

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

عباس روحانی<sup>۱</sup>، سید ایمان سعیدی<sup>۲</sup>، هادی گرایلو<sup>۳</sup>، محمد حسین آق خانی<sup>۴</sup>

۱- استادیار گروه مکانیک ماشینهای کشاورزی دانشگاه فردوسی مشهد

۲- مری دانشکده کشاورزی دانشگاه صنعتی شاهرود

۳- استادیار دانشکده برق و ریاتیک دانشگاه صنعتی شاهرود

۴- دانشیار گروه مکانیک ماشینهای کشاورزی دانشگاه فردوسی مشهد

### چکیده

اندازه گیری 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، در کنار محاسبه میزان مواد بوششی 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 اندازه گیری حجم و سطح جانبی می‌باشدند. ضریب کرویت نیز که یکی از پارامترهایی است که برای کمی کردن اختلاف در شکل میوه‌ها، سبزی‌ها، غلات و بذرها به کار می‌رود، در فرایندهای جداسازی توسط ماشینهای غربال و نیز قابلیت غلتی روی سطوح دارای اهمیت می‌باشد. استفاده از شبکه عصبی به عنوان یک روش سریع و غیرمخرب برای پیش‌بینی خصوصیات فیزیکی محصولات کشاورزی حائز اهمیت می‌باشد. توانایی تکنیک شبکه عصبی مصنوعی به عنوان یک روش جایگزین در پیش‌بینی حجم، سطح جانبی و کرویت انار ارزیابی شد. از مقایسه آماری پارامترهای مانند میانگین، واریانس، توزیع آماری و رابطه رگرسیونی بین مقادیر پیش‌بینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شد. نتایج نشان داد که مقادیر  $p \leq 0.085$  بدست آمد، که نشان دهنده عدم وجود تفاوت معنی داری در سطح ۵ درصد بین مقادیر ویژگی‌های آماری مجموعه داده‌های پیش‌بینی شده 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، کرویت، شبکه عصبی

### مقدمه

اندازه گیری دقیق و سریع خواص فیزیکی محصولات کشاورزی به سبب پیچیدگی فناوریهای مدرن برای کاشت، داشت، برداشت، پس از برداشت، ارزیابی کیفی، توزیع، بازاریابی و مصرف حائز اهمیت فراوانی می‌باشد. اندازه گیری 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

افشانه ای داده شده، میزان تنفس و نیز داده های مربوط به جذب یا از دست دادن آب در کار محاسبه میزان مواد پوششی داده شده به مواد غذایی برای افزایش عمر انبار داری، محاسبه انتقال حرارت، میزان تبخیز آب و آفتکش می تواند مفید باشد(Turrell et al., 1995; Clayton et al., 1996; Hershko et al., 1998; Eifert et al., 2006). علاوه بر این، تخمین میزان مواد شیمیایی داده شده، زمان پوست کنی و تعیین میزان تجمع مواد میکروبی روی محصول از کاربردهای مهم این پارامترها در صنایع غذایی می باشد(Sabilov et al., 2002). ضریب کرویت نیز که یکی از پارامترهایی است که برای کمی کردن اختلاف در شکل میوه ها، سبزی ها، غلات و بذرها به کار می رود، در فرایندهای جداسازی توسط ماشین های غربال و نیز قابلیت غلتیش روی سطوح دارای اهمیت می باشد(Mohsenin, 1978; Jain and Bal, 1997). همچنین با این روش های تحلیل ابعادی معادلاتی را برای محاسبه کرویت مواد غذایی دانه ای ارائه کرد(Bayram, 2005). اما در مورد سطح جانبی و حجم روش های متعدد تری وجود دارد. در بعضی روش های تخمین سطح جانبی به صورت مخرب بوده است. فرچت سطح جانبی سبب را با پوست کندن آن و ترسیم خطوط مرزی پوست روی کاغذ انجام داد(Frechette and Zahradnik, 1966). محققانی هم این پارامتر را به صورت غیر مخرب اندازه گیری کردند. به عنوان 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 معادله ای انتگرالی برای محاسبه سطح جانبی محصولات کشاورزی و غذایی با شکل بیضیگون پیشنهاد کردند(Kumar and Mathew, 2003). پژوهش هایی نیز مبتتنی بوده است بر استفاده از روش های پردازش تصویر برای اندازه گیری 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 تخمه مرغ، لیمو و هل و گوشت کوکتلی و پرتوال 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 ناقص های حاصل از تقسیم تصاویر دیجیتالی حاصل می شود. برخی روشها نیز مبتتنی بوده است بر ارائه روابط همبستگی بین سطح جانبی و پارامترهایی مثل وزن، حجم و اقطار اصلی که به سادگی قابل اندازه گیری می باشند(Baten and Marshall, 1943; Banks, 1985; Clayton et al., 1995; Frechette and Zahradnik, 1966; Maw et al., 1996). ایگانیتان و چاتوپادیایی یک معادله رگرسیونی ساده با استفاده از سه قطر اصلی برای اندازه گیری 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 بکار برده شده برای پیش بینی سطح جانبی سبب استفاده کردند(Clayton et al., 1995). هومیدا و هویانی از وزن و قطر میانگین در معادله پیش بینی سطح جانبی و حجم انثار استفاده نمودند(Humeida and Hobani, 1993). در روش هایی جدیدتر وانگ و نگانگ از یک سنسور تصویری و یک میکروکنترلر برای تخمین حجم و سطح جانبی محصولات کشاورزی با شکل متقاضی استفاده ایگانیتان و دیویس 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).

غیرمخرب برای پیش‌بینی خصوصیات فیزیکی محصولات کشاورزی حائز اهمیت می‌باشد. طریف نشاط و همکاران با استفاده از شبکه‌های عصبی مصنوعی حجم لهیدگی‌های میوه سبب را پیش‌بینی نمود و به این نتیجه رسید که دقت این روش از مدل رگرسیونی در پیش‌بینی حجم لهیدگی سبب 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; Kerdpiboon et al., 2006; Razmi-Rad and Ghanbarzadeh, 2007).

هدف این مقاله ارزیابی قابلیت پیش‌بینی حجم، سطح جانبی و ضربیت میوه انار براساس سه قطر اصلی با استفاده از شبکه‌های عصبی مصنوعی و تعیین مقادیر بهینه پارامترهای شبکه عصبی بدین منظور می‌باشد.

## مواد و روش‌ها

۴۰ عدد انار بجستان به صورت تصادفی انتخاب شد. ضربیت کرویت با استفاده از رابطه محسنین محاسبه شد(Mohsenin, 1978):

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

در این رابطه  $L_1$ ,  $L_2$  و  $L_3$  اقطار اصلی انار (بدون در نظر گرفتن تاج) می‌باشند که با کولیس اندازه گیری شده‌اند. حجم واقعی هر انار به روش جایجایی آب محاسبه شد. برای تعیین حجم علاوه بر روش جایجایی آب از روش تقریب بیضیگون نیز استفاده شده‌است. در روش تقریب بیضیگون حجم هر انار با فرض اینکه آن را می‌توان به شکل یک بیضیگون فرض نمود محاسبه شد. با این فرض، حجم هر بیضیگون از رابطه (۲) به دست می‌آید:

$$V = \frac{\pi}{6} (L_1 \times L_2 \times L_3) \quad (2)$$

سطح جانبی از طریق روش محاسباتی زیر (رابطه ۳) تخمین زده شد. این رابطه یک معادله انتگرالی است که توسط کومار و ماتیو ارائه شده‌است(Kumar and Mathew, 2003). این معادله به روش سیمپسون قابل حل می‌باشد.

$$S = 4 \int_0^{\frac{\pi}{2}} \sqrt{b^2 \sin^2 \varphi + c^2 \cos^2 \varphi} \times \sqrt{b^2 \cos^2 \varphi + c^2 \sin^2 \varphi} d\varphi + \quad (3)$$

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

در این رابطه  $a$ ,  $b$  و  $c$  نصف سه قطر اصلی می‌باشند.

**پیش پردازش داده ها:** قبل از بکارگیری داده های خام اولیه در آموزش شبکه، باید داده ها در دامنه مناسبی نرمالیزه شود زیرا الگوریتم یادگیری همراه با داده های خام نمی تواند عملکرد مناسبی داشته باشد و همچنین بدلیل دامنه تغییرات خروجی تابع فعالیت سیگموئیدی [۱۰] بکارگرفته شده در لایه میانی، این امر ضروری به نظر می رسد. در غیر این صورت شبکه در طول فاز آموزش همگرا نخواهد شد و لذا نتایج مطلوب حاصل نخواهد شد(Rohani et al., 2011). زمانیکه از تابع فعالیت سیگموئیدی استفاده می شود، بهترین دامنه تبدیل داده ها [۰/۹۰-۰/۱] می باشد(Rohani and Makarian, 2011). برای تبدیل داده ها از روش نرمالیزاسیون خطی معادله (۴) استفاده شد:

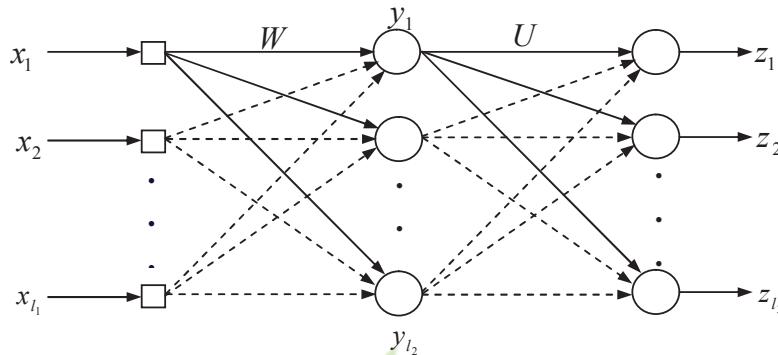
$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times (r_{\max} - r_{\min}) + r_{\min} \quad (4)$$

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

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 بکاربرده شد. مجموعه داده ها شبیه سازی شد تا بتوان براساس آنها شبکه عصبی آموزش ببیند و پس از آن حجم، سطح جانبی و کرویت انارهای واقعی تخمين زده شد.

**شبکه عصبی پرسپترون چندلایه:** بر اساس 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 با دریافت بردار ورودی  $X^q$ ، بردار خروجی  $Z^q$  برای هر  $q=1,\dots,Q$  (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<sup>۱</sup>) استفاده شد. این الگوریتم نسبت به الگوریتم پس انتشار اصلی (BB<sup>۲</sup>) بعنوان 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 ممتومن، کاهش زمان یادگیری از طریق پایین آوردن تعداد تکرارهای مورد نیاز برای یادگیری و بهبود رفتار شبکه در طول آموزش می باشد. کد کامپیوتربی این الگوریتم در محیط برنامه نویسی نرم افزار MATLAB نسخه ۷ تهیه شد.

- 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

**الگوریتم BDLRF :** این الگوریتم نسخه اصلاح شده الگوریتم پس انتشار اصلی می باشد (Vakil-Baghmisheh and Pavešić, 2001). این الگوریتم آموزش با آهنگ یادگیری ( $\eta$ ) و عامل ممتوом ( $\alpha$ ) ثابت و نسبتا بزرگ شروع می کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر  $T$  تکرار ( $3 \leq T \leq 5$ ) آهنگ یادگیری و فاکتور ممتووم را از طریق تصاعد حسابی بصورت یکنواخت کاهش داده تا زمانیکه این پارامترها به  $X$  درصد ( $0.5\%$ ) مقادیر اولیه خودشان برسند.تابع هزینه بکار رفته در این الگوریتم مجموع کل مربعات خطأ (TSSE<sup>۱</sup>) می باشد و با استفاده از معادله ۵ محاسبه می شود:

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

$d_k^q$  و  $z_k^q$  به ترتیب  $k$  امین عنصر از بردارهای خروجی مطلوب و واقعی از  $q$  امین ورودی است. یادگیری شبکه در دو فاز پیش

انتشار و پس انتشار اتفاق می افتد. وزن های هر لایه از شبکه از طریق معادله ۶ و ۷ محاسبه می شوند.

$$u_{jk}(n+1) = u_{jk}(n) - \eta \times \frac{\partial E}{\partial u_{jk}} + \alpha(u_{jk}(n) - u_{jk}(n-1)) \quad \text{و} \quad k = 1, \dots, l_3 \quad , \quad j = 1, \dots, l_2 \quad , \quad i = 1, \dots, l_1 \quad (6)$$

$$w_{ij}(n+1) = w_{ij}(n) - \eta \times \frac{\partial E}{\partial w_{ij}} + \alpha(w_{ij}(n) - w_{ij}(n-1)) \quad (7)$$

در اینجا  $w_{ij}$  اتصال وزنی بین گره های  $i$  و  $j$   $u_{jk}$  اتصال وزنی بین گره های  $j$  و  $k$ ، مقادیر اولیه این وزن ها بطور تصادفی از دامنه مقادیر  $[0/250]$  انتخاب می شود.  $l_2$  و  $l_3$  به ترتیب تعداد نرون ها در لایه مخفی و لایه خروجی می باشند.  $\eta$  و  $\alpha$  به ترتیب آهنگ یادگیری و فاکتور ممتووم هستند و مقادیر آنها در فاصله  $[0/100]$  قرار دارند و  $n$  شماره تکرار الگوریتم (TSSE) می باشد. زمانی الگوریتم متوقف می شود که  $TSSE$  کوچکتر از مقدار آستانه  $(0.0001)$  مقدار آستانه در نظر

1 - Total sum-squared error

گرفته شده برای مطالعه حاضر) باشد. جزئیات بیشتر این الگوریتم را می‌توان در مطالعات وکیل-باغمیشه و پاووسیک مشاهده کرد (Vakil-Baghmisheh and Pavešic, 2003).

**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 خطأ ( $MAPE^1$ ) و ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیش‌بینی شده توسط مدل و مقادیر واقعی آنها استفاده شدند (Rohani et al., 2011).

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

در اینجا  $d_{ji}$  مؤلفه ۱ام از خروجی واقعی مربوط به پtern ۱am،  $p_{ji}$  مؤلفه ۱am از خروجی پیش‌بینی شده توسط شبکه مربوط به پtern ۱am،  $\bar{d}$  و  $\bar{p}$  به ترتیب متوسط خروجی‌های واقعی و پیش‌بینی شده توسط شبکه و  $n$  و  $m$  به ترتیب تعداد پtern‌ها و تعداد متغیرهای خروجی هستند.

## نتایج و بحث

**تنظیم پارامترهای شبکه:** لایه ورودی شامل ۴ نرون می‌باشد زیرا ورودی‌های شبکه شامل عامل بایاس و سه قطر اصلی می‌باشند. لایه خروجی در شبکه تنها شامل یک نرون است که نشان دهنده یکی از پارامترهای سطح جانبی، حجم و کرویت انار می‌باشد. تعیین توپولوژی بهینه، تعداد نرون‌ها در لایه مخفی شبکه از طریق آزمون سعی و خطأ بدست آمد. اگر تعداد نرون‌ها در لایه مخفی کافی نباشد، شبکه قادر به یادگیری خوب نخواهد شد. ولی در تعداد بسیار زیاد آن مسئله پیش برآذشی<sup>۲</sup> بوجود خواهد آمد که این منجر به تضعیف ویژگی تعمیم پذیری شبکه می‌شود (Wang and Elhag, 2007). در طول آزمون آهنگ یادگیری، عامل ممتد و تعداد تکرارها (۱۰۰،  $n_1=100$ ،  $\alpha=0.08$ ،  $\eta=0.4$ ) 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 بدست آمد. بعد از این مرحله، باید مقادیر بهینه پارامتر یادگیری ( $\eta$ ) و عامل ممتد ( $\alpha$ ) را بدست آورد. برای دستیابی به عملکرد بهتر و تسريع در همگرایی شبکه از عامل ممتد استفاده شد (Vakil-Baghmisheh and Pavešic, 2003; Rohani et al., 2011). بدلیل اثرات متقابل این دو پارامتر در عملکرد شبکه، پیدا کردن مقادیر بهینه آنها مشکل می‌باشد (Vakil-Baghmisheh and Pavešic, 2003). از آنجا که این دو پارامتر تنها در آموزش شبکه بکار می‌روند، از معیارهای عملکردی در طول فاز آموزش برای بهینه کردن آنها استفاده شد. مقادیر بهینه پارامترهای  $\eta$  و  $\alpha$  نیز از طریق آزمون و خطأ انتخاب شدند. عملکرد شبکه برای تمام ترکیبات مقادیر آهنگ یادگیری و عامل ممتد در بازه تغییراتی [۰/۹۰ و ۰/۰۵] برای  $\eta$  و [۰/۰ و ۰/۹] برای  $\alpha$  با هم مقایسه شدند. نتایج نشان داد که بهترین عملکرد در مقادیر سطح ثابت  $\eta=0.9$  و  $\alpha=0.08$  بدست می‌آید. تعداد بهینه تکرارهای مورد نیاز شبکه برای یادگیری مجموعه داده‌های

1 - Mean absolute percentage error

2 - Over-fitting

شبیه سازی شده برابر با  $1000$  تکرار شد. نقطه بهینه شروع الگوریتم BDLRF در  $300$  تکرار حاصل شد. مقدار نهایی  $\alpha$  و  $\beta$  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 داده های انارهای مورد مطالعه است اکتفا می کنیم زیرا معتبر بودن این نتایج دال بر موقوفیت آمیز بودن فاز آموزش شبکه عصبی MLP می باشد(*Ranjbar et al., 2010*). وزن های شبکه عصبی به منظور پیش بینی حجم انار طی فاز آموزش محاسبه شدند. هدف از این مرحله ارزیابی ویژگی تعیین پذیری و شایستگی مدل شبکه عصبی است. بنابراین مدل شبکه عصبی با استفاده از مجموعه داده های غیر از مجموعه داده های آموزش (مجموعه داده های تست) ارزیابی شدند. برخی از ویژگیهای آماری داده های استفاده شده در فاز تست همراه با مقادیر پیش بینی شده آنها توسط مدل شبکه عصبی و نیز معادله شماره  $1$  تا  $3$  در جدول  $1$  نشان داده شده است. تفاوت زیادی بین مقادیر پیش بینی شده حجم، سطح جانبی و کرویت و مقادیر واقعی آنها برای مدل شبکه عصبی ملاحظه نمی شود. ولی این تفاوت ها براساس معادله شماره  $2$  در مقایسه با شبکه عصبی چند لایه پرسپترون بسیار چشمگیر می باشند. بنابراین شبکه عصبی در مقایسه با معادله شماره  $2$  از شایستگی بیشتری برای تخمين حجم واقعی انار برخوردار است. لذا فرض بیضیگون بودن انارها را می توان رد کرد.

**جدول ۱- ویژگی های آماری مقادیر واقعی و پیش بینی شده انار به دو روش شبکه عصبی و به روش بیضی گون**

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

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

توضیحات: av: میانگین std: انحراف معیار min: کمینه max: بیشینه kur: کشیدگی ske: چولگی sum: مجموع واقعی dv: مقادیر پیش بینی 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

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 فرضیه صفر بر تساوی میانگین، واریانس و توزیع آماری هر دو سری داده دلالت دارد. هر فرضیه در سطح احتمال ۹۵ درصد به کمک پارامتر  $p$  تست گردید. بنابراین اگر  $p$  محاسبه شده برای هر مقایسه بیشتر از  $0.05$  باشد، فرضیه صفر را نمی‌توان رد کرد. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون  $t$ ،  $F$  و کولموگرف-امسیرنو استفاده شد. مقادیر  $p$  محاسبه شده برای دو روش محاسبه حجم انار و سطح جانبی و کرویت انار در جدول ۲ نشان داده شده است. این نتایج نشان می‌دهند که میانگین، واریانس و توزیع آماری مقادیر واقعی و پیش‌بینی شده حجم انار توسط مدل شبکه عصبی و نیز معادله شماره ۲ اختلاف معنی داری با هم ندارند. ولی مقادیر  $p$  محاسبه شده برای معادله شماره ۲ بسیار کمتر از مدل شبکه عصبی است و تا حدود زیادی در مرز وجود اختلاف معنی دار قرار دارد. این دلیلی دیگر بر بالا بودن توانایی شبکه عصبی در مقایسه با تکنیک 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 از اینرو می‌توان پیشنهاد کرد که شبکه عصبی می‌تواند قابلیت این دو پارامتر را داشته باشد.

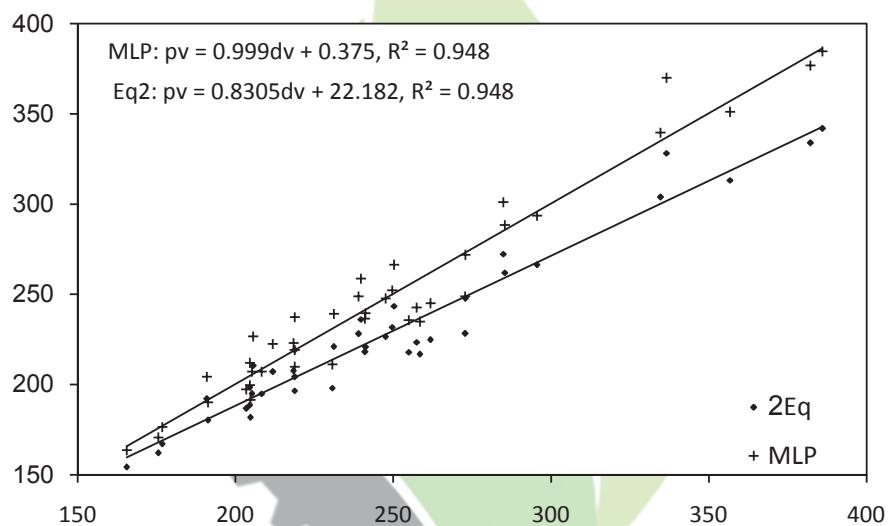
## جدول ۲- مقایسات آماری مقادیر واقعی و پیش‌بینی شده حجم انار

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

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

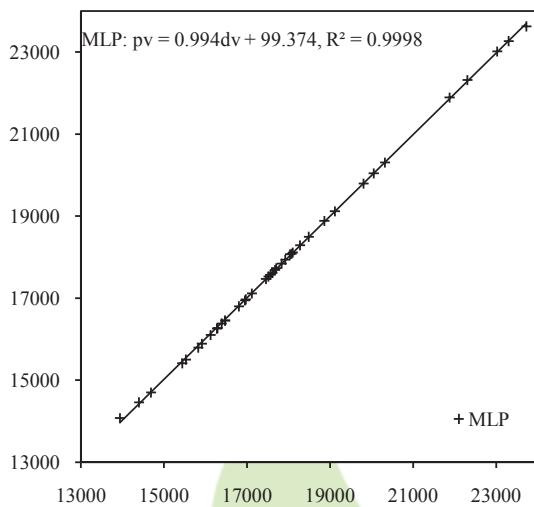
شکل ۲، همبستگی و رابطه رگرسیونی بین حجم واقعی و پیش‌بینی شده توسط معادله شماره ۲ و شبکه عصبی MLP را نشان می‌دهند. بهترین نتایج براساس این شکل وقتی بدست می‌آید که معادله خطی مابین حجم واقعی و حجم پیش‌بینی شده توسط مدل علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدا (نزدیک به صفر) و شبی نزدیک به یک باشد

( $PV=100dv+0.000d^2v$ ). کاملاً واضح است که ضرایب تبیین بین داده های واقعی و پیش بینی شده توسط شبکه عصبی چند لایه پرسپترون و معادله شماره ۲ نسبتاً بالا و برابر با یکدیگر می باشند ( $R^2=0.948$ ). مقایسه رابطه خطی رگرسیونی بین حجم واقعی و پیش بینی شده توسط شبکه عصبی چند لایه پرسپترون و معادله شماره ۲ نشان از برتری مدل شبکه عصبی دارد زیرا مدل MLP علاوه بر داشتن شبیه نزدیک تر به یک، عرض از مبدأ بسیار کوچکتر در حدود ۶۰ مرتبه کوچکتر نسبت به معادله شماره ۱ دارد. موارد مذکور برای کرویت که در شکل ۴ نشان داده شده است کاملاً مشهود می باشد. پراکندگی مابین داده های تئوری و تخمین های شبکه عصبی در مورد پارامتر سطح جانبی در شکل ۳ نشان داده شده است، ضریب تبیین این رابطه بیشتر از ۰.۹۹۹ می باشد و از طرف دیگر شبیه آن نیز نزدیک به یک است ولی عرض از مبدأ بالاتری دارد که این ممکن است به جهت استفاده از تخمین های تئوری به جای واقعی باشد.



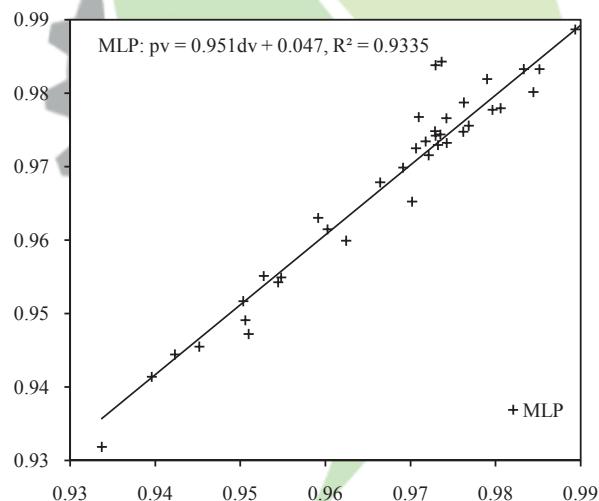
شکل ۲- نمودار پراکندگی مقادیر واقعی و پیش بینی شده حجم انار به کمک دو روش MLP و Eq2

**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 پیش بینی شده سطح جانبی انار به کمک MLP در مقایسه با تخمین های 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 پیش بینی شده کرویت انار به کمک MLP در مقایسه با تخمین های Eq1

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

در جدول شماره ۴ معیار متوسط قدرمطلق درصد خطا برای دو روش مذکور جهت تخمین حجم انار با هم مقایسه می‌شود. با توجه به نتایج درج شده در این جدول، MAPE شبکه عصبی به ترتیب تقریباً نصف و یک سوم معادله شماره ۲ برای محاسبه حجم می‌باشد. مقدار MAPE نیز برای سطح جانبی و کرویت به ترتیب  $0.12/0$  و  $0.20/0$  درصد می‌باشد.

#### 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	volume
MLP	MLP	Eq2
0.20	0.12	7.71
		3.82

**نتیجه گیری:** شبکه عصبی قابلیت پیش‌بینی حجم، سطح جانبی و کرویت میوه انار را دارد. با توجه به نتایج به دست 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 (MAPE) در اندازه گیری حجم واقعی میوه انار به روش شبکه عصبی تقریباً نصف روش تقریب بیضوی بوده است ( به ترتیب  $0.12/0$  و  $0.20/0$ ). همچنین استفاده از شبکه عصبی در پیش‌بینی سطح جانبی انار دارای اهمیت می‌باشد. چراکه دقت آن نسبت به رابطه ارائه شده توسط کومار و ماتیو 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 ( $R^2=0.935$ ). در مجموع استفاده از شبکه عصبی در پیش‌بینی خصوصیات فیزیکی میوه‌های مشابه انار که تقارن محوری دارند مثل مرکبات، سیب و ... قابل توجه می‌باشد و تحقیقات بیشتری را می‌طلبد.

#### منابع

1. Banks, N. H. 1985. Surface area estimation of potato tubers. Potato Research 28: 487–495.
2. 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.
3. Bayram, M. 2005. Determination of the sphericity of granular food materials. Journal of Food Engineering 68(3): 385-390.
4. 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.

5. 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.
6. 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.
7. Frechette, R. J., and J. W. Zahradnik. 1966. Surface area-weight relationships for McIntosh apples. *Transactions of the American Society of Agricultural Engineers* 9: 526-527.
8. Haykin, S. 1994. Neural networks: A comprehensive foundation. McMillan College Publishing Company, New York.
9. 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. Kerdpiboon, 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. Tabatabaeefar. 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. Mullinx. 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. Ajabshir, 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.
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. Abdolahpour. 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 spheriodal surfaces and volumes from spherical

- surfaces and volumes. Proceedings of American Society for Horticultural Science 48:326.
27. Vakil-Baghmisheh, M.T. 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
28. Vakil-Baghmisheh M.T., and N. Pavešić N. 2001. Back-propagation with declining learning rate. Proceeding of the 10<sup>th</sup> Electrotechnical and Computer Science Conference, Portorož, Slovenia B: 297-300.
29. Vakil-Baghmisheh, M. T., and N. Pavešić. 2003. A Fast simplified fuzzy ARTMAP network. Neural Processing Letters 17: 273-301.
30. Wang, Y.M., and T. M. S. Elhag. 2007. A comparison of neural network, evidential reasoning and multiple regression analysis in modeling bridge risks. Expert Systems with Applications 32: 336-348.
31. Wang, T. Y. and S. K. Nguang. 2007. Low cost sensor for volume and surface area computation of axi-symmetric agricultural products. Journal of Food Engineering 79(3): 870-877.
32. 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.