

مقاله پژوهشی

ارزیابی بهینه‌سازی مؤلفه‌های پرتودهی بذر با فراصوت برای افزایش بنیه گیاهچه ماش (*Vigna radiata*) توسط شبکه عصبی مصنوعی

شمس‌الدین اسکندر نژاد^۱، منوچهر قلی‌پور^{۲*}، حسن مکاریان^۲

چکیده مبسوط

مقدمه: شواهد آزمایشی زیادی نشان‌گر تأثیر مثبت پرتودهی بذر با موج‌های فراصوت می‌باشد؛ به طوری که این پرتودهی می‌تواند باعث تولید گیاهچه قوی‌تر شود. در مقابل، پرتودهی با شدت و مدت نامناسب می‌تواند از طریق تأثیر مخرب بر فعالیت آنزیمی، تأثیری زیان‌بار بر گیاهچه به‌جای گذارد. بین مؤلفه‌های پرتودهی (مدت خیساندن بذر قبل از پرتودهی، مدت و دمای پرتودهی) با یکدیگر و با متغیرهای پاسخ (وزن خشک گیاهچه و درصد گیاهچه‌های غیرطبیعی) رابطه پیچیده‌ای وجود دارد. از این رو نمی‌توان با مقایسه میانگین، یک ترکیب تعادلی دقیق را برای حصول مقادیر مطلوب وزن خشک گیاهچه و درصد گیاهچه‌های غیرطبیعی به‌دست آورد. هدف از این بررسی، بهینه‌سازی (پیدا کردن ترکیب تعادلی) مؤلفه‌های پرتودهی برای حصول وزن خشک زیادتر گیاهچه و درصد کم‌تر گیاهچه‌های غیرطبیعی در ماش با استفاده از شبکه عصبی مصنوعی بود.

مواد و روش‌ها: آزمایش به صورت فاکتوریل در قالب طرح پایه کاملاً تصادفی با سه تکرار انجام شد که در آن، فاکتورها شامل شش مدت خیساندن بذر (دو، چهار، شش، هشت، ده و دوازده ساعت) قبل از پرتودهی، پنج مدت پرتودهی (صفر، سه، شش، نه و دوازده دقیقه) و چهار دمای پرتودهی (۱۷، ۲۲، ۲۷ و ۳۲ درجه سلسیوس) بود. ۲۵ عدد بذر برای هر ظرف پتری انتخاب گردید. برای کمی کردن روابط بین متغیرها از شبکه عصبی چند لایه پرسپترون استفاده شد که در آن، فاکتورهای آزمایش به عنوان ورودی (متغیرهای تأثیرگذار)، و درصد گیاهچه‌های غیر طبیعی و وزن خشک گیاهچه به عنوان خروجی مدل (متغیرهای پاسخ) در نظر گرفته شدند.

یافته‌ها: نتایج تجزیه واریانس نشان داد که اثرات ساده و برهمکنش فاکتورها بر وزن خشک گیاهچه و درصد گیاهچه‌های غیر طبیعی معنی‌دار بود. ساختار ۳:۴:۲ مدل شبکه عصبی مبتنی بر تابع فعال‌سازی سکانت هایپربولیک مناسب به‌دست آمد. وزن خشک گیاهچه و درصد گیاهچه‌های غیر طبیعی از لحاظ میزان مشارکت فاکتورها در توجیه تغییرات آنها تفاوت قابل اغماضی داشتند؛ ترتیب اولویت فاکتورها از نظر تحت تأثیر قرار دادن این صفات به صورت مدت پرتودهی < دمای پرتودهی < مدت خیساندن بذر بود. ترکیب تعادلی مؤلفه‌های به‌دست آمده توسط شبکه عصبی شامل دمای پرتودهی ۱۷/۹۶ درجه سلسیوس، مدت پرتودهی ۵/۳ دقیقه و خیساندن ۱۱/۲۵ ساعته بذر بود که در مقایسه با دو ترکیب تعادلی به‌دست آمده توسط مقایسه میانگین، وزن خشک گیاهچه ۲۷٪ بالاتر و درصد گیاهچه‌های غیرطبیعی ۰/۶٪ پایین‌تر به‌دست آمد.

نتیجه‌گیری: به لحاظ شدت بالای برهمکنش مؤلفه‌های پرتودهی بر رشد گیاهچه، با تغییر کمیت هر مؤلفه، اثر مؤلفه (های) دیگر نیز تغییر شدیدی می‌یابد. از لحاظ یافتن بهترین ترکیب مؤلفه‌های پرتودهی، شبکه عصبی کارآمدتر از مقایسه میانگین بود. از این رو می‌توان از شبکه عصبی به عنوان روش تکمیلی در این‌گونه بررسی‌ها استفاده نمود. بهترین ترکیب تیماری شامل دمای حدود ۱۷/۹۶ درجه سلسیوس، خیساندن ۱۱/۲۵ ساعت و پرتودهی به مدت ۵/۳ دقیقه بود.

واژه‌های کلیدی: بنیه گیاهچه، دمای پرتودهی، مدت پرتودهی، مدت خیساندن

جنبه‌های نوآوری:

- ۱- مؤلفه‌های پرتودهی شامل دما و مدت پرتودهی و مدت خیساندن بذر رشد گیاهچه را متأثر نمودند.
- ۲- سطوح نامناسب مؤلفه‌های پرتودهی بذر، رشد گیاهچه را به کمتر از شرایط بدون پرتودهی تقلیل داد.
- ۳- سطوح مطلوب (تعادلی) مؤلفه‌های پرتودهی بذر افزایش قابل توجهی در رشد گیاهچه ایجاد نمود.



مقدمه

دستگاه ۲۵۰ وات به مدت ۵، ۱۰، ۱۵ و ۲۰ دقیقه گزارش نمودند که در شدت‌های ۴۰ و ۶۰ درصد و مدت پرتودهی ۱۰ دقیقه، بالاترین رشد گیاهچه حاصل می‌گردد. به طور کلی اعتقاد بر این است که در اثر پرتودهی، ساختار و عملکرد مولکول‌ها تغییر می‌یابد (یلداگرد^{۱۳} و همکاران، ۲۰۰۸ الف و ب).

نتایج برخی از بررسی‌ها نشان می‌دهد که پرتودهی با شدت و مدت نامناسب باعث کاهش فعالیت آنزیمی و فعل و انفعالات فیزیولوژیکی در بذر شده (لیو^{۱۴} و همکاران، ۲۰۰۳؛ پیت^{۱۵} و راس، ۲۰۰۳؛ بارتون و همکاران، ۱۹۹۶) و درصد گیاهچه‌های غیر طبیعی را افزایش می‌دهد (رجیبیان^{۱۶}، ۲۰۱۲). در این خصوص، بین مؤلفه‌های پرتودهی (مدت خیساندن بذر قبل از پرتودهی، مدت و دمای پرتودهی) با یکدیگر و با صفاتی هم‌چون وزن خشک گیاهچه و درصد گیاهچه‌های غیر طبیعی، رابطه‌ای چندجانبه و پیچیده‌ای وجود دارد. به عنوان نمونه، با افزایش مدت پرتودهی از یک حد به بعد (این حد بسته به تازگی و کهنگی بذر، واریته و حتی گونه گیاهی فرق می‌کند)، وزن خشک گیاهچه کاهش و درصد گیاهچه‌های غیرطبیعی افزایش می‌یابد. با تغییر دمای پرتودهی و مدت خیساندن بذر قبل از پرتودهی، این اثر پرتودهی نیز دست‌خوش تغییر می‌گردد. به بیان دیگر، در دماهای مختلف پرتودهی و مدت‌های مختلف خیساندن بذر، مدت مطلوب پرتودهی فرق می‌کند. از این رو، در ترکیب یا ترکیب‌هایی از مؤلفه‌های پرتودهی، وزن خشک گیاهچه حداکثر و درصد گیاهچه‌های غیرطبیعی حداقل است که به آن ترکیب تعادلی گویند (بیولی و بلک^{۱۷}، ۱۹۸۲). برای یافتن این ترکیب تعادلی ۳ نکته قابل تأمل وجود دارد: (۱) عدم امکان به‌دست آوردن ترکیب تعادلی دقیق مؤلفه‌های پرتودهی در شرایط استفاده از فاصله معمول بین سطوح مؤلفه‌ها (مثلاً ۵ سطح دمایی در دامنه ۱۵ تا ۳۵ درجه سلسیوس برابر با ۱۵، ۲۰، ۲۵، ۳۰ و ۳۵ درجه

از پرتودهی با فراصوت برای اهداف متعددی از جمله شکستن خواب بذر (بابائی^۱ و همکاران، ۲۰۲۰) و تغییر در مواد آلی بذر (بونتو^۲ و همکاران، ۲۰۲۱؛ لیب^۳ و همکاران، ۲۰۲۰؛ پولاجینی^۴ و همکاران، ۲۰۱۹) استفاده می‌شود. نتایج بررسی‌ها نشان می‌دهد که پرتودهی بذر با موج‌های فراصوت می‌تواند باعث افزایش بنیه گیاهچه گردد (وانگ^۵ و همکاران، ۲۰۲۰؛ میانو^۶ و همکاران، ۲۰۱۹). بارتون^۷ و همکاران (۱۹۹۶) گزارش نمودند که پرتودهی بذرهای آفتابگردان به مدت ۵۰ تا ۶۰ ثانیه باعث افزایش درصد جوانه‌زنی، طول ریشه‌چه و ساقه‌چه به ترتیب به میزان ۴۰، ۳۲ و ۵ الی ۸ درصد می‌گردد. تیمار بذر گیاه دارویی مورد^۸ با موج‌های فراصوت علاوه بر شکستن خواب، باعث افزایش سرعت جوانه‌زنی، وزن خشک ریشه‌چه و ساقه‌چه شده است (الوندیان^۹ و همکاران، ۲۰۱۳). در مطالعه‌ای، تأثیر این موج‌ها بر بذرهای فلفل دلمه‌ای و تربچه مورد آزمایش قرار گرفت. نتایج نشان داد که حداکثر درصد و سرعت جوانه‌زنی بذر فلفل و تربچه به ترتیب در ۴ و ۷ دقیقه پرتودهی حاصل می‌شود (فاریابی^{۱۰} و همکاران، ۲۰۰۹). گوسوس^{۱۱} و همکاران (۲۰۱۰) برای افزایش جوانه‌زنی بذرهای سبزیجات، از موج‌های فراصوت با فرکانس ۴۰ کیلوهرتز به مدت ۵ تا ۶۰ دقیقه استفاده کردند. آن‌ها گزارش نمودند که بالاترین شاخص رشد گیاهچه، برای تیمار ۴۵ دقیقه پرتودهی به‌دست می‌آید. ماچیکوا^{۱۲} و همکاران (۲۰۱۳) با پرتودهی بذرهای آفتابگردان با موج‌های برخورداری از فرکانس ۴۰ کیلوهرتز با شدت‌های ۴۰، ۶۰، ۸۰ و ۱۰۰ درصد توان

¹ Babaei

² Bonto

³ Lib

⁴ Polachini

⁵ Wang

⁶ Miano

⁷ Barton

⁸ *Myrtus communis*

⁹ Alvandian

¹⁰ Fariabi

¹¹ Goussous

¹² Machikowa

¹³ Yaldagard

¹⁴ Liu

¹⁵ Pitt

¹⁶ Rajabian

¹⁷ Bewley and Black

برخوردار کردن گیاه از مقادیر بهینه‌سازی شده صفات، عملکرد دانه افزایش می‌یابد. با بهینه‌سازی غلظت عناصر معدنی در غده چغندر قند با استفاده از شبکه عصبی مصنوعی، عملکرد بالقوه قند و غده بالاتر (حدود ۱۷ درصد) به دست آمده است (قلی‌پور و همکاران، ۲۰۱۲). اخیراً از این روش برای بهینه‌سازی برخی صفات گیاه توتون در جهت افزایش کمی و کیفی برگ فراوری شده استفاده شده است (صالح‌زاده^۹ و همکاران، ۲۰۱۶). هدف از این بررسی، یافتن ترکیب تعادلی (بهینه‌سازی) مؤلفه‌های پرتو دهی (مدت خیساندن بذر قبل از پرتو دهی، مدت و دمای پرتو دهی) برای افزایش وزن خشک گیاهچه و کاهش درصد گیاهچه‌های غیرطبیعی در ماش بود.

مواد و روش‌ها

آزمایش جوانه‌زنی

به منظور بهینه‌سازی مؤلفه‌های پرتو دهی (رگرسورها؛ متغیرهای ورودی مدل شبکه عصبی) در جهت تولید گیاهچه‌های قوی‌تر و تقلیل درصد گیاهچه‌های غیر طبیعی در ماش (*Vigna radiata*)، یک آزمایش در سال ۱۳۹۳ در آزمایشگاه تکنولوژی بذر دانشگاه شاهرود اجرا گردید. تیمارها شامل شش مدت خیساندن بذر (دو، چهار، شش، هشت، ده و دوازده ساعت) قبل از پرتو دهی، پنج مدت پرتو دهی (صفر، سه، شش، نه و دوازده دقیقه) و چهار دمای پرتو دهی (۱۷، ۲۲، ۲۷ و ۳۲ درجه سلسیوس) بود. بر اساس مشاهده‌های قبلی در خصوص مدت خیساندن، شاهد از سطوح تیماری حذف گردید چون در صورت عدم خیساندن، فرایندهای فیزیولوژیکی جوانه‌زنی شروع نشده و پرتو دهی بذر کم‌تأثیر است.

بیست و پنج عدد بذر برای هر ظرف کشت (ظرف پتری) انتخاب گردید و بعد از ضدعفونی کردن آن‌ها، به ظرف‌های کشت یک بار مصرف استریل شده‌ای که در کف آن‌ها یک عدد کاغذ صافی واتمن بود، منتقل شدند. چینش ظرف‌های کشت در قالب طرح آزمایشی کاملاً تصادفی با ۳ تکرار انجام شد که در آن، فاکتورها به

سلسیوس) در آزمایش و انجام مقایسه میانگین. چون به طور مثال ممکن است دمای ۱۶/۴ درجه سلسیوس، دمای مطلوب باشد که جزو سطوح آزمایش (مثال بالا) نیست. (۲) عملی نبودن وارد کردن سطوح با مقیاس کوچک هر یک از مؤلفه‌ها در آزمایش (مثلاً فاصله دمایی ۰/۱ درجه سلسیوس به جای ۵ درجه سلسیوس)؛ زیرا تعداد ترکیب‌های تیماری بی‌شماری حاصل شده و اجرای آزمایش با مشکل مواجه می‌گردد. به عنوان نمونه، در دامنه دمایی ۱۵ تا ۳۵ درجه سلسیوس با فاصله دمایی ۰/۱ درجه سلسیوس، ۲۰۱ سطح دمایی وجود دارد. (۳) عدم امکان استفاده از روش‌های رگرسوونی برای درون‌یابی^۱ به علت این‌که تعداد متغیرهای پاسخ (وزن خشک گیاهچه و درصد گیاهچه‌های غیرطبیعی) بیش از یک می‌باشد و به احتمال زیاد، ترکیب تعادلی مؤلفه‌های پرتو دهی برای متغیرهای پاسخ یک‌سان نیست. خوشبختانه استفاده از روش ریاضی شبکه عصبی مصنوعی برای درون‌یابی ترکیب تعادلی در چنین شرایطی، یک روش کارآمد به شمار می‌رود (کال^۲ و همکاران، ۲۰۰۵؛ روحانی^۳ و همکاران، ۲۰۰۹).

شبکه عصبی مصنوعی یک سامانه پردازشی داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده پردازنده‌های کوچک و بسیار زیاد می‌گذارد. از شبکه عصبی استفاده‌های زیادی در کشاورزی به عمل آمده است. به عنوان نمونه می‌توان به پیش‌بینی متغیرهای پیوسته‌ای مانند رطوبت خاک (چانگ و اسلام^۴، ۲۰۰۰)، نمونه برداری (زانگ و باریون^۵، ۲۰۰۶)، تخمین بیوماس و عملکرد دانه (دراموند^۶ و همکاران، ۲۰۰۳؛ جین و لئو^۷، ۱۹۹۷) اشاره نمود. قلی‌پور^۸ و همکاران (۲۰۱۳) با استفاده از شبکه عصبی، صفات‌های مؤثر بر عملکرد دانه جو را بهینه‌سازی نموده و بیان داشتند که با انجام اصلاح نباتات در جهت

¹ Interpolation

² Kaul

³ Rohani

⁴ Chang and Islam

⁵ Zhang and Barrion

⁶ Drummond

⁷ Jin and Liu

⁸ Gholipoor

⁹ Salehzadeh

$$f\left(\sum W_{ij}X_i\right) = \frac{e^{\left(\sum_{i=1,j=1}^n W_{ij}X_i\right)} - e^{-\left(\sum_{i=1,j=1}^n W_{ij}X_i\right)}}{e^{\left(\sum_{i=1,j=1}^n W_{ij}X_i\right)} + e^{-\left(\sum_{i=1,j=1}^n W_{ij}X_i\right)}}$$

• تابع سکانت هایپربولیک:

$$f\left(\sum W_{ij}X_i\right) = \frac{2e^{\left(\sum_{i=1,j=1}^n W_{ij}X_i\right)}}{e^{2\left(\sum_{i=1,j=1}^n W_{ij}X_i\right)} + 1}$$

• تابع گوس:

$$f\left(\sum W_{ij}X_i\right) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{\left[\left(\sum_{i=1,j=1}^n W_{ij}X_i\right) - \mu\right]^2}{2\sigma^2}}$$

که در آن W وزن، X ورودی مدل، e عدد نپر، π عدد پی و σ انحراف معیار می‌باشند. برای ارزیابی قابلیت شبکه عصبی پرسپترون در پیش‌بینی تغییرات خروجی مدل، از همبستگی، میانگین خطای مطلق^۳ (MAE)، خطای استاندارد نسبی^۴ (RSE) و مجذور میانگین مربعات خطا^۵ (RMSE) استفاده گردید. رابطه ۳ شاخص شاخص اخیر به شرح زیر است:

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|$$

$$RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}}{Ybar}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}$$

که آن Y_i خروجی مشاهده شده، $Ybar$ میانگین خروجی مشاهده شده، و \hat{Y}_i خروجی برآورد شده می‌باشند.

بهینه‌سازی رگرورها در جهت افزایش وزن خشک گیاهچه و کاهش درصد گیاهچه‌های غیرطبیعی، در سه مرحله صورت گرفت (قلی‌پور و همکاران، ۲۰۱۲؛ صالح‌زاده و همکاران، ۲۰۱۶):

(۱) ابتدا در بین رگرورها، رگروری که رابطه قوی‌تری (همبستگی بالاتری) با وزن خشک گیاهچه و درصد گیاهچه‌های غیرطبیعی داشت (مدت پرتودهی)، به عنوان خروجی، وارد مدل شبکه عصبی گردید. وزن خشک گیاهچه، درصد گیاهچه‌های غیرطبیعی، مدت خیساندن بذر و دمای پرتودهی به عنوان ورودی‌های مدل شبکه عصبی در نظر گرفته شدند. سپس داده‌های به طور تصادفی پشت سرهم قرار گرفته، به دو قسمت

صورت فاکتوریل ترکیب شده بودند. از بین صفات اندازه‌گیری شده، درصد گیاهچه‌های غیر طبیعی و وزن خشک گیاهچه (متغیرهای خروجی مدل شبکه عصبی) در تجزیه و تحلیل‌ها استفاده گردید.

بهینه‌سازی رگرورها با استفاده از شبکه عصبی

ابتدا داده‌های مربوط به ورودی و خروجی مدل به طور تصادفی پشت سرهم قرار داده شده و به دو قسمت داده‌های آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم گردیدند. سپس با استفاده از رابطه زیر، داده‌ها استاندارد شدند:

$$Y_i = 0.8 \times \frac{X_i - X_{min}}{X_{max} - X_{min}} + 0.1$$

که در آن Y_i داده استاندارد شده، X_i داده استاندارد نشده، X_{min} کوچک‌ترین داده، و X_{max} بزرگترین داده می‌باشد. با استفاده از این رابطه، داده‌های ورودی بین ۰/۱ و ۰/۹ قرار می‌گیرند.

در این مطالعه از شبکه عصبی چند لایه پرسپترون استفاده شد. اگر تعداد نرون‌های لایه پنهان و نیز داده‌های آموزش به مقدار کافی باشند، آن گاه شبکه چند لایه پرسپترون می‌تواند به طور واقعی هر تابع را با هر دقت دلخواه تقریب بزند (کال و همکاران، ۲۰۰۵؛ روحانی و همکاران، ۲۰۰۹). شبکه چند لایه پرسپترون 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 واقعی Z^q است که تا جای ممکن، به خروجی مطلوب d^q متناظر با خود نزدیک باشد. با استفاده از نرم‌افزار QNET، از الگوریتم پس‌انتشار^۱ برای آموزش شبکه استفاده گردید. تعداد لایه‌های پنهان مورد استفاده یک و دو عدد بود. برای هر لایه پنهان، یکی از چهار تابع انتقال^۲ (تابع فعال‌سازی) زیر مورد استفاده قرار گرفت:

• تابع سیگموئید:

$$f\left(\sum W_{ij}X_i\right) = \frac{1}{1 + e^{-\left(\sum_{i=1,j=1}^n W_{ij}X_i\right)}}$$

• تابع تانژانت هایپربولیک:

³ Mean absolute error (MAE)

⁴ Relative standard error (RSE)

⁵ Root mean square of error (RMSE)

¹ Back propagation

² Transfer function

نتایج و بحث

نتایج تجزیه واریانس نشان داد که همانند مدت پرتودهی، تأثیر مدت خیساندن بذر و دمای پرتودهی بر وزن خشک گیاهچه و درصد گیاهچه‌های غیر طبیعی معنی‌دار بود. علاوه بر این، برهمکنش آن‌ها نیز معنی‌دار به‌دست آمد (جدول ۲). به منظور ارزیابی مدل‌های شبکه عصبی برای (۱) توابع فعال‌سازی مختلف، (۲) تعداد لایه‌های پنهان و (۳) تعداد نرون در هر لایه پنهان، از شاخص‌های آماری استفاده می‌شود. ترکیب این سه عامل ممکن است بیش از ۵۰ گزینه (سناریو) را ایجاد نماید که ارائه شاخص‌های آماری برای کلیه این سناریوها جدولی حجیم و غیر ضرور را به دنبال دارد. بر همین اساس، پس از انتخاب بهترین تعداد لایه پنهان و تعداد نرون در لایه پنهان بر اساس شاخص‌های آماری همبستگی، میانگین خطای مطلق، خطای استاندارد نسبی و مجذور میانگین مربعات خطا، تنها به ارائه این شاخص‌ها برای توابع فعال‌سازی مورد آزمون بسنده گردید (جدول ۳).

در شکل ۱، نتایج روند تغییرات مقادیر پیش‌بینی شده توسط مدل شبکه عصبی در مرحله آزمون برای تابع فعال‌سازی سکانت هاپرپولیک آورده شده است. انطباق خوب خط رگرسیونی با خط ۱:۱ در مرحله آزمون نیز از مناسب بودن این تابع فعال‌سازی حکایت دارد. به طوری که در شکل ۲، دیده می‌شود، ورودی‌های این مدل، مؤلفه‌های پرتودهی می‌باشند. به طور مور انتظار در اغلب موارد، میزان این انطباق در مرحله آموزش بالاتر از مرحله آزمون می‌باشد (قلی‌پور و همکاران، ۲۰۱۲؛ ۲۰۱۳).

شکل ۱ به خوبی نشان می‌دهد که مقدارهای برآورد شده توسط مدل شبکه عصبی و مقدارهای مشاهده شده وزن خشک گیاهچه به خوبی در کل محدوده دامنه تغییرات داده‌ها توزیع شده‌اند. در این بررسی، ساختار ۳:۳:۲ مدل شبکه عصبی (شکل ۲) مناسب تشخیص داده شد. به بیان دیگر، وجود سه نرون در لایه پنهان توانست کارکرد مدل را به بالاترین سطح ممکن ارتقاء دهد.

داده‌های آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم گردیدند. سناریوهای متفاوتی مورد آزمون قرار گرفت و از بین آن‌ها، مدل برتر انتخاب گردید. سناریوها شامل ترکیبی از تعداد لایه پنهان، تعداد نرون در هر لایه پنهان و تابع انتقال بود. شاخص انتخاب مدل برتر، شاخص‌های آماری همبستگی، میانگین خطای مطلق، خطای استاندارد نسبی و مجذور میانگین مربعات خطا بودند. سپس بر اساس مدل برتر، مدت پرتودهی برآورد گردید. هر کدام از این مدت‌های پرتودهی برآورد شده می‌تواند به طور بالقوه مدت پرتودهی مطلوب برای حصول حداکثر وزن خشک گیاهچه و کم‌ترین درصد گیاهچه‌های غیرطبیعی باشد. علت این امر، چند متغیره (در اینجا دو متغیره) بودن خروجی مدل می‌باشد (قلی‌پور و همکاران، ۲۰۱۲). مقادیری از مدت‌های پرتودهی که در محدوده مدت‌های پرتودهی مورد آزمون بودند انتخاب شدند که قسمتی (هفت ردیف) از آن‌ها در جدول ۱ آورده شده است.

(۲) در این مرحله، با استفاده از داده‌های اصلی و داده‌های برآورد شده در مرحله قبل، دو رگرسور دیگر یعنی مدت خیساندن بذر و دمای پرتودهی به عنوان خروجی وارد مدل گردید. ورودی‌های مدل شامل وزن خشک گیاهچه، درصد گیاهچه‌های غیرطبیعی و مدت پرتودهی بود. همانند مرحله اول، داده‌ها به دو دسته تقسیم شده و سناریوهای مختلفی مورد بررسی قرار گرفت و مدل برتر انتخاب گردید. سپس با استفاده از این مدل برتر، اقدام به پیش‌بینی مدت خیساندن بذر و دمای پرتودهی گردید. مقادیری از این دو متغیر که در دامنه سطوح مورد آزمون آن‌ها قرار داشت انتخاب گردید (جدول ۱).

(۳) پس از این‌که در دو مرحله قبل، مقدار متغیرهای مستقل وارد مدل شبکه عصبی گردید و مقدار آن‌ها برآورد شد، در این مرحله برای پیش‌بینی وزن خشک گیاهچه و درصد گیاهچه‌های غیر طبیعی مورد استفاده قرار گرفت. شایان ذکر است که در این مرحله، از مدل شبکه عصبی ایجاد شده در ابتدای محاسبات استفاده شد (جدول ۱).

جدول ۱. قسمتی از نتایج مربوط به مقادیر برآورد شده ورودی و خروجی مدل شبکه عصبی طی مراحل سه‌گانه بهینه‌سازی

Table 1. Part of the results regarding predicted amounts for input and output of neural network model during three-step optimization stages

مدت خیساندن بذر (ساعت) Seed pre-soaking duration (h)	دمای پرتودهی (°C) Irradiation temperature (°C)	مدت پرتودهی (ساعت) Irradiation duration (h)	جوانه‌های غیرطبیعی (درصد) Abnormal seedlings (%)	وزن خشک گیاهچه (گرم) Seedling dry weight (g)
3.054	18.545	0.215	1.584	0.098
3.958	28.452	7.549	0	0.108
7.554	22.215	6.548	2.545	0.126
11.251	17.961	5.304	0	0.152
11.554	19.145	9.548	1.245	0.104
7.564	25.125	5.428	4.949	0.145
3.854	30.245	6.865	0.458	0.125

جدول ۲. میانگین مربعات وزن خشک گیاهچه و درصد جوانه‌های غیرطبیعی

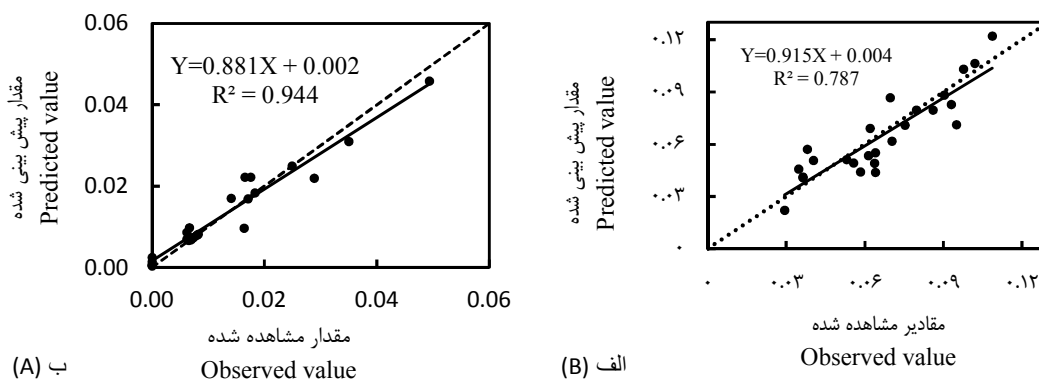
Table 2. Mean squares of seedling dry weight and abnormal seedlings percent

منابع تغییر Sources of variation	درجه آزادی Degree of freedom	وزن خشک گیاهچه Seedling dry weight	درصد گیاهچه‌های غیر طبیعی Abnormal seedlings percent
خیساندن بذر (P) Seed pre-soaking	5	0.01055**	0.00326**
دمای پرتودهی (T) Irradiation temperature	3	0.27025**	0.00202**
پرتودهی (U) Irradiation	4	0.06485**	0.06750**
P×T	15	0.14054**	0.0018900
P×U	20	0.06349**	0.00191**
T×U	12	0.05355**	0.00276**
P×T×U	60	0.05025**	0.00101**
خطا Error	240	0.00059	0.000441

جدول ۳. شاخص‌های آماری مربوط به توابع فعال‌سازی مختلف

Table 3. Statistical indices regarding different activation functions

تابع فعال‌سازی Activation function	خروجی مدل	Model output	RMSE	MAE	RSE	r
سیگموئید	وزن خشک گیاهچه	Seedling dry weight	0.013	0.010	0.195	0.78
Sigmoid	درصد گیاهچه‌های غیرطبیعی	Abnormal seedlings percentage	0.005	0.003	0.348	0.92
گوس	وزن خشک گیاهچه	Seedling dry weight	0.012	0.009	0.179	0.81
Gaussian	درصد گیاهچه‌های غیرطبیعی	Abnormal seedlings percentage	0.004	0.003	0.281	0.94
تانژانت هایپربولیک	وزن خشک گیاهچه	Seedling dry weight	0.010	0.005	0.148	0.88
Tangent hyperbolic	درصد گیاهچه‌های غیرطبیعی	Abnormal seedlings percentage	0.002	0.001	0.170	0.98
سکانت هایپربولیک	وزن خشک گیاهچه	Seedling dry weight	0.002	0.002	0.042	0.99
Secant hyperbolic	درصد گیاهچه‌های غیرطبیعی	Abnormal seedlings percentage	0.001	0.001	0.085	0.97




شکل ۱. روند تغییرات مقادیر پیش‌بینی شده توسط تابع فعال‌سازی سکانت هایپربولیک در مقابل مقادیر مشاهده شده درصد گیاهچه‌های غیرطبیعی (الف) و وزن خشک گیاهچه ماش (ب) در مرحله آموزش

Fig. 1. Changes in the predicted values by secant hyperbolic activation function against observed values of abnormal seedlings percent (A) and seedling dry weight of mung bean (B)

غیرطبیعی برای ترکیب تعادلی دمای پرتودهی ۱۷/۹۶ درجه سلسیوس، مدت پرتودهی ۵/۳ دقیقه و خیساندن ۱۱/۲۵ ساعته بذر به دست آمد. نتایج روش معمول یافتن بهترین ترکیب تعادلی (ترکیب تیماری) مؤلفه‌های پرتودهی [مقایسه میانگین (نتایج ارائه نشده)] حاکی از آن بود که بیش‌ترین وزن خشک گیاهچه (۰/۱۲ گرم) در ترکیب تیماری شامل دمای پرتودهی ۱۷ درجه سلسیوس، مدت پرتودهی شش دقیقه و خیساندن ۱۰ ساعته بذر قبل از پرتودهی به دست آمد. این در حالی است که بهترین ترکیب تیماری برای حصول کم‌ترین درصد جوانه‌های غیرطبیعی در روش مقایسه میانگین، برابر با دمای پرتودهی ۲۲ درجه سلسیوس، مدت پرتودهی سه دقیقه و خیساندن ۱۰ ساعته بذر قبل از پرتودهی بود که منجر به تولید ۰/۱۶ درصد گیاهچه‌های غیرطبیعی شد. با مقایسه نتایج حاصل از دو روش مشخص می‌گردد که در شرایط استفاده از شبکه عصبی، وزن خشک گیاهچه حدود ۲۷ درصد بالاتر از روش معمول است و هم‌چنین، درصد گیاهچه‌های غیرطبیعی از ۰/۱۶ درصد در روش معمول به صفر در روش شبکه عصبی تقلیل می‌یابد.

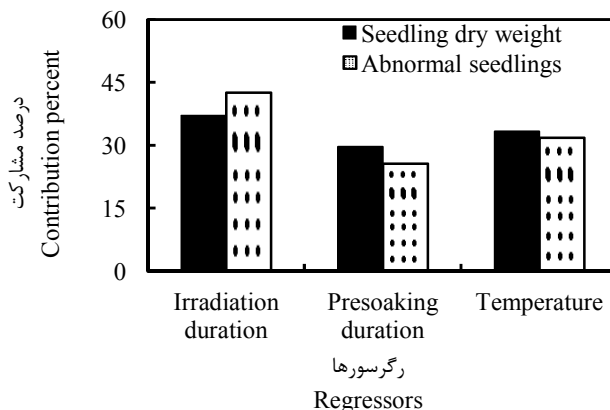
با این‌که وزن خشک گیاهچه و درصد گیاهچه‌های غیرطبیعی از لحاظ میزان مشارکت رگرسورها در توجیه تغییرات‌شان اندکی با هم تفاوت داشتند، ولی به طور کلی، ترتیب اولویت رگرسورها از نظر تحت تأثیر قرار دادن متغیرهای پاسخ (ضریب همبستگی بالاتر) به صورت مدت پرتودهی < دمای پرتودهی < مدت خیساندن بذر بود (شکل ۳). این امر اهمیت نسبی هر سه مؤلفه پرتودهی را به خوبی نشان داده و این نکته را گوشزد می‌کند که نادیده گرفتن یک مؤلفه می‌تواند منجر به عدم حصول نتیجه مطلوب گردد. تاکنون هیچ گزارش منتشر شده‌ای در خصوص اهمیت نسبی مؤلفه‌های پرتودهی در دست نیست. با توجه به واکنش متفاوت گیاهان مختلف به پرتودهی لازم است که میزان تأثیر پذیری گیاهان دیگر از این مؤلفه‌ها نیز مطالعه گردد.

نتایج بهینه‌سازی (درون‌یابی ترکیب تعادلی مؤلفه‌های پرتودهی) توسط مدل شبکه عصبی نشان داد که بالاترین رشد گیاهچه و کم‌ترین درصد گیاهچه‌های غیرطبیعی به ترتیب برابر با ۰/۱۵۲ گرم و صفر درصد بود. این مقدار وزن خشک گیاهچه و درصد گیاهچه‌های



شکل ۲. ساختار ۳:۳:۲ شبکه عصبی به کار رفته در تجزیه و تحلیل داده‌ها

Fig. 2. Structure of 3:3:2 neural network used in data analysis



شکل ۳. میزان مشارکت رگرسورها (مؤلفه‌های پرتودهی) در توجیه تغییرات وزن خشک گیاهچه و درصد گیاهچه‌های غیرطبیعی ماش

Fig. 3. The participation of regulators (irradiation components) in justifying changes in seedling dry weight and percentage of abnormal mung bean seedlings

دارد. در صورتی که از پرتودهی در شرایط مناسب (دما و مدت خیساندن مطلوب) استفاده شود، موج‌های فراصوت تأثیر مثبت خود را به جای می‌گذارند. تأثیر مثبت به دست آمده از پرتودهی بر رشد گیاهچه در این بررسی با نتایج گزارش شده بر گیاهان دیگر مطابقت دارد (گوسوس و همکاران، ۲۰۱۰؛ ماچیکوا و همکاران، ۲۰۱۳). شایان ذکر است که در مدت‌های خیلی طولانی پرتودهی، یا دمای بالای پرتودهی، اثرات مثبت پرتودهی خنثی شده و حتی در مورد بذره‌های گیاهان روغنی، اثر آن کاهنده می‌گردد. یکی از علت این امر، دنا توره شدن پروتئین‌ها و کاهش فعالیت آنزیم‌های هیدرولیتیک می‌باشد (بوممن^۵ و همکاران، ۱۹۹۲). علاوه بر این، تولید رادیکال‌های آزاد نظیر پروکسید هیدروژن و هیدروکسیل بیش تر می‌گردد.

این امر به روشنی مشخص می‌کند که در روش مقایسه میانگین، بهترین ترکیب تیماری را نمی‌توان به دقت تعیین نمود و شبکه عصبی به لحاظ برخورداری از ویژگی‌های منحصر به فرد و بسیار دقیق (کاشی^۱ و همکاران، ۲۰۱۳؛ هانگ^۲ و همکاران، ۲۰۱۰؛ گرین^۳ و همکاران، ۲۰۰۷؛ پارک^۴ و همکاران، ۲۰۰۵؛ کال و همکاران، ۲۰۰۵) می‌تواند این مشکل را رفع نموده و یک ترکیب تعادلی مؤلفه‌های پرتودهی را به دست آورد. در برخی از ترکیبات تیماری، وزن خشک گیاهچه کمتر از شاهد بدست آمد که بر اهمیت مضاعف یافتن ترکیب تعادلی مؤلفه‌های پرتودهی دلالت دارد. ضریب همبستگی بالا برای تابع فعال‌سازی سکانت هایپربولیک (جدول ۳) بر صحت و دقت بالای این برآورد دلالت

¹ Kashi

² Huang

³ Green

⁴ Park

⁵ Bommannan

براساس نتایج می‌توان اظهار داشت که به‌علت وجود برهمکنش بسیار معنی‌دار بین مؤلفه‌های پرتودهی (مدت خیساندن بذر قبل از پرتودهی، مدت و دمای پرتودهی)، با تغییر کمیت هر مؤلفه، اثر مؤلفه (های) دیگر بر بنیه گیاهچه ماش نیز تغییر شدیدی می‌یابد. از این‌رو یافتن ترکیب تعادلی مؤلفه‌های پرتودهی می‌تواند در بهبود جوانه‌زنی بذر ماش بسیار مؤثر واقع شود. در همین راستا، شبکه عصبی کارآمدتر از مقایسه میانگین بود. از این‌رو می‌توان از شبکه عصبی به عنوان روش تکمیلی در این‌گونه بررسی‌ها استفاده نمود. بهترین ترکیب تیماری شامل دمای حدود ۱۷/۹۶ درجه سلسیوس، خیساندن ۱۱/۲۵ ساعت و پرتودهی به مدت ۵/۳ دقیقه بود.

این رادیکال‌های آزاد منجر به پروکسیده شدن لیپیدهای غشای سلولی شده و نشت الکترولیت‌ها را موجب می‌گردند (بارتون و همکاران، ۱۹۹۶). سازوکار تأثیر پرتودهی مربوط به پدیده ایجاد حفره^۱ ناشی از موج‌های فراصوت است که منجر به تغییر در نفوذپذیری غشای سلولی می‌گردد (بوممن و همکاران، ۱۹۹۲). علاوه بر این، افزایش جنبش^۲ محیط مایع و در نتیجه، بیش‌تر شدن انتقال توده‌ای مواد بین اندامک‌ها در درون سلول و بیش‌تر شدن سرعت واکنش‌های بیوشیمیایی نیز از اثرهای مثبت پرتودهی به شمار می‌رود (بار^۳، ۱۹۸۸).

نتیجه‌گیری

منابع

- Alvandian, S., Vahedi, A. and Taghizadeh, R. 2013. Study of ultrasonic waves and low temperature effects on germination of myrtle (*Myrtus communis*). Journal of Seed Research, 3(3): 21-31. [In Persian with English Summary].
- Babaei, A., Alebrahim, M.T., MacGregor, D.R., Khatami, A. and Hasani_Nasab, R. 2020. Evaluation of ultrasound technology to break seed dormancy of common lambsquarters (*Chenopodium album*). Food Science and Nutrition, 8(6): 2662-2669. <https://doi.org/10.1002/fsn3.1547>
- Bar, R. 1988. Ultrasound-enhanced bioprocesses: cholesterol oxidation by *Rhodococcus erythropolis*. Biotechnology and Bioengineering, 32: 655-663. <https://doi.org/10.1002/bit.260320510>
- Barton, S., Bullock, C. and Weir, D. 1996. The effects of ultrasound on the activities of some glucosidase enzymes of industrial importance. Enzyme and Microbial Technology, 18(3): 190-194. [https://doi.org/10.1016/0141-0229\(95\)00092-5](https://doi.org/10.1016/0141-0229(95)00092-5)
- Bewley, J.D. and Black, M. 1982. Physiology and biochemistry of seeds in relation to germination: volume 2: viability, dormancy, and environmental control. Springer Science & Business Media. https://doi.org/10.1007/978-3-642-68643-6_2
- Bommannan, D., Menon, G.K., Okuyama, H., Elias, P.M. and Guy, R.H. 1992. Sonophoresis: II Examination of the mechanism(s) of ultrasound enhanced transdermal drug delivery. Pharmaceutical Research, 9(8): 1043-1047. <https://doi.org/10.1023/A:1015806528336>
- Bonto, A.P., Tiozon Jr, R.N., Sreenivasulu, N. and Camacho, D.H. 2021. Impact of ultrasonic treatment on rice starch and grain functional properties: A review. Ultrasonics Sonochemistry, 71: 105383. <https://doi.org/10.1016/j.ultsonch.2020.105383>
- Chang, D.H. and Islam, S. 2000. Estimation of soil physical properties using remote sensing and artificial neural network. Remote Sensing of Environment, 74: 534-544. [https://doi.org/10.1016/S0034-4257\(00\)00144-9](https://doi.org/10.1016/S0034-4257(00)00144-9)

¹ Cavitations

² Movement

³ Bar

- Drummond, S.T., Sudduth, K.A., Joshi, A., Birrell, S.J. and Kitchen, N.R. 2003. Statistical and neural methods for site-specific yield prediction. Transactions of the American Society of Agricultural and Biological Engineers (ASABE), 46(1): 5-14. <https://doi.org/10.13031/2013.12541>
- Fariabi, A., Zarmanesh, H., Keshvari, M. and Abdoli, N. 2009. Effect of ultrasonic waves on physiological and morphological processes of germination in bell pepper (*Capsicum annum*) and radish (*Rhaphnus sativus*). Proceedings of first national symposium of seed science and technology, Gorgan, Iran. [In Persian with English Summary].
- Gholipoor, M., Emamgholizadeh, S., Hassanpour, H., Shahsavani, D., Shahoseini, H., Baghi, M. and Karim, A. 2012. The optimization of root nutrient content for increased sugar beet productivity using an artificial neural network. International Journal of Plant Production, 6: 429-442.
- 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): 1-18.
- Goussous, S.J., Samarah, N.H., Alqudah, A.M. and Othman, M.O. 2010. Enhancing seed germination of four crops species using an ultrasonic technique. Experimental Agriculture, 46(2): 231-242. <https://doi.org/10.1017/S0014479709991062>
- Green, T.R., Salas, J.D., Martinez, A. and Erskine, R.H. 2007. Relating crop yield to topographic attributes using spatial analysis neural networks and regression. Geoderma, 139(1): 23-37. <https://doi.org/10.1016/j.geoderma.2006.12.004>
- Huang, Y., Lan, Y., Thomson, S.J., Fang, A., Hoffmann, W.C. and Lacey, R.E. 2010. Development of soft computing and applications in agricultural and biological engineering. Computer, Electronic and Agriculture, 71: 107-127. <https://doi.org/10.1016/j.compag.2010.01.001>
- Jin, Y.Q., and Liu, C. 1997. Biomass retrieval from high-dimensional active/passive remote sensing data by using artificial neural networks. International Journal of Remote Sensing 18(4): 971-979. <https://doi.org/10.1080/014311697218863>
- Kashi, H., Emamgholizadeh, S., Ghorbani, H. and Hashemi, A.I. 2013. Estimation of soil Infiltration in agricultural and pasture lands using artificial neural networks and multiple regressions. Journal of Environmental Erosion Researches, 9: 42-56. [In Persian with English Summary].
- Kaul, M., Hill, R.L. and Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. Agricultural Systems, 85(1): 1-18. <https://doi.org/10.1016/j.agsy.2004.07.009>
- Lib, Y., Pana, D., Caoa, J., Liua, L., Zhoucd, X. and Barbae, F.J. 2020. Characterizing physicochemical, nutritional and quality attributes of wholegrain *Oryza sativa* L. subjected to high intensity ultrasound-stimulated pre-germination. Food Control, 108: 106827. <https://doi.org/10.1016/j.foodcont.2019.106827>
- Liu, Y., Takatsuki, H., Yoshikoshi, A., Wang, B.C. and Sakanishi, A. 2003. Effects of ultrasound on the growth and vacuolar H⁺-ATPase activity of aloe arborescens callus cells. Colloids and Surfaces (Biointerfaces), 32(2): 105-116. [https://doi.org/10.1016/S0927-7765\(03\)00150-4](https://doi.org/10.1016/S0927-7765(03)00150-4)
- Machikowa, T., Kulrattanak, T. and Wonprasaid, S. 2013. Effects of ultrasonic treatment on germination of synthetic sunflower seeds. International Journal of Agricultural, Biosystems Science and Engineering, 7(1): 1-3.
- Miano, A.C., Sabadoti, V.D. and Augusto P.E.D. 2019. Combining ionizing irradiation and ultrasound technologies: effect on beans hydration and germination. Journal of Food Science, 84: 3179-3185. <https://doi.org/10.1111/1750-3841.14819>

- Park, S.J., Hwang, C.S. and Vlek, P.L.G. 2005. Comparison of adaptive techniques to predict crop yield response under varying soil and land management conditions. *Agricultural Systems*, 85: 59-81. <https://doi.org/10.1016/j.agsy.2004.06.021>
- Pitt, W.G. and Ross, S.A. 2003. Ultrasound increases the rate of bacterial cell growth. *Biotechnology Progress*, 19(3): 1038-1044. <https://doi.org/10.1021/bp0340685>
- Polachini, T.C., Mulet, A., Telis-Romero, J. and Cárcel, J.A. 2019. Influence of high-intensity ultrasound application on the kinetics of sugar release from acid suspensions of artichoke (*Cynara scolymus*) biomass. *Chemical Engineering and Processing-Process Intensification*, 145: 107-113. <https://doi.org/10.1016/j.cep.2019.107681>
- Rajabian, S. 2012. Effect of ultrasonic waves and pseudomonas bacteria on growth and growth and yield of corn. MSc thesis, Shahrood University of Technology, Shahrood, Iran. [In Persian with English Summary].
- Rohani, A., Rangbar, A., Abbasporfard, M.H., Ajabshirchi, Y. and Valizadeh, M. 2009. Prediction of repair and maintenance costs for two-wheel drive tractor using artificial neural network and comparison with regression. *Journal of Natural Resources and Agricultural Sciences*, 16: 1-12 [In Persian with English Summary].
- Salehzadeh, H., Gholipoor, M., Abbasdokht, H., Baradaran, M. 2016. Optimizing plant traits to increase yield quality and quantity in tobacco using artificial neural network. *International Journal of Plant Production*, 10: 97-108.
- Wang, J., Bian, Z., Wang, S. and Zhang, L. 2020. Effects of ultrasonic waves, microwaves, and thermal stress treatment on the germination of Tartary buckwheat seeds. *Journal of Food Process Engineering*, 43: e13494. <https://doi.org/10.1111/jfpe.13494>
- Yaldagard, M., Mortazavi, S.A. and Tabatabaie, F. 2008a. Influence of ultrasonic on the germination of barley seed and its alpha-amylase. *African Journal of Biotechnology*, 7: 2456-2471.
- Yaldagard, M., Mortazavi, S.A. and Tabatabaie, F. 2008b. The effect of ultrasound in combination with thermal treatment on the germinated barley's alpha-amylase activity. *Korean Journal of Chemical Engineering*, 25(3): 517-523. <https://doi.org/10.1007/s11814-008-0087-1>
- Zhang, W.J. and Barrion, A.T. 2006. Function approximation and documentation of sampling data using artificial neural networks. *Environmental Monitoring and Assessment*, 122(1): 185-201. <https://doi.org/10.1007/s10661-005-9173-6>

Research Article

Evaluating the Optimization of Irradiation Components of Mung Bean (*Vigna radiata*) Seeds with Ultrasound for Increased Seedling Vigor, Using Artificial Neural Network

Shamsaldin Skandarnejad¹, Manoochehr Gholipoor^{2, *}, Hassan Makarian²

Extended Abstract

Introduction: A large number of experimental evidence indicates the positive effect of irradiating the seed with ultrasonic waves; so that irradiation causes the production of a more vigorous seedling. Conversely, inappropriate intensity and duration of irradiation can impose deleterious effects on seedlings by damaging the enzymatic activity. There are complex inter-and intra-relations between irradiation components (pre-soaking duration, temperature, and duration of irradiation) and response variables [seedling dry weight (SDW) and percent of abnormal seedlings (PAS)]. Therefore the balance values of the irradiation components cannot be precisely obtained by mean comparison. This study aimed to optimize (finding the balance values of) irradiation components for increased SDW, but diminished PAS of mung bean, using an artificial neural network.

Materials and Methods: A factorial experiment was conducted based on a completely randomized design with three replications. The factors were six pre-soaking durations (2, 4, 6, 8, 10, and 12 hours), 5 irradiation durations (0, 3, 6, 9 and 12 minutes), and 4 irradiation temperatures (17, 22, 27, and 32 °C). The 25 seeds were chosen for each petri dish. The multi-layer perceptron neural network was used to quantify the relations between variables; the experimental factors were used as the input (regressors), and PAS and SDW as the output of the model (response variables).

Results: The analysis of variance results indicated that the simple and interactive effects of factors were significant on PAS and SDW. The structure 3:3:2 of the neural network, which is based on Secant Hyperbolic function, was suitable. The SDW and PAS were negligibly different for the contribution of the factors in determining their changes. In terms of relative contribution, the factors ranked from higher to lower as irradiation duration, irradiation temperature, and pre-soaking duration. The optimized values of components of irradiation by the neural network were irradiation temperature of 17.96 °C, irradiation duration of 5.3 minutes, and pre-soaking duration of 11.25 hours. For these components, SDW was 27% higher, and PAS tended to be 0.6% lower, compared to the best component combination gotten by mean comparison.

Conclusion: Due to the highly strong interaction of irradiation components on seedling growth, the effect of component (s) tends to be changed intensively with changing the quantity of each component. In terms of finding the best combination of irradiation components, the neural network was more efficient than the mean comparison. Therefore, the neural network could be used as a complementary procedure in such investigations.

Keywords: Irradiation duration, Irradiation temperature, Pre-soaking duration, Seedling vigour

Highlights:

- 1- Irradiation components including irradiation duration and temperature, and pre-soaking duration affected seedling growth.
- 2- Inappropriate irradiation components diminished seedling growth to the below of no-irradiation conditions.
- 3- The optimum (balanced) levels of irradiation components increased seedling growth remarkably.

¹ Ph.D. Student of Shahrood University, Department of Agriculture, Shahrood, Iran

² Associate Professor of Shahrood University, Department of Agriculture, Shahrood, Iran