

امکان‌سنجی آموزش شبکه‌های عصبی مصنوعی با استفاده از مدل‌های گیاهی برای پیش‌بینی عملکرد و طول دوره‌های رشد گندم

فاطمه صفری^۱، هادی رمضانی اعتدالی^۲، عباس کاویانی^۳، بهنام آبابایی^۴

۱- دانشجوی کارشناسی ارشد آبیاری و زهکشی، دانشگاه بین‌المللی امام خمینی (ره)

۲- عضو هیات علمی گروه علوم و مهندسی آب، دانشگاه بین‌المللی امام خمینی (ره)

۳- عضو هیات علمی گروه علوم و مهندسی آب، دانشگاه بین‌المللی امام خمینی (ره)

۴- پژوهشگر مرکز علوم گیاهی، دانشگاه کوئینزلند، استرالیا

(تاریخ دریافت: ۹۷/۰۵/۰۸، تاریخ پذیرش: ۹۸/۰۳/۰۱)

چکیده

افزایش روزافزون تقاضای محصولات کشاورزی و افزایش فشار بر منابع آب و خاک از یک سو و مشکلات دستیابی به داده‌های میدانی از سوی دیگر، ضرورت استفاده از مدل‌های مناسب برای پیش‌بینی عملکرد محصولات کشاورزی را نمایان می‌سازد. بسیاری از پارامترهای ورودی مدل‌های گیاهی در کشور ما در دسترس نیستند. از طرف دیگر با پدید آمدن تکنیک‌های آماری نوین و شبکه‌های عصبی مصنوعی، مدل‌های پیش‌بینی‌کننده عملکرد محصولات زراعی به سرعت رو به توسعه است. بدین منظور پژوهشی با هدف ارزیابی قابلیت شبکه‌های عصبی مصنوعی برای یادگیری از مدل‌های پیچیده گیاهی و توانایی آنها در پیش‌بینی عملکرد و طول دوره رشد گندم و برخی از پارامترهای مورد نیاز مدل گیاهی AquaCrop انجام گرفت. ارزیابی مدل‌های شبکه عصبی مصنوعی نیز با شاخص‌های آماری ضریب تبیین (R^2)^۱، جذر میانگین مربعات خطا نرمال شده (SRMSE)^۲ انجام شد. نتایج نشان داد که مدل شبکه عصبی شماره ۹ (طول دوره رشد از گل‌دهی تا برداشت) با R^2 و SRMSE به ترتیب برابر با ۰/۹۸ و ۴/۷۹٪ و مدل شبکه عصبی شماره ۲ (عملکرد دانه در زمان برداشت) با R^2 و SRMSE به ترتیب برابر با ۰/۹۷ و ۹/۶۹٪ به ترتیب بهترین دقت را در بین مدل‌های پیش‌بینی دوره‌های مهم رشد و عملکرد دانه گندم داشتند. براساس نتایج این مطالعه، کارایی شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد و طول دوره‌های مهم فصل رشد گندم با استفاده از متغیرهای اقلیمی مورد تایید قرار گرفت.

واژه‌های کلیدی: شبیه‌سازی، مدل گیاهی، متغیرهای اقلیمی، دوره‌های رشد گندم.

مقدمه

باتوجه به اینکه بررسی پاسخ گندم به نهاده‌های مختلف در اقلیم‌های متفاوت با روش میدانی زمان‌بر و پرهزینه و در برخی موارد غیرممکن است، همچنین امکان بررسی همزمان اثرات آب، کود، زمان کاشت، تراکم و نوع خاک بر روی گیاه در روش میدانی وجود ندارد بنابراین معرفی مدلی موفق و قابل اعتماد کمک شایانی برای این مشکل است. از آنجایی که دقت تمامی مدل‌ها تابعی از ورودی‌های آنها می‌باشد، شناسایی پارامترهای ورودی مؤثر از اهمیت ویژه‌ای برخوردار است و مدل‌هایی که از پارامترهای ورودی کمتری

گندم مهمترین محصول کشاورزی است که به وسیله انسان زراعت شده و به همین دلیل مهمترین گیاه زراعی به شمار می‌آید. گندم (*Triticum aestivum*) گیاهی است متعلق به خانواده غلات، که در سطح وسیعی از زمین‌های کشاورزی دنیا کشت و تولید می‌شود. این گیاه از نظر ارزش غذایی نقش عمده‌ای در تغذیه انسان دارد و به دلیل سهم آن در الگوی غذایی عمده جمعیت جهان، از اهمیت ویژه‌ای برخوردار است (Khodabandeh, 1998).

استفاده کرده و قادر به ارائه نتایج نزدیکتری به واقعیت هستند، مطلوب می‌باشند (Bagheri et al, 2012). با این حال؛ واسنجی، اعتبارسنجی و بکارگیری مدل‌های گیاهی عموماً به تخصص و تجربه قبلی نیازمند است که شاید در دسترس نباشد. لذا تلاش برای یافتن جایگزینی ساده‌تر برای این مدل‌ها به نحوی که برای کاربران فاقد تخصص مدل‌سازی گیاهی امکان‌پذیر باشد، برخی متغیرهای گیاهی مثل عملکرد و دوره‌های رشد را فراهم سازد ضروری به نظر می‌رسد.

یکی از روش‌های مدل‌سازی که در سال‌های اخیر مورد توجه بسیاری از محققین در علوم مختلف واقع شده، مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی است. شبکه‌های عصبی مصنوعی با پردازش روی داده‌های تجربی یا دانش، داده‌ها را به ساختار شبکه منتقل می‌کنند. در ساختار این سیستم‌ها پارامترهایی وجود دارند که قابل تنظیم هستند. تنظیم این پارامترها برای آن است که سیستم رفتار مطلوبی را در برابر تحریکات و اطلاعات خارجی از خود نشان دهد که به اصطلاح به این عمل آموزش آن سیستم گفته می‌شود (Jain et al, 1996).

پژوهشگران حوزه کشاورزی از شبکه‌های عصبی مصنوعی در شبیه‌سازی متغیرهایی چون میزان تبخیر و تعرق هفتگی (Landeras et al, 2009)، تبخیر روزانه (Piri et al, 2009)، پیش‌بینی دمای هوا (Smith et al, 2009)، تابش-خورشیدی (Mubiru, 2008)، شبیه‌سازی جریان رودخانه (Ababaei et al, 2012)، پیش‌بینی سیلاب (Mukerji et al, 2009)، تخمین میزان فرسایش خاک (Kim et al, 2008)، پیش‌بینی عملکرد سیستم‌های آبیاری تحت فشار (Ababaei et al, 2013)، و قابلیت نگهداشت آب و ضریب آبگذری اشباع خاک (Merdun et al, 2006) استفاده کرده‌اند.

بررسی‌ها نشان می‌دهد از شبکه‌های عصبی مصنوعی در برآورد عملکرد محصولات زراعی کمتر استفاده شده‌اند. دراموند و همکاران (۲۰۰۳) برای تعیین روابط میان خصوصیات خاک، توپوگرافی و عملکرد غلات در منطقه میسوری آمریکا مطالعاتی را انجام دادند و مشاهده نمودند که روش شبکه‌های عصبی مصنوعی نسبت به روش‌های

رگرسیون دارای خطای کمتری می‌باشد (Drummond et al, 2003). کول و همکاران (۲۰۰۵) 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 به عنوان 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 (Kaul et al, 2005). آلوارز (۲۰۰۹) شبکه‌های عصبی-مصنوعی را برای تعیین بازده گیاه گندم در منطقه پامپاس آرژانتین بکار برد. وی نسبت بارندگی به تبخیر و تعرق پتانسیل محصول (R/CPET) را به عنوان مهمترین فاکتور آب و هوایی مؤثر بر بازده این محصول معرفی نمود (Alvarez, 2009). نوروزی و همکاران (۲۰۱۰) از شبکه‌های عصبی-مصنوعی به منظور پیش‌بینی عملکرد گندم در مناطق نیمه خشک و کوهستانی غرب ایران استفاده نمودند و بیان داشتند که شاخص انتقال رسوب مهمترین عامل توپوگرافی بر میزان عملکرد این گیاه بوده‌است و میزان پروتئین موجود در دانه‌ها تحت تأثیر میزان نیتروژن کل خاک می‌باشد (Norouzi et al, 2010).

اندرزیان و همکاران (۲۰۱۱) از AquaCrop برای شبیه‌سازی مراحل رشد و میزان آب مصرفی بر عملکرد گندم تحت سناریوهای مختلف آبیاری در اقلیم گرم و خشک اهواز استفاده کردند. نتایج این تحقیق نشان داد که این مدل قادر است به خوبی میزان رطوبت منطقه ریشه، توده گیاهی و عملکرد دانه را شبیه‌سازی کند (Andarzian et al., 2011).

پندی و همکاران (۲۰۱۷) از دو نوع شبکه عصبی مصنوعی برای پیش‌بینی عملکرد سیب‌زمینی در منطقه Bhadohi هندوستان استفاده کردند. براساس نتایج حاصله از این پژوهش شبکه عصبی رگرسیون تعمیم یافته (GRNN) قادر به پیش‌بینی بهتر برای عملکرد در این منطقه بود (Pandey et al., 2017). ابوکریم و همکاران (۲۰۱۵) اقدام به پیش‌بینی

استفاده کرده و قادر به ارائه نتایج نزدیکتری به واقعیت هستند، مطلوب می‌باشند (Bagheri et al, 2012). با این حال؛ واسنجی، اعتبارسنجی و بکارگیری مدل‌های گیاهی عموماً به تخصص و تجربه قبلی نیازمند است که شاید در دسترس نباشد. لذا تلاش برای یافتن جایگزینی ساده‌تر برای این مدل‌ها به نحوی که برای کاربران فاقد تخصص مدل‌سازی گیاهی امکان‌پذیر باشد، برخی متغیرهای گیاهی مثل عملکرد و دوره‌های رشد را فراهم سازد ضروری به نظر می‌رسد.

یکی از روش‌های مدل‌سازی که در سال‌های اخیر مورد توجه بسیاری از محققین در علوم مختلف واقع شده، مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی است. شبکه‌های عصبی مصنوعی با پردازش روی داده‌های تجربی یا دانش، داده‌ها را به ساختار شبکه منتقل می‌کنند. در ساختار این سیستم‌ها پارامترهایی وجود دارند که قابل تنظیم هستند. تنظیم این پارامترها برای آن است که سیستم رفتار مطلوبی را در برابر تحریکات و اطلاعات خارجی از خود نشان دهد که به اصطلاح به این عمل آموزش آن سیستم گفته می‌شود (Jain et al, 1996).

پژوهشگران حوزه کشاورزی از شبکه‌های عصبی مصنوعی در شبیه‌سازی متغیرهایی چون میزان تبخیر و تعرق هفتگی (Landeras et al, 2009)، تبخیر روزانه (Piri et al, 2009)، پیش‌بینی دمای هوا (Smith et al, 2009)، تابش-خورشیدی (Mubiru, 2008)، شبیه‌سازی جریان رودخانه (Ababaei et al, 2012)، پیش‌بینی سیلاب (Mukerji et al, 2009)، تخمین میزان فرسایش خاک (Kim et al, 2008)، پیش‌بینی عملکرد سیستم‌های آبیاری تحت فشار (Ababaei et al, 2013)، و قابلیت نگهداشت آب و ضریب آبگذری اشباع خاک (Merdun et al, 2006) استفاده کرده‌اند.

بررسی‌ها نشان می‌دهد از شبکه‌های عصبی مصنوعی در برآورد عملکرد محصولات زراعی کمتر استفاده شده‌اند. دراموند و همکاران (۲۰۰۳) برای تعیین روابط میان خصوصیات خاک، توپوگرافی و عملکرد غلات در منطقه میسوری آمریکا مطالعاتی را انجام دادند و مشاهده نمودند که روش شبکه‌های عصبی مصنوعی نسبت به روش‌های

مواد و روش‌ها

منطقه مورد مطالعه

به دلیل کمبود اطلاعات مکانی و زمانی (گسترده‌گی مکانی و طول دوره آماری) مربوط به عملکرد و طول دوره-های رشد محصولات مختلف در سطح کشور، در این مطالعه از داده‌های حاصل از شبیه‌سازی رشد و عملکرد گندم با استفاده از مدل AquaCrop در کل سطح اتحادیه اروپا (به انضمام بریتانیا) استفاده شده است (Ababaei et al., 2016). بانک‌های اطلاعاتی مورد استفاده در این مطالعه در جدول ۱ بطور مختصر معرفی شده‌اند. شبیه‌سازی بین سال‌های زراعی ۱۹۸۴ تا ۲۰۱۴ و تنها در مناطقی (نقاط شبکه ۲۵×۲۵ کیلومتری، موسوم به شبکه JRC) انجام گرفت که سطح کشت گندم بیش از ۱۰۰۰ هکتار گزارش شده است. اطلاعات روزانه هواشناسی بر روی همین شبکه ۲۵×۲۵ کیلومتری و از بانک اطلاعاتی Agri4Cast استخراج گردید. پارامترهای گیاهی با مقایسه نتایج شبیه‌سازی‌ها با عملکرد گندم در بانک اطلاعاتی EuroStat در مقیاس منطقه‌ای و نیز مقایسه نتایج شبیه‌سازی‌ها با دوره رشد گندم در بانک اطلاعاتی AgroPheno (با تمرکز بر زمان گلدهی) و واسنجی و برای هر منطقه ارزیابی شدند. داده‌های همین بانک اطلاعاتی، معیار انتخاب تاریخ کشت در هر یک از نقاط شبکه قرار گرفتند. منظور از منطقه در این مطالعه، مناطق موسوم به NUTS2^۱ می‌باشد که بطور معمول برای ارائه و طبقه‌بندی اطلاعات آماری در مقیاس ملی و منطقه‌ای در سطح اروپا مورد استفاده قرار می‌گیرند. اطلاعات خاکشناسی از بانک اطلاعات HWSN نسخه ۱/۲ در مقیاس ۱×۱ کیلومتر استخراج گردید.

سطح برگ پنبه در مصر با استفاده از شبکه عصبی مصنوعی کردند که بر اساس نتایج بدست آمده، زمانیکه ورودی‌های مدل شامل عرض برگ، طول آویز اصلی، طول آویز راست و چپ برگ باشد بهترین پیش‌بینی بدست می‌آید (Aboukarima et al., 2015). ساجیترا و همکاران (۲۰۱۸) میزان کود مورد نیاز برای درخت نارگیل را در واحد اکولوژیکی کشاورزی شمال ساحل کرالا با استفاده از دو نوع شبکه عصبی مصنوعی (DNN و ANN) پیش‌بینی کردند که میزان دقت DNN در مقایسه با ANN برای برآورد کود مورد نیاز بهتر بوده است (Suchithra et al., 2018). اکهند و همکاران (۲۰۱۸) طی پژوهشی که در بنگلادش بر روی عملکرد برنج با استفاده از شبکه عصبی مصنوعی انجام دادند، به نتایج امیدوارکننده‌ای دست یافتند و با مقایسه مقادیر پیش‌بینی شده عملکرد با داده‌های واقعی، مشخص شد این مدل با خطای پیش‌بینی کمتر از ۱۰٪ قادر به برآورد میزان عملکرد برنج در این منطقه می‌باشد (Akhand et al., 2018).

با توجه به احساس نیاز در جایگزینی مدل‌های گیاهی پیچیده با مدل‌های آماری ساده‌تر و نیز با توجه به عدم وجود سوابق قبلی در ارتباط با این نیاز، هدف از این پژوهش بررسی قابلیت شبکه عصبی در یادگیری از مدل‌های گیاهی و توانایی آن در پیش‌بینی عملکرد و شبیه‌سازی دوره‌های رشد گندم از کاشت تا گل‌دهی، کاشت تا برداشت و گل‌دهی تا برداشت با استفاده از متغیرهای اقلیمی و تعیین متغیرهای مهم برای برآورد عملکرد محصول و شبیه‌سازی دوره‌های حساس رشد گیاه می‌باشد.


جدول ۱: منابع اطلاعات استفاده شده برای شبیه سازی با مدل AquaCrop

نوع داده	منبع	متغیرها	توضیحات
هواشناسی	Agri4Cast Gridded Agro-Meteorological Data in Europe	دمای بیشینه (°C) دمای کمینه (°C) میانگین دما (°C) میانگین سرعت باد در ارتفاع ۱۰ متری (m/s) میانگین فشار بخار آب روزانه (hPa) بارش (mm/day) مجموع تشعشع (KJ/m2/day)	پایگاه CGMS شامل داده های هواشناسی از ایستگاه های هواشناسی است که در شبکه ۲۵×۲۵ کیلومتری درونیابی شده اند. داده های هواشناسی روزانه از ۱۹۷۵ تا کنون برای کشورهای اتحادیه اروپا، کشورهای همسایه اروپا و کشورهای خاورمیانه در دسترس می باشند.
سطح زیر کشت گندم	Agri4Cast European Crops Masks	سطح زیر کشت گندم در سطح شبکه ۲۵×۲۵ کیلومتری	این بانک اطلاعاتی از طریق ارتباطات شخصی تهیه شده است. این اطلاعات شامل داده های شبکه بندی شده برای ۸۴۸۶ نقطه در سطح شبکه ۲۵×۲۵ کیلومتری JRC (مشابه اطلاعات هواشناسی) می باشد.
خاک	Harmonized World Soil Database (HWSD) (42)	حداکثر عمق توسعه ریشه باقث خاک درصد مواد آلی چگالی ظاهری خاک	یک بانک اطلاعاتی رستری با شبکه بندی ۳۰ ثانیه (حدود ۱ کیلومتر) که از تجمیع اطلاعات نقشه FAO-UNESCO با مقیاس ۱:۵۰۰۰۰۰۰ و چندین نقشه بزرگ مقیاس دیگر ایجاد شده است.
فنولوژی (دوره های رشد)	AgroPheno (JRC-MARS)	تاریخ کشت تاریخ گلدهی تاریخ رسیدن	این بانک اطلاعاتی از طریق ارتباطات شخصی تهیه شده و شامل تاریخ های کاشت، جوانه زنی، گلدهی، رسیدن و برداشت برای ۲۲۸۲۳ سلول شبکه (مشابه اطلاعات هواشناسی) است. تاریخ کاشت تاریخ گلدهی برای ارزیابی مدل در شبیه سازی دوره های رشد استفاده شد.
عملکرد	EuroStat	داده های تاریخی عملکرد دانه در مقیاس منطقه ای و ملی	داده های تاریخی عملکرد دانه در سطح مناطق NUTS2 برای دوره ۲۰۱۰-۱۹۸۵ از بانک اطلاعات کشاورزی Eurostat استخراج شد. داده های عملکرد برای ارزیابی مدل در مقیاس منطقه ای استفاده شد.

روش انجام پژوهش

در این تحقیق، از شبکه عصبی مصنوعی چندلایه استفاده شد (شکل ۱). این شبکه دارای سه لایه نرون است. تعداد نرون در لایه اول برابر با تعداد عناصر ورودی و در لایه سوم یک نرون برای خروجی استفاده شد. ورودی های شبکه به صورت دسته ای و همزمان به شبکه اعمال شدند. در اینجا، ساختار شبکه با افزودن یا کاستن تعداد نرون ها در لایه های میانی تغییر یافت. روال آموزش و اعتبارسنجی برای هراسختار تکرار شد. در نهایت ساختاری که نتایج آن بر مبنای شاخص های آماری حداقل اختلاف را با مقادیر

مشاهده ای داشت به عنوان ساختار بهینه معرفی شد. قابل ذکر است که آموزش و ارزیابی عملکرد مدل های شبکه عصبی مصنوعی در محیط نرم افزار MATLAB انجام گرفت.



شکل ۱- ساختار یک شبکه عصبی مصنوعی

جدول ۲- متغیرهای اقلیمی مورد استفاده در مدل‌های شبکه عصبی مصنوعی

شماره متغیر ورودی	شرح ورودی‌ها
1	مجموع بارش بین کاشت تا گل‌دهی (mm)
2	مجموع بارش بین گل‌دهی تا برداشت (mm)
3	مجموع بارش بین کاشت تا برداشت (mm)
4	متوسط دمای هوا بین کاشت تا گل‌دهی (°C)
5	متوسط دمای هوا بین گل‌دهی تا برداشت (°C)
6	متوسط دمای هوا بین کاشت تا برداشت (°C)
7	متوسط دمای میانگین روزانه بین کاشت تا گل‌دهی (°C)
8	متوسط دمای میانگین روزانه بین گل‌دهی تا برداشت (°C)
9	متوسط حداکثر دمای روزانه بین کاشت تا گل‌دهی (°C)
10	متوسط حداکثر دمای روزانه بین گل‌دهی تا برداشت (°C)
11	متوسط تابش خورشیدی روزانه بین کاشت تا گل‌دهی (MJ/m ²)
12	متوسط تابش خورشیدی روزانه بین گل‌دهی تا برداشت (MJ/m ²)
13	مجموع تابش خورشیدی روزانه بین کاشت تا گل‌دهی (MJ/m ²)
14	مجموع تابش خورشیدی روزانه بین گل‌دهی تا برداشت (MJ/m ²)
15	متوسط فشاربخار میانگین روزانه بین کاشت تا گل‌دهی (kPa)
16	متوسط فشاربخار میانگین روزانه بین گل‌دهی تا برداشت (kPa)

مدیریت زراعی، امکان استفاده از این اطلاعات در مدل‌های- گیاهی همچون AquaCrop است. طول دوره‌های رشد مهم گیاه (به صورت طول دوره یا درجه-روز مورد نیاز برای تکمیل دوره) از مهمترین متغیرهای ورودی به مدل‌های گیاهی هستند.

به دلیل سهولت بیشتری دسترسی به داده‌های بارش و دما در مقایسه با سایر متغیرهای اقلیمی، برای مدل‌سازی طول دوره‌های مهم رشد گندم تنها از داده‌های بارش و دما (متغیرهای ۱-۶) استفاده گردید. علت پیش‌بینی دوره‌های مهم رشد گیاه گندم در این مطالعه علاوه بر اهمیت این دوره‌ها در

جدول ۳- مشخصات مدل‌های شبکه عصبی

شماره مدل شبکه عصبی	عوامل ورودی	عوامل خروجی
۲	۷-۱۶	عملکرد دانه در زمان برداشت (kg/ha)
۳	۱-۶	طول دوره رشد از کاشت تا جوانه زنی (روز)
۴	۱-۶	طول دوره رشد از جوان زنی تا ساقه رفتن (روز)
۵	۱-۶	طول دوره رشد از ساقه رفتن تا گل‌دهی (روز)
۶	۱-۶	طول دوره رشد از گل‌دهی تا پرشدن غلاف (روز)
۷	۱-۶	طول دوره رشد از کاشت تا گل‌دهی (روز)
۸	۱-۶	طول دوره رشد از کاشت تا گل‌دهی (روز)
۹	۱-۶	طول دوره رشد از گل‌دهی تا برداشت (روز)
۱۰	۱-۶	طول دوره رشد از کاشت تا برداشت (روز)

و مدل شماره ۲ (متغیرهای ۱۶-۷) با ورودی‌های دما، تابش-خورشیدی و فشاربخار آب با مقادیر R^2 و SRMSE به ترتیب در آموزش ۰/۹۷ و ۹/۶۹٪ و در اعتبارسنجی ۰/۹۶ و ۱۱/۵۷٪ است. در ادامه تاثیر افزودن متغیرهای تابش خورشیدی و متوسط فشاربخار آب مورد بررسی قرار گرفت.

در پژوهش مشابهی که سجادی و همکاران (۱۳۹۱) بر روی گیاه کلزا در منطقه گنبد گلستان انجام دادند این نتیجه حاصل شد، شبکه عصبی که دارای کمترین مقدار RMSE برابر با ۱۰۱/۲۳ و بیشترین مقدار R^2 برابر با ۰/۹۹۷ بود در میان ساختارهای مختلف شبکه عصبی بعنوان ساختار بهینه انتخاب شد (Sajadi et al., 2012). اندرزیان و همکاران (۲۰۱۱) طی پژوهشی گزارش کردند که مدل AquaCrop بخوبی توانسته رطوبت خاک، زیست توده محصول و عملکرد دانه را شبیه‌سازی کند. این محققان ریشه دوم خطای میانگین مربعات نرمال را کمتر از ۱۰٪ بدست آوردند (Andarzian et al., 2011). رضانی اعتدالی و همکاران (۲۰۰۹) کارایی مدل Cropwat را حدود ۰/۵۸ و -۰/۱۵ برای گندم در دور آبیاری ۷ و ۱۴ روز (Ramezani-Etedali et al., 2009) و عزیزاده و همکاران (۲۰۱۰) نیز کارایی مدل AquaCrop را ۰/۹۸ و ۰/۷۶ برای دور آبیاری ۷ و ۱۴ روز (Alizadeh et al., 2010) گزارش کردند. همچنین حداکثر خطای نسبی برای پیش‌بینی عملکرد گندم توسط مدل CropWat حدود ۲۵ و توسط مدل AquaCrop حدود ۲۷ درصد گزارش شده‌است. نتیجه ارزیابی مدل AquaCrop توسط آرایا و همکاران (۲۰۱۰) در اتیوپی نشان می‌دهد که این مدل جرم توده هوایی و عملکرد محصول را در تاریخ‌های کشت متفاوت در منطقه مورد مطالعه به خوبی شبیه‌سازی می‌کند (Araya et al., 2010).

همانطور که جدول ۴ نشان می‌دهد، لحاظ کردن این پارامترها تاثیر چندانی بر روی شاخص R^2 نداشته اما باعث کاهش شاخص MSE شده است. بنابراین تنها با استفاده از متغیرهای اقلیمی مربوط به بارش و دما (مدل شبکه عصبی شماره ۱) که به آسانی در دسترس‌اند، می‌توان میزان عملکرد گیاه را با دقت قابل قبولی برآورد کرد.

در نهایت به منظور مقایسه کمی مقادیر محاسبه و مشاهداتی از شاخص‌های آماری ضریب تبیین (R^2) بین مقادیر اندازه‌گیری شده و پیش‌بینی شده، SRMSE (جذر میانگین مربعات خطاهای استاندارد شده) استفاده شد:

$$SRMSE = 100 \times \frac{\sqrt{\frac{\sum (y_p - y_o)^2}{n}}}{\bar{y}_o} \quad (1)$$

$$R^2 = \frac{[\sum_{i=1}^n (y_p - \bar{y}_p)]^2}{\sum_{i=1}^n (y_p - \bar{y}_p)^2} \quad (2)$$

که در آن y_p مقدار پیش‌بینی شده عامل مورد نظر، y_o مقدار مشاهده‌ای عامل مورد نظر، \bar{y}_p میانگین مقادیر پیش‌بینی شده عامل‌های مورد نظر، \bar{y}_o میانگین مقادیر مشاهده‌ای عامل‌های مورد نظر و n تعداد داده مورد استفاده در محاسبات است. در رابطه با این دو معادله قابل ذکر است که SRMSE بصورت درصد اختلاف نسبی مقادیر پیش‌بینی شده در برابر مقادیر واقعی بیان می‌شود و براساس تعریف، قدرت پیش‌بینی مدل در صورتیکه مقدار SRMSE 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).

نتایج و بحث

پیش‌بینی عملکرد

با استفاده از شبکه عصبی مصنوعی در نرم‌افزار متلب، مدل‌های متعدد با ساختارها و متغیرهای ورودی متفاوت برای پیش‌بینی عملکرد و دوره‌های مهم رشد گندم تعریف شد. نتایج پیش‌بینی عملکرد در جدول ۴ ارائه شده است. مدل‌های شماره ۱ و ۲ مربوط به پیش‌بینی عملکرد با استفاده از متغیرهای اقلیمی (بارش، دما، تابش خورشیدی و فشاربخار آب) است. براساس نتایج ارائه شده، بهترین معماری شبکه عصبی در مدل شماره ۱ با ورودی‌های بارش و دما (متغیرهای ۱-۶) و مقادیر R^2 و SRMSE به ترتیب در آموزش ۰/۹۴ و ۱۳٪/۶۱ و در اعتبارسنجی ۰/۹۳ و ۱۴/۵۵٪

پیش‌بینی دوره‌های رشد

استفاده از مدل‌های شبیه‌سازی به دلیل هزینه پایین، سرعت بالا و در اختیار قرار دادن اطلاعات کامل گزینه مناسبی برای تکمیل و توسعه نتایج آزمایش‌های مزرعه‌ای محسوب می‌شوند (Singh et al., 2008). پیش‌بینی صحیح مراحل رشد گیاهان زراعی برای بهینه‌سازی فعالیت‌های مدیریتی در مزرعه و سازگاری بهتر تقویم زراعی با سیستم‌های اگرواکولوژیک خاص، بسیار مهم است (Khanal, 2005). فاصله زمانی کاشت تا گلدهی یکی از خصوصیات مهم برای پیش‌بینی عملکرد و دستیابی به عملکرد بالقوه گیاهان زراعی از جمله گندم در مناطق مختلف می‌باشد. متخصصان مدل‌سازی گیاهان زراعی اقدام به ارائه فرمول‌های کمی اکوفیزیولوژی برای تشریح پاسخ‌های فتوترمال فنولوژی نموده‌اند تا بتوانند زمان گلدهی ژنوتیپ‌های مختلف گیاهان زراعی را در شرایط متفاوت محیطی و اقلیمی پیش‌بینی نمایند (Yin et al., 2005). مدل‌های

مختلفی برای شبیه‌سازی رشد گندم توسعه داده شده‌اند، از جمله این مدل‌ها می‌توان به CERES-Wheat، WOFOST، APSIM و AquaCrop اشاره نمود. در مطالعه‌ای که دلقندی و همکاران (۱۳۹۳) به منظور ارزیابی مدل CERES-Wheat در شرایط آب و هوایی اهواز انجام دادند، توانایی بسیار بالای این مدل در شبیه‌سازی عملکرد و مراحل فنولوژیکی رشد گندم مورد تایید قرار گرفت (Delghandi et al., 2014).

در جدول ۴، نتایج پیش‌بینی طول دوره‌های مهم رشد گندم با متغیرهای اقلیمی در شبکه عصبی نیز ارائه شده است. مطابق جدول، مدل شبکه عصبی شماره ۹ با مقادیر R^2 و SRMSE به ترتیب در آموزش ۰/۹۸ و ۰/۴/۷۹ و در اعتبارسنجی ۰/۹۷ و ۰/۵/۷۴ مناسب‌ترین ساختار شبکه عصبی مصنوعی برای پیش‌بینی طول دوره رشد شناخته شد.

جدول ۴- نتایج مدل‌سازی عملکرد و طول دوره رشد گندم



شماره مدل	عاملهای ورودی	تعداد نرون در لایه پنهان	۵	۱۰	۱۵	۲۰	
۱	۱-۶	تعداد نرون‌های لایه ورودی	۶				
		Training	R^2	۰,۹۳	۰,۹۳	۰,۹۴	۰,۹۲
			SRMSE (%)	۱۵,۱۴	۱۴,۴۸	۱۳,۶۱	۱۵,۷۲
		Validating	R^2	۰,۹۲	۰,۹۲	۰,۹۳	۰,۹۲
SRMSE (%)	۱۵,۷۸		۱۵,۴۳	۱۴,۵۵	۱۶,۱۴		
۲	۷-۱۶	تعداد نرون‌های لایه ورودی	۱۲				
		Training	R^2	۰,۹۶	۰,۹۷	۰,۹۷	۰,۹۷
			SRMSE (%)	۱۱,۲۵	۱۰,۱۷	۱۰,۱۲	۹,۶۹
		Validating	R^2	۰,۹۵	۰,۹۶	۰,۹۵	۰,۹۶
SRMSE (%)	۱۲,۵۶		۱۱,۰۳	۱۱,۹۲	۱۱,۵۷		
۳	۱-۶	تعداد نرون‌های لایه ورودی	۶				
		Training	R^2	۰,۸۹	۰,۹۱	۰,۹۲	۰,۹۳
			SRMSE (%)	۷,۳۳	۷,۸۳	۶,۰۹	۶,۱۳
		Validating	R^2	۰,۸۹	۰,۹۰	۰,۹۲	۰,۹۲
SRMSE (%)	۷,۸۳		۶,۹۱	۶,۴۱	۶,۲۰		

ادامه جدول ۴

شماره مدل	عوامل ورودی	تعداد نرون در لایه پنهان	۵	۱۰	۱۵	۲۰	
۴	۱-۶	تعداد نرون های لایه ورودی		۶			
		Training	R ²	۰,۷۰	۰,۷۵	۰,۷۶	۰,۷۸
			SRMSE (%)	۱۵,۸۸	۱۵,۷۵	۱۴,۶۶	۱۳,۷۶
		Validating	R ²	۰,۷۲	۰,۷۱	۰,۷۷	۰,۷۴
			SRMSE (%)	۱۵,۷۵	۱۴,۸۰	۱۴,۲۱	۱۵,۲۱
		۵	۱-۶	تعداد نرون های لایه ورودی		۶	
Training	R ²			۰,۷۸	۰,۸۲	۰,۸۳	۰,۸۱
	SRMSE (%)			۸,۵۷	۹,۳۰	۷,۷۱	۸,۰۳
Validating	R ²			۰,۷۸	۰,۸۱	۰,۸۱	۰,۸۰
	SRMSE (%)			۹,۳۰	۸,۱۴	۷,۸۹	۸,۵۷
۶	۱-۶			تعداد نرون های لایه ورودی		۶	
		Training	R ²	۰,۹۵	۰,۹۶	۰,۹۵	۰,۹۶
			SRMSE (%)	۴,۷۰	۴,۵۶	۴,۴۸	۴,۲۳
		Validating	R ²	۰,۹۵	۰,۹۶	۰,۹۵	۰,۹۶
			SRMSE (%)	۴,۵۶	۴,۴۲	۴,۶۶	۴,۵۰
		۷	۱-۶	تعداد نرون های لایه ورودی		۶	
Training	R ²			۰,۹۶	۰,۹۷	۰,۹۷	۰,۹۷
	SRMSE (%)			۷,۶۴	۷,۶۷	۶,۸۵	۶,۹۶
Validating	R ²			۰,۹۶	۰,۹۶	۰,۹۷	۰,۹۷
	SRMSE (%)			۷,۶۷	۷,۴۵	۶,۹۵	۶,۹۳
۸	۱-۶			تعداد نرون های لایه ورودی		۶	
		Training	R ²	۰,۹۰	۰,۹۴	۰,۹۳	۰,۹۴
			SRMSE (%)	۵,۶۸	۵,۵۶	۴,۷۳	۴,۳۴
		Validating	R ²	۰,۹۱	۰,۹۳	۰,۹۳	۰,۹۳
			SRMSE (%)	۵,۵۶	۴,۶۶	۴,۸۳	۴,۹۵
		۹	۱-۶	تعداد نرون های لایه ورودی		۶	
Training	R ²			۰,۹۷	۰,۹۸	۰,۹۸	۰,۹۷
	SRMSE (%)			۶,۱۶	۶,۳۰	۴,۷۹	۵,۲۶
Validating	R ²			۰,۹۶	۰,۹۷	۰,۹۷	۰,۹۸
	SRMSE (%)			۶,۳۰	۵,۲۶	۵,۷۴	۵,۲۹
۱۰	۱-۶			تعداد نرون های لایه ورودی		۶	
		Training	R ²	۰,۹۱	۰,۹۲	۰,۹۳	۰,۹۳
			SRMSE (%)	۵,۴۵	۵,۳۲	۴,۷۰	۴,۹۴
		Validating	R ²	۰,۹۱	۰,۹۱	۰,۹۴	۰,۹۲
			SRMSE (%)	۵,۳۲	۵,۵۸	۴,۵۵	۴,۸۷

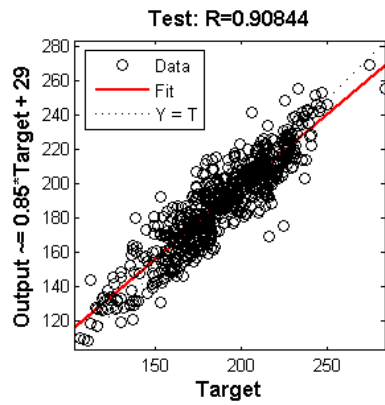

(ب)

(الف)





(د)





(ج)



(و)

(ه)





شکل ۲- بررسی بهترین برازش ها برای متغیر خروجی، الف) مدل شماره ۱ با ۱۵ نرون در لایه پنهان، ب) مدل شماره ۲ با ۲۰ نرون در لایه پنهان، ج) مدل شماره ۳ با ۲۰ نرون در لایه پنهان، د) مدل شماره ۴ با ۲۰ نرون در لایه پنهان، ه) مدل شماره ۵ با ۱۵ نرون در لایه پنهان، و) مدل شماره ۶ با ۲۰ نرون در لایه پنهان، ز) مدل شماره ۷ با ۱۵ نرون در لایه پنهان، ح) مدل شماره ۸ با ۲۰ نرون در لایه پنهان، ط) مدل شماره ۹ با ۱۵ نرون در لایه پنهان، ی) مدل شماره ۱۰ با ۱۵ نرون در لایه پنهان.

دوره رشد گیاه مورد ارزیابی قرار گرفت. نتایج ارزیابی نشان داد که مدل شبکه عصبی شماره ۶ بیشترین تطابق را با خروجی های مدل گیاهی دارد. بطوریکه مقدار شاخص های SRMSE و MSE برای این مدل به ترتیب در بازه ۴/۲۳-۴/۷ درصد و ۰/۱۷-۰/۱۵ می باشند.

در واقع این نتایج نشان دهنده آنست که برای هر دو پارامتر مورد بررسی، مقدار عملکرد و طول دوره رشد را به مقدار بسیار کمی بیشتر از مقادیر واقعی نشان می دهد که این

نتایج حاصل از این مطالعه با تحقیقات قبلی انجام شده در این زمینه هماهنگی نزدیکی دارد. بطوریکه دقت پیش بینی عملکرد گندم توسط حسینی و همکاران (۲۰۰۷) در منطقه قروه کردستان با استفاده از شبکه مصنوعی برابر با ۰/۹۹ بود اما درباره ساختار شبکه عصبی مورد استفاده اطلاعاتی گزارش نشده است (Hosaini et al, 2007).

همچنین مدل های شبکه عصبی با شاخص های آماری SRMSE و MSE برای هر یک از پارامترهای عملکرد و طول

۳- آبابایی، ب.، رضاوردی‌نژاد، و. ۱۳۹۲. برآورد عملکرد هیدرولیکی سیستم‌های آبیاری تحت فشار با استفاده از مدل‌های شبکه عصبی مصنوعی و رگرسیون ناپارامتری. مجله آب و خاک، دانشگاه فردوسی مشهد. ۲۷(۴): ۷۶۹-۷۷۹.

۴- سجادی، ج.، صبوری، ح. ۱۳۹۱. کاربرد شبکه‌های عصبی مصنوعی در پیش‌بینی عملکرد محصول کلزا. مجله تولید و فرآوری محصولات زراعی و باغی، سال سوم، شماره دهم.

۵- دلقدی، م.، اندرزیان، ب.، برومند نسب، س.، مساح بوانی، ع.، جواهری، ا. ۱۳۹۳. ارزیابی مدل CERES-Wheat نسخه 4.5 در شبیه‌سازی رشد، عملکرد و مراحل فنولوژی گندم در شرایط مدیریت‌های مختلف تخصیص آب در مزرعه (مطالعه موردی: شهرستان اهواز). نشریه آب و خاک، دانشگاه فردوسی مشهد. ۲۸(۱): ۸۲-۹۱.

6- Ababaei, B., Sohrabi, T., Mirzaei, F. 2012. Assessment of radial basis and generalized regression neural networks in daily reservoir inflow simulation. *Elixir Comp. Sci. & Engg.* 42(2012) 6074-6077.

7- Ababaei, B., Derery, J., Martre, P. 2016. Recent changes in spatiotemporal patterns of pan-European wheat yield gap and environmental stresses. *Native Trait, Limagrain Europe.* Clermont-Ferrand, France.

8- Aboukarima, A.M., Elsoury, H.A., and Menyawi, M. 2015. Artificial Neural Network Model for the Prediction of the cotton Crop Leaf Area. *International Journal of Plant & Soil Science.* 8(4): 1-13.

9- Alvarez, A. 2009. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. *Eur J. Agron.* 30: 70-77.

10- Alizadeh, H. A., Nazari, B., Parsinejad, M., Ramezani-Eetedali, H. and Janbaz, H. R. 2010. Evaluation of AquaCrop model on wheat deficit irrigation in Karaj area. *Iranian J. Irrig. Drain.* 2(4): 273-283. (in Farsi)

11- Andarzian, B., Bannayan, M., Steduto, P., Mazraeh, H., Barati, M.E. and Rahnema, A. 2011. Validation and Testing of the AquaCrop Model

موضوع حاکی از دقت نسبتاً بالای مدل‌های شبکه عصبی توسعه یافته در این تحقیق برای پیش‌بینی عملکرد و طول دوره رشد گندم است.

نتیجه‌گیری

در این پژوهش به بررسی کارایی شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد و طول دوره‌های مهم رشد گندم با استفاده از پارامترهای اقلیمی و امکان جایگزینی مدل‌های پیچیده گیاهی با این مدل‌های آماری پرداخته شد. نتایج نشان داد که هنگامی که مجموع بارش و متوسط دمای هوا به عنوان ورودی به مدل معرفی می‌شود، شبکه‌های عصبی مصنوعی می‌توانند عملکرد و طول دوره‌های رشد گیاه را با دقت نسبتاً خوبی شبیه‌سازی کنند. همچنین با بررسی متغیرهای هواشناسی موجود مشخص شد که افزودن متغیرهای تابش خورشیدی و رطوبت نسبی به ورودی‌های مدل تاثیر چندانی بر کیفیت پیش‌بینی طول دوره‌های رشد نداشته و به همین سبب در شبیه‌سازی مقادیر آن تنها از متغیرهای بارش و دما (قبل از جوانه زنی تا پس از بلوغ گیاه) استفاده گردید که به آسانی قابل اندازه‌گیری و در دسترس اند. این در حالی است که برای پیش‌بینی عملکرد گندم، با وجود اختلاف ناچیز بین دو مدل، مدلی که در آن تعداد ورودی‌ها بیشتر بوده بهترین کارایی را نشان داد. براساس نتایج این پژوهش، کارایی شبکه‌های عصبی مصنوعی برای یادگیری از مدل‌های گیاهی و پیش‌بینی عملکرد و طول دوره‌های مهم فصل رشد گندم با استفاده از متغیرهای اقلیمی با دقت نسبتاً بالایی مورد تایید قرار گرفت.

منابع

۱- خداپنده ن.، ۱۳۷۷. غلات. انتشارات دانشگاه تهران.

۲- شیردلی ع.، توسلی ا. ۱۳۹۴. پیش‌بینی عملکرد و کارایی مصرف آب زعفران با استفاده از مدل‌های شبکه عصبی مصنوعی بر مبنای فاکتورهای اقلیمی و آب، نشریه زراعت و فناوری زعفران، ۳(۲): ۱۲۱-۱۳۱.

- 22- 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 Agric Scandinavica, Section B-Plant Soil Sci.* 60: 341-352.
- 23- Pandey, A., Mishra, A. 2017. Application of Artificial Neural Networks in Yield Prediction of Potato Crop. *Russian Agricultural Sciences.*43(3): 266-272.
- 24- Piri, J., Amin, S., Moghaddamnia, A., Keshavarz, A., Han, D., and Remesan, R. 2009. Daily pan evaporation modeling in a hot and dry climate. *Hydrol Eng, ASCE.* 14: 803-811.
- 25- Ramezani-Etedali, H., Nazari, B., Tavakoli, A. R. and Parsinejad, M. 2009. Evaluation of CROPWAT model in deficit irrigation management of wheat and barley in Karaj. *J. Water Soil.* 23(1): 119-129.(in Farsi).
- 26- Singh A.K., Tripathy R., and Chopra U.K. 2008. Evaluation of CERES-Wheat and CropSyst models for water-nitrogen interactions in wheat crop. *Agricultural Water Management.* 95: 776-786.
- 27- Smith, B.A., Hoogenboom, G., and McClendon, R.W. 2009. Artificial neural Networks for automated year-round temperature prediction. *Comp. Electron Agric.* 68: 52-61.
- 28- Suchithra, M.S., Pai, Maya.L. 2018. Impact of Deep Neural Network on Predicting Application Rate of Fertilizers (Focus on Coconut Trees of Kerala Northern Coastal Plain Agro Ecological Unit). *International Journal of Pure and Applied Mathematics.* 119(10): 451-466.
- 29- 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).
- 30- Yin, Xinyou., P. C. Struik, J. Tang, Ch. Qi and T. Liu. 2005. Model analysis of flowering phenology in recombinant inbred lines of barley. *J. Exp. Bot.* 56(413): 959-965.
- under Full and Deficit Irrigation Wheat Production in Iran. *Agricultural Water Management.*100: 1-8.
- 12- 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: 1. 5-14.
- 13- Hosaini, M. T., A. Siosemarde, P. Fathi and M. Siosemarde. 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. *Agricultural Research* 7(1) :41-54 (in Farsi)
- 14- Jain, A.K., Mao, J., and Mohiuddin, K.M. 1996. Artificial Neural Networks: a tutorial computer. *IEEE,* Pp: 31-44.
- 15- Kaul, M., Hill, R.L., and Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agric Sys.* 85: 1-18.
- 16- Khanal, R. R. 2005. Phyllochron and leaf development in field grown rice genotypes under varying thermal environments of a high altitude cropping system. MSc. Thesis. Univ. of Zu Bonn. Germany.
- 17- Kim, M., and Gilley, J. E. 2008. Artificial neural network estimation of soil erosion and nutrient concentrations in runoff from land application areas.
- 18- Landeras, G., Ortiz-Barredo, A., and López, J.J. 2009. Forecasting weekly evapotranspiration with ARIMA and artificial neural network models. *Irrigation and Drainage Engineering, ASCE.* 135: 323-334.
- 19- Merdun, H., Çınar, Ö., Meral, R., and Apan, M. 2006. Comparison of artificial neural network and regression pedotransfer functions for prediction of soil water retention and saturated hydraulic conductivity. *Soil. Till Res.* 90: 108-116.
- 20- Mubiru, J. 2008. Predicting total solar irradiation values using artificial neural networks. *Renewable Energy.* 33: 2329-2332.
- 21- Mukerji, A., Chatterjee, C., and Raghuwanshi, N.S. 2009. Flood forecasting using ANN, Neuro-Fuzzy, and Neuro-GA models. *Hydrol Eng. ASCE.* 14: 647-652.