

پیش‌بینی حجم، سطح جانبی و ضریب کرویت انار با استفاده از شبکه عصبی مصنوعی MLP

عباس روحانی^{۱*} - سید ایمان ساعدی^۲ - هادی گرایلو^۳ - محمد حسین آق‌خانی^۴

تاریخ دریافت: ۱۳۹۲/۰۸/۲۱

تاریخ پذیرش: ۱۳۹۳/۰۱/۱۸

چکیده

اندازه‌گیری سریع و دقیق خصوصیات هندسی محصولات کشاورزی کاربردهای زیادی در امور مربوط به کاشت، داشت، برداشت و پس از برداشت دارد. محاسبات مربوط به انبارداری و نقل و انتقال، میزان مواد پوشش‌دهنده داده شده به محصولات برای افزایش عمر انبار داری، همچنین تخمین زمان پوست کنی و تعیین میزان تجمع مواد میکروبی روی محصول، از جمله کاربردهای مهم اندازه‌گیری حجم و سطح جانبی می‌باشند. ضریب کرویت نیز که یکی از پارامترهایی است که برای کمی کردن اختلاف در شکل میوه‌ها، سبزی‌ها، غلات و بذرها به‌کار می‌رود، در فرآیندهای جداسازی توسط ماشین‌های غربال و نیز قابلیت غلتش روی سطوح دارای اهمیت می‌باشد. استفاده از شبکه عصبی به‌عنوان یک روش سریع و غیرمخرب برای پیش‌بینی خصوصیات فیزیکی محصولات کشاورزی حائز اهمیت می‌باشد. در این تحقیق توانایی تکنیک شبکه عصبی مصنوعی به‌عنوان یک روش جایگزین در پیش‌بینی حجم، سطح جانبی و کرویت انار ارزیابی شد. برای این کار از مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری و رابطه رگرسیونی بین مقادیر پیش‌بینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شد. طبق نتایج به‌دست آمده مقدار $p \geq 0/85$ می‌باشد که نشان‌دهنده عدم وجود تفاوت معنی‌داری در سطح ۵ درصد بین مقادیر ویژگی‌های آماری مجموعه داده‌های پیش‌بینی شده توسط شبکه عصبی و مقادیر واقعی آنها بود. همچنین ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده بزرگتر از ۰/۹ شد.

واژه‌های کلیدی: انار، حجم، سطح جانبی، شبکه عصبی، کرویت

مقدمه

سبزی‌ها، غلات و بذرها به‌کار می‌رود و در فرآیندهای جداسازی توسط ماشین‌های غربال و نیز قابلیت غلتش روی سطوح دارای اهمیت می‌باشد (Mohsenin, 1978; Jain and Bal, 1997). باایرام با روش‌های تحلیل ابعادی معادلاتی را برای محاسبه کرویت مواد غذایی ارائه کرده (Bayram, 2005). اما در مورد سطح جانبی و حجم روش‌های متنوع‌تری وجود دارد. در بعضی روش‌ها تخمین سطح جانبی به‌صورت مخرب بوده است. فرچت و زهرادینک سطح جانبی سیب را با پوست‌کنند آن و ترسیم خطوط مرزی پوست روی کاغذ به‌دست آوردند (Frechette and Zahradnik, 1966). محققانی هم این پارامتر را به‌صورت غیر مخرب اندازه‌گیری کردند. به‌عنوان مثال هرشکو و همکاران از میکروسکوپی نیروی اتمی برای محاسبه میزان پوست پیاز و سیر استفاده کردند (Hershko et al., 1998). در پژوهشی دیگر کومار و ماتیو معادله‌ای انتگرالی برای محاسبه سطح جانبی محصولات کشاورزی و غذایی با شکل بیضی‌گون پیشنهاد کرده‌اند (Kumar and Mathew, 2003). پژوهش‌هایی نیز مبتنی بوده است بر استفاده از روش‌های پردازش تصویر برای اندازه‌گیری پارامترهای مختلف فیزیکی محصولات کشاورزی و غذایی با استفاده از این روش حجم و سطح جانبی محصولات کشاورزی که شکلی شبیه به بیضی‌گون دارند مثل

اندازه‌گیری حجم و سطح جانبی محصولات کشاورزی و غذایی از جمله میوه‌ها، سبزی‌ها و خشکبار در محاسبات مربوط به انبارداری و نقل و انتقال، میزان مواد گازی یا افشانه‌ای داده شده، میزان تنفس و نیز داده‌های مربوط به جذب یا از دست دادن آب در کنار محاسبه میزان مواد پوشش‌دهنده به مواد غذایی برای افزایش عمر انبارداری، محاسبه انتقال حرارت، میزان تبخیر آب و آفت‌کش می‌تواند مفید باشد (Turrell et al., 1946; Clayton et al., 1995; Hershko et al., 1998; Eifert et al., 2006). علاوه بر این، تخمین میزان مواد شیمیایی داده شده، زمان پوست‌کنی و تعیین میزان تجمع مواد میکروبی روی محصول از کاربردهای مهم این پارامترها در صنایع غذایی می‌باشد (Sabilov et al., 2002). ضریب کرویت، یکی از پارامترهایی است که برای کمی کردن اختلاف در شکل میوه‌ها،

۱ و ۴- به‌ترتیب استادیار و دانشیار گروه مهندسی بیوسیستم و اعضای مرکز پژوهشی ماشین‌های کشاورزی، دانشکده کشاورزی، دانشگاه فردوسی مشهد (*- نویسنده مسئول: Email: arohani@um.ac.ir)

۲- دانشجوی دکتری، گروه مهندسی مکانیک ماشین‌های کشاورزی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران

۳- استادیار دانشکده مهندسی برق و روباتیک، دانشگاه شاهرود

(Mohsenin, 1978):

$$\varphi = \frac{(L_1 \times L_2 \times L_3)^{1/3}}{L_1} \quad (۱)$$

در این رابطه L_1 ، L_2 و L_3 اقطار اصلی انار (بدون در نظر گرفتن تاج) می‌باشند که با کولیس (دقت آن ۰/۰۱) اندازه‌گیری شدند.

حجم واقعی هر انار به روش جابه‌جایی آب محاسبه شد. برای تعیین حجم علاوه بر روش جابه‌جایی آب از روش تقریب بیضی‌گون نیز استفاده شد. در روش تقریب بیضی‌گون حجم هر انار با فرض اینکه می‌توان آن را به شکل یک بیضی‌گون فرض نمود محاسبه شد. با این فرض، حجم هر بیضی‌گون از رابطه (۲) به دست می‌آید:

$$V = \frac{\pi}{6} (L_1 \times L_2 \times L_3) \quad (۲)$$

از آنجا که امکان محاسبه سطح جانبی از طریق یک تابع ریاضی وجود ندارد، لذا از رابطه (۳) تخمین زده شد. این رابطه یک معادله انتگرالی است که توسط کومار و ماتیو ارائه شده است (Kumar and Mathew, 2003). این معادله به روش سیمپسون قابل حل می‌باشد.

(۳)

S

$$= 4 \int_0^{\frac{\pi}{2}} \sqrt{b^2 \sin^2 \varphi + c^2 \cos^2 \varphi} \\ \times \sqrt{b^2 \cos^2 \varphi + c^2 \sin^2 \varphi} d\varphi (4a \int_0^{\frac{\pi}{2}} \sqrt{b^2 \sin^2 \varphi + c^2 \cos^2 \varphi} \\ \times \left(\frac{\arcsin \left(\sqrt{1 - \left(\frac{b^2 \cos^2 \varphi + c^2 \sin^2 \varphi}{a^2} \right)} \right)}{\sqrt{1 - \left(\frac{b^2 \cos^2 \varphi + c^2 \sin^2 \varphi}{a^2} \right)}} \right) d\varphi)$$

در این رابطه a ، b و c نصف سه قطر اصلی می‌باشند. دقت این رابطه وابسته به دقت اندازه‌گیری سه قطر اصلی است.

پیش‌پردازش داده‌ها: قبل از به‌کارگیری داده‌های خام اولیه در

آموزش شبکه، باید داده‌ها در دامنه مناسبی نرمالیزه شود، زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین به دلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی [۰ ۱] به‌کار گرفته شده در لایه میانی، این امر ضروری به نظر می‌رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و لذا نتایج مطلوب حاصل نمی‌شود (Rohani et al., 2011). زمانی که از تابع فعالیت سیگموئیدی استفاده می‌شود، بهترین دامنه تبدیل داده‌ها [۰/۱ ۰/۹] می‌باشد (Rohani and Makarian, 2011). برای تبدیل داده‌ها از روش نرمالیزاسیون خطی رابطه (۴) استفاده شد:

تخم‌مرغ، لیمو، هلو، گوشت کبک‌کلی و پرتقال محاسبه شده است (Sabilov et al., 2002; Du and Sun, 2006; Khojastehnazhand et al., 2009). در این روش‌ها اغلب، حجم و سطح جانبی هر محصول از مجموع حجم و سطح جانبی هر کدام از مخروط ناقص‌های حاصل از تقسیم تصاویر دیجیتالی حاصل می‌شود. برخی روش‌ها نیز مبتنی بوده است بر ارائه روابط همبستگی بین سطح جانبی و پارامترهایی مثل وزن، حجم و اقطار اصلی که به سادگی قابل اندازه‌گیری می‌باشند (Baten and Marshall, 1943; Banks, 1985; Clayton et al., 1995; Frechette and Zahradnik, 1966; Maw et al., 1996). ایگاتیناتان و چاتوپادیای یک معادله رگرسیونی ساده با استفاده از سه قطر اصلی برای اندازه‌گیری سطح جانبی مواد غذایی بیضی‌گون پیشنهاد کردند (Igathinathane and Chattopadhyay, 2000). همچنین کلایتون و همکاران از یک مدل رگرسیونی غیر خطی که جرم و حجم میوه در آن به‌کار برده شده برای پیش‌بینی سطح جانبی سیب استفاده کردند (Clayton et al., 1995). هومیدا و هوبانی از وزن و قطر میانگین در معادله پیش‌بینی سطح جانبی و حجم انار استفاده نمودند (Humeida and Hobani, 1993). در روش‌هایی جدیدتر وانگ و نگوانگ از یک حسگر تصویری و یک میکروکنترلر برای تخمین حجم و سطح جانبی محصولات کشاورزی با شکل متقارن استفاده نمودند و ایگاتیناتان و همکاران از تصویر برداری سه بعدی برای تعیین حجم، سطح جانبی و تراکم پوشش بیوماس متراکم استفاده نمودند (Wang and Nguang, 2007; Igathinathane et al., 2010). استفاده از شبکه عصبی به‌عنوان یک روش سریع و غیرمخرب برای پیش‌بینی خصوصیات فیزیکی محصولات کشاورزی مفید می‌باشد. ظریف نشاط و همکاران با استفاده از شبکه‌های عصبی مصنوعی حجم لهیدگی‌های میوه سیب را پیش‌بینی نمود و به این نتیجه رسید که دقت این روش از مدل رگرسیونی برای پیش‌بینی حجم لهیدگی سیب بیشتر می‌باشد (Zarifneshat et al., 2012). کاربرد شبکه عصبی در پیش‌بینی خصوصیات رئولوژیکی نان، خصوصیات ظاهری هویج در حین خشک شدن، خصوصیات الکتریکی شیر و غیره در منابع ذکر شده است (Therdthai and Zhou, 2001; Kerdpiroon et al., 2006; Razmi-Rad et al., 2007). هدف از این تحقیق پیش‌بینی حجم، سطح جانبی و ضریب کرویت میوه انار براساس سه قطر اصلی آن با استفاده از شبکه عصبی مصنوعی به‌عنوان یک روش جایگزین می‌باشد.

مواد و روش‌ها

در این تحقیق ۴۰ عدد انار از نوع رقم بجستانی با اندازه‌های مختلف انتخاب شدند و پس از اندازه‌گیری ابعاد آنها در یک جهت عمود بر هم، ضریب کرویت شان با استفاده از رابطه (۱) محاسبه شد

مجموع کل مربعات خطا (TSSE^۳) می‌باشد و با استفاده از رابطه (۵) محاسبه می‌شود:

$$TSSE = \sum_q \sum_k (d_k^q - z_k^q)^2, \quad q = 1, \dots, Q \quad (5)$$

زمانی الگوریتم متوقف می‌شود که TSSE کوچکتر از مقدار آستانه (۰/۰۰۱) مقدار آستانه در نظر گرفته شده برای تحقیق حاضر) باشد.

معیارهای ارزیابی عملکرد شبکه عصبی: برای ارزیابی

مدل‌ها و روش‌های مورد بحث در پیش‌بینی حجم، سطح جانبی و کرویت انار از معیارهای متوسط قدرمطلق درصد خطا (MAPE^۴) و ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش‌بینی شده توسط مدل و مقادیر واقعی آنها استفاده شد (Rohani et al., 2011).

$$MAPE = \frac{1}{nm} \sum_{j=1}^n \sum_{i=1}^m \left| \frac{d_{ji} - p_{ji}}{d_{ji}} \right| \times 100 \quad (6)$$

در اینجا d_{ji} مؤلفه i ام از خروجی واقعی مربوط به الگوی j ام، p_{ji} مؤلفه i ام از خروجی پیش‌بینی شده توسط شبکه مربوط به الگوی j ام، \bar{d} و \bar{p} به ترتیب متوسط خروجی‌های واقعی و پیش‌بینی شده توسط شبکه و n و m به ترتیب تعداد الگوها و تعداد متغیرهای خروجی هستند.

نتایج و بحث

تنظیم پارامترهای شبکه: لایه ورودی شامل ۳ نرون می‌باشد

زیرا ورودی‌های شبکه شامل سه قطر اصلی می‌باشند. برای آموزش بهتر شبکه از عامل بایاس نیز در بردار ورودی استفاده شد. لایه خروجی در شبکه تنها شامل یک نرون است که نشان‌دهنده یکی از پارامترهای سطح جانبی، حجم و کرویت انار می‌باشد. تعیین توپولوژی بهینه، تعداد نرون‌ها در لایه مخفی شبکه از طریق آزمون سعی و خطا به دست آمد. اگر تعداد نرون‌ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. ولی در تعداد بسیار زیاد آن مسئله بیش برآزشی^۵ به وجود خواهد آمد که این منجر به تضعیف ویژگی تعمیم‌پذیری شبکه می‌شود. در طول آزمون آهنگ یادگیری، عامل ممتوم و تعداد تکرارها ($\alpha=0/8$, $\eta=0/4$, $\alpha_1=100$ و $Q=1000$) ثابت نگه داشته شد. این فرآیند برای تعداد نرون‌های لایه مخفی ۲ تا ۱۰ انجام شد. نهایتاً بهترین نتیجه در ۵ نرون در لایه مخفی به دست آمد. بعد از این مرحله، باید مقادیر بهینه پارامتر یادگیری (η) و عامل ممتوم (α) را به دست آورد.

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times (r_{\max} - r_{\min}) + r_{\min} \quad (4)$$

در اینجا x داده خام اولیه، x_n داده نرمالیزه شده، x_{\min} و x_{\max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه و r_{\min} و r_{\max} به ترتیب حد بالایی و پایینی دامنه تغییرات داده‌های تبدیل شده است. در این تحقیق تنها مقادیر حجم به صورت واقعی محاسبه شده است، سطح جانبی و کرویت انار از طریق روابط مذکور محاسبه و به عنوان مقادیر واقعی در شبکه عصبی به کار برده شد. مجموعه داده‌ها شبیه‌سازی شد تا بتوان براساس آنها شبکه عصبی آموزش ببیند و پس از آن حجم، سطح جانبی و کرویت انارهای واقعی تخمین زده شد.

شبکه عصبی پرسپترون چندلایه: براساس قضیه تقریب

عمومی، شبکه عصبی با یک لایه مخفی و با تعداد کافی نرون در آن لایه قادر به تقریب هر تابع پیوسته دلخواه است (Makarian and Rohani, 2011; Haykin, 1994)، بنابراین یک لایه مخفی برای شبکه عصبی انتخاب شد. ساختار شبکه MLP با یک لایه مخفی در شکل ۱ نشان داده شده است. شبکه MLP با دریافت بردار ورودی $[L_1 \ L_2 \ L_3]^q$ ، بردار خروجی Z^q را 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 حد ممکن نزدیک به خروجی مطلوب d^q متناظر با خود باشد. برای آموزش شبکه از الگوریتم پس انتشار با نرخ یادگیری کاهشی (BDLRF^۱) استفاده شد. این الگوریتم نسبت به الگوریتم پس انتشار اصلی (BB^۲) به عنوان یک الگوریتم رایج در آموزش شبکه MLP دارای مزایایی از قبیل سهولت در تنظیم پارامترهای یادگیری شبکه به سبب پایین آوردن حساسیت شبکه به مقادیر آهنگ یادگیری و عامل ممتوم، کاهش زمان یادگیری از طریق پایین آوردن تعداد تکرارهای مورد نیاز برای یادگیری و بهبود رفتار شبکه در طول آموزش می‌باشد. برنامه رایانه‌ای این الگوریتم در محیط برنامه‌نویسی نرم افزار MATLAB نسخه ۷ تهیه شد.

الگوریتم BDLRF: این الگوریتم نسخه اصلاح شده الگوریتم

پس انتشار اصلی می‌باشد (Vakil-Baghmisheh and Pavešic, 2001). این الگوریتم آموزش را با آهنگ یادگیری (η) و عامل ممتوم (α) ثابت و نسبتاً بزرگ شروع می‌کند و قبل از آن که شبکه ناپایدار و یا همگرایی آن کند شود، هر T تکرار ($3 \leq T \leq 5$) آهنگ یادگیری و فاکتور ممتوم را از طریق تصاعد حسابی به صورت یکنواخت کاهش داده تا زمانی که این پارامترها به x درصد (۵٪) مقادیر اولیه خودشان برسند. تابع هزینه به کار رفته در این الگوریتم


3- Total sum-squared error

4- Mean absolute percentage error

5- Over-fitting

1- Back-propagation with declining learning-rate factor

2- Basic back-propagation



شکل ۱- ساختار شبکه MLP با یک لایه مخفی

Fig.1. MLP architecture with a hidden layer

شماره (۱) تا (۳) در جدول ۱ نشان داده شده است. تفاوت زیادی بین مقادیر پیش‌بینی شده حجم، سطح جانبی و کرویت و مقادیر واقعی آنها برای مدل شبکه عصبی ملاحظه نمی‌شود. ولی این تفاوت‌ها براساس رابطه (۲) در مقایسه با شبکه عصبی چندلایه پرسپترون بسیار چشمگیر می‌باشند. بنابراین شبکه عصبی در مقایسه با رابطه (۲) از شایستگی بیشتری برای تخمین حجم واقعی انار برخوردار است. لذا فرض بیضی‌گون بودن انارها را می‌توان رد کرد.

برای بررسی بیشتر قابلیت هر دو روش، میانگین، واریانس و توزیع آماری مقادیر واقعی و مقادیر پیش‌بینی شده آنها از نظر آماری مقایسه گردید. در اینجا فرض صفر بر تساوی میانگین، واریانس و توزیع آماری هر دو سری داده دلالت دارد. هر فرض در سطح احتمال ۹۵ درصد به کمک پارامتر p تست گردید. بنابراین اگر p محاسبه شده برای هر مقایسه بیشتر از $0/05$ باشد، فرض صفر را نمی‌توان رد کرد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون F ، t و کولموگروف-اسمیرنو استفاده شد. مقادیر p محاسبه شده برای دو روش محاسبه حجم انار و سطح جانبی و کرویت انار در جدول ۲ آمده است. این نتایج نشان می‌دهند که میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده حجم انار توسط مدل شبکه عصبی و نیز رابطه (۲) اختلاف معنی‌داری با هم ندارند. ولی مقادیر p محاسبه شده برای رابطه (۲) بسیار کمتر از مدل شبکه عصبی است و تا حد زیادی در مرز وجود اختلاف معنی‌دار قرار دارد. این دلیلی دیگر بر بالا بودن توانایی شبکه عصبی در مقایسه با فرض بیضی‌گون بودن انار برای تخمین حجم انار می‌باشد. تفاوت بین مقادیر پیش‌بینی شده توسط MLP و مقادیر تئوری دو پارامتر سطح جانبی و کرویت در سطح ۵ درصد قابل مشاهده نیست، لذا می‌توان پیشنهاد کرد که شبکه عصبی می‌تواند قابلیت این دو پارامتر را داشته باشد.

برای دستیابی به عملکرد بهتر و تسریع در همگرایی شبکه از عامل ممنتوم استفاده شد (Rohani *et al.*, 2011). به دلیل اثرات متقابل این دو پارامتر در عملکرد شبکه، پیدا کردن مقادیر بهینه آنها مشکل می‌باشد. از آنجا که این دو پارامتر تنها در آموزش شبکه به کار می‌روند، از معیارهای عملکردی در طول فاز آموزش برای بهینه کردن آنها استفاده شد. مقادیر بهینه پارامترهای η و α نیز از طریق آزمون و خطا انتخاب شدند. عملکرد شبکه برای تمام ترکیبات مقادیر آهنگ یادگیری و عامل ممنتوم در بازه تغییراتی $[0/5 \ 0/90]$ برای η و $0/9$ برای α با هم مقایسه شدند. نتایج نشان داد که بهترین عملکرد در مقادیر سطح ثابت $\alpha=0/80$ و $\eta=0/9$ به دست می‌آید. تعداد بهینه تکرارهای مورد نیاز شبکه برای یادگیری مجموعه داده‌های شبیه‌سازی شده برابر با ۱۰۰۰ تکرار بود. نقطه بهینه شروع الگوریتم BDLRF در ۳۰۰ تکرار حاصل شد. مقدار نهایی η و α به ترتیب برابر با $0/045$ و $0/04$ رسید.

تحلیل آماری: در اینجا تنها به آوردن نتایج حاصل از ارزیابی

شبکه عصبی آموزش دیده که شامل داده‌های انارهای مورد مطالعه است اکتفا می‌کنیم، زیرا معتبر بودن این نتایج دال بر موفقیت‌آمیز بودن فاز آموزش شبکه عصبی MLP می‌باشد (Ranjbar *et al.*, 2010). وزن‌های شبکه عصبی به منظور پیش‌بینی حجم انار طی فاز آموزش محاسبه شدند. هدف از این مرحله ارزیابی ویژگی تعمیم‌پذیری و شایستگی مدل شبکه عصبی است. بنابراین مدل شبکه عصبی با استفاده از مجموعه داده‌هایی غیر از مجموعه داده‌های آموزش (مجموعه داده‌های تست) ارزیابی شدند. برخی از مشخصه‌های آماری داده‌های استفاده شده در مرحله آزمون همراه با مقادیر پیش‌بینی شده آنها توسط مدل شبکه عصبی و نیز روابط

جدول ۱- مشخصه‌های آماری مقادیر واقعی و پیش‌بینی شده انار به دو روش شبکه عصبی و به روش بیضی‌گون

Table 1- Statistical characteristics of the actual values and the predicted of pomegranate using ellipsoidal technique and neural network method

ویژگی‌های آماری Statistical characteristics						نوع روش Type method		
sum	ske	kur	max	min	std	av		
9833.12	1.05	3.63	386.03	165.48	53.78	245.83	MLP, Eq2	dv
9053.34	1.04	3.55	341.96	154.26	45.87	226.33	Eq2	حجم Volume
9845.34	1.06	3.56	384.77	163.71	55.22	246.13	MLP	pv
716184.16	0.89	3.36	23724.99	13940.45	2369.48	17904.51	Eq3	dv
716249.82	0.89	3.31	23621.11	14076.68	2356.76	17906.52	MLP	Pv
38.69	-0.52	2.67	0.99	0.93	0.01	0.97	Eq1	dv
38.71	-0.75	2.81	0.99	0.93	0.01	0.97	MLP	pv
								سطح جانبی Lateral surface
								کرویت Sphericity

توضیحات: av: میانگین، std: انحراف معیار، min: کمینه، max: بیشینه، kur: کشیدگی، ske: چولگی، sum: مجموع، dv: مقادیر واقعی، pv: مقادیر پیش‌بینی شده، MLP: شبکه عصبی چند لایه پرسپترون

Description: av: Average, std: standard deviation, min: minimum, max: maximum, kur: kurtosis, ske: skewness, dv: actual value, pv: prediction value, MLP: multi-layer perceptron neural network

جدول ۲- مقایسات آماری مقادیر واقعی و پیش‌بینی شده حجم انار

Table 2- Statistical comparisons of actual values and the predicted volume of pomegranate

نوع تحلیل آماری Type of statistical analysis			نوع روش Method type	شاخص‌های هندسی Geometric parameters
مقایسه توزیع Comparisons of distribution	مقایسه واریانس Comparisons of variances	مقایسه میانگین Comparisons of means		
0.09	0.32	0.08	Eq2	حجم Volume
0.98	0.87	0.98	MLP	سطح جانبی Lateral surface
1.00	0.97	1.00	MLP	کرویت Sphericity
1.00	0.85	0.88	MLP	

کاملاً مشهود می‌باشد. پراکندگی مابین داده‌های تئوری و تخمین‌های شبکه عصبی در مورد پارامتر سطح جانبی در شکل ۳ نشان داده شده است، ضریب تبیین این رابطه بیشتر از ۰/۹۹۹ می‌باشد و از طرف دیگر شیب آن نیز نزدیک به یک است ولی عرض از مبدأ بالاتری دارد که این ممکن است به جهت استفاده از تخمین‌های تئوری به جای واقعی باشد.


در جدول شماره ۴ معیار متوسط قدر مطلق درصد خطا برای دو روش مذکور جهت تخمین حجم انار با هم مقایسه شده‌اند. با توجه به نتایج ذکر شده در این جدول، MAPE شبکه عصبی به‌ترتیب تقریباً نصف و یک سوم رابطه (۲) برای محاسبه حجم می‌باشند. مقدار MAPE نیز برای سطح جانبی و کرویت به‌ترتیب ۰/۱۲ و ۰/۲۰ درصد می‌باشد.

شکل ۲، همبستگی و رابطه رگرسیونی بین حجم واقعی و پیش‌بینی‌شده توسط رابطه (۲) و شبکه عصبی MLP را نشان می‌دهد. بهترین نتایج براساس این شکل وقتی به‌دست می‌آید که معادله خطی مابین حجم واقعی و حجم پیش‌بینی شده توسط مدل علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدأ (نزدیک به صفر) و شیب نزدیک به یک باشد ($pv=1/0 \cdot dv+0/0$). کاملاً واضح است که ضرایب تبیین بین داده‌های واقعی و پیش‌بینی شده توسط شبکه عصبی چندلایه پرسپترون و رابطه (۲) نسبتاً بالا و برابر با یکدیگر می‌باشند ($R^2=0/948$). مقایسه رابطه خطی رگرسیونی بین حجم واقعی و پیش‌بینی شده توسط شبکه عصبی چندلایه پرسپترون و رابطه (۲) نشان از برتری مدل شبکه عصبی دارد، زیرا مدل MLP علاوه بر داشتن شیب نزدیک‌تر به یک، عرض از مبدأ بسیار کوچکتر در حدود ۶۰ مرتبه کوچکتر نسبت به رابطه (۱) دارد. موارد مذکور برای کرویت که در شکل ۴ نشان داده شده است

نتیجه‌گیری

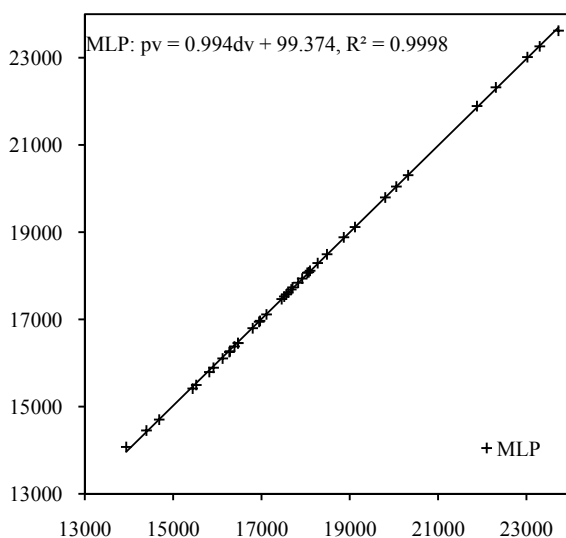
(MAPE) در اندازه‌گیری حجم واقعی میوه انار به روش شبکه عصبی تقریباً نصف روش تقریب بیضوی بوده است (به ترتیب ۳/۸۲ و ۷/۷۱). همچنین استفاده از شبکه عصبی در پیش‌بینی سطح جانبی انار دارای اهمیت می‌باشد.

شبکه عصبی مصنوعی قابلیت پیش‌بینی حجم، سطح جانبی و کرویت میوه انار را دارا می‌باشد. با توجه به نتایج به‌دست آمده از این تحقیق، دقت بالاتر شبکه عصبی در پیش‌بینی حجم انار نسبت به رابطه ریاضی تقریب بیضوی به اثبات رسید. معیار متوسط درصد خطا




شکل ۲- نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده حجم انار به کمک دو روش MLP و Eq2

Fig.2. Scatter diagram of the predicted values of MLP versus actual values of volume pomegranate in comparison with estimates from Eq2



شکل ۳- نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده سطح جانبی انار به کمک MLP در مقایسه با تخمین‌های Eq3

Fig.3. Scatter diagram of the predicted values of MLP versus actual values of lateral surface pomegranate in comparison with estimates from Eq3



شکل ۴- نمودار پراکندگی مقادیر واقعی و پیش‌بینی شده کرویت انار به کمک MLP در مقایسه با تخمین‌های Eq1

Fig. 4. Scatter diagram of the predicted values of MLP versus actual values of sphericity pomegranate in comparison with estimates from Eq1

چراکه دقت آن نسبت به رابطه ارائه شده توسط کومار و ماتيو تفاوت چندانی نداشته و در مقابل، از سادگی بیشتری نسبت به آن برخوردار می‌باشد (Kumar and Mathew, 2003). ضریب کرویت نیز پارامتر فیزیکی دیگری است که در این پژوهش توسط شبکه عصبی با دقت بالا پیش‌بینی شد ($R^2=0.9335$). در مجموع استفاده از مقادیر محاسبه شده حجم (رابطه ۲) و سطح جانبی (رابطه ۳) در الگوریتم پیش‌بینی شبکه عصبی، خطای پیش‌بینی را افزایش می‌دهد و بهتر است مقادیر اندازه‌گیری شده سطح جانبی و حجم محصول در الگوریتم شبکه عصبی استفاده شود.

جدول ۴- مقدار MAPE شبکه عصبی در پیش‌بینی سطح جانبی، حجم و کرویت انار

Table 4- The value MAPE of neural network in the prediction of lateral surface, volume and sphericity pomegranate

کرویت	سطح جانبی	حجم	
Sphericity	Lateral surface	Eq2	MLP
MLP	MLP	7.71	3.82
0.20	0.12		

منابع

- Banks, N. H. 1985. Surface area estimation of potato tubers. Potato Research 28: 487-495.
- Baten, W. D., and R. E. Marshall. 1943. Some methods of approximate prediction of surface area of fruits. Journal of Agricultural Research 66: 357-373.
- Bayram, M. 2005. Determination of the sphericity of granular food materials. Journal of Food Engineering 68 (3): 385-390.
- Clayton, M., N. D. Amos., N. H. Banks., and R. H. Morton. 1995. Estimation of apple fruit surface area. New Zealand Journal of Crop and Horticulture Science 23: 345-349.
- Du, C. J., and D. W. Sun. 2006. Estimating the surface area and volume of ellipsoidal ham using computer vision. Journal of Food Engineering 73 (3): 260-268.
- Eifert, J. D., G. C. Sanglay, D. Lee, S. S. Summer, and M. D. Pierson. 2006. Prediction of raw produce surface area from weight measurement. Journal of Food Engineering 74 (4): 552-556.
- Frechette, R. J., and J. W. Zahradnik. 1966. Surface area-weight relationships for Macintosh apples. Transactions of the American Society of Agricultural Engineers 9: 526-527.
- Haykin, S. 1994. Neural networks: A comprehensive foundation. McMillan College Publishing Company, New York.
- Hershko, V., D. Weisman, and A. Nussinovitch. 1998. Method for studying surface topography and

- roughness of onion and garlic skins for coating purposes. *Journal of Food Science* 63 (2): 317-321.
10. Humeida, M. A., and A. I. Hobani. 1993. Physical properties of pomegranate fruits. *Journal of King Saud University Agricultural Science* 5 (2): 165-175.
 11. Igathinathane, C., and P. K. Chattopadhyay. 2000. Surface area of general ellipsoid shaped food materials by simplified regression equation method. *Journal of Food Engineering* 46 (4): 257-266.
 12. Igathinathane, C., J. D. Davis., J. L. Purswell., and E. P. Columbus. 2010. Application of 3D scanned imaging methodology for volume, surface area, and envelope density evaluation of densified biomass. *Bioresource Technology* 101 (11): 4220-4227.
 13. Jain, R. K., and S. Bal. 1997. Properties of pearl millet. *Journal of Agricultural Engineering Research* 66 (2): 85-91.
 14. Kerdpi boon, S., W. L. Kerr, and S. Devahastin. 2006. Neural network prediction of physical property changes of dried carrot as a function of fractal dimension and moisture content. *Food Research International* 39 (10): 1110-1118.
 15. Khojastehnazhand, M., M. Omid, and A. Tabatabaefar. 2009. Determination of orange volume and surface area using image processing technique. *Int. Agrophys.* 23: 237-242.
 16. Kumar, V. A., and S. Mathew. 2003. A Method for estimating the surface area of ellipsoidal food materials. *Biosystems Engineering* 85 (1): 1-5.
 17. Makarian, H., and A. Rohani. 2011. Prediction of spatial distribution patterns of *Hordeum glaucum* steud. Population using neural network model. *Journal of Plant Protection* 24 (4): 471-480. (in Farsi).
 18. Maw, B. W., Y. C. Hung, E. W. Tollner, D. A. Smittle, and B. G. Mullinix. 1996. Physical and mechanical properties of fresh and stored sweet onions. *Transactions of the American Society of Agricultural Engineers* 39 (2): 633-637.
 19. Mohsenin, N. N. 1978. *Physical properties of plant and animal materials*. Gordon and Breach Science Publishers, New York.
 20. Ranjbar, I., M. H. Abbaspour-Fard., Y. Ajabshirchi, and A. Rohani. 2010. Prediction of John Deere tractor repair and maintenance costs by using two different structures of MLP artificial neural network. *Agriculture Economics & Development* 22 (2): 87-96. (In Farsi).
 21. Razmi-Rad, E., B. Ghanbarzadeh, S. M. Mosavi, Z. Emam-Djomeh, and J. Khazaei. 2007. Prediction of rheological properties of Iranian bread dough from chemical composition of wheat flour by using artificial neural networks. *Journal of Food Engineering* 81 (4): 728-734.
 22. Rohani, A., M. H. Abbaspour-Fard, and S. Abdolapour. 2011. Prediction of tractor repair and maintenance costs using artificial neural network. *Expert Sys. Applications* 38: 8999-9007.
 23. Rohani, A., and H. Makarian. 2011. Making weed management maps by artificial neural networks for using in precision agriculture. *Journal of Agricultural Machinery Engineering* 1 (2): 74-83. (In Farsi).
 24. Sabilov, C. M., D. Boldor, K. M. Keener, and B. E. Farkas. 2002. Image processing method to determine surface area and volume of axisymmetric agricultural products. *International Journal of Food Properties* 5 (3): 641-653.
 25. Therdthai, N., and W. Zhou. 2001. Artificial neural network modelling of the electrical conductivity property of recombined milk. *Journal of Food Engineering* 50 (2): 107-111.
 26. Turrell, F. M., J. P. Carlson, and L. J. Klotz. 1946. Tables of coefficients for estimating oblate and prolate spheroidal surfaces and volumes from spherical surfaces and volumes. *Proceedings of American Society for Horticultural Science* 48: 326.
 27. Vakil-Baghmisheh, M. T., and N. Pavešić. 2001. Back-propagation with declining learning rate. *Proceeding of the 10th Electrotechnical and Computer Science Conference, Portorož, Slovenia B*: 297-300.
 28. Wang, T. Y., and S. K. Nguang. 2007. Low cost sensor for volume and surface area computation of axisymmetric agricultural products. *Journal of Food Engineering* 79 (3): 870-877.
 29. Zarifneshat, S., A. Rohani, H. R. Ghassemzadeh, M. Sadeghi, A. Ebrahim, and M. Zarifneshat. 2012. Predictions of apple bruise volume using artificial neural network. *Computers and Electronics in Agriculture* 82: 75-86.

Prediction of lateral surface, volume and sphericity of pomegranate using MLP artificial neural network

A. Rohani^{1*} - S. I. Saedi² - H. Gerailue³ - M. H. Aghkhani⁴

Received: 12-11-2013

Accepted: 07-04-2014

Introduction: Fast and accurate determination of geometrical properties of agricultural products has many applications in agricultural operations like planting, cultivating, harvesting and post-harvesting. Calculations related to storing, shipping and storage-coating materials as well as peeling time and surface-microbial concentrations are some applications of estimating product volume and surface area. Sphericity is also a parameter by which the shape differences between fruits, vegetables, grains and seeds can be quantified. This parameter is important in grading systems and inspecting rolling capability of agricultural products. Bayram presented a new dimensional method and equation to calculate the sphericity of certain shapes and some granular food materials (Bayram, 2005). Kumar and Mathew proposed a theoretically sound method for estimating the surface area of ellipsoidal food materials (Kumar and Mathew, 2003). Clayton *et al.* used non-linear regression models for calculation of apple surface area using the fruit mass or volume (Clayton *et al.*, 1995). Humeida and Hobani predicted surface area and volume of pomegranates based on the weight and geometrical diameter mean (Humeida and Hobani, 1993). Wang and Nguang designed a low cost sensor system to automatically compute the volume and surface area of axi-symmetric agricultural products such as eggs, lemons, limes and tamarillos (Wang and Nguang, 2007). The main objective of this study was to investigate the potential of Artificial Neural Network (ANN) technique as an alternative method to predict the volume, surface area and sphericity of pomegranates.

Materials and methods: The water displacement method (WDM) was used for measuring the actual volume of pomegranates. Also, the sphericity and surface area are computed by using analytical methods. In this study, the neural MLP models were designed based upon the three nominal diameters of pomegranates as variable inputs, while the output model consisted of each of the three parameters including the volume, sphericity and surface area. Prior to any ANN training process, the data normalized over the range of [0, 1]. Fig. 1 shows a MLP with one hidden layer. In this study, back-propagation with declining learning-rate factor (BDLRF) training algorithm was employed. The mean absolute percentage error (MAPE) and the coefficient of determination of the linear regression line between the predicted values from the MLP model and the actual output were used to evaluate the performance of the model.

Results and Discussion: The number of neurons in the hidden layer and also the optimal values for the learning parameters η and α were selected by trial and error method. The best result was achieved with five neurons in the hidden layer. The results showed that the optimum model of performance was obtained at constant momentum term equal to 0.8 and learning rate equal to 0.9. In this study, 300 epochs were selected as the starting points of the BDLRF. Some statistical characteristics of the actual values of volume were estimated by WDM, surface area was computed by equation (3) and sphericity of pomegranates was computed by equation (1) and the predicted values of them using the neural network method were shown in Table 1. The obtained results verified that the differences between the actual values and the estimated ones can be ignored. But, the predicted values of the volume using the MLP model in comparison with equation (2) are much closer to the actual values. Statistical comparisons of desired and predicted data and the corresponding p values are given in Table 2. The results showed that P-value was greater than 0.08 in all cases. Therefore, there was no significant difference between the statistical parameters. However, the P-value for equation 2 is much less than that of the MLP model. The results shown in Figures 2, 3 and 4 show that the coefficients of determination between actual and predicted data were greater than 0.9. Considering all the results in our study, the MLP model is more accurate than the WDM and analytical methods.

1, 4- Respectively Assistant and Associate Professor of Biosystems Engineering and Members of Research Center for Agricultural Machines, College of Agriculture, Ferdowsi University of Mashhad

2- PhD Candidate of Agricultural Machinery Mechanics, Department of Agricultural Machinery, Faculty of Agricultural Engineering and Technology, University College of Agriculture and Natural Resources, University of Tehran

3- Assistant Professor, Department of Electrical and Robotics Engineering, Faculty of Electronics, University of Shahrood

(* - Corresponding Author Email: arohani@um.ac.ir)

Conclusions: In this paper, we first measure the actual volume of the pomegranate using WDM and equation (2). Also, assuming an elliptical fruit, the sphericity and surface area are computed analytically based on the three nominal diameters of a pomegranate. Finally, the results of achievements of the MLP designed revealed that the MLP model could be successfully applied to the prediction of the sphericity and surface area. Therefore, the MLP model can be a viable alternative to the analytical methods. However, this is possible only if there is a precise way to compute the three nominal diameters of pomegranates. In addition, according to the MAPE, the accuracy of the MLP model in prediction of volume of pomegranates was twice the analytical method.

Keywords: Neural network, Pomegranate, Sphericity, Surface area, Volume