‌وری آب برای محصولات تولیدی ضروری است (Behdani et al., 2008).

زعفران نسبت به سایر گیاهان به دلیل نیاز به آب کم و آبیاری آن در زمان‌های غیر بحرانی، از کارایی مصرف آب بالاتری برخوردار است. به‌طوری‌که صادقی (Sadeghi, 2013) کارایی^۱ و بهره‌وری^۲ مصرف آب برای چند محصول مهم در مقایسه با زعفران را به ترتیب چنین محاسبه کرده است. گندم ۰/۷ کیلوگرم (به ازای هر مترمکعب آب مصرفی) و ۲۷۴۳ ریال (در هر متر مکعب آب مصرفی)، چغندر قند ۲/۵ کیلوگرم و ۲۴۴۵ ریال، پنبه ۰/۲۳ کیلوگرم و ۲۸۶۶ ریال، سیب‌زمینی ۱/۴ کیلوگرم و ۴۱۲۰ ریال، سیب‌درختی ۱ کیلوگرم و ۹۴۵۲ ریال و زعفران ۱/۲۵ کیلوگرم و ۲۴۵۰۰ ریال؛ بدین ترتیب هر مترمکعب آب در زعفران ۹ برابر گندم، ۱۰ برابر چغندر قند، ۶ برابر سیب‌زمینی و ۲/۵ برابر سیب‌درختی درآمد حاصل می‌نماید. امروزه از شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله پیش‌بینی و مدل‌سازی فرایندها در علوم مختلف می‌توان استفاده کرد (Veelenturf, 1995). مزیت روش شبکه عصبی یادگیری

۱- کارایی: عملکرد بر حسب کیلوگرم به ازای هر مترمکعب آب مصرفی.

۲- بهره‌وری: عملکرد بر حسب ریال در هر مترمکعب آب مصرفی.

مشهد، نیشابور و فریمان از شمال و با شهرستان‌های خواف و گناباد از جنوب هم‌جوار می‌باشد. آب و هوای این شهرستان نیمه بیابانی است (Rahimi et al., 2007). منطقه تربت‌حیدریه بزرگ‌ترین تولیدکننده زعفران در جهان محسوب می‌شود (Rahimi et al., 2007). لذا تحقیقات در زمینه زعفران در این شهرستان امری ضروری است. به طوری که در این مطالعه سعی شد به بررسی تخمین عملکرد و کارایی مصرف آب زعفران با استفاده از مدل شبکه عصبی مصنوعی پرداخته شود.

از شبکه عصبی با ساختار پرسپترون سه لایه^۱ (MLP) در این پژوهش استفاده شد. لایه ورودی فقط اطلاعات را دریافت کرده و مشابه متغیر مستقل عمل می‌کند، بنابراین تعداد نرون‌های لایه ورودی بر اساس طبیعت مسئله تعیین می‌شود و بستگی به تعداد متغیرهای مستقل دارد. لایه خروجی نیز همانند متغیر وابسته عمل نموده و تعداد نرون‌های آن بستگی به تعداد متغیر وابسته دارد؛ اما بر خلاف لایه‌های ورودی و خروجی، لایه پنهان بیانگر هیچ مفهومی نمی‌باشد، بلکه وظیفه تنظیم وزن‌ها و یادگیری را بر عهده داشته و تنها یک نتیجه میانی در فرآیند محاسبه ارزش خروجی می‌باشد (Montazer et al., 2009).

عامل‌های لایه ورودی، تلفیقی از عوامل اقلیمی شامل دمای حداقل (Tmin)، حداکثر (Tmax) و میانگین (Tmean) هوا، میانگین رطوبت نسبی (RH)، میزان تشعشع خورشیدی (ساعات آفتابی) (S) و بارندگی (R) هر یک از ماه‌های فصل رشد و مقدار آب مصرفی در طول فصل رشد (آب آبیاری) (I) بودند. به این ترتیب مدل‌های شبکه عصبی در قالب ترکیب‌های متفاوتی از ۶۱ عامل ورودی فوق طراحی و ارزیابی شدند. در جدول ۱ مدل‌های شبکه عصبی مورد مطالعه ارائه شده است.

در این تحقیق، ساختار شبکه با افزودن یا کاستن تعداد نرون‌ها در لایه‌های میانی، تغییر تابع محرک، تغییر حدس‌های اولیه عامل‌های شبکه و تعداد سیکل‌های آموزش تغییر یافت.

ورودی‌های مدل استفاده کردند و دریافتند که بارندگی در ماه‌های ژوئن تا اوت دارای اهمیت بیشتری می‌باشد و به همین دلیل بهتر است که آمار بارندگی در این ماه‌ها به صورت هفتگی به مدل معرفی گردد. مطالعات در ایران نیز حاکی از دقت بالای این مدل در پیش‌بینی محصولات زراعی دارد. نوروزی (Norouzi, 2009) از شبکه‌های عصبی مصنوعی به منظور پیش‌بینی عملکرد گندم در مناطق نیمه‌خشک و کوهستانی غرب ایران استفاده نمودند و بیان داشتند که شاخص انتقال رسوب مهم‌ترین عامل توپوگرافی بر میزان عملکرد این گیاه بوده است. مطالعاتی نیز توسط منتظر و همکاران (Montazer et al., 2009) روی گندم در شرق تهران و باقری و همکاران (Bagheri et al., 2012) بر ذرت علوفه‌ای در منطقه ورامین با استفاده از داده‌های اقلیمی مورد بررسی قرار گرفت. نتایج این محققین حاکی از دقت بالای مدل در پیش‌بینی عملکرد محصولات ذکر شده دارد.

بررسی تحقیقات انجام شده، نشان می‌دهد که فاکتورهای اقلیمی از عوامل تأثیرگذار بر عملکرد و کارایی آب زعفران محسوب می‌شوند که به دلیل پیچیدگی تأثیرگذاری آن‌ها بر فرآیند رشد گیاهی، پیش‌بینی اثرات آن‌ها دشوار است. تحقیق حاضر باهدف توسعه و ارزیابی مدل شبکه عصبی مصنوعی برای پیش‌بینی عملکرد و کارایی مصرف آب زعفران بر اساس پارامترهای اقلیمی و آب در منطقه تربت‌حیدریه انجام شده است.

مواد و روش‌ها

تربت‌حیدریه یکی از شهرهای استان خراسان رضوی و در ۱۴۰ کیلومتری جنوب مشهد واقع شده است. این شهرستان حدود ۲۳۸۸۸ کیلومترمربع وسعت دارد و ارتفاع آن ۱۳۳۳ متر از سطح دریا می‌باشد. تربت‌حیدریه از نظر جغرافیایی در ۳۵ درجه و ۱۶ دقیقه شمالی و ۵۹ درجه و ۱۴ دقیقه شرقی، با شهرستان‌های تایباد، تربت‌جام و رشتخوار از شرق، با کاشمر از غرب، با

روال آموزش و اعتباریابی برای هر ساختار تکرار شد. در نهایت ساختاری که نتایج آن بر مبنای شاخص‌های آماری حداقل اختلاف را با مقادیر مشاهده‌ای داشت به‌عنوان ساختار بهینه معرفی شد. قابل ذکر است که برنامه‌نویسی مدل‌های شبکه عصبی در محیط نرم‌افزار Matlab انجام گرفت.

جدول ۱- مشخصات مدل‌های شبکه عصبی مورد مطالعه

Table 1- Characteristics of neural network models under study

شماره مدل (ساختار شبکه عصبی) Model number (Neural network structure)	عوامل‌های ورودی Inputs factors	عوامل‌های خروجی Output factors
1	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, RH1, RH2, RH3, RH4, RH5, RH6, RH7, RH8, RH9, RH10, RH11, RH12, Tmean1, Tmean2, Tmean3, Tmean4, Tmean5, Tmean6, Tmean7, Tmean8, Tmean9, Tmean10, Tmean11, Tmean12, Tmin1, Tmin2, Tmin3, Tmin4, Tmin5, Tmin6, Tmin7, Tmin8, Tmin9, Tmin10, Tmin11, Tmin12, Tmax1, Tmax2, Tmax3, Tmax4, Tmax5, Tmax6, Tmax7, Tmax8, Tmax9, Tmax10, Tmax11, Tmax12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	
2	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, RH1, RH2, RH3, RH4, RH5, RH6, RH7, RH8, RH9, RH10, RH11, RH12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	(۱) عملکرد
3	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, RH1, RH2, RH3, RH4, RH5, RH6, RH7, RH8, RH9, RH10, RH11, RH12, Tmean1, Tmean2, Tmean3, Tmean4, Tmean5, Tmean6, Tmean7, Tmean8, Tmean9, Tmean10, Tmean11, Tmean12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	(1) yield
4	I, RH1, RH2, RH3, RH4, RH5, RH6, RH7, RH8, RH9, RH10, RH11, RH12, Tmin1, Tmin2, Tmin3, Tmin4, Tmin5, Tmin6, Tmin7, Tmin8, Tmin9, Tmin10, Tmin11, Tmin12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	
5	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, RH1, RH2, RH3, RH4, RH5, RH6, RH7, RH8, RH9, RH10, RH11, RH12, Tmax1, Tmax2, Tmax3, Tmax4, Tmax5, Tmax6, Tmax7, Tmax8, Tmax9, Tmax10, Tmax11, Tmax12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	
6	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, Tmean1, Tmean2, Tmean3, Tmean4, Tmean5, Tmean6, Tmean7, Tmean8, Tmean9, Tmean10, Tmean11, Tmean12, Tmin1, Tmin2, Tmin3, Tmin4, Tmin5, Tmin6, Tmin7, Tmin8, Tmin9, Tmin10, Tmin11, Tmin12, Tmax1, Tmax2, Tmax3, Tmax4, Tmax5, Tmax6, Tmax7, Tmax8, Tmax9, Tmax10, Tmax11, Tmax12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	
7	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, RH1, RH2, RH3, RH4, RH5, RH6, RH7, RH8, RH9, RH10, RH11, RH12, Tmean1, Tmean2, Tmean3, Tmean4, Tmean5, Tmean6, Tmean7, Tmean8, Tmean9, Tmean10, Tmean11, Tmean12, Tmin1, Tmin2, Tmin3, Tmin4, Tmin5, Tmin6, Tmin7, Tmin8, Tmin9, Tmin10, Tmin11, Tmin12, Tmax1, Tmax2, Tmax3, Tmax4, Tmax5, Tmax6, Tmax7, Tmax8, Tmax9, Tmax10, Tmax11, Tmax12	(۲) کارایی مصرف آب
8	R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, RH1, RH2, RH3, RH4, RH5, RH6, RH7, RH8, RH9, RH10, RH11, RH12, Tmean1, Tmean2, Tmean3, Tmean4, Tmean5, Tmean6, Tmean7, Tmean8, Tmean9, Tmean10, Tmean11, Tmean12, Tmin1, Tmin2, Tmin3, Tmin4, Tmin5, Tmin6, Tmin7, Tmin8, Tmin9, Tmin10, Tmin11, Tmin12, Tmax1, Tmax2, Tmax3, Tmax4, Tmax5, Tmax6, Tmax7, Tmax8, Tmax9, Tmax10, Tmax11, Tmax12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	(2) Water use efficiency
9	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12, S1, S2, S3, S4, S5, S6, S7, S8, S9, S10, S11, S12	
10	I, R1, R2, R3, R4, R5, R6, R7, R8, R9, R10, R11, R12	
11	I	

جدول ۲- میانگین ماهانه پارامترهای اقلیمی مورد بررسی منطقه تربت حیدریه (۹۱-۱۳۹۰)

Table 2- The mean of monthly climate parameters under study in Torbat-e-Heydarieh region (2009-10)

پارامتر اقلیمی	SEP	OCT	NOV	DEC	JAN	FEB	MAR	APR	MAY	JUNE	JULY	AUG
میانگین دما Mean temperature (C°)	21.0	13.8	8.3	4.2	4.7	4.9	11.3	16.0	20.4	25.1	26.7	24.8
حداقل دما Minimum temperature (C°)	13.3	5.7	2.0	-0.1	-1.0	-0.2	4.8	9.6	13.5	17.7	19.8	18.5
حداکثر دما Maximum temperature (C°)	28.7	21.9	14.6	8.6	10.4	10.1	17.8	22.4	27.3	32.5	33.6	31.1
میانگین رطوبت نسبی Humidity (%)	31	32	55	81	70	70	58	51	45	23	20	21
بارندگی Precipitation (mm)	0.0	1.0	17.4	29.8	30.5	36.6	34.2	40.5	46.0	2.4	0.0	0.0
ساعات آفتابی Sun radiation	313.0	297.6	210.4	142.9	191.8	150.1	194.0	249.2	293.5	361.3	388.7	368.6

شکل ریاضی تابع سیگموئیدی در معادله ۲ نشان داده شده است (Hosaini et al., 2007):

$$F(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

خروجی این تابع اعداد بین صفر تا یک می‌باشد و شکل داده‌های ورودی به آن نقش مهمی در یادگیری شبکه ایفا می‌کند. برای ورودی‌های نزدیک به صفر تا یک، تغییرات وزن نرون‌ها حداقل خواهد بود زیرا در این اعداد عناصر پردازش‌گر به دلیل شکل تابع سیگموئید کند عمل می‌کنند ولی برای مقادیر ورودی‌های نزدیک به نیم پاسخ نرون‌ها به سیگنال ورودی سریع‌تر خواهد بود. با توجه به این موضوع، برای نرمال‌سازی داده‌ها از معادله ۳ استفاده شد (Hosaini et al., 2007):

$$X_{norm} = 0.5 \left(\frac{X_0 - \bar{X}}{X_{max} - X_{min}} \right) + 0.5 \quad (3)$$

که در آن مقدار نرمال شده ورودی X_0 ، \bar{X} میانگین داده‌ها، X_{min} و X_{max} به ترتیب حداقل و حداکثر داده‌ها می‌باشد.

در نهایت به منظور مقایسه کمی مقادیر محاسبه و مشاهداتی از شاخص‌های آماری ضریب تبیین (R^2) بین مقادیر اندازه‌گیری شده و پیش‌بینی شده، RMSEn (جذر میانگین مربعات خطا نرمال شده) معادله ۴ و MSE (میانگین مربعات خطا) معادله ۵

برای واسنجی و اعتباریابی مدل‌ها، از داده‌های عملکرد کالاه زعفران و مقدار آب مصرفی (تعداد و زمان آبیاری) برای سال زراعی ۹۱-۱۳۹۰ که به صورت پیمایشی از ۱۲ مزرعه‌ای که به طور تصادفی در منطقه انتخاب شده بودند جمع‌آوری گردید. داده‌های هواشناسی نیز شامل میزان بارندگی، سرعت باد، حداقل، حداکثر و میانگین دما، رطوبت نسبی هوا و ساعات آفتابی به صورت روزانه از ایستگاه هواشناسی شهرستان تهیه شد. در جدول ۲ میانگین ماهانه پارامترهای اقلیمی مورد بررسی ارائه شده است.

برای محاسبه شاخص کارایی مصرف آب از معادله ۱ استفاده شد (Montazer et al., 2009):

$$WUE \quad (kg/m^3) = \frac{Y_a \quad (kg/ha)}{Water \quad use \quad (I+R) \quad (m^3/ha)} \quad (1)$$

که در آن WUE کارایی مصرف آب گیاه، Y_a عملکرد واقعی گیاه، I و R به ترتیب مقدار آب آبیاری و بارندگی است. پس از جمع‌آوری اطلاعات، نرمال‌سازی داده‌ها انجام گرفت.

هدف از نرمال‌سازی آن است که داده‌ها به اعدادی مابین صفر تا ۱ تبدیل شوند، زیرا در این پژوهش برای عناصر پردازش‌گر (نرون‌ها) لایه مخفی تابع آستانه سیگموئیدی انتخاب گردید.

استفاده شد:

$$RMSE_n = 100 (y_p - y_o)^2 / n)^{0.5} / \bar{y}_o \quad (۴)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_p - y_o)^2 \quad (۵)$$

که در آن y_p مقدار پیش‌بینی شده عامل موردنظر، y_o مقدار مشاهده‌ای عامل موردنظر، \bar{y}_p میانگین مقادیر پیش‌بینی شده عامل‌های موردنظر، \bar{y}_o میانگین مقادیر مشاهده‌ای عامل‌های موردنظر و n تعداد داده مورد استفاده در محاسبات است. در رابطه با این دو معادله قابل ذکر است که $RMSE_n$ به صورت درصد اختلاف نسبی مقادیر پیش‌بینی شده در برابر مقادیر واقعی بیان می‌شود و بر اساس تعریف، قدرت پیش‌بینی مدل در صورتی که مقدار $RMSE_n$ کمتر از ۱۰٪ باشد «عالی»، اگر بین ۱۰ تا ۲۰٪ باشد «خوب»، اگر بین ۲۰ تا ۳۰٪ باشد «متوسط» و اگر بالاتر از ۳۰٪ باشد «ضعیف» برآورد می‌گردد (Tavassoli, 2014). هرچه مقدار MSE کمتر باشد، بیان‌گر آن است که نتایج شبیه‌سازی شده مدل به مقادیر اندازه‌گیری شده نزدیک‌تر و دقت شبیه‌سازی مدل بالاتر است (Bagheri et al., 2012).

نتایج و بحث

ارزیابی مدل‌های شبکه عصبی

در جدول ۳، تعداد نرون در لایه پنهان و ضرایب تبیین شبکه‌های عصبی مورد مطالعه در ساختار بهینه ارائه شده است. مطابق با جدول، مدل شبکه عصبی ۹ برای هر دو پارامتر مورد بررسی (عملکرد و کارایی مصرف آب) مناسب‌ترین ساختار شبکه عصبی شناخته شدند، به طوری که این ساختار برای عملکرد با ۲ لایه پنهان، ۸ نرون و ضریب تبیین ۰/۹۷ و برای کارایی مصرف آب نیز با ۱ لایه پنهان، ۷ نرون و ضریب تبیین ۰/۹۰ مناسب‌ترین برازش را داشتند.

همچنین مدل‌های شبکه عصبی با شاخص‌های آماری $RMSE_n$ و MSE برای هر یک از پارامترهای عملکرد و کارایی مصرف آب زعفران مورد ارزیابی قرار گرفت. نتایج مقایسات ارزیابی نشان داد که محاسبه‌های مدل شبکه عصبی ۹ بیشترین تطابق را با داده‌های مشاهده‌ای عملکرد و کارایی مصرف آب زعفران دارند.

جدول ۳- تعداد نرون در لایه پنهان، تعداد لایه پنهان و ضریب تبیین ساختارهای شبکه عصبی

Table 3- No. of neurons in hidden layer, No. of hidden layer, and Coefficient of determination of neural network structure

عامل Factor	شماره ساختار شبکه عصبی No. neural network structure											
		1	2	3	4	5	6	7	8	9	10	11
عملکرد Yield	تعداد نرون در لایه پنهان No. of neurons in hidden layer	9	12	14	20	17	18	26	26	8	27	26
	تعداد لایه پنهان No. of hidden layer	2	1	3	3	3	3	3	3	2	2	3
	ضریب تبیین Coefficient of determination	0.95	0.95	0.89	0.86	0.89	0.86	0.82	0.79	0.97	0.80	0.78
کارایی مصرف آب WUE	تعداد نرون در لایه پنهان No. of neurons in hidden layer	11	13	16	20	18	20	24	28	7	22	29
	تعداد لایه پنهان No. of hidden layer	2	1	5	4	5	3	5	5	1	5	6
	ضریب تبیین Coefficient of determination	0.90	0.90	0.88	0.83	0.87	0.85	0.81	0.80	0.91	0.81	0.80

جدول ۴- مقادیر شاخص‌های آماری حاصل از ارزیابی ساختارهای شبکه عصبی
Table 4- The results of statistics indexes for neural network structures

عامل Factor		شماره ساختار شبکه عصبی No. of neural network structure										
		1	2	3	4	5	6	7	8	9	10	11
عملکرد Yield	RMSE _n (%)	2.98	4.56	12.25	20.09	16.13	15.44	19.88	30.00	2.78	18.44	28.72
	MSE	0.0040	0.0095	0.0134	0.0245	0.0188	0.0167	0.0201	0.0387	0.0040	0.0199	0.0411
کارایی مصرف آب WUE	RMSE _n (%)	5.81	9.34	14.91	18.67	15.44	18.52	15.11	27.73	5.41	16.73	25.08
	MSE	0.0069	0.0123	0.0179	0.0289	0.0234	0.0199	0.0300	0.0506	0.0073	0.0345	0.0544

براساس جدول ۵ پارامتر آبیاری به‌عنوان مهم‌ترین پارامتر مؤثر بر پیش‌بینی عملکرد زعفران شناخته شد و پس از آن به ترتیب پارامترهای بارندگی و ساعت آفتابی حائز اهمیت می‌باشند. انجام تحلیل حساسیت در این مطالعه نیز مشخص کرد که پس از آبیاری و بارندگی که بر توسعه برگ‌ها و نمو زایشی گیاه تأثیر داشته و نیز از طریق اثر بر روی تعادل عرضه و تقاضای آب بر رشد و میزان عملکرد گیاه مؤثر است، ساعات آفتابی که بیانگر میزان انرژی دریافتی توسط گیاه می‌باشد، در برآورد میزان عملکرد زعفران نقش بسزایی دارد. سادراس و کالوینو (Sadras & Calviño, 2001) تعیین نمودند که ۹۰ درصد از تغییرات عملکرد سویا و ۷۶ درصد تغییرات عملکرد ذرت به کمبود آب مرتبط است. کول و همکاران (Kaul et al., 2005) اظهار داشتند که پارامتر آب قابل دسترس یکی از فاکتورهای اساسی در تخمین عملکرد محصولات کشاورزی می‌باشد. اکبرپور و همکاران (Akbarpour et al., 2013) نشان دادند که با حذف بارندگی از مدل شبکه عصبی تغییرات شدیدی در ضرایب همبستگی ایجاد می‌شود و رتبه دوم و سوم مربوط به دما و رطوبت نسبی است.

مطابق با عملکرد زعفران، برای کارایی مصرف آب نیز مشاهده شد که آبیاری مهم‌ترین پارامتر در پیش‌بینی کارایی مصرف آب زعفران شناخته شد و پارامترهای بارندگی و ساعت آفتابی در درجه دوم اهمیت قرار داشتند. همان‌طور که معادله ۱ نشان می‌دهد عملکرد کلاله و مقدار آب مصرفی از مؤلفه‌های

به‌طوری‌که مقدار شاخص‌های RMSE_n و MSE در مدل شماره ۹ برای عملکرد به ترتیب ۲/۷۸ درصد و ۰/۰۰۴۰ و برای کارایی مصرف آب ۵/۴۱ درصد و ۰/۰۰۷۳ است (جدول ۴). در واقع این نتایج بیان‌گر آن است که برای هر دو صفت مورد بررسی، مدل‌های شبکه عصبی تحت مطالعه، مقدار عملکرد و کارایی مصرف آب را به مقدار بسیار کمی بیشتر از مقادیر واقعی نشان می‌دهد که این موضوع حاکی از دقت نسبتاً بالای مدل‌های شبکه عصبی توسعه یافته در این تحقیق برای پیش‌بینی عملکرد و کارایی مصرف آب زعفران در منطقه تربت‌حیدریه است.

آنالیز حساسیت

فرآیند آنالیز حساسیت، میزان حساسی مدل را نسبت به متغیرهای ورودی آن نشان می‌دهد. در این پژوهش برای انجام آنالیز حساسیت مدل از روش StatSoft استفاده گردید (StatSoft, 2004). در این روش مقادیر ضریب حساسیت متغیرهای ورودی از تقسیم نمودن خطای کل شبکه در غیاب یک متغیر بر خطای کل شبکه در حضور تمامی متغیرهای ورودی، به دست می‌آید. بر این اساس اگر مقدار ضریب حساسیت یک متغیر بیشتر از یک باشد، آن متغیر سهم زیادی در توضیح تغییرپذیری مؤلفه‌های عملکرد دارد (Norouzi, 2009). نتایج آنالیز حساسیت برای مؤلفه‌های عملکرد و کارایی مصرف آب زعفران در جدول ۵ نشان داده شده است.

تأثیر بر عملکرد کلاله) می‌تواند بر شبیه‌سازی کارایی مصرف آب زعفران تأثیرگذار باشد، بنابراین تغییرات آبیاری، بارندگی و ساعات آفتابی می‌تواند تأثیر زیادی بر پیش‌بینی کارایی مصرف آب زعفران داشته باشد.

اصلی در تعیین کارایی مصرف آب محسوب می‌شوند لذا هر گونه تغییرات در این دو مؤلفه می‌تواند بر روی دقت پیش‌بینی کارایی مصرف آب تأثیرگذار باشد. از آنجایی که آبیاری و بارندگی به‌طور مستقیم و ساعات آفتابی نیز به‌طور غیر مستقیم (از طریق

جدول ۵- ضرایب حساسیت پارامترهای مورد استفاده در روش StatSoft
Table 5- Sensitivity analysis of parameters used in StatSoft method

پارامترهای ورودی Input parameters	فاکتور حذف شده Eliminated factor	MSE		ضریب حساسیت فاکتور حذف شده Sensitivity coefficient of eliminated factor	
		عملکرد Yield	کارایی مصرف آب WUE	عملکرد yield	کارایی مصرف آب WUE
آبیاری + بارندگی + رطوبت نسبی + ساعات آفتابی + حداکثر دما + حداقل دما Irrigation + Precipitation + Relative humidity + Sun radiation + Tmax + Tmin + Tmean	-	0.0040	0.0069	-	-
آبیاری + بارندگی + رطوبت نسبی + ساعات آفتابی + حداقل دما + میانگین دما Irrigation + Precipitation + Relative humidity + Sun radiation + Tmin + Tmean	حداکثر دما Tmax	0.0056	0.0077	1.40	1.11
آبیاری + بارندگی + ساعات آفتابی + حداکثر دما + حداقل دما + میانگین دما Irrigation + Precipitation + Sun radiation + Tmax + Tmin + Tmean	رطوبت نسبی Relative humidity	0.0081	0.0110	2.02	1.59
آبیاری + بارندگی + رطوبت نسبی + ساعات آفتابی + حداکثر دما + حداقل دما Irrigation + Precipitation + Relative humidity + Sun radiation + Tmax + Tmin	میانگین دما Tmean	0.0109	0.0156	2.72	2.26
آبیاری + بارندگی + رطوبت نسبی + ساعات آفتابی + حداکثر دما + میانگین دما Irrigation + Precipitation + Relative humidity + Sun radiation + Tmax + Tmean	حداقل دما Tmin	0.0147	0.0185	3.67	2.68
آبیاری + بارندگی + رطوبت نسبی + ساعات آفتابی + حداکثر دما + میانگین دما Irrigation + Precipitation + Relative humidity + Tmax + Tmin + Tmean	ساعات آفتابی Sun radiation	0.0224	0.0309	5.60	4.47
آبیاری + رطوبت نسبی + ساعات آفتابی + حداکثر دما + حداقل دما + میانگین دما Irrigation + Relative humidity + Sun radiation + Tmax + Tmin + Tmean	بارندگی Precipitation	0.0279	0.0345	6.97	5.00
بارندگی + رطوبت نسبی + ساعات آفتابی + حداکثر دما + حداقل دما + میانگین دما Precipitation + Relative humidity + Sun radiation + Tmax + Tmin + Tmean	آبیاری Irrigation	0.0311	0.0489	7.77	7.08

جدول ۶- تأثیر افزودن پارامترهای هواشناسی بر عملکرد شبکه‌های عصبی مصنوعی
 Table 6- Influence of adding climate parameters on yield and WUE of artificial neural network

پارامتر هواشناسی climate parameters	MSE	
	عملکرد Yield	کارایی مصرف آب WUE
آبیاری+بارندگی Irrigation + Precipitation	0.0199	0.0345
آبیاری+ ساعات آفتابی Irrigation + Sun radiation	0.0225	0.0379
آبیاری+رطوبت نسبی Irrigation + Relative humidity	0.0411	0.0479
آبیاری + حداقل دما + حداکثر دما + میانگین دما Irrigation + Tmax + Tmin + Tmean	0.0506	0.0582

به‌دست آمده در جدول ۶ نیز دلالت دارد.

نتیجه‌گیری

در این پژوهش به بررسی کارایی شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد و کارایی مصرف آب زعفران با استفاده از آمار عملکرد محصول و پارامترهای اقلیمی پرداخته شد. نتایج نشان داد که هنگامی که آب آبیاری به‌عنوان ورودی به مدل معرفی می‌شود، مدل می‌تواند عملکرد و کارایی مصرف آب را با دقت نسبتاً بالایی شبیه‌سازی کند. انجام آنالیز حساسیت مشخص نمود که بعد از پارامتر آبیاری، میزان بارندگی نقش بسزایی در پیش‌بینی عملکرد و کارایی مصرف آب زعفران داشت و پس از این دو پارامتر ساعات آفتابی که بیانگر میزان انرژی دریافتی توسط گیاه است در درجه دوم اهمیت برای پیش‌بینی صفات فوق در محصول زعفران قرار دارد. همچنین با بررسی پارامترهای هواشناسی موجود مشخص شد که افزودن پارامترهای رطوبت نسبی و دما به ورودی‌های مدل تأثیری در بهبود روند آموزش شبکه ندارد و دقت شبیه‌سازی مدل افزایش چندانی را نشان نمی‌دهد.

منتظر و همکاران (Montazer et al., 2009) گزارش

کردند که آبیاری و بارندگی مهم‌ترین پارامترهای تأثیرگذار بر شبیه‌سازی بهره‌وری آب گندم محسوب می‌شوند.

بررسی تأثیر افزودن پارامترهای هواشناسی بر عملکرد شبکه

مطابق با جدول ۵ هم برای عملکرد و هم برای کارایی مصرف آب زعفران، افزودن پارامترهای رطوبت نسبی، حداقل، حداکثر و میانگین دما تأثیر چندانی بر کاهش میانگین مربعات خطا (MSE) ندارد، اما اضافه کردن پارامترهای بارندگی و ساعات آفتابی سبب کاهش میزان MSE می‌شود. البته کاهش این شاخص زمانی که دو پارامتر توأم استفاده می‌شوند بیشتر است که نشان از دقت بالاتر مدل برای شبیه‌سازی عملکرد و کارایی مصرف آب زعفران در استفاده از این دو پارامتر اقلیمی است. همان‌طور که در آنالیز حساسیت ورودی‌های مدل (جدول ۴) نیز مشاهده شد آبیاری، بارندگی و ساعات آفتابی به‌ترتیب مهم‌ترین مؤلفه‌های پیش‌بینی عملکرد و کارایی مصرف آب زعفران محسوب می‌شدند که نتایج حاصل از آن بر صحت نتایج

منابع

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).
- Alvarez, A. 2009. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *European Journal of Agronomy* 30: 70-77.
- Azadeh A., Ghaderi, S.F., and Sohrabkhani, S. 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematical Computer* 186: 1753-1761.
- Bagheri, S., Gheysari, M., Ayoubi, S., and Lavaee, N. 2012. Silage maize yield prediction using artificial neural networks. *Journal of Plant Production* 19 (4): 77-95. (In Persian with English Summary).
- Behdani, M.A., Nassiri Mahallati, M., and Koocheki, A. 2008. Evaluation of irrigation management of saffron at agroecosystem scale in dry regions of Iran. *Asian Journal of Plant Sciences* 7 (1): 22-25.
- Daneshvar Kakhki, M., and Farahmand Gelyan, K. 2012. Review of interactions between e-commerce, brand and packaging on value added of saffron: A structural equation modeling approach. *African Journal of Business Management* 6 (26): 7924-7930.
- Drummond, S.T., Sudduth, K.A., Joshi, A., Birell, S.J., and Kitchen, N.R. 2003. Statistical and neural methods for site-specific yield prediction. *Transaction of the ASAE* 46 (1): 5-14.
- Gupta M.M., Jin, J., and Homma, N. 2003. *Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory*. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Hosaini, M.T., Siosemarde, A., Fathi, P., and Siosemarde, M. 2007. Application of artificial neural network (ANN) and multiple regressions for estimating assessing the performance of dry farming wheat yield in Ghorveh region, Kurdistan province. *Agriculture research: Water, Soil and Plant in Agriculture* 7 (1): 41-54. (In Persian with English Summary).
- Jehade Keshavari Khorasan Razavi. 2012. Report on agronomic research for saffron. (On published). (In Persian).
- Kaul, M., Hill, R.L., and Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agricultural System* 85: 1-18.
- Koocheki, A. 2013. Research on production of saffron in Iran: Past trend and future prospects. *Saffron Agronomy & Technology*, 1 (1): 3-21. (In Persian with English Summary).
- Montazer, A.A., Azedegan, B., and Shahraki, M. 2009. Performance evaluation of artificial neural network models in estimation of yield and water productivity of wheat on the basis of climate factor and consumption water-nitrogen fertilizer. *Iranian Journal of Water Research* 3 (5): 17-29. (In Persian with English Summary).
- Norouzi, M. 2009. Prediction of rainfed wheat yield using artificial neural network in Ardal district of Chaharmahal and Bakhtiari province. M.Sc. Thesis, Collage of Agriculture, Isfahan University of Technology, Isfahan, Iran. 112 p. (In Persian with English Summary).
- Rahimi, H., Ghavidel, G.R., and MohsenNia, J. 2007. *The geography of Torbat-e-Heydarieh city*. Mashhad press. 216 p. (In Persian).
- Sadeghi, B. 2013. Round table scientific debate on saffron. Faculty of Agriculture. Ferdowsi University of Mashhad. (In Persian with English Summary).
- Sadras, V.O., and Calviño, P.A. 2001. Quantification of grain yield response to soil depth in soybean, maize, sunflower, and wheat. *Agronomy Journal* 93: 577-583.
- StatSoft Inc. 2004. *Electronic Statistics Textbook* (Tulsa, OK). Available at Web site <http://www.statsoft.com/textbook/stathome.html> (verified 5 march 2015).
- Tavassoli, A. 2014. Quantifying yield gap of wheat in water and nitrogen limit conditions in Shirvan region:

model and field experiment. Ph.D thesis in the Agronomy, University of Zabol. (In Persian with English Summary).

Torrecilla J.S., Otero, L., and Sanz, P.D. 2004. A neural network approach for thermal/pressure food processing. Food Engineering 62: 89-95.

Vakil-Baghmisheh, M.T. 2002. Farsi character recognition using artificial neural networks. Ph.D Thesis, Faculty of Electrical Engineering, University of Ljubljana.

Veelenturf L.P.J. 1995. Analysis applications of artificial neural networks. Simon and Schuster international group, United States of America.

Predicting Yield and Water Use Efficiency in Saffron Using Models of Artificial Neural Network Based on Climate Factors and Water

*Azim Shirdeli^{*1} and Abolfazl Tavassoli²*

1. Assistant Professor, Department of Agriculture, Zanjan University, Iran.
2. Assistant Prof. Department of Agriculture, Payame Noor University, I. R. of Iran.
(*-Corresponding Author E-mail: Abolfazl202060@yahoo.com)

Received: 2 March, 2015

Accepted: 6 June, 2015

Abstract:

The predicted models for crops yield are developing rapidly by the creation of new statistical techniques and neural networks. For this purpose, a research was carried out in the Torbat-e-Heydarieh region for predicting yield and water use efficiency of saffron by using an artificial neural network model. The model was calibrated and validated by using crop yield and climate parameters data during 2009-2010. The models were evaluated by using indices of correlation coefficient (R^2), root mean squares error normalized (RMSE_n), and mean squares error (MSE). The results showed that the suggested neural network (model No. 9) with having 2 hidden layers, 8 neurons, and $R^2= 0.97$ (for saffron yield); and 1 hidden layer, 7 neurons, and $R^2= 0.90$ (for water use efficiency) had a high accommodation with these two factors. Also, according to the indices RMSE_n and MSE, model No. 9 simulated the yield and WUE of saffron with a high accuracy, such that RMSE_n and MSE for yield in this model obtained were 2.78% and 0.0041, respectively; and for WUE they were calculated to be 5.41% and 0.0073, respectively. Also, the results of sensitivity analysis indicated that irrigation is the most important parameter for predicting yield and WUE, and after that is precipitation and solar radiation. Generally, use of the suggested neural network in this research can improve saffron cultivation in the Torbat-e-Heydarieh region.

Keywords: *Model, Simulation, Stigma, Torbat-e-Heydarieh.*