

## توسعه توابع تولید غلات مهم دشت قزوین در شرایط کم آبی و تنش شوری با استفاده از مدل AquaCrop و شبکه عصبی مصنوعی

سارا بلوک آذری، حسین بابازاده<sup>۱</sup>، نیازعلی ابراهیمی پاک، سیدحبیب موسوی جهرمی و

هادی رضانی اعتدالی

دانشجوی دکتری، گروه علوم و مهندسی آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

sara.bulukazari@yahoo.com

استاد، گروه علوم و مهندسی آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

h\_babazadeh@srbiau.ac.ir

دانشیار، بخش آبیاری موسسه تحقیقات خاک و آب، سازمان تحقیقات، آموزش و ترویج کشاورزی، کرج، ایران.

nebrahimipak@yahoo.com

استاد، گروه عمران-مهندسی و مدیریت منابع آب، دانشگاه آزاد اسلامی واحد شهرقدس، تهران، ایران.

h-mousavi@srbiau.ac.ir

دانشیار، گروه علوم و مهندسی آب، دانشگاه بین المللی قزوین، قزوین، ایران.

ramezani@eng.ikiu.ac.ir

دریافت: اردیبهشت ۱۴۰۰ و پذیرش: شهریور ۱۴۰۰

### چکیده

در بهره‌برداری از آب‌های با کیفیت پایین در مناطق خشک و نیمه‌خشک، مدیریت آبیاری برای افزایش بهره‌وری مصرف آب ضروری می‌باشد. تعیین تابع تولید آب-شوری-عملکرد ابزار مهمی برای مدیریت آبیاری است. در این پژوهش، توانایی مدل گیاهی AquaCrop در مدیریت‌های مختلف آبیاری و در سطوح مختلف شوری برای غلات عمده دشت قزوین شامل گندم، جو و ذرت ارزیابی شد. نتایج بررسی، ضریب تبیین را برای عملکرد گندم، جو و ذرت به ترتیب ۰/۹۷، ۰/۸۶ و ۰/۹۱- نشان داد. بنابراین مدل مزبور در شرایط شوری و کم آبیاری با تقریب خوبی می‌تواند عملکرد را ارزیابی نماید. برای تعیین توابع تولید بهینه هر محصول نتایج مدل گیاهی با سه مدل رگرسیون خطی، غیرخطی و همچنین شبکه عصبی مصنوعی مقایسه گردید. نتایج نشان داد که مدل شبکه عصبی توانست عملکرد را نسبت به مدل AquaCrop با همبستگی بالا (۰/۹۹) برآورد نماید. در صورتی که این مقادیر در تابع خطی برای گیاه گندم و جو و ذرت به ترتیب ۰/۹۸، ۰/۹۵، ۰/۷۸ و در تابع نمایی ۰/۹۲، ۰/۸۶ و ۰/۸۱ بود. همچنین، خطای محاسبه شده در روش شبکه عصبی برای گیاه گندم، جو، ذرت به ترتیب ۰/۱۶، ۰/۰۹ و ۰/۰۹ کیلوگرم بود که این میزان به ترتیب در مقایسه با مدل خطی ۰/۷۵٪، ۰/۷۰٪ و ۰/۹۵٪ و نسبت به مدل نمایی ۰/۹۰٪، ۰/۸۵٪ و ۰/۹۳٪ کاهش داشت. بهترین شبکه آموزش دیده برای تعیین تابع تولید آب-شوری برای جو و گندم پنج نرون و برای ذرت هفت نرون در ساختار شبکه‌ی تک لایه معرفی گردید. تحلیل حساسیت به کار رفته برای گیاهان گندم و جو نشان داد که مدل‌های رگرسیون خطی، نمایی و شبکه عصبی نسبت به پارامتر مقدار آب آبیاری و میزان شوری آب و خاک حساسیت کم دارند و تنها حساسیت گیاه ذرت نسبت به پارامتر شوری خاک در محدوده متوسط قرار گرفت.

واژه‌های کلیدی: تحلیل حساسیت، گندم، جو، ذرت، مدیریت آبیاری

<sup>۱</sup> - آدرس نویسنده مسئول: گروه علوم و مهندسی آب، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

امروزه در بسیاری از مناطق خشک و نیمه خشک، کاهش کمیت منابع آبی با شور شدن منابع آب و خاک همراه شده است (فلاح و همکاران، ۱۳۹۱). به طوری که محدودیت منابع آب با کیفیت مناسب باعث شده است تا کشاورزان برای دستیابی به تولید محصولات، آب‌های با کیفیت نامناسب را برای آبیاری به کار برند. در نتیجه استفاده مداوم از این منابع موجب تجمع بیش از حد نمک‌ها در خاک شده به طوری که در برخی مناطق بسیاری از گیاهان زراعی با مشکلاتی مواجه شده است (آمزکاتا و همکاران، ۲۰۰۶). شوری آب و خاک‌های زراعی و کمبود آب از محدودیت‌های عمده تولید محصولات زراعی در این مناطق می‌باشند و گیاهان بر حسب کمیت و کیفیت آب ممکن است تحت تاثیر همزمان شوری و خشکی قرار گیرند (کمالی و همکاران، ۱۳۹۶: جیانگ و همکاران، ۲۰۱۶). به گونه‌ای که براساس گزارش فائو در مناطق شور، این مساله سبب کاهش ۱۰ الی ۶۰ درصدی عملکرد گیاهان زراعی شده است (فائو، ۲۰۰۸). تأثیر توأم تنش شوری و کم‌آبی بر جذب آب و در نتیجه آن بر عملکرد محصولات در یک مکان خاص به نوع گیاه، تناوب آبیاری، خصوصیات شیمیایی و فیزیکی خاک، اقلیم و کیفیت آب آبیاری بستگی دارد (شهیدی و همکاران، ۱۳۸۹). تنش آبی ناشی از کم‌آبیاری با استفاده از آب شور، جذب آب توسط گیاه را محدود می‌کند (فرهنگیان و همکاران، ۲۰۱۰). شوری خاک فاکتور اثرگذار در تولید محصول است که کمتر مورد توجه قرار می‌گیرد (ژانگ و همکاران، ۲۰۱۸). تاثیر شوری تنها به یک مرحله خاص از رشد گیاه محدود نمی‌شود بلکه در تمام طول دوره رشد گیاه موثر بوده و در نهایت به کاهش عملکرد محصول منجر می‌شود. در این شرایط راهکار مناسب برای مقابله با کاهش عملکرد استفاده از ارقام مقاوم به شوری می‌باشد. البته شایان ذکر است حتی ژنوتیپ‌های مقاوم به شوری در مرحله جوانه زنی به شوری حساس می‌باشند (فرهنگیان و همکاران، ۲۰۱۰). آگاهی دقیق از

رابطه بین کمیت و کیفیت آب مصرفی و عملکرد (CWPFs) محصول در شرایط توأم شوری و کم‌آبی ضروری می‌باشد (یزدانی و همکاران، ۱۳۹۳: شین و همکاران، ۲۰۱۶: فاستر و همکاران ۲۰۱۸). روش‌های تعیین تابع تولید (CWPFs) شامل آزمایش‌های مزرعه‌ای و مدل‌سازی می‌باشد که پرهزینه و زمانبر است. توابع تجربی مرسوم نیز از لحاظ منطقه‌ای قابل گسترش نمی‌باشند (براملو و جورگاکالوس، ۲۰۰۷: داتا و همکاران، ۱۹۹۸: ژانگ و همکاران، ۲۰۱۸). مدل‌های شبیه‌ساز گیاه مانند APSIM و swap و CERES، WOFOST، AquaCrop و ... جایگزین مناسب برای تخمین عملکرد در برابر آب و شرایط محیطی می‌باشند. مدل AquaCrop به نسبت مدل‌های شبیه‌ساز دیگر، پارامترها و داده‌های ورودی کمتری برای شبیه‌سازی واکنش گیاه به آب احتیاج دارد و برای اغلب محصولات گیاهی و زراعی در سراسر جهان قابل استفاده است. در مطالعات متعددی از مدل AquaCrop برای شبیه‌سازی عملکرد در شرایط تنش شوری استفاده شده است. نتایج حاکی از کارایی قابل قبول و مناسب مدل در شبیه‌سازی عملکرد محصولات بوده است (خرسند و همکاران، ۱۳۹۳؛ مهرآذر و همکاران، ۱۳۹۴؛ حیدری نیا و همکاران، ۱۳۹۶: گارسیا ویلا و همکاران، ۲۰۱۲: کیم و همکاران، ۲۰۱۲: محمدی و همکاران، ۲۰۱۶). اجرای مدل‌های شبیه‌ساز گیاهان و لینک شدن آن‌ها با سایر مدل‌ها دارای معضلات و مشکلات می‌باشد. به همین دلیل گاهی مدل‌هایی مانند مدل‌های رگرسیونی و انواع پیچیده‌تر آن براساس جهت شبیه‌سازی عملکرد گیاهان استفاده می‌شوند. مدل‌های جایگزین ارائه شده در مطالعات مختلف دارای خطای شبیه‌سازی مشابه با مدل‌های شبیه‌سازی گیاهان می‌باشند که با کاهش خطای آن‌ها می‌توان به کارایی آن‌ها بیشتر اتکا نمود (حیدری نیا و همکاران، ۱۳۹۶؛ کیم و همکاران، ۲۰۱۵: محمدی و همکاران ۲۰۱۶). یکی از روش‌های مدل‌سازی که در سال‌های اخیر مورد توجه بسیاری از محققین در علوم مختلف واقع شده است، مدل‌سازی به روش شبکه‌های عصبی مصنوعی می‌باشد.

عملکرد گندم توسط این روش را بسیار ناچیز برآورد نمودند ( $RMSE=0/05$ ) و همچنین عملکرد جو با چهار لایه پنهان و میزان خطای  $33/12$  و ضریب تبیین  $0/81$  بهترین شرایط توسط شبکه عصبی برای شبیه سازی برآورد گردید (چوپان و امامی، ۲۰۱۹) در حالی که کمترین میزان خطا برای شبیه سازی عملکرد گوجه فرنگی در شرایط سه لایه پنهان می باشد (لوپز آگیلار، ۲۰۲۰). از آن جایی که امکان بررسی هم زمان اثرات آب، اقلیم، 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 می باشد. از طرفی دقت تمامی مدل ها تابعی از ورودی های آن ها می باشد. بنابراین شناسایی پارامترهای ورودی مؤثر از اهمیت ویژه ای برخوردار است از طرفی مدل هایی که با پارامترهای ورودی کمتر قادر به ارائه نتایج نزدیک تری نسبت به واقعیت باشند، گزینه های مطلوب تر به شمار می روند. بررسی ها نشان داده است مطالعات نسبتاً محدودی در خصوص تولید تابع تولید در شرایط توام شوری و کم آبی توسط مدل های مختلف و مقایسه آن ها انجام شده است. لذا در این مطالعه ابتدا مدل AquaCrop به کمک چندین سری داده میدانی از چندین نوع خاک با شوری های مختلف برای سه محصول غالب در دشت قزوین شامل گندم، جو و ذرت واسنجی می گردد، سپس به کمک الگوریتم مونت کارلو به تعداد مورد نیاز برای تولید مجموعه داده های لازم برای آموزش شبکه عصبی مصنوعی جهت جایگزینی مدل AquaCrop در شرایط تنش آبی و شوری پرداخته شد و در نهایت پارامترهایی که تاثیر بیشتری بر عملکرد گیاه دارند به عنوان ورودی مدل انتخاب شده و میزان عملکرد با استفاده از شبکه های عصبی مصنوعی شبیه سازی و آنالیز حساسیت مدل انجام خواهد گرفت.

#### مواد و روش ها

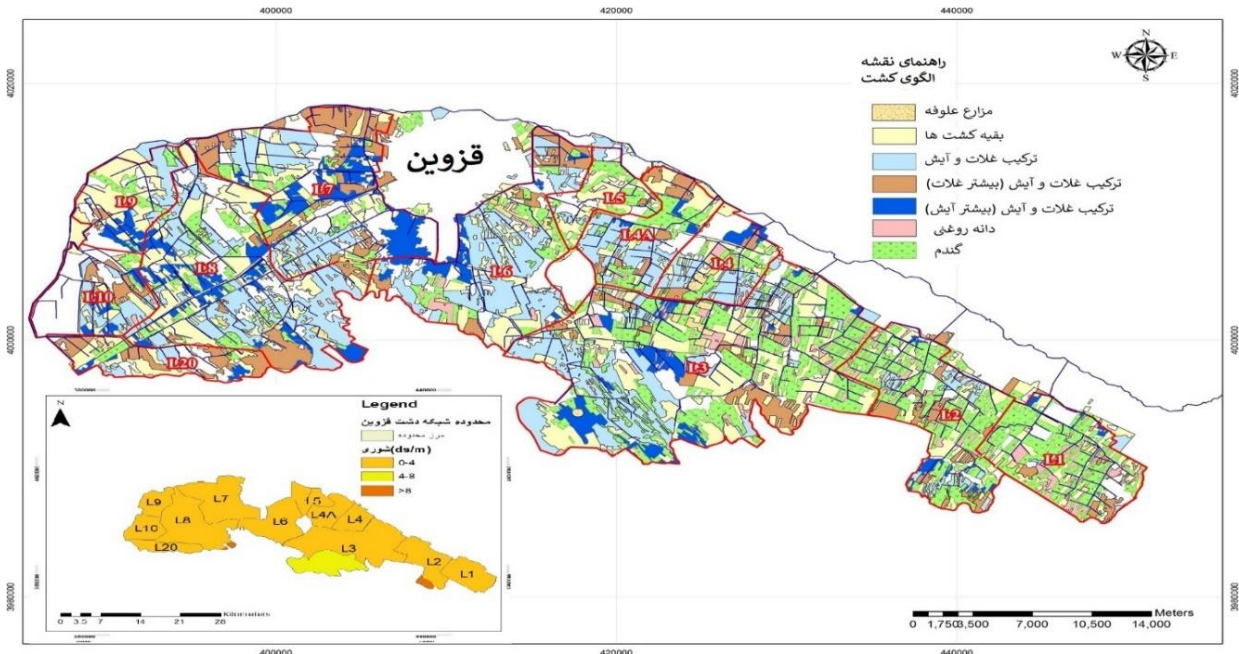
##### منطقه مورد مطالعه

دشت قزوین در محدوده  $35$  درجه و  $30$  دقیقه تا  $36$  درجه و  $30$  دقیقه عرض جغرافیایی و  $50$  درجه طول

شبکه های عصبی مصنوعی یک تکنیک محاسباتی بسیار قدرتمند برای مدل سازی روابط پیچیده غیرخطی، به خصوص در شرایطی که در آن به شکل صریح و روشن از رابطه بین متغیرهای درگیر ناشناخته است (اسمیت و همکاران، ۱۹۹۳؛ ملک محمدی و همکاران، ۲۰۱۱). تحقیقات انجام گرفته در این حوزه می توان به پیش بینی تغییرات کیفیت آب سطحی (محتشم و همکاران، ۱۳۹۵؛ نیکو و همکاران، ۱۳۹۰؛ سینگ و کانوار، ۲۰۰۹؛ چترجی، ۲۰۱۷؛ نوری و همکاران، ۲۰۲۰) تجزیه و تحلیل شوری (هالکی و همکاران، ۲۰۱۷؛ روستایی و همکاران، ۲۰۱۸)، تخمین تبخیر و تعرق پتانسیل گیاه مرجع (پیری و همکاران، ۱۳۹۷؛ نورانی و سیاح فرد، ۱۳۹۰؛ کریمی پور و بنی طالبی، ۱۳۹۹؛ گوپال و همکاران، ۲۰۱۴) اشاره نمود. انواع شبکه های عصبی مصنوعی در زمینه علوم کشاورزی نیز پر کاربرد بوده است. محققان کشاورزی به منظور برآورد شاخص سطح برگ (LAI) از شبکه عصبی بسیار استفاده نمودند که از آن میان می توان به تحقیقات ماهانتی و همکاران (۲۰۲۰) و وازکر کروز (۲۰۱۲) اشاره کرد که به ترتیب برای ارزیابی شاخص سطح برگ گیاهان اسفناج، ذرت و گوجه فرنگی استفاده نمودند. در تولیدات کشاورزی اعم از میوه ها و غلات نیز این شاخه از هوش مصنوعی مورد توجه قرار گرفته است. برای پیش بینی وزن میوه ها که توسط شبکه عصبی مصنوعی انجام شده می توان برای نمونه به تحقیق راد و همکاران (۲۰۱۵) برای میوه هندوانه و سوارس و همکاران (۲۰۱۳) برای موز اشاره نمود. براساس مطالعات پیشین شبکه عصبی مصنوعی در پیش بینی عملکرد نسبت به مدل های رگرسیونی دقت بیشتری دارد. به عنوان مثال میزان خطا و ضریب تبیین در پیش بینی عملکرد ذرت در مقایسه با رگرسیون خطی به ترتیب  $30\%$  کاهش و  $0/42$  افزایش داشته است (کائول و همکاران، ۲۰۰۵) و عملکرد گندم  $70$  درصد کاهش خطا و  $75$  درصد افزایش همبستگی را نسبت به رگرسیون غیرخطی نشان دادند (منتظر و همکاران، ۱۳۸۸). آلوارز و همکاران (۲۰۰۹) میزان خطای حاصل از شبیه سازی

چاه‌های تلفیقی موجود در سطح شبکه تامین می‌گردد. سه محصول عمده این دشت گندم، جو و ذرت می‌باشد که در این تحقیق مورد بررسی قرار گرفت. اطلاعات شوری خاک منطقه از مطالعات صورت گرفته در استان قزوین استخراج گردید (پاک‌نهاد، ۱۳۸۶). شکل ۱ موقعیت شبکه آبیاری و زهکشی دشت قزوین و پراکندگی الگوی کشت را در منطقه نشان می‌دهد.

جغرافیایی قرار گرفته است. منبع آب سطحی موجود، آب انتقالی از سد مخزنی طالقان می‌باشد. بر اساس دوره آماری ۳۰ ساله (۱۳۶۸-۱۳۹۸) متوسط بارندگی در دشت قزوین حدود ۲۵۰ میلی‌متر در سال و متوسط دمای ماهانه ۱۴ درجه می‌باشد. اقلیم منطقه بر اساس روش دو مارتن نیمه خشک می‌باشد. وسعت شبکه آبیاری دشت قزوین حدود ۵۷ هزار هکتار است که آب مورد نیاز آن از سد طالقان و



شکل ۱- محدوده شبکه آبیاری و زهکشی قزوین و تقسیم بندی کانال‌ها و شوری خاک

بدین منظور لازم است مطالعات مزرعه‌ای که در منطقه مورد نظر یا مناطق مجاور بر روی محصولات انتخابی، جمع آوری شود. این مطالعات مزرعه‌ای بایستی شامل تیمارهای مختلف آبیاری باشند تا امکان واسنجی مناسب و همچنین اعتبارسنجی وجود داشته باشد. در این تحقیق برای واسنجی مدل AquaCrop از نتایج مطالعات گلکار (۱۳۷۷) برای گندم و محمدی و همکاران (۱۳۹۴)، فرهادی بانسوله (۱۳۷۷) و پیرسته انوشه و همکاران (۱۳۹۶) برای جو، میرلطیفی و ستوده‌نیا (۱۳۸۱) و حیدری‌نیا و همکاران برای ذرت استفاده شد. تیمارهای مطالعات گلکار (۱۳۷۷) شامل ۱۰، ۱۱۰، ۹۰، ۸۰، ۷۰، ۶۰، ۵۰، ۴۰، ۳۰، ۲۰ و ۱۰ درصد نیاز آبی گیاه (به ترتیب تیمارهای T100، T110، T90، T80، T70، T60، T50، T40، T30، T20، T10) و تیمار دیم با دو آبیاری در زمان کاشت (۱۵ آب‌ان) و اولین آبیاری

#### واسنجی مدل AquaCrop و بیان تیمارهای تحقیق

استفاده از مدل‌های شبیه‌ساز گیاهی به دلیل هزینه کم، سرعت زیاد و در اختیار قراردادن اطلاعات کامل، گزینه مناسبی برای تکمیل و توسعه نتایج آزمایش‌های مزرعه‌ای محسوب می‌شود (سینگ و همکاران، ۲۰۰۸). در این تحقیق از مدل AquaCrop برای محاسبه عملکرد گیاهان گندم، جو و ذرت دانه‌ای استفاده شد. ورودی‌های اصلی مدل اطلاعات مربوط به اقلیم، خاک، گیاه و روش مدیریتی می‌باشد. در بخش مربوط به هواشناسی، داده‌های بارش، دمای هوا و تبخیر و تعرق مرجع به عنوان ورودی مدل وارد می‌گردد. برای واسنجی پارامترهای مدل تحت تنش آبی و شوری نیاز به چند سری داده میدانی است که از داده‌های حاصل از مطالعات گذشته جمع آوری گردید. واسنجی مدل بیشتر شامل واسنجی پارامترهای گیاهی است.

ورودی و عملکرد واقعی دانه و سال اجرای آزمایش در جدول (۱) ارائه شده است. برای کالیبره مدل گیاهی از تیمارهای شوری و کم آبیاری و عملکرد متناظر آنها که به طور همزمان در مطالعات مربوطه اندازه گیری شده است، استفاده گردید و سری‌های به کار رفته برای صحت‌سنجی و واسنجی غیر از تصادفی بودن به گونه‌ای انتخاب شد که از هر مجموعه مطالعات حداقل یک سری برای صحت‌سنجی به کار رفته باشد و همچنین ۷۰ درصد داده‌های برای واسنجی و ۳۰ درصد تیمارها برای صحت‌سنجی استفاده گردید. در نهایت واسنجی عملکرد گیاهان بررسی گردید و پارامترهای گیاهی به‌نحوی تغییر یافت که در عملکرد مقادیر تخمین زده شده و مقادیر واقعی کمترین میزان خطا مشاهده شود؛ بنابراین مدل گیاهی برای گیاهان مختلف کالیبره گردید و می‌توان در دشت قزوین با توجه به محدوده‌های شوری منتخب در خاک‌های قزوین (جدول ۲) از این مدل استفاده گردد تا عملکرد متناظر در هر محدوده شوری به شکل تقریباً نزدیک به واقعیت برآورد گردد.

بهاره (۲۰ فروردین) قبل از اعمال تنش بود (T0). تیمارهای مطالعات محمدی و همکاران (۱۳۹۴) شامل سطوح مختلف شوری آب آبیاری (S3, S2, S1) به ترتیب معادل ۹/۴، ۶/۱، ۵/۴ دسی زیمنس بر متر) بود. تیمارهای مطالعات فرهادی بانسوله (۱۳۷۷) شامل ۱۰۰، ۹۰، ۸۰، ۷۰، ۶۰، ۵۰، ۴۰، ۳۰، ۲۰ و ۱۰ درصد نیاز آبی گیاه (به ترتیب تیمارهای T10, T20, T30, T40, T50, T60, T70, T80, T90, T100 و T10) و تیمار دیم با دو آبیاری در زمان کاشت (۱۰ آبان) و اولین آبیاری بهار (۲۰ فروردین) قبل از اعمال تنش بود (T0). تیمارهای مطالعات پیرسته انوشه و همکاران (۱۳۹۶) شامل سطوح مختلف شوری آب آبیاری (S2, S1) به ترتیب معادل ۲، ۱۲ دسی زیمنس بر متر) بود. تیمارهای مطالعات میرلطیفی و ستوده‌نیا (۱۳۸۱) شامل آبیاری در نقاط ۴۰، ۵۰، ۶۰ و ۸۰ درصد آب قابل دسترس گیاه در نظر گرفته شد (به ترتیب تیمارهای T40, T50, T60, T80)؛ و تیمارهای حیدری نیا و همکاران (۱۳۹۴) شامل سطوح مختلف شوری آب آبیاری (S3, S2, S1) به ترتیب معادل ۲، ۴/۵، ۷ دسی زیمنس بر متر) بود. مقادیر اصلی پارامترهای

جدول ۱- مقادیر اصلی میزان آب آبیاری، شوری آب آبیاری، شوری خاک، عملکرد واقعی و زیست توده

گیاه	سال آزمایش	تاریخ کشت	مشخصات خاک ۳۰-۰	رطوبت در pwp	رطوبت در fc	موقعیت جغرافیایی طرح	میزان آب آبیاری (mm)	شوری اولیه آب آبیاری (dS/m)	شوری اولیه خاک (dS/m)	عملکرد (Kg/ha)
گندم قدس	۷۶-۷۷	۱۵ آبان	لومی	۱۶/۱	۳۲/۲	۵۱°E، ۳۵°۳۸'N	۴۰۰	۰/۴	۵/۳	۵۶۲۵
"	۱۳۸۴	۲۳ آبان	کلی لوم	۱۹/۷	۳۳/۴	۵۵°E، ۵۳°۳۲'N	۶۶۰	۱/۴	۲/۱	۴۴۰۰
جو والفجر	۷۶-۷۷	۱۰ آبان	لومی	۱۶/۱	۳۲/۲	۵۱°E، ۳۵°۳۸'N	۳۱۹	۰/۴	۵/۳	۶۰۰۰
"	۹۱-۹۲	۲۸ آبان	لومی شنی	۳/۷	۲۱/۶	۵۲°E، ۲۹°۲۹'N	۶۵۰	۲	۵	۶۸۲۶
ذرت Sc704	۷۹-۸۰	۵ خرداد	لومی	۱۲	۲۴	۵۰°E، ۳۶° و ۱۹°N	۷۶۳	۰/۴	۰/۹۳	۱۲۶۲۴
"	۹۴	۱ مرداد	لومی سیلتی	۱۸	۳۴	۵۵°E، ۳۲°۵۳'N	۷۴۲	۲	۳	۵۷۰۰

افزایش دقت از مدل واسنجی شده استفاده شد. سپس سناریوهای مربوط به طرح با توجه به ملاحظات شوری خاک و احتمال تغییرات شوری آب تیمارهای مطالعه در چهار سطح شوری خاک منطقه (S1=۰/۴)،

در ادامه برای تعیین تابع عملکرد محصول به دامنه گسترده‌ای از داده‌های عملکرد متناسب با مقادیر شوری و عمق آبیاری مورد نیاز است. با توجه به اینکه داده‌های موجود برای تخمین این توابع معمولاً کم می‌باشد برای

فائو محاسبه شد. براساس گزارشات موجود منطقه راندمان آبیاری ۳۵ درصد در نظر گرفته شد (نچارچی، ۱۳۹۰). برای مشخصات خاک منطقه نیز از جدول (۲) استفاده شد. در نهایت از طریق برازش رگرسیون‌های خطی، غیرخطی و روش شبکه عصبی مصنوعی بهترین روش برای تهیه تابع تولید انتخاب شد. از طرفی متغیرهای مستقل میزان آب آبیاری، شوری آب و شوری خاک می‌باشد و تابع عملکرد به صورت تابعی از این سه متغیر محاسبه گردید. برای واسنجی روابط رگرسیونی غیرخطی و خطی بین متغیرهای ورودی و عملکرد محصولات نرم افزار آماری SPSS و Excel مورد استفاده قرار گرفت.

و چهار سطح شوری آب آبیاری ( $S_4=12, S_3=8, S_2=4$ ) و همچنین ( $SW_4=4, SW_3=3, SW_2=2, SW_1=0/67$ ) و همچنین مقادیر مختلف کم آبیاری در ماههای مختلف در چهار سطح ( $I_4=0/40, I_3=0/60, I_2=0/80, I_1=0/100$ ) در براساس مقادیر کم آبیاری در ماههای مختلف و با تغییر عمق آبیاری و شوری آب و خاک، با اجرای روش مونت کارلو اعداد تصادفی تولید و مدل اجرا شد. به این ترتیب توابع تولید آب-محصول به کمک مدل AquaCrop که در آن عملکرد تابعی از میزان آب آبیاری و شوری آب و خاک می‌باشد توسعه یافت. ابتدا برای اجرای مدل AquaCrop از اطلاعات و آمار ۱۵ ساله داده هواشناسی (۱۳۸۰-۱۳۹۵) استفاده شد. تبخیر و تعرق با استفاده از روش پنمن مونتیت

جدول ۲- ویژگی‌های فیزیکی غالب خاک در منطقه (عمق ۰-۳۰ سانتی متر)

بافت خاک	رس (%)	سیلت (%)	شن (%)	EC (dS/m)	نقطه پژمردگی (درصد حجمی)	ظرفیت زراعی (درصد حجمی)
سیلتی-لوم	۴۱	۴۴	۱۵	۰/۴	۱۶/۳	۲۶/۷
سیلتی-لوم	۳۹	۴۶	۱۵	۴	۱۶	۳۲
کلی-لوم	۳۷/۶	۳۲	۳۰/۴	۸	۱۹/۲	۳۵/۲
کلی-لوم	۳۳/۶	۳۴/۲	۳۲/۲	۱۲	۱۵	۳۲/۲

### شبکه عصبی مصنوعی (ANN)

شبکه عصبی مصنوعی ابزاری قدرتمند برای شبیه‌سازی سامانه‌های پیچیده غیرخطی می‌باشد. در این تحقیق از شبکه عصبی مصنوعی چندلایه با معماری پرسپترون استفاده شد که متشکل از یک لایه ورودی، لایه یا لایه‌های پنهان و لایه خروجی می‌باشد (شکل ۲). 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. ورودی‌های شبکه به صورت دسته‌ای و همزمان به شبکه اعمال شدند. لایه ورودی تنها 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 متغیر مستقل بستگی دارد. و تعداد لایه خروجی نیز بستگی به متغیر وابسته دارد. برخلاف لایه ورودی و خروجی لایه پنهان تنها وظیفه تنظیم وزن و یادگیری را دارد و تنها یک نتیجه میانی در فرایند محاسبه

شکل کلی تابع عملکرد به ازای شوری‌های مختلف و مقادیر متفاوت آب آبیاری بصورت  $Y=f(AW, EC)$  در نظر گرفته شد که در آن: Y مقدار عملکرد بر حسب تن در هکتار، I مجموع عمق آب آبیاری در طول دوره رشد بر حسب سانتی‌متر و EC متوسط شوری آب آبیاری بر حسب dS/m بود. توابع تولید آب - شوری بکار برده شده در این تحقیق عبارتند از:

$$Y = a_0 + a_1 \times I + a_3 \times EC \quad (1)$$

$$Y = a_0 \times I^{a_1} \times EC^{a_2} \quad (2)$$

(۳) تابع عملکرد بر اساس معماری شبکه عصبی مصنوعی (ANN): توضیحات کامل در قسمت تعریف شبکه عصبی بیان گردیده است

یک تبدیل شوند، زیرا در این پژوهش برای عناصر پردازش گر لایه مخفی تابع آستانه سیگموئیدی انتخاب گردید. شکل ریاضی تابع سیگموئیدی در معادله ۴ نشان داده شده است. (منتظر و همکاران، ۱۳۸۹)


$$F(x) = \frac{1}{1+e^x} \quad (4)$$

همچنین برای استفاده داده در شبکه با تابع فعالیت سیگموئیدی، کلیه داده ها قبل از اعمال به شبکه با استفاده از تابع ۵ نرمال شدند.

$$x_n = 0.5 \left( \frac{x_0 - x_{mean}}{x_{max} - x_{min}} \right) + 0.5 \quad (5)$$

$x_n$  مقدار نرمال شده  $x_0$  ورودی میانگین داده ها و  $x_{max}$  و  $x_{min}$  به ترتیب میزان حداکثر و حداقل داده ها می باشد.

ارزش خروجی می باشد. (منتظر و همکاران، ۱۳۸۹) عامل ورودی عبارت است از مقدار آب مصرفی در طول فصل رشد (I) و میزان شوری خاک و میزان شوری آب آبیاری. اما برخلاف لایه ورودی و ساختار شبکه با افزودن یا کاستن تعداد نرون ها تغییر یافت. تابع غیرخطی سیگموئید به عنوان توابع انتقال شبکه در لایه مخفی و تابع خطی در لایه خروجی مورد استفاده قرار گرفت. روال آموزش و اعتبارسنجی برای هرساختار تکرار شد. در هر دوره، الگوریتم آموزش سعی در کم کردن خطای مجموعه داده های شبیه سازی شده به کمک شبکه و مجموعه داده های مشاهداتی می نماید. بنابراین در هر دوره وزن ها به گونه ای تغییر می نمایند که این خطا را کمتر نمایند. پس از جمع آوری اطلاعات، نرمال سازی داده ها انجام گرفت. هدف از نرمال سازی آن است که داده ها به اعدادی مابین صفر تا



شکل ۲- شبکه عصبی مصنوعی با معماری پرسپترون

خروجی مورد بررسی قرار گرفت. با علم به این مطلب که با افزایش مقدار آبیاری در محدوده مورد نیاز گیاه باید عملکرد گیاه افزایش و با افزایش شوری آب و خاک باید مقدار عملکرد گیاه کاهش یابد، شبکه هایی که از این اصل تبعیت نکردند به عنوان شبکه معیوب که تحت پدیده **over fitting** قرار گرفته از بررسی ها حذف شد. قابل ذکر است که برای آموزش شبکه ها، ۸۰٪ داده ها برای آموزش، ۱۰٪ داده ها برای اعتبارسنجی و ۱۰٪ باقیمانده برای تست به کار گرفته شد.

در نهایت ساختاری که نتایج آن بر مبنای شاخص های آماری اختلاف حداقل را با مقادیر مشاهده ای داشت به عنوان ساختار بهینه معرفی شد. مقایسه بین نتایج ANN و روش های کلاسیک صورت گرفته در شرایط یکسان، شبکه عصبی با کاهش طول داده ها و صرف زمان کمتر مقادیر واقعی تری را پیش بینی میکند (توکار و همکاران، ۱۹۹۹). آموزش و ارزیابی عملکرد مدل شبکه عصبی مصنوعی در محیط نرم افزار MATLAB انجام گرفت. برای مقابله با پدیده **over fitting** پس از اتمام فرایند آموزش، هر شبکه به وسیله تغییر در مقادیر ورودی ها آنالیز حساسیت شده و تغییرات در مقدار

## ارزیابی مدل و تحلیل حساسیت

$P_i$  مقادیر پیش‌بینی شده،  $O_i$  مقادیر اندازه‌گیری شده (مشاهده‌ای)،  $n$  تعداد نمونه‌های به کار رفته،  $\bar{O}$  مقدار متوسط پارامتر مشاهده شده می‌باشد.

برای تعیین میزان حساسیت خروجی مدل AquaCrop و مدل‌های جایگزین رگرسیون‌های خطی و غیرخطی و همچنین شبکه عصبی مصنوعی نسبت به داده‌های ورودی ابتدا پارامترهای اندازه‌گیری شده مانند عملکرد به عنوان خروجی پایه در نظر گرفته شده و با هر بار اجرای مدل، یکی از داده‌های ورودی تا  $\pm 25\%$  درصد تغییر داده شد و بقیه ثابت نگه داشته شدند. سپس با استفاده از رابطه ۱۰ تحلیل حساسیت شدند. (لو و همکاران، ۲۰۰۷).

$$Sc = \frac{\frac{\Delta W}{\bar{W}}}{\frac{\Delta P}{\bar{P}}} \quad (10)$$

که در این رابطه:

$\Delta W$  اختلاف مقدار پارامتر خروجی، قبل و بعد از تغییر پارامتر ورودی،  $\bar{W}$  متوسط مقدار پارامتر خروجی قبل و بعد از تغییر پارامتر ورودی،  $\Delta P$  اختلاف مقدار پارامتر ورودی و  $\bar{P}$  متوسط مقادیر ورودی هر پارامتر به مدل را نشان می‌دهد. دامنه تغییرات ضریب حساسیت در جدول (۳) نشان داده شده است.

جدول ۳- دامنه تغییرات ضریب حساسیت ( $Sc$ )

$Sc > 1/5$	$1/3 < Sc < 1/5$	$0 < Sc < 1/3$	$Sc = 0$	دامنه تغییرات
حساسیت زیاد	حساسیت متوسط	حساسیت کم	بدون حساسیت	شدت حساسیت

پارامترهایی که برای واسنجی مدل در این تحقیق مد نظر قرار گرفت عبارت است از پارامترهای کم‌آبیاری و شوری. مدل برای پارامترهای گیاهی و عملکرد محصول واسنجی شد. به طوری که اختلاف بین عملکرد شبیه‌سازی و مشاهده ای حداقل گردد. در جدول (۴) مقادیر برخی پارامترهای واسنجی شده برای هر محصول ارائه شده است.

شاخص‌های ارزیابی مدل برای ارزیابی و سنجش اعتبار مدل AquaCrop و نیز برای ارزیابی رگرسیون‌های خطی و غیرخطی و شبکه عصبی به کار گرفته شد. این شاخص‌ها شامل ضریب تبیین ( $R^2$ ) و ریشه میانگین مربع خطا (RMSE)، ریشه میانگین مربع خطای نرمال شده (NRMSE) و میانگین خطای مطلق (AME) است. نحوه محاسبه‌ی شاخص‌های ذکر شده در روابط (۶) تا (۹) ارائه شده است:

$$R^2 = \frac{\sum_{i=1}^n (P_i - \bar{O})^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (7)$$

$$NRMSE = \frac{1}{\bar{O}} \times \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \times 100 \quad (8)$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \quad (9)$$

که در آنها:

## نتایج و بحث

### واسنجی مدل AquaCrop

در مدل AquaCrop ضرایب مختلفی برای هر گیاه تعریف شده است که باید به کمک داده‌های میدانی واسنجی شود. در این مطالعه مدل AquaCrop بر اساس داده‌هایی که کلیات آن در بخش پیشین ارائه شد، برای سه غله‌ی مهم یعنی گندم، جو و ذرت دانه‌ای واسنجی شد.




جدول ۴- پارامترهای واسنجی شده مربوط به غلات منتخب

ذرت	گندم	جو	گیاه
۸۷/۳۳	۸۶	۸۲/۵	حداکثر پوشش گیاهی
۱۵/۴۴	۴/۵۳	۵/۵۶	ضریب رشد پوشش
۱۱/۳۳	۹/۷۷	۶/۴۴	ضریب کاهش پوشش
۰/۷۹	۰/۵۴	۰/۵۲	ضریب بسته شدن روزنه
۲	۶	۷	حد پایین شوری
۹	۱۹	۲۰	حد بالای شوری
۱۰	۱۳	۱۳	طول دوره گلدهی (روز)
۲۳۵	۱۰۵	۱۰۰	حداکثر عمق ریشه (cm)
۳۳/۸۵	۱۵	۱۴/۳۳	بهره وری آب نرمال شده

مزرعه نشان داد که همبستگی خوبی بین مقادیر شبیه‌سازی و واقعی وجود دارد.

در شکل ۳ عملکرد شبیه‌سازی و مشاهده‌ای برای محصولات انتخابی ارائه شده است. مقایسه عملکردهای به‌دست آمده از مدل و عملکردهای اندازه‌گیری شده در



شکل ۳- عملکرد شبیه‌سازی و مشاهده شده محصولات زراعی: الف: جو، ب: گندم، ج: ذرت

محصول در بازه قابل قبول می‌باشد. همچنین، کمترین مقدار آماره MAE نیز برای جو به میزان ۰/۳۷ کیلوگرم برآورد شد (جدول ۵).

شاخص‌های آماری نیز نشان دهنده برآورد مناسب مدل در تعیین عملکرد محصولات بود. بر اساس نتایج بیشترین و کمترین ضریب همبستگی به ترتیب مربوط به گندم و ذرت می‌باشد. مقادیر NRMSE نیز برای هر سه

جدول ۵- مقادیر پارامترهای آماری برای ارزیابی مدل

MAE (kg/ha)	NRMSE	R <sup>2</sup>	محصول
۰/۳۷	۷/۹۱	۰/۸۶	جو
۰/۴	۸/۷۹	۰/۷۳	صحت سنجی
۰/۳۵	۵/۲۷	۰/۹۳	گندم
۰/۴۵	۸/۱۸	۰/۸۷	صحت سنجی
۰/۵۱	۹/۱۴	۰/۹۶	ذرت
۰/۶	۰/۵۳	۰/۹۵	صحت سنجی

همکاران، (۱۹۹۸) توابع غیرخطی را به عنوان بهترین الگو برای تابع تولید ارزیابی نمودند. این درحالی است که پیش‌بینی عملکرد توسط شبکه عصبی مصنوعی با دقت بالا، کاهش خطا و با سرعت قابل قبول همراه می‌باشد (حسینی و همکاران، ۱۳۸۶، منتظر و همکاران، ۱۳۸۸، سجادی و همکاران، ۱۳۹۱، صفری و همکاران، ۱۳۹۸).

نتایج حاصل از این مطالعه با تحقیقات قبلی انجام شده در این زمینه مطابقت دارد. حسینی و همکاران (۱۳۸۶) دقت پیش‌بینی عملکرد گندم را در قروه کردستان با استفاده از شبکه مصنوعی برابر ۰/۹۹ برآورد نموده است. منتظر و همکاران (۱۳۸۸) در مقایسه مدل رگرسیون غیرخطی و شبکه عصبی برای پیش‌بینی عملکرد گندم افزایش ۱۸٪ در ضریب تبیین و کاهش ۳۳٪ خطا را برآورد نمودند. باقری و همکاران (۱۳۹۱) نیز عملکرد گندم را با خطای بسیار ناچیز توسط شبکه عصبی برآورد نمود. شیردلی و توسلی (۱۳۹۴) ضریب تبیین را در پیش‌بینی عملکرد زعفران توسط شبکه عصبی ۰/۹۷ برآورد نمودند. علت عملکرد بهتر شبکه عصبی را می‌توان به هوشمند بودن فرآیند آنالیز داده‌ها دانست طی فرآیند آموزش، شبکه عصبی قادر خواهد بود روابطی منطقی میان ورودی و خروجی را آموزش دهد و از آن برای محاسبه داده‌هایی که در آموزش شبکه به کار نرفته‌اند استفاده کند. در حالی که آنالیز رگرسیونی تنها قادر به برقراری تعدادی از مفاهیم ریاضی و آماری میان داده‌ها است.

#### تعیین توابع تولید آب - شوری

در این بخش نتایج مدل‌های شبکه عصبی با نتایج معادلات رگرسیونی غیرخطی و خطی برازش شده بر داده‌های استخراج شده از مدل گیاهی AquaCrop ارائه می‌شود. معادلات رگرسیونی خطی و غیرخطی (نمایی) استخراج شده برای محاسبه عملکرد دانه (Y)، به صورت تابعی از میزان آب آبیاری (I)، شوری آب آبیاری (EC) به صورت زیر (جدول ۷) هستند.

نتایج این تحقیق با سایر تحقیقات مشابه درخصوص واسنجی مدل آکواکراپ در شرایط تنش خشکی و شوری مورد بررسی قرار گرفت. محمدی و همکاران (۱۳۹۴) مدل را برای شبیه‌سازی عملکرد گندم ارزیابی نمودند نتایج آن‌ها نیز نشان داد خطای برآورد ۰/۸۹ می‌باشد. المخ و همکاران (۲۰۱۶) دقت شبیه‌سازی مدل را برای برآورد گیاه جو در شرایط شوری آب و کم‌آبی در اقلیم خشک تونس مناسب ارزیابی نمودند (۰/۹۷- $R^2=0/88$ ). حیدری نیا و همکاران (۱۳۹۶) نیز خطای به‌کارگیری مدل را در برآورد عملکرد ذرت در شرایط مشابه ۰/۹۳ گزارش کردند. با توجه به نتایج حاصل از مدل می‌توان اظهار داشت که مدل توانسته است روند کاهش این پارامترها در اثر تنش‌های شوری و آبی نیز به‌خوبی شبیه‌سازی کند.

#### مقایسه مدل شبکه عصبی با مدل‌های رگرسیون غیرخطی

برای تعیین تابع تولید از مدل خطی، غیرخطی و شبکه عصبی مصنوعی استفاده شد. توابع تولید بصورت تابعی از میزان آب آبیاری، میزان شوری آب آبیاری و شوری خاک بیان گردید. سپس برای تعیین تابع تولید بهینه، توابع بر اساس آماره‌ها درجه‌بندی شدند. به منظور مقایسه‌ی کارایی (performance) شبکه‌های آموزش داده شد. در این مطالعه، تابع خطی و نمایی مربوط به هر گیاه نیز توسط نرم افزار SPSS تهیه شد که مقدار خطای آن در جدول (۶) گزارش شد سپس مدل‌های شبکه عصبی با نتایج معادلات رگرسیون غیرخطی و خطی مورد مقایسه قرار گرفتند. نتایج نشان داد شبکه عصبی مصنوعی با کمترین میزان خطا و بیشترین همبستگی توانایی زیادی در تولید تابع عملکرد-آب دارد. تعیین تابع تولید کاربردی‌ترین نتایج این مطالعه می‌باشد که برای تعیین عمق آبیاری هر محصول مدیریت و برنامه‌ریزی آبیاری در شرایط محدودیت کمی و کیفی آب کاربرد دارد. کیانی و عباسی (۱۳۸۵)، شیرمحمدی و همکاران (۱۳۹۲)، پیری و همکاران (۱۳۹۷) و داتا و

جدول ۶- مقادیر خطای مدل‌های جایگزین مورد بررسی در تحقیق

مخروجی	RMSE (kg)	AME (kg)	NRMSE	R <sup>2</sup>	تعداد نرون	ورودی	تابع	محصول
عملکرد	۱۷۶/۱۹	۱۳۶/۰۳	۰/۰۳	۰/۹۸	-	میزان آبیاری دوره میانی رشد-	Linear	گندم
	۳۹۲/۳۱	۳۱۱/۱۳	۰/۰۷	۰/۹۲	-	میزان آبیاری دوره انتهایی رشد-	Non-Linear	
	۶۲/۹۱	۴۷/۷۸	۰/۰۱	۰/۹۹	۴	میزان شوری خاک- میزان	ANN	
	۴۰/۱۶	۲۸/۷۳	۰/۰۱	۰/۹۸	۵	شوری آب آبیاری		
	۴۰/۳۲	۳۲/۳۴	۰/۰۱	۰/۹۸	۶			
	۴۳/۹۲	۳۱/۲۶	۰/۰۱	۰/۹۹	۷			
	۲۴/۱۳	۱۳/۲۷	۰/۰۱	۰/۹۸	۸			
	۲۲۸/۲۰	۱۷۵/۴۸	۰/۰۴	۰/۹۵	-	میزان آبیاری دوره میانی رشد-	Linear	
جو	۳۹۵/۲۳	۳۱۶/۵۵	۰/۰۸	۰/۸۷	-	میزان آبیاری دوره انتهایی رشد-	Non-Linear	
	۱۲۲/۴۳	۷۹/۱۳	۰/۰۲	۰/۹۸	۳	میزان شوری خاک-میزان شوری	ANN	
	۷۶/۷۹	۴۵/۳۴	۰/۰۲	۰/۹۹	۴	آب آبیاری		
	۶۲/۰۹	۲۴/۲۰	۰/۰۱	۰/۹۹	۵			
	۶۳/۶۱	۲۵/۲۰	۰/۰۱	۰/۹۹	۶			
	۱۲۶۲/۲۰	۷۷۳/۳۸	۰/۱۱	۰/۷۹	-	میزان آبیاری در دوره اولیه رشد-	Linear	
	۹۰۴/۶۲	۷۲۰/۲۲	۰/۰۸	۰/۸۲	-	میزان آبیاری دوره میانی رشد- میزان آبیاری دوره انتهایی رشد-	Non-Linear	
	۱۵۴/۵۶	۱۱۳/۴۸	۰/۰۲	۰/۹۹	۳	میزان شوری خاک میزان شوری	ANN	
ذرت	۹۵/۳۷	۶۹/۸۰	۰/۰۱	۰/۹۹	۴	آب آبیاری		
	۷۶/۱۱	۵۶/۳۳	۰/۰۱	۰/۹۹	۵			
	۷۲/۵۲	۵۲/۷۶	۰/۰۱	۰/۹۹	۶			
	۵۷/۰۸	۴۳/۹۲	۰/۰۱	۰/۹۹	۷			
	۶۰/۶۸	۳۵/۸۸	۰/۰۱	۰/۹۹	۸			

جدول ۷- ضرایب رگرسیونی توابع خطی و نمایی برای سه محصول جو، ذرت و گندم

گیاه	ضرایب	S <sub>1</sub> =۰/۴	S <sub>2</sub> =۴	S <sub>3</sub> =۸	S <sub>4</sub> =۱۲
		تابع خطی	تابع نمایی	تابع خطی	تابع نمایی
جو	C	۱/۵۱	۰/۷۷۴	۱/۵۱۹	۰/۷۶۴
	a <sub>1</sub>	۰/۰۱۴	۰/۳۲۶	۰/۰۱۴۵	۰/۳۲۶
	a <sub>2</sub>	-۰/۰۰۸۱۲	-۰/۰۰۷۷۸	-۰/۰۰۱۶	-۰/۰۱۵۶
ذرت	C	۱/۵۳۳	۰/۹۴۲	۱/۶۴۴	۰/۹۶۵
	a <sub>1</sub>	۰/۰۱۱	۰/۳۳۸	۰/۰۰۹۳	۰/۳۱۲
	a <sub>2</sub>	-۰/۰۴۰۹	-۰/۰۱۶۴	-۰/۱۰۶	-۰/۰۵۱
گندم	C	۱/۹۶۴	۱/۴۷۷	۱/۹۷۸	۱/۴۴
	a <sub>1</sub>	۰/۰۱۱۷	۰/۲۰۹	۰/۱۱۳۱۵	۰/۲۰۹
	a <sub>2</sub>	-۰/۰۱۴۴	-۰/۰۱۱	-۰/۰۳۲۹	-۰/۰۲۷

محصولات دارد. در شبکه‌های تک لایه، به طور کلی با افزایش تعداد نرون، مقدار خطای ایجاد شده در شبکه کاهش می‌یافت. ولی پس از یک مقدار بهینه، با افزایش نرون‌ها خطای شبکه‌ها افزایش یافت. همچنین با افزایش

از طرفی مقدار بهینه نرون در بهترین شبکه آموزش دیده برای جو و گندم پنج نرون و برای ذرت هفت نرون در ساختار شبکه‌ی تک لایه بود. نتایج کلیه‌ی شبکه‌ها برای گیاهان گندم، جو و ذرت نشان داد که شبکه عصبی به صورت کل توانایی زیادی در شبیه‌سازی عملکرد

نرونها، شبکه‌ها در فرایند آموزش تمایل زیادی به فراآموزی پیدا می‌کردند. (جدول ۶)

### تحلیل حساسیت توابع مختلف تولید نسبت به داده‌های ورودی

میزان حساسیت توابع مختلف نسبت به داده‌های ورودی مورد ارزیابی قرار گرفته و نتایج در جدول (۷) ارائه شده است. گیاه جو نسبت به پارامتر میزان آب آبیاری از حساسیت تقریباً مشابهی در تمام مدل‌ها برخوردار می‌باشد ( $S_c=0.12$ ). همچنین، کلیه مدل‌ها حساسیت کمی نسبت به شوری آب و خاک را نشان دادند، ولی حساسیت آن‌ها نسبت به پارامترهای آبیاری به مراتب کمتر بود. آنالیز حساسیت گیاه گندم و ذرت نشان داد که ورودی‌های آبیاری نسبت به گیاه جو از حساسیت بیشتری برخوردار بودند. ولی همچنان در محدوده حساسیت کم قرار می‌گیرند و باز می‌توان اذعان نمود متغیرها از حساسیت یکسانی برخوردار می‌باشند. در این میان گیاه ذرت بیشترین و گیاه جو از کمترین حساسیت در میان ورودی‌های گروه آبیاری برخوردار بودند. ورودی شوری آب و خاک برای گیاهان گندم و ذرت نیز مانند گیاه جو از ورودی‌های آبیاری حساس‌تر بودند. همچنین، در تمام مدل‌ها، حساسیت کلیه گیاهان به شوری خاک بیشتر از شوری آب آبیاری می‌باشد. در این میان حساسیت گیاه ذرت نسبت به شوری خاک متوسط می‌باشد.

در این میان مدل شبکه عصبی از میان سایر مدل‌ها از نظر حساسیت بسیار شبیه مدل AquaCrop بود. به همین صورت کم و بیش برای ضرایب حساسیت گیاه گندم نیز مشاهده شد. گیاه گندم نیز نسبت به ورودی‌های آبیاری حساسیت کمی برخوردار بود. در گندم نیز شبکه عصبی حساسیت بسیار نزدیک به مدل AquaCrop نشان داد. ولی مدل‌هایی اختلاف بسیار فاحشی با مدل AquaCrop داشت. وضعیت مقادیر حساسیت گیاه ذرت به ورودی‌ها مانند گیاه گندم و جو در گروه ضرایب با حساسیت کم قرار گرفت با این تفاوت که با تحلیل حساسیت گیاه در مدل AquaCrop، ضرایب حساسیت گیاه ذرت نسبت به ورودی‌های شوری آب و خاک بیشتر از حساسیت این گیاه نسبت به ورودی‌های آبیاری بود. گلابی و همکاران (۱۳۹۲) در تحقیقی پارامترهای مربوط به آب (میزان آب آبیاری و هدایت الکتریکی آب) را در مقایسه با پارامترهای هواشناسی بر عملکرد نیشکر موثرتر دانستند. باقری و همکاران (۱۳۹۰) نیز پارامتر آبیاری و کود نیتروژن و درجه روز را پارامترهای موثر بر پیش‌بینی عملکرد دانستند و متغیر آبیاری در درجه اهمیت دوم قرار دارد. آلوارز و همکاران (۲۰۰۹) پارامتر نسبت بارندگی به تبخیر و تعرق پتانسیل را به عنوان مهمترین پارامتر در پیش‌بینی عملکرد گندم توسط شبکه عصبی دانستند کائول و همکاران (۲۰۰۵) میزان باران در ماه‌های ژوئن تا آگوست و خصوصیات خاک را به عنوان مهمترین پارامترها برای پیش‌بینی عملکرد ذرت و سویا در نظر گرفتند.

جدول ۷- میانگین ضریب حساسیت پارامترهای مختلف ورودی

مدل	پارامترهای ورودی	ضریب حساسیت	
		گندم	ذرت دانه ای
AquaCrop	میزان آب آبیاری	۰/۱۷	۰/۱۶
	شوری آب آبیاری	۰/۰۹	۰/۲۴
	شوری خاک	۰/۱۲	۰/۳۱
تابع خطی	میزان آب آبیاری	۰/۱۷	۰/۱۸
	شوری آب آبیاری	۰/۱۰	۰/۱۵
	شوری خاک	۰/۱۰	۰/۲۱
تابع غیرخطی	میزان آب آبیاری	۰/۲۱	۰/۲۵
	شوری آب آبیاری	۰/۱۳	۰/۱۴
	شوری خاک	۰/۱۷	۰/۲۷
شبکه عصبی	میزان آب آبیاری	۰/۱۷	۰/۱۲
	شوری آب آبیاری	۰/۰۹	۰/۲۶
	شوری خاک	۰/۱۲	۰/۳۲

## نتیجه گیری

لایه با تعداد نرون‌های مخالف آموزش داده شد. به منظور مقایسه شبکه‌ها آموزش داده شده،  $R^2$ ، MAR، NRMSE و RMSE بین خروجی‌های محاسباتی توسط شبکه‌ها و خروجی‌های AquaCrop محاسبه شد. نتایج نشان داد که با افزایش تعداد نرون‌ها خطای ایجاد شده کمتر می‌شود؛ که این پدیده را می‌توان در پیچیده‌تر شدن شبکه‌ها دانست. برای مقایسه ارزیابی شبکه‌ها به عنوان یک مدل جایگزین، بر اساس مجموعه‌های تولید شده به کمک داده‌هایی که از طریق مونت کارلو تولید شد، رگرسیون خطی و نمایی نیز محاسبه شد. خطاهای ایجاد شده بین خروجی‌های شبیه‌سازی شده توسط رگرسیون خطی و نمایی نشان داد در صورتی که میزان آبیاری و شوری آب و خاک به عنوان ورودی مدل باشد، مدل شبکه عصبی نسبت به رگرسیون خطی و نمایی بسیار قدرتمندتر است. مناسبترین تابع تولید در شرایط شوری و کم آبیاری در بهترین شبکه آموزش دیده برای جو و گندم پنج نرون و برای ذرت هفت نرون در ساختار شبکه‌ی تک لایه بود. از طرف دیگر نتایج آنالیز حساسیت نشان داد که حساسیت مدل‌های شبکه عصبی به جز گیاه ذرت، بسیار به حساسیت مدل AquaCrop نزدیک است و با آن همخوانی دارد. حساسیت گیاهان گندم و جو نسبت به پارامترهای میزان آبیاری و شوری آب و خاک در محدوده حساسیت کم قرار می‌گیرند، در این در حالی است که گیاه ذرت نسبت به پارامتر شوری حساسیت بیشتری دارد.

در این تحقیق، ابتدا به کمک داده‌های مزرعه‌ای مربوط به سه گیاه گندم، جو و ذرت در کلاس‌های مختلف تنش شوری و آبیاری، مدل AquaCrop واسنجی شد. سپس کارایی شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد محصولات گندم، جو و ذرت بررسی گردید. برای ارزیابی کارایی شبکه عصبی مصنوعی، بهترین شبکه‌ی آموزش دیده هر گیاه، نسبت به ورودی‌های تنش آبیاری و شوری مورد تحلیل حساسیت قرار گرفت. در این مطالعه نرم افزار AquaCrop با توجه به کمیت و کیفیت متفاوت منابع آب و تغییرات مکانی خصوصیات خاک در مناطق مختلف دشت قزوین با استفاده از اطلاعات میدانی اعتبارسنجی شد. خطاهای ایجاد شده بین شبیه‌سازی‌های مدل و داده‌های مشاهداتی نشان داد که می‌توان از مدل‌های شبیه‌سازی به عنوان یک ابزار مناسب جهت پیش‌بینی عملکرد محصول تحت کمیت و کیفیت‌های مختلف آب آبیاری استفاده نمود. گندم در بین گیاهان مورد بررسی بهترین پاسخ و ذرت بیشتر خطا را در شبیه‌سازی نشان داد. برای آموزش شبکه نیاز به مجموعه داده‌های بیشتر از داده‌ها میدانی به کار رفته در واسنجی مدل AquaCrop بود. برای ایجاد داده‌های مورد نیاز با پراکندگی لازم که فضای حالت ورودی‌های مدل را پوشش دهد از نوع خاصی از شبیه‌سازی مونت کارلو استفاده شد. به کمک داده‌ها تولید شده برای هر گیاه چند معماری از شبکه‌های تک لایه و دو

## فهرست منابع

۱. پیری، ح.، انصاری، ح. و پارسا، م. ۱۳۹۷. تعیین تابع تولید آب- شوری- عملکرد با در نظر گرفتن زمان برداشت علوفه و ارزیابی شاخص‌های تولید در ذرت خوشه‌ای. مجله‌ی مهندسی منابع آب، ۱۱: ۲۶-۱۵.
۲. تافته، آ.، بابازاده، ح.، ابراهیمی پاک، ن.ع. و کاوه، ف. ۱۳۹۳. بهینه‌سازی تخصیص آب ماهانه برای بهینه‌سازی کارایی مصرف آب بر اساس تابع تولید محصول. (مطالعه موردی دشت قزوین). رساله دکتری دانشکده کشاورزی و منابع طبیعی دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران.
۳. حیدری نیا، م.، برومندنسب، س. و ناصری، ع. ۱۳۹۶. ارزیابی مدل AquaCrop در تخمین عملکرد ذرت و شوری خاک تحت شرایط مدیریت‌های مختلف زراعی و آبیاری با آب شور. تحقیقات آب و خاک ایران، ۴۸(۱): ۴۹-۶۱.

۴. خرسند، ا.، رضوردی نژاد، و. شهیدی، ع. ۱۳۹۳. ارزیابی عملکرد مدل AquaCrop در پیش‌بینی عملکرد گندم، رطوبت و شوری نیم‌رخ خاک تحت تنش‌های شوری و کم آبی. مدیریت آب آبیاری، ۴(۱): ۸۹-۱۰۴.
۵. رضوانی اعتدالی، ه.، لیاقت، ع.، پارس‌نژاد، م. و توکلی، ع. ۱۳۹۵. واسنجی و اعتبارسنجی مدل AquaCrop در مدیریت آبیاری غلات مهم. نشریه آبیاری و زهکشی ایران، ۳(۱۰): ۳۸۹-۳۹۷.
۶. شیرمحمدی، ع. اکبرخانی، ز. انصاری، ح. علیزاده، ا. کافی، م. ۱۳۹۲. ارزیابی توابع تولید آب شوری عملکرد در ذرت علوفه‌ای در استان خراسان رضوی نشریه آبیاری زهکشی ایران، ۴(۷): ۵۳۳-۵۳۵.
۷. صفری، ف.، رضوانی اعتدالی، ه.، کاویانی، ع.، آبابایی، ب.، ۱۳۹۸. امکان‌سنجی شبکه آموزش‌های عصبی مصنوعی مدل با استفاده از مدل‌های گیاهی برای پیش‌بینی عملکرد و طول دوره‌های رشد گندم. مجله علمی و ترویجی نیوار، ۱۰۴-۱۰۵: ۱۰۱-۱۱۲.
۸. کریمی اورگانی، ح.، رحیمی خوب، ع. و نظری فر، م. ح. ۱۳۹۶. ارزیابی مدل AquaCrop در شبیه‌سازی زیست توده جو در شرایط کم‌آبیاری. نشریه پژوهش آب در کشاورزی، ۳۱(۳): ۳۴۱-۳۵۳.
۹. محمدی، م.، داوری، ک.، قهرمان، انصاری، ح. و حق‌وردی، ا. ۱۳۹۴. واسنجی و صحت‌سنجی مدل AquaCrop برای شبیه‌سازی عملکرد گندم بهار تحت تنش همزمان شوری و خشکی، پژوهش آب در کشاورزی، ۲۹(۳): ۲۷۷-۲۹۵.
۱۰. مهرآذر، آ.، سلطانی، ج. رحمتی، ا. ۱۳۹۴. ارزیابی مدل AquaCrop در شبیه‌سازی عملکرد ذرت تحت شرایط تنش شوری، نشریه آب و خاک (علوم و صنایع کشاورزی). ۳۰(۵): ۱۴۳۹-۱۴۲۶.
۱۱. یزدانی، و. داوری، ک. قهرمان، ب. و کافی، م. ۱۳۹۳. ارزیابی عملکرد کلزا به صورت تابعی از ارتفاع آب آبیاری و شوری در منطقه مشهد. فصلنامه علوم پژوهشی علوم آبیاری و آب، ۵(۱۸): ۵۳-۳۲.
12. 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.
13. Brumbelow, K. and Georgakakos, A. 2007. Determining crop-water production functions using yield-irrigation gradient algorithms. *Agricultural Water Management* 87: 151-161.
14. Choopan, Y. and Emami, S. 2019. Estimation of barley yield under irrigation with wastewater using RBF and GFF models of artificial neural network. *Journal of Applied Research in Water and Wastewater*, 6(1): 73-79.
15. Farhangian Kashani, S. and Monem, R. 2010. Effect of salt stress on seed germination characters of ten St. John's wort (*hypericum perforatum* L.) genotypes. *Journal of Crop Production Research (Environmental Stresses in Plant Sciences)*, 2(1): 75-81.
16. Foster, T. and Brozović, N. 2018. Simulating crop-water production functions using crop growth models to support water policy assessments. *Ecological Economics*, 152: 9-21.
17. Gandhi, N. and Armstrong, L. J. 2016. Rice crop yield forecasting of tropical wet and dry climatic zone of India using data mining techniques. In 2016 IEEE International Conference on Advances in Computer Applications (ICACA) (pp. 357-363). IEEE.
18. García-Vilaa, M. and Fereres, E. 2012. Combining the simulation crop model AquaCrop with an economic model for the optimization of irrigation management at farm level. *Europ. J. Agronomy* 36: 21- 31.
19. Hsiao, T. C., Heng, L. K., Steduto, P., Rojas-Lara, B., Raes, D. and Fereres, E. 2009. AquaCrop-the FAO crop model to simulate yield response to water, III: Parameterization and testing for maize. *Agronomy Journal*, 101: 448-459.
20. Hussain, S. and Hatibaruah, D. 2015. Modeling for prediction of tomato yield and its deviation using artificial neural network. *International Journal of Engineering Trends and Technology*, 29: 102-108.

21. Jiang, Y., Xu, X., Huang, Q., Huo, Z. and Huang, G. 2016. Optimizing regional irrigation water use by integrating a two-level optimization model and an agro-hydrological model. *Agricultural water management*, 178: 76-88.
22. Kaul, M., Hill, R. L. and Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems*, 85(1): 1-18.
23. Kim, D. and Kaluarachchi, J. 2015. Validating FAO AquaCrop using Landsat images and regional crop information. *Agricultural Water Management*, 149 143–155.
24. Liu, H. F., Genard, M., Guichard, S. and Bertin, N. 2007. Model-assisted analysis of tomato fruit growth in relation to carbon and water fluxes, *Experimental Botany*, 58 (13): 3567-3580.
25. López-Aguilar, K., Benavides-Mendoza, A., González-Morales, S., Juárez-Maldonado, A., Chiñas-Sánchez, P. and Morelos-Moreno, A. 2020. Artificial neural network modeling of greenhouse tomato yield and aerial dry matter. *Agriculture*, 10(4): 97.
26. Mohammadi, M., Ghahraman, B., Davary, K., Ansari, H. Shahidi, A. and Bannayan, M. 2016. Nested Validation of AquaCrop Model for Simulation of Winter Wheat Grain Yield, Soil Moisture and Salinity Profiles under Simultaneous Salinity and Water Stress . *Irrigation and Drainage*, 65: 112–128.
27. Noori, N., Kalin, L. and Isik, S. 2020. Water quality prediction using SWAT-ANN coupled approach. *Journal of Hydrology*, 590: 125220.
28. 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.
29. Xin, H., Peiling, Y., Shumei, R., Yunkai, L., Guangyu, J. and Lianhao, L. 2016. Quantitative response of oil sunflower yield to evapotranspiration and soil salinity with saline water irrigation. *International Journal of Agricultural and Biological Engineering*, 9(2): 63-73.
30. Zhang, B., Feng, G., Ahuja, L. R., Kong, X., Ouyang, Y., Adeli, A. and Jenkins, J. N. 2018. Soybean crop-water production functions in a humid region across years and soils determined with APEX model. *Agricultural Water Management*, 204: 180-191.

## Development of Production Functions for Important Cereals of Qazvin Plain under Water Shortage and Salinity Stress Using AquaCrop Model and Artificial Neural Network

**S. Bulukazari, H. Babazadeh<sup>1</sup>, N. A. Ebrahimi-Pak, S. H. Mosavi-Jahromi, and H. Ramezani-Etedali**

Ph.D. Candidate, Department of Water Science and Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

**Sara.bulukazari@yahoo.com**

Professor, Department of Water Science and Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran.

**h\_babazadeh@hotmail.com**

Associate Professor, Department of Irrigation, Soil and Water Research Institute, Agricultural Research, Education and Promotion Organization, Karaj, Iran.

**nebrahimipak@yahoo.com**

Professor, Department of Civil Engineering, Shahr-e-Qods Branch, Islamic Azad University, Tehran, Iran.

**h-mousavi@srbiau.ac.ir**

Associate Professor, Department of Water Engineering, Imam Khomeini International University, Qazvin, Iran.

**ramezani@eng.ikiu.ac.ir**

Received: May 2021, and Accepted: September 2021

### Abstract

In exploitation of low-quality water in arid and semi-arid regions, irrigation management is essential to increase water use efficiency. Determination of crop-water-salinity production function is an essential tool for proper irrigation management. In this study, the AquaCrop model was first evaluated by considering 4 soil and water salinity levels and 4 deficit irrigation levels for the major cereal crops including wheat, barley, and corn in Qazvin Plain. The results showed that the coefficients of determination for wheat, barley, and corn yield were 0.97, 0.86 and 0.91, respectively. Therefore, the model can evaluate the performance in salinity and deficit irrigation conditions with a good approximation. To determine the optimal production functions of each crop, the results of the plant model were compared with three models of linear and nonlinear regression, and artificial neural network. The neural network model was able to estimate the performance compared to the AquaCrop model with lower error and higher correlation (0.99). These values in the linear function for wheat, barley, and corn were 0.98, 0.95, and 0.78 and in the nonlinear function as 0.92, 0.86 and 0.81, respectively. Also, the error calculated in the neural network method for wheat, barley, and maize was 40.16, 62.09, and 57.08 kg, respectively, which were less than the linear model by 75 %, 70 %, and 95 %; and less than the exponential model by 90 %, 85 %, and 93%, respectively. The best trained network for determining the water-salt production function for barley and wheat 5 Nero and for corn 7 Nero was introduced in the single layer structure. Sensitivity analysis on wheat and barley showed that this model had low sensitivity to irrigation and salinity parameters and only corn plant showed a moderate range sensitivity to salinity parameter.

**Keywords:** Sensitivity Analysis, Wheat, Barley, Corn, Irrigation management

<sup>1</sup> - Corresponding Author: Department of Water Science and Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran