



بررسی تنوع و تخمین سطح برگ در اکو-تیپ‌های مختلف گیاه دارویی نعناع با استفاده از مدل‌های هوش مصنوعی و رگرسیونی تحت شرایط تنفس شوری

**سید جابر حسینی^۱، زین العابدین طهماسبی سروستانی^۲، همت الله پیردشتی^۳، سید علی محمد مدرس ثانوی^۴،
علی مختصی بیدگلی^۵ و سعید حضرتی^۶**

- ۱- دانشجوی دکتری، گروه زراعت داشکده کشاورزی داشکده کشاورزی تربیت مدرس
 - ۲- دانشیار، گروه زراعت داشکده کشاورزی داشکده کشاورزی تربیت مدرس (نویسنده مسؤول: tahmaseb@modares.ac.ir)
 - ۳- استاد، دانشگاه علوم کشاورزی و منابع طبیعی ساری
 - ۴ و ۵- استاد و استادیار، گروه زراعت داشکده کشاورزی داشکده کشاورزی تربیت مدرس
 - ۶- استادیار گروه زراعت و اصلاح نباتات، داشکده کشاورزی، دانشگاه شهید مدنی آذربایجان، تبریز
- تاریخ دریافت: ۹۸/۸/۲ تاریخ پذیرش: ۹۸/۸/۹

صفحه: ۵۹ تا ۷۳

چکیده

سطح برگ یک شاخص کلیدی برای رشد و تولید محصولات گیاهی و همچنین عاملی تعیین‌کننده در کارایی مصرف نور محسوب می‌گردد، لذا بررسی تنوع و همچنین تخمین مختلف سطح برگ در اکو-تیپ‌های مختلف نعناع از اهمیت خاصی برخوردار است. از جمله روش‌های معمول برای تخمین سطح برگ تجزیه و تحلیل رگرسیونی می‌باشد که سطح برگ به عنوان متغیر مستقل، و طول و عرض برگ به عنوان متغیر وابسته می‌باشند. در این مطالعه سطح برگ ۱۸ اکو-تیپ گیاه دارویی نعناع با مدل‌های مختلف ANFIS، شبکه عصبی مصنوعی (MLP و RBF)، رگرسیون‌های خطی و غیرخطی با استفاده از دو ورودی طول و عرض برگ در چهار سطح تنفس شوری (شاهد، ۵/۲، ۵ و ۷/۵ دسی‌زیمنس بر متر) و در دو مرحله برداشت تخمین زده شد. نتایج نشان داد که همبستگی بالایی بین طول و عرض با سطح برگ وجود دارد، به طوری که همبستگی عرض با سطح برگ بیشتر از طول برگ بود. از بین مدل‌های رگرسیونی در هر دو برداشت و در تمامی سطوح تنفس، مدل NLR به عنوان بهترین و دقیق‌ترین مدل معرفی شده است. مدل ANFIS در هر دو مرحله برداشت و در تمامی سطوح تنفس نسبت به سایر مدل‌ها از دقت بالاتری برخوردار بود و میزان خطای کمتری را به خود اختصاص داد. همچنین نتایج حاصل از تجزیه کلاستر نشان داد که تنوع مطلوبی بین اکو-تیپ‌ها وجود دارد. علاوه‌بر این مقایسه میانگین بین گروه‌های مختلف اکو-تیپ‌ها می‌باشد که بیشترین مقدار طول، عرض و سطح برگ در هر دو مرحله برداشت و در تمام سطوح تنفس شوری مربوط به اکو-تیپ ۱۸ (E18) بوده است.

واژه‌های کلیدی: اکو-تیپ، تنفس شوری، سطح برگ، نعناع، مدل‌های رگرسیونی

آبیاری است (۷). بنابراین سطح برگ گیاهان بهشدت رشد گیاه و تولید محصولات کشاورزی را تحت تاثیر قرار می‌دهد و تخمین این فاکتور مهم یکی از اجزای اساسی مدل‌های رشد گیاهان زراعی به شمار می‌رود (۳۲). تعیین سطح برگ به وسیله روش‌های مستقیم و غیرمستقیم مختلفی امکان‌پذیر است (۲۴). روش‌های مستقیمی که برای اندازه‌گیری سطح برگ به کار می‌رود شامل استفاده از انواع مختلفی از پلانی‌مترهای لیزری، روش‌های مبتنی بر اسکن (۸ و ۴۰)، گراوی‌متری (۴۲) و یا یک دوربین ثابت و نرم‌افزار آنالیز تصویری (۱۷) است که در کنار مزایای آن‌ها دارای معایی نیز می‌باشند. به عنوان مثال، اندازه‌گیری سطح برگ کل و یا بخشی از گیاه با روش‌های مستقیم هزینه‌بر و زمان‌بر می‌باشد و نیازمند به استفاده از دستگاه‌های گران‌قیمت می‌باشند (۳۱). علاوه‌بر این روش‌هایی مثل کپی‌برداری، چاپ‌کردن اوزالیدی، عکس‌برداری با استفاده از یک پلانی‌متر متدالوک که اندازه‌گیری را تسهیل می‌کند، به مقدار زیادی از سطح برگ نیاز داشته و همچنین کانونی گیاه و بافت‌های سطح برگ نیز ممکن است در اثر این عمل مورد آسیب قرار گیرند (۱۲). سطح برگ به صورت سریع و غیرتخریبی با استفاده از یک پلانی‌متر اسکن کننده دستی نیز قابل اندازه‌گیری است (۱۳). اما

مقدمه
نعناع یکی از پُرمصرف‌ترین گیاهان دارویی است که مقدار مصرف سالانه انسان آن در جهان بسیار زیاد می‌باشد. این گیاه به عنوان یک منبع غنی از روغن‌های اساسی که مصارف غذایی عمده‌ای داشته و از نظر مصارف دارویی نیز به عنوان ضدنفخ، ضدبakterی و کمک‌کننده هضم غذا مورد مصرف می‌باشد (۲۵). کارایی بیشتر این گیاه به انسان آن که جزء متابولیت‌های ثانویه محسوب می‌شود، نسبت داده شده است، بنابراین هر عاملی نظیر سطح برگ، طول و عرض برگ که بر کمیت و کیفیت انسان اثرگذار باشد مورد توجه قرار می‌گیرد (۲۳). از سوی دیگر تنفس شوری از مهم‌ترین تنش‌های غیرزیستی می‌باشد که رشد گیاهان را محدود کرده و صفات موافل‌وژیک، فیزیولوژیک و بیوشیمیایی گیاهان را تحت تاثیر قرار می‌دهد (۱۵، ۲۱، ۳۴ و ۴۶). برگ مهم‌ترین اندام فتوستنتزی برای گیاه محسوب می‌گردد، از این‌رو چندین عامل مرتبط با برگ شامل اندازه، شکل، سطح و تعداد برگ در هر گیاه نقش تعیین‌کننده‌ای در عملکرد دارد (۶). علاوه‌بر این سطح برگ یک متغیر کلیدی برای مطالعات فیزیولوژیکی شامل رشد گیاه، جذب نور، کارایی فتوستنتزی، تبخیر و تعرق و همچنین پاسخ گیاه به کودها و

رگرسیون غیرخطی ($NL R^{\circ}$)^۷، رگرسیون لگاریتمی (Log)^۸، رگرسیون حداقل مربعات جزئی (PLS°)^۹، رگرسیون حداقل مربعات معمولی (OLS°)^{۱۰} و رگرسیون مولفه‌های اصلی (PCR°)^{۱۱} برای پیش‌بینی میزان پارامتر خروجی در مطالعات متعدد استفاده نمودند (۲۲).

هدف از این مطالعه تخمین سطح برگ گیاه دارویی نعناع و همچنین پی‌بردن به بهترین مدل برای تخمین سطح برگ با استفاده از صفات طول و عرض برگ بوده است. هدف دوم این تحقیق، بررسی تنوع بین اکوتبهای مورد مطالعه بر اساس صفات مربوط به سطح برگ با استفاده از تجزیه خوش‌های بوده است.

مواد و روش‌ها

این تحقیق در پژوهشکده ژنتیک و زیستفناوری کشاورزی تبرستان اجرا شد. ابتدا نشاء‌های گیاه نعناع در گلدان‌های پلاستیکی بهصورت آزمایش فاکتوریل اسپلیت‌پلات در زمان و در قالب طرح بلوک‌های کامل تصادفی با چهار تکرار در محل گلخانه تحقیقاتی (دماهی ۲۸ درجه سانتی‌گراد، دوره روشانی و تاریکی بهترنی ۱۶ و ۸ ساعت و رطوبت نسبی ۶۰ درصد) صورت گرفت. تیمارهای مورد مطالعه در این آزمایش شامل تیمار شوری در چهار سطح (صفر، ۵/۲، ۵ و ۷/۵ دسی‌زیمنس بر متر) و اکوتبهای مختلف نعناع در ۱۸ سطح می‌باشد. در این آزمایش گلدان‌هایی با قطر ۲۵ سانتی‌متر و ارتفاع ۳۰ سانتی‌متر استفاده و هر گلدان از کوکوپیت (۴۰٪) + پرلیت (۶۰٪) بهمیزان مساوی پر شد. آزمایش بهصورت هیدروپونیک انجام شد، بههمین منظور از محلول غذایی هوگلندر برای تعذیه گیاهان مورد کشت استفاده شد. نحوه اعمال تنش شوری از روز پانزدهم پس از کاشت اعمال شد. اعمال تیمار شوری جهت جلوگیری از وارد‌آمدن شوک به گیاه در سطوح ۵ و ۷/۵ دسی‌زیمنس بر متر بهطور تدریجی صورت گرفت، بهطوری که در هر مرحله از شوری ۲/۵ دسی‌زیمنس بر متر اعمال شد تا به سطوح ۵ و ۷/۵ دسی‌زیمنس بر متر برسد. همچنین برای جلوگیری از تجمع املاح در بستر کشت، شستشو در دوره‌های زمانی معین انجام شد. در پایان فصل رشد ابتدا طول و عرض برگ توسط کولیس مورد اندازه‌گیری قرار گرفت. پس از آن سطح برگ با دستگاه اندازه‌گیری سطح برگ مورد سنجش قرار گرفت. داده‌های حاصل از آزمایش با نرم‌افزار آماری SAS (نسخه ۹/۱) مورد تجزیه و تحلیل قرار گرفت. علاوه‌بر این از نرم‌افزار XLSTAT برای انجام تجزیه کلاساستر استفاده شد. همچنین نرم‌افزار متلب برای بررسی مدل‌های مختلف مورد استفاده قرار گرفت. برای تیمين صحت و اعتبار مدل‌ها از آماره‌های R^2 ^{۱۲}، VAF^{۱۳}، MAPE^{۱۴}، RMSE^{۱۵}، BIC^{۱۶}، AIC^{۱۷} و RPD^{۱۸} استفاده شد. که این آماره‌ها توسط روابط زیر قابل محاسبه است (۲۲، ۳۲).

این روش نیز برای گیاهان با تعداد برگ‌های کم مناسب است (۳۸). در نقطه مقابل روش‌های مستقیم، روش‌های غیرمستقیم سریع، معبر، ارزان، ساده و غیرتخریبی برای تخمین سطح برگ بوده که برای انجام آزمایش ضروری بهنظر می‌رسد (۲۶). تعیین سطح برگ با استفاده از طول و عرض برگ در روش‌های مستقیم و غیرتخریبی معمول است، به این صورت که در ابتدا ارتباط بین سطح برگ با طول و عرض برگ مشخص شده و سپس سطح برگ با اندازه‌گیری مستقیم طول و عرض برگ توسط خط‌کش تعیین می‌شود، این روش در مورد گیاهانی صادق است که تعداد برگ محدود دارند (۴۴). از جمله روش‌های دیگر برای تخمین سطح برگ، رگرسیون خطی چندمتغیره می‌باشد که باستی ارتباط خطی بین متغیرهای وابسته با متغیر مستقل وجود داشته باشد (۱). بهدلیل وجود روابط غیرخطی بین طول و عرض با سطح برگ استفاده از رگرسیون‌های خطی سخت و مشکل می‌باشد و تخمین حاصله با خطأ همراه می‌باشد، بههمین دلیل از روش‌های دیگری نظریه روش پلی‌نومیال (۴۱) و روش گراویمتریک (۵) نیز استفاده شده است. پژوهشگران دیگری از شبکه عصبی مصنوعی برای تخمین سطح برگ گیاهان مختلف نظریه ذرت (۴۹)، فلفل (۲) و گوجه (۴۷) استفاده کردند. شبکه عصبی مصنوعی (ANN)^۱ از عناصر عملیاتی ساده‌ای تشکیل می‌شوند که بهصورت موازی در کنار هم عمل می‌کنند و از سیستم‌های عصبی زیستی الهام می‌گیرند. همچنین قابل ذکر است که در طبیعت عملکرد شبکه‌های عصبی از طریق نحوه اتصال میان اجزای مختلف برآورد می‌شود. از پرکاربردترین مدل‌های مختلف شبکه عصبی می‌توان به مدل برسپترون چند لایه (MLP)^۲ و مدل توابع پایه‌ای شعاعی (RBF)^۳ جهت پیش‌بینی اشاره کرد (۲۲). بررسی‌های صورت گرفته نشان می‌دهد که تاکنون مطالعه‌ای در زمینه استفاده از مدل‌های شبکه عصبی مصنوعی برای تخمین سطح برگ ناعنایان صورت نگرفته است. سیستم استنتاج عصبی-فازی انبطاقی (ANFIS)^۴ یک چارچوب محاسباتی راجع بر مبنای مفهوم مجموعه‌های فازی، قواعد if-then و استدلال فازی محسوب می‌شوند که ساختار پایه‌ای سیستم‌های آن از سه بخش مفهومی تشکیل می‌شود (۲۲).

تحقیقات در زمینه استفاده از مدل ANFIS نیز برای تعیین سطح برگ ناعنایان انجام نشده است، ولی در سال‌های اخیر استفاده از ANFIS در زمینه‌های مختلف کشاورزی در حال افزایش است که شامل برآورد تعییرات تولید عملکرد (۱۸)، پیش‌بینی پتانسیل تورمی خاک‌های رسی (۴۸)، پیش‌بینی نیتریت آب‌های زیرزمینی (۳۵)، راندمان حذف یون‌های سرب از محلول‌های آبی (۴)، ظرفیت تبادل کاتیونی و نفوذ خاک (۱۶)، پایداری خاکدانه‌های خاک (۳۳) و پیش‌بینی عملکرد گندم دیم با استفاده از ورودی‌های مختلف انرژی (۲۹، ۳۶) بوده است. همچنین محققان از مدل‌های رگرسیون غیرپارامتری (NP R)^۵

- 1- Artificial neural network
- 4- Adaptive neuro fuzzy inference system
- 7- Logarithmic regression
- 10- Principal component regression
- 13- Mean absolute percentage error
- 16- Bayesian information criteria
- 17- Akaike information criterion

- 2- Multilayer perceptron
- 5- Nonparametric regression
- 8- Partial least squares regression
- 11- Coefficient of determination
- 14- Root mean square error

- 3- Radial basis function
- 6- Nonlinear regression
- 9- Ordinary least squares regression
- 12- Variance account factor
- 15- Relative percent difference

و معنی‌داری در سطح یک درصد بین عرض و سطح برگ در تمام سطوح تنش شوری دیده شد که کمترین مقدار همبستگی مربوط به سطح شوری ۲/۵ دسی‌زیمنس بر متر بوده است. همچنین همبستگی پایین و غیرمعنی‌داری بین طول و سطح برگ در سطوح شوری ۲/۵ و ۵ دسی‌زیمنس بر متر وجود داشت (شکل ۱).

نتایج آنالیز حساسیت نشان داد که در هر دو برداشت، اهمیت عرض برگ روی سطح برگ نسبت به طول برگ بیشتر بوده و همچنین میزان اهمیت عرض برگ در مرحله بدون تنش نسبت به دیگر مراحل تنش بیشتر بوده است (شکل ۲). با افزایش مقدار تنش شوری میزان اهمیت عرض و طول برگ به ترتیب کاهش و افزایش می‌یابد. میزان اهمیت طول روی سطح برگ در تنش ۷/۵ دسی‌زیمنس بر متر نسبت به دیگر سطوح تنش بیشتر بوده است (شکل ۱). در واقع این مطلب نشان می‌دهد که طول و عرض برگ اثرات مکملی روی سطح برگ داشته‌اند به این صورت که با افزایش تنش به ترتیب از اثر عرض برگ بر سطح برگ کاسته شده و اثر طول برگ پر رنگ‌تر می‌شود. به‌نظر می‌رسد رطوبت مناسب برای رشد گیاه بیشتر موجب رشد عرضی برگ شده است و به همین دلیل بر جذب تابش خورشید اثر گذاشته که موجب جذب بیشتر تشعشعات خورشیدی و افزایش فتوستتر می‌شود. هینا و همکاران (۱۹) گزارش کردند که همبستگی بالایی بین طول و عرض برگ‌های گیاه بادنجان با سطح برگ وجود داشته است.

$$(Equation\ 1)\ VAF = [1 - \frac{Var(P(si)-M(si))}{Var(M(si))}] \times 100$$

$$(Equation\ 2)\ RMSE = \sqrt{\frac{\sum_{i=1}^n [P(si)-M(si)]^2}{n}}$$

$$(Equation\ 3)\ R2 = 1 - \frac{\sum_{i=1}^n [M(si)-P(si)]^2}{\sum_{i=1}^n [M(si)-A(si)]^2}$$

$$(Equation\ 4)\ MAPE = \frac{\sum_{i=1}^n |A_i - P_i|}{N} \times 100$$

$$(Equation\ 5)\ BIC = (n) \log (SSE/n) + (K) \log (n)$$

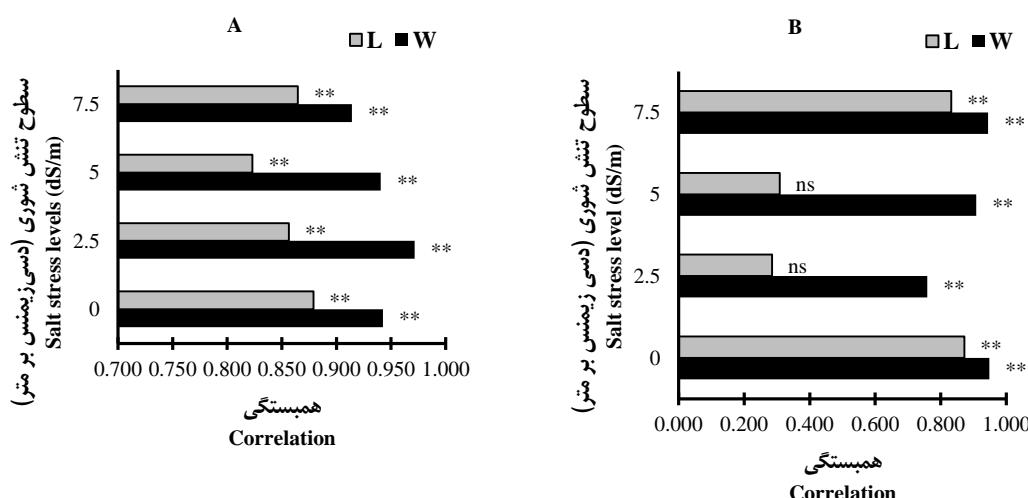
$$(Equation\ 6)\ AIC = (n) \log (SSE/n) + 2p$$

$$(Equation\ 6)\ RPD = \frac{SD}{RMSE_p}$$

نتایج و بحث

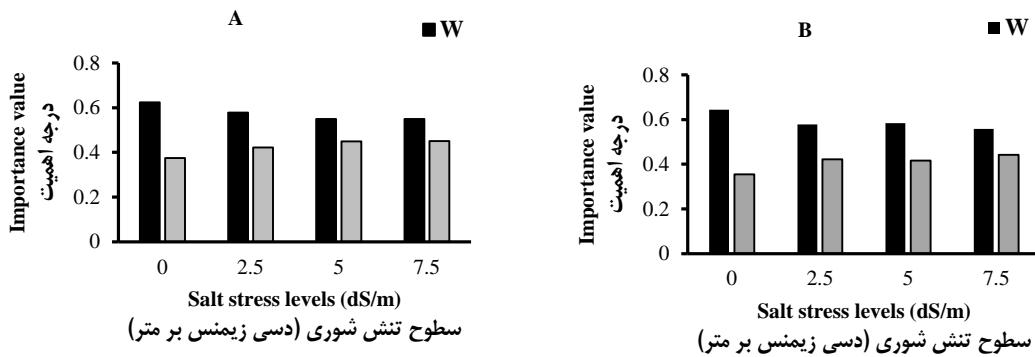
آنالیز حساسیت و تجزیه همبستگی مربوط به صفات سطح با طول و عرض برگ

نتایج نشان داد که در برداشت اول، طول و عرض برگ همبستگی معنی‌داری در سطح یک درصد با سطح برگ در تمامی سطوح تنش شوری داشته است. علاوه‌بر این مشاهده شد که میزان همبستگی عرض برگ با سطح برگ نسبت به طول برگ بیشتر بوده است. بیشترین میزان همبستگی بین طول و عرض با سطح برگ به ترتیب در سطح شوری ۷/۵ دسی‌زیمنس بر متر و شاهد مشاهده شد. اما در برداشت دوم، همبستگی زیاد



شکل ۱- ضریب همبستگی بین صفات طول و عرض برگ با صفت سطح برگ تحت تنش شوری در برداشت اول (A) و برداشت دوم (B). همچنین L و W به ترتیب نشان‌دهنده طول و عرض برگ هستند. ns, * و ** به ترتیب غیر معنی‌دار، معنی‌دار در سطح احتمال ۵ و ۱ درصد

Figure 1. Correlation coefficient between length and width traits of leaf with leaf area under salt stress condition in first harvest (A) and second harvest (B). L and W related to length and width of leaf, respectively. Ns, * and **: are non-significant and significant at 5 and 1% probability levels, respectively.



شکل ۲- نتایج آنالیز حساسیت مربوط به صفات طول و عرض برگ تحت تنش شوری در برداشت اول (A) و برداشت دوم (B)
Figure 2. The results of sensitivity analysis related to length and width traits under salt stress conditions in first harvest (A) and second harvest (B)

از سه شاخص طول، عرض و سطح برگ و مبتنی بر تجزیه چندمتغیره گروه‌بندی شده‌اند به‌طوری که اکوئیپ‌های مورد مطالعه در برداشت اول و سطوح شوری شاهد، ۲/۵، ۵ و ۷/۵ دسی‌زیمنس بر متر به ترتیب در ۳، ۴، ۴ و ۴ گروه و در برداشت دوم در ۳، ۴، ۵ و ۴ گروه مجزا از هم تفکیک شده‌اند (شکل ۳).

تجزیه کلاستر

نتایج مربوط به آماره‌های توصیفی در جدول ۱ نشان داده شد که حاکی از تنوع مطلوب بین اکوئیپ‌های مختلف مورد مطالعه بر اساس صفات طول برگ، عرض برگ و سطح برگ می‌باشد. در این آزمایش ۱۸ اکوئیپ گیاه دارویی نعناع با استفاده

جدول ۱- آماره‌های توصیفی مربوط به صفات مختلف مورد مطالعه در ۱۸ اکوئیپ نعناع

Table 1. Descriptive statistics related to different traits studied in 18 mint ecotypes

تشش شوری (دسی‌زیمنس بر متر)	صفات	برداشت اول				برداشت دوم			
		کمینه	بیشینه	میانگین	انحراف معیار	کمینه	بیشینه	میانگین	انحراف معیار
شاهد	عرض برگ	۱/۵۹۸	۴/۵۰۵	۳/۵۵۷	۰/۶۶۱	۱/۶۵۸	۴/۵۷۸	۳/۶۱۸	۰/۶۶۳
	طول برگ	۱/۰۱۵	۴/۵۱۰	۳/۶۷۴	۰/۴۴۵	۳/۰۷۵	۴/۵۷۸	۳/۷۳۳	۰/۴۴۷
	سطح برگ	۴/۲۶۸	۱۴/۷۴۸	۹/۵۲۰	۲/۷۵۰	۴/۵۰۸	۱۴/۹۹۸	۹/۸۵۳	۲/۷۲۳
۲/۵	عرض برگ	۱/۵۹۰	۲/۹۰۳	۲/۲۲۶	۰/۳۹۵	۱/۶۴۵	۴/۵۰۵	۲/۷۴۸	۰/۷۴۷
	طول برگ	۳/۷۳۵	۵/۱۶۵	۴/۶۱۳	۰/۳۶۸	۳/۰۱۵	۵/۰۹۸	۴/۱۷۳	۰/۷۳۰
۵	سطح برگ	۴/۳۳۳	۱۰/۷۲۰	۷/۵۴۴	۱/۸۱۹	۴/۳۲۰	۱۴/۷۴۸	۸/۰۷۶	۲/۲۳۴
	عرض برگ	۱/۴۲۵	۲/۷۷۵	۱/۹۶۹	۰/۳۹۷	۱/۴۸۵	۴/۵۰۵	۲/۴۵۰	۰/۱۶۱
	طول برگ	۳/۲۴۸	۴/۹۵۸	۴/۰۰۸	۰/۴۸۸	۳/۰۱۵	۴/۶۴۰	۳/۹۵۹	۰/۵۳۶
۷/۵	سطح برگ	۳/۲۷۵	۹/۶۰۰	۵/۷۷۰	۱/۶۴۵	۳/۵۱۰	۱۴/۷۴۸	۶/۹۳۹	۲/۶۰۳
	عرض برگ	۱/۰۱۰	۲/۴۲۵	۱/۵۹۸	۰/۳۸۹	۱/۰۷۰	۲/۹۲۶	۱/۶۸۲	۰/۴۵۳
	طول برگ	۲/۳۳۳	۴/۴۲۳	۳/۲۵۱	۰/۵۶۲	۲/۴۰۳	۴/۴۴۶	۳/۳۰۹	۰/۵۵۷
	سطح برگ	۱/۶۷۵	۷/۶۲۸	۳/۸۱۶	۱/۴۱۶	۱/۸۳۵	۹/۵۱۴	۴/۱۱۸	۱/۷۳۵

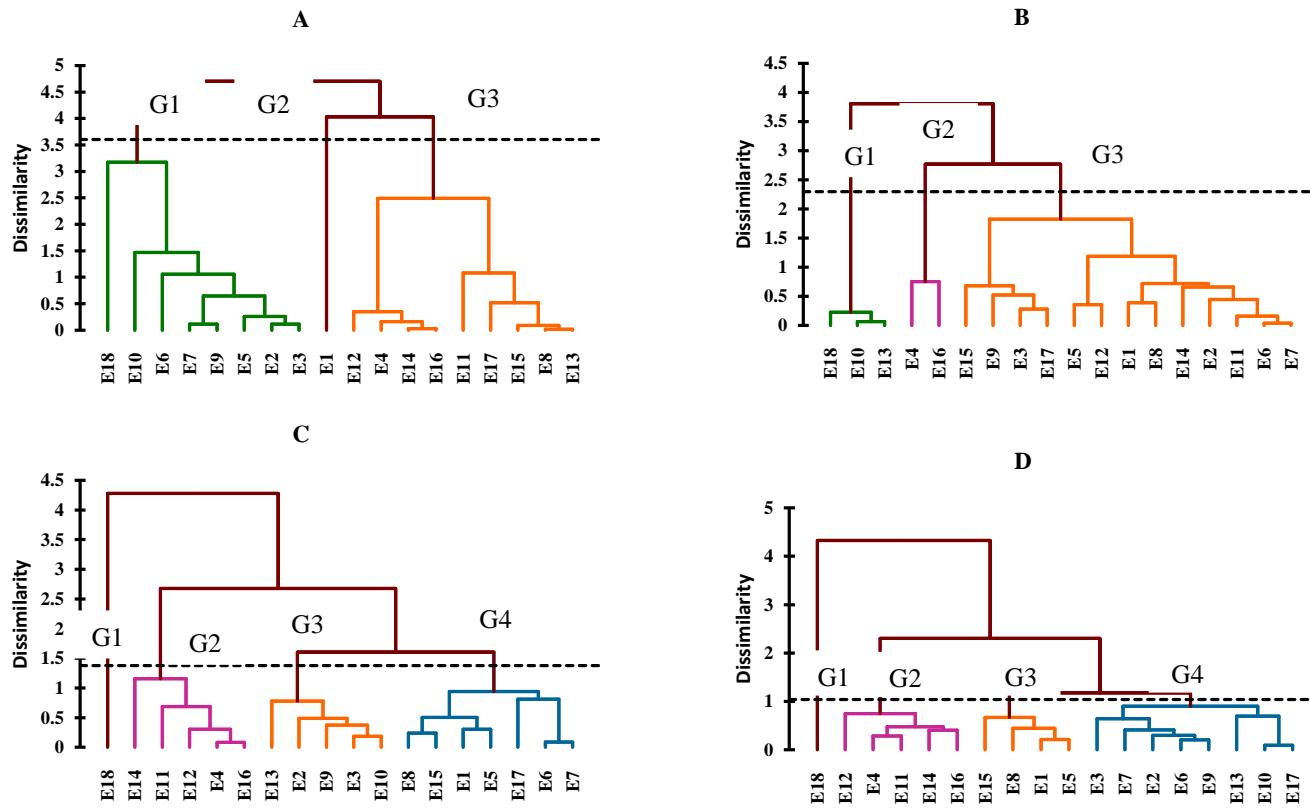
(E13) قرار گرفتند. از سویی دیگر نتایج حاصل از تجزیه کلاستر نشان داد که تنش شوری که در برداشت اول، وضعیت اکوئیپ‌ها در شرایط بدون تنش شوری به ترتیب در گردید، به‌طوری که در تنش شوری سطح ۲/۵ دسی‌زیمنس بر متر، اکوئیپ‌ها در سه گروه متمایز به ترتیب G1

نتایج حاصل از تجزیه کلاستر نشان داد که در برداشت اول، وضعیت اکوئیپ‌ها در شرایط بدون تنش شوری به ترتیب در G2، (E18, E10, E6, E7, E9, E5, E2, E3) G1 (E12, E4, E14, E16, E11, E17, E15, E8,) G3 (E1)

E13,) G4, (E15, E8, E1, E5) G3, (E14, E16, E4, E11 صورت گرفته است (شکل .^۳)

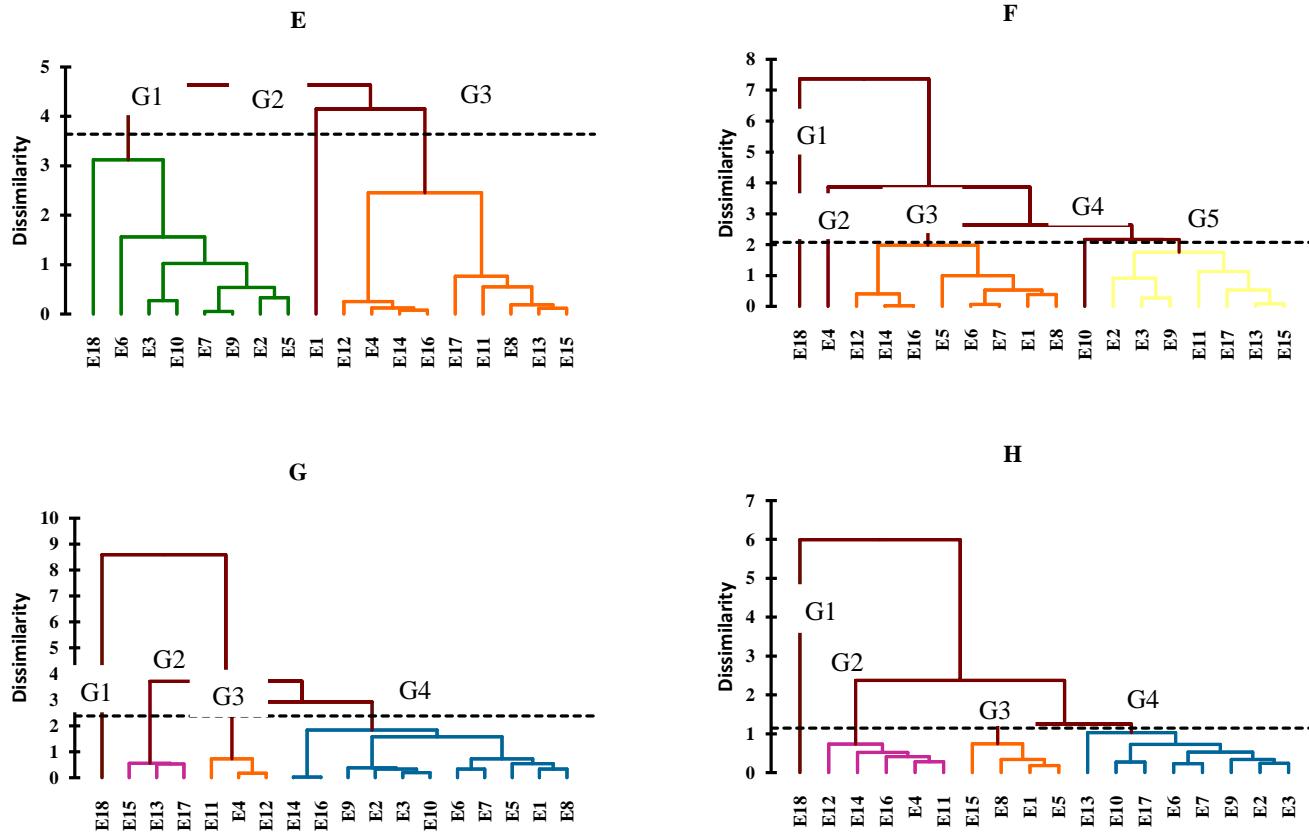
نتایج مقایسه میانگین بین گروههای حاصل از تجزیه کلاستر نشان می‌دهد که بیشترین مقدار طول، عرض و سطح برگ مربوط به گروه G1 می‌باشد (شکل .^۴). همچین نتایج مقایسه میانگین بین گروههای حاصل از تجزیه کلاستر نشان می‌دهد که اکوتیپ E18 در هر دو برداشت و در تمام شرایط تنش شوری و عدم تنش شوری در گروه G1 قرار گرفت (شکل .^۴) و در نتیجه، نسبت به تنش شوری تحمل بیشتری نشان می‌دهد. ولی اکوتیپ‌های دیگر نسبت به شرایط تنش در گروههای مختلفی قرار می‌گیرند. هر کدام از اکوتیپ‌ها در غلظت‌های خاصی از تنش شوری سازگار هستند و می‌توانند در آن شوری، شاخص‌های طول، عرض و سطح برگ را تولید نمایند. در برداشت اول به نظر می‌رسد که اکوتیپ‌های E7 و E6 نسبت به تنش شوری بسیار حساس می‌باشند چون با شروع تنش شوری از ۲/۵ به ۷ دسی‌زیمنس بر متر در ضعیفترین گروه قرار گرفته‌اند که موجب کاهش طول، عرض و سطح برگ شده‌اند. در برداشت دوم اکوتیپ‌های E9, E2 و E3 در ضعیفترین گروه قرار داشتند که نشان از حساسیت آن‌ها به تنش شوری می‌باشد. قابل ذکر است که با اعمال تنش شوری میزان طول، عرض و سطح برگ در این اکوتیپ‌ها کاهش یافته است.

E15, E9, E3,) G3 و (E16, E4) G2, (E18, E10, E13) (E17, E5, E12, E1, E8, E14, E2, E11, E6, E7 گرفتند. همچنین نتایج در سطح شوری ۵ دسی‌زیمنس بر متر به ترتیب (E18) G1, (E14, E11, E12, E4, E16) G2 و (E13, E2, E9, E3, E10) (E6, E7) بود. در آخرین سطح تنش شوری ۷/۵ دسی‌زیمنس بر متر گروه‌بندی اکوتیپ‌ها به ترتیب (E18) G1, (E12,) G2, (E18, E6, E3, E10, E17) (E4, E11, E14, E16) E3,) G4, (E15, E8, E1, E5) G3, (E1, E12, E1, E8, E14, E16) (E7, E2, E6, E9, E13, E10, E17) اکوتیپ‌ها در گروه‌ها در برداشت دوم نسبت به برداشت اول متفاوت بوده، به طوری که در شرایط بدون تنش (شاهد) G1, G3 (E1) G2, (E18, E6, E3, E10, E7, E9, E2, E5) (E12, E4, E14, E16, E17, E11, E8, E13, E15) بوده است. علاوه‌بر این نتایج کلاستر در سطح تنش شوری ۲/۵ دسی‌زیمنس بر متر نشان داد که اکوتیپ‌ها در گروههای E12, E14, E16, E5, E6, E7, E1,) G3, (E4) G2, (E18, E2, E3, E9, E11, E17, E13, E15) G5, (E10) G4, (E8) قرار گرفتند. از طرف دیگر در تنش شوری سطح ۵ دسی‌زیمنس بر متر گروه‌بندی دستخوش تغییر شده است، به طوری که اکوتیپ‌های مورد مطالعه در گروه‌های E15,) G2, (E18) G1, E14, E16, E9,) G4, (E11, E4, E12) G3, (E13, E17 (E2, E3, E10, E6, E7, E5, E1, E8) قرار گرفتند. دندروگرام ۷/۵ حاصل از تجزیه کلاستر نشان داد که در تنش شوری سطح دسی‌زیمنس بر گروه‌بندی به ترتیب (E18) G1, (E12,) G2



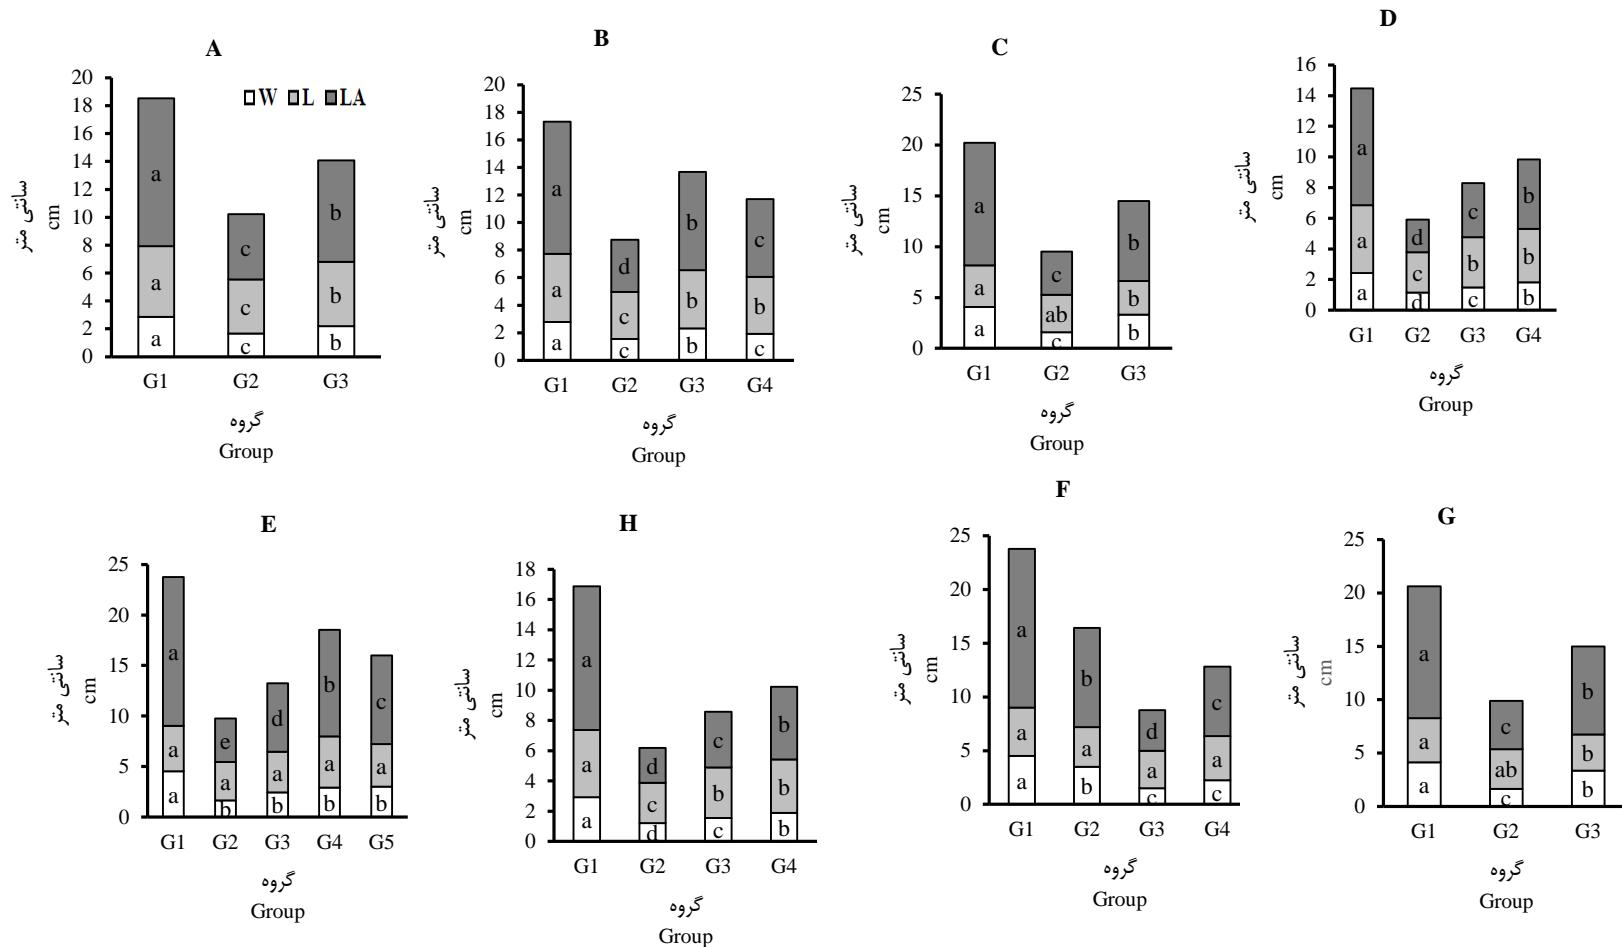
شکل ۳- نتایج مربوط به تجزیه کلاستر در سطوح مختلف تنش شوری در برداشت‌های اول و دوم، [A (شاهد+برداشت اول)، B (۲/۵ دسی‌زیمنس بر متر+برداشت اول)، C (۵ دسی‌زیمنس بر متر+برداشت اول)، D (۷/۵ دسی‌زیمنس بر متر+برداشت اول)]

Figure 3. The results of cluster analysis under different salt stress levels in first and second harvest. [A (Control+first harvest), B (2.5 dS/m+first harvest), C (5 dS/m+first harvest), D (7.5 dS/m+first harvest)]



شکل ۴- نتایج مربوط به تجزیه کلاستر در سطوح مختلف تنفس شوری در برداشت‌های اول و دوم. [E (شاهد+برداشت دوم)، F (۵/۲ دسی‌زیمنس بر متر+برداشت دوم)، G (۵ دسی‌زیمنس بر متر+برداشت دوم) و H (۷/۵ دسی‌زیمنس بر متر+برداشت دوم)]

Figure 4. The results of cluster analysis under different salt stress levels in first and second harvest. [A (Control+first harvest), B (2.5 dS/m+first harvest), C (5 dS/m+first harvest), D (7.5 dS/m+first harvest), E (Control+second harvest), F (2.5 dS/m+second harvest), G (5 dS/m+second harvest) and H (7.5 dS/m+second harvest)]



شکل ۵- نتایج مربوط به مقایسه میانگین گروههای حاصل از تجزیه کلاستر تحت تنش شوری در برداشت‌های اول و دوم. [A (شاهد+برداشت اول)، B (شاهد+برداشت اول)، C (دسى زیمنس بر متر+برداشت اول)، D (دسى زیمنس بر متر+برداشت اول)، E (شاهد+برداشت دوم)، F (شاهد+برداشت دوم)، G (دسى زیمنس بر متر+برداشت دوم) و H (دسى زیمنس بر متر+برداشت دوم)]. ستون‌های دارای حروف مشابه بر اساس آزمون دانکن اختلاف معنی‌داری در سطح پنج درصد ندارند.

Figure 5. The results of mean comparison related to different groups of cluster analysis under salt stress condition in first and second harvest. [A (Control+first harvest), B (2.5 dS/m+first harvest), C (5 dS/m+first harvest), D (7.5 dS/m+first harvest), E (Control+second harvest), F (2.5 dS/m+second harvest), G (5 dS/m+second harvest) and H (7.5 dS/m+second harvest)]. At $\alpha=5\%$ based on Duncan test, means with similar letters in each column are not significantly different.

مدل معرفی شد ($R^2=0.9849$). بر طبق مطالعه هینا و همکاران (۱۹)، مدل‌های power و quadratic با مقدار R^2 (۰.۹۶۴) (برای هر دو مدل) و RMSE به ترتیب $\frac{33}{4}$ و $\frac{34}{4}$ با دقت بالا و کمترین خطا مقدار سطح برگ را در بادمحان تخمین زده است. کومار و همکاران (۳۰) گزارش کردند که رگرسیون خطی نسبت به رگرسیون‌های غیرخطی شاخص سطح برگ گیاه خارگیل (*Durio zibethinus*) را دقیق‌تر تخمین زده است. در مطالعات انجام شده روی گونه‌هایی مانند (*Pigeon pea*) (۹)، تربچه (۱۰)، آفتابگردان (۱۴)، گلایول (۴۳)، لوبيا سبز (۴۶) مدل غیرخطی potency به عنوان یک مدل دقیق و مناسب برای تخمین سطح برگ بر اساس یکی از دو پارامتر عرض و طول برگ بیان شد که با نتایج آزمایش حاضر مطابقت داشت. مطالعات قبلی انجام شده نشان می‌دهند که مدل‌های غیرخطی نسبت به مدل خطی با دقت بالاتری توانستند خروجی مدل را تخمین بزنند (۲۰، ۲۷ و ۲۸).

تخمین سطح برگ با استفاده از مدل‌های رگرسیونی
نتایج موجود در جدول ۲ نشان می‌دهد که ارتباط بین طول و عرض برگ با سطح برگ در تمامی سطوح تنش شوری و در برداشت‌های اول و دوم با استفاده از بهترین معادلات رگرسیون خطی، غیرخطی، خطی - لگاریتمی، OLS، PCR و PLS به دست آمده است. بهمنظور درک بهترین مدل برای تخمین سطح برگ از پارامترهای آمارهای استفاده می‌شود. به این صورت که، بهترین مدل دارای بالاترین میزان R^2 ، AIC، VAF و $MAPE$ و کمترین میزان RPD باشد. از بین مدل‌های رگرسیونی در هر دو برداشت و در تمامی سطوح تنش، مدل NLR به عنوان بهترین و دقیق‌ترین مدل معرفی شده است. کاروالهبو و همکاران (۱۱) بیان کردند که پارامترهای طول و عرض برگ برای تخمین سطح برگ گیاه *Crotalaria juncea* کافی می‌باشند. علاوه‌بر این، آن‌ها با استفاده از مدل‌های خطی و غیرخطی سطح برگ را تخمین زدند که مدل خطی و با استفاده از ورودی‌های طول و عرض برگ به عنوان دقیق‌ترین

جدول ۲- نتایج مربوط به تخمین سطح برگ اکوئیپ‌های مختلف نعناع با استفاده از مدل‌های مختلف رگرسیونی

مدل	سطوح شوری (dS/m)	برداشت دوم	برداشت اول
PLS	.	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	۲/۵	$LA = -7.293 + 3.366 * W + 1.586 * L$	$LA = -6.997 + 3.320 * W + 1.543 * L$
	۵	$LA = -5.615 + 2.931 * W + 1.405 * L$	$LA = -5.349 + 2.883 * W + 1.362 * L$
	۷/۵	$LA = -3.924 + 2.378 * W + 1.221 * L$	$LA = -3.702 + 2.331 * W + 1.176 * L$
PCR	.	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	۲/۵	$LA = -7.293 + 3.366 * W + 1.586 * L$	$LA = -6.997 + 3.320 * W + 1.543 * L$
	۵	$LA = -5.615 + 2.931 * W + 1.405 * L$	$LA = -5.349 + 2.883 * W + 1.362 * L$
	۷/۵	$LA = -3.924 + 2.378 * W + 1.221 * L$	$LA = -3.702 + 2.331 * W + 1.176 * L$
OLS	.	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	۲/۵	$LA = -7.293 + 3.366 * W + 1.586 * L$	$LA = -6.997 + 3.320 * W + 1.543 * L$
	۵	$LA = -5.615 + 2.931 * W + 1.405 * L$	$LA = -5.349 + 2.883 * W + 1.362 * L$
	۷/۵	$LA = -3.924 + 2.378 * W + 1.221 * L$	$LA = -3.702 + 2.331 * W + 1.176 * L$
Linear regression	.	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	۲/۵	$LA = -7.293 + 3.366 * W + 1.586 * L$	$LA = -6.997 + 3.320 * W + 1.543 * L$
	۵	$LA = -5.615 + 2.931 * W + 1.405 * L$	$LA = -5.349 + 2.883 * W + 1.362 * L$
	۷/۵	$LA = -3.924 + 2.378 * W + 1.221 * L$	$LA = -3.702 + 2.331 * W + 1.176 * L$
Log-linear regression	.	$LA = \exp(0.259 + 0.319 * W + 0.223 * L)$	$LA = \exp(0.225 + 0.325 * W + 0.2263 * L)$
	۲/۵	$LA = \exp(0.069 + 0.418 * W + 0.213 * L)$	$LA = \exp(0.002 + 0.429 * W + 0.216 * L)$
	۵	$LA = \exp(-0.146 + 0.460 * W + 0.238 * L)$	$LA = \exp(-0.195 + 0.475 * W + 0.242 * L)$
	۷/۵	$LA = \exp(-0.518 + 0.538 * W + 0.291 * L)$	$LA = \exp(-0.576 + 0.558 * W + 0.296 * L)$
Nonlinear regression	.	$LA = -2.950 + 2.241 * W - 0.692 * L + 0.086 * W^2 + 0.435 * L^2$	$LA = -2.783 + 2.203 * W - 0.718 * L + 0.086 * W^2 + 0.440 * L^2$
	۲/۵	$LA = -2.401 + 1.195 * W + 0.515 * L + 0.463 * W^2 + 0.116 * L^2$	$LA = -2.196 + 1.149 * W + 0.467 * L + 0.475 * W^2 + 0.118 * L^2$
	۵	$LA = -2.273 + 1.011 * W + 0.704 * L + 0.451 * W^2 + 0.086 * L^2$	$LA = -2.159 + 1.028 * W + 0.661 * L + 0.449 * W^2 + 0.088 * L^2$
	۷/۵	$LA = -0.508 + 1.277 * W - 0.317 * L + 0.300 * W^2 + 0.231 * L^2$	$LA = -0.470 + 1.269 * W - 0.320 * L + 0.300 * W^2 + 0.229 * L^2$

عصبی (MLP و RBF)، علاوه بر متغیرهای طول و عرض برگ به متغیرهای دیگری نیز نیاز می‌باشد. علت اینکه مدل ANFIS نتایج بهتر از شبکه عصبی مصنوعی داشته، به این دلیل می‌باشد که ANFIS در واقع نوعی مدل شبکه عصبی بوده است که نواقص آن به وسیله قوانین فازی بطرف شده است. شبانی و همکاران (۴۵) گزارش کردند که شبکه عصبی مصنوعی می‌تواند با دقت بالا و خطای پایین سطح برگ را در گونه‌های مختلف گیاهان تخمین بزند و هر چه تعداد متغیرهای ورودی مرتبط با سطح برگ افزایش یابد تخمین حاصله کمترین خطای را خواهد داشت که با نتایج آزمایش حاضر مطابقت نداشت. کومار و همکاران (۳۰) توضیح دادند که مدل شبکه عصبی مصنوعی (ANN) نسبت به مدل‌های رگرسیونی با دقت بالاتری سطح برگ گیاه خارگیل را برآورد می‌کند. افزایش نتاش شوری موجب کاهش خطای و تقریباً افزایش دقت در مدل‌های موجود شده است. به‌نظر می‌رسد افزایش نتاش شوری، ارتباط ورودی‌ها (طول و عرض برگ) و خروجی مدل (سطح برگ) را تشدیدتر کرده و درجه اهمیت ورودی‌ها را بر خروجی افزایش داده است، در نتیجه مدل با دقت بالاتری می‌تواند بین ورودی‌ها و خروجی ارتباط برقرار کند.

مقایسه مدل‌های رگرسیونی و غیررگرسیونی برای تخمین سطح برگ
شاخص‌های عملکرد مدل‌ها در برداشت‌های اول و دوم در تمامی سطوح نتش در جداول ۳ و ۴ ارائه شده است. با توجه به شاخص‌های موجود (به‌جز AIC و BIC)، مدل ANFIS با دقت بالا پارامتر سطح برگ را در هر دو برداشت و در تمامی سطوح نتش برآورد نمود. مطالعه صورت‌گرفته توسط امیری و شبانی (۳) بیان کردند که مدل ANFIS یک روش دقیق و سریع برای برآورد سطح برگ بوده و همچنین در زمان صرفجویی کرده و معایب موجود در روش‌های دیگر را ندارد که با نتایج آزمایش حاضر مطابقت داشت. حسینی و همکاران (۲۲) گزارش کردند که ANFIS با دقت بالایی توانست خروجی مدل (فسفر خاک) RBF را نسبت به مدل‌های رگرسیون خطی برآورد کند. مدل شاخص سطح برگ را در برداشت اول در تمامی سطوح نتش شوری با دقت پایین و خطای بالا برآورد نمود ولی در برداشت دوم، در سطح بدون نتش مدل MLP و در سایر سطوح نتش شوری مدل RBF، شاخص سطح برگ را با دقت بالایی برآورد نمی‌کند. به‌نظر می‌رسد برای افزایش دقت در تخمین شاخص سطح برگ در گیاه دارویی نفعان با استفاده از مدل‌های شبکه

جدول ۳- شاخص‌های عملکرد (RPD, AIC, BIC, RMSE, VAF, MAPE and R2) مربوط به مدل در برداشت اول

Table 3. Performance indices (RPD, AIC, BIC, RMSE, VAF, MAPE and R2) for models in first harvest

سطوح شوری (dS/m)	شاخص‌های عملکرد	PLS	PCR	OLS	LR	Log R	NL R	NP R	MLP	RBF	ANFIS
۰	R2	.۹۸۶	.۹۸۶	.۹۸۶	.۹۸۶	.۹۷۵	.۹۸۸	.۹۹۰	.۹۸۸	.۹۷۱	.۹۹۱
	VAF	۹۹/۵۴۴	۹۹/۵۴۴	۹۹/۵۲۱	۹۹/۵۴۴	۹۷/۰۲۰	۹۹/۰۳	۹۹/۱۳۵	۹۹/۶۲۹	۹۸/۶۸۳	۹۹/۸۶۶
	MAPE	۳/۲۰۱	۳/۲۰۱	۳/۲۴۶	۳/۲۰۱	۴/۰۱۱	۲/۹۵۷	۲/۷۰۲	۲/۷۴۷	۴/۴۳۱	۲/۵۱۹
	RMSE	.۰/۳۴۴	.۰/۳۴۴	.۰/۲۵۳	.۰/۳۴۴	.۰/۸۳۰	.۰/۲۴۷	.۰/۲۲۵	.۰/۳۰۹	.۰/۶۲۵	.۰/۰۲۰
	RPD	۸/۸۴۹	۸/۸۴۹	۸/۶۱۲	۸/۸۴۹	۳/۸۱۰	۱۲/۴۱۳	۱۳/۶۷۳	۹/۹۰۶	۴/۸۶۷	۱۵/۲۷۱
	AIC	۱۹۸/۲۶۵	۱۹۸/۲۶۵	۱۹۸/۱۹۴	۱۹۸/۲۶۵	۲۰/۰/۷۶۷	۱۹۹/۰۲۶	۲۰۰/۰۴۰	۱۹۹/۰۲۶	۱۹۸/۷۹۷	۲۰۱/۳۵۲
	BIC	۲۰۸/۰۸۲	۲۰۸/۰۸۲	۲۰۸/۰۱۱	۲۰۸/۰۸۲	۲۱۳/۶۹۳	۲۰۹/۰۴۳	۲۱۰/۰۴۸	۲۰۹/۰۱۳	۲۰۶/۶۱۵	۲۱۱/۱۶۹
۲/۵	R2	.۹۸۲	.۹۸۱	.۹۸۲	.۹۸۲	.۹۸۰	.۹۸۵	.۹۸۸	.۹۸۴	.۹۶۶	.۹۸۹
	VAF	۹۹/۶۲۲	۹۹/۴۴۷	۹۹/۶۰۵	۹۹/۶۱۹	۹۹/۷۴۱	۹۹/۸۳۷	۹۹/۹۳۰	۹۹/۷۶۱	۹۹/۰۸۳	۹۹/۹۳۵
	MAPE	۲/۷۲۶	۲/۸۰۵	۲/۷۴۰	۲/۷۵۷	۳/۲۷۲	۲/۷۹۲	۲/۴۴۱	۲/۸۵۰	۳/۹۲۲	۲/۲۶۰
	RMSE	.۰/۱۹۸	.۰/۲۳۵	.۰/۲۰۲	.۰/۲۰۰	.۰/۱۸۲	.۰/۱۴۲	.۰/۱۰۰	.۰/۱۶۴	.۰/۳۲۵	.۰/۰۹۳
	RPD	۹/۹۷۰	۸/۳۵۰	۹/۷۱۴	۹/۸۳۸	۱۱/۰۶۱	۱۳/۹۴۶	۱۹/۹۱۳	۱۱/۹۸۷	۵/۹۹۹	۲۱/۴۴۰
	AIC	۱۲۲/۵۰۹	۱۲۲/۰۲۴	۱۲۲/۴۳۶	۱۲۲/۴۷۷	۱۲۶/۷۹۵	۱۲۳/۸۴۵	۱۲۵/۷۳۶	۱۲۳/۲۶۷	۱۱۹/۸۷۵	۱۲۵/۹۱۸
	BIC	۱۲۲/۳۲۷	۱۳۱/۸۴۱	۱۲۲/۲۵۳	۱۳۲/۲۹۴	۱۲۶/۶۱۲	۱۳۳/۶۶۲	۱۲۵/۵۵۴	۱۳۳/۰۸۴	۱۱۹/۵۹۲	۱۳۵/۷۳۶
۵	R2	.۹۸۰	.۹۸۰	.۹۸۰	.۹۷۹	.۹۸۱	.۹۸۶	.۹۹۱	.۹۷۸	.۹۶۴	.۹۹۳
	VAF	۹۹/۲۶۴	۹۹/۲۶۲	۹۹/۲۶۲	۹۸/۹۶۴	۹۹/۵۳۴	۹۹/۰۳	۹۹/۹۶۸	۹۸/۹۵۳	۹۸/۴۴۱	۹۹/۹۸۳
	MAPE	۳/۴۱۸	۳/۳۱۲	۳/۳۱۲	۳/۳۴۸	۳/۶۴۹	۳/۰۹۵	۲/۷۵۶	۳/۳۰۴	۴/۴۸۵	۲/۵۴۷
	RMSE	.۰/۲۵۶	.۰/۲۵۵	.۰/۲۵۵	.۰/۲۹۸	.۰/۲۱۶	.۰/۱۴۲	.۰/۰۶۸	.۰/۲۹۹	.۰/۳۸۷	.۰/۰۵۲
	RPD	۷/۳۶	۷/۳۳۷	۷/۳۳۷	۶/۲۸۵	۹/۲۶۷	۱۳/۴۴۱	۲۸/۱۶	۶/۱۵۸	۴/۸۹۲	۳۶/۹۹۱
	AIC	۱۱۳/۷۰۱	۱۱۳/۹۸۰	۱۱۳/۹۸۰	۱۱۳/۳۱۹	۱۲۵/۵۲۱	۱۱۷/۲۶۵	۱۱۸/۹۴۶	۱۱۰/۹۳۱	۱۱۴/۵۵۰	۱۲۰/۱۰۵
	BIC	۱۲۳/۵۱۹	۱۲۳/۷۹۷	۱۲۳/۷۹۷	۱۲۳/۱۳۶	۱۲۵/۳۳۸	۱۲۷/۱۸۲	۱۲۸/۷۶۳	۱۲۰/۷۴۸	۱۲۴/۳۶۸	۱۲۹/۹۷۲

ادامه جدول ۳- شاخص‌های عملکرد (RPD, AIC, BIC, RMSE, VAF, MAPE and R2) مربوط به مدل در برداشت اول
Continue of Table 3. Performance indices (RPD, AIC, BIC, RMSE, VAF, MAPE and R2) for models in first harvest

7.5	R2	.۹/۷۷	.۹/۷۷	.۹/۷۵	.۹/۷۷	.۹/۶۷	.۹/۹۰	.۹/۹۵	.۹/۹۴	.۹/۶۱	.۹/۹۶
	VAF	۹۹/۵۹۹	۹۹/۵۹۹	۹۹/۵۰۱	۹۹/۵۹۹	۹۵/۷۲۴	۹۹/۹۳۵	۹۹/۹۹۰	۹۹/۹۸۶	۹۸/۰۲۴	۹۹/۹۹۵
	MAPE	۴/۹۲۳	۴/۹۲۳	۵/۰۲۱	۴/۹۲۳	۵/۱۲۰	۳/۳۵۸	۲/۷۱۱	۲/۶۵۰	۵/۰۹۵	۲/۰۲۳
	RMSE	.۱/۱۷۱	.۱/۱۷۱	.۱/۱۸۱	.۱/۱۷۱	.۰/۰۱۰	.۰/۰۷۰	.۰/۰۳۰	.۰/۰۳۶	.۰/۳۶۷	.۰/۰۲۴
	RPD	۹/۳۰۷	۹/۳۰۷	۸/۷۹۳	۹/۳۰۷	۲/۰۱	۲۳/۴۴۳	۵۴/۷۱۷	۴۶/۳۶۱	۴/۶۰۰	۶۸/۰۰۹
	AIC	۸۶/۲۶۱	۸۶/۲۶۱	۸۵/۷۰۷	۸۶/۲۶۱	۱۰۴/۷۳۴	۹۲/۷۰۱	۹۴/۱۸۸	۹۳/۵۷۸	۹۴/۷۲۴	۹۲/۸۳۴
	BIC	۹۶/۰۷۹	۹۶/۰۷۹	۹۵/۵۲۴	۹۶/۰۷۹	۱۱۴/۵۵۴	۱۰۲/۵۱۸	۱۰۴/۰۰۵	۱۰۳/۳۹۶	۱۰۴/۵۴۱	۱۰۲/۶۵۱

جدول ۴- شاخص‌های عملکرد (RPD, AIC, BIC, RMSE, VAF, MAPE and R2) مربوط به مدل در برداشت دوم
Table 4. Performance indices (RPD, AIC, BIC, RMSE, VAF, MAPE and R2) for models in second harvest

سطوح شوری (dS/m)	شاخص‌های عملکرد	PCR	PLS	OLS	LR	Log R	NL R	NP R	MLP	RBF	ANFIS
0	R2	.۹/۸۶	.۹/۸۶	.۹/۸۶	.۹/۸۶	.۹/۷۵	.۹/۸۸	.۹/۸۹	.۹/۳۳	.۹/۶۵	.۹/۹۰
	VAF	۹۹/۵۱۱	۹۹/۴۹۲	۹۹/۵۱۱	۹۹/۵۰۹	۹۷/۱۹۹	۹۹/۷۸۸	۹۹/۸۱۷	۸۶/۳۰۶	۹۸/۰۰۹	۹۹/۸۵۲
	MAPE	۳/۱۶۱	۳/۱۹۴	۳/۱۶۱	۳/۱۸۲	۳/۹۶۹	۲/۹۳۳	۲/۶۹۶	۴/۹۷۴	۴/۶۷۶	۲/۰۷۷
	RMSE	.۰/۳۶۳	.۰/۳۷۰	.۰/۳۶۳	.۰/۳۶۴	.۰/۸۲۷	.۰/۲۶۱	.۰/۲۴۱	۱/۷۸۲	.۰/۷۹۱	.۰/۰۲۰
	RPD	۸/۰۹۱	۸/۴۱۵	۸/۰۹۱	۸/۰۵۸	۳/۸۹	۱۱/۹۶	۱۲/۰۲۶	۱/۵۰۷	۲/۴۹۹	۱۴/۱۲۰
	AIC	۲۰۰/۲۱۶	۲۰۰/۱۹۶	۲۰۰/۲۱۶	۲۰۰/۲۲۳	۲۰۰/۲۲۲	۲۰۰/۵۷۱	۲۰۰/۱۱۴	۱۷۱/۹۵۶	۲۰۰/۹۱۵	۲۰۰/۷۹۸
	BIC	۲۱۲/۰۳۳	۲۱۲/۰۱۳	۲۱۲/۰۳۳	۲۱۲/۰۵۱	۲۱۷/۰۴۰	۲۱۲/۳۸	۲۱۳/۹۲۲	۱۸۱/۷۷۳	۲۱۰/۷۳۳	۲۱۰/۶۱۵
۲/۵	R2	.۹/۸۲	.۹/۸۲	.۹/۸۲	.۹/۸۲	.۹/۸۰	.۹/۸۴	.۹/۸۸	.۹/۸۷	.۹/۶۵	.۹/۸۹
	VAF	۹۹/۶۳۳	۹۹/۶۲۷	۹۹/۶۳۴	۹۹/۶۲۳	۹۹/۷۱۶	۹۹/۸۳۲	۹۹/۹۲۱	۹۹/۹۰۹	۹۸/۶۷۹	۹۹/۹۲۵
	MAPE	۲/۷۰۰	۲/۷۴۳	۲/۷۳۲	۲/۷۰۰	۳/۷۹	۲/۷۷۳	۲/۴۲۱	۲/۶۲۰	۳/۸۹۹	۲/۰۴۶
	RMSE	.۰/۰۲۲	.۰/۰۲۵	.۰/۰۲۲	.۰/۰۲۰	.۰/۱۹۵	.۰/۱۴۹	.۰/۱۰۸	.۰/۱۱۸	.۰/۳۸۸	.۰/۰۱۰
	RPD	۹/۰۸۴	۹/۸۴۶	۹/۹۷۳	۹/۹۸۴	۱۰/۵۴۰	۱۳/۰۶	۱۸/۹۳۱	۱۷/۳۰۷	۵/۲۳۰	۲۰/۱۰۰
	AIC	۱۲۶/۸۵۲	۱۲۶/۸۷۷	۱۲۶/۹۰۷	۱۲۶/۸۵۲	۱۲۰/۰۵۲	۱۲۷/۹۲۷	۱۳۰/۰۰۱	۱۲۹/۲۱۰	۱۲۶/۸۷۲	۱۲۹/۷۱۹
	BIC	۱۳۶/۶۶۹	۱۳۶/۸۰۰	۱۳۶/۷۲۴	۱۳۶/۶۶۹	۱۴۰/۰۳۰	۱۳۷/۷۲۴	۱۳۹/۸۱۸	۱۳۹/۰۲۷	۱۳۶/۶۸۹	۱۳۹/۰۳۶
۵	R2	.۹/۸۰	.۹/۸۰	.۹/۸۰	.۹/۸۰	.۹/۸۱	.۹/۸۶	.۹/۹۱	.۹/۸۵	.۹/۴۹	.۹/۹۳
	VAF	۹۹/۲۷۳	۹۹/۲۷۳	۹۹/۲۶۵	۹۹/۲۷۳	۹۹/۵۲۴	۹۹/۸۰۱	۹۹/۹۵۴	۹۹/۷۲۲	۹۷/۸۶۰	۹۹/۹۸۱
	MAPE	۳/۲۵۰	۳/۲۹۰	۳/۲۱۱	۳/۲۵۰	۳/۰۴۲	۳/۰۵۸	۲/۷۵۱	۳/۱۱۲	۵/۱۶۸	۲/۰۵۵
	RMSE	.۰/۲۶۱	.۰/۲۶۱	.۰/۲۶۳	.۰/۲۶۱	.۰/۲۲۳	.۰/۱۴۷	.۰/۰۷۴	.۰/۱۶۹	.۰/۴۸۴	.۰/۰۵۷
	RPD	۷/۳۷۶	۷/۳۶۵	۷/۳۱۱	۷/۳۷۶	۹/۱۷۰	۱۳/۰۹۵	۲۶/۶۳۱	۱۱/۴۸۴	۲/۸۹۸	۳۴/۷۹۰
	AIC	۱۱۸/۸۶۲	۱۱۹/۰۰۰	۱۱۸/۶۳۶	۱۱۸/۸۶۲	۱۲۹/۷۵۲	۱۲۱/۹۵۷	۱۲۳/۴۷۰	۱۲۱/۱۰۷	۱۱۲/۸۲۷	۱۲۴/۲۳۴
	BIC	۱۲۸/۶۷۹	۱۲۸/۸۱۷	۱۲۸/۴۵۳	۱۲۸/۶۷۹	۱۳۹/۰۷۰	۱۳۱/۷۹۲	۱۳۳/۲۸۸	۱۳۰/۰۷۵	۱۲۲/۶۴۴	۱۳۴/۱۵۲
۷/۵	R2	.۹/۷۸	.۹/۷۷	.۹/۷۴	.۹/۷۷	.۹/۶۸	.۹/۹۱	.۹/۹۵	.۹/۹۴	.۹/۶۶	.۹/۹۶
	VAF	۹۹/۶۲۰	۹۹/۶۱۸	۹۹/۰۲	۹۹/۶۲۲	۹۵/۸۵۸	۹۹/۹۳۸	۹۹/۹۸۹	۹۹/۹۸۱	۹۸/۳۲۹	۹۹/۹۹۴
	MAPE	۴/۷۰۶	۴/۷۳۴	۴/۷۸۰	۴/۸۳۸	۵/۰۱۲	۳/۲۸۷	۲/۶۹۱	۳/۰۳۴	۴/۱۴۱	۲/۰۹۶
	RMSE	.۰/۱۷۳	.۰/۱۷۴	.۰/۲۳۸	.۰/۱۷۴	.۰/۵۱۸	.۰/۰۷۲	.۰/۰۳۴	.۰/۰۴۳	.۰/۳۳۹	.۰/۰۲۶
	RPD	۹/۵۲۷	۹/۴۵۲	۶/۸۸۱	۹/۴۸۷	۳/۰۴۱	۲۳/۶۷۲	۵۰/۹۸۶	۳۹/۴۷۲	۴/۷۹۴	۶۶/۳۰۲
	AIC	۹۲/۱۱۷	۹۱/۸۷۴	۹۰/۰۷۸	۹۱/۸۳۳	۱۰۹/۰۵۷	۹۸/۲۵۸	۹۹/۷۳۳	۹۹/۰۳۱	۸۸/۴۷۴	۹۸/۸۷۲
	BIC	۱۰۱/۹۳۵	۱۰۱/۵۹۱	۱۰۰/۰۸۵	۱۰۱/۰۵۱	۱۱۹/۰۴۷	۱۰۸/۰۷۶	۱۰۹/۰۵۰	۱۰۸/۰۴۹	۹۸/۲۹۲	۱۰۸/۵۹۰

گونه‌های گیاهی از جمله گیاه دارویی نعناع مورد استفاده قرار گیرد. در این پژوهش، مدل‌های شبکه عصبی مصنوعی (RBF) و (MLP) با دقت کمتری نسبت به سایر روش‌ها شاخص سطح برگ را تخمین زده است. نتایج حاصل از تجزیه کلاستر نشان داد که اکوتیپ E18 در هر دو برداشت و در تمام شرایط تنش شوری و همچنین بدون تنش بیشترین مقدار طول، عرض و سطح برگ را داشته است و نسبت به سطوح مختلف تنش شوری از آستانه تحمل بالاتری برخوردار می‌باشد.

برآورد دقیق و غیرمخرب سطح برگ در محصولات کشاورزی و باگی، به دلیل ارتباط سطح برگ با عملکرد محصول بسیار مهم می‌باشد. امروزه استفاده از تکنیک‌های کامپیوترا و مدل‌های ریاضی در مباحث کشاورزی به سرعت در حال افزایش است. مدل هوش مصنوعی مانند ANFIS نسبت به روش‌های رگرسیون خطی و غیرخطی، شاخص سطح برگ را با دقت بالا و خطای کمتری تخمین زده است. از این‌رو، روش ANFIS می‌تواند به عنوان یک روش جایگزین برای تخمین سطح برگ

منابع

1. Aboukarim, A.M., H.A. Elsoury and M. Menyawi. 2015. Artificial neural network model for the prediction of the cotton crop leaf area. International Journal of Plant and Soil Science, 8(4): 1-13.
2. Ahmadian-Moghadam, H. 2012. Prediction of pepper (*Capsicum annuum L.*) leaf area using group method of data handling-type neural networks. International Journal of Agriculture Science, 2(11): 993-999.
3. Amiri, M.J. and A. Shabani. 2017. Application of an Adaptive Neural-Based Fuzzy Inference System Model for Predicting Leaf Area. Communications in Soil Science and Plant Analysis, 48(14): 1669-1683.
4. Amiri, M.J., J. Abedi-Koupai, S.S. Eslamian, S.F. Mousavi and H. Hasheminejad. 2013. Modeling Pb (II) adsorption from aqueous solution by ostrich bone ash using adaptive neural-based fuzzy inference system. Journal of Environmental Science and Health, Part A 48: 543-558.
5. Aschonitis, V.G., D.M. Papamichail, A. Lithourgidis and E.A. Fano. 2014. Estimation of leaf area index and foliage area index of rice using an indirect gravimetric method. Communications in Soil Science and Plant Analysis, 45: 1726-1740.
6. Basbag, S., R. Ekinci and G. Oktay. 2008. Relationships between some physio-morphological traits and cotton (*Gossypium hirsutum L.*) yield. International Cotton Advisory Committee. Tenth Regional Meeting.
7. 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(4): 305-309.
8. Caldas, L.S., C. Bravo, H. Piccolo and C.R. Faria. 1992. Measurement of leaf area with a hand-scanner linked to a microcomputer. Revista Brasileira de Fisiologia Vegetal, 4: 17-20.
9. Cargnelutti Filho, A., M. Toebe, B. Mendonca Alves, C. Burin and J.A. Kleinpaul. 2015. Estimation of leaf area of canola by leaf size. Bragantia, 74(2): 139-148.
10. Cargnelutti Filho, A., M. Toebe, C. Burin, A.L. Fick and G. Casarotto. 2012. Estimate of leaf area of forage turnip according to leaf dimensions. Bragantia, 71(1): 47-51.
11. Carvalho, J.O., M. Toebe, F.L. Tartaglia, C.T. Bandeira and A.L. Tambara. 2017. Leaf area estimation from linear measurements in different ages of *Crotalaria juncea* plants. Anais da Academia Brasileira de Ciências, 89(3): 1851-1868.
12. Cristofori, V., Y. Rousphael, E. Mendoza-de Gyves and C. Bignami. 2007. A simple model for estimating leaf area of hazelnut from linear measurements. Scientia Horticulture, 113(2): 221-225.
13. Daughtry, C.S.T. 1990. Direct measurements of canopy structure. International Journal of Remote Sensing Reviews, 5: 45-60.
14. De Aquino, L.A., V.C. dos Santos Júnior, J.V. Santos Guerra and M. Moreira Costa. 2011. Estimates of sunflower leaf area by a non-destructive method. Bragantia, 70(4): 832-836.
15. Ghanbari, S., A. Nooshkam, B.A. Fakheri and N. Mahdinezhad. 2019. Relationship between Yield and its Component in Soybean Genotypes (*Glycine Max L.*) using Multivariate Statistical Methods. Journal of Crop Breeding, 11(29): 85-92 (In Persian).
16. Ghorbani, H., H. Kashi, N. Hafezi Moghadas and S. Emamgholizadeh. 2015. Estimation of soil cation exchange capacity using multiple regression, artificial neural networks, and adaptive neuro-fuzzy inference system models in Golestan province, Iran. Communications in Soil Science and Plant Analysis, 46: 763-780.
17. Granier, C., C. Massonnet, O. Turc, B. Muller, K. Chenu and F. Tardieu. 2002. Individual leaf development in *Arabidopsis thaliana*: a stable thermal-time-based programme. Annals of Botany, 89(5): 595-604.

18. Gupta, D.K., R. Prasad, P. Kumar, V. N. Mishra, P.K.S. Dikshit, S.B. Dwivedi and P.K. Srivastava. 2015. Crop variables estimation by adaptive neuro-fuzzy inference system using bistatic scatterometer data. In *Microwave and Photonics (ICMAP)*, 2015 International Conference on 1-2 pp.
19. Hinnah, F., A. Heldwein, I. Maldaner, L. Loose, D.D. Lucas and M. Bortoluzzi. 2014. Estimation of eggplant leaf area from leaf dimensions. *Bragantia*, 73(3): 213-218.
20. Hosseini, M., S.A.M. Naeini, A.A. Dehghani and Y. Khaledian. 2016. Estimation of soil mechanical resistance parameter by using particle swarm optimization, genetic algorithm and multiple regression methods. *Soil and Tillage Research*, 157: 32-42.
21. Hosseini, M.S., D. Samsampour, M. Ebrahimi and M. Khanahmadi. 2019. Study of Physiological and Biochemical Changes of Iraninan Licorice (*Glycyrrhiza Glabra*) under Salinity Stress in Filed Condition. *Journal of Crop Breeding*, 11(29): 193-201 (In Persian).
22. Hosseini, M., S.R. Agereh, Y. Khaledian, H.J. Zoghalchali, E.C. Brevik and S.A. Naeini. 2017. Comparison of multiple statistical techniques to predict soil phosphorus. *Applied Soil Ecology*, 114: 123-131.
23. Izadi, A., G. Ahmadvand, M. Asna Ashari and K. Piri. 2010. Effect of nitrogen and planting density on some growth characteristics, performance and essential oil in peppermint (*Mentha piperita L.*), *Iranian Journal of Crop Research*, 8(5): 824-836 (In Persian).
24. Kandiannan, K., U. Parthasarathy, K.S. Krishnamurthy, C.K. Thankamani and V. Srinivasan. 2009. Modeling individual leaf area of ginger (*Zingiber officinale Roscoe*) using leaf length and width. *Scientia Horticulturae*, 120(4): 532-537.
25. Kazem Alvandi R., A. Sharifan, M. Aghazadeh Meshghi. 2010. Investigation of the chemical composition and antimicrobial effect of essential oil of peppermint (*Mentha piperita L.*). *Scientific Journal of Pathobiology*, 4: 355- 364.
26. Keramatlou, I., M. Sharifani, H. Sabouri, M. Alizadeh and B. Kamkar. 2015. A simple linear model for leaf area estimation in Persian walnut (*Juglans regia L.*). *Scientia Horticulturae*, 184: 36-39.
27. Khaledian, Y., E.C. Brevik, P. Pereira, A. Cerdà, M.A. Fattah and H. Tazikeh. 2017. Modeling soil cation exchange capacity in multiple countries. *Catena*, 158: 194-200.
28. Khaledian, Y., J.N. Quinton, E.C. Brevik, P. Pereira and M. Zeraatpisheh. 2018. Developing global pedotransfer functions to estimate available soil phosphorus. *Science of the Total Environment*, 644: 1110-1116.
29. Khoshnevisan, B., S. Rafiee, M. Omid and H. Mousazadeh. 2014. Development of an intelligent system based on ANFIS for predicting wheat grain yield on the basis of energy inputs. *Information processing in agriculture*, 1(1): 14-22.
30. Kumar, K., S. Kumar, V. Sankar, T. Sakthivel, G. Karunakaran and P.C. Tripathi. 2017. Non-destructive estimation of leaf area of durian (*Durio zibethinus*)—An artificial neural network approach. *Scientia horticulturae*, 219: 319-325.
31. Leroy, C., L. Saint-Andre and D. Auclair. 2007. Practical methods for non-destructive measurement of tree leaf area. *Agroforestry systems*, 71(2): 99-108.
32. Laio, F., G. Di Baldassarre and A. Montanari. 2009. Model selection techniques for the frequency analysis of hydrological extremes. *Water Resources Research*, 45(7): W07416.
33. Lizaso, J.I., W.D. Batchelor and M.E. Westgate. 2003. A leaf area model to simulate cultivar-specific expansion and senescence of maize leaves. *Field Crops Research*, 80: 1-17.
34. Mahmoudi, A. and M. Danesh. 2019. Assessment of Salinity Effects on Some Morphological and Physiological Traits and In Vitro Culture of Halophyte Plant (*Salicornia Europaea*). *Journal of Crop Breeding*, 11(29):161-168 (In Persian).
35. Marashi, M., A.M. Torkashvand, A. Ahmadi and M. Esfandyari. 2019. Adaptive neuro-fuzzy inference system: Estimation of soil aggregates stability. *Acta Ecologica Sinica*, 39(1): 95-101.
36. Mousavi, S.F. and M.J. Amiri. 2012. Modeling nitrate concentration of groundwater using adaptive neural-based fuzzy inference system. *Soil Water Research*, 7(2): 73-83.
37. Naderloo, L., R. Alimardani, M. Omid, F. Sarmadian, P. Javadikia, M.Y. Torabi and F. Alimardani. 2012. Application of ANFIS to predict crop yield based on different energy inputs. *Measurement*, 45(6): 1406-1413.
38. Nyakwende, E., C.J. Paull and J.G. Atherton. 1997. Non-destructive determination of leaf area in tomato plants using image processing. *Journal of Horticulture Science*, 72(2): 225-262.
39. Odabas, M.S., 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(4): 766-769.
40. Olsoy, P.J., J.J. Mitchell, D.F. Levia, P.E. Clark and N.F. Glenn. 2016. Estimation of big sagebrush leaf area index with terrestrial laser scanning. *Ecological indicators*, 61: 815-821.

41. Rodríguez Padrón, R.A., S.J. Lopes, A. Swarowsky, R.R. Cerquera, C.U. Nogueira and M. Maffei. 2016. Nondestructive models to estimate leaf area on bell pepper crop. Ciência Rural, 46(11): 1938-1944.
42. Ross, J., V. Ross and A. Koppel. 2000. Estimation of leaf area and its vertical distribution during growth period. Agricultural and Forest Meteorology, 101: 237-246.
43. Schwab, N.T., N.A. Streck, A. Rehbein, B.S. Ribeiro, L.O. Ulmann, J.A. Langner and C.C. Becker. 2014. Linear dimensions of leaves and its use for estimating the vertical profile of leaf area in gladiolus. Bragantia, 73(2): 97-105.
44. Shabani, A., A.R. Sepaskhah and A.A. Kamgar-Haghghi. 2013. Growth and physiologic response of rapeseed (*Brassica napus* L.) to deficit irrigation, water salinity and planting method. International Journal of Plant Production, 7(3): 569-96.
45. Shabani, A., K.A. Ghaffary, A.R. Sepaskhah and A.A. Kamgar-Haghghi. 2017. Using the artificial neural network to estimate leaf area. Scientia Horticulturae, 216: 103-110.
46. Taherian, M., M.R. Bihamta, S.A. Peyghambari, H. Alizadeh and A. Rasoulnia. 2019. Stability Analysis and Selection of Salinity Tolerant barley Genotypes. Journal of Crop Breeding, 11(29): 93-103 (In Persian).
47. Toebe, M., A. Cargnelutti Filho, L.H. Loose, A.B. Heldwein and A.J. Zanon. 2012. Leaf area of snap bean (*Phaseolus vulgaris* L.) according to leaf dimensions. Semina: Ciências Agrárias, 33(1): 2491-2500.
48. Vazquez-Cruz, M.A., R. Luna-Rubio, L.M. Contreras-Medina, I. Torres-Pacheco and R.G. 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(4): 319-327.
49. Yilmaz, I. and O. Kaynar. 2011. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. Expert Systems with Applications, 38: 5958-5966.

Study of Diversity and Estimation of Leaf Area in Different Mint Ecotypes Using Artificial Intelligence and Regression Models under Salinity Stress Conditions

**Seyed Jaber Hosseini¹, Zeinolabedin Tahmasebi-Sarvestani², Hematolahe Pirdashti³,
Seyed Ali Mohammad Modarres Sanavi⁴, Ali Mokhtassi-Bidgoli⁵ and Saeid Hazrati⁶**

1- PhD. Student, Department of Agriculture, Tarbiat Modares University, Tehran, Iran

2- Associate Professor, Department of Agriculture, Tarbiat Modares University, Tehran, Iran

(Corresponding author: tahmaseb@modares.ac.ir)

3- Professor, Sari Agricultural Sciences and Natural Resources University

4 and 5- Professor and Assistant Professor, Department of Agriculture, Tarbiat Modares University

6- Assistant Professor, Department of Agronomy and Plant Breeding, Faculty of Agriculture, Azarbaijan Shahid Madani University, Tabriz-Iran

Received: April 22, 2019

Accepted: October 31, 2019

Abstract

Leaf area is a key indicator for the growth and production of plant products and also determines the efficiency of light consumption. Therefore, the study of diversity and also the estimation of leaf area in different mint ecotypes is particular importance. One of the common methods for estimating leaf area is regression analysis, the leaf area as independent variable, and leaf length and width as dependent variable. In this study, leaf area of 18 mint ecotypes with different models of ANFIS, artificial neural network (MLP and RBF), linear and nonlinear regressions using two inputs of leaf length and width in four levels of salinity stress (control, 2.5, 5 and 7.5 dS/m) were estimated in two levels of harvesting. The results showed that there is a high correlation between length and width with leaf area, so that the width correlation with leaf area was greater than leaf length. Among the regression models in both harvest levels and at all levels of salinity stress, the NLR model is presented as the best and most accurate model. ANFIS model was harvested in both stages and at all levels of stress was more accurate than other models and less error rate was obtained. Also, the results of cluster analysis showed that there is a good variation between ecotypes. In addition, the mean comparison between different cluster analysis groups showed that the highest amount of length, width and leaf area was taken in both stages and at all levels of salinity stress was related to E18.

Keywords: Ecotypes, Leaf Area, Mint, Regression Models, Salinity Stress