



مجله پژوهش‌های تولید گیاهی

جلد نوزدهم، شماره چهارم، ۱۳۹۱

<http://jopp.gau.ac.ir>

پیش‌بینی عملکرد ذرت علوفه‌ای با استفاده از شبکه‌های عصبی مصنوعی

سارا باقری^۱، * مهدی قیصری^۲، شمس‌اله ایوبی^۳ و نیلوفر لوائی^۴

^۱ دانشجوی سابق کارشناسی ارشد آبیاری و زهکشی، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، ^۲ استادیار گروه خاکشناسی، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، ^۳ مهندس برق و دانشجوی سابق مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان

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. در این میان مدل‌های کامپیوتری امکان بررسی استراتژی‌های مختلف مدیریتی را فراهم آورده‌اند. هدف اصلی این پژوهش تعیین حداقل پارامترهای ورودی مورد نیاز برای تعیین عملکرد ذرت علوفه‌ای به کمک شبکه‌های عصبی مصنوعی و نیز کاربرد این نوع از شبکه‌ها برای پیش‌بینی عملکرد ذرت علوفه‌ای در سطوح مختلف آب و کود نیتروژنی می‌باشد. بدین منظور داده‌های آزمایشی مزرعه‌ای ذرت علوفه‌ای در چهار سطح آبیاری ۰/۷، ۰/۸۵، ۱ و ۱/۱۳ آب مورد نیاز گیاه (ET_c) و سه سطح کودی صفر، ۱۵۰ و ۲۰۰ کیلوگرم نیتروژن در هکتار مورد استفاده قرار گرفت. نتایج نشان داد زمانی که حداقل سه پارامتر آب آبیاری، کود نیتروژنی و درجه روز رشد به‌عنوان ورودی به مدل شبکه عصبی مصنوعی معرفی شوند این مدل قادر به پیش‌بینی عملکرد ماده خشک ذرت علوفه‌ای با دقت بالایی می‌باشد. بهترین اعتبار سنجی این مدل، در گام دهم آموزش و با میانگین مربعات خطای ۰/۰۰۳۲ حاصل شد. همچنین نتایج آنالیز حساسیت حاکی از آن بود که درجه روز رشد با ضریب حساسیت ۹/۹۶، مهمترین پارامتر مؤثر بر پیش‌بینی عملکرد ذرت علوفه‌ای می‌باشد و پس از آن میزان آب آبیاری با ضریب حساسیت ۲/۰۷ قرار می‌گیرد. افزودن

*مسئول مکاتبه: gheysari@cc.iut.ac.ir

پارامترهای تشعشع خورشیدی و رطوبت نسبی متوسط به ورودی‌ها سبب کاهش میزان میانگین مربعات خطا یا به عبارتی افزایش دقت مدل در روند آموزش شبکه می‌شوند.

واژه‌های کلیدی: ذرت، آبیاری، کود نیتروژنی، آنالیز حساسیت، پارامترهای هواشناسی.

مقدمه

ذرت علوفه‌ای یکی از مهمترین گیاهان علوفه‌ای در ایران و جهان است و در ایران معمولاً در مناطق خشک و نیمه خشک و در ابتدای فصل تابستان پس از برداشت گندم و جو پائیزه کشت می‌شود. با توجه به زمان کاشت و شرایط اقلیمی، آبیاری این گیاه زراعی اجتناب‌ناپذیر است و بنابراین تدوین برنامه آبیاری و اعمال مدیریت صحیح آبیاری می‌تواند در افزایش کارایی تولید این گیاه و نیز کاهش زیان‌های ناشی از کمبود منابع آب تأثیر بسزایی داشته باشد. در کشاورزی مدرن نیاز به نیتروژن نسبت به سایر عناصر غذایی بیشتر است و خاک بیشتر مناطق کشاورزی جهان فاقد این عنصر غذایی مهم است. نیاز نیتروژن گیاه با اضافه کردن کودهای نیتروژنی به زمین تأمین می‌گردد.

تاکنون مطالعات بسیاری در زمینه شناخت عوامل مؤثر بر میزان رشد و نمو گیاهان زراعی و از جمله گیاه ذرت صورت گرفته است که در این میان می‌توان به مطالعات ولف و همکاران (b و a ۱۹۸۸)، سادراس و کالوینو (۲۰۰۱)، بتران و همکاران (۲۰۰۳)، قیصری و همکاران (b و a ۲۰۰۹) و سیچینو و همکاران (۲۰۱۰) اشاره نمود. با توجه به جایگاه ویژه گیاه ذرت علوفه‌ای در میان گیاهان علوفه‌ای، مدل‌سازی عملکرد این گیاه و تعیین عوامل مؤثر بر رشد آن از اهمیت بالایی برخوردار است. یکی از روش‌های مدل‌سازی که در سال‌های اخیر مورد توجه بسیاری از محققین در علوم مختلف واقع شده است، مدل‌سازی به روش شبکه عصبی مصنوعی^۱ می‌باشد. پژوهشگران علوم کشاورزی از شبکه‌های عصبی مصنوعی در شبیه‌سازی پارامترهایی چون میزان تبخیر-تعرق هفتگی (لندراس و همکاران، ۲۰۰۹)، تبخیر روزانه (پیری و همکاران، ۲۰۰۹)، پیش‌بینی دمای هوا (اسمیت و همکاران، ۲۰۰۹)، تشعشع خورشیدی (میوبیرو، ۲۰۰۸)، پیش‌بینی سیلاب (موکرجی و همکاران، ۲۰۰۹)، تخمین میزان فرسایش خاک (کیم و جیلی، ۲۰۰۸) و قابلیت نگاه‌داشت آب و ضریب آب‌گذری اشباع خاک (مردون و همکاران، ۲۰۰۶) استفاده کرده‌اند. دراموند و همکاران (۲۰۰۳) جهت تعیین

1- Artificial Neural Network (ANN)

روابطی 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 رگرسیونی دارای خطای کمتری می‌باشد. 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. آلاوز (۲۰۰۹) شبکه‌های عصبی مصنوعی را جهت تعیین بازده گیاه گندم در منطقه پامپاس آرژانتین به کار برد. وی نسبت بارندگی به تبخیر- تعرق پتانسیل محصول (R/CPET) را به عنوان مهمترین فاکتور آب و هوایی مؤثر بر بازده این محصول معرفی نمود. نوروزی و همکاران (۲۰۱۰) از شبکه‌های عصبی مصنوعی به منظور پیش‌بینی عملکرد گندم دیم 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 بوده است و میزان پروتئین موجود در دانه‌ها تحت تأثیر میزان نیتروژن کل خاک می‌باشد.

باتوجه به اینکه بررسی پاسخ ذرت علوفه‌ای به نهاده‌های مختلف در اقلیم‌های متفاوت با روش میدانی زمان‌بر و پرهزینه و در پاره‌ای 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 استفاده کرده و قادر به ارائه نتایج نزدیکتری به واقعیت هستند، مطلوب می‌باشند.

تاکنون مطالعه‌ای در زمینه کاربرد مدل‌های شبکه عصبی مصنوعی در شناسایی حداقل پارامترهای ورودی مورد نیاز برای شبیه‌سازی عملکرد ذرت علوفه‌ای انجام نشده است. این پژوهش به منظور تعیین حداقل پارامترهای ورودی مؤثر در تعیین عملکرد این گیاه با استفاده از شبکه‌های عصبی مصنوعی و کاربرد این نوع از شبکه‌ها برای پیش‌بینی عملکرد ذرت علوفه‌ای تحت سطوح مختلف آب کاربردی و کود نیتروژنی در منطقه ورامین صورت گرفته است.

مواد و روش‌ها

داده‌های این پژوهش نتایج آزمایش‌های مزرعه‌ای می‌باشد که در سال‌های زراعی ۱۳۸۲ و ۱۳۸۳ روی ذرت علوفه‌ای صورت گرفته است. مزرعه مورد مطالعه در شهرستان ورامین با طول جغرافیایی ۳۸° ۵۲ شرقی، عرض جغرافیایی ۲۰° ۳۵ شمالی و ارتفاع ۹۷۲ متر از سطح دریا قرار گرفته است. متوسط بارندگی در این منطقه ۱۷۰ میلی‌متر می‌باشد که اکثراً در فصول پاییز و زمستان رخ می‌دهد. سطح آب زیرزمینی در عمقی بیشتر از ۱۰ متری سطح خاک قرار دارد. بافت خاک لوم رسی با چگالی ظاهری ۱/۳۲ گرم بر سانتی‌مترمکعب و چگالی واقعی ۲/۵۵ گرم بر سانتی‌مترمکعب می‌باشد. در این تحقیق سه سطح کودی صفر، ۱۵۰ و ۲۰۰ کیلوگرم نیتروژن در هکتار و چهار سطح آبیاری ۰/۷، ۰/۸۵، ۱ و ۱۳/۱ تخلیه آب خاک^۱ با استفاده از طرح آماری کرت‌های نواری در قالب بلوک‌های کامل تصادفی با سه تکرار در نظر گرفته شد. هر کرت شامل ۱۵ جوی و پشته به فاصله ۷۵ سانتی‌متر و طول ۱۶ متر و بذر مصرفی از نوع هیبرید ذرت علوفه‌ای سینگل کراس ۷۰۴ بود. برای آبیاری گیاه از سیستم آبیاری بارانی کلاسیک ثابت با آبیاش متحرک استفاده شد. جهت اندازه‌گیری رطوبت خاک در سال اول از روش وزنی و در سال دوم از نوترون‌متر استفاده شد. زمان آبیاری بر اساس میزان تخلیه مجاز رطوبت، برابر ۵۰ درصد آب قابل دسترس خاک در عمق توسعه ریشه گیاه، در تیمار بدون تنش تعیین شد. عمق آب آبیاری برای پر کردن کمبود رطوبت خاک در عمق توسعه ریشه تا حد رطوبت ظرفیت مزرعه در تیمار شاهد محاسبه گردید. سایر تیمارهای آبیاری ضریبی (۰/۷، ۰/۸۵، ۱ و ۱/۱۳) از عمق آب آبیاری محاسبه شده را دریافت نمودند. با توجه به این امر که عمق آبیاری با هدف جبران کمبود رطوبت خاک در عمق توسعه ریشه تا حد ظرفیت مزرعه اعمال گردید، دور آبیاری در طی فصل رشد متغیر بود اما زمان آبیاری تیمارهای مختلف آبیاری یکسان بود. کود نیتروژنی به همراه آب آبیاری از منبع کودی اوره در طی دوره رشد تأمین گردید. داده‌های هواشناسی مورد نیاز که شامل درجه حرارت روزانه، تشعشع خورشیدی، رطوبت نسبی متوسط و سرعت متوسط باد می‌باشند، از ایستگاه هواشناسی ورامین واقع در فاصله ۵۰۰ متری محل اجرای طرح، تهیه شدند. وزن زیست‌توده^۲ در طی دوره رشد و در زمان برداشت اندازه‌گیری شد. اولین نمونه‌گیری گیاهی ۲۵ روز پس از کاشت از یک متر طول ردیف کاشت، و سایر نمونه‌گیری‌های گیاهی با فاصله زمانی دو هفته یکبار از سه بوته انجام

1- Soil Moisture Depletion (SMD)

2- Biomass

شد. نمونه‌گیری در مرحله برداشت علوفه‌ای از دو ردیف کاشت با مجموع طول ۹ متر از وسط کرت انجام شد. به این منظور نمونه‌های برداشت شده، شامل کلیه اندام‌های هوایی گیاه، به مدت ۴۸ ساعت در دمای ۷۵ درجه سانتی‌گراد داخل آون خشک و سپس توزین شدند. همچنین تمام مراحل رویشی و زایشی ذرت، در طی دوره رشد به ثبت رسید. جزئیات بیشتر در مورد روش کار مزرعه‌ای در مراجع قیصری و همکاران (۲۰۰۹a) و قیصری و همکاران (۲۰۰۹b) ارائه شده است. شکل (۱) تغییرات برخی از مهمترین پارامترهای مورد مطالعه در این پژوهش را نشان می‌دهد.

از داده‌های درجه حرارت روزانه به منظور تعیین پارامتر درجه روز رشد^۱ استفاده شد. این پارامتر از رابطه زیر به دست می‌آید:

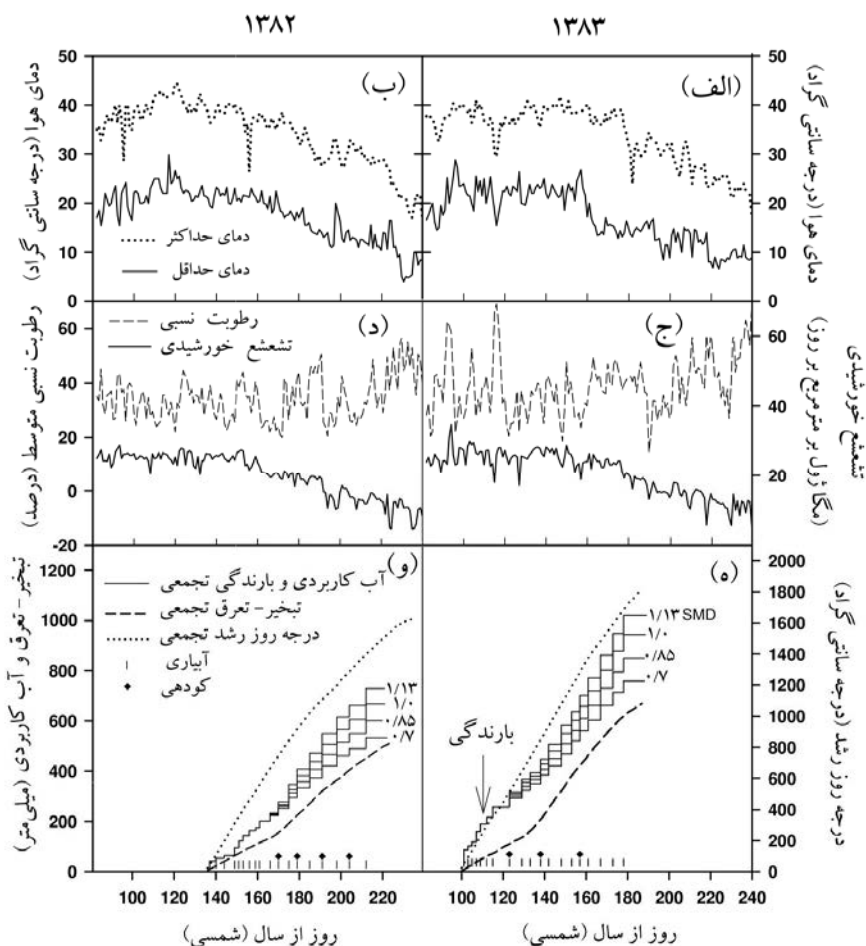
$$GDD = \sum_{i=1}^n \frac{T_{max_i} + T_{min_i}}{2} - T_b \quad (1)$$

در این رابطه T_{min_i} دمای حداقل روزانه برحسب درجه سانتی‌گراد، T_{max_i} دمای حداکثر روزانه برحسب درجه سانتی‌گراد، T_b دمای پایه گیاه که برای ذرت برابر ۸ درجه سانتی‌گراد در نظر گرفته می‌شود (کیری، ۱۹۹۱) و n مشخص کننده تعداد روز می‌باشد. ضریب پراکندگی پارامتر درجه روز رشد (نسبت انحراف معیار به میانگین داده‌ها) برای داده‌های موجود برابر ۰/۳۵ محاسبه شد.

شبکه عصبی مصنوعی: شبکه‌های عصبی مصنوعی با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به همین خاطر به این سیستم‌ها هوشمند گفته می‌شود، چراکه بر اساس محاسبات روی داده‌های عددی یا مثال‌ها، قوانین کلی را فرا می‌گیرند. در ساختار این سیستم‌ها پارامترهایی وجود دارند که قابل تنظیم می‌باشند. 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^۲ آن سیستم گفته می‌شود. در واقع این سیستم‌ها قادرند یاد بگیرند و از راه یادگیری، دانش لازم برای برخورد مناسب با یک پدیده را جمع‌آوری نمایند و از آن دانش به هنگام نیاز بهره ببرند (چین و همکاران، ۱۹۹۶).

1- Growing Degree Days (GDD)

2- Training



شکل ۱- حداقل و حداکثر دمای هوا در طی فصل رشد در سال‌های (الف) ۱۳۸۳ و (ب) ۱۳۸۲؛ متوسط رطوبت نسبی و تشعشع خورشیدی در سال‌های (ج) ۱۳۸۳ و (د) ۱۳۸۲؛ میزان آب کاربردی، تبخیر-تعرق بر اساس رابطه فانو-پنمن-مانتیش، درجه روز رشد، زمان‌های آبیاری و کودهی در سال‌های (ه) ۱۳۸۳ و (و) ۱۳۸۲.

شبکه‌های عصبی مصنوعی علی‌رغم تنوع، از ساختار مشابهی برخوردار می‌باشند و معمولاً از سه لایه ورودی، پنهان و خروجی تشکیل شده‌اند (منهاج، ۲۰۰۱). لایه ورودی فقط اطلاعات را دریافت کرده و مشابه متغیر مستقل عمل می‌کند، بنابراین تعداد نرون‌های لایه ورودی بر اساس طبیعت مسأله تعیین می‌شود و بستگی به تعداد متغیرهای مستقل دارد. لایه خروجی نیز همانند متغیر وابسته عمل

نموده و تعداد نرون‌های آن بستگی به تعداد متغیر وابسته دارد. اما بر خلاف لایه‌های ورودی و خروجی، لایه پنهان بیانگر هیچ مفهومی نمی‌باشد، بلکه وظیفه تنظیم وزن‌ها و یادگیری را برعهده داشته و تنها یک نتیجه میانی در فرآیند محاسبه ارزش خروجی می‌باشد.

روش‌های آموزش شبکه به دو دسته کلی با نظارت و بدون نظارت تقسیم می‌شوند. آموزش نظارت شده به زوج‌هایی نیاز دارد که از بردار ورودی و بردار هدف (خروجی دلخواه) تشکیل شده باشند. یک بردار ورودی و خروجی دلخواه مربوط به آن، یک زوج آموزشی نامیده می‌شود. معمولاً یک شبکه تحت تعدادی از چنین زوج‌های آموزشی تربیت می‌گردد. به این صورت که با به کار بردن یک بردار ورودی، خروجی شبکه محاسبه و با بردار هدف خود مقایسه می‌شود و تفاوت بین خروجی محاسبه شده و خروجی دلخواه که خطا نامیده می‌شود به سمت عقب در سراسر شبکه منتشر می‌گردد و سپس وزن‌ها مطابق با الگوریتمی که تمایل به حداقل رساندن خطا را دارد تغییر یافته و تنظیم می‌شوند. یکی از الگوریتم‌هایی که در روش‌های آموزش با نظارت مورد استفاده قرار می‌گیرد، الگوریتم لونیبرگ-مارکواریت است که در سال ۱۹۹۴ ارائه شد و از جمله سریع‌ترین و مؤثرترین روش‌های آموزش به شمار می‌آید که برای شبکه‌های با حجم متوسط بسیار سریع‌تر از الگوریتم‌های دیگر است (هاگان و همکاران، ۱۹۹۵). شبکه‌های عصبی مصنوعی مورد استفاده در این تحقیق از نوع پرسپترون سه لایه با الگوریتم آموزش انتشار به عقب لونیبرگ-مارکواریت بوده که به کمک نرم افزار متلب (۲۰۰۷) طراحی شده‌اند.

آموزش شبکه‌های عصبی در واقع تعیین مقادیر بهینه وزن‌ها می‌باشد تا شبکه کمترین خطا را داشته باشد. ایده کلی این آموزش از روند تربیت و آموزش در انسان گرفته شده است. ذهن انسان از بدو تولد با دریافت الگوهای مختلف از خارج شکل گرفته و در واقع وزن‌های داخلی ذهن براساس الگوهای مختلف تغییر می‌یابند. همین ایده در شبکه‌های عصبی مصنوعی استفاده شده است. بدین ترتیب که در ابتدا یکسری وزن‌ها به صورت تصادفی انتخاب شده و سپس با توجه به اطلاعات آموزشی که شامل ورودی و خروجی‌های مرتبط می‌باشد و یک روش مناسب تربیت، وزن‌ها به نحوی تغییر می‌کنند که شبکه به ازای مقادیر ورودی داده‌ها، مقادیر خروجی را بدهد.

یکی از مشکلاتی که در آموزش شبکه‌های عصبی اتفاق می‌افتد مشکل فرا انطباقی^۱ است. در این وضعیت میزان خطا در مورد داده‌های آموزشی بسیار کم و در مورد داده‌های جدیدی که به شبکه ارائه می‌شود زیاد است. در واقع شبکه به جای اینکه داده‌های کلی را یاد بگیرد، نمونه‌های آموزشی را حفظ می‌کند. یکی از راه‌های جلوگیری از این مشکل، تقسیم داده‌ها به دو قسمت می‌باشد. دسته اول برای آموزش و دسته دوم برای معتبر ساختن شبکه به کار می‌رود. دسته دوم که خود شامل دو قسمت اعتبارسنجی و آزمون می‌باشد، در تنظیم پارامترها نقشی ندارند ولی تغییرات میزان خطا برای هر دو دسته در حین آموزش بررسی می‌شود. هنگامی که میزان خطا برای دسته دوم در چندین تکرار افزایش پیدا کرد آموزش متوقف شده و پارامترها به حالتی که خطای دسته دوم حداقل بوده است برگردانده می‌شود. به همین منظور از ۲۸۴ داده اندازه‌گیری شده، تعداد ۲۰۰ سری داده برای آموزش شبکه به صورت تصادفی انتخاب و از ۸۴ سری باقیمانده، ۴۲ داده برای اعتبارسنجی و ۴۲ داده برای آزمون شبکه استفاده شد. داده‌های مذکور از ۳۶ پلات آزمایشی در طی مراحل مختلف رشد تهیه شده‌اند. برای تعیین صحت و اعتبار مدل‌ها از آماره‌های ضریب تبیین (R) بین مقادیر اندازه‌گیری شده و پیش‌بینی شده و میانگین مربعات خطا^۲ استفاده شد که این آماره از رابطه زیر قابل محاسبه است (کسکین و تایلن، ۲۰۰۹):

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - x'_i)^2 \quad (2)$$

که در آن x_i مقدار شبیه‌سازی شده داده‌ها، x'_i مقدار اندازه‌گیری شده داده‌ها، i شمارشگر و n تعداد داده‌های اندازه‌گیری شده است. هرچه مقدار میانگین مربعات خطا کمتر باشد، بیانگر آن است که نتایج شبیه‌سازی شده مدل به مقادیر اندازه‌گیری شده نزدیک‌تر است.

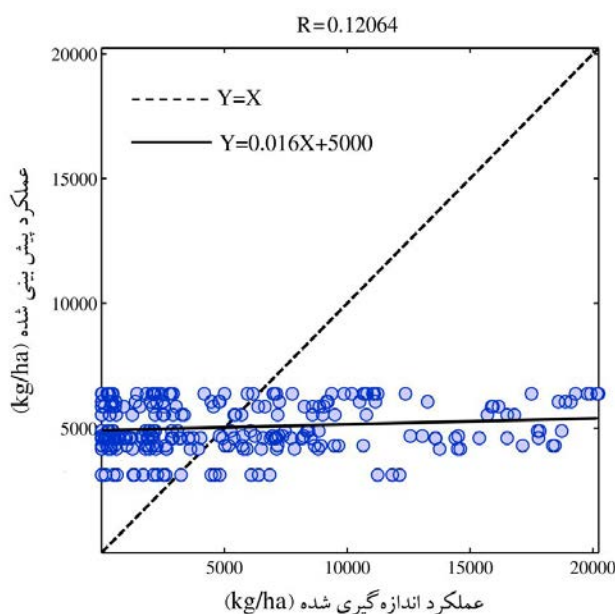
نتایج و بحث

تعیین متغیرهای ورودی مدل: یکی از مهم‌ترین مراحل فرآیند توسعه مدل‌های شبکه عصبی تعیین متغیرهای ورودی مؤثر می‌باشد. معمولاً همه متغیرهای ورودی دارای اهمیت یکسان نبوده و مقادیر برخی از آنها ممکن است توأم با ناطمینانی بوده و یا هیچ رابطه معنی‌داری با متغیر خروجی نداشته


1- Over fitting

2- Mean Square Error (MSE)


باشند. در این پژوهش ابتدا مقادیر آب آبیاری و کود نیتروژنی به عنوان ورودی‌های مدل و میزان عملکرد خشک به عنوان خروجی مد نظر قرار گرفتند. با ورود این دو پارامتر، مدل شبکه عصبی قادر به شناسایی این روند نبوده (شکل ۲) و در نتیجه نیاز به پارامتر سوم حساس می‌شود. با توجه به اینکه رشد گیاه و سپری نمودن مراحل مختلف فیزیولوژیک آن تابع مقدار انرژی دریافتی توسط گیاه می‌باشد، پارامتر درجه روز رشد به عنوان یکی دیگر از متغیرهای اساسی در تعیین میزان عملکرد خشک انتخاب گردید. در این شرایط شبکه عصبی روند را شناسایی نموده و بنابراین سه متغیر ورودی آب آبیاری، کود نیتروژنی و مقدار درجه روز رشد پارامترهای لازم برای شناسایی روند توسط شبکه عصبی مصنوعی می‌باشند. در زمانی که پارامتر درجه روز رشد به تنهایی در مقابل عملکرد خشک بررسی شد، نتایج نشان داد که مقدار عملکرد خشک با افزایش این پارامتر افزایش یافته، اما شبکه قادر به تشخیص تغییرات موجود در میزان عملکرد خشک برای یک درجه روز رشد مشخص، که به علت تفاوت در مقادیر آب آبیاری و کود دریافتی می‌باشد، نبوده است (شکل ۳). با توجه به مطالب بیان شده مشخص است که شبکه زمانی قادر به تخمین عملکرد واقعی محصول است که آموزش با هر سه ورودی آب آبیاری، کود نیتروژنی و میزان درجه روز رشد صورت گیرد.



شکل ۲- مقایسه عملکرد خشک واقعی و محاسبه شده به وسیله شبکه با ورودی میزان آب آبیاری و مقدار کود نیتروژنی.




شکل ۳- منحنی برازش یافته توسط شبکه بین مقدار درجه روز رشد به عنوان ورودی و عملکرد خشک به عنوان خروجی.




شکل ۴- مقایسه عملکرد خشک واقعی و محاسبه شده به وسیله شبکه با ورودی درجه روز رشد.

پس از آزمایشات مکرر شبکه‌ای با یک لایه پنهان و ۲۵ نرون در این لایه و تابع محرک سیگموئید کمترین مقدار خطا را در روند آموزش شبکه، اعتبارسنجی و آزمون آن ایجاد نمود (شکل ۵). خط بهترین اعتبارسنجی در شکل ۵ نشان‌دهنده بهترین مقدار میانگین مربعات خطا برای شبکه طراحی شده می‌باشد و زمانی روند آموزش شبکه صحیح بوده که مقدار میانگین مربعات خطای منحنی آموزش کمتر از این مقدار باشد و نیز منحنی‌های مربوط به مقادیر اعتبارسنجی و آزمون نزدیک یکدیگر قرار گیرند که تمامی این موارد در شکل ۵ مشاهده می‌شوند. با توجه به شکل ۵ بهترین اعتبارسنجی در گام دهم آموزش و با میانگین مربعات خطای ۰/۰۰۳۲ حاصل شد.

شکل ۶ همبستگی بین عملکرد خشک واقعی و محاسبه شده توسط شبکه عصبی مصنوعی را نشان می‌دهد ($R=0.988$). مقدار بالای ضریب همبستگی، نشان‌دهنده توانایی شبکه طراحی شده در تخمین میزان عملکرد خشک با ورودی‌های بیان شده است.



شکل ۵- تغییرات میانگین مربعات خطا در طول گام‌های آموزشی با ورودی میزان آب آبیاری، مقدار کود نیتروژنی و درجه روز رشد.



شکل ۶- مقایسه عملکرد خشک واقعی و محاسبه شده به وسیله شبکه با ورودی میزان آب آبیاری، مقدار کود نیتروژنی و میزان درجه روز رشد.


آنالیز حساسیت: فرآیند آنالیز حساسیت، میزان حساسیت مدل را نسبت به متغیرهای ورودی آن نشان می‌دهد. در این پژوهش برای انجام آنالیز حساسیت مدل از روش Statsoft استفاده گردید (استات سافت، ۲۰۰۴). در این روش مقادیر ضریب حساسیت متغیرهای ورودی از تقسیم نمودن خطای کل شبکه در غیاب یک متغیر بر خطای کل شبکه در حضور تمامی متغیرهای ورودی، به دست می‌آید. بر این اساس اگر مقدار ضریب حساسیت یک متغیر بیشتر از یک باشد، آن متغیر سهم زیادی در توضیح تغییرپذیری مؤلفه‌های عملکرد دارد (نوروزی، ۲۰۰۹). نتایج آنالیز حساسیت برای مؤلفه‌های عملکرد ذرت در جدول ۱ ارائه شده است.

جدول ۱- ضرایب حساسیت پارامترهای مورد استفاده در روش Statsoft


پارامترهای ورودی	فاکتور حذف شده	MSE	ضریب حساسیت فاکتور حذف شده
درجه روز رشد+آب+کود	—	۰/۰۰۳۲۱۴۶	—
درجه روز رشد+آب	کود	۰/۰۰۴۱۵۲۸	۱/۲۹
درجه روز رشد+کود	آب	۰/۰۰۶۶۵۴۶	۲/۰۷
آب+کود	درجه روز رشد	۰/۰۳۲۰۱۸	۹/۹۶

بر اساس جدول ۱ پارامتر درجه روز رشد به عنوان مهم ترین پارامتر مؤثر بر پیش بینی عملکرد ذرت علوفه ای شناخته شد و پس از آن به ترتیب پارامترهای آب و کود نیتروژنی حائز اهمیت می باشند. به منظور بررسی نتایج حاصل از روش Statsoft نمودارهای بی بعد شده عملکرد به ازای تغییرات $\pm 10\%$ هر یک از پارامترهای ورودی ترسیم شد. در این روش یکی از متغیرها را به میزان ۱۰ درصد تغییر داده و با ثابت نگاه داشتن سایر متغیرها، شبکه اجرا می شود و خروجی آن به دست می آید. خروجی های محاسبه شده در مقابل پارامتر مورد بررسی ترسیم می گردند، انحراف بیشتر خطوط عملکرد با تغییرات $\pm 10\%$ نسبت به خط عملکرد با داده های واقعی نشان دهنده حساسیت بیشتر مدل به پارامتر تغییر یافته است. همان گونه که از شکل های ۷، ۸ و ۹ مشخص است تغییرات درجه روز رشد بر میزان عملکرد پیش بینی شده توسط شبکه تأثیر بیشتری داشته و پس از آن پارامترهای آب و کود نیتروژنی قرار می گیرند. نتایج حاصل از این روش با نتایج روش Statsoft مطابقت دارد.


سadaras و کالوینو (۲۰۰۱) تعیین نمودند که ۹۰ درصد از تغییرات عملکرد سویا و ۷۶ درصد تغییرات عملکرد ذرت به کمبود آب مرتبط است، همچنین کول و همکاران (۲۰۰۵) اظهار داشتند که پارامتر آب قابل دسترس یکی از فاکتورهای اساسی در تخمین عملکرد محصولات کشاورزی می باشد. انجام تحلیل حساسیت در این مطالعه نیز مشخص کرد که بعد از پارامتر درجه روز رشد که بیانگر میزان انرژی دریافتی توسط گیاه می باشد، پارامتر مقدار آب آبیاری در برآورد میزان عملکرد ذرت علوفه ای نقش بسزایی دارد. در واقع میزان آب، بر توسعه برگ ها و نمو زایشی گیاه تأثیر داشته و نیز از طریق اثر بر روی تعادل عرضه و تقاضای آب و نیتروژن در طول پر شدن دانه ها بر میزان عملکرد گیاه مؤثر است (ولف و همکاران، a و b ۱۹۸۸).



شکل ۷- نسبت عملکرد محاسبه شده به وسیله شبکه به نسبت تغییرات پارامتر درجه روز رشد.



شکل ۸- نسبت عملکرد محاسبه شده به وسیله شبکه به نسبت تغییرات پارامتر آب آبیاری.



شکل ۹- نسبت عملکرد محاسبه شده به وسیله شبکه به نسبت تغییرات پارامتر کود نیتروژنی.

بررسی تأثیر افزودن پارامترهای هواشناسی بر عملکرد شبکه: در ادامه تأثیر افزودن پارامترهای تشعشع خورشیدی، متوسط رطوبت نسبی و متوسط سرعت باد در روند آموزش شبکه بررسی شد. همان‌طور که جدول ۲ نشان می‌دهد، منظور کردن این پارامترها تأثیر چندانی بر روی ضریب همبستگی ندارد اما اضافه کردن پارامترهای تشعشع خورشیدی و رطوبت نسبی سبب کاهش میزان میانگین مربعات خطا می‌گردد. افزودن همزمان این دو پارامتر به شبکه سبب کاهش میانگین مربعات خطا شده اما میزان این کاهش در مقایسه با زمانی که هریک از این پارامترها به صورت مجزا اعمال شوند کمتر است. همچنین نتایج حاکی از آن بود که افزودن پارامتر سرعت باد، تأثیری در بهبود روند آموزش شبکه ندارد.

جدول ۲- خصوصیات بهترین شبکه‌های عصبی مصنوعی با افزودن پارامترهای هواشناسی

MSE	R	تعداد نرون در لایه منحرفی	متغیرهای ورودی
۰/۰۰۳۲	۰/۹۸۷۶	۲۵	درجه روز رشد+آب+کود
۰/۰۰۱۵	۰/۹۸۸۱	۲۲	درجه روز رشد+آب+کود+تشعشع خورشیدی
۰/۰۰۱۶	۰/۹۸۷۹	۲۷	درجه روز رشد+آب+کود+رطوبت نسبی
۰/۰۰۳۱	۰/۹۸۵۴	۲۴	درجه روز رشد+آب+کود+سرعت متوسط باد
۰/۰۰۲۱	۰/۹۸۶۵	۲۶	درجه روز رشد+آب+کود+تشعشع خورشیدی+رطوبت نسبی

نتیجه گیری

در این پژوهش از توانایی شبکه‌های عصبی مصنوعی به عنوان ابزاری جهت تعیین پارامترهای مؤثر در عملکرد گیاه ذرت علوفه‌ای و نیز برآورد میزان عملکرد خشک این گیاه در طول دوره رشد استفاده شد. نتایج نشان داد زمانی که آب آبیاری، مقدار کود نیتروژنی و میزان درجه روز رشد به عنوان ورودی به مدل معرفی شوند، مدل می‌تواند عملکرد خشک گیاه را با دقت نسبتاً بالایی برآورد نماید. انجام آنالیز حساسیت مشخص نمود که بعد از پارامتر درجه روز رشد که بیانگر میزان انرژی دریافتی توسط گیاه و یا به عبارتی مرحله رشد گیاه می‌باشد، پارامتر مقدار آب آبیاری در برآورد میزان عملکرد ذرت علوفه‌ای نقش بسزایی دارد و پس از این دو پارامتر میزان کود نیتروژنی حائز اهمیت می‌باشد. همچنین با بررسی پارامترهای هواشناسی موجود مشخص شد که افزودن پارامترهای تشعشع خورشیدی و رطوبت نسبی به ورودی‌های مدل سبب کاهش میزان میانگین مربعات خطا یا به عبارتی افزایش دقت شبیه سازی در روند آموزش شبکه می‌شود اما افزودن پارامتر سرعت باد تأثیری در بهبود روند آموزش شبکه ندارد.

منابع

1. 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.

2. Betran, F.J., Ribaut, J.M., Beck, D., and Gonzalez de leon, D. 2003. Genetic diversity, specific combining ability, and heterosis in tropical maize under stress and nonstress environments. *Crop Sci.* 43:797-806.
3. Cicchino, M., Rattalino Edreira, J.I., Uribebarrea M., and Otegui, M.E. 2010. Heat stress in field-grown maize: response of physiological determinants of grain yield. *Crop Sci.* 50:1438-1448.
4. 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.
5. Gheysari, M., Mirlatifi, S.M., Bannayan, M., Homae, M., and Hoogenboom, G. 2009a. Interaction of water and nitrogen on maize grown for silage. *Agric Water Manage.* 96: 809-821.
6. Gheysari, M., Mirlatifi, S.M., Homae, M., Asadi, M.E., and Hoogenboom, G. 2009b. Nitrate leaching in a silage maize field under different irrigation and nitrogen fertilizer rate. *Agric Water Manage.* 96: 946-954.
7. Hagan, M.T., Demuth, H.B., and Beale, M. 1995. *Neural Network Design*. PWS Publishing Company.
8. Jain, A.K., Mao, J., and Mohiuddin, K.M. 1996. *Artificial Neural Networks: a tutorial computer*. IEEE, Pp: 31-44.
9. Kaul, M., Hill, R.L., and Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. *Agric Sys.* 85: 1-18.
10. Keskin, M.E., and Taylan, D., 2009. Artificial models for interbasin flow prediction in southern Turkey. *Hydrologic Engineering, ASCE*, 14: 7. 752-758.
11. Kim, M., and Gilley, J. E. 2008. Artificial neural network estimation of soil erosion and nutrient concentrations in runoff from land application areas. *Comput. Electron. Agric.* 64: 268-275.
12. Kiniry, J.R. 1991. Maize phase development. In: Hanks, J., Ritchie, J. T. (Eds.), *Modeling Plant and Soil Systems*. Agronomy Monograph 31. ASA, Madison, WI, Pp: 55-69.
13. 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.
14. Matlab. 2007. *Neural Network Toolbox*. Mathworks Inc., Natick, MA, USA.
15. Menhaj, M.B., 2001. *Computational intelligence, fundamentals of neural networks*. 2nd ed., Amir Kabir University of Technology, Tehran: Iran (In Persian).
16. 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.
17. Mubiru, J. 2008. Predicting total solar irradiation values using artificial neural networks. *Renewable Energy*. 33: 2329-2332.

18. 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.
19. Norouzi, M., 2009. Prediction of rainfed wheat yield using artificial neural network in Ardal district of Chaharmahal and Bakhtiari province. M.Sc. Thesis, Collage of Agriculture, Isfahan University of Technology, Isfahan, Iran, 112 p. (In Persian)
20. 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.
21. 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.
22. Sadras, V.O., and Calviño, P.A. 2001. Quantification of grain yield response to soil depth in soybean, maize, sunflower, and wheat. *Agron J*. 93: 577-583.
23. 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.
24. StatSoft Inc. 2004. *Electronic Statistics Textbook* (Tulsa, OK). <http://www.statsoft.com/textbook/stathome.html>.
25. Wolfe, D.W., Henderson, D.W., Hsiao, T.C. and Alvino, A. 1988a. Interactive water and nitrogen effects on senescence of maize: I. Leaf area duration, nitrogen distribution, and yield. *Agron J*. 80: 859-864.
26. Wolfe, D.W., Henderson, D.W., Hsiao, T.C. and Alvino, A. 1988b. Interactive water and nitrogen effects on senescence of maize: II. Phptosynthtic decline and longevity of individual leaves. *Agron J*. 80: 865-870.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Plant Production, Vol. 19(4), 2012

<http://jopp.gau.ac.ir>

Silage maize yield prediction using artificial neural networks

S. Bagheri¹, M. Gheysari², Sh. Ayoubi³ and N. Lavaee⁴

¹Graduate Student, Dept. Water Engineering, College of Agriculture, Isfahan University of Technology, ²Assistant Prof., Water Engineering Department, College of Agriculture, Isfahan University of Technology, Iran, ³Associated Professor, College of Agriculture, Isfahan University of Technology, ⁴Graduated Student, Water Engineering Department, College of Agriculture, Isfahan University of Technology

Abstract

The increasing demands for agricultural products and pressure on the water and land resources also the problems to generate new data specify the necessity of using suitable models to predict the performance of agricultural products. In this situation, computer models provide the possibility to investigate different management strategies. The objectives of this study were to determine the least important computer input parameters which affecting the silage maize yield using artificial neural networks in different levels of water and nitrogen applications. The experiments included four irrigation levels (0.7, 0.85, 1.0, and 1.13 of crop evapotranspiration, ET_c) and three nitrogen fertilization levels (0, 150, and 200 kg N ha^{-1}). The results of artificial neural network analysis showed that when at least three parameters of irrigation, fertilizer and growing degree days (GDD) were introduced as the input of ANN, the model could predict the performance of silage maize with high accuracy. The best validation performance of the model was at step 10 with mean square error of 0.0032. Also the results of sensitivity analysis indicate that the growing degree days with the coefficient of sensitivity of 9.96 is the most important parameter for predicting of silage maize performance and after that is the amount of irrigation with the sensitivity coefficient of 2.07. The results showed that adding the solar radiation and average relative humidity to the input parameter cause reduction in MSE and increasing the accuracy of the model in the process network training.

Keywords: Maize; Irrigation; Nitrogen Fertilizer; Sensitivity Analysis; Weather Parameters.

*Corresponding Author; Email: gheysari@cc.iut.ac.ir