



بررسی تنوع و تخمین سطح برگ در اکوتیپ‌های مختلف گیاه دارویی نعناع با استفاده از مدل‌های هوش مصنوعی و رگرسیونی تحت شرایط تنش 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 دانشکده کشاورزی دانشگاه تربیت مدرس

۲- دانشیار، گروه زراعت دانشکده کشاورزی دانشگاه تربیت مدرس (نویسنده مسؤل: tahmaseb@modares.ac.ir)

۳- استاد، دانشگاه علوم کشاورزی و منابع طبیعی ساری

۴ و ۵- استاد و استادیار، گروه زراعت دانشکده کشاورزی دانشگاه تربیت مدرس

۶- استادیار گروه زراعت و اصلاح نباتات، دانشکده کشاورزی، دانشگاه شهید مدنی آذربایجان، تبریز

تاریخ دریافت: ۹۸/۲/۲ تاریخ پذیرش: ۹۸/۸/۹

صفحه: ۵۹ تا ۷۳

چکیده

سطح برگ یک شاخص کلیدی برای رشد و تولید محصولات گیاهی و همچنین عاملی تعیین کننده در کارایی مصرف نور محسوب می‌گردد، لذا بررسی تنوع و همچنین تخمین سطح برگ در اکوتیپ‌های مختلف نعناع از اهمیت خاصی برخوردار است. از جمله روش‌های معمول برای تخمین سطح برگ تجزیه و تحلیل رگرسیونی می‌باشد که سطح برگ به‌عنوان متغیر مستقل، و طول و عرض برگ به‌عنوان متغیر وابسته می‌باشند. در این مطالعه سطح برگ ۱۸ اکوتیپ 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 تنش شوری (شاهد، ۲/۵، 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، به‌طوری که همبستگی عرض با سطح برگ بیشتر از طول برگ بود. از بین مدل‌های رگرسیونی در هر دو برداشت و در تمامی سطوح تنش، مدل NLR به‌عنوان بهترین و دقیق‌ترین مدل معرفی شده است. مدل ANFIS در هر دو مرحله برداشت و در تمامی سطوح تنش نسبت به سایر مدل‌ها از دقت بالاتری برخوردار بود و میزان خطای کمتری را به‌خود اختصاص داد. همچنین نتایج حاصل از تجزیه کلاستر نشان داد که تنوع مطلوبی بین اکوتیپ‌ها وجود دارد. علاوه بر این مقایسه میانگین بین گروه‌های مختلف حاصل از تجزیه کلاستر نشان داد که بیشترین مقدار طول، عرض و سطح برگ در هر دو مرحله برداشت و در تمام سطوح تنش شوری مربوط به اکوتیپ ۱۸ (E18) بوده است.

واژه‌های کلیدی: اکوتیپ، تنش شوری، سطح برگ، نعناع، مدل‌های رگرسیونی

مقدمه

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 به‌شمار می‌رود (۳۲). تعیین سطح برگ به‌وسیله روش‌های مستقیم و غیرمستقیم مختلفی امکان‌پذیر است (۲۴). روش‌های مستقیمی که برای اندازه‌گیری سطح برگ به‌کار 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 معایبی نیز می‌باشند. به‌عنوان 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). علاوه بر این روش‌هایی مثل کپی‌برداری، چاپ‌کردن اوزالیدی، عکس‌برداری با استفاده از یک پلانی‌متر متداول که اندازه‌گیری را تسهیل می‌کند، به‌مقدار 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 به‌صورت سریع و غیرتخریبی با استفاده از یک پلانی‌متر اسکن‌کننده دستی نیز قابل اندازه‌گیری است (۱۳). اما

نعناع یکی از پرمصرف‌ترین گیاهان دارویی است که مقدار مصرف سالانه اسانس آن در جهان بسیار زیاد می‌باشد. این گیاه به‌عنوان یک منبع غنی از روغن‌های اساسی که مصارف غذایی عمده‌ای داشته و از نظر مصارف دارویی نیز به‌عنوان ضدنفخ، ضدباکتری و کمک‌کننده هضم غذا مورد مصرف می‌باشد (۲۵). کارایی بیشتر این گیاه به اسانس 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 اسانس اثرگذار باشد مورد توجه قرار می‌گیرد (۲۳). از سوی دیگر تنش شوری از مهم‌ترین تنش‌های غیرزیستی می‌باشد که رشد گیاهان را محدود کرده و صفات موفولوژیک، فیزیولوژیک و بیوشیمیایی گیاهان را تحت تاثیر قرار می‌دهد (۱۵، ۲۱، ۳۴ و ۴۶). برگ مهم‌ترین اندام فتوسنتزی 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). علاوه بر این سطح برگ یک متغیر کلیدی برای مطالعات فیزیولوژیکی شامل رشد گیاه، جذب نور، کارایی فتوسنتزی، تبخیر و تعرق و همچنین پاسخ گیاه به کودها و

رگرسیون غیرخطی (NL R)، رگرسیون لگاریتمی (Log)، رگرسیون حداقل مربعات جزئی (PLS)، رگرسیون حداقل مربعات معمولی (OLS) و رگرسیون مولفه‌های اصلی (PCR) برای پیش‌بینی میزان پارامتر خروجی در مطالعات متعدد استفاده نمودند (۲۲).

هدف از این مطالعه تخمین سطح برگ گیاه دارویی نعنای 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 اکوتیپ‌های 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 نعنای در گلدان‌های پلاستیکی به صورت آزمایش فاکتوریل اسپلیت پلات در زمان و در قالب طرح بلوک‌های کامل تصادفی با چهار تکرار در محل گلخانه تحقیقاتی (دمای ۲۸ درجه سانتی‌گراد، دوره روشنایی و تاریکی به ترتیب ۱۶ و ۸ ساعت و رطوبت نسبی ۶۰ درصد) صورت گرفت. تیمارهای مورد مطالعه در این آزمایش شامل تیمار شوری در چهار سطح (صفر، ۲/۵، ۵ و ۷/۵ دسی‌زیمنس بر متر) و اکوتیپ‌های مختلف نعنای 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٪) به میزان مساوی پر شد. آزمایش به صورت هیدروپونیک انجام شد، به همین منظور از محلول غذایی هوگلند برای تغذیه گیاهان مورد کشت استفاده شد. نحوه اعمال تنش شوری از روز پانزدهم پس از کاشت اعمال شد. اعمال تیمار شوری جهت جلوگیری از وارد آمدن شوک به گیاه در سطوح ۵ و ۷/۵ دسی‌زیمنس بر متر به طور تدریجی صورت گرفت، به طوری 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. علاوه بر این از نرم‌افزار XLSTAT برای انجام تجزیه کلاستر استفاده شد. همچنین نرم‌افزار متلب برای بررسی مدل‌های مختلف مورد استفاده قرار گرفت. برای تعیین صحت و اعتبار مدل‌ها از آماره‌های 2R ، VAF، MAPE، RMSE، RPD، BIC و AIC استفاده شد که این آماره‌ها توسط روابط زیر قابل محاسبه است (۲۲، ۲۳).

این روش نیز برای گیاهان با تعداد برگ‌های کم مناسب است (۳۸). در نقطه مقابل روش‌های مستقیم، روش‌های غیرمستقیم سریع، معتبر، ارزان، ساده و غیرتخریبی برای تخمین سطح برگ بوده که برای انجام آزمایش ضروری به نظر 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 بایستی ارتباط خطی بین متغیرهای وابسته با متغیر مستقل وجود داشته باشد (۱). به دلیل وجود روابط غیرخطی بین طول و عرض با سطح برگ استفاده از رگرسیون‌های خطی سخت و مشکل می‌باشد و تخمین حاصله با خطا همراه می‌باشد، به همین دلیل از روش‌های دیگری نظیر روش پلی‌نومیل (۴۱) و روش گراویمتریک (۵) نیز استفاده شده است. پژوهشگران دیگری از شبکه عصبی مصنوعی برای تخمین سطح برگ گیاهان مختلف نظیر ذرت (۳۹)، فلفل (۲) و گوجه (۴۷) استفاده کردند. شبکه عصبی مصنوعی (ANN) از عناصر عملیاتی ساده‌ای تشکیل می‌شوند که به صورت موازی در کنار هم عمل می‌کنند و از سیستم‌های عصبی زیستی الهام می‌گیرند. همچنین قابل‌ذکر 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 پرسپترون چند لایه (MLP) و مدل توابع پایه‌ای شعاعی (RBF) جهت پیش‌بینی اشاره کرد (۲۲). بررسی‌های صورت‌گرفته نشان می‌دهد که تاکنون مطالعه‌ای در زمینه استفاده از مدل‌های شبکه عصبی مصنوعی برای تخمین سطح برگ نعنایان صورت نگرفته است. سیستم استنتاج عصبی-فازی انطباقی (ANFIS) یک چارچوب محاسباتی رایج 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 نعنایان انجام نشده است، ولی در سال‌های اخیر استفاده از ANFIS در زمینه‌های مختلف کشاورزی در حال افزایش است که شامل برآورد تغییرات تولید عملکرد (۱۸)، پیش‌بینی پتانسیل تورمی خاک‌های رسی (۴۸)، پیش‌بینی نیتريت 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)،

1- Artificial neural network	2- Multilayer perceptron	3- Radial basis function
4- Adaptive neuro fuzzy inference system	5- Nonparametric regression	6- Nonlinear regression
7- Logarithmic regression	8- Partial least squares regression	9- Ordinary least squares regression
10- Principal component regression	11- Coefficient of determination	12- Variance account factor
13- Mean absolute percentage error	14- Root mean square error	15- Relative percent difference
16- Bayesian information criteria		
17- Akaike information criterion		

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. به نظر 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 فتوسنتز می‌شود. هینا و همکاران (۱۹) گزارش کردند که همبستگی بالایی بین طول و عرض برگ‌های گیاه بادمجان با سطح برگ وجود داشته است.

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

$$\text{(Equation 2)} \quad \text{RMSE} = \sqrt{\frac{\sum [P(si) - M(si)]^2}{n}}$$

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

$$\text{(Equation 4)} \quad \text{MAPE} = \frac{\sum_i \left| \frac{Ai - Pi}{Ai} \right|}{N} \times 100$$

$$\text{(Equation 5)} \quad \text{BIC} = (n) \log (\text{SSE}/n) + (K) \log (n)$$

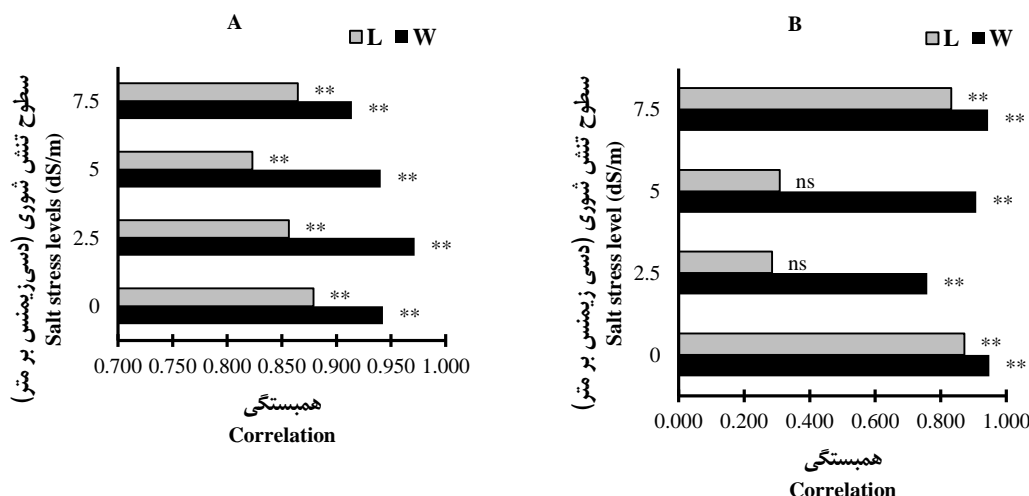
$$\text{(Equation 6)} \quad \text{AIC} = (n) \log (\text{SSE}/n) + 2p$$

$$\text{(Equation 6)} \quad \text{RPD} = \frac{SD}{RMSEP}$$

نتایج و بحث

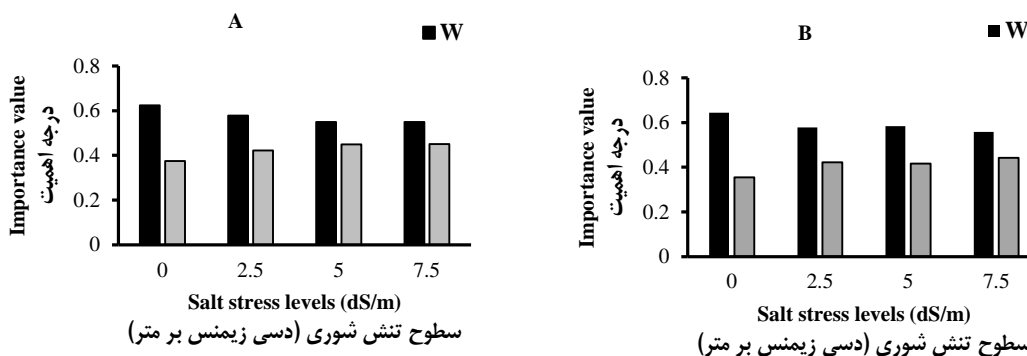
آنالیز حساسیت و تجزیه همبستگی مربوط به صفات سطح با طول و عرض برگ

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. علاوه بر 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 ۲/۵ 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 اکوتیپ‌های مورد مطالعه در برداشت اول و سطوح شوری شاهد، ۲/۵، ۵ و ۷/۵ دسی‌زیمنس بر متر به‌ترتیب در ۳، ۴، ۴ و ۴ گروه و در برداشت دوم در ۳، ۵، ۴ 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 اکوتیپ‌های مختلف مورد مطالعه بر اساس صفات طول برگ، عرض برگ و سطح برگ می‌باشد. در این آزمایش ۱۸ اکوتیپ گیاه دارویی نعنای با استفاده

جدول ۱- آماره‌های توصیفی مربوط به صفات مختلف مورد مطالعه در ۱۸ اکوتیپ نعنای
Table 1. Descriptive statistics related to different traits studied in 18 mint ecotypes

تنش 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	۲/۲۳۶	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
	سطح برگ	۴/۳۳۳	۱۰/۷۲۰	۷/۵۴۴	۱/۸۳۹	۴/۳۲۰	۱۴/۷۴۸	۸/۰۷۶	۲/۲۳۴
۵	عرض برگ	۱/۴۲۵	۲/۷۷۵	۱/۹۶۹	۰/۳۹۷	۱/۴۸۵	۴/۵۰۵	۲/۴۵۰	۰/۸۶۱
	طول برگ	۳/۲۴۸	۴/۹۵۸	۴/۰۰۸	۰/۴۸۸	۳/۰۱۵	۴/۶۴۰	۳/۹۵۹	۰/۵۳۶
	سطح برگ	۳/۲۷۵	۹/۶۰۰	۵/۷۷۰	۱/۶۴۵	۳/۵۱۰	۱۴/۷۴۸	۶/۹۳۹	۲/۶۰۳
۷/۵	عرض برگ	۱/۰۱۰	۲/۴۲۵	۱/۵۹۸	۰/۳۸۹	۱/۰۷۰	۲/۹۲۶	۱/۶۸۲	۰/۴۵۳
	طول برگ	۲/۴۴۳	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

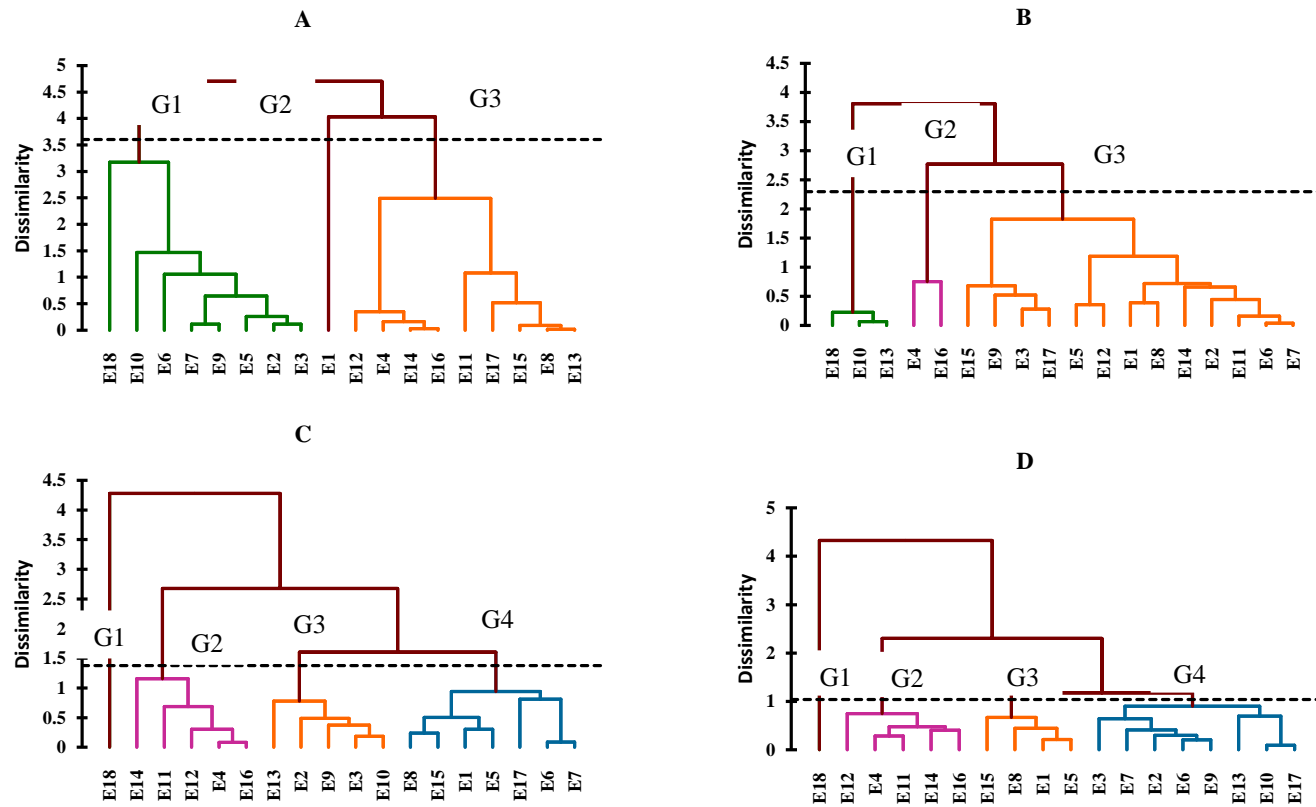
E13 قرار گرفتند. از سویی دیگر نتایج حاصل از تجزیه کلاستر نشان داد که تنش شوری موجب تغییر در چیدمان دندروگرام گردید، به‌طوری که در تنش شوری سطح ۲/۵ دسی‌زیمنس بر متر، اکوتیپ‌ها در سه گروه متمایز به ترتیب G1

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

E13,) G4, (E15, E8, E1, E5) G3, (E14, E16, E4, E11 E10, E17, E6, E7, E9, E2, E3 صورت گرفته است (شکل ۳).

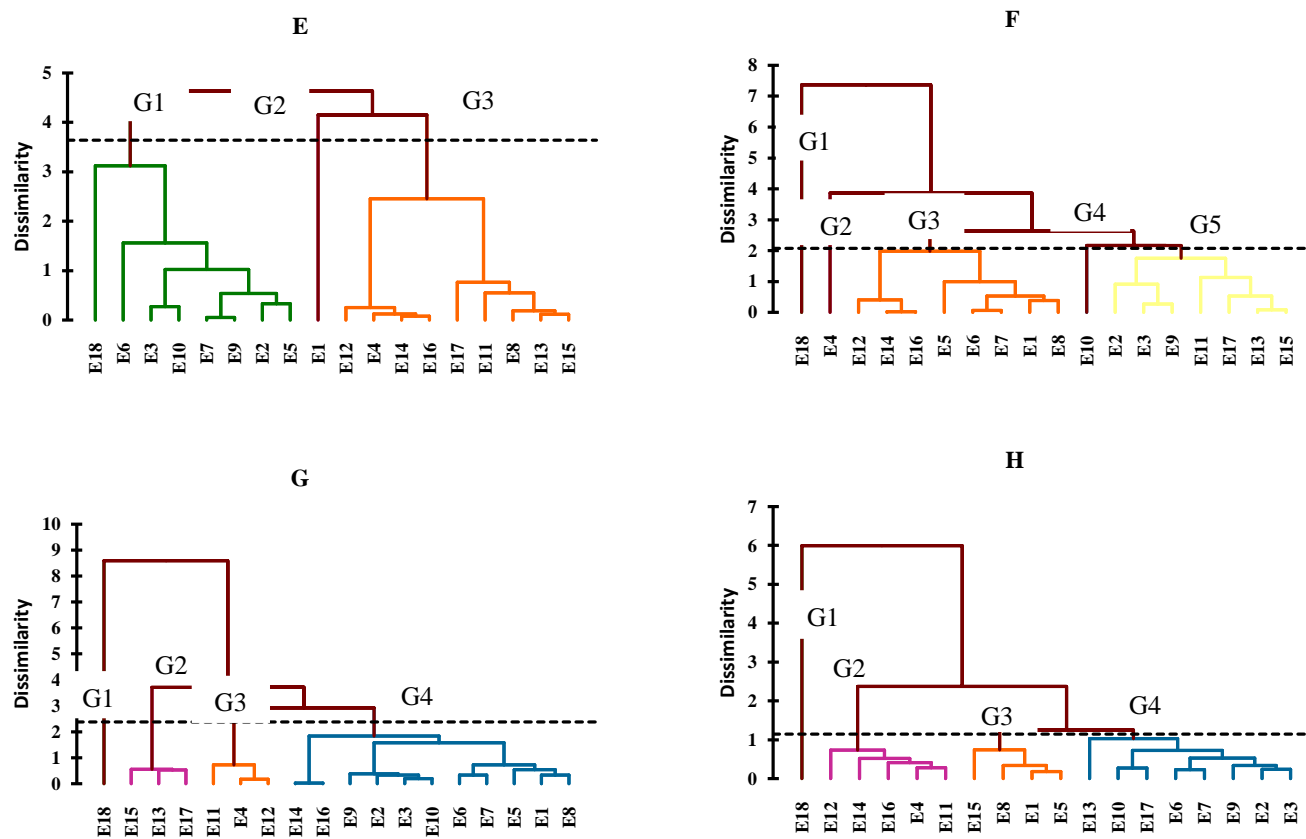
نتایج مقایسه میانگین بین گروه‌های حاصل از تجزیه کلاستر نشان می‌دهد که بیشترین مقدار طول، عرض و سطح برگ مربوط به گروه G1 می‌باشد (شکل ۴). همچنین نتایج مقایسه میانگین بین گروه‌های حاصل از تجزیه کلاستر نشان می‌دهد که اکوتیپ E18 در هر دو برداشت و در تمام شرایط تنش شوری و عدم تنش شوری در گروه G1 قرار گرفت (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 به‌نظر می‌رسد که اکوتیپ‌های E6 و E7 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 به‌ترتیب G1 (E18), G2 (E14, E11, E12, E4, E16), G3 (E13, E2, E9, E3, E10) و G4 (E8, E15, E1, E5, E17,) در آخرین سطح تنش شوری (۷/۵ دسی‌زیمنس بر متر گروه‌بندی اکوتیپ‌ها به‌ترتیب G1 (E18), G2 (E12, E14, E16, E5, E6, E7, E1,) G3 (E4, E11, E14, E16, E17, E2, E6, E9, E13, E10, E17) بوده است. اما وضعیت اکوتیپ‌ها در گروه‌ها در برداشت دوم نسبت به برداشت اول متفاوت بوده، به‌طوری که در شرایط بدون تنش (شاهد) G1 (E1), G2 (E18, E6, E3, E10, E7, E9, E2, E5), G3 (E12, E4, E14, E16, E17, E11, E8, E13, E15) به‌ترتیب بوده است. علاوه بر این نتایج کلاستر در سطح تنش شوری ۲/۵ دسی‌زیمنس بر متر نشان داد که اکوتیپ‌ها در گروه‌های G1 (E18), G2 (E4), G3 (E12, E14, E16, E5, E6, E7, E1,) G4 (E2, E3, E9, E11, E17, E13, E15), G5 (E10) قرار گرفتند. از طرف دیگر در تنش شوری سطح ۵ دسی‌زیمنس بر متر گروه‌بندی دستخوش تغییر شده است، به‌طوری که اکوتیپ‌های مورد مطالعه در گروه‌های G1 (E18), G2 (E15, E14, E16, E9,) G4 (E11, E4, E12), G3 (E2, E3, E10, E6, E7, E5, E1, E8) قرار گرفتند. دندروگرام حاصل از تجزیه کلاستر نشان داد که در تنش شوری سطح ۷/۵ دسی‌زیمنس بر گروه‌بندی به‌ترتیب G1 (E18), G2 (E12,)

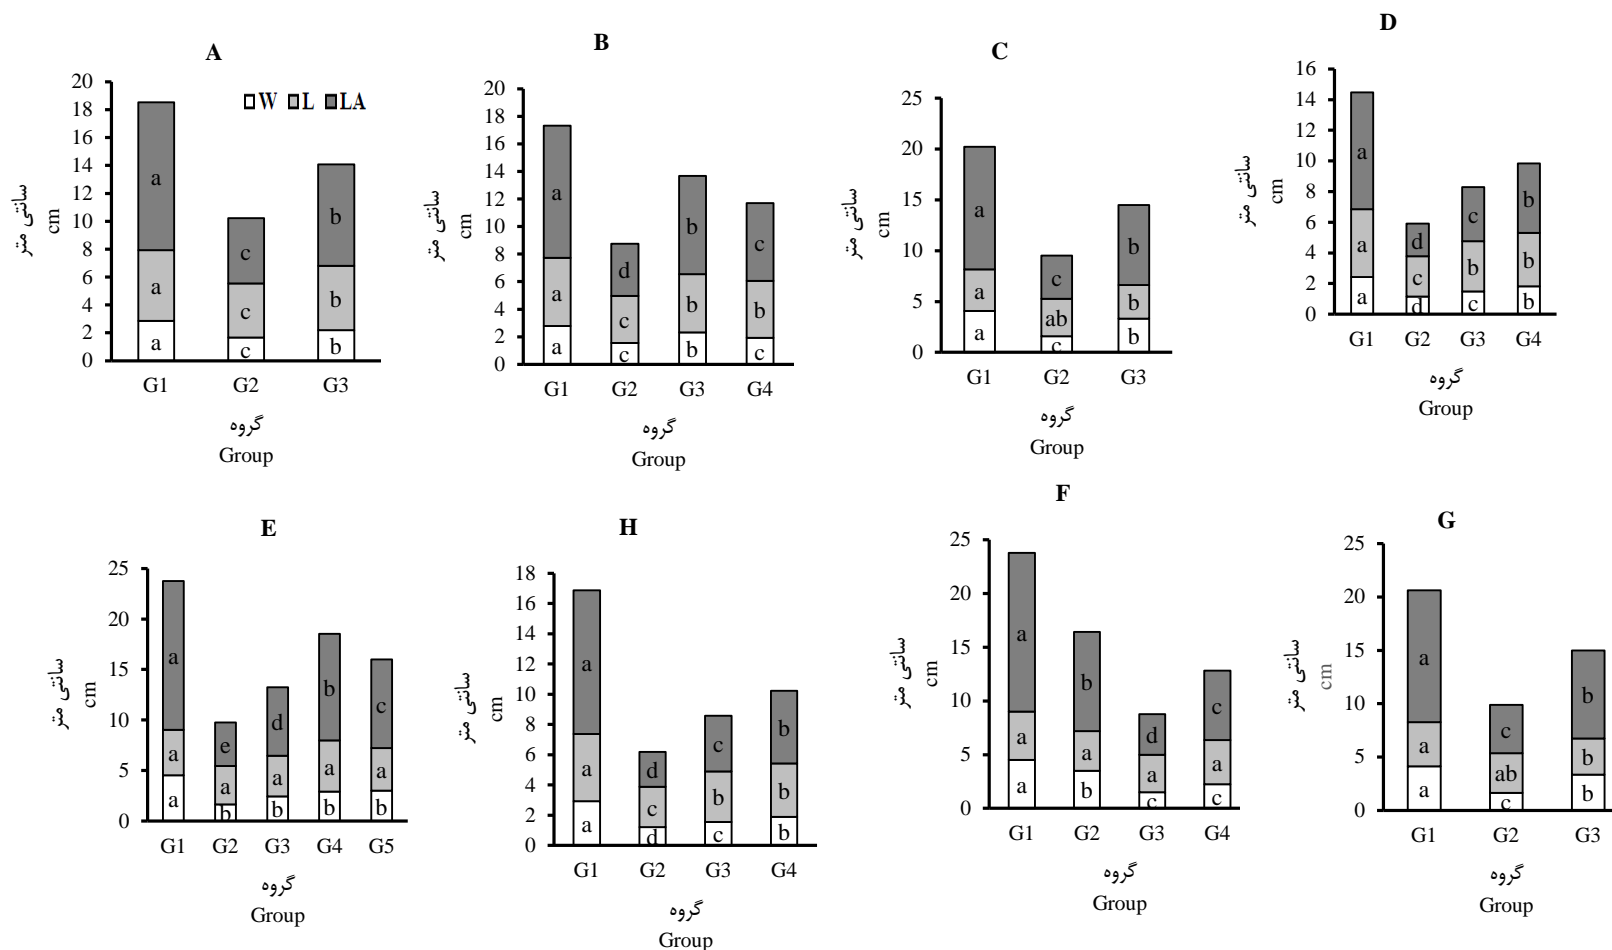


شکل ۳- نتایج مربوط به تجزیه کلاستر در سطوح مختلف تنش شوری در برداشت‌های اول و دوم. A] (شاهد+برداشت اول)، B (۲/۵ دسی‌زیمنس بر متر+برداشت اول)، C (۵ دسی‌زیمنس بر متر+برداشت اول)، D (۷/۵ دسی‌زیمنس بر متر+برداشت اول)

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 تنش شوری در برداشت‌های اول و دوم. E^۱ (شاهد+برداشت دوم)، F (۲/۵ دسی‌زیمنس بر متر+برداشت دوم)، G (۵ دسی‌زیمنس بر متر+برداشت دوم) و H (۷/۵ دسی‌زیمنس بر متر+برداشت دوم) [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 (۲/۵ دسی‌زیمنس بر متر+برداشت اول)، C (۵ دسی‌زیمنس بر متر+برداشت اول)، D (۷/۵ دسی‌زیمنس بر متر+برداشت اول)، E (شاهد+برداشت دوم)، F (۲/۵ دسی‌زیمنس بر متر+برداشت دوم)، G (۵ دسی‌زیمنس بر متر+برداشت دوم) و H (۷/۵ دسی‌زیمنس 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.

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، PLS، PCR و OLS به‌دست 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 ، VAF، AIC، BIC و کمترین میزان RMSE، MAPE، RPD باشد. از بین مدل‌های رگرسیونی در هر دو برداشت و در تمامی سطوح تنش، مدل NLR به‌عنوان بهترین و دقیق‌ترین مدل معرفی شده است. کاروالهو و همکاران (۱۱) بیان کردند که پارامترهای طول و عرض برگ برای تخمین سطح برگ گیاه *Crotalaria juncea* کافی می‌باشند. علاوه بر 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

مدل معرفی شد ($R^2=0.9849$). بر طبق مطالعه هینا و همکاران (۱۹)، مدل‌های quadratic و power با مقدار 0.964 (R^2) (برای هر دو مدل) و RMSE به ترتیب $33/2$ و $34/4$ با دقت بالا و کمترین خطا مقدار سطح برگ را در بادمجان 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)، گلابول (۴۳)، لوبیا 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).

جدول ۲- نتایج مربوط به تخمین سطح برگ اکوتیپ‌های مختلف نعنای با استفاده از مدل‌های مختلف رگرسیونی
Table 2. Results related to estimation of leaf area for different mint ecotypes using different regression models

مدل	سطوح شوری (dS/m)	برداشت دوم	برداشت اول
PLS	۰	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	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	۰	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	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	۰	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	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	۰	$LA = -10.179 + 2.819 * W + 2.658 * L$	$LA = -9.838 + 2.7745 * W + 2.611 * L$
	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	۰	$LA = \exp(0.259 + 0.319 * W + 0.223 * L)$	$LA = \exp(0.225 + 0.325 * W + 0.2263 * L)$
	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	۰	$LA = -2.950 + 2.241 * W - 0.692 * L + 0.086 * W^2 + 0.435 * L^2$	$LA = -2.783 + 2.203 * W - 0.718 * L + 0.086 * W^2 + 0.440 * L^2$
	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	$LA = -0.508 + 1.277 * W - 0.317 * L + 0.300 * W^2 + 0.231 * L^2$	$LA = -0.470 + 1.269 * W - 0.320 * L + 0.300 * W^2 + 0.229 * L^2$

مقایسه مدل‌های رگرسیونی و غیررگرسیونی برای تخمین سطح برگ

شاخص‌های عملکرد مدل‌ها در برداشت‌های اول و دوم در تمامی سطوح تنش 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 تنش برآورد نمود. مطالعه صورت‌گرفته توسط امیری و شعبانی (۳) بیان کردند که مدل ANFIS یک روش دقیق و سریع برای برآورد سطح برگ بوده و همچنین در زمان صرفه‌جویی 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) را نسبت به مدل‌های رگرسیون خطی برآورد کند. مدل RBF شاخص سطح برگ را در برداشت اول در تمامی سطوح تنش شوری با دقت پایین و خطای بالا برآورد نمود ولی در برداشت دوم، در سطح بدون تنش مدل MLP و در سایر سطوح تنش شوری مدل RBF، شاخص سطح برگ را با دقت بالایی برآورد نمی‌کنند. به‌نظر می‌رسد برای افزایش دقت در تخمین شاخص سطح برگ در گیاه دارویی نعنای با استفاده از مدل‌های شبکه

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 به‌وسیله قوانین فازی برطرف شده است. شعبانی 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 خطا 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 تنش شوری موجب کاهش خطا و تقریباً افزایش دقت در مدل‌های موجود شده است. به‌نظر می‌رسد افزایش تنش 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.

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
0	R2	۰/۹۸۶	۰/۹۸۶	۰/۹۸۶	۰/۹۸۶	۰/۹۷۵	۰/۹۸۸	۰/۹۹۰	۰/۹۸۸	۰/۹۷۱	۰/۹۹۱
	VAF	۹۹/۵۴۴	۹۹/۵۴۴	۹۹/۵۲۱	۹۹/۵۴۴	۹۷/۰۲۰	۹۹/۸۰۳	۹۹/۸۳۵	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	۰/۳۵۳	۰/۳۴۴	۰/۸۳۰	۰/۳۴۷	۰/۲۲۵	۰/۳۰۹	۰/۶۲۵	۰/۲۰۲
	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	۲۰۳/۸۷۶	۱۹۹/۸۲۶	۲۰۰/۴۳۰	۱۹۹/۲۸۶	۱۹۶/۷۹۷	۲۰۱/۳۵۲
	BIC	۲۰۸/۰۸۲	۲۰۸/۰۸۲	۲۰۸/۰۱۱	۲۰۸/۰۸۲	۲۱۳/۶۹۳	۲۰۹/۶۴۳	۲۱۰/۲۴۸	۲۰۹/۱۰۳	۲۰۶/۶۱۵	۲۱۱/۱۶۹
۲/۵	R2	۰/۹۸۲	۰/۹۸۱	۰/۹۸۲	۰/۹۸۲	۰/۹۸۰	۰/۹۸۵	۰/۹۸۸	۰/۹۸۴	۰/۹۶۶	۰/۹۸۹
	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	۹/۹۲۰	۸/۳۵۰	۹/۷۱۴	۹/۸۳۸	۱۱/۰۶۱	۱۳/۹۴۶	۱۹/۹۳۳	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	۱۳۲/۳۲۷	۱۳۱/۸۴۱	۱۳۲/۲۵۳	۱۳۲/۲۹۴	۱۳۶/۶۱۲	۱۳۳/۶۶۲	۱۳۵/۵۵۴	۱۳۳/۰۸۴	۱۱۹/۶۹۲	۱۳۵/۷۳۶
۵	R2	۰/۹۸۰	۰/۹۸۰	۰/۹۸۰	۰/۹۷۹	۰/۹۸۱	۰/۹۸۵	۰/۹۹۱	۰/۹۷۸	۰/۹۶۴	۰/۹۹۳
	VAF	۹۹/۲۶۴	۹۹/۲۶۲	۹۹/۲۶۲	۹۸/۹۶۴	۹۹/۵۳۴	۹۹/۸۰۳	۹۹/۹۶۸	۹۸/۹۵۳	۹۸/۴۴۱	۹۹/۹۸۳
	MAPE	۳/۴۱۸	۳/۳۱۲	۳/۳۱۲	۳/۳۴۸	۳/۵۴۹	۳/۰۹۵	۲/۷۵۶	۳/۳۰۴	۲/۴۸۵	۲/۵۴۷
	RMSE	۰/۱۵۵	۰/۲۵۵	۰/۲۵۵	۰/۲۹۸	۰/۲۱۶	۰/۱۴۲	۰/۰۶۸	۰/۲۹۹	۰/۳۸۷	۰/۰۵۲
	RPD	۷/۳۰۶	۷/۳۳۷	۷/۳۳۷	۶/۲۵۵	۹/۲۶۷	۱۳/۴۴۱	۲۸/۱۸۶	۶/۱۵۸	۴/۸۹۲	۳۶/۹۹۱
	AIC	۱۱۳/۷۰۱	۱۱۳/۹۸۰	۱۱۳/۹۸۰	۱۱۳/۳۱۹	۱۲۵/۵۲۱	۱۱۷/۳۶۵	۱۱۸/۹۴۶	۱۱۰/۹۳۱	۱۱۴/۵۵۰	۱۲۰/۱۵۵
	BIC	۱۲۳/۵۱۹	۱۲۳/۷۹۷	۱۲۳/۷۹۷	۱۲۳/۱۳۶	۱۳۵/۳۳۸	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	۰/۹۷۷	۰/۹۷۷	۰/۹۷۵	۰/۹۷۷	۰/۹۶۷	۰/۹۹۰	۰/۹۹۵	۰/۹۹۴	۰/۹۶۱	۰/۹۹۶
	NAF	۹۹/۵۹۹	۹۹/۵۹۹	۹۹/۵۵۱	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	۵/۵۹۵	۲/۵۲۳
	RMSE	۰/۱۷۱	۰/۱۷۱	۰/۱۸۱	۰/۱۷۱	۰/۵۱۰	۰/۰۷۰	۰/۰۳۰	۰/۰۳۶	۰/۳۶۷	۰/۰۳۴
	RPD	۹/۳۰۷	۹/۳۰۷	۸/۷۹۳	۹/۳۰۷	۳/۵۰۱	۲۳/۴۴۳	۵۴/۷۱۷	۴۶/۳۶۱	۴/۶۰۰	۶۸/۰۰۹
	AIC	۸۶/۲۶۱	۸۶/۲۶۱	۸۵/۷۰۷	۸۶/۲۶۱	۱۰۴/۷۳۶	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	۰/۹۸۶	۰/۹۸۶	۰/۹۸۶	۰/۹۸۶	۰/۹۷۵	۰/۹۸۸	۰/۹۸۹	۰/۹۳۳	۰/۹۶۵	۰/۹۹۰
	NAF	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	۲/۵۷۷
	RMSE	۰/۳۶۳	۰/۳۷۰	۰/۳۶۳	۰/۳۶۴	۰/۸۳۷	۰/۲۶۱	۰/۳۴۱	۱/۷۸۲	۰/۷۹۱	۰/۳۲۰
	RPD	۸/۵۹۱	۸/۴۱۵	۸/۵۹۱	۸/۵۵۸	۳/۸۹۹	۱۱/۹۹۶	۱۳/۰۲۶	۱/۵۰۷	۳/۹۴۹	۱۴/۳۲۰
	AIC	۲۰۲/۲۱۶	۲۰۲/۱۹۶	۲۰۲/۲۱۶	۲۰۲/۲۳۳	۲۰۷/۲۲۲	۲۰۳/۵۷۱	۲۰۴/۱۱۴	۱۷۱/۹۵۶	۲۰۰/۹۱۵	۲۰۴/۷۹۸
	BIC	۲۱۲/۰۳۳	۲۱۲/۰۱۳	۲۱۲/۰۳۳	۲۱۲/۰۵۱	۲۱۷/۰۴۰	۲۱۳/۲۸۸	۲۱۳/۹۳۲	۱۸۱/۷۷۳	۲۱۰/۷۲۳	۲۱۴/۶۱۵
۲/۵	R2	۰/۹۸۲	۰/۹۸۲	۰/۹۸۲	۰/۹۸۲	۰/۹۸۰	۰/۹۸۴	۰/۹۸۸	۰/۹۸۷	۰/۹۶۵	۰/۹۸۹
	NAF	۹۹/۶۳۳	۹۹/۶۲۷	۹۹/۶۳۴	۹۹/۶۳۳	۹۹/۷۱۶	۹۹/۸۳۲	۹۹/۹۲۱	۹۹/۹۰۹	۹۸/۶۷۹	۹۹/۹۲۵
	MAPE	۲/۷۰۰	۲/۷۴۳	۲/۷۳۲	۲/۷۰۰	۳/۲۷۹	۲/۷۷۳	۲/۴۲۱	۲/۶۲۰	۳/۸۹۹	۲/۲۴۶
	RMSE	۰/۲۰۲	۰/۲۰۵	۰/۲۰۲	۰/۲۰۲	۰/۱۹۵	۰/۱۴۹	۰/۱۰۸	۰/۱۱۸	۰/۳۸۸	۰/۱۰۲
	RPD	۹/۹۸۴	۹/۸۴۶	۹/۹۷۳	۹/۹۸۴	۱۰/۵۴۰	۱۳/۶۰۶	۱۸/۹۳۱	۱۷/۳۰۷	۵/۲۳۰	۲۰/۱۰۰
	AIC	۱۲۶/۸۵۲	۱۲۶/۹۸۷	۱۲۶/۹۰۷	۱۲۶/۸۵۲	۱۳۰/۵۳۲	۱۲۷/۹۲۷	۱۳۰/۰۰۱	۱۲۹/۲۱۰	۱۲۶/۸۷۲	۱۲۹/۷۱۹
	BIC	۱۳۶/۶۶۹	۱۳۶/۸۰۵	۱۳۶/۷۲۴	۱۳۶/۶۶۹	۱۴۰/۳۵۰	۱۳۷/۷۴۴	۱۳۹/۸۱۸	۱۳۹/۰۲۷	۱۳۶/۸۹۹	۱۳۹/۵۳۶
۵	R2	۰/۹۸۰	۰/۹۸۰	۰/۹۸۰	۰/۹۸۰	۰/۹۸۱	۰/۹۸۶	۰/۹۹۱	۰/۹۸۵	۰/۹۴۹	۰/۹۹۳
	NAF	۹۹/۲۷۳	۹۹/۲۷۳	۹۹/۲۶۵	۹۹/۲۷۳	۹۹/۵۲۴	۹۹/۸۰۱	۹۹/۹۶۴	۹۹/۷۲۲	۹۷/۸۶۰	۹۹/۹۸۱
	MAPE	۳/۲۵۰	۳/۲۹۰	۳/۳۱۱	۳/۲۵۰	۳/۵۴۲	۳/۰۵۸	۲/۷۵۱	۳/۱۱۲	۵/۱۶۸	۲/۵۵۵
	RMSE	۰/۲۶۱	۰/۲۶۱	۰/۲۶۳	۰/۲۶۱	۰/۲۲۳	۰/۱۴۷	۰/۰۷۴	۰/۱۶۹	۰/۴۸۴	۰/۰۵۷
	RPD	۷/۳۷۶	۷/۲۶۵	۷/۳۱۱	۷/۳۷۶	۹/۱۷۰	۱۳/۲۹۵	۲۶/۶۳۱	۱۱/۴۸۴	۳/۸۹۸	۳۴/۷۹۰
	AIC	۱۱۸/۸۶۲	۱۱۹/۰۰۰	۱۱۸/۶۳۶	۱۱۸/۸۶۲	۱۲۹/۷۵۲	۱۲۱/۹۵۷	۱۲۳/۴۷۰	۱۲۱/۱۵۷	۱۱۲/۸۲۷	۱۲۴/۳۳۴
	BIC	۱۲۸/۶۷۹	۱۲۸/۸۱۷	۱۲۸/۴۵۳	۱۲۸/۶۷۹	۱۳۹/۵۷۰	۱۳۱/۷۹۲	۱۳۳/۲۸۸	۱۳۰/۹۷۵	۱۲۲/۶۴۴	۱۳۴/۱۵۲
۷/۵	R2	۰/۹۷۸	۰/۹۷۷	۰/۹۷۴	۰/۹۷۷	۰/۹۶۸	۰/۹۹۱	۰/۹۹۵	۰/۹۹۴	۰/۹۶۶	۰/۹۹۶
	NAF	۹۹/۶۲۰	۹۹/۶۱۸	۹۹/۲۰۲	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	۲/۴۹۶
	RMSE	۰/۱۷۳	۰/۱۷۴	۰/۲۳۸	۰/۱۷۴	۰/۵۱۸	۰/۰۷۲	۰/۰۳۴	۰/۰۴۳	۰/۳۳۹	۰/۰۲۶
	RPD	۹/۵۲۷	۹/۴۶۲	۶/۸۸۱	۹/۴۸۷	۳/۵۴۱	۲۳/۶۷۲	۵۰/۹۸۶	۳۹/۴۷۲	۴/۷۹۴	۶۶/۳۰۲
	AIC	۹۲/۱۱۷	۹۱/۸۷۴	۹۰/۷۶۸	۹۱/۸۳۳	۱۰۹/۵۷۰	۹۸/۲۵۸	۹۹/۷۳۳	۹۹/۰۳۱	۸۸/۴۷۴	۹۸/۸۷۲
	BIC	۱۰۱/۹۳۵	۱۰۱/۶۹۱	۱۰۰/۵۸۵	۱۰۱/۶۵۱	۱۱۹/۳۸۷	۱۰۸/۰۷۶	۱۰۹/۵۵۰	۱۰۸/۸۴۹	۹۸/۲۹۲	۱۰۸/۶۹۰

گونه‌های گیاهی از جمله گیاه دارویی نعنای 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 باغی، به دلیل ارتباط سطح برگ با عملکرد محصول بسیار مهم می‌باشد. امروزه استفاده از تکنیک‌های کامپیوتری 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. Ekinici 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. Mendonça 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. Rouphael, 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. Kandianan, 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. Esfandvari. 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. Uhlmann, 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-Haghighi. 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-Haghighi. 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- Ph.D. 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 Modarres 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