

برآورد سطح برگ بوته ذرت با استفاده از شبکه عصبی مصنوعی

خدیدجه نظری^۱، محسن زواره^{۲*} و افشین اشرفزاده^۳

(تاریخ دریافت: ۱۳۹۵/۲/۱۸؛ تاریخ پذیرش: ۱۳۹۵/۱۲/۱۱)

چکیده

با هدف برآورد ساده و دقیق سطح برگ بوته ذرت با شبکه عصبی پرسپترون چند لایه، آزمایشی در دانشکده علوم کشاورزی دانشگاه گیلان در سال زراعی ۱۳۹۳ - ۱۳۹۲ انجام شد. تیمارهای این آزمایش سه تراکم بوته (۷۵، ۸۵ و ۹۵ هزار بوته در هکتار) و پنج رقم (پریشیا ۴۵۴، پریشیا ۴۸۴، پریشیا ۵۶۵، پریشیا ۶۲۶ و ۶۴۷) بود و نمونه برداری در چهار زمان متفاوت (۳۵، ۴۹، ۶۳ و ۷۷ روز پس از کاشت) انجام شد. در هر نمونه برداری، تعداد برگ‌های روی بوته، تعداد، طول و عرض برگ‌های سبز، سطح برگ بوته، وزن خشک برگ و ساقه، ارتفاع بوته، قطر ساقه و عملکرد زیست‌توده اندازه‌گیری شدند. یافته‌ها نشان داد که متغیرهای اندازه‌گیری شده همبستگی مثبت و معنی‌داری با سطح برگ داشته ($r \geq 0.859^{**}$) و می‌توانند به‌عنوان ورودی در مدل‌های برآورد سطح برگ استفاده شوند. در بین آنها بیشترین حساسیت به‌ترتیب مرتبط با عرض برگ، تعداد برگ سبز، طول برگ، تعداد برگ‌های بوته و قطر ساقه بود. با این حال، استفاده از مدلی با آماره‌های مناسب و با ورودی‌های عرض، تعداد و طول برگ‌های سبز، برای برآورد سریع سطح برگ مناسب‌تر تشخیص داده شد. هنگامی که از تک‌ورودی برای برآورد سطح برگ استفاده شد، وزن خشک برگ نسبت به دیگر متغیرها، سطح برگ را به‌خوبی ($RMSE (\%) = 15/67$) شبیه‌سازی و ۹۵/۶۹٪ از تغییرات آن را توجیه ($r^2 = 0.9569$) کرد. در هر دو روش برآورد سطح برگ (آنالیز حساسیت و تک‌ورودی)، بهترین مدل برآورد شده تحت تأثیر رقم، تراکم و برهمکنش آنها قرار نگرفت. بنابراین، می‌توان از یک مدل کلی برای برآورد سطح برگ همه رقم‌ها و تراکم‌های این آزمایش استفاده کرد.

واژه‌های کلیدی: آنالیز حساسیت، پرسپترون چند لایه، تراکم، رقم، روابط آلومتریک

۱ و ۲. به‌ترتیب دانشجوی کارشناسی ارشد و دانشیار، گروه زراعت، دانشکده علوم کشاورزی، دانشگاه گیلان

۳. استادیار، گروه مهندسی آب، دانشکده علوم کشاورزی، دانشگاه گیلان

*. مسئول مکاتبات، پست الکترونیکی: mzavareh@guilan.ac.ir

مقدمه

شبکه‌های عصبی مصنوعی یک سیستم پردازش اطلاعات مبتنی بر سخت‌افزار رایانه‌ای هستند که ویژگی‌های ساختاری و عملکردی مشابه با سیستم‌های بیولوژیک دارند (۳۶) و به دلیل عملکرد خوب آنها در حل مسائل متفاوت، کاربرد گسترده‌ای در علوم مختلف پیدا کرده‌اند (۱۰). الگوی نخستین شبکه عصبی در سال ۱۹۴۳ پیشنهاد شد و تا سال ۱۹۹۹ بیش از ۳۰ مدل مختلف از آن توسعه یافت (۳۵).

شبکه عصبی مصنوعی از تعدادی عناصر پردازنده یا نرون یا گره‌های متصل به هم تشکیل شده است که معمولاً به صورت لایه‌های عصبی، سازمان‌دهی می‌شوند. در هر شبکه عصبی مصنوعی، سه لایه اصلی شامل لایه ورودی، لایه خروجی و لایه میانی وجود دارد. لایه ورودی داده‌ها را به شبکه معرفی می‌کند و لایه خروجی واکنش شبکه به ورودی‌ها را دریافت می‌کند؛ لایه میانی یا پنهان شامل یک یا چند لایه بین دو لایه مذکور است (۳۵).

پرسپترون چند لایه، یکی از پرکاربردترین انواع شبکه‌های عصبی بوده و از نوع شبکه‌های پیش‌خور است. بهترین کارایی این شبکه زمانی است که وزن‌ها نرمال می‌شوند و خروجی در محدوده صفر تا یک قرار می‌گیرد. این شبکه به‌طور معمول با الگوریتم پس‌خور (پس‌انتشار خطا) یا قانون آموزش اصلاح خطا، آموزش می‌بیند. تعداد درجات آزادی (مثلاً تعداد ورودی‌ها، خروجی‌ها و نرون‌های هر لایه) برای طراحی یک شبکه چند لایه‌ای پیش‌خور زیاد است. به‌عنوان نمونه تعداد نرون‌های لایه میانی از یک تا ۵۰ قابل تغییر است اما تعداد ورودی‌های شبکه و تعداد خروجی‌های آن تحت تأثیر مسئله مورد نظر قرار می‌گیرد. در مسائل رگرسیون، اگر تعداد کافی از نرون‌ها در لایه‌های مخفی وجود داشته باشد یک پرسپترون چند لایه با یک لایه مخفی می‌تواند هر رابطه‌ای را میان ورودی‌ها و خروجی‌ها شناسایی کند (۴۵). از نظر تئوریک اگر چه شبکه‌ای با یک لایه مخفی و تعدادی نرون می‌تواند هر تابعی را تخمین بزند ولی در عمل شبکه با یک لایه پنهان

آموزش داده می‌شود و در صورت عملکرد نامناسب آن، تعداد لایه‌های پنهان تا حداکثر دو افزایش خواهد یافت (۸).

برگ اندام کلیدی در فرایند تعرق و کربن‌گیری گیاه است و گسترش و دوام پهنک آن، می‌تواند بر مقدار تابش دریافتی و تولید فتوسنتزی اثر بگذارد (۲۰ و ۴۶). به همین دلیل، در بیشتر مطالعات فیزیولوژیک و زراعی گیاهان از جمله جذب نور، فتوسنتز، رشد و نمو، تبخیر و تعرق، کارایی مصرف آب و واکنش گیاه به کودها و آبیاری مد نظر قرار می‌گیرد (۱ و ۴). پیش‌بینی دقیق رشد و عملکرد گیاهان زراعی با استفاده از مدل‌های شبیه‌سازی مختلف هم نیازمند اطلاع دقیقی از سطح برگ و تغییرات آن در طول فصل رشد است (۲۰).

تعیین سطح برگ با دو رهیافت مستقیم و غیرمستقیم امکان‌پذیر است (۱۵). در رهیافت مستقیم، اندازه‌گیری سطح برگ به صورت تخریبی (جمع‌آوری برگ‌های جدا شده از گیاه) و غیر تخریبی انجام می‌شود. در پژوهش‌های کشاورزی، باغبانی و جنگل‌داری به منظور بررسی رشد و نمو در طول زمان اندازه‌گیری غیر تخریبی سطح برگ انجام می‌شود (۳۸). اما، در روش مستقیم تخریبی امکان اندازه‌گیری‌های بعدی روی همان برگ وجود نداشته و باعث آسیب سایه‌انداز خواهد شد (۵). علاوه بر این، در هر دو نوع روش رهیافت مستقیم با وجود دقت اندازه‌گیری بالا، فراهمی تجهیزات ضروری بوده و اندازه‌گیری کاری زمان‌بر، پرزحمت و پرهزینه است (۴ و ۱۸). این کاستی‌ها منجر به توسعه روش‌های غیر مستقیم برای برآورد سریع سطح برگ مبتنی بر معادلات و مدل‌های ریاضی شده است (۹ و ۱۸). از این معادلات و در کل از روش غیر مستقیم غیر تخریبی (استفاده از تعداد، طول و یا عرض برگ، ارتفاع بوته، قطر ساقه، تعداد گره یا برگ روی ساقه اصلی و طول یا تعداد شاخه) برای برآورد سطح برگ گیاهانی چون سورگوم (۴۳ و ۵۰)، ارزن مرواریدی (۳۳)، برنج (۳۲)، کنجد (۵۳)، سویا (۱۹)، پنبه (۲، ۱۳، ۱۷ و ۵۰)، کرچک (۵۰)، فندق (۵)، شاه‌بلوط (۴۰)، کیوی (۲۳)، توت‌فرنگی (۶)، گلرنگ (۳۹)، کدو (۲۷)، ذرت (۲۲، ۲۴، ۳۴، ۴۱ و ۴۶)، نیشکر (۴۲)،

می‌توان واکنش گسترش سطح برگ به عوامل محیطی را درک کرد.

با وجود اهمیت تراکم بوته و رقم در تولید دانه ذرت و نقش پررنگ برآورد سطح برگ در مدل‌های پیش‌بینی‌کننده رشد و نمو این گیاه، برآورد غیرتخریبی، ساده و دقیق سطح برگ آن در شرایط مدیریتی مذکور ضروری است. لذا، این آزمایش با هدف برآورد ساده، دقیق و غیرمستقیم سطح برگ بوته ذرت با شبکه عصبی پرسپترون چند لایه و بررسی اثر رقم، تراکم بوته و برهمکنش این دو عامل بر مدل‌های برازش شده طراحی و اجرا شد.

مواد و روش‌ها

این آزمایش در سال زراعی ۱۳۹۳ - ۱۳۹۲ در مزرعه پژوهشی دانشکده علوم کشاورزی دانشگاه گیلان با عرض جغرافیایی ۳۷ درجه و ۱۱ دقیقه و ۴۷ ثانیه شمالی، طول جغرافیایی ۴۹ درجه و ۳۸ دقیقه و ۲۸ ثانیه شرقی و ارتفاع ۲۹ متر بالاتر از سطح آب‌های آزاد اجرا شد.

آزمایش به صورت فاکتوریل در قالب طرح بلوک‌های کامل تصادفی با سه تکرار انجام شد و در آن سه تراکم بوته (۷۵، ۸۵ و ۹۵ هزار بوته در هکتار) و پنج رقم ذرت (پرشیا ۴۵۴، پرشیا ۴۸۴، پرشیا ۵۶۵، پرشیا ۶۲۶ و ۶۴۷) به عنوان تیمارهای آزمایش در نظر گرفته شدند. هر کرت آزمایشی شامل شش ردیف کاشت سه متری با فاصله ۷۵ سانتی‌متر بود که در آنها تنظیم تراکم بوته با تغییر فاصله روی ردیف‌ها انجام شد. در طول دوره رشد، چهار نمونه برداری تخریبی متوالی به فاصله هر دو هفته یکبار (۳۵، ۴۹، ۶۳ و ۷۷ روز پس از کاشت) از چهار ردیف میانی هر کرت و با در نظر گرفتن حاشیه انجام شد. در نمونه برداری‌ها، برگ‌های سبزی که یقه آنها آشکار بود (برگ‌های کاملاً توسعه یافته) شمارش شدند و به عنوان تعداد برگ سبز در نظر گرفته شدند. برگ‌های خشک نیز از محل تلاقی پهنک و غلاف برگ جدا شدند. مجموع برگ‌های سبز و خشک شمارش شده نیز به عنوان تعداد برگ روی بوته در نظر

نخود (۳۷ و ۴۴)، چغندر قند (۴۸)، گیاه دارویی بادرشبی (۱۶)، فلفل سیاه (۱۴)، انگور (۷ و ۲۵)، پیاز (۹)، خیار (۴)، گوجه‌فرنگی (۳۸)، ریحان (۲۶)، زنجبیل (۱۵)، کلم (۳۰) و گندم (۳) استفاده شده است.

با این حال، به دلیل قدرت شبکه عصبی مصنوعی در مدل‌سازی روابط غیرخطی، آموزش لحظه‌ای و پردازش موازی آن (۴۷)، گرایش گسترده‌ای به استفاده از آن در مدل‌سازی سطح برگ در مقایسه با روش‌های پیشین ایجاد شده است (۲۹). و همکاران (۵۲) از مدل پس انتشار خطای شبکه عصبی با پارامترهای ورودی طول برگ و بیشینه عرض برگ برای اندازه‌گیری سطح برگ سرخالو (*Litchi chinensis* Sonn.) استفاده کردند. یافته‌های آنها نشان‌دهنده معتبر بودن مدل شبکه عصبی بود. نیه و همکاران (۲۸) از شبکه‌های پس‌انتشار خطا با چهار ورودی که شامل شدت نور، میزان نور عبور یافته از برگ، دمای محیط و مقادیر اختلاف ولتاژ صفحه حسگر فوتوالکترونیک بود، برای محاسبه سطح برگ بوته استفاده کردند. یافته‌های آنها نشان‌دهنده دقت بالای این روش در محاسبه سطح برگ بوته بود. آداباس و همکاران (۲۹) برای مدل‌سازی سطح برگ رقم‌های ذرت از شبکه عصبی چند لایه از نوع پیش‌خور با داده‌های طول و عرض برگ استفاده کردند. یافته‌های آنها نشان داد که ترکیب این دو ویژگی به‌عنوان ورودی می‌تواند سطح برگ را با دقت بالا و خطای پایین، مدل‌سازی کند. وازکوئز - کروز و همکاران (۴۹) به‌منظور تخمین سطح برگ گوجه‌فرنگی در واکنش به تغییرات جوی و کاربرد اسید سالیسیلیک در شرایط گلخانه از دو شبکه با پنج (طول برگ)، عرض برگ، دما، غلظت کربن دی‌اکسید و تابش فعال فتوسنتزی) و سه (طول برگ، عرض برگ و اسید سالیسیلیک) ورودی استفاده کردند که نوع شبکه استفاده شده پرسپترون چند لایه بود. اگرچه هر دو مدل دقت خوبی در برآورد داشتند اما شبکه‌ای با پنج ورودی به‌درستی رابطه پیچیده بین فاکتورهای اقلیمی را در تیمارهای مختلف شناسایی کرد. بنابراین با استفاده از نتایج شبیه‌سازی شده توسط شبکه‌های عصبی مصنوعی

تعداد لایه‌های میانی، برابر یک در نظر گرفته شد. برای تعیین تعداد نرون مطلوب در لایه میانی از یک تا ۲۵ نرون در نظر گرفته شد. برای این منظور، توابع انتقال لایه‌های مخفی و خروجی، TanhAxon (معادله ۱)، SigmoidAxon (معادله ۲)، LinearTanhAxon (معادله ۳) و LinearSigmoidAxon (معادله ۴)، BiasAxon (معادله ۵) و LinearAxon (معادله ۶) در نظر گرفته شدند. برای قانون یادگیری، از الگوریتم مومنتوم استفاده شد. شبکه‌های ایجاد شده پس از آموزش، آزمون شدند. علاوه بر ورودی‌های منفرد، به‌منظور تعیین ورودی‌های مؤثر بر خروجی شبکه از آنالیز حساسیت استفاده شد. برحسب آنالیز حساسیت، از بین ۹ متغیر ورودی متغیرهایی که بیشترین حساسیت را داشتند، به‌عنوان متغیر ورودی مدل انتخاب شدند.

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

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

$$f(x) = \begin{cases} -1 & \text{if } x < -1 \\ 1 & \text{if } x > 1 \\ x & \text{if } -1 \leq x \leq 1 \end{cases} \quad (3)$$

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ 1 & \text{if } x > 0 \\ x & \text{if } 0 \leq x \leq 1 \end{cases} \quad (4)$$

$$f(x) = x + w \quad (5)$$

$$f(x) = x \quad (6)$$

در معادله ۵، w مقدار بایاس است که مقدار آن در فرآیند یادگیری، بهینه می‌شود.

برای ارزیابی مدل‌های شبکه عصبی از شاخص آماری انحراف معیار استفاده شد. برای توصیف بهتری از قابلیت مدل‌ها، از نوع نسبی این شاخص نیز استفاده شد. این دو معیار به ترتیب با استفاده از معادله‌های ۷ و ۸ محاسبه شدند. دو معیار ارزیابی دیگر، ضریب تعیین و ضریب توافق ویل موت (۵۱) بودند که به ترتیب با استفاده از معادله‌های ۹ و ۱۰

گرفته شدند. فاصله از محل تلاقی پهنک و غلاف تا نوک پهنک برگ (در امتداد رگبرگ اصلی) به‌عنوان طول برگ سبز و بیشترین پهنای پهنک برگ به‌عنوان عرض پهنک با دقت یک میلی‌متر و با استفاده از خط‌کش اندازه‌گیری شدند. سطح برگ‌های سبز بوته با استفاده از دستگاه اندازه‌گیری سطح برگ (Delta-T Devices Ltd, Cambridge- England) و با دقت ۰/۰۰۰۱ سانتی‌متر مربع اندازه‌گیری شد. برای اندازه‌گیری وزن خشک برگ و ساقه، برگ‌های سبز و خشکی که از بوته جدا شده بودند و ساقه هر بوته در آونی (مدل آرکتکو، آروین تجهیز اسپادانا) با دمای ۷۵ درجه سلسیوس به مدت ۴۸ تا ۷۲ ساعت خشک‌کننده شدند و سپس با ترازوی دیجیتالی (AND-FX300GD, 0.001-320 gram, Japan) با دقت ۰/۰۰۱ گرم توزین شدند. همچنین، برای اندازه‌گیری عملکرد زیست‌توده، بوته‌های کف‌بر شده پس از خشک شدن در آون مذکور با ترازوی دیجیتالی نام برده توزین شدند. ارتفاع بوته از محل طوقه (نزدیک به سطح خاک) تا محل قوس بالاترین برگی که بیش از ۵۰٪ از پیچ‌خوردگی آن باز شده بود با دقت یک میلی‌متر اندازه‌گیری شد. قطر ساقه ذرت با دقت ۰/۰۱ میلی‌متر و با استفاده از کولیس دیجیتالی (Guanglu, China) قرائت شد.

برای شبیه‌سازی سطح برگ بوته ذرت با استفاده از ۹ ویژگی اندازه‌گیری شده به‌عنوان متغیر ورودی از نرم‌افزارهای Neuro Solutions نسخه ۴ و Excel نسخه ۱۱ استفاده شد. در ابتدا مدل‌های مورد نظر روی همه ورودی‌ها (n = ۵۴۰) برازش داده شدند. سپس، بهترین مدل برازش یافته برای هر رقم (n = ۱۰۸)، هر تراکم (n = ۱۸۰) و هر برهمکنش رقم و تراکم (n = ۳۶) نیز بررسی شد. پیش از ایجاد شبکه داده‌ها برای افزایش قابلیت تعمیم شبکه تصادفی شدند. برای آموزش، اعتبارسنجی و آزمون شبکه به ترتیب از ۶۰، ۱۵ و ۲۵ درصد از داده‌ها استفاده شد. نوع شبکه استفاده شده با توجه به ارائه نتایج بهتر نسبت به سایر مدل‌ها، پرسپترون چند لایه بود. تعداد لایه مخفی به‌منظور جلوگیری از کاهش سرعت شبکه با افزایش

برآورد شدند.

ورودی عرض برگ با توپولوژی ۱-۲۳-۱، برحسب بیشترین ضریب تعیین (۰/۸۵۷۹)، بیشترین ضریب توافق (۰/۹۶۱)، کمترین انحراف معیار (۴۳۳/۹۱) و کمترین انحراف معیار نسبی (۰/۲۸/۶۳) به ترتیب، LinearSigmoidAxon و Axon بودند.

در بین ۹ ویژگی استفاده شده در برآورد سطح برگ بوته ذرت، وزن خشک برگ با توجه به داشتن بیشترین ضریب تعیین (۰/۹۵۶۹)، بیشترین ضریب توافق (۰/۹۸۹)، کمترین انحراف معیار (۲۳۷/۵۴) و کمترین انحراف معیار نسبی (۰/۱۵/۶۷) به عنوان بهترین متغیر ورودی در نظر گرفته شد

(شکل ۱). به دلیل سهولت اندازه‌گیری وزن خشک برگ، این متغیر می‌تواند سبب تسریع برآورد سطح برگ بوته ذرت شود.

در تحقیق انجام شده توسط اکرم قادری و سلطانی (۲) نیز وزن خشک برگ نسبت به ارتفاع بوته و وزن خشک کل برآورد بهتری از سطح برگ بوته با استفاده از معادله توانی به صورت تبدیل شده خطی داشت. همچنین در تحقیق ما و همکاران (۲۱) وزن خشک برگ نسبت به وزن خشک کل با استفاده از

رابطه توانی در برآورد سطح برگ مؤثرتر بود. پس از این ویژگی، عرض برگ (میانگین عرض برگ‌های بوته) با داشتن شاخص‌های آماری بهتر، می‌تواند به عنوان متغیر مناسب در

تعیین سطح برگ بوته ذرت استفاده شود. اما، در بین این ویژگی‌ها قطر ساقه آماره‌های ضعیفی از خود ارائه داد. در نتیجه، استفاده از این ویژگی در برآورد سطح برگ بوته ذرت مطلوب نیست. به دلیل کنترل دینامیک سطح برگ با ژنوتیپ و محیط (۱۱)، بهترین مدل برازش یافته با ورودی وزن خشک برگ که دارای پنج نرون با تابع SigmoidAxon در لایه میانی و تابع LinearTanhAxon در لایه خروجی بود، روی داده‌های هر رقم، هر تراکم و هر برهمکنش رقم و تراکم بررسی شد، که

نتایج آنها به ترتیب در جدول‌های ۲، ۳ و ۴ آورده شده است. نتایج نشان داد که شاخص‌های آماری هر رقم (جدول ۲)، هر تراکم (جدول ۳) و هر برهمکنش رقم و تراکم (جدول ۴) در حدی مطلوب قرار دارند. بنابراین، مدل برازش شده بر همه داده‌ها (بهترین مدل برازش یافته با ورودی وزن خشک برگ که

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y})^2}{n}} \quad (7)$$

$$RMSE(\%) = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y})^2}{n}} \cdot \frac{100}{\bar{y}} \quad (8)$$

$$R^2 = \frac{(COV_{y\hat{y}})^2}{(V_y) \cdot (V_{\hat{y}})} \quad (9)$$

$$d = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (|\hat{y}_i - \bar{y}| + |y_i - \bar{y}|)^2} \quad (10)$$

که در آنها؛ y_i ، \hat{y}_i و \bar{y} به ترتیب، مقدار مشاهده نام، مقدار شبیه‌سازی شده مشاهده نام و میانگین مشاهدات آزمون شده می‌باشند. همچنین، COV ، V و n به ترتیب کوواریانس، واریانس و تعداد مشاهدات آزمون شده (برابر با ۱۳۵ داده که معادل ۲۵٪ داده‌های آزمایش می‌باشند) هستند.

ضریب تعیین بالاتر به منزله قوی‌تر بودن رابطه بین متغیر (متغیرهای) مستقل و متغیر وابسته می‌باشد. چنانچه مقدار (RMSE) کمتر از ۱۰٪ باشد شبیه‌سازی عالی، بین ۲۰-۱۰٪ خوب، بین ۳۰-۲۰٪ متوسط و بیشتر از ۳۰٪ ضعیف خواهد بود (۱۱). برابر بودن مقدار d با عدد یک، نشان‌دهنده تطابق کامل داده‌های مشاهده شده و برآورد شده می‌باشد.


نتایج و بحث

نتایج پرسپترون چند لایه با یک ورودی

بهترین تعداد نرون لایه میانی و توابع تبدیل لایه‌های میانی و خروجی برای هر متغیر ورودی، بر مبنای بیشترین مقدار ضریب تعیین و ضریب توافق و کمترین مقدار انحراف معیار و نوع نسبی آن، در جدول ۱ ارائه شده است. به عنوان نمونه، بهترین توابع تبدیل لایه‌های میانی و خروجی برای متغیر

جدول ۱. خروجی شبکه برای هر ورودی روی کل داده‌های آزمون شده

ضریب	انحراف معیار	انحراف معیار	ضریب	تابع تبدیل لایه	تابع تبدیل لایه میانی	تعداد نرون لایه میانی	متغیر ورودی شبکه
توافق	نسبی (RMSE (%))	(RMSE)	تعیین (R ²)	خروجی			
۰/۹۶۱	۲۸/۶۳	۴۳۳/۹۱	۰/۸۵۷۹	Axon	LinearSigmoidAxon	۲۳	عرض برگ
۰/۹۳۷	۳۵/۳۷	۵۳۶/۱۵	۰/۷۸۲۲	Axon	LinearSigmoidAxon	۵	طول برگ
۰/۹۵۳	۳۰/۸۹	۴۶۸/۲۴	۰/۸۳۲۵	TanhAxon	TanhAxon	۲	تعداد برگ سبز
۰/۹۵۳	۳۰/۸۳	۴۶۷/۳۷	۰/۸۳۲۸	TanhAxon	TanhAxon	۲	تعداد برگ روی بوته
۰/۷۰۹	۶۱/۴۲	۹۳۰/۹۸	۰/۳۳۷۱	Axon	LinearSigmoidAxon	۶	قطر ساقه
۰/۹۵۲	۳۰/۸۸	۴۶۸/۱۶	۰/۸۳۲۰	LinearAxon	LinearSigmoidAxon	۱۲	عملکرد زیست‌توده
۰/۹۴۷	۳۲/۵۵	۴۹۳/۳۳	۰/۸۱۳۹	TanhAxon	TanhAxon	۲	وزن خشک ساقه
۰/۹۸۹	۱۵/۶۷	۲۳۷/۵۴	۰/۹۵۶۹	LinearTanhAxon	SigmoidAxon	۵	وزن خشک برگ
۰/۹۵۳	۳۱/۴۹	۴۷۷/۳۶	۰/۸۲۹۹	LinearTanhAxon	SigmoidAxon	۳	ارتفاع بوته



شکل ۱. رگرسیون خطی بین سطح برگ مشاهده شده (y) و مقدار برآورد شده آن (\hat{y}) با ورودی وزن خشک برگ. تعداد مشاهدات (۱۳۵ داده) شامل ۲۵٪ داده‌های آزمایش (۵۴۰ داده) که ترکیبی از پنج رقم، سه تراکم بوته، چهار زمان نمونه‌برداری، سه تکرار و سه نمونه هستند، می‌باشد.

دارای پنج نرون با تابع SigmoidAxon در لایه میانی و تابع کلی استفاده کرد.

LinearTanhAxon در لایه خروجی بود، به خوبی می‌تواند

نتایج مدل‌سازی برحسب آنالیز حساسیت

سطح برگ هر رقم، هر تراکم و هر برهمکنش رقم و تراکم را

برای تعیین متغیرهای ورودی مؤثر در برآورد سطح برگ بوته

برآورد کند و به جای استفاده از چند مدل می‌توان از یک مدل

جدول ۲. مقادیر شاخص‌های آماری سطح برگ برآورد شده با ورودی وزن خشک برگ برای هر رقم

رقم	ضریب تعیین (R ²)	انحراف معیار (RMSE)	انحراف معیار نسبی (RMSE (%))	ضریب توافق (d)
پریشیا ۴۵۴	۰/۹۶۰۵	۲۷۲/۵۸	۱۶/۶۳	۰/۹۸۷
پریشیا ۴۸۴	۰/۹۴۵۱	۳۱۰/۰۰	۱۴/۶۴	۰/۹۸۳
پریشیا ۵۶۵	۰/۹۴۲۵	۲۸۰/۴۴	۱۵/۴۳	۰/۹۸۲
پریشیا ۶۲۶	۰/۹۳۴۱	۳۰۳/۷۷	۱۷/۹۹	۰/۹۸۲
۶۴۷	۰/۹۲۰۰	۳۱۸/۰۲	۱۹/۵۲	۰/۹۷۷

جدول ۳. مقادیر شاخص‌های آماری سطح برگ برآورد شده با ورودی وزن خشک برگ برای هر تراکم

تراکم بوته	ضریب تعیین (R ²)	انحراف معیار (RMSE)	انحراف معیار نسبی (RMSE (%))	ضریب توافق (d)
۷۵۰۰۰	۰/۹۳۷۳	۳۰۲/۴۷	۱۷/۱۲	۰/۹۸۳
۸۵۰۰۰	۰/۹۶۸۱	۲۸۹/۶۶	۱۸/۶۶	۰/۹۸۹
۹۵۰۰۰	۰/۹۷۵۸	۲۱۰/۰۴	۱۲/۷۲	۰/۹۹۲

مدل (شکل ۲) و بیشتر مدل‌های دیگر، پس از دو ویژگی مذکور، به ترتیب طول برگ، تعداد برگ روی بوته و قطر ساقه نیز حساسیت بالایی نشان دادند. اما، ویژگی‌های دیگر میزان حساسیت پایینی نشان دادند. بنابراین، با حذف این ویژگی‌های غیرضروری از مدل، اندازه شبکه کاهش یافته و سرعت آموزش افزایش خواهد یافت.

در جدول ۶ مدل‌هایی (با دو تا پنج متغیر مستقل) آورده شده‌اند که دارای مطلوب‌ترین شاخص‌های آماری هستند. هنگامی که از دو متغیر مستقل در برآورد سطح برگ بوته استفاده شد، ۹۶٪ از تغییرات سطح برگ بوته با میانگین عرض برگ‌های بوته و تعداد برگ سبز توجیه شد و این مدل بر مبنای انحراف معیار نسبی و ضریب توافق ویل‌موت، شبیه‌سازی خوبی از سطح برگ بوته ذرت داشت. با اضافه شدن میانگین طول برگ‌های بوته به مدل مذکور، شاخص‌های آماری بهبود یافتند و با دقت بیشتری توانستند سطح برگ بوته را برآورد

ذرت با استفاده از شبکه عصبی پرسپترون چند لایه، ابتدا ضرایب همبستگی پیرسون بین سطح برگ و نه متغیر دیگر محاسبه شدند (جدول ۵). به دلیل مثبت و معنی‌دار بودن این روابط (جدول ۵)، همه ۹ متغیر تحت آنالیز حساسیت در مرحله آموزش شبکه قرار گرفتند.

بر مبنای آنالیز حساسیت، در همه مدل‌های شبکه عصبی که در آنها از دو متغیر برای پیش‌بینی سطح برگ بوته استفاده شده بود، بیشترین تأثیر مربوط به عرض برگ و تعداد برگ سبز بود (نتایج ارائه نشده). نمونه‌ای از این حالت، در شکل ۲ مشاهده می‌شود که توابع تبدیل لایه‌های میانی و خروجی آن به ترتیب TanhAxon و Axon است. در پژوهش وازکوئز-کروز و همکاران (۴۹) که از اندازه‌گیری‌های خطی (طول و عرض برگ)، دما، غلظت دی‌اکسیدکربن و تابش فعال فتوسنتزی برای برآورد سطح برگ گوجه‌فرنگی استفاده کرده بودند، بیشترین اثر در بین پنج ورودی مربوط به عرض برگ بود (۹۰/۸٪). در این

جدول ۴. مقادیر شاخص‌های آماری سطح برگ برآورد شده با ورودی وزن خشک برگ برای هر برهمکنش رقم و تراکم

تراکم بوته	رقم	ضریب تعیین (R ²)	انحراف معیار (RMSE)	انحراف معیار نسبی (RMSE (%))	ضریب توافق (d)
	پریشیا ۴۵۴	۰/۹۸۲۳	۱۹۰/۶۱	۹/۳۲	۰/۹۸۹
	پریشیا ۴۸۴	۰/۹۹۳۰	۲۲۳/۹۰	۱۵/۴۴	۰/۹۹۲
۷۵۰۰۰	پریشیا ۵۶۵	۰/۹۹۱۴	۱۲۱/۶۲	۹/۶۸	۰/۹۹۷
	پریشیا ۶۲۶	۰/۹۷۴۴	۲۵۵/۴۴	۱۴/۰۲	۰/۹۹۱
	۶۴۷	۰/۹۶۱۲	۲۱۷/۵۴	۱۲/۴۹	۰/۹۸۷
	پریشیا ۴۵۴	۰/۹۴۹۵	۲۰۷/۶۲	۱۰/۱۷	۰/۹۸۳
	پریشیا ۴۸۴	۰/۹۵۲۷	۲۷۲/۴۱	۱۲/۷۵	۰/۹۸۸
۸۵۰۰۰	پریشیا ۵۶۵	۰/۹۷۷۷	۲۱۱/۳۱	۱۴/۲۹	۰/۹۹۴
	پریشیا ۶۲۶	۰/۹۶۱۱	۱۸۶/۴۵	۱۳/۴۳	۰/۹۸۹
	۶۴۷	۰/۹۷۸۲	۱۹۰/۱۶	۱۸/۲۹	۰/۹۸۸
	پریشیا ۴۵۴	۰/۹۲۴۳	۲۲۰/۶۲	۱۹/۸۷	۰/۹۷۱
	پریشیا ۴۸۴	۰/۹۶۴۷	۲۵۹/۰۹	۱۲/۶۹	۰/۹۹۰
۹۵۰۰۰	پریشیا ۵۶۵	۰/۹۷۰۶	۳۱۹/۶۰	۱۷/۸۱	۰/۹۸۷
	پریشیا ۶۲۶	۰/۹۹۰۵	۱۸۷/۸۷	۱۱/۹۳	۰/۹۹۲
	۶۴۷	۰/۹۶۹۷	۱۷۷/۲۷	۹/۶۱	۰/۹۹۲

جدول ۵. ضرایب همبستگی ساده بین سطح برگ و ۹ متغیر دیگر*

طول برگ	عرض برگ	وزن خشک برگ	تعداد برگ سبز	ارتفاع بوته	قطر ساقه	وزن خشک ساقه	تعداد برگ روی بوته	عملکرد زیست‌توده
۰/۸۶۱	۰/۹۱۲	۰/۹۶۳	۰/۸۹۲	۰/۹۰۵	۰/۵۹۶	۰/۸۹۵	۰/۸۸۷	۰/۸۵۹

* همه ضرایب مثبت و معنی‌دار (Pr ≤ ۰/۰۰۰۱) هستند.

جدول ۶. خروجی شبکه برحسب آنالیز حساسیت

متغیر ورودی شبکه	تعداد نرون	تابع تبدیل	تابع تبدیل	ضریب تعیین (R ²)	انحراف معیار (RMSE)	انحراف معیار نسبی (RMSE (%))	ضریب توافق (d)
W, LN, L, NN, D	۱۳	TanhAxon	LinearAxon	۰/۹۹۱۲	۱۰۸/۱۵	۷/۱۳	۰/۹۹۸
W, LN, L, NN	۲۳	TanhAxon	TanhAxon	۰/۹۹۱۵	۱۰۶/۰۲	۶/۹۹	۰/۹۹۸
W, LN, L	۲۵	TanhAxon	Axon	۰/۹۹۰۷	۱۱۰/۷۶	۷/۳۱	۰/۹۹۸
W, LN	۲	TanhAxon	TanhAxon	۰/۹۶۰۱	۲۲۸/۱۷	۱۵/۰۵	۰/۹۹۰

W, LN, L, NN و D به ترتیب میانگین عرض برگ‌های بوته، تعداد برگ سبز، میانگین طول برگ‌های بوته، تعداد برگ روی بوته و قطر ساقه هستند.



شکل ۲. میزان حساسیت متغیرها در شبیه‌سازی سطح برگ بوته ذرت

تراکم در حد مطلوب قرار دارند. بنابراین، می‌توان انتظار داشت که مدل برازش شده بر همه داده‌ها، قابل استفاده برای همه رقم‌ها، تراکم‌ها و برهمکنش‌های آزمایش باشد. بنابراین، به‌جای استفاده از چند مدل مختلف می‌توان از یک مدل کلی برای برآورد سطح برگ بوته استفاده کرد. اما آنر و همکاران (۳۱) برای برآورد سطح برگ منفرد رقم‌های مختلف ذرت از معادلات مختلفی با ورودی طول برگ، عرض برگ و محل برگ استفاده کردند. دلیل استفاده آنها از مدل‌های مختلف، متفاوت بودن شکل و اندازه برگ در ژنوتیپ‌های استفاده شده بود.


نتیجه‌گیری

به دلیل وجود روابط آلومتریک قوی بین سطح برگ بوته با دیگر اجزای بوته و برگ، بیشتر متغیرهای مستقل همبستگی بالایی با سطح برگ بوته ذرت داشتند و توانستند سطح برگ ذرت را به خوبی برآورد کنند. لذا با اندازه‌گیری خطی برگ یا شمارش تعداد برگ‌ها به‌تنهایی یا ترکیبی از این سه یا چهار ورودی یا مدل‌سازی این متغیرهای مستقل، می‌توان سطح برگ بوته ذرت را به سهولت و با دقت بالا به کمک شبکه عصبی پرسپترون

کنند. اما، با افزایش تعداد متغیرهای ورودی به چهار یا پنج، تفاوت چندانی با سه ورودی متغیر دیده نشد. استفاده از متغیرهای طول برگ، عرض برگ و تعداد برگ که اندازه‌گیری آنها در مزرعه به سهولت امکان‌پذیر است، باعث اندازه‌گیری غیرتخریبی سطح برگ شده و مطالعات بعدی روی همان برگ‌ها می‌تواند انجام شود (۳۱).

بنابراین، اگر هدف برآورد دقیق سطح برگ بوته ذرت باشد، بهتر است از مدلی با سه تا پنج متغیر ورودی استفاده شود که در این بین، انتخاب مدلی با سه ورودی یعنی عرض برگ، تعداد برگ سبز و طول برگ به دلیل ساده شدن مدل، می‌تواند بهترین مدل برآورد کننده سطح برگ بوته ذرت باشد (شکل ۳). با در نظر گرفتن این موضوع، بهترین مدل برازش یافته با سه ورودی عرض برگ، تعداد برگ سبز و طول برگ که دارای ۲۵ نرون با تابع TanhAxon در لایه میانی و تابع Axon در لایه خروجی بود، روی داده‌های هر رقم، هر تراکم و هر برهمکنش رقم و تراکم بررسی شد که نتایج آنها به‌ترتیب در جدول‌های ۷، ۸ و ۹ آورده شده است.

بررسی مقادیر جدول‌های ۷، ۸ و ۹ نشان می‌دهد که شاخص‌های آماری هر رقم، هر تراکم و هر برهمکنش رقم و



شکل ۳. رگرسیون خطی بین سطح برگ مشاهده شده (y) و مقدار برآورد شده آن (\hat{y}) با ورودی طول، عرض و تعداد برگ سبز. تعداد مشاهدات (۱۳۵ داده) شامل ۲۵٪ داده‌های آزمایش (۵۴۰ داده) که ترکیبی از پنج رقم، سه تراکم بوته، چهار زمان نمونه برداری، سه تکرار و سه نمونه هستند، می‌باشد.

جدول ۷. مقادیر شاخص‌های آماری سطح برگ برآورد شده با ورودی‌های عرض، طول و تعداد برگ سبز برای هر رقم

رقم	ضریب تعیین (R^2)	انحراف معیار (RMSE)	انحراف معیار نسبی (RMSE (%))	ضریب توافق (d)
پرشیا ۴۵۴	۰/۹۸۶۹	۱۰۳/۷۷	۷/۲۲	۰/۹۹۷
پرشیا ۴۸۴	۰/۹۸۲۹	۱۶۱/۴۲	۹/۸۳	۰/۹۹۵
پرشیا ۵۶۵	۰/۹۹۱۲	۱۵۸/۷۱	۶/۵۱	۰/۹۹۸
پرشیا ۶۲۶	۰/۹۹۰۱	۱۲۲/۹۸	۷/۷۱	۰/۹۹۷
۶۴۷	۰/۹۹۳۹	۷۸/۵۲	۵/۷۹	۰/۹۹۸

جدول ۸. مقادیر شاخص‌های آماری سطح برگ برآورد شده با ورودی‌های عرض، طول و تعداد برگ سبز برای هر تراکم

تراکم بوته	ضریب تعیین (R^2)	انحراف معیار (RMSE)	انحراف معیار نسبی (RMSE (%))	ضریب توافق (d)
۷۵۰۰۰	۰/۹۸۹۰	۱۱۹/۳۱	۷/۳۳	۰/۹۹۷
۸۵۰۰۰	۰/۹۹۰۲	۱۴۱/۹۲	۸/۲۱	۰/۹۹۷
۹۵۰۰۰	۰/۹۸۴۸	۱۷۹/۳۷	۱۰/۰۳	۰/۹۹۵

جدول ۹. مقادیر شاخص‌های آماری سطح برگ برآورد شده با ورودی‌های عرض، طول و تعداد برگ سبز برای هر برهمکنش رقم و تراکم

تراکم بوته	رقم	ضریب تعیین (R ²)	انحراف معیار (RMSE)	انحراف معیار نسبی (RMSE (%))	ضریب توافق (d)
	پرشیا ۴۵۴	۰/۹۹۲۶	۱۱۴/۰۵	۶/۰۶	۰/۹۹۶
	پرشیا ۴۸۴	۰/۹۹۵۰	۸۶/۶۰	۶/۰۹	۰/۹۹۹
۷۵۰۰۰	پرشیا ۵۶۵	۰/۹۹۱۲	۱۲۷/۱۷	۷/۳۵	۰/۹۹۷
	پرشیا ۶۲۶	۰/۹۹۰۱	۱۲۸/۶۹	۷/۱۷	۰/۹۹۶
	۶۴۷	۰/۹۹۴۷	۱۱۲/۲۳	۱۰/۶۲	۰/۹۹۵
	پرشیا ۴۵۴	۰/۹۹۴۸	۹۵/۲۶	۴/۸۰	۰/۹۹۸
	پرشیا ۴۸۴	۰/۹۷۳۵	۲۵۴/۲۵	۱۵/۳۴	۰/۹۸۶
۸۵۰۰۰	پرشیا ۵۶۵	۰/۹۹۲۱	۱۳۶/۲۴	۶/۴۶	۰/۹۹۸
	پرشیا ۶۲۶	۰/۹۸۹۴	۱۳۰/۸۳	۹/۷۰	۰/۹۹۲
	۶۴۷	۰/۹۸۵۰	۱۳۶/۲۹	۹/۷۹	۰/۹۹۵
	پرشیا ۴۵۴	۰/۹۸۱۰	۱۴۵/۴۰	۱۱/۱۷	۰/۹۹۳
	پرشیا ۴۸۴	۰/۹۸۸۸	۱۷۵/۸۹	۱۲/۱۵	۰/۹۹۶
۹۵۰۰۰	پرشیا ۵۶۵	۰/۹۸۰۲	۲۸۸/۲۵	۱۹/۰۲	۰/۹۹۱
	پرشیا ۶۲۶	۰/۹۹۰۴	۱۰۳/۱۹	۶/۵۸	۰/۹۹۷
	۶۴۷	۰/۹۸۷۷	۱۲۰/۵۰	۷/۸۳	۰/۹۹۶

چند لایه پیش‌بینی کرد. بهترین مدل برازش داده شده بر همه داده‌ها تحت تأثیر عامل‌های آزمایش قرار نگرفت. به عبارت دیگر این عامل‌ها بر آلومتری بین سطح برگ و دیگر اجزا مؤثر نبودند. بنابراین، از این مدل کلی می‌توان برای همه رقم‌ها، تراکم‌ها و برهمکنش‌های مورد آزمایش استفاده کرد.

منابع مورد استفاده

1. Aase, J. 1978. Relationship between leaf area and dry matter in winter wheat. *Agronomy Journal* 70: 563-565.
2. Akram-Ghaderi, F. and A. Soltani. 2007. Leaf area relationships to plant vegetative characteristics in cotton (*Gossypium hirsutum* L.) grown in a temperate sub-humid environment. *International Journal of Plant Production* 1: 63-71.
3. Bakhshandeh, E., A. Soltani, E. Zeinali, M. Arabi and R. s in bread and durum wheat cultivars. *Iranian Journal of Crop Sciences* 13: 642-657. (In Farsi).
4. Blanco, F. F. and M. V. Folegatti. 2005. Estimation of leaf area for greenhouse cucumber by linear measurements under salinity and grafting. *Scientia Agricola* 62: 305-309.
5. Cristofori, V., Y. Rouphael, E. Mendoza-de Gyves and C. Bignami. 2007. A simple model for estimating leaf area of hazelnut from linear measurements. *Scientia Horticulturae* 113: 221-225.
6. Demirsoy, H., L. Demirsoy and A. Öztürk. 2005. Improved model for the non-destructive estimation of strawberry leaf area. *Fruits* 60: 69-73.
7. Eftekhari, M., B. Kamkar and M. Alizadeh. 2011. Prediction of leaf area in some Iranian table grape (*Vitis vinifera* L.) cuttings by a non-destructive and simple method. *Science Research Reporter* 1: 115-121.

8. Esfandiari Darabad, F., S. Hosseini, M. Azadi Mobaraki and Z. Hejazizadeh. 2011. Prediction of monthly average temperature through artificial neural network multilayer perceptron (MLP). *Geography* 8: 45-65. (In Farsi).
9. Gamiely, S., W. Randle, H. Mills and D. Smittle. 1991. A rapid and nondestructive method for estimating leaf area of onions. *HortScience* 26.
10. Hagan, M. T., H. B. Demuth and M. H. Beale. 1996. *Neural Network Design*. PWS Publishing Company, Boston.
11. Hammer, G., P. Carberry and R. Muchow. 1993. Modelling genotypic and environmental control of leaf area dynamics in grain sorghum. I. Whole plant level. *Field Crops Research* 33: 293-310.
12. Jamieson, P. D., J. R. Porter and D. R. Wilson. 1991. A test of the computer simulation model ARCWHEAT1 on wheat crops grown in New Zealand. *Field Crops Research* 27: 337-350.
13. Johnson, R. 1967. Comparison of methods for estimating cotton leaf area. *Agronomy Journal* 59: 493-494.
14. Kandiannan, K., C. Kailasam, K. Chandaragiri and N. Sankaran. 2002. Allometric model for leaf area estimation in black pepper (*Piper nigrum* L.). *Journal of Agronomy and Crop Science* 188: 138-140.
15. Kandiannan, K., U. Parthasarathy, K. Krishnamurthy, C. Thankamani and V. Srinivasan. 2009. Modeling individual leaf area of ginger (*Zingiber officinale* Roscoe) using leaf length and width. *Scientia Horticulturae* 120: 532-537.
16. Karimian Fariman, F. Z., B. A. Mousavi Bazaz and A. M. Banayan Aval. 2012. Modeling leaf area of *Dracocephalum moldavica* L. as a medicine plant using destructive and non-destructive methods. *Iranian Journal of Medicinal and Aromatic Plants* 28: 176-186. (In Farsi).
17. Khajehpour, M., M. Karimi and F. Mousavi. 1988. Leaf area estimation of cotton. *Iranian Journal of Agricultural Sciences* 19: 53-58. (In Farsi).
18. Leroy, C., L. Saint-André and D. Auclair. 2007. Practical methods for non-destructive measurement of tree leaf area. *Agroforestry Systems* 71: 99-108.
19. Lieth, J. H., J. F. Reynolds and H. H. Rogers. 1986. Estimation of leaf area of soybeans grown under elevated carbon dioxide levels. *Field Crops Research* 13: 193-203.
20. Lizaso, J., W. Batchelor and M. Westgate. 2003. A leaf area model to simulate cultivar-specific expansion and senescence of maize leaves. *Field Crops Research* 80: 1-17.
21. Ma, L., F. Gardner and A. Selamat. 1992. Estimation of leaf area from leaf and total mass measurements in peanut. *Crop Science* 32: 467-471.
22. McKee, G. W. 1964. A coefficient for computing leaf area in hybrid corn. *Agronomy Journal* 56: 240-241.
23. Mendoza-de Gyves, E., Y. Roupheal, V. Cristofori and F. R. Mira. 2007. A non-destructive, simple and accurate model for estimating the individual leaf area of kiwi (*Actinidia deliciosa*). *Fruits* 62: 171-176.
24. Mokhtarpour, H., C. B. Teh, G. Saleh, A. B. Selamat, M. E. Asadi and B. Kamkar. 2010. Non-destructive estimation of maize leaf area, fresh weight, and dry weight using leaf length and leaf width. *Communications in Biometry and Crop Science* 5: 19-26.
25. Montero, F., J. De Juan, A. Cuesta and A. Brasa. 2000. Nondestructive methods to estimate leaf area in *Vitis vinifera* L. *HortScience* 35: 696-698.
26. Mousavi Bazaza, A., Z. Karimian Farimana and M. Bannayanb. 2011. Modeling individual leaf area of basil (*Ocimum basilicum*) using different methods. *International Journal of Plant Production* 5: 439-448.
27. NeSmith, D. 1992. Estimating summer squash leaf area nondestructively. *HortScience* 27: 77.
28. Nie, P., Y. Yang, F. Liu, J. Zheng and Y. He. 2010. Method of non-destructive measurement for plant leaf area and its instrument development. *Transactions of the Chinese Society of Agricultural Engineering* 26: 198-202. (In Chinese With English Abstract).
29. Odabas, M., E. Ergun and F. OnEr. 2013. Artificial neural network approach for the prediction of the corn (*Zea mays* L.) leaf area. *Bulgarian Journal of Agricultural Science* 19: 766-769.
30. Olfati, J., G. Peyvast, H. Shabani and Z. Nosrati-Rad. 2010. An estimation of individual leaf area in Cabbage and Broccoli using non-destructive methods. *Journal of Agricultural Science and Technology* 12: 627-632.
31. Oner, F., M. Odabas, I. Sezer and F. Odabas. 2011. Leaf area prediction for corn (*Zea mays* L.) cultivars with multiregression analysis. *Photosynthetica* 49: 637-640.
32. Palaniswamy, K. and K. Gomez. 1974. Length-width method for estimating leaf area of rice. *Agronomy Journal* 66: 430-433.
33. Payne, W., C. Wendt, L. Hossner and C. Gates. 1991. Estimating pearl millet leaf area and specific leaf area. *Agronomy Journal* 83: 937-941.
34. Pearce, R., J. Mock and T. Bailey. 1975. Rapid method for estimating leaf area per plant in maize. *Crop Science* 15: 691-694.

35. Peng, C. and X. Wen. 1999. Recent applications of artificial neural networks in forest resource management: An overview. pp. 15-22, *In*: U. Corte and M. Sanchez-Marre (Eds.), Environmental Decision Support Systems and Artificial Intelligence. Technical Report WS-99-07, American Association for Artificial Intelligence Press, Menlo Park, CA, USA.
36. Picton, P. 2000. Neural Networks. Macmillan Publishing Co., Inc., Indianapolis, USA.
37. Rahemi Karizaki, A., A. Soltani, J. Pourreza, E. Zeynali and R. Sarparast. 2006. Allometric relationships between leaf area and vegetative characteristics in field-grown chickpea. *Journal of Agricultural Sciences and Natural Resources* 13: 49-59. (In Farsi).
38. Schwarz, D. and H. P. Kläring. 2001. Allometry to estimate leaf area of tomato. *Journal of Plant Nutrition* 24: 1291-1309.
39. Sepaskhah, A. 1977. Estimation of individual and total leaf areas of safflowers. *Agronomy Journal* 69: 783-785.
40. Serdar, U. and H. Demirsoy. 2006. Non-destructive leaf area estimation in chestnut. *Scientia Horticulturae* 108: 227-230.
41. Sezer, I., F. Oner and Z. Mut. 2009. Non-destructive leaf area measurement in maize (*Zea mays* L.). *Journal of Environmental Biology* 30: 785-790.
42. Shih, S. and G. Gascho. 1980. Relationships among stalk length, leaf area, and dry biomass of sugarcane. *Agronomy Journal* 72: 309-313.
43. Shih, S., G. Gascho and G. Rahi. 1981. Modeling biomass production of sweet sorghum. *Agronomy Journal* 73: 1027-1032.
44. Soltani, A., M. Robertson, Y. Mohammad-Nejad and A. Rahemi-Karizaki. 2006. Modeling chickpea growth and development: Leaf production and senescence. *Field Crops Research* 99: 14-23.
45. Soltani, S., S. Sardari, M. Sheikh Pour and S. Mousavi. 2010. Artificial Neural Networks: Principles, Applications, and Familiarity with Software Easy NN-Plus and NeuroSolutions. Nass Publishing. (In Farsi).
46. Stewart, D. and L. Dwyer. 1999. Mathematical characterization of leaf shape and area of maize hybrids. *Crop Science* 39: 422-427.
47. Strobl, R. and F. Forte. 2007. Artificial neural network exploration of the influential factors in drainage network derivation. *Hydrological Processes* 21: 2965-2978.
48. Tsialtas, J. and N. Maslaris. 2008. Leaf area prediction model for sugar beet (*Beta vulgaris* L.) cultivars. *Photosynthetica* 46: 291-293.
49. Vazquez-Cruz, M., R. Luna-Rubio, L. Contreras-Medina, I. Torres-Pacheco and R. Guevara-Gonzalez. 2012. Estimating the response of tomato (*Solanum lycopersicum*) leaf area to changes in climate and salicylic acid applications by means of artificial neural networks. *Biosystems engineering* 112: 319-327.
50. Wendt, C. W. 1967. Use of a relationship between leaf length and leaf area to estimate the leaf area of cotton (*Gossypium hirsutum* L.), castors (*Ricinus communis* L.), and sorghum (*Sorghum vulgare* L.). *Agronomy Journal* 59: 484-486.
51. Willmott, C. J. 1981. On the validation of models. *Physical Geography* 2: 184-194.
52. Wu, C., W. Zhang, Q. Ouyang and T. Hong. 2007. BP neural network model for the measurement of the leaf area of litchi. *Transactions of the Chinese Society of Agricultural Engineering* 23: 166-169. (In Chinese With English Abstract).
53. Zavareh, M., H. R. Mashhadi. 2009. Estimation of sesame (*Sesamum indicum* L.) leaf area using non-destructive functional method. *In*: Proceeding of the First National Oilseed Plants Conference. Isfahan University of Technology, Isfahan, Iran. (In Farsi).

Estimating Corn Plant Leaf Area Using Artificial Neural Network

KH. Nazari¹, M. Zavareh^{2*} and A. Ashrafzadeh³

(Received: May 7-2016; Accepted: March 1-2017)

Abstract

This experiment was designed for easy and accurate estimation of corn plant leaf area with multilayer perceptron (MLP) neural network and conducted at Faculty of Agricultural Sciences, University of Guilan, Rasht, Iran in 2013. Three plant densities (75, 85 and 95 thousand plants/ha) and five genotypes (Persia 454, 484, 565, 626 and 647) were considered as treatments. Samplings were conducted at various times (66, 80, 94 & 108 DAP). At each sampling, number of leaves per plant, number of green leaves, leaf length and width, plant leaf area, leaf and stem dry weight, plant height, stem diameter and biological yield were measured. Correlations analysis indicated that measured characteristics had positive significant correlation with plant leaf area ($r \geq 0.859^{**}$) and they can be used as inputs for estimation of leaf area. Among these variables, the highest sensitivity was associated to leaf width, number of green leaves, leaf length, number of leaves per plant and stem diameter, respectively. However the model with a lower number of variable, i.e. including leaf width, number of green leaves and leaf length was more appropriate for quick estimation of leaf area. When a single input had been used for estimation of leaf area, leaf dry weight offered a better simulation than other variables ($d = 0.989$), so that 95.69% of leaf area changes was described through leaf dry weight ($R^2 = 0.9569$) and it can estimate leaf area well (RMSE (%) = 15.67). In both methods of estimation for leaf area (by using single input and sensitivity analysis), the best fitted models were not affected by cultivar, plant density and interaction of these two factors. Therefore, a general model can be used for rapid and accurate leaf area estimation of genotypes and plant densities used in the experiment.

Keywords: Allometric relations, Cultivar, Density, Multi-layer perceptron (MLP), Sensitivity analysis

1, 2. MSc. Student and Associate Professor, Respectively, Department of Agronomy and Plant Breeding, Faculty of Agricultural Sciences, University of Guilan, Rasht, Iran.

3. Assistant Professor, Department of Irrigation, Faculty of Agricultural Sciences, University of Guilan, Rasht, Iran.

*. Corresponding Author, Email: mzavareh@guilan.ac.ir