

پیش‌بینی حجم دانه کلزا با استفاده از شبکه‌های عصبی مصنوعی

مجید رهنما^۱، سامان آبدانان مهدی‌زاده^{۱*} و عبدالله ایمانمهر^۲

۱- استادیار گروه ماشین‌های کشاورزی و مکانیزاسیون دانشگاه کشاورزی و منابع طبیعی رامین خوزستان،

Rahnamam2002@yahoo.com

Saman.abdanan@gmail.com

۲- استادیار گروه ماشین‌های کشاورزی دانشگاه اراک

imanmehr2000@yahoo.com

*مسئول مکاتبات

چکیده

دانستن خصوصیات فیزیکی دانه‌های کلزا برای طراحی ادواتی که با این محصول در ارتباط می‌باشند مثل ادوات فراوری، لازم است. در این پژوهش حجم محصول با استفاده از ۱۰ خصوصیت فیزیکی دانه و با استفاده از شبکه‌های عصبی محاسبه گردید. ابتدا در آزمایشگاه برای ۸ نوع گونه مختلف در پنج سطح رطوبتی (بر پایه تر)، پارامترهای ابعاد محوری (قطر بزرگ، قطر کوچک و قطر متوسط)، قطر متوسط هندسی، سطح مقطع، حجم، سطح جانبی، کرویت و شاخص شکل دانه‌ها در ده تکرار اندازه‌گیری شد. بعد از تعیین پارامترهای فوق با استفاده از شبکه عصبی سه‌لایه‌ای BP با یک لایه میانی، حجم محصول محاسبه با مقدار اندازه‌گیری شده مقایسه گردید. نتایج نشان داد که شبکه بهینه‌سازی شده، توانایی تعیین حجم محصول با دقت بالا را دارد.

واژه‌های کلیدی: کلزا، خواص فیزیکی، شبکه عصبی مصنوعی و حجم محصول.

مقدمه

دانه‌های روغنی پس از غلات دومین ذخایر غذایی جهان به حساب می‌آیند. در این میان کلزا به عنوان یکی از مهمترین گیاهان روغنی در سطح جهان مطرح می‌باشد. آمار فائو (FAO) نشان می‌دهد که کلزا از نظر کمیت سومین منبع تولید روغن نباتی جهان به شمار می‌آید (Ticke, 2003). کلزا در حال حاضر بزرگترین منبع تولید بیودیزل در دنیا نیز می‌باشد (نظرداد، ۱۳۸۰). این دانه روغن‌دیر اکثر مناطق ایران کشت می‌شود و مقدار روغن دانه کلزا در حدود ۴۰ تا ۴۵ درصد وزن کل دانه است (سعادت، ۱۳۵۹). برای طراحی و ساخت ادوات مربوط به کاشت، داشت و فراوری این محصول در موقع برداشت و پس از آن، نیاز به شناخت خصوصیات فیزیکی می‌باشد که حجم یکی از این خصوصیات است.



تعیین حجم محصولات کشاورزی با توجه به نامنظم بودن شکل شان بسیار مشکل می‌باشد. روش‌های متعددی چون جابجایی مایع، جابجایی گاز، ماشین بینایی وجود دارد که می‌توان حجم محصولات را به کمک آن‌ها اندازه‌گیری نمود. در این پژوهش حجم محصول به روش جدید و با استفاده از شبکه عصبی تعیین گردید. شبکه عصبی یکی از پویاترین پژوهش‌ها در دوران معاصر می‌باشد. این روش در بسیاری از رشته‌ها از جمله علوم فنی مهندسی، مدیریت یا کشاورزی کاربردهای مهم و اساسی را دارا می‌باشد.

در کشاورزی برای تعیین کیفیت محصول یا مدیریت مزرعه می‌توان از شبکه‌های عصبی کمک گرفت. به عنوان مثال شین و سیمونز (۲۰۰۱) از شبکه‌های عصبی برای درجه‌بندی عدس استفاده نمودند. آن‌ها ابتدا از عدس با استفاده از ماشین بینایی تصویربرداری نموده و بعد از پردازش تصویر، توسط شبکه عصبی درجه بندی صورت گرفته است (Shahinand and Symons, 2001). در پژوهش‌های دیگر که توسط رستم‌پور و همکاران (۲۰۱۳) صورت گرفته بود خرابی میوه سیب با استفاده از شبکه عصبی مورد بررسی قرار گرفته بود (Rostampouretal, 2013). ساواکار در سال ۲۰۱۲ از شبکه‌های عصبی برای شناسایی و تقسیم بندی پنج میوه سیب، انبه، چیکو، پرتقال و لیموشیرین استفاده نمود. وی از شبکه بک پروپگیشن تابع سیگموئیدی استفاده نمود (Savakar, 2012). در تحقیقی دیگر از شبکه‌های عصبی برای پیشبینی سینتیک خشک شدن سیب‌زمینی استفاده شده و شبکه عصبی به خوبی توانسته است سینتیک خشک شدن سیب زمینی را در دماها رطوبت‌ها و سرعت‌های مختلف جریان ورودی پیشبینی کند (singh and pandey, 2011). پیشبینی فرایند خشک شدن و تغییر رطوبت کنگد در اثر خشک شدن طبیعی بوسیله شبکه‌های عصبی مصنوعی به وسیله خزایی (۲۰۰۸) انجام گرفته است. وی مدلی از شبکه عصبی برای پیشبینی فرایند خشک کردن نیز ارائه داده است و اعلام نموده این مدل بهتر از مدل تجربی می‌تواند پیش‌بینی کند (Khazaci, 2008).

هم اکنون در اکثر کشورها از شبکه عصبی در سیستم کنترل خودکار راه‌آهن، آژانس‌های هواپیمایی و پست استفاده وسیعی می‌شود (البرزی، ۱۳۸۰). در این پژوهش ابتدا به معرفی شبکه‌های عصبی و شبکه بکار گرفته شده در تعیین حجم، پرداخته شده و در نهایت مواد و روش‌ها، بحث و نتایج بدست آمده شرح داده شده است.

- معرفی شبکه عصبی و شبکه مورد استفاده در این پژوهش

شبکه عصبی یکی از تکنیک‌های محاسباتی در ریاضیات می‌باشد که از نحوه کار نرون‌های مغز انسان سرچشمه گرفته و هدف آن ایجاد هوش مصنوعی است که همانند مغز بتواند در فرایندهای تجزیه و تحلیل داده‌ها و تصمیم‌گیری‌ها شرکت کند و تمام ویژگی‌های انسان (قدرت تجزیه و تحلیل) و کامپیوتر (سرعت و دقت) را داشته باشد. تاریخچه شروع



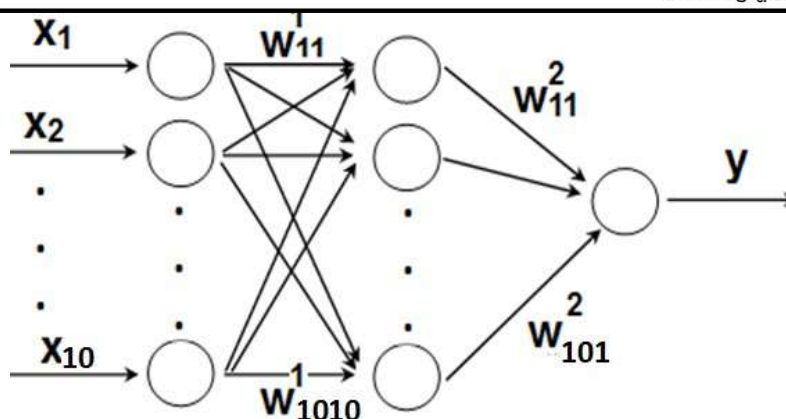
فعالیت در مورد شبکه‌های عصبی به اوایل قرن بیستم، توسط دانشمندانی چون ماکس برمی‌گردد و توسط دانشمندانی چون هاپفیلد و دونالد هب توسعه یافته است. از شبکه‌های عصبی می‌توان در طبقه‌بندی، شناسایی و تشخیص الگو، پردازش سیگنال، مدل‌سازی و کنترل، بهینه‌سازی، سیستم‌های خبره و فازی، مسائل مالی، بیمه، امنیتی، بازار بورس، امور حمل و نقل و غیره استفاده نمود (نظرداد، ۱۳۸۰).

ساختار شبکه‌های عصبی از نرون تشکیل شده است و بسته به هدفی که برای شبکه تعریف شده نوع، ساختار و روش یادگیری آن فرق می‌کند. در این پژوهش با توجه به اینکه هدف تعیین حجم بود از شبکه عصبی پرسپترون چند لایه استفاده شد. این شبکه دارای یک لایه ورودی با تعداد نرون‌هایی برابر با تعداد فاکتورهای ورودی، چند لایه میانی (که با توجه به داده‌ها، تعداد این لایه‌ها و نرون‌های هر لایه، روش یادگیری، مقادیر اولیه وزن‌ها و غیره، بهینه می‌شوند) و یک لایه خروجی تشکیل می‌شود. تعداد نرون‌های لایه خروجی برابر با هدف شبکه و پارامترهای دیگر آن نیز همانند لایه میانی و با توجه به داده‌های مساله بهینه‌سازی می‌شوند.

مواد و روش‌ها

مشخصات شبکه مورد استفاده:

مشخصات شبکه شامل نوع شبکه، تعداد لایه‌های میانی، تعداد نرون‌های لایه میانی (n)، نوع آموزش، مقادیر ضریب وزنی (α) که سرعت تعدیل را کنترل می‌کند، ضریب بتا (β) یا ضریب گشتاور و ممتم، مقادیر w یا وزن اولیه و توابع انتقال لایه میانی و لایه خروجی می‌باشد. با توجه به در دسترس بودن ۱۰ مشخصه دانه‌های یکلزا در ورودی، تعداد نرون‌های ورودی ۱۰ در نظر گرفته شد. در لایه میانی از روش یادگیری بک پروپگیشن و تابع انتقال از نوع سیکموئیدی استفاده گردید. تعداد لایه‌های میانی با توجه به اینکه یک شبکه با سه لایه توانایی حل اکثر مسائل مهندسی را دارد و برای راحتی کار، یک در نظر گرفته شد (Rumbelhart et al., 1986). در لایه خروجی از روش یادگیری بک پروپگیشن و تابع انتقال خطی (با توجه به اینکه خروجی بزرگتر از ۱ بود) استفاده شد. به منظور تشکیل ساختار شبکه عصبی مذکور، از برنامه ThinksPro استفاده گردید. ملاک بهینه‌سازی کمترین خطای یادگیری به روش کمترین مربعات (MSE) بود. نمودار روندنمای این شبکه در شکل (۱) نشان داده شده است.



شکل ۱: نمودار روندنمای شبکه پرسپترون با یک لایه میانی مورد استفاده برای تعیین حجم دانه کلزا

در این پژوهش ابتدا از هشت گونه کلزای سرز، Okapy، Licord، Hyola 401، Hyola 308، Hyola 501، Option و پلائی، ۵۰ نمونه به تصادف در پنج سطح رطوبتی ۰/۲۵، ۰/۰۵، ۰/۰۷۵، ۰/۱ و ۰/۵ انتخاب و برای تعیین مشخصات و تست شبکه مورد استفاده قرار گرفت. همچنین برای تسریع در کار و کاهش داده‌ها از هر گونه به تصادف ۱۰ نمونه و جمعاً ۸۰ نمونه برای آموزش شبکه و بهینه‌سازی آن انتخاب و ۱۰ مشخصه، گونه، رطوبت، قطر کوچک، قطر متوسط، قطر بزرگ، قطر متوسط هندسی، کرویت، سطح مقطع، سطح جانبی و شاخص شکل آن تعیین و در نهایت حجم نمونه‌ها نیز محاسبه شد.

در مرحله اول فرایند آموزش شبکه، برای تعیین بهینه مقدار آلفا (α) از مقادیر ۰، ۰/۰۱، ۰/۰۵، ۰/۱، ۰/۵ و ۱، بتا (β) از مقادیر ۰، ۰/۰۱، ۰/۰۵، ۰/۱ و ۱ و برای تعیین مقدار بهینه وزن اولیه مقادیر ۰، ۰/۰۱، ۰/۰۵، ۰/۱ و ۱ برای شبکه استفاده شد. در این مرحله تعداد نرون‌های لایه میانی سه حالت یک، سه و پنج نرون فرض گردید و مقادیر فوق با استفاده از نمونه ۵۰ تایی تست و ارزیابی شد که آزمایش‌ها در مجموع ۶۴۸ بار تکرار گردید. در ارزیابی اولیه خطای شبکه، برای آلفا (α) با مقادیر ۰، ۰/۵ و ۱ و بتا (β) با مقدار ۱ نا معلوم و شبکه واگرا گردید. در نتیجه از این مقادیر آلفا (α) و بتا (β) از استفاده در شبکه برای ارزیابی حذف گردید. در مرحله بعد، پس از مشخص شدن مقدار مطلوب مقادیر بتا (β)، آلفا (α) و w ، آزمایش‌ها بار دیگر برای تعیین تعداد مطلوب نرون‌های لایه میانی (n) برای بهترین برازش و پیشبینی تکرار گردید.


دلیل استفاده از این روش برای پیدا کردن فاکتورهای شبکه، تعداد زیاد فاکتورهای تأثیرگذار در بهینه‌سازی شبکه بود و لازم بود که به تدریج فاکتورها را محدود کرده تا یک جواب بهینه به دست آید. بنابراین ابتدا مقدار مطلوب بتا (β)، آلفا (α) و w ، به دست آمد و در مرحله بعد تأثیر افزایش تعداد نرون‌های لایه میانی (۵، ۷، ۹ و ۱۱ نرون در لایه میانی)، تأثیر نحوه پردازش ورودی (دو حالت بدون پردازش ورودی (none) و استفاده از میانگین بر انحراف معیار (mean/sd) به جای داده اصلی) مورد بررسی قرار گرفت. در نهایت بعد از پیدا کردن مقادیر بهینه آلفا (α)، بتا (β)، w ، نوع پردازش ورودی و تعداد نرون‌های



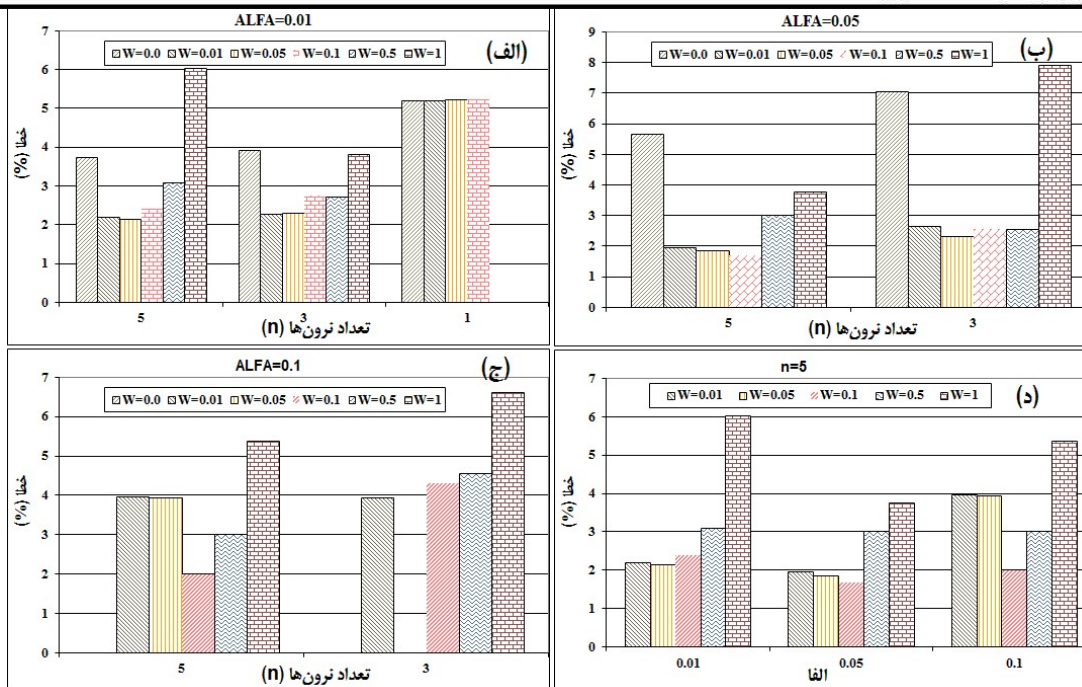
لایه میانی، با تنظیم پارامترهای شبکه‌بر حسب مقادیر به بدست آمده یعنی مقادیر بهینه‌حاصل شده از آزمایشات ذکر شده، یک نمونه ۳۲۰-تایی (از هر گونه به تصادف ۴۰ نمونه انتخاب گردید) برای آموزش شبکه و حصول کمترین خطا به روش میانگین مربع خطا تا مقدار ۰/۰۰۵ مورد استفاده قرار گرفت و تعداد ماکزیمم تکرارهای^۱ شبکه برای رسیدن به خطای مذکور برابر ۴۰۰۰۰ در نظر گرفته شد. بعد از آموزش شبکه و مشخص شدن وزن‌نرون‌ها، ۱۰ نمونه از هر هشت گونه تعیین حجم گردید و با حجم واقعی مقایسه شد.

نتایج و بحث

شکل (۲) درصد خطای شبکه برای مقادیر مختلف نرون‌ها، w و α نسبت به مقادیر مختلف بتا را نشان می‌دهد. با توجه به شکل ملاحظه می‌شود در تمام نمودارها (الف تا ز) با تغییر مقدار بتا درصد خطا تغییر اساسی نداشته و تقریباً ثابت می‌باشد. با این حال با افزایش مقدار بتا در صد خطا به مقدار کم تقلیل یافته است. ولی با افزایش بیشتر مقدار بتا (برابر ۱) برای تمام داده‌ها، شبکه واگرا گردید. همچنین با توجه به شکل مشخص می‌شود با افزایش مقدار α و بتا و کاهش مقدار n پایداری شبکه کاهش می‌یابد به طوری که برای تعداد نرون‌های $n=1$ مقدار بتا نمی‌تواند بزرگتر از ۰/۱ و مقدار α نمی‌تواند بزرگتر از ۰/۰۱ باشد (شکل ۲-ز) ولی با افزایش n به ۳، α می‌تواند تا ۰/۰۵ و بتا نیز می‌تواند تا مقادیر ۰/۵ را بپذیرد (شکل ۲-د، ذ و ر). وقتی n برابر ۵ می‌شود فقط در ماکزیمم مقدار α (۰/۱) و ماکزیمم مقدار بتا (۰/۵) شبکه واگرا شده است (شکل ۲-ج). بنابراین می‌توان گفت بهترین مقدار بتا می‌تواند ۰/۱ باشد مشروط بر اینکه تعداد نرون‌ها بالاتر از ۳ بوده و مقدار α نیز به اندازه کافی بزرگ باشد (بزرگتر یا مساوی ۰/۰۱) باشد. بنابراین مقدار بتا برای کاهش حداکثر خطا در شبکه در تمامی مراحل برابر ۰/۱ در نظر گرفته شد. شکل (۳) تغییرات خطا برای w ها و α های مختلف در موقعی که بتا برابر ۰/۱ می‌باشد، برای n برابر ۱، ۳ و ۵ رسم شده است. همانطور که از شکل‌های (۳-الف، ب و ج) مشخص است در تمامی مقادیر α مقدار خطا در $n=5$ کمترین مقدار شده است. این مطلب نشان می‌دهد که مقدار نرون‌های لایه میانی باید افزایش پیدا کند و لازم است برای n های بزرگتر از ۵ نیز شبکه آزمایش شود. به همین خاطر بعد از بدست آوردن بهترین مقادیر w و α مقدار مناسب n نیز مشخص خواهد شد. همچنین با توجه به نمودارهای مذکور کمترین مقدار خطا در w بین ۰/۰۱ تا ۰/۱ به دست آمده است.



شکل ۲: نمودار درصد خطای به دست آمده برای ۵، ۳ و ۱ ترون در لایه میانی نسبت به مقادیر مختلف بتا



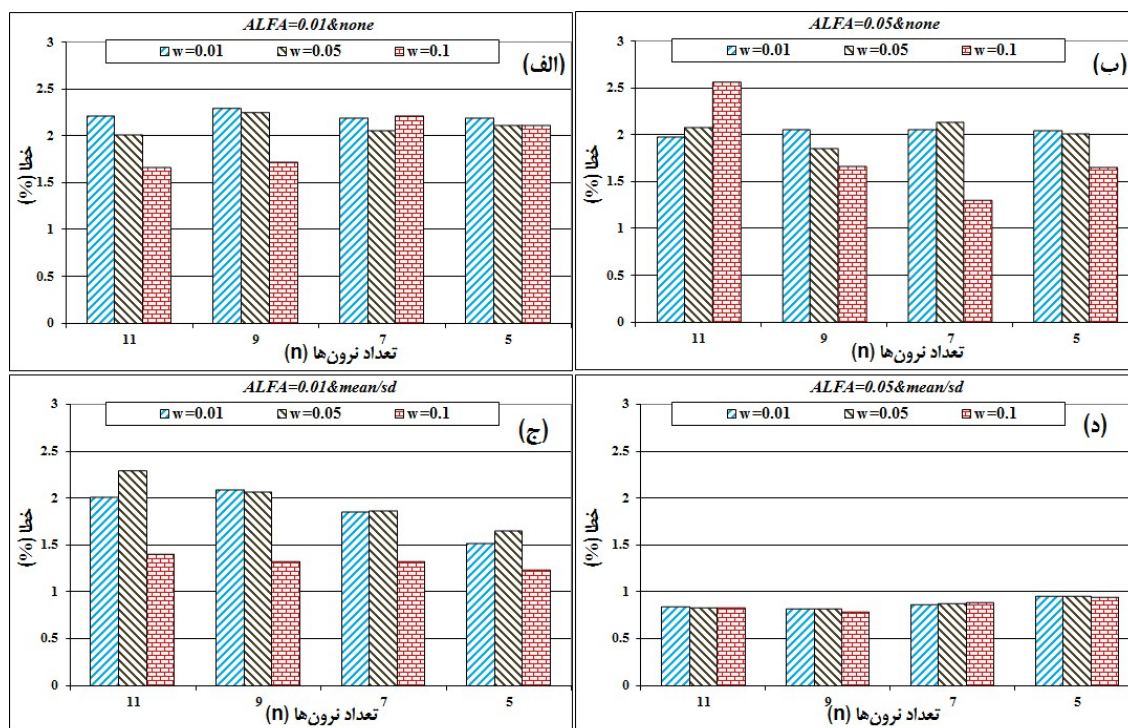
شکل ۳: نمودار تغییرات خطا نسبت به تعداد نرون‌ها و مقادیر مختلف آلفا در بتا برابر ۰/۱

همچنین با توجه به نمودار شکل (۳-د) کمترین مقدار خطا موقعی به دست می‌آید که $n=5$ ، آلفا برابر $0/05$ و مقدار w برابر $0/1$ باشد ($1/68\%$). همچنین وقتی آلفا برابر $0/01$ و w برابر $0/01$ و $0/05$ باشد خطا کم می‌باشد (به ترتیب $2/19\%$ و $2/12\%$). این مطلب بیانگر آن است که آلفا و w بهینه باید به ترتیب مقداری بین $0/01$ الی $0/05$ و $0/01$ الی $0/1$ داشته باشد تا مقدار خطا کمترین مقدار گردد.

بعد از تقلیل مقادیر بتا با $0/1$ ، آلفا به $0/01$ و $0/05$ و مقدار w به $0/01$ ، $0/05$ و $0/1$ ، در مرحله بعد، تأثیر افزایش تعداد نرون‌های لایه میانی (۵، ۷، ۹ و ۱۱ نرون در لایه میانی) و تأثیر نحوه پردازش ورودی (دو حالت بدون پردازش ورودی (none) و روش میانگین انحراف معیار (mean/sd)) روی مقدار خطای شبکه مورد بررسی قرار گرفت.

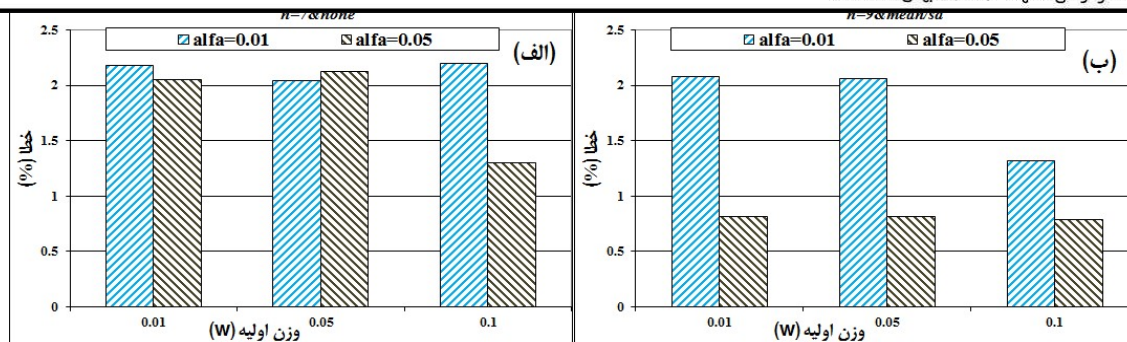
در شکل (۴) تغییرات خطای شبکه برای دو حالت ورودی بدون پردازش (none) و روش میانگین انحراف معیار (mean/sd) نسبت به تعداد نرون‌های لایه میانی نشان داده شده است. در شکل (۴-الف) تغییرات شبکه برای حالت بدون پردازش ورودی و آلفا برابر $0/01$ آورده شده است، با توجه به شکل مذکور کمترین مقدار خطا در این حالت زمانی به دست آمده است که مقدار $w=0/1$ و تعداد نرون‌ها ۱۱ عدد باشد ($1/66\%$). در حالی که وقتی مقدار آلفا با $0/05$ افزایش پیدا می‌کند (شکل ۴-ب) مقدار خطا در حالتی که مقدار $w=0/1$ و تعداد نرون‌ها ۷ عدد باشد، کمترین مقدار را حتی نسبت به حالت شکل (الف) دارد ($1/31\%$ در مقایسه با $1/66\%$). پس می‌توان نتیجه گرفت که برای حالتی که داده‌ها پردازش نشوند مقدار بهینه

پارامترهای شبکه برای حصول کمترین خطا در پیش‌بینی حجم برای الف، بتا، w و n به ترتیب برابر 0.1 ، 0.1 ، 0.05 و 7 می‌باشد. همچنین در حالتی که داده‌های ورودی پردازش شده باشند و به فرم میانگین بر انحراف معیار (mean/sd) وارد شبکه گردند (شکل ۴-ج و د)، در حالتیکه آلفا برابر 0.1 باشد، بهترین مقادیر w و n به ترتیب 0.1 و 5 به دست آمده است (شکل ۴-ج) و برای حالتی که آلفا برابر 0.05 باشد مقدار خطای خیلی کمتر از تمامی حالت‌های قبل است و بهترین حالت با مقادیر $w = 0.1$ و $n = 9$ حاصل شده است (0.79% در مقایسه با 1.23% برای آلفا برابر 0.1).



شکل ۴: تغییرات خطای شبکه برای دو حالت ورودی بدون پردازش (none) و روش میانگین انحراف معیار (mean/sd) با پارامتر بتا برابر 0.1

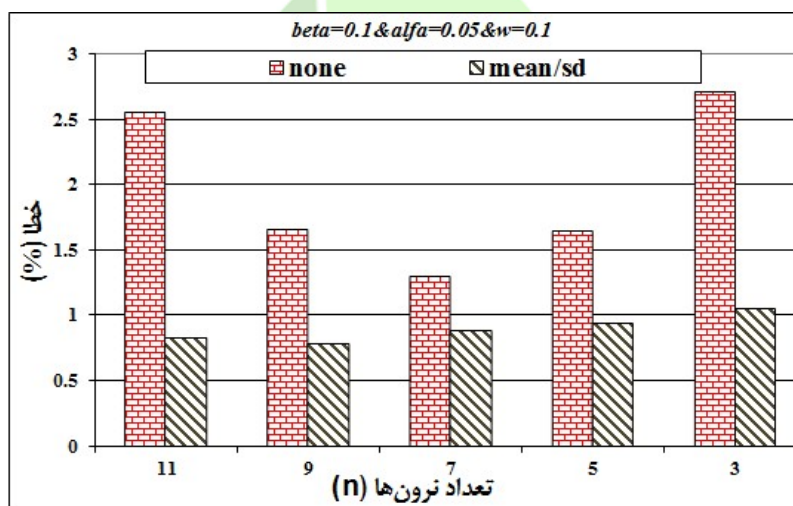
در شکل (۵) تغییرات خطای شبکه را برای حالات بهینه ورودی بدون پردازش (بتا برابر 0.1 و $n=7$) و ورودی پردازش شده (بتا برابر 0.1 و $n=7$) رسم شده است. کمترین مقدار خطا برای داده‌های پردازش نشده و پردازش شده (شکل‌های الف و ب) به ترتیب برابر 1.31% و 0.79% در آلفا برابر 0.05 و $w=0.1$ به دست آمده است. پس با مقایسه شکل‌های (۴ و ۵) به طور کلی مقادیر بهینه آلفا و w به ترتیب برابر 0.05 و 0.1 به دست می‌آید.



شکل ۵: تغییرات خطای شبکه برای دو حالت n=7 و بدون پردازش و حالت n=9 و روش میانگین انحراف معیار

برایند نتایج به دست آمده از شکل‌های (۲) الی (۵) در نمودار شکل (۶) آورده شده است. شکل مذکور تغییرات خطای

شبکه در دو حالت بدون و با پردازش ورودی و مقادیر بهینه آلفا، بتا و w نسبت به نرون‌های مختلف لایه میانی نشان می‌دهد.



شکل ۶: تغییرات خطای شبکه در دو حالت بدون و با پردازش ورودی و مقادیر بهینه آلفا، بتا و w نسبت به نرون‌های مختلف

همانطور که در شکل (۶) مشخص شده است در حالتی که داده‌های ورودی پردازش نشوند بهترین تعداد نرون‌های

لایه میانی برابر ۷ به دست می‌آید (خطا برابر ۱/۳۱٪) و با کاهش یا افزایش تعداد نرون‌ها خطا افزایش می‌یابد. این در حالی

است که با پردازش داده‌های ورودی خطای شبکه کاهش چشمگیری داشته است به طوری که در تمامی حالات مختلف تعداد

نرون‌ها خطا کمتر از حالت بدون پردازش ورودی است. بهترین تعداد نرون‌ها برای حالت ورودی پردازش شده ۹ به دست

می‌آید (خطا برابر ۰/۷۹٪). می‌توان نتیجه گرفت که کمترین مقدار خطای پیش‌بینی شبکه در حالت، داده‌های ورودی پردازش


شده و ۹ نرون در لایه میانی به دست می‌آید که مقدار آن برابر ۰/۷۹٪ می‌باشد.




می‌توان با توجه به شکل‌های (۲) الی (۶) می‌توان نتیجه گرفت که بهترین حالت شبکه برای تخمین و پیش‌بینی

حجم دانه کلزا با مقادیر آلفا، بتا، w ، n و نحوه پردازش ورودی به ترتیب برابر 0.05 ، 0.1 ، 0.1 ، 0.01 و پردازش شده $(mran/sd)$ می‌باشد.

بعد از مشخص کردن بهتری مقادیر برای پارامترهای متغیر شبکه‌ی آموزشی شبکه با مقادیر بهینه، ۸۰ نمونه به تصادف (از هر گونه ۱۰ نمونه) تعیین حجم شده و با مقدار واقعی آن مورد مقایسه قرار گرفت. شکل (۷) نزدیکی ارقام حاصل از حجم واقعی و حجم محاسبه شده بوسیله شبکه عصبی و شکل (۸) نزدیکی مقادیر حجم واقعی به حجم پیش‌بینی شده به وسیله شبکه عصبی را برای تمام گونه‌های کلزا را نشان می‌دهد. همانطور که در شکل (۷) دیده می‌شود شیب خط حاصل از داده‌های پیش‌بینی شده نسبت به داده‌های واقعی تقریباً برابر ۱ و ضریب آن همبستگی نیز بسیار بالا و برابر $R^2 = 0.9999$ به دست آمده است. این مطلب نشان می‌دهد حجم دانه‌های کلزای پیش‌بینی شده بوسیله شبکه‌های عصبی کاملاً بر حجم واقعیان منطبق می‌باشند. همچنین با مراجعه به شکل (۸) مشخص می‌شود که شبکه توانسته حجم تمام ارقام را با دقت بالا پیش‌بینی نماید. بنابراین می‌توان از شبکه‌های عصبی برای اندازه‌گیری حجم دانه کلزا با دقت بالا استفاده نمود بدون آنکه نیازی به استفاده از روش‌های معمول که سخت و طاقت‌فرسا و زمان‌بر هستند، باشد. برای مقایسه بهتر تمامی داده‌های مربوط به حجم به دست آمده از شبکه عصبی و مقدار واقعی آن در جدول ۱ آورده شده است.



شکل ۷: رابطه بین حجم واقعی و حجم محاسبه شده بوسیله شبکه عصبی برای ۱۰ نمونه از هر گونه که جزء داده‌های آموزش شبکه نبودند.



شکل ۸: نزدیکی ارقام حاصل از پیش‌بینی به وسیله شبکه‌های عصبی با مقدار واقعی برای ۸ گونه دانه کلزا

جدول ۱: نتایج حجم‌گونه‌های مختلف به دست آمده کلزایا شبکه‌عصبی و مقایسه انحراف معیار آنها

گونه	حجم		انحراف معیار	
	مقدار مطلوب	خروجی شبکه	مقدار مطلوب	خروجی شبکه
سبز	۲/۸۸۶۸	۲/۸۸۶۳	۰/۸۰۰۲	۰/۸۰۵
Okapy	۳/۸۱۰۲	۳/۸۰۶۲	۰/۶۰۱۱	۰/۶۰۳۸
Licord	۴/۴۰۶۹	۴/۴۰۶۲	۰/۵۸۸۴	۰/۵۸۷۸
Hyola 401	۳/۳۴۳۶	۳/۳۴۳۲	۰/۷۶۹۷	۰/۷۷۱۱
طلایه	۲/۵۷۴	۲/۵۹۹۴	۰/۶۳۳۴	۰/۶۰۵۸
Hyola 308	۴/۰۳۰۵	۴/۰۳۰۳	۰/۷۴۱۶	۰/۷۴۸۵
Option 501	۲/۸۵۵۳	۲/۸۵۷۶	۰/۶۴۷۵	۰/۶۴۵۸
Orient	۳/۸۳۳۸	۳/۸۳۹	۱/۰۵۸۳	۱/۰۷۱۲

نتیجه گیری

با توجه به مطالب فوق برای اندازه‌گیری حجم محصول کلزا، حالت بهینه شبکه موقعی حاصل می‌شود که مقدار بتا برابر ۰/۱، آلفا برابر ۰/۰۵، وزن اولیه برابر ۰/۱، تعداد نرون‌های لایه پنهان برابر ۹ و نوع داده‌های ورودی بصورت میانگین انحراف معیار، باشد خطای ۰/۷۹٪. بعد از بهینه‌سازی شبکه حجم هشت گونه محصول کلزا تعیین شد. نتایج نشان داد شبکه با دقت بالا قادر است حجم تمام گونه‌ها را با توجه به مشخصات اندازه‌گیری شده با R^2 برابر ۰/۹۹۹۹، اندازه‌گیری نماید.

منابع

- ۱- البرزی، م. ۱۳۸۰. آشنایی با شبکه‌های عصبی. ترجمه. نویسنده جکسون، آر و بیل، تی. انتشارات علمی دانشگاه شریف.
- ۲- سعادت لاجوردی، ن. ۱۳۵۹. دانه‌های روغنی. انتشارات دانشگاه تهران. شماره ۱۷۷۳.
- ۳- نظرداد، ا. ۱۳۸۰. مکانیزاسیون کلزا. وزارت جهاد کشاورزی. معاونت و زیربنایی، مرکز توسعه مکانیزاسیون کشاورزی.
- 4- Khazaei, J. 2008. Natural drying characteristics of sesame seeds. *Cercetări Agronomice în Moldova*, Vol. XLI, No. 3 (135).
- 5- Rostampour, V., A. Modares Motlagh, M.H. Komarizadeh, M. Sadeghi, I. Bernousi. and T. Ghanbari. 2013. Using Artificial Neural Network (ANN) technique for prediction of apple bruise damage. *AJCS* 7(10):1442-1448.
- 6- Rumbelhart, D.E., G.E. Hinton, and R.J. Williams. 1986. Learning internal representation by error propagation. *parallel distribution processing*, V. 1.
- 7- Savakar, D. 2012. Identification and Classification of Bulk Fruits Images using Artificial Neural Networks. *International Journal of Engineering and Innovative Technology (IJEIT)*. 1(3): 36-41
- 8- Shahin, M.A. and S.J. Symons. 2001. A machine vision system for grading lentils. *Canadian Grain Commission, Grain Research Laboratory CANADIAN BIOSYSTEMS ENGINEERING*, Volume 43.
- 9- Singh, N.J. and R.K. Pandey. 2011. Neural Network Approaches for Prediction of Drying Kinetics During Drying of Sweet Potato. *Agricultural Engineering International: CIGR Journal*. 13 (1): 1-12.

10- Tickle, J. 2003. From the Fryer to the Fuel Tank: The complete guide to using vegetable oil as an alternative fuel, USA.

11- Unay, D. and B. Gosselin. 2002 Apple Defect Detection and Quality Classification with MLP-Neural Networks. TCTS Laboratory, Faculty Polytechnique de Moons, Initials Scientific Park, 1, Copernic.

Volume prediction of the canola seed using artificial neural network

Majid Rahnama¹, Saman Abdanan Mehdizadeh*¹, Abdollah Imanmehr²

Rahnamam2002@yahoo.com

Saman.abdanan@gmail.com

1. Assistant professor, College of Agricultural Engineering, Ramin Khuzestan University of Agriculture and Natural Resources, Mollasani, Ahvaz, Khuzestan, Iran

2. Assistant professor, College of Agricultural Engineering, Hamedan University, Hamedan, Iran

*:correspond author

Abstract

The physical properties of canola seeds are necessary to design the instruments in which the seeds are contact with. In this research the volume of the 8 varieties of the canola seeds were determined using 8 physical properties and neural network. At the first, the three linear dimensions of the seeds (namely length, width and thickness), geometric mean diameter, surface area, cross section area, volume, sphericity and aspect ratio for each variety of canola seeds in 5 moisture levels (w.b) were measured. After determination of the mentioned properties, the volume of the canola seeds were determined through backpropagation learning for multilayer feed-forward neural networks and comparison with measured value. After optimization of the neural network, the results show that volume of canola seeds can be determined using neural network with high accuracy.

Key words: canola, physical properties, neural network and volume.