



به‌زراعی کشاورزی

دوره ۱۵ ■ شماره ۴ ■ زمستان ۱۳۹۲

صفحه‌های ۵۳-۶۴

مدل‌سازی و بهینه‌کردن مقاومت روزنه‌ای زیتون در شرایط تنش شوری ناشی از کلرید سدیم با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک

مهدی رضایی^{۱*}، عباس روحانی^۲

۱. استادیار گروه علوم باغبانی، دانشکده کشاورزی، دانشگاه شهردر

۲. استادیار گروه ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد

تاریخ وصول مقاله: ۹۲/۰۱/۲۳

تاریخ پذیرش مقاله: ۹۲/۰۹/۱۱

چکیده

مقاومت روزنه‌ای نقش مهمی در تبادلات آبی گیاه و میزان فتوسنتز در شرایط تنش دارد و یکی از پارامترهای کلیدی در بسیاری از مدل‌های اکولوژیکی و بیولوژیکی است. در این پژوهش، مقادیر بهینه پارامترهای مؤثر بر مقاومت روزنه‌ای زیتون براساس دست‌یابی به حداکثر مقاومت روزنه‌ای تعیین شد. سطوح شوری (۰، ۲۵، ۵۰ و ۱۰۰ میلی‌مول در لیتر کلرید سدیم)، درصد عناصر برگ (کلر، سدیم، پتاسیم، کلسیم، فسفر، منیزیم)، نسبت K/Na ، وزن تر برگ (mg)، سطح برگ (cm^2)، میزان آب نسبی برگ (درصد) و نسبت سطح برگ (cm^2/g) به‌عنوان پارامترهای مؤثر بر مقاومت روزنه‌ای زیتون در نظر گرفته شد. مقاومت روزنه‌ای با استفاده از مدل شبکه عصبی تابع پایه شعاعی (RBF) به‌صورت تابعی از متغیرهایی مدل شد که قبلاً لیست شد. نتایج پیش‌بینی‌شده نشان داد که شبکه عصبی توانسته است عملکرد خوبی فراهم کند، زیرا نتایج پیش‌بینی‌شده مطابق نتایج اندازه‌گیری‌شده بودند. بیشترین درصد خطا بین داده‌های آزمایشگاهی و پیش‌بینی‌شده کمتر از ۲/۵۷ درصد و ضریب همبستگی بین آن‌ها ۰/۹۹۴ شد. همچنین، مقایسه آماری بین داده‌های آزمایشگاهی و پیش‌بینی‌شده نشان‌دهنده قابلیت اطمینان پیش‌بینی‌ها با مدل شبکه عصبی RBF بود. شبکه عصبی آموزش‌دیده به‌عنوان تابع هدف برای دست‌یابی به پارامترهای بهینه با استفاده از الگوریتم ژنتیک استفاده شد. به‌ترتیب مقادیر بهینه برای اولین تا آخرین پارامترها در ۱۰۰، ۰/۱۵، ۰/۵۷، ۰/۷۸، ۰/۳۲، ۰/۰۶، ۰/۱۷، ۱/۲۹، ۲۶/۶۳، ۵/۰۳، ۰/۷۶ و ۷۲/۸۹ به‌دست آمد.

کلیدواژه‌ها: الگوریتم ژنتیک، زیتون، شبکه عصبی، شوری، مقاومت روزنه‌ای.

۱. مقدمه

زیتون گونه‌ای شیرین رست و نسبتاً مقاوم به شوری است که به‌عنوان گونه‌ای مدل، برای مطالعات تنش در درختان میوه مطرح است [۱]؛ با وجود این، از نظر تحمل به شوری تفاوت‌های معنی‌داری در بین ارقام زیتون وجود دارد [۲، ۳]. جذب و انتقال مقادیر زیادی از سدیم و کلر در گیاه در طول تنش شوری باعث افزایش پتانسیل اسمزی، اثر سمیت مخصوص یونی و عدم توازن در روابط یونی گیاه و وضعیت تغذیه‌ای درختان زیتون می‌شود [۱، ۴، ۵]. شوری می‌تواند به‌طور مستقیم جذب مواد تغذیه‌ای را کاهش دهد؛ برای مثال سدیم جذب پتاسیم یا کلراید جذب نترات را کاهش می‌دهد [۵]. سرعت انتقال سدیم و کلراید به برگ‌ها در گیاهان مقاوم نسبت به گیاهان حساس کمتر است و گیاهان مقاوم برای جلوگیری از تأثیرات سمی شوری در سیتوپلاسم یا دیواره سلولی می‌توانند این یون‌ها را در واکوئل جمع‌آوری کنند [۶]. پژوهش‌های قبلی نشان داد که مقاومت به شوری ارقام زیتون در ارتباط با کارایی مکانیزم آن‌ها ممانعت از انتقال و حفظ یون‌های سدیم و کلراید در ریشه دارد [۱، ۲، ۷]. یکی از مشکلاتی که طی تنش شوری به‌وجود می‌آید برهم‌خوردن روابط آبی در درون گیاه است [۸، ۹]. یکی از تأثیرات شوری بر گیاهان کاهش تبخیر و تعرق روزنه‌ای است که در نتیجه بسته‌شدن روزنه رخ می‌دهد [۹]. بسته‌شدن روزنه‌ها باعث کاهش میزان جذب دی‌اکسیدکربن و در نتیجه، کاهش فتوسنتز در گیاه می‌شود [۴]. گیاهان هالوفیت به دو طریق بر این مشکل فائق می‌آیند [۱] با استفاده از یون Na^+ به جای K^+ که بتواند تغییرات تورژسانسی را کنترل کنند و [۲] ممانعت از ورود Na^+ و اینکه K^+ بتواند نقش اصلی خویش را حفظ کند [۱۰]. در شوری علاوه بر یون سدیم، کلراید هم ممکن است تأثیرات آنتاگونیسمی با یون پتاسیم داشته باشد [۱۱] و از طرف دیگر شوری باعث برهم‌خوردن تعادل یونی

می‌شود [۱] که می‌تواند در باز و بسته شدن روزنه‌ها تأثیرگذار باشد. مقاومت روزنه‌ای نقش مهمی در تبادلات آبی و اتمسفر گیاه دارد و یکی از پارامترهای کلیدی در بسیاری از مدل‌های اکولوژیکی است [۱۲، ۱۳]. بنابراین، تخمین مقاومت روزنه‌ای در تحقیقات مربوط به روابط آبی و تنش‌های مربوط به آن، سوخت و ساز کربن، تأثیرات افزایش دی‌اکسیدکربن و آلودگی هوا اهمیت دارد [۹، ۱۴]. بیشتر تحقیقاتی که در مورد مدل‌سازی هدایت روزنه‌ای و یا مقاومت روزنه‌ای انجام شده است، مربوط به ارتباط آن با شرایط دمایی و رطوبتی محیطی و تأثیرات آن بر فتوسنتز و در گیاهان علفی یک‌ساله بوده است [۱۳، ۱۵]. تاکنون، هیچ تحقیقی در مدل‌سازی مقاومت روزنه‌ای تحت تنش شوری انجام نشده است. امروزه، شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیندها در علوم مختلف به‌کار گرفته می‌شوند [۱۶]. مزیت روش شبکه عصبی یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آن‌ها است [۱۷]. شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین، دانش قبلی از روابط بین پارامترهای مورد مطالعه، می‌تواند رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه را پیدا کند [۱۸، ۱۹]. ویژگی دیگر شبکه عصبی، تحمل‌پذیری در مقابل خطا است [۱۶]. این مزایا دلایل به‌کارگیری شبکه عصبی در این مطالعه است.

هدف این مطالعه، مدل‌سازی مقاومت روزنه‌ای زیتون با استفاده از شبکه عصبی RBF به کمک پارامترهای رشد و میزان عناصر موجود در برگ درختان زیتون در شرایط تنش شوری ناشی از کلرید سدیم و بهینه‌کردن این مدل با درک بهتر تأثیرات برهم‌خوردن تعادل یونی ناشی از تنش شوری در مقاومت روزنه‌ای زیتون به‌عنوان یک گیاه چوبی چندساله است.

۲. مواد و روش‌ها

۱.۲. اعمال تیمارها و اندازه‌گیری صفات

در این پژوهش قلمه‌های ریشه‌دار ۵ رقم زیتون به نام‌های فیشمی، زرد، کنسروالیا، مانزانیا و دزفولی به مدت ۷ ماه با روش هیدروپونیک با محلول نصف غلظت کوئیک [۲۰] در درون گلدان‌های ۲۰ لیتری حاوی پرلیت و ماسه (۱:۱) در شرایط گلخانه‌ای پرورش داده شدند. در هر گلدان ۳ قلمه ریشه‌دار قرار داده شد. در ماه دوم استقرار، نهال‌ها به‌صورت ۳ شاخه هرس شدند و تیماری شوری در غلظت‌های ۰، ۲۵، ۵۰ و ۱۰۰ میلی‌مول کلرید سدیم در مدت ۳ هفته به‌تدریج به محلول تغذیه‌ای اضافه شد. میزان هدایت الکتریکی برای سطوح صفر، ۲۵، ۵۰ و ۱۰۰ میلی‌مول در لیتر کلرید سدیم به‌ترتیب ۱/۲، ۴/۱، ۷ و ۱۲/۸ دسی‌زیمنس بر متر بود. در این آزمایش برای هر رقم در هریک از تیمارهای شوری ۳ تکرار (۳ گلدان) در نظر گرفته شد. برای اندازه‌گیری سطح برگ، برگ‌های واقع در گره‌های چهارم و پنجم انتهای شاخه‌ها انتخاب، از هر نهال ۶ برگ و جمعاً ۱۸ برگ از هر کرت جدا و سطح آن‌ها با دستگاه اندازه‌گیری سطح برگ، بر حسب سانتی‌متر مربع، اندازه‌گیری شد و میانگین ۱۸ برگ به‌عنوان شاخص سطح برگ در هر تکرار در نظر گرفته شد. اندازه‌گیری میزان عناصر سدیم، پتاسیم و کلسیم با استفاده از روش عصاره‌گیری خاکستر و اسید در برگ با استفاده از دستگاه فلاپم فتومتر^۱ انجام شد. اندازه‌گیری فسفر و منیزیم با استفاده از کیت^۲ ویژه با دستگاه اسپکتوفتومتر اندازه‌گیری شد [۲۱، ۲۲]. برای اندازه‌گیری کلر روش تیتراسیون با نیترات نقره و کلرور پتاسیم استفاده شد [۲۳]. برای محاسبه محتوای نسبی آب برگ تعداد ۳ برگ از گره‌های

پنجم و شش از هر شاخه، یعنی ۱۸ برگ از هر کرت جمع‌آوری شد، ابتدا وزن اندازه‌گیری و سپس، به مدت ۴۸ ساعت در آب مقطر قرار داده شد تا آبگیری کنند و سپس، به مدت ۴۸ ساعت در آون با دمای ۸۵°C قرار داده شد و وزن خشک آن‌ها یادداشت شد. با استفاده از ۳ مقدار وزنی برگ‌ها در زمان نمونه‌برداری و استفاده از فرمول زیر مقدار محتوای نسبی آب برگ محاسبه شد.

$$RWC = \frac{FM - DM}{TM - DM} \times 100 \quad (1)$$

در اینجا، DW وزن خشک نمونه‌ها، FW وزن تر نمونه‌ها، TW وزن برگ‌ها در حالت تورژسانس کامل مقاومت روزنه‌ای با دستگاه پرومتر AP۴ (از شرکت دلتا - تی)^۳ در ماه چهارم اجرای تیمار شوری پس از ظهور علائم سمیت یونی و کاهش رشد اندازه‌گیری شد. بدین صورت که از هر گیاه ۶ برگ (۳ برگ از قسمت‌های جوان و ۳ برگ از قسمت پیر) که در کل از هر کرت ۱۸ برگ که میانگین آن به‌عنوان مقاومت روزنه‌ای در نظر گرفته شد. زمان این اندازه‌گیری در طول روز با یک آزمایش اولیه در ساعت ۱ تا ۳ بعدازظهر تعیین شد. برای محاسبه نسبت سطح برگ^۴ نیز پس از محاسبه سطح برگ، آن‌ها را در آون در دمای ۷۰ درجه به مدت ۲۴ ساعت خشک و وزن خشک آن محاسبه شد. از تقسیم سطح برگ بر حسب سانتی‌متر مربع بر وزن خشک بر حسب گرم میزان نسبت سطح برگ محاسبه شد.

۱.۱.۲. شبکه عصبی RBF

در ابتدا داده‌های موجود به‌طور تصادفی به ۲ دسته مجموعه آموزش، ۸۰ درصد کل داده‌ها و مجموعه آزمون، ۲۰ درصد کل داده‌ها تقسیم‌بندی شد؛ البته اگر این

3. ΔT

4. LAR: Leaf area ratio

1. Flame photometer

2. Kit

از طریق پایین آوردن تعداد تکرارهای مورد نیاز برای یادگیری و بهبود رفتار شبکه در طول آموزش است [۱۶، ۱۷، ۲۴]. کد کامپیوتری این الگوریتم در محیط برنامه نویسی MATLAB تهیه شد.

تابع هزینه به کاررفته در این الگوریتم مجموع کل مربعات خطا^۲ (TSSE) است و به صورت زیر محاسبه می شود:

$$TSSE = \sum_q \sum_k (d_k^q - z_k^q)^2, q=1, \dots, Q \quad (3)$$

d_k^q و z_k^q به ترتیب k مین عنصر از بردارهای خروجی مطلوب و واقعی از q مین ورودی است. یادگیری شبکه در ۲ فاز پیش انتشار و پس انتشار اتفاق می افتد. وزن های هر لایه از شبکه از طریق زیر محاسبه می شوند.

$$u_{mj}(n+1) = u_{mj}(n) - \eta_r \frac{\partial E}{\partial u_{mj}} \quad (4)$$

$$v_{im}(n+1) = v_{im}(n) - \eta_r \frac{\partial E}{\partial v_{im}} \quad (5)$$

$$m=1 \dots l_2, j=1 \dots l_3, i=1 \dots l_1 \quad (6)$$


$$\sigma_m^r(n+1) = \sigma_m^r(n) - \eta_r \frac{\partial E}{\partial \sigma_m^r}$$

در اینجا u_{mj} اتصال وزنی بین گره های j و m ، v_{im} اتصال وزنی بین گره های i و m و σ_m پارامتر پراکندگی برای گره های m هستند. مقادیر اولیه این وزن های u_{mj} به طور تصادفی از دامنه مقادیر $[-0.1, 0.1]$ انتخاب می شوند. l_1 و l_2 به ترتیب تعداد نرون ها در لایه ورودی، لایه مخفی و لایه خروجی هستند. η_1 ، η_2 و η_3 به ترتیب آهنگ های یادگیری برای σ_m ، v_{im} و u_{mj} هستند و n شماره تکرار الگوریتم ($n=1, \dots, N$) است. برای جزئیات بیشتر این الگوریتم به منبع [۲۵] مراجعه شود. برای ارزیابی قابلیت شبکه عصبی RBF در پیش بینی از معیارهای

تقسیم بندی به نتایج مطلوب منجر نشود، می توان این مرحله را دوباره تکرار کرد [۱۶، ۲۴]. برای تبدیل داده ها از نرمالیزاسیون خطی (معادله ۲) استفاده شد:

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \times (r_{\max} - r_{\min}) + r_{\min} \quad (2)$$

در اینجا X داده خام اولیه، X_n داده نرمالیزه شده، X_{\max} و X_{\min} به ترتیب مقادیر بیشینه و کمینه داده های اولیه و r_{\max} و r_{\min} به ترتیب حد بالایی و پایینی دامنه تغییرات داده های تبدیل شده است.



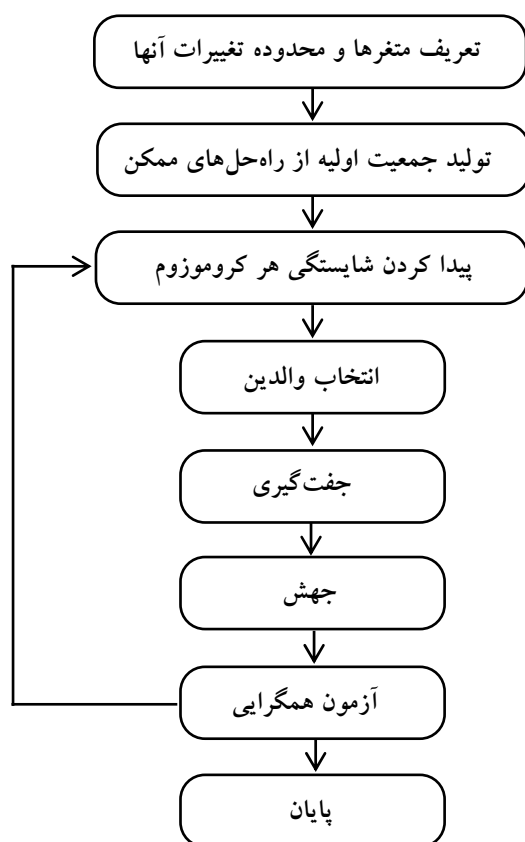
شکل ۱. ساختار شبکه RBF با یک لایه مخفی [۲۵]

ساختار شبکه RBF با یک لایه مخفی در شکل ۱ نشان داده شده است. شبکه RBF با دریافت بردار ورودی X^q بردار خروجی Z^q برای هر q ($q=1 \dots Q$) تولید خواهد کرد. هدف اتخاذ پارامترهای صحیح شبکه به منظور دستیابی به خروجی واقع Z^q که تا جای ممکن نزدیک به خروجی مطلوب d^q متناظر با خود باشد. برای آموزش شبکه از الگوریتم پس انتشار با نرخ یادگیری کاهشی^۱ (BDLRF) استفاده شد. مزیت این الگوریتم شامل سهولت در تنظیم پارامترهای یادگیری شبکه به سبب پایین آوردن حساسیت شبکه به مقادیر آهنگ های یادگیری، کاهش زمان یادگیری

2. Total sum-squared error

1. Backpropagation with declining learning-rate factor

مدل‌سازی و بهینه‌کردن مقاومت روزنه‌ای زیتون در شرایط تنش شوری ناشی از کلرید سدیم با استفاده از شبکه عصبی مصنوعی و ...



شکل ۲. روندنمایی الگوریتم ژنتیک

۳. نتایج و بحث

لایه ورودی در شبکه شامل ۱۳ نرون است که شامل عامل بایاس و ۱۲ عامل مؤثر بر مقاومت روزنه‌ای هستند. لایه خروجی تنها شامل یک نرون است که آن نشان‌دهنده مقدار مقاومت روزنه‌ای است. براساس تحقیق لین و چن در سال ۲۰۰۴، تعداد نرون‌های لایه مخفی برابر با تعداد کل داده‌های موجود است. مقادیر بهینه پارامترهای یادگیری η_1, η_2, η_3 از طریق آزمون و خطا و مطابق روش شرح داده‌شده را روحانی و همکاران، در سال ۲۰۱۱، انتخاب کردند [۱۶]. نتایج نشان می‌دهند که بهترین عملکرد شبکه در $\eta_1 = \eta_2 = 10^{-1}$ و $\eta_3 = 0.5$ به دست می‌آید. ۳۰ تعداد بهینه تکرارهای مورد نیاز شبکه همراه با نقطه شروع (n_1) در ۷ به دست آمد. ادامه یادگیری شبکه پس از

متوسط قدر مطلق درصد خطا^۱ (MAPE)، ریشه متوسط مربعات خطا^۲ (RMSE) و ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش‌بینی‌شده با شبکه عصبی و مقادیر واقعی آن‌ها و نیز بازده شبکه (EF) استفاده شدند.

$$RMSE = \sqrt{\sum_{i=1}^n (d_i - p_i)^2} \quad (7)$$

$$MAPE = \frac{1}{nm} \sum_{j=1}^n \sum_{i=1}^m \left| \frac{d_{ji} - p_{ji}}{d_{ji}} \right| \times 100 \quad (8)$$

$$EF = 1 - \frac{\sum_{i=1}^n (d_i - p_i)^2}{\sum_{i=1}^n (d_i + \bar{d})^2} \quad (9)$$

در اینجا d_i مؤلفه i ام از خروجی واقعی، p_i مؤلفه i ام از خروجی پیش‌بینی‌شده با شبکه، \bar{d} متوسط خروجی‌های واقعی هستند.


۲.۱.۲. الگوریتم ژنتیک

پس از آنکه مدل مقاومت به روزنه‌ای زیتون با شبکه عصبی RBF تشکیل شد، از این مدل به عنوان تابع شایستگی در الگوریتم ژنتیک به منظور بهینه‌کردن متغیرهای مورد مطالعه استفاده می‌شود. محدوده تغییرات هر متغیر براساس کمینه و بیشینه آن‌ها انتخاب شد. شروع الگوریتم ژنتیک براساس تولید یک مجموعه راه‌حل‌های ممکن از فضای تغییرات متغیرهای مستقل است. به این مجموعه متغیرهای تولیدی، جمعیت اولیه می‌گویند. براساس بیشترین مقدار مقاومت روزنه‌ای، جمعیت اولیه به ترتیب نزولی مرتب می‌شود و سپس، نصف جمعیت با شایستگی پایین تر حذف می‌شود و آنگاه مجموعه جمعیت جدید تولید می‌شود و این عمل تا زمانی ادامه می‌یابد که تمام راه‌حل‌ها به یک نقطه همگرا شوند. کد کامپیوتری الگوریتم ژنتیک براساس روندنمایی شکل ۲ [۲۶] در محیط برنامه‌نویسی مطلب تهیه شد.

1. Mean absolute percentage error
2. Root mean squared error

جدول ۲ مقادیر میانگین و واریانس و نیز مقایسه بین مقادیر میانگین و واریانس داده‌های واقعی مقاومت روزنه‌ای زیتون و مقادیر پیش‌بینی شده آن‌ها با شبکه در ۲ مرحله آموزش و آزمون شبکه عصبی RBF را نشان می‌دهد. براساس پژوهش‌های انجام شده برای داشتن عملکرد بهتر، تقسیم داده به ۲ مجموعه آموزش و آزمون در هر مورد می‌توانند متفاوت از هم باشند [۱۶، ۱۷]. تفاوت زیادی بین ویژگی‌های آماری میانگین و واریانس مقادیر پیش‌بینی شده و مقادیر واقعی آن‌ها برای شبکه عصبی آموزش دیده ملاحظه نمی‌شود. در اینجا فرضیه صفر بر تساوی میانگین و واریانس هر دو سری داده دلالت دارد. هر فرضیه در سطح احتمال ۹۵ درصد به کمک پارامتر p آزمون شد. به ترتیب برای مقایسه میانگین و واریانس از آزمون t و F استفاده شد. این نتایج نشان می‌دهند که میانگین و واریانس مقادیر واقعی و پیش‌بینی شده، اختلاف معنی‌داری با هم ندارند (در تمام موارد $p > 0.01$). نتیجه مربوط به مرحله آموزش شبکه نشان می‌دهد که پارامترهای یادگیر و سایر پارامترهای شبکه به خوبی بهینه شده‌اند و همچنین، نتیجه آزمایش شبکه با مجموعه داده‌هایی غیر از مجموعه داده‌های آموزش بیانگر این موضوع است که شبکه آموزش داده شده قابلیت تعمیم‌پذیری مناسبی دارد.

۳۰ تکرار که مجموع مربعات خطا برای داده‌های نرمال شده برابر با ۰/۰۰۹۳ شده است، به کاهش عملکرد تعمیم‌پذیری شبکه منجر خواهد شد و لذا، پس از این نقطه باید یادگیری به اتمام برسد (شکل ۳).



شکل ۳. نمودار همگرایی شبکه عصبی RBF در طول مرحله آموزش، q تعداد تکرار و TSSE مجموع کل مربعات خطا در مرحله آموزش برای داده‌های نرمال شده

برخی ویژگی‌های آماری داده‌های واقعی و پیش‌بینی شده مربوط به مقاومت روزنه‌ای زیتون در جدول ۱ آمده است. همان‌طور که ملاحظه می‌شود تفاوت عددی زیادی بین مقادیر واقعی و پیش‌بینی شده وجود ندارد. این تفاوت برای مرحله آزمایش شبکه عصبی بیشتر از مرحله آموزش شبکه عصبی است و این بدان دلیل است که داده‌های به کارگرفته شده در مرحله آزمایش برای شبکه تازگی دارند. البته تفاوت اندک مشاهده شده برای مرحله آزمایش دال بر مناسب بودن قابلیت تعمیم‌پذیری شبکه عصبی آموزش دیده است.

جدول ۱. ویژگی‌های آماری مقادیر واقعی و پیش‌بینی شده مقاومت به روزنه

ویژگی‌های آمار								
sum	ske	kur	max	min	std	var	av	
۲۳۳/۱۲	۰/۸۱	۲/۸۶	۱۲/۷۷	۱/۳۷	۲/۷۵	۷/۵۷	۴/۸۶	dv
۲۳۳/۶۱	۰/۷۳	۲/۵۲	۱۱/۸۱	۱/۴۷	۲/۶۷	۷/۱۳	۴/۸۷	pv
۷۱/۰۴	۰/۶۹	۲/۷۱	۱۲/۷۷	۱/۴۳	۳/۱۳	۹/۷۷	۵/۹۲	dv
۷۰/۱۱	۰/۶۶	۲/۵۲	۱۱/۸۱	۲/۳۷	۲/۸۱	۷/۸۸	۵/۸۴	pv

توضیحات: av: میانگین var: واریانس std: انحراف معیار min: کمینه max: بیشینه kur: کشیدگی ske: چولگی sum: مجموع dv: مقادیر واقعی داده‌ها pv: مقادیر پیش‌بینی شده با مدل RBF شبکه عصبی

مدل‌سازی و بهینه‌کردن مقاومت روزنه‌ای زیتون در شرایط تنش شوری ناشی از کلرید سدیم با استفاده از شبکه عصبی مصنوعی و ...


جدول ۲. مقایسه آماری مقادیر واقعی و پیش‌بینی شده مقاومت به روزنه با RBF

مجموعه داده	نوع تحلیل آماری		
	مقایسه میانگین	مقایسه واریانس	مقایسه توزیع
مرحله آموزش	۰/۹۸	۰/۷۷	۱/۰۰
مرحله آزمایش	۰/۹۹	۰/۶۱	۰/۹۳

جدول ۳. عملکرد شبکه عصبی RBF در پیش‌بینی مقاومت روزنه‌ای برای ۲ مرحله آموزش و آزمون و کل داده‌ها

EF	RMSE			MAPE		
	کل	آزمون	آموزش	کل	آزمون	آموزش
۰/۹۹	۰/۲۵	۰/۴۲	۰/۱۸	۲/۵۷	۵/۶۷	۱/۷۹

به واحد و عرض از مبداهای نسبتاً کوچکی هستند، بنابراین، می‌توان به چنین شبکه‌هایی اطمینان داشت.



شکل ۴. رابطه خطی رگرسیونی و ضریب تبیین بین داده‌های واقعی (dv) و پیش‌بینی شده (pv) برای مجموعه کل داده

۱.۳. بررسی تأثیر پارامترهای مؤثر بر مقاومت روزنه‌ای زیتون

برای ارزیابی تأثیر هریک از پارامترها بر مقاومت روزنه‌ای زیتون، مدل شبکه عصبی را با تمام پارامترها به‌جز پارامتر مورد بررسی آموزش، آزمایش شد. نتایج حاصل از حذف هریک از عوامل مؤثر بر مقاومت روزنه‌ای در جدول ۴

عملکرد شبکه عصبی RBF طراحی شده در ۲ مرحله آموزش، آزمون داده‌ها و نیز برای کل داده‌ها با هم مقایسه شده است (جدول ۳). طبق این جدول مقادیر خطا در مرحله آموزش و آزمایش بسیار کم است که این نشان از قابلیت بالای شبکه عصبی مصنوعی RBF در پیش‌بینی مقاومت روزنه‌ای زیتون دارد. بازده مدل RBF برای کل داده‌ها برابر ۰/۹۹ شد، لذا، مدل شبکه عصبی توانسته است به‌طور کامل رفتار تغییرات مقاومت روزنه‌ای زیتون را پیش‌بینی کند که ناشی از عوامل مذکور در بخش مواد و روش‌ها بوده است.

شکل ۴ ضریب تبیین و همچنین، رابطه خطی رگرسیونی بین مقاومت روزنه‌ای واقعی در مقابل مقاومت روزنه‌ای پیش‌بینی شده با شبکه عصبی RBF را نشان می‌دهد. در صورتی که معادله خطی بین مقادیر واقعی و پیش‌بینی شده از طریق شبکه عصبی دارای ضرایب تبیین بالا، عرض از مبدا کوچک (نزدیک به صفر) و شیب نزدیک به ۱ باشد ($pv = 1/000dv + 0/000$) بهترین نتیجه حاصل می‌شود [۱۶]. ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده بسیار بالا هستند ($R^2 > 0/99$). همچنین، معادله خطی رگرسیونی بین آن‌ها دارای شیب‌های نزدیک

آبی [۲۸] و مکانیسم اسید آسبیزیک (ABA) [۲۹] باعث بسته شدن روزنه ها می شوند. در تمام موارد، بسته شدن روزنه ها در ابتدا با آزاد شدن سریع یون K^+ از سلول های نگهبان به بخش آپوپلاست است [۳۰]. یون پتاسیم می تواند باز و بسته شدن روزنه ها را کنترل کند. پژوهش های متعددی نشان داده است که در شرایط کمبود پتاسیم تأثیر تنش های شوری و خشکی در درختان زیتون به مراتب شدیدتر است [۳۱، ۳۲].

آمده است. عاملی که دارای بالاترین ضریب تبیین (R^2) و کمترین مقدار خطا (RMSE) باشد، کمترین تأثیر را در مدل برای تخمین مقدار متغیر پاسخ خواهد داشت. این نتایج نشان می دهد که به ترتیب سطح شوری و مقدار منیزیم بیشترین و کمترین تأثیر بر مقاومت روزنه ای زیتون را دارد. پس از سطوح شوری، به ترتیب نسبت پتاسیم به سدیم، درصد پتاسیم برگ، درصد سدیم برگ و میزان آب نسبی برگ بیشترین تأثیر را بر مقاومت روزنه ای داشته اند (جدول ۴). عوامل مختلفی از قبیل تاریکی [۲۷] و تنش

جدول ۴. تأثیر پارامترهای مؤثر بر مقاومت روزنه ای

معیار ارزیابی	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12
R^2	۰/۸۳	۰/۹۶	۰/۹۲	۰/۹۱	۰/۹۶	۰/۹۰	۰/۹۹	۰/۹۹	۰/۹۸	۰/۹۷	۰/۹۴	۰/۹۷
RMSE	۱/۱۶	۰/۵۵	۰/۸۱	۰/۸۵	۰/۵۵	۰/۹۰	۰/۳۵	۰/۲۳	۰/۴۰	۰/۴۵	۰/۶۶	۰/۴۷
رتبه تأثیر	۱	۶	۴	۳	۶	۲	۱۰	۱۱	۹	۸	۵	۷

توضیح: X1 سطوح شوری، X2 کلر، X3 سدیم، X4 پتاسیم، X5 کلسیم، X6 نسبت پتاسیم به سدیم، X7 فسفر، X8 منیزیم، X9 وزن تر برگ، X10 سطح برگ (سانتی متر مربع)، X11 میزان آب نسبی برگ، X12 نسبت سطح برگ

جدول ۵. مقادیر همبستگی بین متغیرهای مستقل و وابسته

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	Y
X1	1.00												
X2	0.69	1.00											
X3	0.90	0.68	1.00										
X4	-0.74	-0.52	-0.77	1.00									
X5	-0.51	-0.23	-0.41	0.36	1.00								
X6	-0.77	-0.62	-0.81	0.74	0.43	1.00							
X7	-0.39	-0.21	-0.24	0.29	0.20	0.31	1.00						
X8	-0.17	-0.11	-0.19	0.15	-0.08	-0.07	-0.15	1.00					
X9	-0.52	-0.39	-0.48	0.50	0.28	0.40	0.30	0.13	1.00				
X10	-0.14	-0.23	-0.10	0.09	-0.04	0.07	0.04	0.15	0.35	1.00			
X11	-0.07	-0.22	-0.15	0.10	-0.05	0.18	-0.02	-0.05	0.22	0.31	1.00		
X12	-0.38	-0.31	-0.38	0.31	0.08	0.32	0.16	0.29	0.05	0.36	-0.02	1.00	
Y	0.51	0.22	0.57	-0.41	-0.17	-0.45	-0.14	-0.05	0.06	0.21	0.17	-0.31	1.00

توضیح: Y مقاومت روزنه ای، X1 سطوح شوری، X2 کلر، X3 سدیم، X4 پتاسیم، X5 کلسیم، X6 نسبت پتاسیم به سدیم، X7 فسفر، X8 منیزیم، X9 وزن تر برگ، X10 سطح برگ (سانتی متر مربع)، X11 میزان آب نسبی برگ، X12 نسبت سطح برگ. اعداد قرمز سطوح معنی دار را نشان می دهند.

نتایج حاصل از همبستگی بین متغیرها که در جدول ۵ آمده است، تأیید دیگری بر نتایج به‌دست‌آمده در جدول ۴ است. افزایش NaCl در محلول غذایی موجب افزایش میزان کلر و سدیم در برگ شده است، ولی تأثیر آن بر افزایش میزان سدیم بیشتر از کلر است. یون Na^+ و به میزان کمتر یون Cl^- تأثیرات معنی‌دار منفی (-0.77) و (-0.52) بر K^+ داشته است که در نسبت پتاسیم به سدیم نیز به‌خوبی مشهود است (جدول ۵). تنش‌های حاوی یون سدیم، جذب پتاسیم را از طریق ریشه محدود می‌کند [۳۳]. علاوه بر پتاسیم یک رابطه منفی بین یون کاتیونی کلسیم با سدیم دیده می‌شود. شواهد آزمایشگاهی بر این موضوع دلالت دارند که یون کلسیم در سازگاری به نمک نقش دارد و کاربرد خارجی کلسیم تأثیرات سمی کلرید سدیم را کاهش می‌دهد که احتمالاً با افزایش خاصیت جذب انتخابی نسبت پتاسیم به سدیم این کار صورت می‌گیرد [۳۴]. رابطه منبسط با سطوح شوری و یون سدیم منفی بود، اما معنی‌دار نبود (جدول ۵) رابطه سطوح شوری و یون سدیم و کلر در برگ با وزن تر برگ و نسبت سطح برگ یک رابطه منفی معنی‌دار است، ولی با سطح برگ رابطه معنی‌داری ندارد (جدول ۵) شوری باعث کاهش فتوسنتز، کاهش بیوماس و ضخامت برگ در زیتون می‌شود [۱]. رابطه افزایش سطوح شوری، یون سدیم با مقاومت روزنه‌ای یک رابطه مثبت معنی‌دار و یون پتاسیم و نسبت پتاسیم به سدیم با مقاومت روزنه‌ای یک رابطه منفی معنی‌دار است (جدول ۵). این رابطه نشان می‌دهد که با افزایش میزان NaCl یون سدیم باعث بسته‌شدن روزنه می‌شود و یون پتاسیم در باز نگه‌داشتن روزنه نقش ویژه‌ای دارد.

۲.۳. بهینه‌کردن پارامترها با استفاده از الگوریتم ژنتیک

برای پیدا کردن مقادیر بهینه پارامترهای شاخص‌های رشد و


میزان عناصر موجود در زیتون برای داشتن حداکثر مقاومت در مقابل بیشترین شوری مورد مطالعه (۱۰۰) از طریق الگوریتم ژنتیک محاسبه شد. مقادیر این پارامترها در جدول ۶ آمده است. حداکثر مقاومت روزنه‌ای با داشتن مقادیر این پارامترها برابر با ۱۲/۶۲ شد (شکل ۴).

جدول ۶ نشان می‌دهد که از جمله پارامترهایی که در تعیین مقاومت روزنه‌ای و شناسایی ارقام مقاوم مهم است می‌توان به شاخص‌های رشدی چون نسبت سطح برگ (LAR) و وزن تر برگ و سطح برگ اشاره کرد. شواهدی در دیگر پژوهش‌ها [۱، ۲] نشان می‌دهند که ارقامی از زیتون که برگ‌های ریزتری دارند، مقاومت بیشتری به تنش شوری نشان می‌دهند. در میان عناصر نسبت پتاسیم به سدیم شاخصی است که از آن می‌توان برای انتخاب ارقام مقاوم استفاده کرد (جدول ۶). از این شاخص برای تعیین ارقام مقاوم در زیتون استفاده شده است [۱، ۷]. مقاومت روزنه‌ای نقش زیادی در تحمل تنش‌ها دارد، چرا که بازبودن روزنه‌ها در شرایط تنش شوری متوسط می‌تواند علاوه بر حفظ فتوسنتز بر روابط آبی گیاه و جذب عناصر کمک شایانی بکند. با نگاهی به شکل ۵ مشخص می‌شود که تغییرات مقاومت روزنه‌ای ارقام مختلف نسبت به تنش شوری چگونه است. طبیعتاً ارقامی که در سلول‌های نگهبان روزنه سریع با تنش شوری واکنش می‌دهند و روزنه‌های خود را می‌بندند، نسبت به تنش حساس‌ترند و زودتر آسیب می‌بینند. همان‌طور که در نمودار مشاهده می‌شود رقم دزفولی کمترین تغییرات روزنه‌ای را طی تنش شوری نشان می‌دهد، در حالی که، در رقم فیشمی مقاومت روزنه‌ای طی تنش شوری افزایش می‌یابد. این روند در رقم مانزانیلا ابتدا افزایش می‌یابد و سپس کمتر می‌شود؛ در حالی که، در رقم کنسروالیا، این روند افزایشی در ابتدا و تا سطح ۵۰ میلی‌مول کلرید سدیم کند می‌شود و سپس افزایش می‌یابد.

جدول ۶. مقادیر بهینه پارامترهای شاخص‌های رشد و میزان عناصر برای داشتن حداکثر مقاومت در مقابل بیشترین شوری

X12	X11	X10	X9	X8	X7	X6	X5	X4	X3	X2	X1
۷۲/۸۹	۰/۷۶	۵/۰۳	۲۶/۶۳	۰/۱۷	۰/۰۶	۱/۲۹	۰/۳۲	۰/۷۸	۰/۵۷	۰/۱۵	۱۰۰

توضیح: Y مقاومت روزنه‌ای، X1 سطوح شوری، X2 کلر، X3 سدیم، X4 پتاسیم، X5 کلسیم، X6 نسبت پتاسیم به سدیم، X7 فسفر، X8 منیزیم، X9 وزن تر برگ، X10 سطح برگ (سانتی‌متر مربع)، X11 میزان آب نسبی برگ، X12 نسبت سطح برگ



شکل ۵. سطح پاسخ مقاومت روزنه‌ای در مقابل سطوح شوری و ارقام مورد مطالعه

۳.۳. نتیجه‌گیری

مدل‌های ریاضی مانند شبکه‌های عصبی و الگوریتم ژنتیکی در درک عکس‌العمل فیزیولوژیکی یک فرایند بیولوژیکی در گیاه می‌تواند استفاده شود. به کمک شبکه عصبی می‌توان رفتار تغییرات یک عامل وابسته مانند مقاومت روزنه را در مقابل مجموعه‌ای از متغیرهای مستقل مدل کرد و آنگاه با استفاده از روش‌های بهینه‌کردن مانند الگوریتم ژنتیک مدل حاصل‌شده براساس یک هدف مشخص مانند بیشترین مقاومت روزنه‌ای بهینه کرد. مقاومت روزنه‌ای به عنوان یک عامل کلیدی می‌تواند در مدل‌سازی واکنش گیاهان چوبی چندساله مدنظر قرار بگیرد. درختان زیتونی که در شرایط تنش شوری کمترین تغییرات در روزنه‌های خود را دارند، مقاوم‌تر از سایر ارقام هستند. یون پتاسیم نقش زیادی در باز نگه‌داشتن روزنه‌ها در شرایط تنش دارد. از معیارهای نسبت پتاسیم به سدیم و

مقاومت روزنه‌ای می‌توان برای انتخاب گیاهان مقاوم در شرایط تنش شوری استفاده کرد.

منابع

1. Gucci R and Tattini M (1997) Salinity tolerance in olive. Hort. Rev. 21: 177-214
2. Rezaei M Talaei A Babalar M and Lessani H. (2006) Effect of NaCl on Growth and Ion Content of Five Olive Cultivars. Acta Horticulture. 773:209-215
3. Kchaou H Larbi A Gargouri K Chaieb M Morales F and Msallem M. (2010) Assessment of tolerance to NaCl salinity of five olive cultivars based on growth characteristics and Na^+ and Cl^- exclusion mechanisms. Scientia Horticulturae. 124: 306-315

4. Tattini M Marzi L Tafani R and Traversi M (1999) A review on salinity-induced changes in leaf gas exchange parameters of olive plants. *Acta Horticulturae* 2: 415-418
5. Grattan S and Grieve C (1998) Salinity-mineral nutrient relations in horticultural crops. *Scientia Horticulturae*. 78: 127-157
6. Munns R (2002) Comparative physiology of salt and water stress. *Plant Cell & Environment* 25 239-250
7. Chartzoulakis K Loupassaki M Bertaki M and Androulakis I. (2002) Effects of NaCl salinity on growth ion content and CO₂ assimilation rate of six olive cultivars. *Scientia Horticulturae*. 96: 235-247
8. Rezaie M Lessani H and Soleimani A. (2004) The Linked Effect of Saline and Drought Stress on Olive (*Olea europaea* L.) Plants. *Acta Horticulture*. 791:493-496
9. Zavala M A (2004) Integration of drought tolerance mechanisms in Mediterranean sclerophylls: a functional interpretation of leaf gas exchange simulators. *Ecological modelling* 176: 211-226
10. Robinson M F Very A A Sanders D and Mansfield T. (1997) How can stomata contribute to salt tolerance? *Annals of Botany*. 80: 387-393
11. Munns R and Tester M (2008) Mechanisms of salinity tolerance. *Annu. Rev. Plant Biol.* 59: 651-681
12. Wong S Cowan I and Farquhar G. (1979) Stomatal conductance correlates with photosynthetic capacity.
13. Liu Z Zhang Z Wang Z and Shu Q. (2008) Measuring and modeling stomatal conductance of cucumber crop in solar greenhouse in Northeast China. *Scientia Horticulturae*. 117: 103-108
14. Fuhrer J. (2000) Introduction to the special issue on ozone risk analysis for vegetation in Europe. *Environmental pollution* (Barking Essex: 1987) 109: 359
15. Ball J. (1987) A model predicting stomatal conductance and its contribution to the control of photosynthesis under different environmental conditions. In *Prog. Photosynthesis Res. Proc. Int. Congress 7th Providence*. 10-15 Aug 1986. Vol4. Kluwer Boston. pp. 221-224
16. Rohani A and Makarian H (2011) Making Weed Management Maps by Artificial Neural Networks for Using in Precision Agriculture. *Journal of agricultural machinery engineering*. 2:72-83
17. Gholipoor M Rohani A and Torani S. (2013) Optimization of traits to increasing barley grain yield using an artificial neural network. *International Journal of Plant Production*. 7: 1-17
18. Kaul M Hill R L and Walthall C. (2005) Artificial neural networks for corn and soybean yield prediction. *Agricultural Systems*. 85: 1-18
19. Torrecilla J Otero L and Sanz P. (2004) A neural network approach for thermal/pressure food processing. *Journal of Food Engineering*. 62: 89-95
20. Coic Y and Lesaint C. (1976) Influence de la modalite de deficiencia en phosphore sur l'equilibre photosynthese-protidosynthese.

- Comptes Rendus de l'Academie d'Agriculture de France 62
21. Barbour H M and Davidson W. (1988) Studies on measurement of plasma magnesium: application of the Magon dye method to the "Monarch" centrifugal analyzer. Clinical chemistry 34 2103-2105
 22. Page A L. (1982) Methods of soil analysis. Part 2. Chemical and microbiological properties American Society of Agronomy Soil Science Society of America
 23. Gilliam J (1971) Rapid measurement of chlorine in plant materials. Soil Science Society of America Journal. 35: 512-513
 24. Zarifneshat S Rohani A Ghassemzadeh H R Sadeghi M Ahmadi E and Zarifneshat M. (2012) Predictions of apple bruise volume using artificial neural network. Computers and Electronics in Agriculture. 82: 75-86
 25. Vakil-Baghmisheh M-T and Pavešić N. (2003) Premature clustering phenomenon and new training algorithms for LVQ. Pattern recognition. 36: 1901-1912
 26. Haupt R L and Haupt S E. (2004) Practical genetic algorithms. Wiley-Interscience.
 27. Zeiger E Moody W Hepler P and Varela F. (1977) Light-sensitive membrane potentials in onion guard cells. Nature, UK 270(5634): 270-271
 28. Assmann S M and Shimazaki K. (1999) The multisensory guard cell. Stomatal responses to blue light and abscisic acid. Plant Physiology. 119: 809-816
 29. Cummins W Kende H and Raschke K. (1971) Specificity and reversibility of the rapid stomatal response to abscisic acid. Planta. 99: 347-351
 30. Benlloch-González M Romera J Cristescu S Harren F Fournier J M and Benlloch M. (2010) K⁺ starvation inhibits water-stress-induced stomatal closure via ethylene synthesis in sunflower plants. Journal of experimental botany. 61: 1139-1145
 31. Arquerro O Barranco D and Benlloch M. (2006) Potassium starvation increases stomatal conductance in olive trees. HortScience. 41: 433-436
 32. Benlloch-Gonzalez M Arquerro O Fournier J M Barranco D and Benlloch M. (2008) K⁺ starvation inhibits water-stress-induced stomatal closure. Journal of Plant Physiology. 165: 623-630
 33. Zhu J K. (2003) Regulation of ion homeostasis under salt stress. Current opinion in plant biology. 6: 441-445
 34. Parida A K and Das A B. (2005) Salt tolerance and salinity effects on plants: a review. Ecotoxicology and Environmental Safety. 60: 324-349