

پیش بینی جرم و حجم پرتقال رقم محلی دزفول با استفاده از شبکه های عصبی MLP

حسن مسعودی^{۱*} و عباس روحانی^۲

۱- استادیار گروه مهندسی بیوسیستم، دانشکده کشاورزی دانشگاه شهید چمران اهواز، ایران

۲- استادیار گروه مهندسی بیوسیستم، دانشکده کشاورزی دانشگاه فردوسی مشهد، ایران

چکیده	تاریخچه مقاله
<p>استفاده از شبکه های عصبی مصنوعی به عنوان روشی جدید برای برآورد مشخصه های فیزیکی محصولات کشاورزی و درجه بندی آنها بر حسب پارامترهای مختلف مطرح شده است. در این پژوهش ابتدا مقادیر مشخصه های فیزیکی ۱۰۰ عدد پرتقال رقم محلی دزفول شامل سه بعد هندسی، جرم، حجم و سطح تصویر عمودی اندازه گیری شد و از دو شبکه عصبی مصنوعی برای مدل سازی جرم و حجم پرتقال بر حسب ابعاد هندسی ($ANN(h,w,t)$) و سطح تصویر ($ANN(A)$) میوه استفاده گردید. شبکه عصبی پرسپترون چندلایه (MLP) با یک لایه مخفی، تابع سیگموئید به عنوان تابع فعال سازی نرون ها و الگوریتم پس انتشار با نرخ یادگیری کاهشی (BDLRF) برای آموزش شبکه انتخاب شد. نتایج مقایسه های آماری نشان داد که اختلاف بین مقادیر واقعی و پیش بینی شده توسط شبکه های عصبی معنی دار نیست؛ همچنین حداقل مقدار ضریب تبیین (R^2) برای هر یک از متغیرهای جرم و حجم در هر سه مرحله پیاده سازی شبکه عصبی (آموزش، معتبرسازی و آزمون) برابر با ۰/۹۶ بود. در مقایسه عملکرد دو مدل شبکه عصبی، بر اساس کوچکی معیارهای RMSE و MAPE و بزرگی ME، مشخص شد که شبکه عصبی $ANN(h, w, t)$ به $ANN(A)$ در هر سه مرحله آموزش، معتبرسازی و آزمون برتری دارد. همچنین مقایسه عملکرد مدل های شبکه عصبی با مدل های رگرسیونی ($F(h,w,t)$ و $F(A)$) نشان داد که اختلاف بین آنها معنی دار نبوده، ولی عملکرد پیش بینی مدل رگرسیونی $F(h,w,t)$ بهتر از $F(A)$ و در نهایت عملکرد مدل $ANN(h,w,t)$ بهتر از مدل رگرسیونی $F(h,w,t)$ می باشد.</p>	<p>دریافت: ۱۳۹۴/۰۳/۲۴ پذیرش نهایی: ۱۳۹۵/۰۳/۱۴</p> <p>کلمات کلیدی: پرتقال، تخمین جرم و حجم، ابعاد، سطح تصویر، شبکه عصبی مصنوعی</p> <p>*عهده دار مکاتبات Email:hmasoudi@scu.ac.ir</p>

امروزه درجه بندی محصولات کشاورزی با روش های مختلفی انجام می شود. تکنیک ماشین بینایی و استفاده از پردازش تصویر، یکی از روش های نوین در زمینه درجه بندی محصولات کشاورزی است و اصولاً سامانه های بینایی ماشین قادر به درجه بندی بر اساس مشخصه های

مقدمه

تعیین رابطه بین جرم و حجم میوه با طول، عرض، ضخامت و سطوح تصویر آن برای طراحی ماشین های اندازه بندی مفید می باشد. به همین دلیل شناخت روابط بین جرم و حجم با این خواص فیزیکی ضروری است.

تحقیقات زیادی در خصوص تعیین رابطه بین جرم یا حجم پرتقال با سایر مشخصه‌های فیزیکی با استفاده از مدل‌سازی رگرسیونی انجام شده است (۳ و ۱۵ و ۱۶)؛ تحقیقات در زمینه استفاده از تکنیک شبکه‌های عصبی مصنوعی برای تعیین رابطه بین خواص فیزیکی محصولات کشاورزی اندک و رو به گسترش است. ظریف نشاط و همکاران^۳ (۱۷) با استفاده از روش شبکه‌های عصبی مصنوعی حجم لهیدگی‌های میوه سیب را پیش‌بینی نمودند و به این نتیجه رسیدند که دقت این روش از مدل رگرسیونی برای پیش‌بینی حجم لهیدگی سیب بیش‌تر می‌باشد. جعفرلو و فرخی تیمورلو (۶) به کمک پردازش تصویر و شبکه‌ی عصبی، حجم سیب و تورفتگی‌های آن را برآورد نمودند. حجم واقعی سیب نیز با استفاده از روش جابه‌جایی آب، بر حسب سانتی‌متر مکعب اندازه‌گیری شد و رابطه‌ای بین حجم واقعی و حجم پیکسلی سیب ارائه گردید که می‌تواند در تخمین حجم سیب استفاده شود. آزمون t و بلاند-آلتمن نشان داد که بین حجم واقعی سیب و حجم پردازش تصویر در سطح احتمال ۵ درصد اختلاف معنی‌داری نیست و اختلاف میانگین بین آن‌ها ۱/۵۲ سانتی‌متر مکعب بوده و دارای دقت ۰/۹۲ می‌باشد. استفاده از شبکه عصبی با پارامترهای ورودی ابعاد و جرم سیب دقت اندازه‌گیری حجم سیب را تا ۰/۹۷ بالا برده و اختلاف میانگین بین حجم‌ها را تا ۰/۷ کاهش داد. این تحقیق نشان داد که پردازش تصویر و شبکه‌ی عصبی می‌تواند به عنوان روش‌های ساده و کارآمد در تخمین حجم محصولات کشاورزی استفاده شوند. در پژوهشی دیگر توانایی تکنیک شبکه عصبی مصنوعی به عنوان یک روش جایگزین در پیش‌بینی حجم، سطح جانبی و کرویت انار ارزیابی شد. از مقایسه آماری پارامترهایی مانند میانگین، واریانس، توزیع آماری و رابطه رگرسیونی بین مقادیر پیش‌بینی شده توسط شبکه عصبی نوع MLP و مقادیر واقعی مشخصه‌های انار استفاده شد. مقادیر $p \geq 0/85$

ظاهری و رنگی محصول می‌باشند؛ لذا در یک سامانه بینایی ماشین که برای درجه‌بندی محصولات کشاورزی بر حسب جرم یا حجم آنها به کار می‌روند، داشتن رابطه بین مشخصات فیزیکی محصول با جرم و حجم آن ضروری است. همچنین در سال‌های اخیر تمایل تازه‌ای به سمت برداشت رباتیک محصولات کشاورزی ایجاد شده است. اولین گام در برداشت رباتیک شناسایی دقیق و تعیین موقعیت میوه است. شناسایی از طریق پردازش تصویر توسط دوربین‌های رنگی و رایانه رایج‌ترین روش در حال حاضر می‌باشد، لذا داشتن رابطه بین جرم و حجم میوه با ابعاد هندسی آن می‌تواند در سامانه‌های برداشت رباتیک نیز کاربرد داشته باشد.

امروزه از شبکه‌های عصبی برای پیاده‌سازی توابع پیچیده در زمینه‌های مختلف از جمله تشخیص الگو، تشخیص هویت، طبقه‌بندی، پردازش صوت و تصویر و نیز سیستم‌های کنترلی استفاده می‌شود. شبکه‌های عصبی مصنوعی ابزار بسیار مناسبی برای برازش توابع^۱ (تعیین ارتباط بین متغیرهای مختلف) می‌باشد. این شبکه‌ها قادر به برازش هر تابع عملیاتی هستند (۷). بدلیل طبیعت غیرخطی پدیده‌های جهان واقعی هم‌چون روابط بین خواص فیزیکی محصولات کشاورزی، شبکه‌های عصبی گزینه خوبی برای کاربرد در این‌گونه مسائل نیز می‌باشند؛ زیرا شبکه‌های عصبی در مسائل برازش توابع مسائل غیرخطی به خوبی عمل می‌کنند. 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 می‌باشد (۲). یک شبکه پس‌انتشار^۲ با دارا بودن بایاس، یک لایه پنهان با تابع تبدیل سیگموئیدی و یک لایه خروجی با تابع تبدیل خطی به شرط داشتن تعداد کافی نرون در لایه پنهان، توانایی تخمین هر تابعی با تعداد نقاط ناپیوستگی محدود را داراست (۷).

1- Fitting a function

2- Back propagation network

3- Zarifneshat et al.

مواد و روش ها

در این پژوهش تعداد ۱۰۰ نمونه از میوه پرتقال رقم محلی دزفول پس از برداشت از باغ به آزمایشگاه منتقل شد و دمای ۱۷ تا ۲۲ درجه سانتیگراد و رطوبت نسبی ۵۳ تا ۷۳ درصد اندازه گیری های مختلفی برای تعیین مشخصه های فیزیکی اصلی شامل سه بعد هندسی (یعنی ارتفاع، پهنا و ضخامت میوه)، جرم میوه (M)، حجم میوه (V) و سطح تصویر میوه (A) انجام شد. با توجه به اینکه مقدار محتوای رطوبتی میوه بر خواص فیزیکی آن اثر مستقیم دارد، لذا ابتدا مقدار رطوبت پرتقال ها با روش خشک کردن درون آون الکتریکی در دمای ۷۵ درجه سانتیگراد و به مدت پنج روز اندازه گیری شد (۱۴). ابعاد هندسی میوه ها در سه جهت عمود بر هم t, w, h که به ترتیب ارتفاع میوه (بزرگترین فاصله بین دم و ساقه میوه)، عرض میوه (بزرگترین قطر عمود بر h) و ضخامت میوه (بزرگترین قطر عمود بر w و h) می باشند، بوسیله یک عدد کولیس با دقت 0.05 میلی متر تعیین شد. جرم میوه ها با استفاده از ترازوی دیجیتال، با دقت 0.01 گرم تعیین شد. برای تعیین حجم میوه ها از روش جابجائی سیال استفاده شد. بدین صورت که ابتدا تک تک میوه ها در هوا وزن شده و پس از غوطه ورکردن آنها در درون آب مقطر (به کمک یک میله بسیار باریک)، عدد نشان داده شده بوسیله ترازو قرائت شده و حجم هر کدام از میوه ها از رابطه ۱ محاسبه گردید (۹ و ۱۴).

$$V = \frac{M_2 - M_1}{D_w} \quad (1)$$

که در این رابطه V حجم میوه برحسب سانتیمتر مکعب، M_2 مجموع جرم میوه، ظرف و آب برحسب گرم، M_1 مجموع جرم ظرف و آب برحسب گرم و D_w جرم مخصوص آب (مساوی یک گرم بر سانتیمتر مکعب) می باشند. سطح تصویر عمود بر ارتفاع میوه ها نیز با استفاده از دستگاه سطح سنج WinDias 2.0 ساخت

به دست آمد، که نشان دهنده وجود تفاوت معنی داری در سطح ۵ درصد بین مقادیر شاخص های آماری مجموعه داده های پیش بینی شده و داده های واقعی بود؛ همچنین ضرایب تبیین بین داده های واقعی و پیش بینی شده بزرگتر از 0.9 شد (۱۲). احمدی و امیری پریان (۱) تشخیص پرتقال روی درخت با کاربرد پردازش تصاویر دیجیتال براساس الگوی تراکم سایه روشن را اجرا نمودند. ایشان در پژوهش خود برای قطعه بندی تصاویر پرتقال از شبکه عصبی MLP با سه لایه استفاده کردند که موفقیت به کارگیری آن با توجه به نرخ کشف صحیح پرتقال ها، با دقت 88.2 درصد مورد تأیید قرار گرفت. ایزدی و همکاران (۵) در پژوهشی با هدف به دست آوردن الگوریتمی برای تشخیص و درجه بندی محصول گوجه فرنگی، از شبکه های فازی-عصبی در محیط آنفیس^۱ استفاده کردند. سامانه نهایی با در نظر گرفتن همزمان سه سطح رنگ، اندازه و سلامت، نمونه ها را در ۸ دسته قرار دادند. میزان دقت در هر سطح برای قبل و بعد از آموزش، نشان از ارتقاء ۱۰ درصدی کیفیت تشخیص و درجه بندی در شرایط پس از آموزش داشت که این میزان برای درجه بندی های رنگ، اندازه، بافت و نهایی بترتیب برابر ۸۹، ۸۱، ۹۵ و ۸۱ درصد بود. پژوهش های دیگری نیز برای خشک کردن محصولات کشاورزی (۱۰ و ۱۱)، درجه بندی پسته (۱۳) و گردو (۸) با استفاده از تکنیک شبکه های عصبی مصنوعی انجام شده است.

هدف از این پژوهش برآورد جرم و حجم پرتقال رقم محلی دزفول از روی پارامترهای هندسی آن (شامل سه بعد هندسی و سطح تصویر عمودی) با استفاده از مدل سازی شبکه های عصبی مصنوعی است. از نتایج این مطالعه در طراحی و ساخت سامانه ماشین بینایی و الکترونیکی برای درجه بندی پرتقال برحسب جرم یا حجم میوه استفاده خواهد شد.


شبکه MLP با یک لایه مخفی در شکل ۲ نشان داده شده است.

در شبکه عصبی MLP، ابعاد هندسی پرتقال شامل ارتفاع، پهنا و ضخامت (t, w, h) و سطح تصویر عمودی (A) به عنوان ورودی و جرم یا حجم پرتقال به عنوان خروجی در نظر گرفته شد. تابع سیگموئید به عنوان تابع فعالیت هر یک از نرون‌ها انتخاب شد.

شرکت DeltaT Devices با دقت ۰/۱ میلی‌متر مربع (شکل ۱)، اندازه‌گیری شد. (۴)


مدل‌سازی شبکه عصبی:

شبکه عصبی پرسپترون چندلایه (MLP) برای مدل‌سازی جرم و حجم پرتقال استفاده شد. بر اساس قضیه تقریب عمومی، تنها یک لایه مخفی برای شبکه عصبی پرسپترون چندلایه در نظر گرفته شد. ساختار



شکل (۱) دستگاه سطح سنج WinDias 2.0 مورد استفاده برای اندازه‌گیری سطح تصویر میوه‌ها (۴) (۱- دوربین، ۲- چراغ‌های نورپردازی، ۳- صفحه قرارگیری نمونه، ۴- تسمه نقاله انتقال نمونه، ۵- بدنه)

Figure (1) WinDias 2.0 area-meter Used for measurement of fruits projected area (4) (1-Camera, 2-Light sources, 3- Sample plate, 4- Sample belt, 5-Chassis)



شکل (۲) ساختار شبکه عصبی MLP با یک لایه مخفی

Figure (2) Structure of MLP neural network with one hidden layer

یادگیری و عامل ممتوم هستند و مقادیر آنها در فاصله [۱] قرار دارند و n شماره تکرار الگوریتم ($n=1, \dots, N$) می باشد. برنامه رایانه ای این الگوریتم در محیط نرم افزار متلب نسخه ۸/۱ تهیه شد. تجزیه و تحلیل آماری نتایج با نرم افزار متلب انجام شد و مقایسه میانگین ها در سطح معنی داری پنج درصد صورت گرفت.

معیارهای ارزیابی عملکرد مدل ها:

برای ارزیابی و مقایسه عملکرد مدل های شبکه عصبی MLP در پیش بینی جرم و حجم پرتقال از معیارهای آماری جذر میانگین مربعات خطا^۲ (RMSE) (رابطه ۴)، میانگین قدرمطلق درصد خطا^۳ (MAPE) (رابطه ۵) و بازده مدل سازی^۴ (ME) استفاده شد. همچنین معادلات خطی رگرسیونی بین مقادیر پیش بینی شده توسط مدل ها و مقادیر واقعی داده ها و ضریب تبیین (R^2) مربوطه بررسی شد و تجزیه واریانس یک طرفه^۵ و مقایسه میانگین ها به روش LSD انجام شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (dv - pv)^2}{n}} \quad (4)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{dv - pv}{dv} \right| \quad (5)$$

که در این روابط dv مقدار واقعی جرم یا حجم میوه، pv مقدار پیش بینی شده آنها و n تعداد نمونه ها است.

نتایج و بحث

میانگین درصد رطوبت بر پایه تر نمونه های پرتقال در زمان اندازه گیری ها ۴۱/۶۱ درصد به دست آمد. بر اساس روش سعی و خطا بهترین ساختار شبکه با ۱۵ نرون در لایه پنهان برای مدل سازی جرم و حجم انتخاب شد. لذا ساختار بهینه شبکه های عصبی برای مدل $ANN(h,$

در ابتدا برای همگرا شدن و بهبود عملکرد یادگیری شبکه عصبی، داده های ابعاد هندسی شامل ارتفاع، پهنا و ضخامت و نیز جرم، حجم و سطح تصویر میوه ها به روش نرمالیزاسیون خطی در محدوده [۰/۹ ۰/۱] نرمال شد. ۸۰ درصد داده ها (۸۰ الگو) به طور تصادفی برای آموزش و دستیابی به مقادیر بهینه پارامترهای شبکه عصبی انتخاب شد و ۲۰ درصد داده های باقی مانده (۲۰ الگو) نیز به منظور ارزیابی قابلیت تعمیم پذیری شبکه انتخاب شد.

برای آموزش شبکه از الگوریتم پس انتشار با نرخ یادگیری کاهشی^۱ (BDLRF) استفاده شد. الگوریتم آموزش BDLRF با آهنگ یادگیری (η) و عامل ممتوم (α) ثابت و نسبتاً 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 عامل ممتوم را از طریق تصاعد حسابی بصورت یکنواخت کاهش می دهد تا زمانیکه این پارامترها به X درصد (۵٪) مقادیر اولیه خودشان برسند (۲). یادگیری شبکه در دو فاز پیش انتشار و پس انتشار اتفاق می افتد. وزن های هر لایه از شبکه از طریق روابط ۲ و ۳ محاسبه می شوند:

$$u_{jk}(n+1) = u_{jk}(n) - \eta \frac{\partial E}{\partial u_{jk}} + \alpha (u_{jk}(n) - u_{jk}(n-1)) \quad (2)$$

$$w_{ij}(n+1) = w_{ij}(n) - \eta \frac{\partial E}{\partial w_{ij}} + \alpha (w_{ij}(n) - w_{ij}(n-1)) \quad (3)$$

که در این روابط w_{ij} اتصال وزنی بین گره های i ، j و u_{jk} اتصال وزنی بین گره های k و j ، مقادیر اولیه این وزن ها بطور تصادفی از دامنه مقادیر [۰/۲۵ ۰/۲۵] انتخاب می شود. I_2 و I_3 به ترتیب تعداد نرون ها در لایه مخفی و لایه خروجی می باشند. η و α به ترتیب آهنگ

2- Root mean square error (RMSE)
3- Mean absolute percentage error (MAPE)
4- Modelling efficiency (ME)
5- One-way ANOVA

1- Back-propagation with declining learning-rate factor (BDLRF)

تعمیم پذیری خوبی برخوردار می‌باشد. بنابراین نتایج پیش‌بینی شبکه عصبی قابل اطمینان است.

نتایج عملکرد مدل شبکه عصبی زمانیکه ورودی تنها سطح تصویر است (ANN(A))، برحسب مقادیر p در سه مرحله آموزش، معتبرسازی و آزمون نیز در جدول ۱ آورده شده است. در تمام موارد $P\text{-value} > 0.7$ می‌باشد، بنابراین بین میانگین و واریانس داده‌های آزمایشگاهی و مقادیر پیش‌بینی شده توسط شبکه عصبی مصنوعی اختلاف معنی‌داری وجود ندارد. همچنین بر اساس مقدار ضریب تبیین (R^2) برای هر سه مرحله کاری شبکه می‌توان الگوی تغییرات جرم و حجم را به کمک شبکه عصبی و براساس سطح تصویر تخمین زد. همچنین مقایسه مقادیر ضریب تبیین (R^2) هر دو نوع مدل نشان می‌دهد که شبکه عصبی ANN(h,w,t) به ANN(A) در هر سه مرحله آموزش، معتبرسازی و آزمون برتری دارد.

w, t) بصورت ۱-۱۵-۳ و برای مدل ANN(A) بصورت ۱-۱۵-۱ می‌باشد.

نتایج مقایسات آماری بین مقادیر آزمایشگاهی و مقادیر پیش‌بینی شده توسط شبکه عصبی مصنوعی برای جرم و حجم پرتقال بر حسب ابعاد سه گانه آن (ANN(h, w, t)) به صورت مقادیر p برای مقایسات آماری میانگین و واریانس در جدول ۱ آورده شده است. مشاهده می‌شود که اختلاف بین آنها معنی‌دار نیست (در تمام موارد $P\text{-value} > 0.9$). همچنین حداقل مقدار ضریب تبیین (R^2) در هر سه مرحله کاری شبکه عصبی و برای هر یک از متغیرهای جرم و حجم برابر با ۰/۹۶ می‌باشد. مقدار ضریب تبیین در مرحله آزمون کمتر از مرحله معتبرسازی و آموزش است، زیرا داده‌های ارائه شده به شبکه عصبی در این مرحله تازگی دارند. بر اساس این نتایج شبکه عصبی توانسته است به خوبی الگوی تغییرات جرم و حجم را یاد بگیرد و همچنین از توانایی

جدول (۱) مقادیر p (مقایسات آماری میانگین و واریانس) و R^2 (بین مقادیر واقعی و پیش‌بینی شده) مدل‌های ANN
Table (1) The P (for mean and variance comparisons) and R^2 (between the actual and predicted data) values for ANN models

فاز آزمون (Test phase)		فاز معتبرسازی (Validation phase)		فاز آموزش (Train phase)		شاخص آماري (Statistical index)	مشخصه فیزیکی (Physical property)	مدل شبکه عصبی (ANN model)
واریانس (Variance)	میانگین (Mean)	واریانس (Variance)	میانگین (Mean)	واریانس (Variance)	میانگین (Mean)			
0.942	0.975	0.949	0.967	0.931	0.970	P	جرم	ANN (h,w,t)
	0.968		0.982		0.972	R^2	(Mass)	
0.962	0.943	0.992	0.882	0.983	0.973	P	حجم	ANN (A)
	0.978		0.977		0.983	R^2	(Volume)	
0.974	0.883	0.958	0.933	0.902	0.996	P	جرم	ANN (A)
	0.83		0.96		0.97	R^2	(Mass)	
0.798	0.675	0.925	0.942	0.873	0.997	P	حجم	ANN (A)
	0.86		0.97		0.94	R^2	(Volume)	

مقایسه با مدل‌های حجم اختلاف بین خطوط برازش دو نوع مدل آنقدر زیاد نیست. با توجه به ضرایب تبیین بالای معادلات برازش نشان داده شده در شکل ۳ می‌توان نتیجه گرفت که مدل‌های شبکه عصبی به خوبی توانسته اند مقادیر جرم و حجم پرتقال را برآورد نمایند. در پژوهش جعفرلو و فرخی تیمورلو (۶) نیز چنین نتیجه‌گیری شده است.

تجزیه واریانس یک طرفه سه سری داده شامل داده های واقعی و داده های پیش‌بینی شده توسط هر یک از مدل‌های ANN(h,w,t) و ANN(A) انجام شد. نتیجه مقایسه میانگین‌ها با روش LSD به صورت نمودار جعبه ای در شکل ۴ نشان داده شده است. همانطور که ملاحظه می‌شود اختلاف بین آنها در سطح احتمال یک درصد معنی‌دار نشد. بنابراین از لحاظ آماری بین دو مدل تفاوتی وجود ندارد و می‌توان از هر یک از مدل‌ها برای تخمین جرم و حجم استفاده کرد. اما با توجه به مقادیر ضرایب تبیین ذکر شده در شکل ۳، عملکرد پیش‌بینی مدل ANN(h,w,t) بهتر از مدل ANN(A) می‌باشد. لذا برآورد جرم و حجم پرتقال از روی سه بعد هندسی آن از دقت بیشتری نسبت به برآورد این مشخصه‌ها برحسب سطح تصویر پرتقال برخوردار است.


دو مدل شبکه عصبی پیشنهاد شده با استخراج مقادیر شاخص‌های آماری RMSE و MAPE و ME با یکدیگر مقایسه شدند. میانگین مقادیر این شاخص‌ها در پیش‌بینی جرم و حجم پرتقال توسط مدل شبکه عصبی برحسب پارامترهای ابعادی ANN(h,w,t) و شبکه عصبی بر حسب سطح تصویر عمودی ANN(A) در جدول ۲ آورده شده است. بر اساس کوچکی مقادیر شاخص‌های RMSE و MAPE و بزرگی ME عملکرد عملکرد مدل ANN(h,w,t) بهتر از ANN(A) می‌باشد.

پراکندگی داده‌های آزمایشگاهی و داده‌هایی پیش‌بینی شده توسط مدل‌های شبکه‌های عصبی جرم و حجم در شکل ۳ نشان داده شده است. پراکندگی داده‌ها حول محور قطری نشان دهنده نزدیکی دو سری مقادیر واقعی (dv) و مقادیر پیش‌بینی شده (pv) است. در این حالت بهترین وضعیت پیش‌بینی زمانی خواهد بود که $R^2 \cong 1$ و $pv = 1.000 dv + 0.000$ باشد. ضریب تبیین دو مدل شبکه عصبی در پیش‌بینی حجم مساوی ۰/۹۸ بوده و در پیش‌بینی جرم متفاوت (۰/۹۶ و ۰/۹۷) است. همچنین شیب و عرض از مبدا خط برازش مدل شبکه عصبی برآورد حجم بر حسب ابعاد هندسی در مقایسه با مدل شبکه عصبی برآورد حجم بر حسب سطح تصویر عمودی کوچکتر می‌باشد. اما در مدل‌های جرم در


جدول (۲) مقادیر شاخص‌های آماری مقایسه عملکرد مدل‌های شبکه عصبی و رگرسیونی

Table (2) Statistical indexes values for comparison of ANN and regression models performance

شاخص آماری	مدل	جرم پرتقال	حجم پرتقال
RMSE	F(h,w,t)	3.02	2.51
	F(A)	3.10	4.56
	ANN(h,w,t)	2.66	2.41
	ANN(A)	2.97	4.33
MAPE (%)	F(h,w,t)	1.97	1.50
	F(A)	1.99	2.69
	ANN(h,w,t)	1.60	1.46
	ANN(A)	1.70	2.54
EF (%)	F(h,w,t)	95.97	98.01
	F(A)	95.75	93.40
	ANN(h,w,t)	96.88	98.15
	ANN(A)	96.08	94.06



شکل (۳) رابطه بین مقادیر واقعی (dv) و مقادیر پیش‌بینی شده توسط مدل‌های شبکه عصبی (pv) (a: حجم و b: جرم)
 Figure (3) Relationship between the actual values (dv) and the predicted values by neural network models (pv) (a: volume and b: mass)



شکل (۴) نمودار جعبه ای تغییرات مقادیر واقعی جرم و حجم پرتقال در برابر مقادیر پیش‌بینی شده توسط مدل‌های ANN(A) و ANN(h,w,t)

Figure (4) Box graphs for changes in the actual values of orange mass and volume versus the predicted values by ANN (h, w, t) and ANN (A) models

هندسی میوه مشارکت دارند و می‌تواند برآورد بهتری از جرم و حجم میوه ایجاد نماید.

مقایسه عملکرد مدل سازی شبکه عصبی با مدل سازی رگرسیونی:

دو مدل شبکه عصبی (ANN(h,w,t) و ANN(A)) برای تخمین هر یک از ویژگی‌های جرم و حجم پرتقال با مدل‌های مشابه رگرسیونی (F(h,w,t) و F(A)) مقایسه

در پژوهش طباطبائی فر و همکاران^۱ (۱۵) که در آن مدل‌سازی رگرسیونی جرم پرتقال بر اساس مشخصه‌های هندسی آن برای ۱۰ رقم پرتقال انجام شد نیز نتایج مشابهی به دست آمده است. این نتایج تا حدی منطقی بنظر می‌آید زیرا در مدل‌سازی بر حسب ابعاد هر سه بعد

- یک روش مطمئن برای تخمین جرم و حجم پرتقال استفاده شود.
- ۲- مقادیر پیش‌بینی شده جرم و حجم پرتقال توسط شبکه های عصبی از نظر آماری اختلاف معنی‌داری با مقادیر واقعی آنها نداشتند.
- ۳- مقایسه معیارهای عملکردی مدل‌های شبکه عصبی نشان داد که مدل‌های جرم در مقایسه با مدل‌های حجم بسیار نزدیکتر به یکدیگر هستند.
- ۴- عملکرد پیش‌بینی مدل $ANN(h,w,t)$ بهتر از $ANN(A)$ و نیز عملکرد پیش‌بینی مدل رگرسیونی $F(h,w,t)$ بهتر از $F(A)$ و در نهایت عملکرد مدل شبکه عصبی $ANN(h,w,t)$ بهتر از مدل رگرسیونی $F(h,w,t)$ بود.
- ۵- با توجه به اینکه تفاوت بین مقادیر ضریب تبیین دو نوع مدل شبکه عصبی چندان زیاد نبوده و مدل $ANN(A)$ در یک سامانه بینایی تک دوربینه قابل استفاده است که پیچیدگی و هزینه کمتری دارد، لذا این مدل می‌تواند کاربردی تر باشد.

سپاس‌گزاری

نویسندگان مقاله از خانم‌ها سیمین آقاپور و ندا احمدیان (دانشجویان سابق مقطع کارشناسی) بخاطر کمک در انجام آزمایشات و معاونت محترم پژوهشی دانشگاه شهید چمران اهواز بابت حمایت مالی از این پژوهش در قالب طرح داخلی از محل گزنت، سپاس‌گزاری می‌نمایند.

شدند. نتایج بررسی عملکرد پیش‌بینی جرم و حجم توسط مدل‌های رگرسیونی برحسب پارامترهای ابعادی $(F(h,w,t))$ ، مدل رگرسیونی برحسب سطح $(F(A))$ و شبکه عصبی برحسب پارامترهای ابعادی $(ANN(h,w,t))$ و شبکه عصبی برحسب سطح تصویر عمودی $(ANN(A))$ در جدول ۲ آمده است. بر اساس کوچکی معیارهای $RMSE$ و $MAPE$ و بزرگی EF در بین مدل‌های شبکه عصبی، عملکرد پیش‌بینی مدل $ANN(h,w,t)$ بهتر از $ANN(A)$ و نیز عملکرد پیش‌بینی مدل رگرسیونی $F(h,w,t)$ بهتر از $F(A)$ و در نهایت عملکرد مدل شبکه عصبی $ANN(h,w,t)$ بهتر از مدل رگرسیونی $F(h,w,t)$ می‌باشد.

تجزیه واریانس یک طرفه پنج سری داده شامل داده‌های واقعی و داده‌های پیش‌بینی شده توسط هر یک از مدل‌های $F(h,w,t)$ ، $F(A)$ ، $ANN(h,w,t)$ و $ANN(A)$ نیز نشان داد که اختلاف بین آنها در سطح احتمال یک درصد معنی‌دار نمی‌باشد، بنابراین از لحاظ آماری بین چهار مدل تفاوتی وجود ندارد. لیکن وضعیت مدل $ANN(h,w,t)$ بهتر از سایر مدل‌ها بوده و مدل $ANN(A)$ در مقایسه با مدل $F(A)$ عملکرد بهتری دارد.

نتیجه‌گیری

در این پژوهش عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی جرم و حجم پرتقال رقم محلی دزفول بررسی شد. مطابق نتایج حاصله:

- ۱- نتایج شبکه‌های عصبی در مراحل آموزش و آزمون نشان داد که این تکنیک می‌تواند به عنوان

منابع

- Ahmadi, H.R. and Amiri Parian., J. 2015. Orange recognition on tree using image processing method based on lighting density pattern. Journal of Agricultural Machinery, 5(1): 92-100. (in Persian with English abstract)
- Beale, R., and Jackson, T. 2001. Neural computing: An introduction. Alborzi, M. Institute of Scientific Publications, Sharif University of Technology. 1st Printing, Tehran, Iran. 137 Pages. (in Persian)
- Dadvar, A.A., Khojastepoor, M., and Sadrnya, H. 2013. Comparison of orange mass determination models based on geometric characteristics required for design of

- grading machine. 7th Student Conference of Mechanical Engineering. 20-22 February 2013. Mechanical Engineering Faculty, University of Tehran, Iran. (in Persian)
4. DeltaT Devices Company. 1998. WinDias 2.0 area meter. <http://www.delta-t.co.uk> (Accessed November 2014).
 5. Izadi, H., Kamgar, S., and Raoufat, M.H. 2016. Defect detection and grading of tomato using machine vision technology and neuro-fuzzy networks. *Journal of Agricultural Machinery*, (in press), (in Persian with English abstract).
 6. Jafarlou, M. and Farrokhi Teimourlou, R. 2014. Estimation of apple volume and its shape indentation using image processing technique and neural network. *Journal of Agricultural Machinery*, 4(1): 57-64. (in Persian with English abstract)
 7. Kia, S.M. 2010. *Soft computing using MATLAB (4 in 1)*. Kian Rayaneh Sabz Publishing, 1st Printing, Tehran, Iran. 623 Pages. (in Persian)
 8. Mahmoudi, A., Khalesi, S., Hoseinpoor, A., and Alipoor, A.H. 2010. Audio identification of walnut genotypes using artificial neural networks. 6th National Congress on Agricultural Machinery Engineering and Mechanization, 15-16 September 2010, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. (in Persian)
 9. Mohsenin, N.N. 1986. *Physical properties of plant and animal materials. Second revised. Gordon and Breach Sci. Publ, New York, USA.*
 10. Motavali, A., Minaei, S., Khoshtaqaza, M.H., Kazemi, M., and Nikbakht, A.M. 2010. Comparison of mathematical and neural networks models prediction for pomegranate seed drying. 6th National Congress on Agricultural Machinery Engineering and Mechanization, 15-16 September 2010, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. (in Persian)
 11. Nasiri, A., Mobli, H., Rafiee, S., and Rezaei, K. 2014. Kinetic model simulation of thin-layer drying of thyme (*Thymus vulgaris L.*) using adaptive neuro-fuzzy inference system (ANFIS). *Journal of Agricultural Engineering*, 36(2): 37-48. (in Persian with English abstract)
 12. Rohani, A., Saedi, S.I., Grailu, H., and Aghkhani, M.H. 2015. Prediction of lateral surface, volume and sphericity of pomegranate using MLP artificial neural network. *Journal of Agricultural Machinery*, 5(2): 292-301. (in Persian with English abstract)
 13. Sajjadi, S.J., Ghazanfari Moghaddam, A., and Rostami, A. 2010. Using wavelet transformation and neural network for detecting blank (hollow) pistachio nuts. *Iranian Journal of Biosystem Engineering*, 40(2): 155-161. (in Persian with English abstract)
 14. Stroshine, R., and hamann, D. 1994. *Physical properties of agricultural materials and food products*. Copyright 1994 (August) by Richard Stroshine.
 15. Tabatabaeefer, A., Vefagh-Nematolahee, A., and Rajabipour, A. 2000. Modeling of orange mass based on dimensions. *Journal of Agricultural Science and Technology*, 2: 299–305.
 16. Topuz, A., Topakci, M., Canakci, M., Akinci, I., and Ozdemir, F. 2005. Physical and nutritional properties of four orange varieties. *Journal of Food Engineering*, 66(4): 519–523.
 17. Zarifneshat, S., Rohani, A., Ghassemzadeh, H.R., Sadeghi, M., Ahmadi, E., and Zarifneshat, M. 2012. Predictions of apple bruise volume using artificial neural network. *Computers and Electronics in Agriculture*, 82: 75-86.