

پیش‌بینی عملکرد جو دیم و آبی (*Hordeum vulgare L.*) با استفاده از رهیافت شبکه عصبی مصنوعی (مطالعه موردی: استان کرمانشاه)

علیرضا باقری^{1*} و ناصر سهرابی²

تاریخ دریافت: 1395/10/14

تاریخ پذیرش: 1396/01/29

باقری، ع.، و سهرابی، ن. 1397. پیش‌بینی عملکرد جو دیم و آبی (*Hordeum vulgare L.*) با استفاده از رهیافت شبکه عصبی مصنوعی (مطالعه موردی: استان کرمانشاه). بوم‌شناسی کشاورزی، 10(2): 516-528.

چکیده

نظر به اهمیت پیش‌بینی تولید محصولات کشاورزی، آزمایشی با هدف برآورد عملکرد محصول جو دیم و آبی (*Hordeum vulgare L.*) با استفاده از رهیافت شبکه عصبی مصنوعی، در استان کرمانشاه به اجرا درآمد. داده‌های مربوط به عملکرد 25 ساله (1370 تا 1394) جو دیم و آبی در شهرستان‌های استان و همچنین داده‌های خام و استاندارد شده هواشناسی (مجموع بارندگی سالیانه، متوسط درجه حرارت سالیانه، متوسط رطوبت سالیانه، مجموع ساعات آفتابی، میانگین تبخیر سالیانه و تعداد روزهای یخبندان) متناظر با این سال‌ها به‌عنوان داده‌های ورودی شبکه مورد استفاده قرار گرفتند. برای یافتن بهترین شبکه، انواع مختلف شبکه عصبی برای تخمین عملکرد، آزمایش شد. ارزیابی مدل‌ها نیز با استفاده از شاخص‌های آماری ضریب همبستگی (R)، ضریب تعیین (R^2)، میانگین مربعات خطا (MSE) و ریشه میانگین مربعات خطا (RMSE) انجام شد. نتایج نشان داد که بهترین شبکه برای جو دیم شبکه‌های عصبی مودولار ساخته شده از داده‌های استاندارد و خام و با قانون یادگیری Momentum دارای ضریب همبستگی به ترتیب 0/96 و 0/92 بود. این در حالی بود که دقت شبکه عصبی در مورد جو آبی به‌اندازه کشت دیم نبود (ضریب همبستگی برای داده‌های ورودی استاندارد و خام به ترتیب 0/72 و 0/78). مقایسه شاخص‌های MSE و RMSE بین مدل‌های ذکر شده نیز مؤید این امر بود. به نظر می‌رسد در جو آبی انجام عملیات مدیریت داشت مانند آبیاری از تأثیر عوامل اقلیمی بر روی عملکرد آن کاسته است. از سوی دیگر، حساسیت شبکه عصبی مربوط به کشت جو دیم نسبت به متغیرهای ورودی مدل بسیار بیشتر از کشت آبی بود که در نهایت دقت بیشتر شبکه را به همراه داشت.

واژه‌های کلیدی: عملکرد اقتصادی، عوامل اقلیمی، متغیرهای پیش‌گو، هوش مصنوعی

مقدمه

کلان مدیریتی، آگاهی و پیش‌بینی مقدار تولید محصولات کشاورزی می‌تواند در قیمت‌گذاری و میزان واردات و صادرات محصولات کشاورزی تعیین‌کننده باشد (Hosaini et al., 2007). استان کرمانشاه با داشتن شرایط آب و هوایی مناسب و تنوع اقلیمی، شامل سه اقلیم گرمسیر (شهرستان‌های سرپل ذهاب، قصر شیرین و گیلان غرب)، اقلیم معتدل (شهرستان‌های کرمانشاه، روانسر، صحنه، اسلام آباد و...) و اقلیم سردسیر (شهرستان‌های سنقر و پاوه) با متوسط بارندگی سالیانه 487 میلی‌متر و دمای متوسط 12/8 درجه سانتی‌گراد از استان‌های مناسب جهت کشت غلات می‌باشد. این استان با سطح زیر کشت زیاد و تولید مازاد بر نیاز خود به‌عنوان یکی

پیش‌بینی مقدار تولید محصولات کشاورزی به‌خصوص محصولات استراتژیکی مانند گندم (*Triticum aestivum L.*) و جو (*Hordeum vulgare L.*) می‌تواند در برنامه‌ریزی و آمادگی مدیران در تأمین نقدینگی جهت خرید محصولات از کشاورزان و تهیه فضای مناسب جهت انبار داری به آن‌ها کمک کند. علاوه بر این در سطح

1 و 2- به ترتیب استادیار و دانشجوی کارشناسی ارشد رشته اگرواکولوژی، گروه زراعت و اصلاح نباتات، پردیس کشاورزی و منابع طبیعی، دانشگاه رازی کرمانشاه (*- نویسنده مسئول: Email: alireza884@gmail.com)

ورودی را نشان دهد. به همین دلیل نسبت به مدل‌های تجربی¹ دارای مزیت هستند (Alvarez, 2009). به طور کلی، شبکه عصبی از سه لایه نرون تشکیل شده است که شامل لایه ورودی، که تعداد نرون‌های ورودی برابر با تعداد متغیرهای ورودی مدل است، لایه پنهان که به طور تجربی در طی توسعه شبکه عصبی، تشکیل می‌شود و لایه خروجی که نرون‌های مربوط به متغیرهای خروجی است (شکل 1). جریان اطلاعات از لایه ورودی به سمت لایه خروجی از طریق لایه پنهان و فرآیند آموزش شامل اختصاص وزن‌های مختلف بر اساس تابع انتقال بین نرون‌ها با مقایسه لایه خروجی با داده‌های مشاهده شده با تکرار بالا (در یک فرآیند تکراری) انجام می‌شود (Alvarez, 2009).


شبکه عصبی مصنوعی در بخش‌های مختلف علوم کشاورزی مورد استفاده قرار گرفته است که از آن جمله می‌توان به پیش‌گویی محتوای کربن آلی خاک (Somaratne et al., 2005)، تخمین خصوصیات هیدرولیک آب (Nemes et al., 2003)، تخمین توسعه گیاهان زراعی (Elizondo et al., 1994)، پیش‌بینی جریان CO₂ در اکوسیستم‌ها (Melesse & Hanley, 2005) و تخمین عملکرد (Kaul et al., 2005) اشاره کرد.

استفاده از شبکه عصبی برای تخمین عملکرد محصولات زراعی نتایج مطلوبی را به همراه داشته و در مقایسه با برخی روش‌های دیگر از دقت بالاتری برخوردار بوده است. وو و یو (Wu & Yen, 1992) از دو روش شبکه‌های عصبی مصنوعی و رگرسیون چند متغیره برای پیش‌بینی عملکرد گندم در ارتباط با مصرف کود ازته استفاده کردند و اعلام کردند شبکه‌های عصبی مصنوعی برای مناسب‌تری برای جایگزینی به جای روش تجزیه و تحلیل رگرسیون چند متغیره می‌باشند. دراموند و همکاران (Drummond et al., 2003) در مطالعه‌ای که بر روی روابط میان خصوصیات خاک، توپوگرافی و عملکرد غلات در آمریکا انجام دادند به این نتیجه رسیدند که روش شبکه عصبی مصنوعی نسبت به روش رگرسیونی دارای خطای کمتری است. کائول و همکاران (Kaul et al., 2005) نیز بیان کردند که روش شبکه عصبی مصنوعی برای پیش‌بینی عملکرد ذرت (*Zea mays L.*) و سویا (*Glycine max L.*) دارای دقت بیشتری نسبت به رگرسیون است.

از قطب‌های کشاورزی کشور مطرح است. به دلیل عدم برنامه‌ریزی و آگاهی از میزان تولید محصولات کشاورزی، متأسفانه هر سال نابسامانی‌های زیادی در خرید محصولات از کشاورزان و عدم وجود فضای مناسب انبارداری در استان به وجود می‌آید. این امر سبب می‌شود که کشاورزان تولیدات خود را یا به قیمت ارزان‌تر فروخته و یا با هزینه‌های زیادتر به خارج از استان صادر کنند (Anonymous, 2015). با توجه به میزان تولید مازاد بر نیاز داخلی استان و اهمیت آمادگی لازم، از نظر خرید و فضای انباری مناسب، ضرورت آگاهی از مقدار تولید محصولات زراعی مختلف و برنامه‌ریزی مناسب بر اساس آن احساس می‌شود. از این رو امکان پیش‌بینی عملکرد محصولات زراعی، قبل از برداشت می‌تواند گامی مهم در این راستا باشد.

برای پیش‌بینی عملکرد محصولات کشاورزی از روش‌های مختلفی استفاده می‌شود که یکی از این روش‌ها، که اخیراً مورد توجه پژوهشگران قرار گرفته، شبکه‌های عصبی مصنوعی است (Landeras et al., 2009). شبکه‌های عصبی مصنوعی کاملاً مشابه دستگاه عصبی انسان بوده و در واقع تقلیدی از مغز و شبکه اعصاب انسان است که امکان درک روابط و آموزش را بر پایه اطلاعات ورودی فراهم می‌آورد (Joergensen & Bendoricchio, 2001). به این ترتیب شبکه‌های عصبی مصنوعی طوری طراحی شده‌اند که همانند مغز قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد (Rao & Rao, 1995). برای یادگیری شبکه، ابتدا یک سری داده (متغیرهای مستقل) به عنوان نمونه‌های آموزشی به شبکه معرفی می‌گردند که با استفاده از این داده‌های ورودی، ارتباط بین متغیرهای مستقل و متغیر وابسته کشف و مقدار متغیر وابسته محاسبه می‌شود (Lingireddy & Brion, 2005). تعداد تکرار نمونه‌های آموزشی باید به اندازه‌ای باشد که دقت شبکه کاهش پیدا نکند. زمانی که تعداد تکرار نمونه‌ها برای فرآیند آموزش کافی نباشد، میزان خطای فرآیند آموزش افزایش و در نتیجه دقت شبکه کاهش می‌یابد، بنابراین انتخاب تعداد تکرار مناسب نمونه‌های آموزشی بسیار مهم است (Lingireddy & Brion, 2005). پس از این مرحله مقادیر محاسبه‌شده با مقادیر واقعی مورد آزمون قرار گرفته و در صورت بالا بودن دقت، شبکه تایید می‌شود.

شبکه عصبی مصنوعی به خوبی روابط غیر خطی تعاملات پیچیده مورد مطالعه را بیان می‌کند و می‌تواند روابط پنهان بین متغیرهای



شکل 1- لایه‌های مختلف شبکه عصبی مصنوعی و ارتباط بین آن‌ها (Alvarez, 2009)
 Fig. 1- Different layer of Artificial Neural Network and their connection (Alvarez, 2009)

عملکرد گندم دیم را پیش‌بینی کرد. نظر به اهمیت آگاهی از مقدار تولید محصولات کشاورزی قبل از برداشت، این آزمایش باهدف پیش‌بینی عملکرد محصول جو دیم و آبی که از محصولات غالب استان کرمانشاه بوده و سالانه بیش از 20 درصد از اراضی استان را به خود اختصاص می‌دهند (Anonymous, 2015) به اجرا درآمد. برای پیش‌بینی محصول از رهیافت شبکه عصبی مصنوعی بر اساس داده‌های مربوط به عملکرد 25 ساله شهرستان‌های استان و همچنین داده‌های هواشناسی متناظر با این سال‌ها استفاده شد.

مواد و روش‌ها

به‌منظور پیش‌بینی عملکرد جو دیم و آبی بر اساس داده‌های هواشناسی بلندمدت استان، در ابتدا داده‌های هواشناسی 25 ساله شهرستان‌های استان کرمانشاه، از سازمان هواشناسی استان استخراج و بر اساس سال زراعی مرتب شدند. بر این اساس، داده‌های هواشناسی، از اوایل ماه مهر سال قبل تا پایان خردادماه سال بعد (طول دوره رشد جو در استان) به‌عنوان یک سال زراعی در نظر گرفته شد. به این ترتیب داده‌های مربوط به سال‌های زراعی 71-1370 الی 94-1393 تهیه شد. عوامل اقلیمی مورد استفاده به‌عنوان متغیرهای پیشگو و مستقل، شامل مجموع بارندگی سالیانه، متوسط درجه حرارت سالیانه، متوسط رطوبت سالیانه، مجموع ساعات آفتابی، میانگین تبخیر

میزان تولیدات محصولات کشاورزی به‌خصوص محصولات دیم صرف‌نظر از وابستگی به خصوصیات ژنتیکی رقم، شرایط خاک و فعالیت‌های مدیریتی، به‌شدت تحت تأثیر عوامل اقلیمی مانند بارندگی، رطوبت هوا، نوسانات درجه حرارت در طول دوره رشد گیاه و تابش خورشید قرار دارد. شکوهی و ثنائی نژاد (Shokoohi & Sanaei Nejjhad, 2014) طی تحقیقی بر ارتباط شرایط آب و هوایی با تولید محصول جو دیم در استان آذربایجان شرقی بیان داشتند که مهمترین عامل اقلیمی محدودکننده تولید محصول درجه حرارت است. به طوری که وقوع دماهای بسیار پایین در بهمن ماه، دماهای بالا پیش از شروع فصل زمستان و دماهای بسیار بالا در مرحله گلدهی مهمترین عوامل محدود کننده تولید این محصول بودند. علاوه بر این بارندگی مناسب در اوایل کاشت محصول سبب افزایش عملکرد جو دیم شد.

با توجه به اثرات قابل‌توجه عوامل اقلیمی روی عملکرد محصولات کشاورزی دیم، به نظر می‌رسد با استفاده از شبکه عصبی مصنوعی بتوان با استفاده از این داده‌های اقلیمی به‌عنوان متغیرهای مستقل، میزان عملکرد محصولات زراعی (به‌عنوان متغیر وابسته) را پیش‌بینی کرد. حسینی و همکاران (Hosaini et al., 2007) در آزمایشی در خصوص پیش‌بینی عملکرد گندم دیم در شهرستان قروه استان کردستان با استفاده از عوامل اقلیمی به این نتیجه رسیدند که با استفاده از شبکه‌های عصبی مصنوعی می‌توان با قابلیت بسیار بالای

شدند. به این ترتیب در لایه ورودی شش نرون در نظر گرفته شد. لایه خروجی نیز شامل یک نرون که همان پیش‌بینی میزان عملکرد بود، در نظر گرفته شد. پس از ساخت شبکه‌ها و انتخاب بهترین شبکه، تعداد نرون‌های لایه پنهان نیز مشخص شد. در این آزمایش برای ساخت شبکه‌های عصبی مصنوعی ورودی شبکه به صورت دسته‌ای و همزمان به شبکه اعمال شدند و تنظیم وزن‌ها و مقادیر آستانه شبکه پس از آن که تمامی ورودی‌ها به شبکه اعمال شدند، انجام گرفت.

برای یافتن بهترین شبکه عصبی توصیف‌کننده میزان عملکرد تحت تأثیر داده‌های ورودی هواشناسی، انواع شبکه‌های عصبی مانند شبکه‌های عصبی چندلایه پرسپترون²، پیش‌خور تعمیم‌یافته³ و شبکه‌های عصبی مودولار⁴ مورد آزمایش قرار گرفته و بر اساس روش آزمون و خطا بهترین شبکه انتخاب شدند (Eghbali et al., 2005). همچنین در این آزمایش از قوانین یادگیری Momentum، Levenberg Marquardt استفاده شد که در هر یک از آن‌ها توابع انتقال LinearTanhAxon، SigmoidAxon، TanhAxon و LinearAxon، SoftMaxAxon، LinearSigmoidAxon و Axon مورد استفاده قرار گرفته و پس از ساخت شبکه‌های عصبی مختلف قانون یادگیری و تابع انتقالی که بیشترین دقت را به همراه داشتند، انتخاب شدند. ساخت انواع شبکه‌های عصبی، آنالیز حساسیت، انتخاب قوانین یادگیری و توابع انتقال با استفاده از نرم‌افزار NeuroSolution v.5.0 انجام شد.

با توجه به این که در این آزمایش به‌طور کلی همگرایی تعلیم در حدود 1000 گام⁵ یادگیری به‌دست آمد. انجام تکرار بیشتر گام یادگیری منجر به افزایش معنی‌دار عملکرد شبکه نشد. به همین دلیل بیشترین مقدار گام یادگیری معادل 1000 تعیین شد. گام یادگیری، یک روش آموزشی در شبکه‌های عصبی است. در یک شبکه عصبی، یک رفت‌وبرگشت بر روی تمام نمونه‌های مجموعه داده‌های آموزش شبکه در راستای کاهش خطا با استفاده از الگوریتم‌های یادگیری را اصطلاحاً یک گام یادگیری می‌گویند (Eghbali et al., 2005).

در این آزمایش برای جلوگیری از افزایش میزان خطا و بیش‌برازش داده‌ها از دو معیار کمترین میانگین مربعات خطای داده‌های

سالیانه و تعداد روزهای یخبندان سالیانه بودند. داده‌های مربوط به عملکرد گیاه زراعی جو دیم و بهاره نیز به‌عنوان متغیر وابسته در نظر گرفته شدند. اطلاعات مربوط به سطح زیر کشت و مقدار تولید در واحد سطح هریک از شهرستان‌های مورد مطالعه استان، از اداره آمار سازمان جهاد کشاورزی و وزارت جهاد کشاورزی استان کرمانشاه تهیه شدند.

با توجه به حساسیت شبکه عصبی مصنوعی به تعداد تکرار نمونه‌های آموزشی، جهت افزایش تعداد نمونه‌های آموزش، در این مطالعه داده‌های هواشناسی ذکر شده هر یک از شهرستان‌های مورد مطالعه به همراه میزان عملکرد جو دیم و آبی آن، در مجموع، مورد استفاده قرار گرفتند. شهرستان‌های مورد مطالعه شامل؛ شهرستان‌های کرمانشاه، کنگاور، صحنه، هرسین، روانسر، جوانرود، سرپل ذهاب، قصر شیرین، اسلام آباد، گیلان غرب و سنقر تهیه شد. لازم به ذکر است که در برخی از شهرستان‌ها، داده‌های هواشناسی 25 ساله به صورت کامل موجود نبود، از این‌رو داده‌های مربوط به سال‌های موجود مورد استفاده قرار گرفت. به این ترتیب برای ساخت شبکه‌های عصبی در این آزمایش به تعداد 191 سری داده مورد استفاده قرار گرفت.

در ساخت شبکه‌های عصبی، جهت کسب نتایج مطلوب در پیش‌بینی پدیده‌های مختلف، برخی عملیات مقدماتی بر روی داده‌ها مورد نیاز است. از جمله این عملیات می‌توان به استانداردسازی داده اشاره کرد (Anysz et al., 2016). به این ترتیب داده‌های هواشناسی مورد استفاده به عنوان لایه ورودی برای ساخت شبکه‌های عصبی، به دو دسته تقسیم شدند. دسته اول، داده‌های خام و دسته دوم، شامل داده‌های استاندارد شده که برای به‌دست آوردن آن‌ها از روش استانداردسازی خطی ویتندورف¹ (معادله 1)، استفاده شد (Anysz et al., 2016).

$$X_i = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

در آن X_i : معادل مقدار داده استاندارد شده، X_{min} : عادل کوچک‌ترین مقدار داده و X_{max} : برابر است با بزرگ‌ترین مقدار از سری داده‌های مربوط به هریک از متغیرهای ورودی مدل. پس از آماده‌سازی داده‌ها، هر یک از دسته داده‌های خام و استاندارد شده، به‌عنوان ورودی مدل شبکه عصبی مصنوعی استفاده

2- Multilayer perceptrons neural networks
3- Generalized feed forward neural networks
4- Modular neural networks
5- Epoch

1- Weitendorf's linear standardization

که در این معادلات؛ O_i ، S_i و \bar{O} ؛ به ترتیب مقدار واقعی مشاهده شده (مقدار واقعی عملکرد محصول)، مقدار پیش بینی شده توسط مدل (شبکه عصبی)، مقدار میانگین مشاهدات و تعداد مشاهدات یا تکرارها (تعداد سال‌های مربوط به آزمایش) می‌باشد.

نتایج و بحث

نتایج حاصل از خروجی شبکه‌های عصبی ساخته شده در این آزمایش نشان داد که شبکه عصبی مودولار با تابع انتقال تانزانانت هیپربولیک Tanaxon و قانون یادگیری Momentum با معیار کمترین مقدار میانگین مربعات خطای آموزش جهت توقف فرآیند آموزش، بالاترین دقت را در پیش‌بینی عملکرد جو دیم و آبی دارا بود. بررسی خروجی شبکه‌های عصبی مودولار بر اساس داده‌های ورودی خام و استاندارد برای جو دیم و آبی نشان داد که بهترین نتایج از شبکه با ورودی داده‌های استاندارد برای جو دیم و شبکه با ورودی داده‌های خام برای جو آبی، به دست آمد. در شبکه حاصل از داده‌های ورودی استاندارد جو دیم، 92 درصد از تغییرات عملکرد به وسیله تغییرات مقدار لایه ورودی شامل مجموع بارندگی سالانه، متوسط درجه حرارت سالانه، متوسط رطوبت سالانه، مجموع ساعات آفتابی، میانگین تبخیر سالانه و تعداد روزهای یخبندان سالانه‌های زراعی بیان شد. این در حالی بود که در شبکه عصبی حاصل از داده‌های خام ورودی مربوط به جو دیم، 85 درصد از تغییرات عملکرد توسط تغییرات لایه ورودی بیان شد. بررسی ریشه میانگین مربعات خطای شبکه‌های ساخته شده از داده‌های ورودی خام و استاندارد برای جو دیم نشان داد که شبکه‌های عصبی ساخته شده از داده‌های استاندارد از مقدار کمتر ریشه میانگین مربعات خطا برخوردار بوده و از این رو دارای دقت بیشتری بودند (جدول 1). بررسی ریشه میانگین مربعات خطای نرمال شده نیز مؤید این امر بود، به طوری که این مقدار در مورد شبکه‌های ساخته شده از داده خام و استاندارد 13/8 و 6/10 درصد از میانگین داده‌های مشاهده شده بود که نشان‌دهنده دقت خوب شبکه عصبی (به‌خصوص شبکه ساخته شده از داده‌های ورودی استاندارد) بوده و به این ترتیب می‌توان عنوان داشت که شبکه‌های عصبی ساخته شده می‌توانند با دقت قابل قبولی عملکرد جو دیم را پیش‌بینی کنند. وو و یین (Wu & Yen, 1992) برای پیش‌بینی عملکرد گندم و همچنین کائول و همکاران (Kaul et al., 2005) در پیش‌بینی عملکرد ذرت (*Zea mays* L.) و سویا (*Glycine max*)

آموزش¹ و روش اعتبار سنجی² برای توقف فرآیند آموزش شبکه استفاده شد. با توجه به دقت بیشتر معیار کمترین میانگین مربعات خطای داده‌های آموزش، این معیار برای توقف آموزش شبکه‌های عصبی ساخته شده، انتخاب شد (Amari et al., 1997). 75 درصد از داده‌ها برای ساخت و آموزش شبکه‌های عصبی اختصاص داده شدند. علاوه بر این جهت انجام آزمون میزان دقت شبکه 25 درصد باقی مانده داده‌ها مورد استفاده قرار گرفتند. به این ترتیب برای آموزش شبکه از 143 تکرار داده و برای تست آن از 48 تکرار از داده‌ها استفاده شد.

به منظور بررسی دقت شبکه عصبی در پیش‌بینی عملکرد جو دیم و آبی از ضریب همبستگی (R) و ضریب تعیین (R^2) مقادیر مشاهده شده و پیش‌بینی شده عملکرد جو، استفاده شد. ضریب همبستگی و ضریب تعیین از جمله پارامترهایی هستند که می‌توان از طریق آن‌ها دقت مدل‌های مختلف را به آسانی ارزیابی کرد. با این حال باید به این نکته توجه داشت که این ضرایب نمی‌توانند به تنهایی معیار مناسبی برای سنجش مدل باشند، زیرا ممکن است در یک مدل با وجود اختلاف فاحش بین داده‌های مشاهده شده و پیش‌بینی شده، روند تغییرات این داده‌ها مشابه باشد. در این حالت اگرچه ضرایب همبستگی و تعیین به خوبی هماهنگی روند تغییرات داده‌های مشاهده شده و پیش‌بینی شده را نشان می‌دهد، اما گویای تطابق عددی بین آن‌ها نیست (Rahmani et al., 2008). بنابراین در این آزمایش از شاخص‌های میانگین مربعات خطا (MSE^3) (معادله 2)، ریشه میانگین مربعات خطا ($RMSE^4$) (معادله 3) و ریشه میانگین مربعات خطای نرمال شده ($nRMSE^5$) (معادله 4) نیز برای ارزیابی دقت مدل استفاده شد (Haykin and Lippmann, 1994).

$$MSE = \frac{\sum_{i=1}^n (S_i - O_i)^2}{n} \quad (2) \text{ معادله}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n}} \quad (3) \text{ معادله}$$

$$nRMSE = \sqrt{\frac{\sum_{i=1}^n (S_i - O_i)^2}{n}} \times \frac{100}{O} \quad (4) \text{ معادله}$$

- 1- Minimum mean square error of the training set
- 2- Cross validation
- 3- Mean square error
- 4- Root mean square error
- 5- Normalized root mean square error

شبکه‌های ساخته شده از داده‌های ورودی خام کمتر از شبکه ساخته شده با داده‌های ورودی استاندارد بود، همچنین درصد ریشه میانگین مربعات خطا در شبکه‌های ساخته شده از داده‌های خام و استاندارد جو آبی به ترتیب معادل 15/4 و 16/7 درصد بود که نشان‌دهنده دقت بیشتر شبکه ساخته شده از داده‌های خام است (جدول 1).

(L) نیز گزارش کردند که استفاده از شبکه عصبی می‌تواند پیش‌بینی قابل قبولی را به همراه داشته باشد.

در ارتباط با پیش‌بینی عملکرد جو آبی، نوع لایه ورودی (عوامل اقلیمی) خام و استاندارد توانستند به ترتیب 60 و 51 درصد از تغییرات عملکرد را باعث شود. علاوه بر این، ریشه میانگین مربعات خطای

جدول 1- دقت شبکه عصبی در پیش‌بینی عملکرد گیاه زراعی جو دیم و آبی با استفاده از داده‌های خام و استاندارد
Table 1- Artificial neural network accuracy in prediction of rainfed and irrigated barley yield using the raw data and standard

ورودی شبکه Input	ضریب تعیین R^2	ضریب همبستگی R	میانگین مربعات خطا MSE	ریشه میانگین مربعات خطا RMSE	ریشه میانگین مربعات خطای نرمال شده nRMSE (%)
جو دیم					
Rainfed barley					
داده‌های خام Raw data	0.85	0.92	155.94	24320.33	13.8
داده‌های استاندارد Standard data	0.92	0.96	127.82	16338.90	10.6
جو آبی					
Irrigated barley					
داده‌های خام Raw data	0.60	0.78	634.17	402180.46	15.4
داده‌های استاندارد Standard data	0.51	0.72	695.66	483954.04	16.7

MSE: میانگین مربعات خطا، RMSE: ریشه میانگین مربعات خطا، R: ضریب همبستگی و R^2 : ضریب تعیین.


MSE: Mean Square Error, RMSE: Root Mean Square Error, R: Correlation coefficient and R^2 : Coefficient of determination

عملیات مدیریتی بیشتر در کشت آبی نسبت به کشت دیم، در نتیجه تأثیرگذاری کمتر عوامل اقلیمی روی عملکرد در کشت آبی، ارتباط کمتری بین لایه ورودی و لایه خروجی در شبکه ساخته شده برای جو آبی برقرار شد. به بیان دیگر، در شرایط کشت دیم، معمولاً کشاورزان اقدام به کشت محصول کرده و تا هنگام برداشت کمترین عملیات مدیریتی مرحله داشت را روی گیاه زراعی اعمال می‌کنند. به همین دلیل فاکتورهای اقلیمی از جمله بارندگی و دما، تبخیر و تعرق و مقدار تشعشع خورشید می‌توانند تأثیر بسیار زیادی را روی عملکرد محصول داشته باشند. این در حالی است که در شرایط کشت آبی، کشاورزان پس از کشت محصول در طول فصل رشد با اعمال انواع عملیات مدیریتی که از مهمترین آن‌ها می‌توان به آبیاری اشاره کرد، در حقیقت باعث کاهش تأثیر عوامل اقلیمی رو محصول می‌شوند. جی و همکاران (Ji et al., 2007) بیان کردند که اقلیم و آب و هوا روی رشد و توسعه گیاهان (به‌ویژه در شرایط دیم) تأثیرگذار هستند و تغییرات عوامل آب و هوایی به‌ویژه در مراحل بحرانی رشد گیاهان

بر اساس نتایج شبکه‌های عصبی ساخته شده از داده‌های استاندارد و خام برای جو دیم، درجه ارتباط (ضریب همبستگی) بین لایه ورودی و خروجی به ترتیب 0/96 و 0/92 بود (جدول 1). بررسی شکل‌های مربوط به عملکرد ثبت شده و پیش‌بینی شده نیز نشان داد که علاوه بر وجود روند تغییرات مشابه مستند بر ضرایب همبستگی ذکر شده، تطابق کمی نسبتاً مناسبی نیز بین مقادیر ثبت شده و پیش‌بینی شده وجود داشته و اختلاف بین عملکرد مشاهده شده و پیش‌بینی شده اندک بود (شکل 2 الف و ب).


درجه ارتباط (ضریب همبستگی) بین لایه ورودی و خروجی شبکه عصبی ساخته شده از داده‌های خام و استاندارد برای جو آبی، به ترتیب معادل 0/78 و 0/72 بود (جدول 1، شکل‌های 3 الف و ب) که میزان ارتباط کمتر بین مقادیر ثبت شده و پیش‌بینی شده عملکرد در کشت آبی جو را نسبت به کشت دیم آن نشان می‌دهد. این امر کارایی کمتر شبکه عصبی مصنوعی در پیش‌بینی عملکرد جو آبی در مقایسه با جو دیم را در نشان می‌دهد. به نظر می‌رسد با توجه به انجام

زراعی ممکن است منجر به کاهش معنی‌دار عملکرد شوند.



شکل 2- مقایسه عملکرد پیش‌بینی شده توسط شبکه عصبی با عملکرد واقعی ثبت شده جو دیم بر اساس الف- داده‌های استاندارد و ب- داده‌های خام

Fig. 2- Comparison of predicted yield by neural network with observed yield of rainfed barley based on A- standard data and B- raw data



شکل 3- مقایسه عملکرد پیش‌بینی شده توسط شبکه عصبی با عملکرد واقعی ثبت شده جو آبی بر اساس الف- داده‌های استاندارد و ب- داده‌های خام
Fig. 3- Comparison of predicted yield by neural network with observed yield of irrigated barley based on A- standard data and B- raw data

است، به طوری که بهترین شبکه عصبی ساخته شده برای جو دیم حساسیت محسوسی را به عوامل اقلیمی به عنوان لایه ورودی شبکه

نتایج حاصل از آنالیز حساسیت شبکه‌های عصبی ساخته شده برای جو دیم و آبی به متغیرهای ورودی مؤید مطالب ذکر شده در بالا


رسیدند که درجه حرارت کمینه و بیشینه و متوسط بارندگی سالیانه افزایش می‌یابد، اما عملکرد گندم ممکن است تا 30 درصد کاهش یابد. بنابراین ارزیابی اثر عوامل اقلیمی روی عملکرد محصولات زراعی به دلیل روابط پیچیده زیستی و غیر زیستی موجود می‌تواند به عنوان موضوعی کاربردی، اطلاعات مفیدی در جهت اتخاذ مدیریت مناسب در اختیار مدیران بخش کشاورزی قرار دهد (Shokoohi & Sanaei Nejjhad, 2014).

بهترین شبکه ساخته شده برای جو آبی، به جز به عامل دما، حساسیت چندانی را به عوامل اقلیمی از خود نشان نداد. بر خلاف شبکه عصبی مربوط به جو دیم که بیشترین حساسیت را به میزان بارندگی از خود نشان داد، در شبکه عصبی مربوط به جو آبی کمترین حساسیت به میزان بارندگی مشاهده شد (شکل 4 ب). در کشت‌های آبی انجام عملیات آبیاری در طی فصل رشد می‌تواند نیاز آبی گیاه را تامین و میزان وابستگی گیاه را به نزولات جوی به حداقل برساند که نتایج به‌دست آمده نشان‌دهنده این امر هستند. محققین در آزمایشی به این نتیجه رسیدند که آبیاری تکمیلی در گندم دیم می‌تواند عملکرد دانه و کاه را افزایش می‌دهد. علاوه بر این در کنار آبیاری محصول، انجام سایر عملیات مدیریتی مانند مبارزه با آفات، بیماری‌ها و علف‌های هرز می‌تواند در نهایت افزایش کارایی مصرف آب را به همراه داشته باشد (Talliee & Sayadian, 2000).

با توجه به حساسیت دقت شبکه عصبی به تعداد تکرار متغیرهای ورودی (Lingireddy & Brion, 2005)، در این مطالعه برای افزایش دقت شبکه‌های عصبی، تعداد تکرار هر یک از متغیرهای ورودی (تعداد تکرار نرون‌های لایه ورودی) با در نظر گرفتن داده‌های هواشناسی و عملکرد جو آبی و دیم در هر یک از شهرستان‌های استان، به تعداد 191 عدد افزایش پیدا کرد. هرچند افزایش تکرارهای لایه‌های ورودی، دقت شبکه عصبی برای جو آبی نسبت به جو دیم چندان بالا نبود. به نظر می‌رسد برای افزایش دقت شبکه عصبی، افزایش تعداد متغیرهای ورودی (تعداد نرون لایه ورودی) نیز بتواند دقت شبکه‌های عصبی را افزایش دهد. از این‌رو ممکن است با افزایش تعداد متغیرهای ورودی (مانند افزایش داده‌های مربوط به میزان بارندگی، دما، تبخیر و تعرق، مقدار رطوبت هوا و ساعات آفتابی به تفکیک ماه در طول فصل کشت) بر میزان دقت شبکه عصبی افزوده شود. بنابراین، افزایش تعداد نرون لایه ورودی و ارزیابی تغییرات دقت شبکه عصبی برای آزمایشات بعدی پیشنهاد می‌شود.

نشان داد. در بین عوامل اقلیمی بارندگی بیشترین تأثیر را بر روی شبکه داشت (شکل 4 الف). آلوارز (Alvarez, 2009) در آزمایشی در خصوص پیش‌بینی عملکرد گندم در آرژانتین، اعلام کرد نسبت بارندگی به تبخیر و تعرق مهم‌ترین عامل اقلیمی بر میزان عملکرد این محصول می‌باشد. کائول و همکاران (Kaul et al., 2005) اعلام کردند که عامل آب قابل‌دسترس یک از عوامل اصلی در تخمین عملکرد محصولات کشاورزی می‌باشد. در تحقیقی دیگر نیز نشان داده شد که مقدار عملکرد گندم دیم رابطه مستقیم با مقدار بارندگی و نحوه توزیع آن در طول فصل رشد دارد (Azizi & Safarkhani, 2002).

پس از عامل بارندگی، بیشترین حساسیت شبکه عصبی ساخته شده برای جو دیم مربوط به دما بود. بیان شده است که بارندگی بیش از درجه حرارت بر عملکرد محصول دیم مؤثر است (Talliee & Bahramy, 2003). علاوه بر این، افزایش بارندگی در اواخر دوره رشد و نمو تأثیر بیشتری نسبت به افزایش بارندگی در اوایل رشد دارد. با این حال نتایج مطالعات مختلف روی ذرت و سویا در آمریکا (Lobell & Asner, 2003)، برنج در فیلیپین (Peng et al., 2004) و گندم در چین (Liangzhi et al., 2005) نشان دادند که افزایش درجه حرارت دارای اثر منفی بر عملکرد محصول است. باید بیان کرد که اثر دمای هوا، بسته به میزان بارندگی در طی فصل زراعی می‌تواند متفاوت باشد. به این ترتیب که در سال‌های خشک اثرات منفی دمای بالای هوا روی گیاه زراعی بیشتر خواهد بود. کراستا و کاکس (Crasta & Cox, 1996) دریافتند که دمای هوای سالانه در شمال شرق ایالات متحده طی سال‌های خشک با تنش خشکی متوسط تا شدید در مقایسه با سال‌های با بارندگی مناسب، اثرات منفی بر عملکرد ذرت دارد، در حالی که طی سال‌های با بارندگی مناسب عملکرد تحت تأثیر دمای هوا قرار نگرفت. زرکانی و همکاران (Zarakani et al., 2014) در پیش‌بینی عملکرد گندم دیم خراسان شمالی بر اساس پارامترهای اقلیمی مانند دما و بارندگی نشان دادند که افزایش دمای کمینه (0/5 درجه سانتی‌گراد)، بیشینه (0/5 درجه سانتی‌گراد) و افزایش بارندگی (25 میلی‌متر) از سال 2010 تا 2039 می‌تواند منجر به افزایش نسبی عملکرد گندم دیم شود. این در حالی بود که رحمانی و همکاران (Rahmani et al., 2016) طی تحقیقی دیگر روی اثر عوامل اقلیمی دما و بارندگی بر عملکرد گندم و جو در همان دوره زمانی 2010 تا 2039 در خراسان جنوبی نیز به این نتیجه



شکل 4- میزان حساسیت خروجی شبکه عصبی مصنوعی ساخته شده برای الف- جو دیم و ب- جو آبی، نسبت به نرون‌های لایه ورودی
 Fig. 4- The artificial neural network output sensitivity for A- rainfed, and B- irrigated barley to the input neurons

مربعات خطا نیز نشان داد که دقت شبکه‌های عصبی ساخته شده برای جو دیم بالاتر از جو آبی است. از این رو، استفاده از شبکه عصبی مصنوعی برای پیش‌گویی عملکرد محصول جو دیم قابل اطمینان‌تر است.

سیاسگزاری

در این‌جا از همکاری صمیمانه سازمان جهاد کشاورزی و همچنین اداره کل هواشناسی استان کرمانشاه در ارائه اطلاعات زراعی و هواشناسی مورد استفاده در این تحقیق، کمال تشکر و قدردانی ابراز می‌شود.

نتیجه‌گیری

به‌طور کلی، نتایج به‌دست‌آمده نشان داد که استفاده از شبکه عصبی مصنوعی برای پیش‌بینی عملکرد محصول جو دیم می‌تواند قابل قبول باشد، این در حالی بود که در مورد جو آبی قدرت پیش‌بینی شبکه عصبی کاهش پیدا کرد. به نظر می‌رسد عدم انجام فعالیت مدیریت داشت در کشت‌های دیم و تأثیرپذیری بیشتر این نوع کشت از عوامل اقلیمی منجر به این امر شد و به همین حساسیت شبکه عصبی ساخته شده به متغیرهای ورودی مدل (متغیرهای آب و هوایی) برای جو دیم، بالا باشد. این در حالی بود که حساسیت شبکه عصبی جو آبی به متغیرهای هواشناسی ورودی مدل، بسیار پایین‌تر بود. علاوه بر این ارزیابی دقت شبکه‌های عصبی بر اساس ریشه میانگین

منابع

- 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: 70-77.
- Amari, S., Murata, N., Muller, K., Finke, M., and Yang, H.H. 1997. Asymptotic statistical theory of overtraining and cross-validation. *IEEE Transactions on Neural Networks* 8: 985-996.
- Anonymous, 2015. *Agricultural Statistics, Agricultural Year of 2014-2015. First Volume, the Crops*. Iranian Ministry of Agriculture 9-11.

- Anysz, H., Zbiciak, A., and Ibadov, N. 2016. The influence of input data standardization method on prediction accuracy of artificial neural networks. *Procedia Engineering* 153: 66-70.
- Azizi, G., and Safarkhani, E. 2002. Evaluation of drought and its impact on rainfed wheat yield in ilam province, with an emphasis on recent drought (1998-2000). *Modarres* 6: 61-79.
- Crasta, O., and Cox, W. 1996. Temperature and soil water effects on maize growth, development yield, and forage quality. *Crop Science* 36: 341-348.
- Drummond, S.T., Sudduth, K.A., Joshi, A., Birrell, S.J., and Kitchen, N.R. 2003. Statistical and neural methods for site-specific yield prediction. *Transactions of the ASAE* 46: 5.
- Eghbali, L., Haghghi, R.S., Rad, H.M., and Bagheri, A. 2005. Seed identification of *Amaranthus* spp. using machine vision and artificial neural network. *Journal of Seed Science and Technology* 2: 74-85.
- Elizondo, D., McClendon, R., and Hoogenboom, G. 1994. Neural network models for predicting flowering and physiological maturity of soybean. *Transactions of the ASAE* 37: 981-988.
- Haykin, S., and Lippmann, R. 1994. Neural networks, a comprehensive foundation. *International Journal of Neural Systems* 5: 363-364.
- Hosaini, M.T., Siosemarde, A., Fathi, P., and Siosemarde, M. 2007. Application of artificial neural network (ann) and multiple regression for estimating assessing the performance of dry farming wheat yield in Ghorveh region, Kurdistan Province. *Agricultural Research: Water, Soil and Crop* 7: 41-54.
- Ji, B., Sun, Y., Yang, S., and Wan, J. 2007. Artificial neural networks for rice yield prediction in mountainous regions. *The Journal of Agricultural Science* 145: 249-261.
- Joergensen, S.E., and Bendricchio, G. 2001. *Fundamentals of Ecological Modelling*. Elsevier, Oxford, UK.
- Kaul, M., Hill, R.L., and Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems* 85: 1-18.
- Landeras, G., Ortiz-Barredo, A., and López, J.J. 2009. Forecasting weekly evapotranspiration with arima and artificial neural network models. *Journal of Irrigation and Drainage Engineering* 135: 323-334.
- Liangzhi, Y., Stanley, W., and Rosegrant, M. 2005. Impact of global warming on chinese wheat productivity. *International Food Policy Research Institute, Discussion paper*, pp. 143-158.
- Lingireddy, S., and Brion, G.M. 2005. *Artificial Neural Networks in Water Supply Engineering*. ASCE Publications.
- Lobell, D.B., and Asner, G.P. 2003. Climate and management contributions to recent trends in U.S agricultural yields. *Science* 299: 1032-1032.
- Melesse, A.M., and Hanley, R.S. 2005. Artificial neural network application for multi-ecosystem carbon flux simulation. *Ecological Modelling* 189: 305-314.
- Nemes, A., Schaap, M., and Wösten, J. 2003. Functional evaluation of pedotransfer functions derived from different scales of data collection. *Soil Science Society of America Journal* 67: 1093-1102.
- Peng, S., Huang, J., Sheehy, J.E., Laza, R.C., Visperas, R.M., Zhong, X., Centeno, G.S., Khush, G.S., and Cassman, K.G. 2004. Rice yields decline with higher night temperature from global warming. *Proceedings of the National Academy of Sciences of the United States of America* 101: 9971-9975.
- Rahmani, L., Liaghat, A., and Khalili, A. 2008. Estimates barley yield in east azerbaijan using meteorological parameters and drought indices by artificial neural network method. *Iranian Journal of Soil and Water Research* 39: 47-56. (In Persian with English Summary)

- Rahmani, M., Jami Al-Ahmadi, M., Shahidi, A., and Hadizadeh Azghandi, M. 2016. Effects of climate change on length of growth stages and water requirement of wheat (*Triticum aestivum* L.) and barley (*Hordeum vulgare* L.) (Case study: Birjand plain). *Journal of Agroecology* 7: 443-460.
- Rao, V., and Rao, H. 1995. *C++ Neural Networks and Fuzzy Logic*. MIS: Press, Dehle, India.
- Shokoohi, M., and Sanaei Nejjhad, S.H. 2014 The relationship between weather conditions and crop production for rainfed barley (Case Study: East Azerbaijan). *Journal of Agroecology* 6: 634-644. (In Persian with English Summary)
- Somaratne, S., Seneviratne, G., and Coomaraswamy, U. 2005. Prediction of soil organic carbon across different land-use patterns. *Soil Science Society of America Journal* 69: 1580-1589.
- Talliee, A.A., and Bahramy, N. 2003. The effect of rainfall and temprature on the yield of dryland wheat in Kermanshah province. *Journal of Soil and Water Science* 17: 106-112. (In Persian with English Summary)
- Talliee, A.A., and Sayadian, K. 2000. Effect of supplementary irrigation and nutrition requirement of chick-pea in dry land conditions. *Iranian Journal of Crop Science* 2: 63-70. (In Persian with English Summary)
- Wu, F.Y., and Yen, K.K. 1992. Applications of neural network in regression analysis. *Computers and Industrial Engineering* 23: 93-95.
- Zarakani, F., Kamali, G., and Chizari, A. 2014. Impact of climate change on the economy of rainfed wheat (Case study: Northern Khorasan). *Journal of Agroecology* 6: 301-310. (In Persian with English Summary)



Predicting Yield of Rainfed and Irrigated Barley (*Hordeum vulgare* L.) in Kermanshah by Artificial Neural Network Approach (Case study Kermanshah, Iran)

A. Bagheri^{1*} and N. Sohrabi²

Submitted: 03-01-2017

Accepted: 18-04-2017

Bagheri, A., and Sohrabi, N. 2018. Predicting yield of rainfed and irrigated barley (*Hordeum vulgare* L.) in Kermanshah by Artificial Neural Network approach (Case study Kermanshah, Iran). Journal of Agroecology. 10(2): 516-528.

Introduction

Predicting the yield of strategic crops such as wheat and barley can provide liquidity to purchase products from farmers, suitable space for storage, sufficient pricing, and estimating the import and export needs of the agricultural products. Crop yield forecasting can be estimated using different methods. Artificial neural network is one of the methods recently has been considered and has high accuracy in crop yield estimation. In this approach the relationship between independent and dependent variables as well as their complex interactions will be studied and hidden correlations between the variables is discovered. Crop yield, particularly in case of rain-fed crops, severely affected by climatic factors such as rainfall, humidity, temperature fluctuations and solar radiation during the growth season. On this basis, it seems that in case of relationships between climatic data (as independent variables) and crop yield (as dependent variable) it would be possible to predict agricultural production.

Materials and Methods

Considering the importance of forecasting agricultural production, an experiment was conducted in Kermanshah province, with the aim of estimating rainfed and irrigated barley yield using artificial neural network approach,. Barley yield data of 25 years (1991 to 2015) as well as raw and corresponding standardized meteorological data (total annual rainfall, average annual temperature, humidity annual average total sunshine hours, average annual evaporation and the number of frost days) were used as input data networks. To find the best network, performance of different types of neural networks was tested to barley yield evaluation. To evaluate models the statistics indices of correlation coefficient (R), coefficient of determination (R^2), mean squared error (MSE) and root mean square error (RMSE) were used.

Results and Discussion

The results showed that the best neural network built for rainfed barley was Modular Neural Network with Momentum learning law. The network had a correlation coefficient of 0.96 and 0.92, and coefficient of determination of 0.85 and 0.92 for raw and standard data, respectively. The best neural network built for irrigated barley was also Modular Neural Network with Momentum learning law. The correlation coefficient for the raw and standard input data was 0.78 and 0.72 with coefficient of determination of 0.60 and 0.51, respectively. The results showed the less efficiency of artificial Neural Network in predicting irrigated compared to rainfed barley yield. Comparison of MSE and RMSE between the models also revealed that networks related to rainfed barely with more accuracy had more correlation coefficient compared to irrigated barely. It seems that the managing operations such as watering in irrigated barley has reduced the effect of climate factors on barley yield. So that the sensitivity of irrigated barley yield was much less than the rainfed barley. In fact, in irrigated cultivations, depending on the amount of available water, crops were irrigated regularly. This would be in addition to supplying the needed water of crops, also reduce the impact of other climatic factors such as

1 and 2- Assistant Professor and Graduated student of Agroecology, Department of Agronomy and Plant Breeding, Campus of Agriculture and Natural Resources, Razi University, Kermanshah, Iran, respectively.

(*- Corresponding author Email: alireza884@gmail.com)

DOI: 10.22067/jag.v10i2.61417

temperature.

Conclusion

Generally based on the results of this study, the accuracy of Artificial Neural Network to predict the yield of rainfed barley was more acceptable than irrigated barley in Kermanshah province. Rainfed cultivation are more affected by climatic factors such as rainfall and temperature, which would be the reason of the achieved results. Hence, the accuracy of neural network for rainfed barley was more than irrigated barely, which represents more relationship between yield of rainfed barley with climatic factors as inputs of the model. So the sensitivity test of the yield to climatic factors revealed more sensitivity in rainfed than irrigated barley. Moreover, the accuracy of neural network showed that neural network was built for barley than wheat.

Keywords: Artificial intelligence, Barley, Predictive variables, Yield prediction