

## بهینه‌سازی کوددهی نیتروژن و تراکم کشت برای افزایش عملکرد برگ و دانه و سمه با استفاده از شبکه عصبی مصنوعی

### Optimization of Nitrogen Fertilization and Planting Density for Enhancing the Leaf and Seed Performances of Woad Using Artificial Neural Network

منوچهر قلی‌پور<sup>۱\*</sup>، حمیده نیکبخت رابینی<sup>۲</sup> و علی انصوری<sup>۳</sup>

تاریخ پذیرش: ۹۹/۱۲/۱۳

تاریخ دریافت: ۹۹/۰۷/۲۰

#### چکیده

به‌طور معمول اثرات ۳ یا ۴ سطح از متغیرهای مستقل (در اینجا کود نیتروژن و تراکم کشت) بر متغیرهای وابسته (در اینجا عملکرد برگ و دانه) مورد بررسی قرار گرفته و با استفاده از مقایسه میانگین‌ها، بهترین سطح متغیرهای مستقل پیدا می‌شود. چنین نتایجی شاید خیلی دقیق نباشند. هدف از این بررسی، یافتن میزان دقیق کود نیتروژن و تراکم کشت از طریق درون‌یابی (بهینه‌سازی) برای افزایش عملکرد برگ و دانه و سمه با استفاده از شبکه عصبی مصنوعی (به‌عنوان یک تجزیه تکمیلی) بود. در یک آزمایش زراعی به صورت اسپلیت پلات در مزرعه تحقیقاتی دانشگاه آزاد جیرفت، تأثیر ۴ تراکم کشت (فاکتور اصلی؛ ۱۰، ۱۵، ۲۵ و ۳۵ بوته در مترمربع) و ۴ سطح کود نیتروژن (فاکتور فرعی؛ ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ کیلوگرم در هکتار) بر وزن برگ و دانه و سمه بررسی گردید. نتایج حاصل از تجزیه داده‌ها نشان داد که ساختار شبکه عصبی مبتنی بر ۴ نرون مناسب بود. میزان بهینه‌شده تراکم کشت و کود نیتروژن به ترتیب برابر با ۳۲ بوته در مترمربع و حدود ۷۰ کیلوگرم کود نیتروژن در هکتار بود که توانست عملکرد برگ و دانه را به ترتیب ۶/۳ و ۷/۷ درصد افزایش دهد.

واژه‌های کلیدی: بهره‌وری، دارویی، صنعتی، درون‌یابی

۱ و ۳. به ترتیب، دانشیار و دانش‌آموخته کارشناسی‌ارشد، گروه زراعت و اصلاح نباتات، دانشکده کشاورزی دانشگاه صنعتی شاهرود، شاهرود، ایران  
۲. دانش‌آموخته کارشناسی‌ارشد، گروه زراعت و اصلاح نباتات دانشکده کشاورزی دانشگاه آزاد جیرفت، جیرفت، ایران  
\*: نویسنده مسئول  
Email: manouchehr.gholipoor@gmail.com  
این مقاله مستخرج از پایان‌نامه کارشناسی‌ارشد نویسنده دوم به راهنمایی منوچهر قلی‌پور می‌باشد.

## مقدمه

وسمه Isatis یا نیل با نام انگلیسی Woad و نام علمی *Indigofera tinctoria* L. از خانواده Fabaceae یکی از گیاهان دارویی و رنگی بسیار قدیمی بوده که رشدی ایستاده دارد. این گیاه دومنظوره بوده و علاوه بر خواص دارویی، به لحاظ امکان استخراج رنگ از آن در صنعت نیز کاربرد دارد. اگرچه وسمه گیاهی است چندساله ولی به صورت یک‌ساله کشت می‌گردد. برگ‌های آن به‌عنوان نیل شناخته شده که عصاره و پودر آن در درمان تنگی نفس، سیاه‌سرفه و تپش قلب مفید می‌باشد (بانگر و سارالیا<sup>۱</sup>، 2011). در طب سنتی از عصاره برگ این گیاه (گاهی اوقات مخلوط با عسل یا شیر) برای درمان بیماری‌های صرع، اختلالات عصبی<sup>۲</sup>، آسم<sup>۳</sup>، برونشیت‌ها<sup>۴</sup>، تب، مشکلات معده، کلیه و طحال، به‌عنوان ماده پیش‌گیری‌کننده هاری و به عنوان پماد برای درمان بیماری‌ها و زخم‌های پوستی، زخم معده و بواسیر استفاده می‌شود. عصاره برگ این گیاه برای درمان سوختگی و زخم حیوانات اهلی همچون گاو و اسب نیز کاربرد دارد. تنتور<sup>۵</sup> بذر وسمه در هند برای از بین بردن شپش مورد استفاده قرار می‌گیرد. از پودر ریشه این گیاه در کامرون برای تسکین درد دندان، در تانزانیا برای مداوای آبله فرنگی، سوزاک و سنگ کلیه استفاده می‌شود. در کشور هند، از دم کرده ریشه این گیاه به‌عنوان یک پادزهر در برابر مارگزیدگی و برای درمان نیش عقرب و حشرات استفاده می‌گردد (بانگر و سارالیا، 2011).

هدف این آزمایش، تعیین میزان دقیق نیتروژن و تراکم کشت برای حصول عملکرد برگ (مورد استفاده در رنگرزی) و دانه بالاتر وسمه بود که طی آن، از شبکه عصبی مصنوعی به‌عنوان ابزاری تکمیلی در تجزیه و تحلیل داده‌ها استفاده شد. در روش‌های معمول مقایسه میانگین، شاید نتوان میزان دقیق متغیرهای مستقل (در این مطالعه، کود نیتروژن و تراکم کشت) را یافت و نیاز به تجزیه و تحلیل‌های تکمیلی دارد. برای روشن شدن موضوع فرض کنید که در یک آزمایش، اثر ۴ سطح نیتروژن (صفر، ۵۰، ۱۰۰ و ۱۵۰ کیلوگرم در هکتار) بر عملکرد دانه وسمه بررسی گردد و نتایج مقایسه میانگین عملکرد دانه نشان دهد که ۱۰۰ کیلوگرم نیتروژن در هکتار، بهترین سطح نیتروژن می‌باشد. این سؤال به ذهن متبادر می‌شود که ممکن است ۸۸ کیلوگرم نیتروژن در هکتار بهترین سطح نیتروژن باشد ولی جزو سطوح مورد آزمایش نیست. راه‌حل برطرف

کردن این‌گونه دقت‌های کم در نتیجه‌گیری‌ها، وارد کردن سطوح خیلی زیاد نیتروژن در آزمایش نمی‌باشد چون در عمل، اجرای آن امکان‌پذیر نمی‌باشد. زیرا به‌عنوان مثال اگر به‌جای فاصله ۵۰ کیلوگرم برای سطوح نیتروژن، فاصله سطوح ۱۲/۵ کیلوگرم انتخاب شود، تعداد سطوح نیتروژن از ۴ به ۱۳ افزایش می‌یابد. اگر همین تعداد سطوح (یعنی ۱۳) نیز برای تراکم انتخاب شود، تعداد کرت در هر تکرار برابر با ۱۶۹ می‌شود که خیلی زیاد بوده و اجرای چنین آزمایشی عملی نیست.

راه‌حل مشکل در چنین شرایطی، عبارت از درون‌یابی<sup>۶</sup> یا به بیانی، بهینه‌سازی<sup>۷</sup> متغیرهای مستقل با استفاده از روش رگرسیون چندگانه می‌باشد. چون بهره‌گیری از رگرسیون در جهت درون‌یابی دو یا چند متغیر مستقل برای افزایش یک متغیر وابسته (مثلاً عملکرد دانه) امری میسر و سهل می‌باشد. اگر متغیر وابسته، بیش از یک عدد (مثلاً عملکرد برگ و دانه) باشد، روش‌های رگرسیونی فاقد قابلیت درون‌یابی هستند. خوشبختانه با بهره‌گیری از تکنیک شبکه عصبی مصنوعی به‌عنوان یک روش تجزیه و تحلیل تکمیلی، می‌توان اقدام به درون‌یابی میزان دقیق متغیر یا متغیرهای مستقل برای افزایش میزان متغیرهای وابسته نمود. این درون‌یابی بر اساس تجزیه و تحلیل میزان و نوع پاسخ متغیرهای وابسته به متغیرهای مستقل می‌باشد.

امروزه تکنیک شبکه عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیندها در علوم مختلف کشاورزی به کار گرفته می‌شود. مزیت روش شبکه عصبی، یادگیری مستقیم از روی داده‌ها، بدون نیاز به برآورد مشخصات آماری آن‌ها است (وکیلی-باغمیشه<sup>۸</sup>، 2002). شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه‌ای از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (روحانی و همکاران، ۱۳۸۸؛ کال<sup>۹</sup> و همکاران، 2005؛ تورسیلا<sup>۱۰</sup> و همکاران، 2004). ویژگی دیگر شبکه عصبی، تحمل‌پذیری در مقابل خطا است (آزاده<sup>۱۱</sup> و همکاران، 2006). افزایش ظرفیت اطلاعات و توانایی بیان اثرات متقابل قوی بین متغیرهای ورودی از خصیصه‌های منحصر به فرد شبکه عصبی به‌شمار می‌رود (ایرماک<sup>۱۲</sup> و

6. Interpolation  
7. Optimization  
8. Vakil-Baghmisheh  
9. Kaul  
10. Torrecilla  
11. Azadeh  
12. Irmak

1. Bangar and Saralaya  
2. Nervous disorders  
3. Asthma  
4. Bronchitis  
5. Tincture

سال زراعی ۸۸-۸۹ به صورت کرت‌های خرد شده بر پایه طرح بلوک‌های کامل تصادفی با ۳ تکرار در مزرعه تحقیقاتی دانشگاه آزاد جیرفت انجام شد. ارتفاع این منطقه از سطح دریا ۶۲۶ متر، بارش سالانه ۱۶۶ میلی‌متر و متوسط دمای سالانه برابر با ۲۳/۶ درجه سانتی‌گراد می‌باشد. فاکتور اصلی شامل ۴ سطح نیتروژن (۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ کیلوگرم در هکتار) و فاکتور فرعی شامل ۴ تراکم گیاهی (۱۰، ۱۵، ۲۵ و ۳۵ بوته در مترمربع) بود. تاریخ کشت، تیرماه بود که بذرها به صورت دستی کشت گردیدند. هر کرت فرعی شامل ۴ خط کاشت به طول ۴ متر با فاصله خطوط کاشت ۴۰ سانتی‌متر بود. فاصله بین کرت‌های فرعی به صورت یک ردیف کشت نشده، فاصله بین کرت‌های اصلی به صورت ۲ ردیف کشت نشده در نظر گرفته شد. عمق کشت حدود یک سانتی‌متر بود. نیتروژن (کود اوره) به ۳ قسمت تقسیم و در مراحل کشت، بعد از تنک کردن و قبل از گل‌دهی به خاک اضافه گردید. برای محاسبه عملکرد برگ و دانه، دو ردیف میانی کرت پس از حذف حاشیه برداشت گردید.

#### شبکه عصبی مصنوعی و بهینه‌سازی

ابتدا معادله رگرسیون چندگانه<sup>۹</sup> رگرسورها (تراکم و نیتروژن) با متغیرهای وابسته (عملکرد برگ و دانه) به دست آورده شد. سپس مقادیر متفاوت رگرسورها (در محدوده مورد آزمایش) در معادله قرار داده شد و مقادیر برگ و دانه برای هر یک از مقادیر برآورد گردید. سپس داده‌های به‌طور تصادفی پشت سرهم قرار گرفته، به دو قسمت داده‌های آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم گردیدند. در صورتی که داده‌ها به صورت خام وارد مدل شوند، به علت تغییرات زیاد آن‌ها، تأثیر متفاوتی بر روی شبکه می‌گذارند به صورتی که برخی از نرون‌ها خیلی زود به حد "آتش" (فعالیت بالا) رسیده و در مقابل، برخی دیگر از نرون‌ها حتی به آستانه فعالیت هم نمی‌رسند (منهاج، ۱۳۸۸). از رابطه زیر برای استاندارد کردن داده‌ها استفاده گردید (کاشی و همکاران، ۱۳۹۲):

$$Y_i = 0.8 \times \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + 0.1 \quad (1)$$

که در آن  $Y_i$  داده استاندارد شده،  $X_i$  داده استاندارد نشده،  $X_{\min}$  کوچک‌ترین داده،  $X_{\max}$  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<sup>۱۰</sup> (لایه میانی) و نیز داده‌های آموزش به مقدار کافی باشد، آن‌گاه شبکه چند لایه پرسپترون

همکاران، ۲۰۰۶). این مزایا دلایل به‌کارگیری شبکه عصبی در بهینه‌سازی تراکم جمعیت و کود نیتروژن را برای ما روشن می‌سازد.

شبکه‌های عصبی شامل تعدادی نرون‌های متصل به هم هستند. مراحل اصلی حل هر مسئله توسط شبکه عصبی شامل آموزش و آزمون می‌باشد. آموزش، فرآیند یادگیری مجموعه داده‌های ورودی به منظور تشخیص الگوهای آن توسط شبکه به‌شمار می‌رود. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون‌ها از طریق قانون یادگیری در طول مرحله آموزش اصلاح می‌گردند. آزمون عبارت از ارزیابی قابلیت تعمیم‌پذیری و شایستگی شبکه آموزش دیده در شرایط کاملاً جدید توسط مجموعه داده‌هایی غیر از داده‌های آموزش می‌باشد (ویلنتورف<sup>۱</sup>، ۱۹۹۵؛ گوپتا<sup>۲</sup> و همکاران، ۲۰۰۳). امروزه مدل‌های شبکه عصبی به‌عنوان ابزارهای شناخته شده‌ای برای تخمین توابع در تحقیقات اکولوژیکی و محیطی به حساب می‌آیند (زانگ<sup>۳</sup> و همکاران، ۲۰۰۸). آن‌ها می‌توانند با دقت بالا جمعیت علف‌هرز را از گیاه زراعی در مزارع متمایز کنند (یانگ<sup>۴</sup> و همکاران، ۲۰۰۳). این تکنیک در پیش‌بینی متغیرهای پیوسته‌ای مانند رطوبت خاک (چانگ و اسلام<sup>۵</sup>، ۲۰۰۰)، ارزیابی کیفیت آب (زانگ و همکاران، ۲۰۰۲)، تخمین بیوماس (دراموند<sup>۶</sup> و همکاران، ۲۰۰۳)، برآورد عملکرد دانه (جین و لیو<sup>۷</sup>، ۱۹۹۷)، و بهینه‌سازی صفات برای افزایش عملکرد جو (قلی‌پور<sup>۸</sup> و همکاران، ۲۰۱۳) نیز پتانسیل بالایی نشان داده است. هدف جنبی این بررسی، معرفی اهمیت شبکه عصبی به‌عنوان ابزاری تکمیلی در تجزیه و تحلیل‌های کشاورزی بود که با استفاده از داده‌های به‌دست‌آمده از واکنش و سمه به ۴ تراکم کشت و نیتروژن به چگونگی کاربرد آن پرداخته شد.

#### مواد و روش

##### آزمایش زراعی

در این بررسی، نتایج آزمایش مزرعه‌ای تأثیر تراکم و نیتروژن بر عملکرد رویشی (تولید برگ) و زایشی (دانه) و سمه در منطقه گرمسیر جیرفت (نیکبخت راینی، ۱۳۹۱؛ نیکبخت راینی و همکاران، ۱۳۹۱) مورد استفاده قرار گرفت. این آزمایش در

1. Veelenturf
2. Gupta
3. Zhang
4. Yang
5. Chang and Islam
6. Drummond
7. Jin and Liu
8. Gholipoor

9. Polynomial regression

10. Hidden layer

گردید. در این مدل، عملکرد دانه و برگ به‌عنوان ورودی، و تراکم بوته به‌عنوان خروجی مدل در نظر گرفته شد. سپس داده‌های به‌طور تصادفی پشت سرهم قرار گرفته، به دو قسمت داده‌های آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم گردیدند. سناریوهای متفاوتی مورد آزمون قرار گرفت و از بین آن‌ها، مدل برتر انتخاب گردید. در نهایت بهترین مقادیر تراکم بوته برآورد گردید. هرکدام از این تراکم‌های بوته برآورد شده می‌تواند به‌طور بالقوه تراکم مطلوب برای حصول عملکرد برگ و دانه و سوسه باشد. تراکم‌های بوته‌ای که در محدوده تراکم‌های مورد آزمون در آزمایش مزرعه‌ای بودند انتخاب گردیدند.

(۲) در این مرحله، با استفاده از داده‌های اصلی و داده‌های برآورد شده در مرحله قبل، رگرسیون دیگر یعنی نیتروژن وارد مدل گردید. ورودی‌های مدل شامل تراکم بوته و عملکرد دانه و برگ، و خروجی مدل شامل نیتروژن 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 نیتروژن گردید. مقادیری از نیتروژن که در دامنه نیتروژن مورد آزمون در آزمایش مزرعه‌ای قرار داشت انتخاب گردید.

(۳) برای برآورد عملکرد برگ و دانه با استفاده از رگرسیون‌های به‌دست‌آمده در دو مرحله قبل، مدل چند لایه شبکه عصبی برتر قبلاً ایجاد شده توسط داده‌های اصلی، مورد استفاده قرار گرفت. سپس مقادیر برآورد شده عملکرد دانه و برگ توسط این مدل شبکه عصبی به‌دست آمد.

می‌تواند به‌طور واقعی هر تابع را با هر دقت دلخواه تقریب بزند (کال و همکاران، 2005؛ روحانی و همکاران، ۱۳۸۸). شبکه چند لایه پرسپترون با دریافت بردار ورودی  $X^q$ ، بردار خروجی  $Z^q$  را برای هر  $q (q=1, \dots, Q)$  تولید می‌نماید. هدف اصلی، اتخاذ پارامترهای صحیح شبکه می‌باشد که تا حد امکان، خروجی واقعی  $Z^q$  به خروجی مطلوب  $d^q$  متناظر خود نزدیک باشد. در این بررسی با استفاده از نرم‌افزار QNET، از الگوریتم پس انتشار<sup>۱</sup> برای آموزش شبکه استفاده گردید. تعداد لایه‌های مخفی مورد استفاده ۲، ۳، ۴، ۵، ۶ و ۷ بود. برای هر لایه مخفی، یکی از ۴ تابع انتقال<sup>۲</sup> (تابع فعال‌سازی) زیر مورد استفاده قرار گرفت:

- تابع سیگموئید:

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

- تابع تانژانت هایپربولیک:

$$f\left(\sum W_{ij}X_i\right) = \frac{e^{\left(\sum_{i=1}^n W_{ij}X_i\right)} - e^{-\left(\sum_{i=1}^n W_{ij}X_i\right)}}{e^{\left(\sum_{i=1}^n W_{ij}X_i\right)} + e^{-\left(\sum_{i=1}^n W_{ij}X_i\right)}} \quad (3)$$

- تابع سکانت هایپربولیک:

$$f\left(\sum W_{ij}X_i\right) = \frac{2e^{\left(\sum_{i=1}^n W_{ij}X_i\right)}}{e^{2\left(\sum_{i=1}^n W_{ij}X_i\right)} + 1} \quad (4)$$

- تابع گوس:

$$f\left(\sum W_{ij}X_i\right) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{\left[\left(\sum_{i=1}^n W_{ij}X_i\right) - \mu\right]^2}{2\sigma^2}} \quad (5)$$

مجموع سناریوهای مورد آزمون ۲۴ عدد بود. برای ارزیابی قابلیت شبکه عصبی پرسپترون، از ضریب تبیین ( $R^2$ )، میانگین خطای مطلق (MAE) (رابطه ۶)، مجذور میانگین مربعات خطا (RMSE) (رابطه ۷) و خطای استاندارد نسبی (RSE) (رابطه ۸) استفاده گردید.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (6)$$

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

$$RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}}{\bar{Y}} \quad (8)$$

که در آن  $Y_i$  مقدار مشاهده شده متغیر وابسته،  $\bar{Y}$  مقدار میانگین متغیر وابسته مشاهده شده،  $\hat{Y}_i$  مقدار برآورد شده متغیر وابسته، و  $\bar{\hat{Y}}$  مقدار میانگین متغیر وابسته برآورد شده می‌باشند.

بهینه‌سازی رگرسیون‌ها در جهت افزایش متغیرهای وابسته،

در ۳ مرحله صورت گرفت (قلی پور و همکاران، 2012):

(۱) ابتدا در بین رگرسیون‌ها، رگرسوری که رابطه قوی‌تری با متغیرهای وابسته داشت (تراکم بوته) وارد مدل شبکه عصبی

1. Back propagation  
2. Transfer function

جدول ۱: شاخص‌های ارزیابی مربوط به توابع انتقال مختلف در مرحله آموزش

Table 1: Evaluation indices regarding to various transfer functions in the training phase

شاخص‌های ارزیابی Evaluation indices				متغیر خروجی Output variable	تابع انتقال Transfer function
R <sup>2</sup>	RMSD	MAE	RSE		
0.9322	269.46	159.97	0.1028	برگ Leaf	سیگموئید Sigmoid
0.9679	5.96	4.21	0.0907	دانه Grain	Sigmoid
0.8116	449.20	268.16	0.1711	برگ Leaf	گوسس Gaussian
0.7723	17.66	8.19	0.2691	دانه Grain	Gaussian
0.6254	758.48	401.38	0.2907	برگ Leaf	تانژانت هایپربولیک Tangent hyperbolic
0.7337	19.16	12.51	0.2940	دانه Grain	Tangent hyperbolic
0.7477	534.81	345.01	0.2072	برگ Leaf	سکانت هایپربولیک Secant hyperbolic
0.7458	17.01	11.78	0.2655	دانه Grain	Secant hyperbolic

جدول ۲: میانگین مربعات عملکرد برگ و دانه و سمه

Table 2: Mean squares of leaf and grain yield of woad

عملکرد دانه Grain yield	وزن برگ Leaf weight	درجه آزادی df	منبع تغییر Source of variation
63.12 <sup>ns</sup>	177518 <sup>ns</sup>	2	تکرار Replication
4543.52 <sup>**</sup>	605139 <sup>ns</sup>	3	نیتروژن (N) Nitrogen(N)
137.50	507695	6	خطای a Error a
21138.99 <sup>**</sup>	16305411 <sup>**</sup>	3	تراکم (D) Density(D)
2815.44 <sup>**</sup>	3460058 <sup>**</sup>	9	نیتروژن × تراکم D × N
135.93	227979	24	خطای b Error b

ns و \*\*: به ترتیب غیرمعنی‌دار و معنی‌دار در سطح احتمال ۱ درصد

ns and \*\*: Non-significant, and significant at 1% probability level, respectively

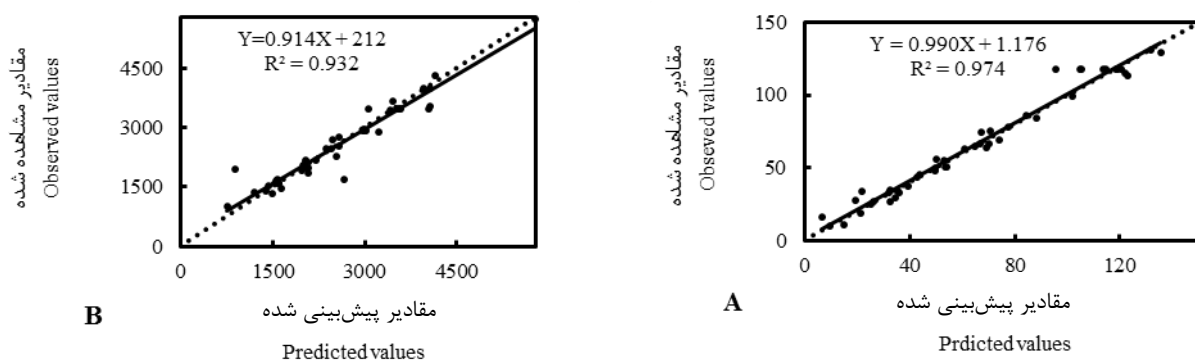
جدول ۳: مقایسه میانگین عملکرد برگ (کیلوگرم در هکتار) و دانه (گرم در مترمربع) و سمه در شرایط ۴ تراکم کشت (گیاه در مترمربع) و مقدار کود نیتروژن

Table 3: Mean comparison for leaf (kg ha<sup>-1</sup>) and grain yield (g m<sup>-2</sup>) of woad under 4 planting density (plant m<sup>-2</sup>) and nitrogen fertilizer amount.

200 کیلوگرم نیتروژن در هکتار 200 kg N ha <sup>-1</sup>		150 کیلوگرم نیتروژن در هکتار 150 kg N ha <sup>-1</sup>		100 کیلوگرم نیتروژن در هکتار 100 kg N ha <sup>-1</sup>		50 کیلوگرم نیتروژن در هکتار 50 kg N ha <sup>-1</sup>		تراکم کشت Planting density
دانه Grain	برگ Leaf	دانه Grain	برگ Leaf	دانه Grain	برگ Leaf	دانه Grain	برگ Leaf	
19.6e	1641fghi	32.3de	2667cdef	6.6e	1210hi	9.8c	756i	10
66.6bc	1359fgh	54cd	894i	21.8e	2206efgh	21.3e	1440ghi	15
132a	3576bcd	136a	3625bc	50.1cd	3220bcde	88.4b	2975bcde	25
53.3cd	4151b	139a	2380efgh	135a	2450defg	64.7bc	5775a	35

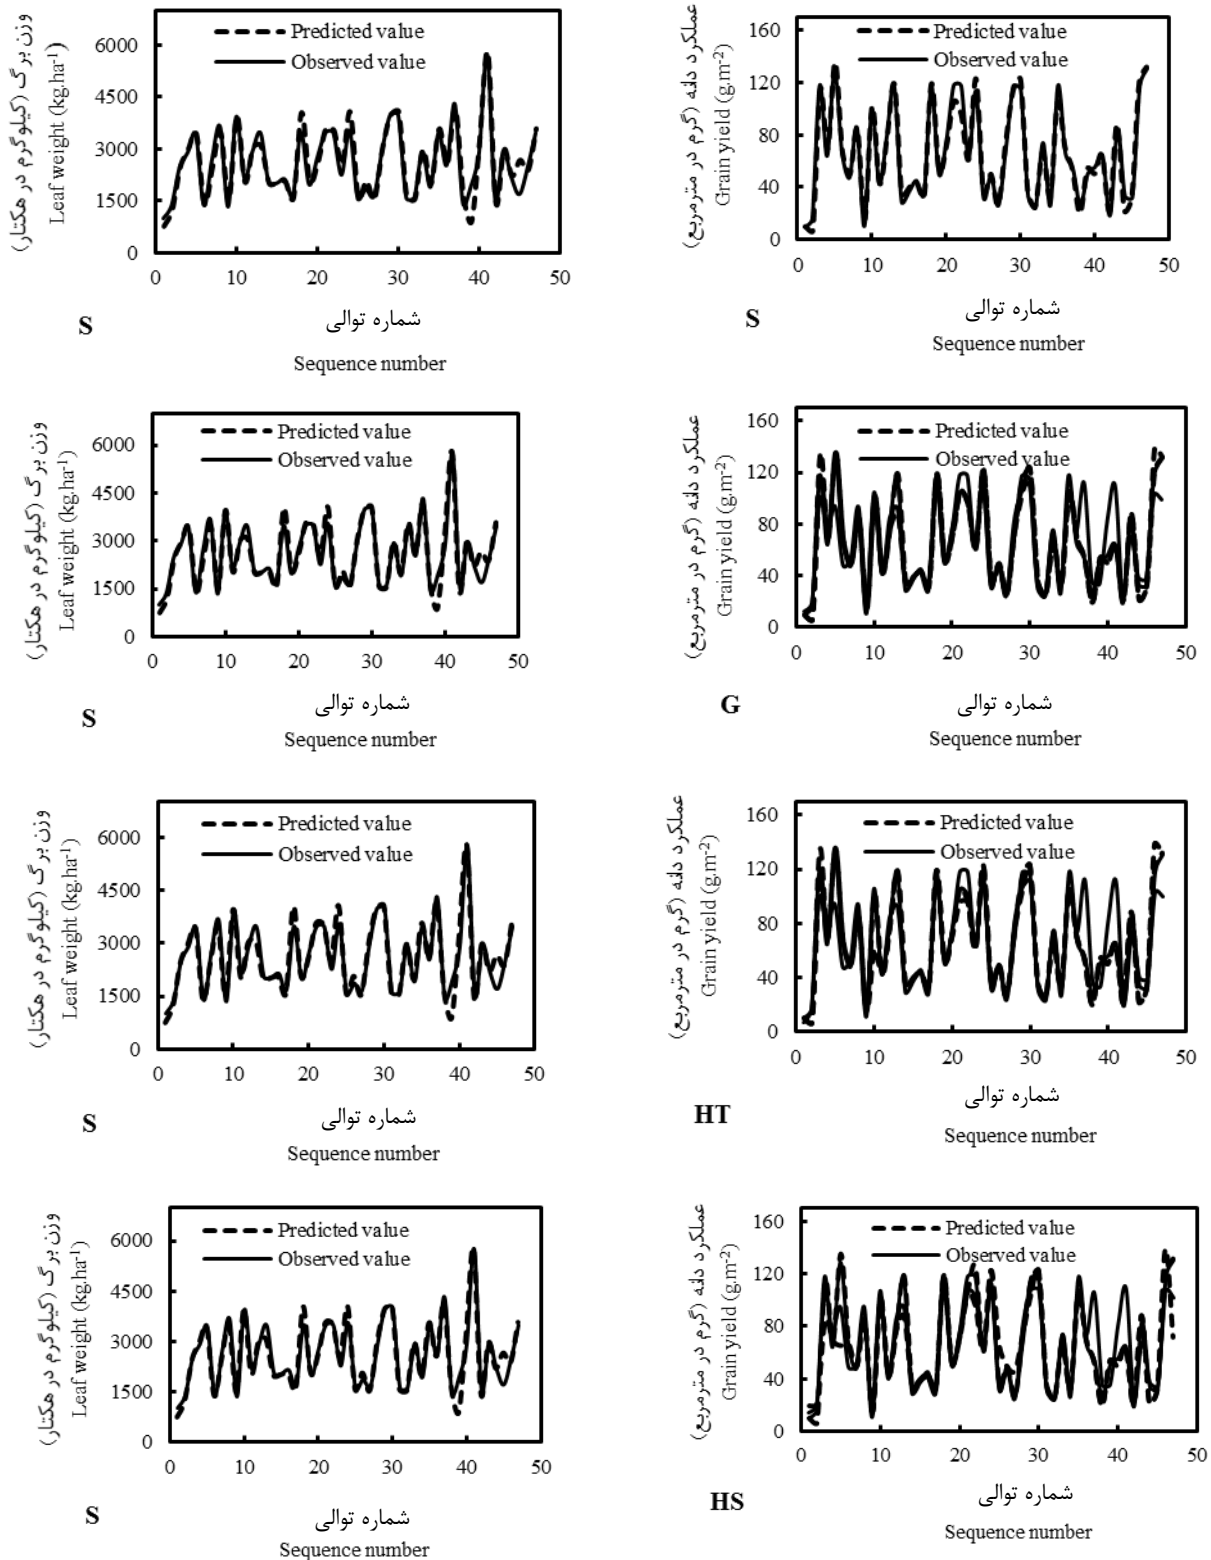
میانگین‌های با حروف مشابه در هر ستون اختلاف آماری معنی‌داری با هم برای بر اساس آزمون LSD ندارند

Means with similar letters in each column have no significant difference based on LSD test



شکل ۱: حساسیت سنجی مدل شبکه عصبی در مرحله آموزش برای وزن دانه (A) و برگ (B)

Fig. 1: Sensitivity analysis of neural network model during training phase for grain (A) and leaf weight (B)



شکل ۲: انحراف مقادیر پیش‌بینی شده از مقادیر مشاهده شده دانه و برگ در مرحله آموزش برای توابع فعال‌سازی سیگموئید (S)، گوس (G)، هایپربولیک تانژانت (HT) و هایپربولیک سکانت (HS)

Fig. 2: Deviation of predicted values from observed values of grain and leaf in the training phase for the sigmoid (S), Gaussian (G), hyperbolic tangent (HT), and Hyperbolic Secant activation functions (HS)

گردید. ولی با افزایش آن از یک مقدار معینی به بعد، کارکرد آن در مرحله آزمون تقلیل یافت. از طرف دیگر تعداد کم نرون در این لایه فرایند آموزش را ضعیف نمود به طوری که ضریب تبیین به دست آمده بسیار کم بود (نتایج ارائه نشده). به طور

## نتایج و بحث

نتایج نشان داد که با افزایش تعداد نرون در لایه (های) پنهان، فرایند آموزش شبکه و اصطلاحاً به "خاطر سپاری" آن بهتر

### 1. Memorization

کلیه منابع تغییر در جدول تجزیه واریانس بر عملکرد دانه معنی‌دار به دست آمد. به لحاظ معنی‌دار شدن اثر متقابل فاکتورها، مقایسه میانگین ترکیبات تیماری انجام شد. از لحاظ مفهوم، معنی‌دار شدن اثر متقابل نشانگر آن است که با تغییر تراکم کشت، تأثیر نیتروژن نیز تغییر می‌نماید. این امر را می‌توان به‌وضوح در جدول ۳ مشاهده نمود. از لحاظ عملکرد برگ، بهترین تراکم کشت و میزان نیتروژن به‌ترتیب شامل ۳۵ بوته در مترمربع و ۵۰ کیلوگرم نیتروژن بود (جدول ۳). برای عملکرد دانه، ۳۵ بوته در مترمربع و ۱۰۰ کیلوگرم نیتروژن بهترین سطوح شناخته شدند. نکته قابل‌تأمل در اینجا عبارت است از (۱) محقق یا کشاورز مردد می‌شود که ۵۰ یا ۱۰۰ کیلوگرم نیتروژن را انتخاب نماید و (۲) ممکن است برای هریک از متغیرهای وابسته (عملکرد برگ و دانه) سطوح دیگری از تراکم و نیتروژن مناسب بوده ولی به دلیل میسر نبودن اجرا (افزایش تعداد کرت)، آن سطوح مورد آزمایش قرار نگرفته‌اند.

نتایج حاصل از شبکه عصبی که در اصل درون‌یابی (بهینه‌سازی) سطوح نیتروژن و تراکم کشت می‌باشد حاکی از آن است که بالاترین عملکرد دانه بهینه‌سازی شده توسط مدل شبکه عصبی برابر با ۱۴۳/۵ گرم در مترمربع می‌باشد که حدود ۶/۳ درصد بالاتر از عملکرد حداکثر مشاهده شده است. این مقدار عملکرد در شرایط تراکم ۳۲ بوته در مترمربع و نیتروژن حدود ۷۲ کیلوگرم در هکتار حاصل شده است. این تراکم اندکی متفاوت از تراکم مطلوب (۳۵ بوته در مترمربع) و نیتروژن مطلوب مشاهده شده (۱۰۰ کیلوگرم در هکتار) است. این مقدار تراکم بهینه شده، بین سطوح تیماری تراکم ۲۵ و ۳۵ بوته در مترمربع قرار دارد. کمیت بهینه شده نیتروژن بین سطوح تیماری ۵۰ و ۱۰۰ کیلوگرم نیتروژن در هکتار قرار گرفته است. در خصوص برگ، بهترین تراکم کشت و نیتروژن بهینه شده توسط مدل، به‌ترتیب برابر با ۳۲ بوته در مترمربع و ۶۸ کیلوگرم در هکتار بود که باعث افزایش ۷/۷ درصدی عملکرد برگ گردید.

پیش‌بینی‌های فوق به‌خوبی، ویژگی مدل شبکه عصبی در برآورد تأثیر سطوح بررسی نشده فاکتورها در آزمایش زراعی را نشان می‌دهد، مضاف بر این که شبکه عصبی نسبت به روش‌های رگرسیونی بسیار دقیق‌تر می‌باشد (کاشی و همکاران، ۱۳۹۲؛ هانگ<sup>۴</sup> و همکاران، ۲۰۱۰؛ گرین<sup>۵</sup> و همکاران، ۲۰۰۷؛ پارک<sup>۶</sup> و همکاران، ۲۰۰۵؛ کال<sup>۷</sup> و همکاران، ۲۰۰۵). به‌عنوان نتیجه‌گیری می‌توان گفت که تراکم ۳۲ بوته در مترمربع و

معمول تعیین تعداد مناسب نرون در لایه پنهان و تعداد لایه‌های پنهان از طریق آزمون و خطا انجام می‌شود (ایبرهارت و دوبینز<sup>۱</sup>، ۱۹۹۰؛ باتنی<sup>۲</sup> و همکاران، ۲۰۰۷). در این بررسی، تعداد ۴ نرون مناسب تشخیص داده شد.

دقت و قابلیت مدل در سناریوهای استفاده از ۴ تابع فعال‌سازی در مرحله آموزش در جدول ۱ آورده است. به‌طورکلی ضریب تبیین بالاتر و در مقابل، میانگین خطای مطلق کم‌تر، خطای استاندارد نسبی کوچک‌تر و مجذور میانگین مربعات خطای پایین‌تر برای تابع سیگموئید نسبت به ۳ تابع دیگر حکایت از برتری این تابع در مرحله آموزش دارد. این امر برای مرحله آزمون نیز صادق بود (نتایج ارائه نشده). شایان ذکر است که همیشه این تابع بر توابع دیگر برتری نداشته و ارجحیت یک تابع بر توابع دیگر به ماهیت داده‌ها بستگی دارد. به‌عنوان مثال در بررسی قلی‌پور و همکاران (۲۰۱۲) در خصوص بهینه‌سازی غلظت عناصر غذایی برای افزایش عملکرد و درصد قند چغندر قند مشخص گردید که این تابع از قابلیت نسبی پایینی برخوردار بود.

به‌طوری‌که در شکل ۱ دیده می‌شود، انطباق نقاط با خط ۱:۱، به‌ویژه در خصوص دانه، برای تابع سیگموئید در مرحله آموزش بالاست. این امر برای مرحله آزمون در حد قابل‌قبول بود (نتایج ارائه نشده). در غالب موارد، میزان این انطباق در مرحله آموزش بالاتر از مرحله آزمون می‌باشد (قلی‌پور و همکاران، ۲۰۱۲؛ ۲۰۱۳). این دو شکل نشان می‌دهند که مقادیر برآورد شده توسط مدل شبکه عصبی و مقادیر مشاهده شده دانه و برگ به‌خوبی در کل محدوده دامنه تغییرات داده‌ها توزیع شده‌اند. در شکل ۲، انحراف<sup>۳</sup> مقادیر پیش‌بینی‌شده از مقادیر مشاهده شده را برای ۴ تابع انتقال نشان می‌دهد. در این شکل می‌توان به‌خوبی نقاط ضعف {شماره(های) توالی که در آن انحراف (عدم‌انطباق مقدار پیش‌بینی شده با مقدار مشاهده شده) وجود دارد و هم‌چنین کمیتی از برگ و دانه که در آن انحراف دیده می‌شود} و میزان ضعف (میزان انحراف) را مشاهده نمود. به‌عنوان نمونه در سناریوهای استفاده از توابع گوس، سکانت‌هایپربولیک و تانژانت‌هایپربولیک، بزرگ‌ترین انحراف در توالی شماره ۴۱ دیده می‌شود. این در حالی است که برای سناریوی استفاده از تابع سیگموئید، هیچ انحرافی در این شماره توالی وجود ندارد.

نتایج حاصل از تجزیه واریانس نشان داد که اثر اصلی نیتروژن بر عملکرد برگ معنی‌دار نبود ولی تأثیر متقابل آن با تراکم کشت معنی‌دار شد (جدول ۲). این در حالی است که اثر

4. Huang  
5. Green  
6. Park

1. Eberhart and Dobbins  
2. Bateni  
3. Bias

حدود ۷۰ کیلوگرم نیتروژن در هکتار باعث حصول عملکرد رویشی و زایشی بالاتر گیاه و سمه در منطقه جیرفت می‌گردد.

## منابع

- روحانی، ع.، رنجبر، ا.، عجب‌شیرچی، ی.، عباسپورفرد، م. و ولیزاده، م. ۱۳۸۸. پیش‌بینی هزینه‌های تعمیر و نگهداری تراکتور دو چرخ محرک با استفاده از شبکه عصبی مصنوعی و مقایسه آن با رگرسیون. مجله علوم کشاورزی و منابع طبیعی، ۱۶: ۱-۱۲.
- کاشی، ح.، امامقلی‌زاده، ص.، قربانی، ه. و هاشمی، ع. ا. ۱۳۹۲. برآورد نفوذپذیری خاک توسط شبکه عصبی مصنوعی و رگرسیون خطی در اراضی کشاورزی و بکر. مجله پژوهش‌های فرسایش محیطی، ۹: ۱۹-۳۴.
- منهاج، م. ب. ۱۳۸۸. مبانی شبکه‌های عصبی. انتشارات دانشگاه صنعتی امیر کبیر، ۱۷۰ صفحه.
- نیکبخت راینی، ح. ۱۳۹۱. اثر سطوح مختلف نیتروژن و تراکم بوته بر عملکرد پیکر رویشی گیاه صنعتی دارویی و سمه *Indigofera tinctoria* در منطقه جیرفت. مجموعه مقالات اولین کنفرانس ملی راهکارهای دستیابی به توسعه پایدار، وزارت کشور، تهران، ایران.
- نیکبخت راینی، ح.، افشارمنش، غ. و سرحدی، ح. ۱۳۹۱. اثر سطوح مختلف نیتروژن و تراکم بوته بر عملکرد زایشی گیاه صنعتی و دارویی و سمه *Indigofera tinctoria* در منطقه جیرفت. مجموعه مقالات اولین کنفرانس ملی راهکارهای دستیابی به توسعه پایدار، وزارت کشور، تهران، ایران.
- Azadeh, A., Ghaderi, S. F. and Sohrabkhani, S. 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. Applied Mathematics and Computation, 186: 1753-1761.
- Bangar, A.V. and Saralaya, M. G. 2011. Anti-hyperglycemic activity of ethanol extract and chloroform extract of *Indigofera tinctoria* leaves in streptozotocin induced diabetic mice. Research Journal of Pharmaceutical, Biological and Chemical Sciences, 2 (1): 445-455.
- Batani, S. A., Borghei, S. M. and Jeng, D. S. 2007. Neural network and neuro-fuzzy assessments for scour depth around bridge piers. Engineering Applications of Artificial Intelligence, 20: 401-414.
- 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.
- 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, 46: 5-14.
- Eberhart, R. C. and Dobbins, R. W. 1990. Neural Network PS Tools: A Practical Guide. Academic Press, 440 pp.
- Gholipour, M., Emamgholizadeh, S., Hassanpour, H., Shahsavani, D., Shahoseini, H., Baghi, M. and Karimi, A. 2012. The optimization of root nutrient content for increased sugar beet productivity using an artificial neural network. International Journal of Plant Production, 6 (4): 429-442.
- Gholipour, 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.
- 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: 23-37.
- Gupta, M. M., Jin, J. and Homma, N. 2003. Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory. John Wiley & Sons, Inc., 752 pp.
- 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.
- Irmak, A., Jones, J. W., Batchelor, W. D., Irmak, S., Boote, K. J. and Paz, J. O. 2006. Artificial neural network model as a data analysis tool in precision farming. Transactions of the American Society of Agricultural and Biological Engineers, 49: 2027-2037.
- 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: 971-979.
- Kaul, M., Hill, R. L. and Walthall, C. 2005. Artificial neural networks for corn and soybean yield prediction. Agricultural Systems, 85: 1-18.
- 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.
- Torrecilla, J. S., Otero, L. and Sanz, P. D. 2004. A neural network approach for thermal/pressure food processing. Food Engineering, 62: 89-95.
- Vakil-Baghmisheh, M. T. 2002. Farsi Character Recognition Using Artificial Neural Networks. Dissertation, University of Ljubljana.
- Veelenturf, L. P. J. 1995. Analysis and Applications of Artificial Neural Networks. Prentice Hall press, 235 pp.
- Yang, C. C., Prasher, S. O., Landry, J. A. and Ramaswamy, H. S. 2003. Development of a herbicide application map using artificial neural networks and fuzzy logic. Agricultural Systems, 76: 561-574.
- Zhang, W. J., Zhong, X. Q. and Liu, G. H. 2008. Recognizing spatial distribution patterns of grassland insects: neural network approaches. Stochastic Environmental Research and Risk Assessment, 22: 207-216.



Zhang, Y., Pulliainen, J., Koponen, S. and Hallikainen, M. 2002. Application of an empirical neural network to surface water quality estimation in the Gulf of Finland using combined optical data and microwave data. *Remote Sensing of Environment*, 81: 327-336.

## Optimization of Nitrogen Fertilization and Planting Density for Enhancing the Leaf and Seed Performances of Woad Using Artificial Neural Network

Gholipoor<sup>1\*</sup>, M., Nikbakht-Raieni<sup>2</sup>, H. and Ansori<sup>3</sup>, A.

### Abstract

Usually, effects of three or four levels of independent variables (here, nitrogen fertilizer and planting density) on the dependent variables (here, leaf and seed performances) are investigated and the best levels of the independent variables are found by comparing the resulting average values. However, such results may be inaccurate. The aim of the present investigation is to find accurate optimal values of nitrogen fertilizer and planting density via interpolation (optimization), so as to enhance leaf and seed performances of woad, using artificial neural network (as a complementary analysis). In a farming test with split plot design at the research farm of Jiroft Branch of Islamic Azad University (Jiroft, Iran), the effects of four planting densities (primary factor, 10, 15, 25, and 35 plants per sq. meter) and four levels of nitrogen fertilizer (secondary factor, 50, 100, 150, and 200 kg per hectare) on the weights of leaf and seed of woad were investigated. The obtained results from the analysis of the data indicated that the neural network structure based on 4 neurons was the most appropriate structure. Optimal levels of planting density and nitrogen fertilizer were found to be 32 plants per sq. meter and about 70 kg of nitrogen fertilizer per hectare, respectively, which could increase the leaf and seed performances by 6.3% and 7.7%, respectively.

**Keywords:** Productivity, Pharmaceutical, Industrial, Interpolation

---

1 and 3. Associate Professor and MSc Graduate, Respectively, Department of Agronomy and Plant Breeding, Faculty of Agriculture, Shahrood University of Technology, Sharood, Iran

2. MSc Graduate, Department of Agronomy and Plant Breeding, Agriculture Faculty of Jiroft Azad University, Jiroft, Iran

\*: Corresponding author      Email: manouchehr.gholipoor@gmail.com

This paper has been extracted from the Third author's MSc thesis under the guidance of Manouchehr Gholipoor.