



پیش‌بینی حجم کوفتگی سیب با استفاده از شبکه عصبی تابع پایه شعاعی (RBF) و مقایسه آن با مدل رگرسیونی

*سعید ظریف نشاط^۱، عباس روحانی^۲، میرمحمد اتفاق^۳ و محمدحسین سعیدی‌راد^۴

استادیار مرکز تحقیقات کشاورزی و منابع طبیعی خراسان رضوی، استادیار دانشگاه صنعتی شاهرود دانشکده کشاورزی،
استادیار دانشکده مهندسی مکانیک دانشگاه تبریز،^۴ استادیار مرکز تحقیقات کشاورزی و منابع طبیعی خراسان رضوی
تاریخ دریافت: ۹۱/۵/۷؛ تاریخ پذیرش: ۹۱/۱۲/۱۸

چکیده

صدمه کوفتگی ناشی از ضربه جزو انواع اصلی صدمات مکانیکی پس از برداشت میوه می‌باشد. مدل‌های پیش‌بینی حجم کوفتگی برای کاربردی کردن شبیه‌سازی المان گسسته که صدمه کوفتگی را در هنگام حمل و نقل شبیه‌سازی می‌کند ضروری است. مدل‌های پیش‌بینی کوفتگی اطلاعات مفیدی در مورد اثر فاکتورهای میوه (مانند رسیدگی) بر حساسیت به کوفتگی می‌دهد به طوری که این اطلاعات نهایتاً منجر به توصیه‌های کاربردی جهت حمل و نقل میوه‌ها می‌گردد. در این پژوهش مدل‌های پیش‌بینی کوفتگی برای سیب رقم زرد لبنانی تعیین گردید. از حجم کوفتگی به عنوان شاخص صدمه کوفتگی استفاده شد. هدف از این تحقیق ارزیابی شبکه عصبی مصنوعی تابع پایه شعاعی در پیش‌بینی حجم کوفتگی سیب می‌باشد. در این تحقیق از داده‌های تجربی ۱۲۰ عدد سیب استفاده گردید. پارامترهای بهینه برای شبکه عصبی مصنوعی تابع پایه شعاعی از طریق روش آزمون و خطا بر روی داده‌های موجود انتخاب گردید. جهت ارزیابی مدل تابع پایه شعاعی و مدل رگرسیونی در پیش‌بینی حجم کوفتگی سیب، علاوه بر رگرسیون خطی، از بعضی آزمون‌های آماری نظیر مقایسه میانگین‌ها، واریانس و توزیع آماری بین داده‌های واقعی و داده‌های پیش‌بینی شده بوسیله مدل شبکه عصبی مصنوعی تابع پایه شعاعی استفاده شد. نتایج نشان داد که مقادیر واقعی و پیش‌بینی شده حجم کوفتگی سیب به خوبی با متوسط قدرمطلق درصد خطای (MAPE) کمتر از ۲/۸۲ درصد برازش شده‌اند ($R^2 > 0/9$). تفاوت معنی‌داری بین مقادیر

*مسئول مکاتبه: zarifneshat@yahoo.com

واقعی و پیش‌بینی شده حجم کوفتگی سیب با استفاده مدل‌ها وجود نداشت. همچنین نتایج نشان داد که مدل تابع پایه شعاعی نسبت به مدل رگرسیونی از دقت بالاتری در پیش‌بینی حجم کوفتگی سیب برخوردار است.

واژه‌های کلیدی: شبکه عصبی، مدل رگرسیونی، حجم کوفتگی، سیب

مقدمه

اغلب تولید کنندگان به دنبال عرضه محصولاتی با کیفیت بالا هستند. صدمه ناشی از ضربه یک عامل کاهش کیفی و کمی محصول می‌باشد. کوفتگی، مهمترین و مرسوم ترین نوع صدمات مکانیکی پس از برداشت سیب به شمار می‌رود. صدمات مکانیکی می‌تواند عامل آلودگی و بیماری در محصول باشد که کنترل آن منجر به کاهش قارچ کشها خواهد شد. همچنین کوفتگی سیب بسته به آگاهی تولید کنندگان می‌تواند منجر به افت ۱۰ تا ۵۰ درصدی شود (وان زیبروک و همکاران، ۲۰۰۷a). کوفتگی یک نوع صدمه داخلی به شمار می‌رود لذا تشخیص آن مشکل تر است البته حساسیت به کوفتگی به واریته میوه بستگی دارد (پانگ و همکاران، ۱۹۹۶؛ پاسینی و همکاران، ۲۰۰۴؛ راگنی و همکاران، ۲۰۰۱). تحقیقات انجام شده در مورد اثر فاکتورهای پس از برداشت روی صدمه کوفتگی به نتایج متفاوتی منجر شده است. کلین (۱۹۸۷) نشان داد که کوفتگی با زمان انبارمانی کاهش می‌یابد. براسویتز و بارتیج (۱۹۸۹) گزارش دادند که نسبت تغییرات در حجم کوفتگی با زمان انبارمانی افزایش می‌یابد. سالتویت (۱۹۸۴) گزارش کرد که در مورد دو واریته سیب حجم کوفتگی بطور قابل ملاحظه‌ای از ۰ تا ۳۰ درجه سانتی‌گراد افزایش می‌یابد. سایر محققان دمای سیب را بر حجم کوفتگی بی‌تاثیر دانستند (کلین، ۱۹۸۷؛ اسکورل و هالت، ۱۹۷۷). مدول الاستیک با حجم کوفتگی همبستگی مثبتی دارد (ون لانکر، ۱۹۷۹؛ وان زیبروک و همکاران، ۲۰۰۷c). وان زیبروک (۲۰۰۷b) نشان داد که سفتی آکوستیک^۱ سیب رقم جاناگولد با میزان صدمه کوفتگی همبستگی مثبت دارد و شعاع انحناء محل ضربه نیز مقدار کوفتگی را تعیین می‌کند. مدل‌سازی ریاضی فهم پایه‌ای صدمه ناشی از ضربه به میوه‌ها را بالا برده است. محققان نشان دادند که مدل‌های رگرسیونی از مدل‌های تئوری بهتر بوده و برای تخمین صدمه کوفتگی از آنها برتر می‌باشند

1- Acoustic stiffness

(منساتی و همکاران، ۱۹۹۹). پانگ و همکاران (۱۹۹۲) در تحقیقی صدمات کوفتگی ناشی از برخورد سیب به سیب را بررسی کردند. آنها نشان دادند که حجم کوفتگی دو میوه با انرژی جذب شده همبستگی دارد. منساتی و پاگلیا (۲۰۰۱) یک شاخص صدمه ناشی از سقوط (DDI) را توسعه دادند بطوری که حساسیت کوفتگی را جایگزین فاکتور مقاومت به کوفتگی کردند. به همین دلیل گارسیا-راموس و همکاران (۲۰۰۲) از روش رگرسیون برای توصیف احتمال کوفتگی استفاده کردند. محققان دیگر نیز از مدل‌های آماری، رگرسیون چند متغیره خطی و یا غیر خطی، برای پیش‌بینی کوفتگی در میوه‌ها استفاده کرده‌اند (باجما و هایدی، ۱۹۹۸؛ باجما و همکاران، ۱۹۹۸؛ منساتی و پاگلیا، ۲۰۰۱؛ منساتی و همکاران، ۲۰۰۲؛ اسپالت-پاسون و همکاران، ۱۹۹۲؛ تیم و همکاران، ۱۹۹۸). مدل‌های پیش‌بینی کوفتگی، دارای دو دسته متغیر اصلی و فرعی هستند که در مدل به عنوان متغیر مستقل ظاهر می‌شوند. متغیرهای اصلی به خصوصیات ضربه بستگی داشته و مواردی چون، بیشینه نیروی برخورد، انرژی ضربه، زمان ضربه و ارتفاع سقوط را در بر می‌گیرد. متغیرهای فرعی با ویژگی‌های میوه در ارتباط می‌باشد، مانند دما، سفتی، زمان انبارداری، تاریخ برداشت و شعاع خمیدگی (وان زیبروک و همکاران، ۲۰۰۷a). در بین متغیرهای اصلی، دو متغیر انرژی ضربه و بیشینه نیروی برخورد از بیشترین موارد استفاده برای تعیین کوفتگی برخوردار هستند (وان زیبروک و همکاران، ۲۰۰۷b). این دو متغیر هر کدام، دارای مزایا و معایبی هستند. مدلی که در آن، متغیر مستقل، بیشینه نیروی برخورد است، می‌توان مدل را به مواد با خصوصیات ماده ای مختلف تعمیم داد. مثلاً در محاسبه کوفتگی، سیب وقتی به یک سیب دیگر برخورد می‌کند و یا اینکه بر روی سطح سخت سقوط می‌کند انتظار می‌رود که کوفتگی در حالت دوم بیشتر باشد، چرا که نیروی برخورد بیشتری در آن ایجاد می‌شود. پس دو مدل متفاوت را می‌توان با یک متغیر اصلی، برای یک میوه تعیین کرد. اما در مدلی که از انرژی ضربه به عنوان متغیر مستقل استفاده می‌شود، کوفتگی تخمین زده شده در مثال قبل، برای هر دو حالت یکسان است، زیرا انرژی ضربه در هر دو حالت مساوی است. اگر از مدلی که برای میوه - فلز تعریف شده است (فلز به عنوان ضربه زن)، کوفتگی برای میوه - میوه تخمین زده شود، حجم کوفتگی بسیار بیشتر از حد واقعی تخمین زده می‌شود، چون انرژی ضربه در حالت اول بسیار بزرگتر از حالت دوم است. عیب مدلی که در آن از بیشینه نیروی برخورد، به عنوان متغیر مستقل استفاده می‌شود، آن است که نیروی برخورد تابع متغیرهای فرعی مانند، دما، سفتی، شعاع خمیدگی و

غیره می‌باشد. بدین ترتیب، بدون در نظر گرفتن این متغیرها، امکان دارد کوفتگی تخمین زده شده، کمتر یا بیشتر از مقدار واقعی آن باشد. ولی مدل مبتنی بر معیار انرژی ضربه، این عیب‌ها را ندارد (وان-زیبروک و همکاران، ۲۰۰۷b). می‌توان به حجم کوفتگی (پانگ و همکاران، ۱۹۹۲)، سطح کوفتگی (منساتی و همکاران، ۲۰۰۲) و فشار حد دینامیکی (باجما و هابد، ۱۹۹۸؛ باجما و همکاران، ۱۹۹۸) به‌عنوان متغیر وابسته محاسبه شده در پیش‌بینی مدل کوفتگی اشاره کرد.

ساختار شبکه عصبی مصنوعی مشابه سیستم عصبی بیولوژی مغز انسان است (گوپتا و همکاران، ۲۰۰۳). امروز شبکه‌های عصبی در بسیاری از زمینه‌ها از جمله طبقه‌بندی، تشخیص الگو، پیش‌بینی و مدل‌سازی فرآیند بکار گرفته می‌شود. مزیت شبکه عصبی یادگیری مستقیم از روی داده‌ها بدون نیاز به برآورد مشخصات آماری آنها است (وکیل‌باغمیشه، ۲۰۰۲). شبکه عصبی بدون در نظر گرفتن هیچ فرضیه اولیه و همچنین دانش قبلی از روابط بین پارامترهای مورد مطالعه، قادر به پیدا کردن رابطه بین مجموعه از ورودی‌ها و خروجی‌ها برای پیش‌بینی هر خروجی متناظر با ورودی دلخواه می‌باشد (تورسیلا و همکاران، ۲۰۰۴). شبکه عصبی قادر به تخمین هر تابع غیر خطی پیوسته می‌باشد (هایکین، ۱۹۹۴). ویژگی دیگر شبکه عصبی، تحمل‌پذیری در مقابل خطا می‌باشد (آزاده و همکاران، ۲۰۰۶). این مزایا دلایل بکارگیری شبکه عصبی در پیش‌بینی حجم کوفتگی را برای ما روشن می‌سازد. در این مطالعه از شبکه عصبی تابع پایه شعاعی (RBF) استفاده شد. مراحل اصلی حل هر مسئله توسط شبکه عصبی شامل آموزش و آزمون می‌باشد. آموزش، فرآیند یادگیری مجموعه داده‌های ورودی به‌منظور تشخیص الگوهای آن توسط شبکه می‌باشد زیرا شبکه RBF از نوع بامعلم می‌باشد. روش آموزش را قانون یادگیری گویند و اتصالات وزنی بین نرون‌ها از طریق قانون یادگیری در طول فاز آموزش اصلاح می‌شوند. اساس الگوریتم‌های آموزش کمینه کردن انحراف خروجی شبکه از مقدار واقعی میباشند. آزمون، ارزیابی قابلیت تعمیم‌پذیری شبکه آموزش دیده در شرایط کاملاً جدید توسط مجموعه داده‌های غیر از داده‌های آموزش گویند (گوپتا و همکاران، ۲۰۰۳؛ ولتتارف، ۱۹۹۵).

هدف از انجام این تحقیق، تعیین مدل‌های رگرسیونی با هدف پیش‌بینی کوفتگی سیب با در نظر گرفتن خصوصیات فیزیکی و مکانیکی میوه سیب زرد لبنانی^۱، طراحی شبکه عصبی RBF به‌منظور

پیش‌بینی کوفتگی سیب در رابطه با خصوصیات فیزیکی و مکانیکی میوه به عنوان یک روش جایگزین، ارزیابی این دو روش به جهت دقت در برآورد کوفتگی سیب برای این مطالعه موردی می‌باشند.


مواد و روش‌ها

سیب مورد استفاده در آزمایشات وارسته گلدن دلشز می‌باشد. برای انجام آزمایش تعداد معینی سیب از باغ‌های شهر شند آباد شبستر طی چند نوبت در سال ۱۳۸۸ برداشت شد. برای جلوگیری از وارد آمدن هر گونه صدمه به میوه، برداشت به صورت دستی انجام شد و سیب‌ها به دقت در جعبه‌های پلاستیکی به صورت یک ردیف جهت حمل به سردخانه قرار داده شدند. میوه‌ها در سردخانه در دمای ۳ درجه سانتی‌گراد و رطوبت نسبی ۸۵ درصد نگهداری شدند.

اندازه‌گیری شعاع انحنا میوه: شعاع انحنا ناحیه‌ای از میوه که می‌بایست تحت ضربه قرار گیرد، با استفاده از دستگاه شعاع سنج اندازه‌گیری شد. با توجه به اینکه دستگاه مناسب برای اندازه‌گیری شعاع به صورت تجاری در دسترس نبود، این دستگاه در کارگاه ساخته شد (شکل ۱-۲a). اندازه‌گیری شعاع میوه با استفاده از رابطه (۱) که توسط محسنین (۱۹۸۶) ارائه شده است، صورت گرفت:

$$Radius = \frac{(AC)^2}{8(BD)} + \frac{(BD)}{2} \quad (1)$$

آن: BD فرو رفتگی پروب متحرک، AC فاصله بین دو پروب ثابت و در شکل (b) نیز OD شعاع انحنا میوه می‌باشد.



شکل ۱- دستگاه شعاع سنج و نحوه اندازه‌گیری شعاع انحنا سیب

اندازه‌گیری سفتی آکوستیک: سفتی مقیاسی برای اندازه‌گیری مقاومت بافت به تغییر شکل تحت اثر نیرو می‌باشد. این پارامتر یک خصوصیت مکانیکی محصول بوده و می‌تواند از طریق روش‌های مختلفی نظیر آزمون‌های پنچری و فشار اندازه‌گیری شود. در روش تعیین سفتی با استفاده از روش تحریک و پاسخ آکوستیک، فرکانس‌های طبیعی میوه سالم از طریق انجام تبدیل فوریه از سیگنال‌های پاسخ به ضربه میوه بدست می‌آید (اسچات و همکاران، ۱۹۹۹). روش انجام کار بدین صورت بود که سیب از طرف دمگل روی یک سطح با پوشش فوم قرار داده شد. روی آن و به فاصله چند میلیمتر یک میکروفن (مدل ۴۱۸۹ ساخت شرکت Brüel & Kjaer دانمارک با گستره فرکانسی ۶/۳ هرتز تا ۲۰ کیلو هرتز و حساسیت ۵۰ میلی ولت بر پاسکال) بوسیله یک پایه فلزی تثبیت گردید. برای تحریک، با استفاده از میله‌ای پلاستیکی به قطر ۷ و طول ۲۰۰ میلی متر، در طرف مقابل میکروفن ضربه‌ای ملایم به محل دایره استوایی سیب زده شد.

یک آمپلی فایر (NEXUS; B&K®) سیگنال را تقویت و خروجی متناسب را تدارک می‌دید. سیگنال خروجی توسط دستگاه پردازش سیگنال پالس (PULSE system, model 3564, B&K) مورد آنالیز قرار گرفت. آزمون فوریه سریع از سیگنال برای تعیین طیف فرکانس حاصل و محاسبه اولین فرکانس تشدید انجام شد. قبل از اندازه‌گیری‌های نهایی جرم هر میوه نیز با استفاده از ترازوی دقیق دیجیتالی اندازه‌گیری شد. سفتی آکوستیک سیب بر اساس پاسخ تحریک آکوستیک با استفاده از فرمول ۲ (اسچات و همکاران، ۱۹۹۹).

$$S \cong f^2 m^{2/3} \quad (2)$$

که در آن، S سفتی آکوستیک ($Hz^2 kg^{2/3}$)، f اولین فرکانس تشدید (Hz) و m جرم سیب (kg) می‌باشد. آنالیز آماری: بعد از محاسبه پارامترهای مدل نیروی برخورد نرمال، از طریق روش‌های آماری ارتباط متغیرهای وابسته (سفتی، k و ثابت میرایی، c) با متغیرهای مستقل (سرعت ضربه، v - سفتی آکوستیک، s و شعاع انحناء میوه، R) مورد تحلیل قرار گرفته و آنالیز واریانس صورت گرفت و سپس از روش رگرسیون چند گانه ارتباط متغیرهای مذکور با یکدیگر بررسی شد. به منظور مقایسه دقت مدل‌های رگرسیونی چندگانه، آزمون کای-اسکور بین داده‌های حاصل از محاسبه پارامترهای مدل نیروی برخورد نرمال و داده‌های حاصل از مدل‌های تخمین زده مقادیر سفتی و مستهلک کننده صورت گرفت. آزمون‌ها بوسیله نرم‌افزار Spss مورد تحلیل قرار گرفت.

پیش پردازش داده‌ها: در ابتدا بطور تصادفی داده‌های موجود را به دو دسته مجموعه آموزش با ۹۶ عضو (۸۰ درصد کل داده‌ها) و مجموعه آزمون با ۲۴ عضو (۲۰ درصد کل داده‌ها) تقسیم‌بندی شد. البته اگر این تقسیم‌بندی منجر به نتایج مطلوب نشود، می‌توان این مرحله را مجدداً تکرار کرد (زانگ و فوه، ۱۹۹۸). قبل از بکارگیری داده‌های خام اولیه در آموزش و آزمون شبکه باید آنها را نرمالیزه کنیم زیرا الگوریتم یادگیری همراه با داده‌های خام نمی‌تواند عملکرد مناسبی داشته باشد و همچنین بدلیل دامنه تغییرت خروجی تابع فعالیت سیگموئیدی [۰/۱] بکارگرفته شده در لایه میانی این امری ضروری به نظر می‌رسد (روحانی و همکاران، ۲۰۱۱). در غیر اینصورت شبکه در طول فاز آموزش همگرا نخواهد شد و نتایج مطلوبی تولید نخواهد شد (آزاده و همکاران، ۲۰۰۶). زمانی که از تابع فعالیت سیگموئیدی استفاده میشود، بهترین دامنه تبدیل داده‌ها [۰/۱ ۰/۹] می‌باشد (باجما و هاید، ۱۹۹۸). از نرمالیزاسیون خطی (معادله ۳) برای تبدیل داده‌ها استفاده شد:


$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times 0.8 + 0.1 \quad (3)$$

در اینجا x داده خام اولیه، x_n داده نرمالیزه شده، x_{\min} و x_{\max} به ترتیب مقادیر بیشینه و کمینه داده‌های اولیه می‌باشد. برای هر مجموعه داده این روش‌ها ارزیابی شد و بهترین آنها براساس عملکرد شبکه انتخاب شدند.

شبکه عصبی RBF: ساختار شبکه RBF با یک لایه مخفی در شکل ۱ نشان داده شده است. شبکه RBF با دریافت بردار ورودی X^q ، بردار خروجی Z^q برای هر q ($q=1, \dots, Q$) تولید خواهد کرد. هدف اتخاذ پارامترهای صحیح شبکه بمنظور دستیابی به خروجی واقع Z^q که تا جای ممکن نزدیک به خروجی مطلوب d^q متناظر با خود باشد. برای آموزش شبکه از الگوریتم پس انتشار اصلی (BB^۱) و الگوریتم پس انتشار با نرخ یادگیری کاهش (BDLRF^۲) استفاده شد. کد کامپیوتری این الگوریتم در محیط برنامه‌نویسی MATLAB تهیه شد.

1- Basic Backpropagation

2- Backpropagation with declining learning-rate factor



شکل ۲- ساختار شبکه RBF با یک لایه مخفی (وکیل باغمیشه و پوسیک، ۲۰۰۴).

الگوریتم BDLRF: این الگوریتم نسخه اصلاح شده الگوریتم پساتنشار اصلی می‌باشد (وکیل باغمیشه و پوسیک، ۲۰۰۲). این الگوریتم آموزش با آهنگ یادگیری و نسبتاً بزرگ شروع می‌کند و قبل از آنکه شبکه ناپایدار و یا همگرایی آن کند شود، هر T تکرار ($3 \leq T \leq 5$) آهنگ یادگیری از طریق تصاعد حسابی بصورت یکنواخت کاهش داده می‌شود تا زمانی که این پارامترها به x درصد (۵ درصد) مقادیر اولیه خودشان برسند. پارامتر یادگیری (η) را با استفاده از فرمول زیر کاهش داده شد:

$$\eta_n = \eta_0 + (x-1) \frac{n\eta_0 T}{Q-n_1} \quad (4)$$

در اینجا n_1 ، η_n و η_0 به ترتیب نقطه شروع BDLRF، آهنگ یادگیری در n امین جمله از تصاعد حسابی و مقدار اولیه آهنگ یادگیری می‌باشند.

الگوریتم BB: تابع هزینه بکار رفته در این الگوریتم مجموع کل مربعات خطا ($TSSE^1$) می‌باشد و بصورت زیر محاسبه میشود:

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

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 می‌افتد. وزن‌های هر لایه از شبکه از طریق زیر محاسبه می‌شوند.

1- Total sum-squared error

$$u_{mj}(n+1) = u_{mj}(n) - \eta_3 \frac{\partial E}{\partial u_{mj}} \quad (6)$$

$$v_{im}(n+1) = v_{im}(n) - \eta_2 \frac{\partial E}{\partial v_{im}} \quad (7)$$

$$\sigma_m^2(n+1) = \sigma_m^2(n) - \eta_1 \frac{\partial E}{\partial \sigma_m^2} \quad (8)$$

$$j=1, \dots, l_3, \quad m=1, \dots, l_2, \quad i=1, \dots, l_1 \quad (9)$$

در اینجا u_{mj} اتصال وزنی بین گره‌های j و m ، v_{im} اتصال وزنی بین گره‌های i و m و σ_m پارامتر پراکندگی برای گره‌های m می‌باشند. مقادیر اولیه این وزن‌های u_{mj} بطور تصادفی از دامنه مقادیر $[-0.1, 0.1]$ انتخاب می‌شود. l_1 ، l_2 و l_3 به ترتیب تعداد نرون‌ها در لایه ورودی، لایه مخفی و لایه خروجی می‌باشند. η_1 ، η_2 و η_3 به ترتیب آهنگ‌های یادگیری برای σ_m ، v_{im} و u_{mj} هستند و مقادیر آنها در فاصله $[0, 1]$ قرار دارند و n شماره تکرار الگوریتم ($n=1, \dots, N$). زمانی الگوریتم متوقف می‌شود که TSSE کوچکتر از مقدار آستانه (0.0001) مقدار آستانه در نظر گرفته شده برای مطالعه حاضر) باشد.

معیارهای ارزیابی عملکرد شبکه عصبی: برای ارزیابی قابلیت شبکه عصبی RBF در پیشبینی حجم کوفتگی سبب از معیارهای متوسط قدرمطلق درصد خطا ($MAPE^1$)، ریشه متوسط مربعات خطا ($RMSE^2$) و ضریب تبیین معادله خطی رگرسیونی بین مقادیر پیشبینی شده توسط شبکه عصبی و مقادیر واقعی آنها استفاده شدند (روحانی و همکاران، ۲۰۱۱).

$$RMSE = \sqrt{\frac{\sum_{j=1}^n \sum_{i=1}^m (d_{ji} - p_{ji})^2}{nm}} \quad (10)$$

$$MAPE = \frac{1}{nm} \sum_{j=1}^n \sum_{i=1}^m \left| \frac{d_{ji} - p_{ji}}{d_{ji}} \right| \times 100 \quad (11)$$

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

1- Mean absolute percentage error

2- Root mean squared error

نتایج و بحث

برای پیش‌بینی حجم کوفتگی سیب بر اساس انرژی برخورد و نیروی تماس شبکه‌های عصبی مصنوعی RBF جداگانه طراحی شد به طوری که بتواند هر یک از روابط $V_E = f(R, T, S, E)$ و $V_F = f(R, T, S, F)$ را مدل‌بندی کند. 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، یک لایه مخفی برای تمام شبکه‌های عصبی انتخاب شدند.

تنظیم پارامترهای شبکه: لایه ورودی در هر شبکه شامل ۵ نرون می‌باشد زیرا ورودی‌های شبکه شامل عامل بایاس، شعاع انحنا، دما، سفتی آکوستیک و انرژی برخورد یا نیروی تماس می‌باشند. لایه خروجی در شبکه‌های عصبی بر مبنای انرژی برخورد و یا نیروی تماس تنها شامل یک نرون است که آن حجم کوفتگی سیب می‌باشد. از طریق آزمون و خطا بر اساس معیارهای عملکردی بهترین توپولوژی هر شبکه انتخاب شد. بر اساس نتایج حاصل شده، بهترین عملکرد شبکه RBF، در تعداد نرون به اندازه تعداد اعضاء مجموعه داده‌های آموزش بدست آمد. بعد از بدست آوردن توپولوژی‌های بهینه برای هر شبکه، باید مقادیر بهینه پارامترهای یادگیری (η_1 و η_2) را بدست آورد. مقادیر بهینه پارامترهای η_1 و η_2 نیز از طریق آزمون و خطا انتخاب شدند. نتایج نشان می‌دهند که بهترین عملکرد شبکه عصبی RBF با الگوریتم آموزش پس انتشار اصلی بر اساس نیروی تماس در سطوح پارامترهای یادگیری $\eta_1 = 1 \times 10^{-9}$ ، $\eta_2 = 1 \times 10^{-6}$ و $\eta_3 = 0.5$ با تعداد تکرار ۲۵۰۰ و بر اساس انرژی برخورد در سطوح پارامترهای یادگیری $\eta_1 = 5 \times 10^{-9}$ ، $\eta_2 = 4 \times 10^{-6}$ و $\eta_3 = 0.5$ با تعداد تکرار ۱۰۰۰ بدست می‌آید. شبکه عصبی بر اساس الگوریتم آموزش پس انتشار با نرخ کاهشی با همان تعداد تکرار الگوریتم قبلی آموزش داده شد. ۱۰۰ و ۱۰۰۰ به ترتیب، نقاط شروع (η_1) برای الگوریتم آموزش پس انتشار با نرخ کاهشی برای شبکه عصبی بر اساس نیروی تماس و انرژی برخورد انتخاب شدند. نتایج نشان داد که بهترین عملکرد شبکه بر اساس الگوریتم آموزش با نرخ کاهشی زمانی بدست می‌آید که η_1 و η_2 را ثابت نگه داریم و تنها η_3 را کاهش دهیم. لذا مقدار اولیه η_3 برای هر دو شبکه عصبی ۰/۹ انتخاب شد که در انتهای آموزش مقدار نهایی آن به ۰/۰۵ رسید.

تحلیل آماری: شبکه عصبی RBF بر اساس پارامترهای بهینه بدست آمده آموزش داده شد. نتایج آموزش شبکه در جدول ۱ آمده است. با مقایسه بین مقادیر ویژگی‌های آماری واقعی و پیش‌بینی شده برای هر

دو الگوریتم می توان بیان کرد که شبکه عصبی توانسته است به خوبی رابطه بین متغیرهای مورد بررسی را یاد بگیرد زیرا تفاوت بین آنها ناچیز است.

جدول ۱- ویژگی های آماری مقادیر واقعی و پیشبینی شده حجم کوفتگی توسط شبکه عصبی RBF در فاز آموزش

ویژگی های آماری							av	الگوریتم آموزش	مدل
sum	ske	kur	max	Min	std	var			
۵۶۸۰۷/۸۳	۰/۴۸	۱/۸۳	۱۴۵۹/۰۰	۵۵/۳۰	۴۴۲/۵۰	۱۹۵۸۰۴/۰۵	۵۷۹/۶۷	BB و BDLRF	dv
۵۶۹۸۷/۲۸	۰/۴۸	۱/۸۲	۱۴۵۸/۹۸	۵۵/۳۳	۴۴۳/۰۷	۱۹۶۳۱۲/۱۲	۵۸۱/۵۰	BB	f(R,T,S,E)
۵۶۹۴۷/۵۹	۰/۴۸	۱/۸۲	۱۴۵۸/۷۵	۵۵/۳۶	۴۴۲/۸۲	۱۹۶۰۹۰/۷۰	۵۸۱/۱۰	BDLRF	pv
۵۴۳۰۱/۸۳	۰/۴۷	۱/۸۲	۱۴۵۹/۰۰	۵۵/۳۰	۴۴۳/۶۴	۱۹۶۸۱۳/۲۸	۵۷۷/۶۸	BB و BDLRF	dv
۵۴۵۲۴/۹۱	۰/۴۶	۱/۷۹	۱۴۵۶/۴۰	۵۵/۳۱	۴۴۳/۵۳	۱۹۶۷۱۹/۵۸	۵۸۰/۰۵	BB	f(R,T,S,F)
۵۴۳۰۶/۳۸	۰/۴۷	۱/۸۰	۱۴۵۶/۹۱	۵۵/۴۷	۴۴۲/۲۸	۱۹۵۶۱۳/۱۴	۵۷۷/۷۳	BDLRF	pv

توضیحات: av: میانگین var: واریانس std: انحراف معیار min: کمینه max: بیشینه kur: کشیدگی ske: چولگی; sum: مجموع dv: مقادیر واقعی داده ها pv: مقادیر پیشبینی شده توسط شبکه عصبی RBF

بعد از آنکه وزن های شبکه (اتصالات بین نرونها) در طول فاز آموزش محاسبه گردید. در فاز آزمون از همان توپولوژی و نیز وزن های تنظیم شده در طول فاز آموزش استفاده شد. هدف از این مرحله ارزیابی ویژگی تعمیم پذیری شبکه عصبی آموزش دیده است. بنابراین ما شبکه را با استفاده از مجموعه داده های غیر از مجموعه داده های آموزش (مجموعه داده های آزمون) ارزیابی کردیم. معتبر بودن نتایج مرحله آزمون دال بر موفقیت آمیز بودن مرحله آموزش برای هر شبکه میباشد. جدول ۲ برخی ویژگی های آماری داده های استفاده شده در فاز آزمون همراه با مقادیر پیشبینی شده آنها توسط شبکه های عصبی RBF نشان می دهد. براساس زانگ و فو (۱۹۹۸) برای داشتن عملکرد بهتر، تقسیم داده به دو مجموعه آموزش و آزمون در هر مورد می توانند متفاوت از هم باشند. تفاوت زیادی بین ویژگی های آماری مقادیر پیشبینی شده و مقادیر واقعی آنها برای شبکه عصبی آموزش دیده ملاحظه نمیشود. بر اساس این نتایج میتوان ادعا کرد که شبکه های عصبی با موفقیت آموزش دیده اند زیرا در غیر این صورت بایست تفاوت بین مقادیر واقعی حجم کوفتگی و مقادیر پیشبینی شده آنها در مجموعه آزمون زیاد باشد. همچنین بدلیل نزدیک بودن مقادیر میانگین، مجموع و کشیدگی می توان نتیجه گرفت که داده های واقعی و پیشبینی شده

در مرحله آزمون مشابه هم هستند. بنابراین قابلیت تعمیم پذیری شبکه آموزش دیده می‌تواند قابل قبول باشد.

جدول ۲- ویژگی‌های آماری مقادیر واقعی و پیشبینی شده حجم کوفتگی توسط شبکه عصبی RBF در فاز آزمون

مدل	الگوریتم آموزش	av	ویژگی‌های آماری						
			var	std	Min	Max	kur	ske	sum
dv	BB و BDLRF	۶۱۴/۴۵	۱۶۹۴۴۹/۰۲	۴۱۱/۶۴	۷۱/۰۰	۱۳۹۲/۰۰	۱/۷۶	۰/۱۲	۱۳۵۱۸/۰۰
	BB	۶۱۲/۹۹	۱۷۰۰۰۷/۹۶	۴۱۲/۳۲	۷۲/۴۰	۱۳۹۱/۳۴	۱/۷۶	۰/۱۱	۱۳۴۸۵/۷۲
	BDLRF	۶۱۳/۵۹	۱۶۹۷۶۹/۵۴	۴۱۲/۰۳	۷۲/۰۶	۱۳۸۷/۸۳	۱/۷۶	۰/۱۰	۱۳۴۹۹/۰۶
f(R,T,S,E)	BB و BDLRF	۶۱۶/۳۱	۱۶۹۵۶۵/۳۴	۴۱۱/۷۸	۷۱/۰۰	۱۳۹۲/۰۰	۱/۸۳	۰/۲۲	۱۶۰۲۴/۰۰
	BB	۶۱۵/۹۱	۱۶۸۱۸۹/۳۶	۴۱۰/۱۱	۷۲/۹۲	۱۳۲۸/۷۳	۱/۷۸	۰/۱۸	۱۶۰۱۳/۷۲
	BDLRF	۶۱۹/۱۶	۱۷۱۹۶۷/۴۴	۴۱۴/۶۹	۷۲/۷۱	۱۳۶۰/۵۶	۱/۸۳	۰/۲۰	۱۶۰۹۷/۹۵

توضیحات: av: میانگین var: واریانس std: انحراف معیار min: کمینه max: بیشینه kur: کشیدگی ske: چولگی

sum: مجموع dv: مقادیر واقعی داده‌ها pv: مقادیر پیشبینی شده توسط شبکه عصبی RBF

برای اثبات ادعای ما در مورد قابل اطمینان بودن شبکه‌های عصبی آموزش دیده برای حجم کوفتگی، داده‌های واقعی و داده‌های پیشبینی شده توسط شبکه را از نظر آماری با هم مقایسه شد. 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 آزمون گردید. به ترتیب برای مقایسه میانگین، واریانس و توزیع آماری از آزمون t ، F و کولموگروف-اسمیرنو استفاده شد. جدول ۳ مقادیر p محاسبه شده برای پیش‌بینی حجم کوفتگی به کمک شبکه عصبی RBF بر اساس انرژی برخورد و نیروی تماس در دو مرحله آموزش و آزمایش نشان می‌دهد. این نتایج نشان می‌دهند که میانگین، واریانس و توزیع آماری مقادیر واقعی و پیشبینی شده حجم کوفتگی هر شبکه عصبی اختلاف معنی‌داری با هم ندارند. بنابراین شبکه عصبی RBF دارای قابلیت بالایی برای پیشبینی حجم کوفتگی سبب می‌باشد. از آنجا که تفاوت معنی‌داری در مرحله آزمایش شبکه با استفاده از داده‌های غیر از مجموعه آموزش مشاهده می‌شود، لذا می‌توان بیان کرد که شبکه عصبی آموزش دیده از قدرت تعمیم‌پذیری خوبی برخوردار است.

جدول ۳- مقایسات آماری مقادیر واقعی و پیشبینی شده حجم کوفتگی در فاز آموزش و آزمون

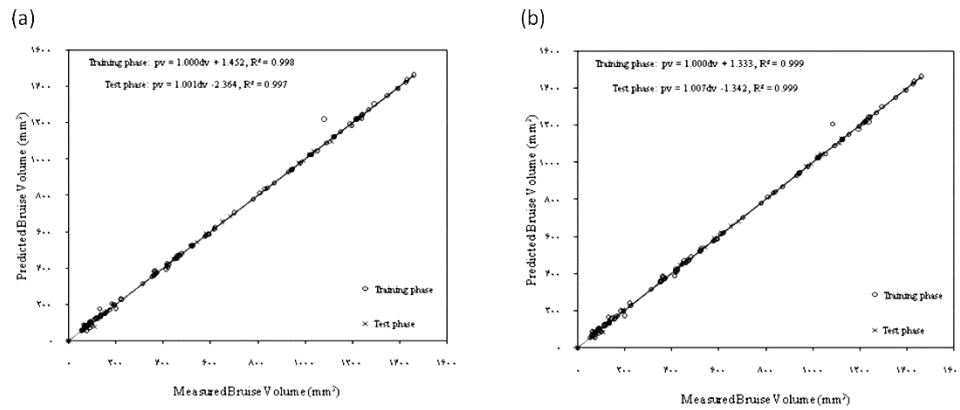
مدل	مرحله کاری شبکه	الگوریتم آموزش	نوع تحلیل آماری		
			مقایسه میانگین	مقایسه واریانس	مقایسه توزیع
f(R,T,S,E)	آموزش	BB	۰/۹۷۷	۰/۹۹۰	۱/۰۰۰
		BDLRF	۰/۹۸۲	۰/۹۹۴	۱/۰۰۰
	آزمایش	BB	۰/۹۹۱	۰/۹۹۴	۱/۰۰۰
		BDLRF	۰/۹۹۴	۰/۹۹۷	۱/۰۰۰
f(R,T,S,F)	آموزش	BB	۰/۹۷۱	۰/۹۹۸	۱/۰۰۰
		BDLRF	۰/۹۹۹	۰/۹۷۷	۱/۰۰۰
	آزمایش	BB	۰/۹۹۷	۰/۹۸۴	۱/۰۰۰
		BDLRF	۰/۹۸۰	۰/۹۷۲	۱/۰۰۰

عملکرد شبکه عصبی RBF: طراحی شده از نظر معیارهای متوسط قدرمطلق درصد خطا (MAPE)، نیز ریشه متوسط مربعات خطا (RMSE) و مجموع مربعات خطا (TSSE) در دو فاز آموزش و آزمون با هم مقایسه شده است (جدول ۴). مقادیر خطا در فاز آموزش برای الگوریتم آموزش پس انتشار با نرخ کاهشی (BDLRF) در مقایسه با الگوریتم پس انتشار اصلی (BB) در هر دو مورد مدل سازی کمتر است. این نتیجه نشان می دهد که الگوریتم آموزش BDLRF نسبت به الگوریتم BB توانسته است بهتر داده های مجموعه آموزش را یاد بگیرد. ولی در مرحله آزمایش شبکه، عملکرد BB تا حدودی بهتر از BDLRF می باشد. نتایج بررسی قابلیت پیش بینی شبکه عصبی چند لایه پرسپترون توسط روحانی و همکاران (۲۰۱۱) نشان داد که عملکرد الگوریتم آموزش BDLRF به مراتب بهتر از BB می باشد.

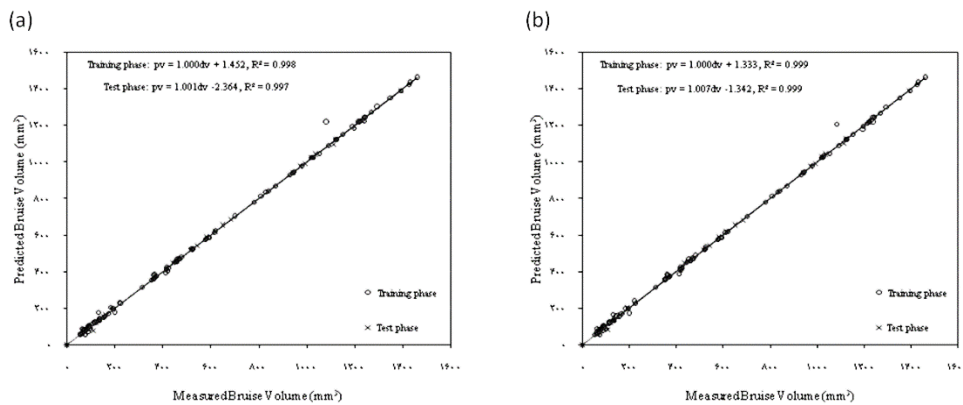
جدول ۴- عملکرد شبکه عصبی RBF در پیشبینی حجم کوفتگی

مدل	مرحله کاری شبکه	الگوریتم آموزش	معیار خطا		
			MAPE	RMSE	TSSE
f(R,T,S,E)	آموزش	BB	۳/۱۱	۱۵/۸۹	۲۴۷۳۶/۷۰
		BDLRF	۲/۹۶	۱۴/۹۵	۲۱۸۹۵/۱۳
	آزمایش	BB	۲/۱۴	۷/۳۰	۱۱۷۳/۲۹
		BDLRF	۲/۱۴	۷/۹۵	۱۳۹۱/۰۷
f(R,T,S,F)	آموزش	BB	۳/۴۷	۲۷/۲۸	۶۹۹۳۳/۶۸
		BDLRF	۲/۹۶	۲۱/۷۰	۴۴۲۷۸/۴۹
	آزمایش	BB	۱/۹۱	۱۴/۶۶	۵۵۸۹/۸۵
		BDLRF	۲/۵۰	۱۶/۶۳	۷۱۹۱/۷۳

شکل ۳ و ۴، ضرایب تبیین و همچنین رابطه خطی رگرسیونی بین حجم کوفتگی اندازه‌گیری شده در مقابل حجم کوفتگی پیشبینی شده توسط شبکه عصبی را نشان می‌دهد. بهترین نتایج براساس این دو معیار وقتی بدست می‌آید که معادله خطی مابین حجم کوفتگی اندازه‌گیری شده و حجم کوفتگی پیشبینی شده توسط شبکه عصبی علاوه بر داشتن ضرایب تبیین بالا دارای کمترین عرض از مبدا (نزدیک به صفر) و شیب نزدیک به یک باشد ($p_v = 1/000dv + 0/000$). کاملاً واضح است که ضرایب تبیین بین داده‌های اندازه‌گیری شده و پیشبینی شده در هر مورد بسیار بالا می‌باشند ($R^2 > 0/9$). همچنین معادله خطی رگرسیونی مابین آنها دارای شیب‌های نزدیک به واحد و عرض از مبدهای نسبتاً کوچکی هستند، بنابراین میتوان به چنین شبکه‌های اطمینان داشت. عرض از مبدهای حاصل از الگوریتم آموزش پس انتشار با نرخ کاهشی تا حدودی کمتر از عرض از مبدهای حاصل از الگوریتم آموزش پس انتشار اصلی با شیب‌ها و ضرایب تبیین نزدیک به یکدیگر هستند. لذا می‌توان براساس این معیار نتیجه گرفت عملکرد الگوریتم آموزش پس انتشار با نرخ کاهشی بهتر از الگوریتم آموزش پس انتشار اصلی است.



شکل ۳- رابطه بین مقادیر حجم کوفتگی اندازه گیری شده و پیش‌بینی شده در دو مرحله آموزش و آزمایش شبکه برای دو الگوریتم آموزش پس انتشار اصلی (a) و پس انتشار با نرخ کاهشی (b) برای مدل انرژی برخورد



شکل ۴- رابطه بین مقادیر حجم کوفتگی اندازه گیری شده و پیش‌بینی شده در دو مرحله آموزش و آزمایش شبکه برای دو الگوریتم آموزش پس انتشار اصلی (a) و پس انتشار با نرخ کاهشی (b) برای مدل نیروی تماس

مقایسه عملکرد مدل رگرسیون و شبکه عصبی RBF: مدل‌های رگرسیونی براساس روش شرح داده شده در بخش مواد و روشها به شرح زیر برای هر مورد انتخاب شدند:
 مدل رگرسیونی بر حسب متغیر مستقل انرژی برخورد:

$$V = -6.97R - 1.48T + 1.94S + 7186.95E + 5.97E \times R - 16.09E \times T, R^2 = 0.97$$

مدل رگرسیونی بر حسب متغیر مستقل نیروی تماس:

$$V = -3.25R + 0.97T - 4.5S + 22.9F - 0.23F \times R - 0.097F \times T, R^2 = 0.93$$

ویژگی‌های آماری میانگین، واریانس و توزیع آماری داده‌های اندازه‌گیری شده از حجم کوفتگی و مقادیر پیش‌بینی شده آنها توسط مدل رگرسیونی و شبکه عصبی RBF مقایسه شد (جدول ۵). این نتایج نشان می‌دهند که هر دو روش می‌تواند قابلیت پیش‌بینی حجم کوفتگی سیب را داشته باشد زیرا در تمام موارد اختلاف معنی‌داری برای میانگین، واریانس و توزیع آماری دیده نشد. مقادیر p برای مقایسات مربوط به شبکه عصبی بیشتر از روش رگرسیونی شد، لذا این معیار نشان داد که شبکه عصبی به مدل رگرسیونی برتری دارد.

جدول ۵- مقایسات آماری مقادیر واقعی و پیش‌بینی شده حجم کوفتگی برای مدل رگرسیونی و شبکه عصبی RBF

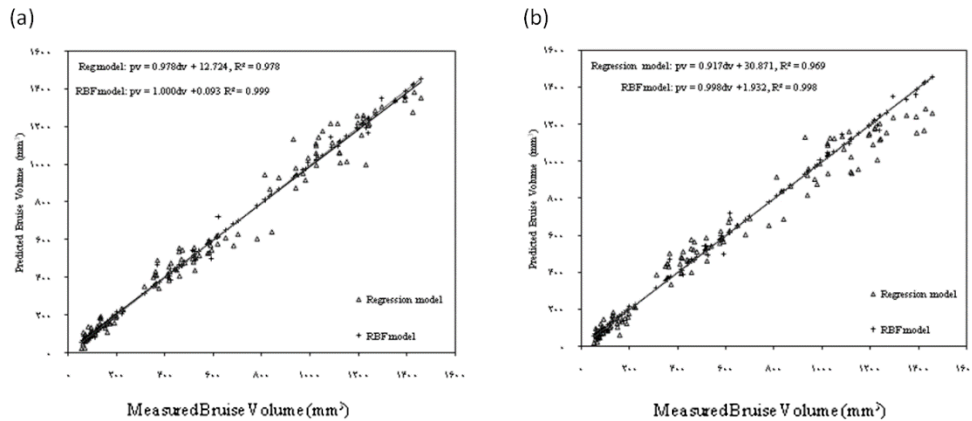
مدل	روش مدل سازی	نوع تحلیل آماری		
		مقایسه میانگین	مقایسه واریانس	مقایسه توزیع
f(R,T,S,E)	شبکه عصبی	۰/۹۸۶	۰/۹۹۴	۱/۰۰۰
	رگرسیون	۰/۹۹۷	۰/۹۰۸	۰/۹۹۹
f(R,T,S,F)	شبکه عصبی	۰/۹۹۱	۰/۹۹۱	۱/۰۰۰
	رگرسیون	۰/۷۵۱	۰/۴۴۵	۰/۶۷۴

عملکرد شبکه عصبی RBF و مدل رگرسیونی بر حسب معیارهای خطای MAPE، RMSE و TSSE در جدول ۶ آورده شده است. اگر چه بر اساس نتایج جدول ۵ عملکرد پیش‌بینی دو روش رگرسیونی و شبکه عصبی تفاوت چندانی با هم نداشتند ولی همانطور که در جدول ۶ ملاحظه می‌شود خطای پیش‌بینی مدل رگرسیونی بیش از چهار برابر خطای شبکه عصبی در تخمین حجم کوفتگی است. لذا نمی‌توان از مدل رگرسیونی با اطمینان در این مورد خاص استفاده کرد.

جدول ۶- عملکرد دو روش رگرسیونی و شبکه عصبی RBF در پیش‌بینی شده حجم کوفتگی

مدل	روش مدل سازی	MAPE	RMSE	TSSE
f(R,T,S,E)	شبکه عصبی	۲/۸۱	۱۴/۷۶	۲۶۱۲۷/۷۸
	رگرسیون	۹۷/۳۱	۶۳/۹۳	۴۹۰۴۱۴/۷۵
f(R,T,S,F)	شبکه عصبی	۲/۸۶	۲۰/۷۱	۵۱۴۷۰/۲۲
	رگرسیون	۹۷/۳۱	۸۱/۳۱	۷۸۸۶۷۲/۸۱

شکل ۵، ضرایب تبیین و همچنین رابطه خطی رگرسیونی بین حجم کوفتگی اندازه‌گیری شده در مقابل حجم کوفتگی پیش‌بینی شده توسط شبکه عصبی و نیز مدل رگرسیونی را نشان می‌دهد. ضرایب تبیین بین داده‌های اندازه‌گیری شده و پیش‌بینی شده برای هر دو روش شبکه عصبی و رگرسیونی بسیار بالا می‌باشند ($R^2 > 0.9$). اگرچه معادله خطی رگرسیونی مابین آنها دارای شیب‌های نزدیک به واحد هستند ولی عرض از مبداهای مربوط به شبکه عصبی بسیار کوچکتر از روش رگرسیونی می‌باشند، بنابراین بر حسب این معیار نیز برتری با شبکه عصبی در پیش‌بینی حجم کوفتگی سیب می‌باشد.



شکل ۵- رابطه بین مقادیر حجم کوفتگی اندازه‌گیری شده و پیش‌بینی شده توسط شبکه عصبی و مدل رگرسیونی بر حسب انرژی برخورد (a) و نیروی تماس (b)

منابع

- Azadeh A., Ghaderi S.F., and Sohrabkhani S. 2006. Forecasting electrical consumption by integration of Neural Network, time series and ANOVA. *Applied Mathematics and Computation*, 186: 1753-1761.
- Bajema, R.W., and Hyde, G.M. 1998. Instrumented pendulum for impact characterization of whole fruit and vegetable specimens. *Transactions of the ASAE*, 41, 1399-1405.
- Bajema, R.W., Hyde, G.M., and Peterson, K. 1998. Instrumentation design for dynamic axial compression of cylindrical tissue samples. *Transactions of the ASAE*, 41, 747-754.
- Brusewitz, G.H., and Bartsch, J.A. 1989. Impact parameters related to post harvest bruising of apples. *Trans. ASAE* 32, 953-957.
- Garcia-Ramos, F.J., Barreiro, P., Ruiz-Altisent, M., Ortiz-Canavate, J., Gil-Sierra, J., and Homer, I. 2002. A procedure for testing padding materials in fruit packing lines using multiple logistic regression. *Transactions of the ASAE*, 45, 751-757.
- Gupta M.M., Jin J., and Homma N. 2003. *Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory*. John Wiley & Sons, Inc., Hoboken, New Jersey.
- Haykin S. 1994. *Neural networks: A comprehensive foundation*. McMillan College Publishing Company, New York.
- Klein, J.D. 1987. Relationship of harvest date, storage conditions and fruit characteristics to bruise susceptibility. *Journal of American Society for Horticultural Science*. 112: 113-118.
- Menesatti, P., Beni, C., Paglia, G., Marcelli, S., and Dandrea, S. 1999. Predictive statistical model for the analysis of drop impact damage on peach. *Journal of Agricultural Engineering Research*, 73: 275-282.
- Menesatti, P., and Paglia, G. 2001. Development of a drop damage index of fruit resistance to damage. *Journal of Agricultural Engineering Research*. 80: 53-64.
- Menesatti, P., Paglia, G., Solaini, S., Zanella, A., Stainer, R., Costa, C., and Cecchetti, M. 2002. Nonlinear multiple regression models to estimate the drop damage index of fruit. *Biosystems Engineering*, 83: 319-326.
- Mohsenin, N.N. 1986. *Physical Properties of Plant and Animal Materials*. Gordon and Breach science publishers, New York.
- Pang, W., Studman, C.J., and Ward, G.T. 1992. Bruising damage in apple-to-apple impact. *J. Agric. Eng. Res.* 52: 229-240.
- Pang, D.W., Studman, C.J., Banks, N.H., and Baas, P.H. 1996. Rapid assessment of the susceptibility of apples to bruising. *Journal of Agricultural Engineering Research*, 64: 37-48.
- Pasini, L., Ragni, L., Rombola, A.D., Berardinelli, A., Guarnieri, A., and Marangoni, B. 2004. Influence of the fertilization system on the mechanical damage of apples. *Biosystems Engineering*, 88: 441-452

- Ragni, L., and Berardinelli, A. 2001. Mechanical behaviour of apples, and damage during sorting and packaging. *Journal of Agricultural Engineering Research*, 78: 273–279.
- Rohani, A., Abbaspour-Fard, M.H., and Abdolahpour, S. 2011. Prediction of tractor repair and maintenance costs using Artificial Neural Network. *Expert Systems with Applications* 38:8999-9007.
- Saltveit, M. 1984. Effects of temperature on firmness and bruising of Starkrimson delicious and golden delicious apples. *Horticultural Science*, 19: 550–551
- Schoorl, D., and Holt, J.E. 1977. The effects of storage time and temperature on the bruising of Jonathan, Delicious and Granny Smith apples. *Journal of Texture Studies*, 8: 409-416.
- Schotte, S., Belie, N., and Baerdemaeker, J. 1999. Acoustic impulse technique for evaluation and modeling of firmness of tomato fruit. *Postharvest Biology and Technology*, 17: 105–115.
- Schulte-Pason, N.L., Brown, G.K., and Timm, E.J. 1992. Apple impact damage thresholds. *Applied Engineering in Agriculture*, 8: 55–60.
- Timm, E.J., Bollen, A.F., Dela Rue, B.T., Woodhead, I.M., 1998. Apple damage and compressive forces in bulk bins during orchard transport. *Applied Engineering in Agriculture*, 14: 165–172.
- Torrecilla J.S., Otero L., and Sanz, P.D. 2004. A neural network approach for thermal/pressure food processing. *Food Engineering*, 62:89-95.
- Vakil-Baghmisheh, M.T. and Pavešic N. 2001. Back-propagation with declining learning rate. Proceeding of the 10th Electro technical and Computer Science Conference, Portorož, Slovenia. Vol. B: 297-300.
- Vakil-Baghmisheh, M.T. 2002. Farsi Character Recognition Using Artificial Neural Networks. PhD Thesis, Faculty of Electrical Engineering, University of Ljubljana.
- Vakil-Baghmisheh, M.T., and Pavešic, N. 2003. A Fast simplified fuzzy ARTMAP network. *Neural Processing Letters*. 17:273-301.
- Vakil-Baghmisheh M.T. and Pavešic N. 2004. Training RBF networks with selective back propagation. *Neurocomputing*. 62: 39-64.
- Van Lancker, J., 1979. Bruising of unpeeled apples and potatoes in relation with temperature and elasticity. *Lebensmittel issenscchaft Technologie*, 12: 157–161.
- Van Zeebroeck, M., Van linden, V., Ramon, H., De BaerDEMaeker, J., Nicola'ý, B.M., and Tijskens, E. 2007a. Impact damage of apples during transport and handling. *Postharvest Biology and Technology*, 45, 157-167.
- Van Zeebroeck, M., Van linden, V., Darius, P., De Ketelaere, B., Ramon, H., and Tijskens, E. 2007b. The effect of fruit properties on the bruise susceptibility of tomatoes. *Postharvest Biology and Technology*, 45: 168-175.
- Van Zeebroeck, M., Van linden, V., Darius, P., De Ketelaere, B., Ramon, H., and Tijskens, E. 2007c. The effect of fruit factors on the bruise susceptibility of apples. *Postharvest Biology and Technology*, Submitted

- Veelenturf, L.P.J. 1995. Analysis applications of artificial neural networks. Simon & Schuster international group, United States of America.
- Zhang, Y.F. and Fuh, J.Y.H. 1998. A neural network approach for early cost estimation of packaging products. *Computers and Industrial Engineering*, 34, 433-50.
- Wang, Y.M., and Elhag, T.M.S. 2007. A comparison of neural network, evidential reasoning and multiple regression analysis in modeling bridge risks. *Expert Systems with Applications*, 32: 336-348.



Predictions of apple bruise volume by using RBF artificial Neural network and comparison it with regression

*S. Zarifneshat¹, A. Rohani², M.M. Ettfagh³ and M. Hossein Saeidirad⁴

¹Assistant Prof., Khorasan Razavi Agricultural and Natural Resources Research Center, Mashhad, Iran, ²Assistant Prof., Dept. of Water and Soil, Shahrood University of Technology, Shahrood, Iran, ³Assistant Prof., Faculty of Mechanical Engineering, University of Tabriz, Tabriz, Iran, ⁴Assistant Prof., Khorasan Razavi Agricultural and Natural Resources Research Center, Mashhad, Iran

Abstract

Bruising damage caused by impact form the main part of all kinds of mechanical damages after harvesting fruits. The prediction of bruise volume is essential for the applicability of the discrete element method to simulate bruise damage during fruit transport and handling. Bruise prediction models can provide useful information about the influence of fruit factors (e.g. ripeness) on bruise susceptibility, leading to recommendations for fruit handling. Bruise prediction models were constructed for the Golden Delicious apple. Bruise volume was used as a measure for apple bruising. The purpose of this research was to evaluate RBF artificial neural network capability in predicting apple bruise volume. The study was conduct using empirical data on 120 apples. Optimal parameters for the RBF neural network were select via a trial and error procedure on the available data. In order to evaluate the performance of the RBF model in the prediction of apple bruise volume, some statistical tests, such as comparisons of the means, variance, statistical distribution as well as linear regression were used between the actual data and the prediction data using RBF neural network. Results showed that in training phase and test phase P-value was greater than 0.9, indicating that there was no significant difference between statsitcal parameters such as average, variance, statistical distribution. This results suggest that RBF neural network can learn bruise volume model very well. Results showed that the predicted values and actual values of apple bruise volume fitted very well ($R^2 > 0.9$), with mean absolute percentage error (MAPE) less than 2.82%. There was no significant difference between the actual values obtained from apple bruise volume and predicted value calculated by models. Also the results revealed that the model established by RBF was more accurate than regression model to predict apple bruise volume.

Keywords: RBF, Neural network, Apple bruise volume

*Corresponding Author; zarifneshat@yahoo.com

