

کاربرد شبکه عصبی مصنوعی و آزمون غیرمخرب سی تی اسکن در تخمین مقدار کوفتگی گلابی در اثر اعمال بارهای خارجی

محسن آزادبخت^{۱*}، محمد واحدی ترشیزی^۲

۱- دانشیار، گروه مکانیک بیوسیستم، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران
* نویسنده مسئول (azadbakht@gau.ac.ir)

۲- دانشجوی کارشناسی ارشد، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران

چکیده

آسیب‌های گلابی یکی از علت‌های اصلی ازدست‌دادن کیفیت میوه است. کبودی در هنگام بارگذاری دینامیکی و شبه استاتیک رخ می‌دهد که باعث تخریب بافت سالم میوه می‌گردد. در این پژوهش ابتدا گلابی‌ها تحت بارگذاری شبه استاتیکی (لبه پهن و لبه نازک) و بارگذاری دینامیکی قرار گرفتند. سپس در دوره‌های ۵، ۱۰ و ۱۵ روزه انبارداری شده و بعد از هر دوره انبارداری با استفاده از تکنیک غیرمخرب سی تی اسکن (CT-Scan) برای تخمین درصد پوسیدگی مورد بررسی قرار گرفتند. شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) با دولایه پنهان و تعداد ۳، ۵، ۷ و ۹ نرون در هر لایه برای مدل‌سازی نیروی بارگذاری و دوره انبارداری میوه گلابی جهت پیشگویی میزان پوسیدگی انتخاب گردید. بیشترین مقادیر R^2 آموزش و آزمون برای بارگذاری شبه استاتیکی لبه نازک و لبه پهن در شبکه‌ای با ۹ نرون به ترتیب ۰/۹۱= لبه نازک آموزش، ۰/۹۹= لبه نازک آزمون و ۰/۹۵= لبه پهن آموزش و ۰/۹۹= لبه پهن آزمون بوده است و برای بارگذاری دینامیکی شبکه‌ای با ۳ نرون در لایه مخفی ۰/۹۸= آموزش، ۰/۹۹= آزمون بیشترین مقدار را به خود اختصاص داده است. همچنین بهترین شبکه برای یادگیری (۹ نرون) بارگذاری شبه استاتیکی لبه نازک، (۷ نرون) بارگذاری شبه استاتیکی لبه پهن و بارگذاری دینامیکی (۷ نرون) بود. باتوجه به نتایج به دست آمده برای $RMSE$ ، R^2 و سیکل یادگیری می‌توان گفت شبکه عصبی توانایی پیش‌بینی میزان درصد پوسیدگی را در حد قابل قبولی برای گلابی داشته است.

تاریخ دریافت: ۱۳۹۷/۰۵/۱۴

تاریخ پذیرش: ۱۳۹۷/۰۹/۲۸

واژه‌های کلیدی

بارگذاری
روش غیرمخرب
شبکه عصبی
کبودی
گلابی

مقدمه

محصولات کشاورزی خصوصیات منحصر به فردی دارند که آنها را از مواد مهندسی مجزا می‌کند. این خصوصیات کیفی میوه‌ها و مقداری عددی که به آنها داده می‌شود باعث کنترل راحت‌تر محصولات کشاورزی می‌گردد (Chakespari, Rajabipour, & Mobli, 2010). از طرفی یک جنبه حیاتی که میوه‌ها را از محصولات دیگر تمایز می‌دهد، از بین رفتن سریع آنهاست. محتوای آب و کربوهیدرات بسیار زیاد، باعث

فرایندهای متابولیک و همچنین رشد میکروارگانیسم‌ها می‌شود که منجر به خسارات کیفی و کمی می‌شود. علاوه بر این، این تولیدها به‌ویژه در معرض آسیب‌های ناشی از ضربه و خراش قرار دارند. بنابراین، توسعه روش‌هایی که اطلاعات پیرامون ویژگی‌های کیفی در مراحل اولیه فرایند پس از برداشت به شیوه‌ای غیرمخرب را به ارمغان می‌آورد، یک چالش بزرگ برای بخش کشاورزی است (Hernández-Sánchez, Moreda, Herre-ro-Langreo, & Melado-Herrerros, 2016). از این رو ارزیابی کیفی غیرمخرب

کاربرد شبکه عصبی در میزان پیش‌بینی میزان کبودی میوه گزارش کردند:

Zarifneshat و همکاران (۲۰۱۲) روی پیش‌بینی میزان کبودی سیب با استفاده از شبکه عصبی آزمایشی را انجام دادند. در این آزمایش عملکرد الگوریتم آموزش پایه^۳ با الگوریتم یادگیری میزان فاکتور^۴ (FRL) مقایسه شد. مشخص شد که FRL دارای عملکرد بهتر برای پیش‌بینی حجم کبودی سیب است. در نهایت به این نتیجه رسیدند که ANN نشان‌دهنده یک ابزار امیدوارکننده برای پیش‌بینی میزان کبودی سیب در مقایسه با مدل رگرسیون است.

Rostampour و همکاران (۲۰۱۳) به بررسی میزان کبودی در آسیب سیب با استفاده از تکنیک شبکه عصبی مصنوعی برای پیش‌بینی میزان کبودی آزمایشی انجام دادند که نتیجه آزمایش نشان داد که مدل با دستورالعمل ۵-۷-۱، تابع انتقال سیگموئیدی در لایه پنهان و تابع انتقال خطی در لایه خروجی با ۴۰۰۰۰ دوره، بهترین رابطه بین مقادیر پیش‌بینی شده و واقعی را نشان می‌دهد.

Zhai و Hu، Wang (۲۰۱۸) روی کاربرد دو شبکه عصبی کانولوشن عمیق^۵، یعنی شبکه Residual (ResNet) و نسخه بهبود یافته آن به نام ResNeXt برای پیش‌بینی آسیب‌های درونی زغال‌اخته^۶ مورد استفاده قرار گرفت که نتایج این مطالعه نشان داد پتانسیل کاربرد CNN Deep در تحلیل آسیب مکانیکی داخلی میوه مناسب بوده است. هدف از انجام این تحقیق بررسی داده‌های آزمایشی با داده‌های شبکه است و همچنین بررسی میزان حساسیت گلابی تحت بارگذاری شبه استاتیکی و دینامیکی نسبت به پارامترهای ورودی نیرو و دوره انبارداری می‌باشد و نیز یافتن بهترین شبکه برای تحلیل داده‌های درصد پوسیدگی است تا بتوان با استفاده از کمترین زمان داده‌های آزمایشی را با داده‌های شبکه مقایسه کرد و بهترین نتیجه را گرفت.

مواد و روش‌ها

آماده‌سازی نمونه

گلابی‌های رقم اسپادانا از بازار گرگان تهیه شدند و

محصولات کشاورزی به یک بخش مهم برای صنعت کشاورزی تبدیل شده است (Kotwaliwale et al., 2014). در دهه‌های اخیر مطالعه‌های متعددی برای انجام روش دقیق ارزیابی محصولات غذایی انجام شده است و دلیل این امر افزایش تقاضای مصرف‌کنندگان و توجه ویژه آنها به کیفیت داخلی میوه، از جمله طراوت، شیرینی و محتوای تغذیه‌ای است (Liu & Ying, 2007; Massah, 2017; Hajiheydari, & Haddad, 2017). همچنین خصوصیات ظاهری میوه‌ها ارزش آنها را در بازار تحت‌تأثیر قرار می‌دهد از این رو، مهم است که پس از برداشت، میوه‌ها را به‌خوبی کنترل کرد (Ganiron, 2014). گلابی^۱ میوه‌ای با ارزش به‌دلیل داشتن عطر و طعم خاص و شیرین بوده و بیشتر انواع گلابی‌ها به‌صورت تازه خورده می‌شوند و در برخی موارد از آنها در اشکال مختلف فراوری شده همچون مربا، خشک‌شده و غیره استفاده می‌شود (Kolniak-Ostek, 2016; Pérez-Jiménez & Saura-Calixto, 2015). مطالعه تکنیک‌های پیش‌بینی و تشخیص نشان می‌دهد که اغلب شبکه عصبی مصنوعی^۲ (ANN) استفاده از سه‌لایه است که شامل لایه ورودی، پنهان و خروجی نشان داده شده است. نتیجه خروجی به وزن استفاده‌شده در داده‌های ارتباط خروجی و لایه‌های پنهان متکی است. در طول آموزش و یادگیری یک شبکه، وزن‌ها هستند که ارزش کار ANN را برای رسیدن به یک نتیجه بسیار نزدیک به خروجی واقعی رقم می‌زنند (Balogun, Salami, 2014; Aibinu, Mustafah, & Isiaka.B.S, 2014). شبکه‌های عصبی مصنوعی (ANNs) تکنیک‌های مدل‌سازی قدرتمند هستند که به‌طور خلاصه با آرایه‌هایی از نرون‌ها در حافظه و یادگیری بیولوژیک کار می‌کنند. ANN‌ها مزایای متعددی نسبت به تکنیک‌های مدل‌سازی معمولی ارائه می‌دهند زیرا می‌توانند براساس هیچ فرضیه‌ای درباره ماهیت مکانیزم‌های پدیده‌شناسی و درک زمینه‌های ریاضی مشکل اصلی فرایند و توانایی یادگیری روابط خطی و غیرخطی بین متغیرها به‌طور مستقیم از مجموعه‌ای از نمونه‌ها، مدل ارائه دهند (Fathi, Mohebbi, & Razavi, 2011). در دهه‌های اخیر، اکثر محققان در مهندسی کشاورزی از الگوریتم‌های یادگیری ماشین‌های مرسوم مانند شبکه عصبی مصنوعی استفاده کرده‌اند (Pan et al., 2016). همچنین محققین زیادی تحقیق‌هایی را درباره

³ Back-Propagation

⁴ Factor Rate Learning

⁵ Convolutional Deep neural network

⁶ blueberriesc


¹ *Pyrus communis* L.

² Artificial neural network

نمونه‌ها به آزمایشگاه دانشگاه علوم کشاورزی و منابع طبیعی گرگان آورده و پس از شست‌وشو برای اندازه‌گیری رطوبت در درون آن قرار گرفت و سپس رطوبت آنها در این آزمایش براساس استانداردها اندازه‌گیری شد (Azadbakht, Aghili, Ziaratban, & Torshizi, 2017). میزان رطوبت اندازه‌گیری شده برای گلابی ۷۷/۹۲ درصد بود.

آزمون شبه استاتیکی

برای انجام آزمون مکانیکی فشار لبه پهن و لبه نازک از دستگاه نیرو-تغییرشکل با نام تجاری اینسترون سنتام (Santam-STM5، ساخت ایران) با لودسل ۵۰۰ نیوتنی استفاده شد. برای تست فشاری از دو صفحه دایره‌ای شکل استفاده شد. این آزمون در سرعت ۵ میلی‌متر بر دقیقه با سه نیروی ۷۰، ۱۰۰ و ۱۳۰ نیوتن با سه تکرار انجام شد (شکل ۱). برای این آزمایش گلابی به صورت افقی در بین دو صفحه قرار گرفته و فشار داده شد و مدت زمان اندازه‌گیری این فرایند ثبت گردید. همچنین برای انجام تست فشار لبه نازک دو فک طراحی شد که از جنس پلاستیک با سطح مقطع مستطیلی به ابعاد $1/5 \times 0/3$ سانتی‌متری در سرعت ۵ میلی‌متر بر دقیقه با سه نیروی ۱۵، ۲۰ و ۲۵ نیوتنی در سه تکرار استفاده شد. با حرکت دادن فک متحرک، عملیات فشار تا جایی انجام شد که نیرو به حد موردنظر از کامپیوتر قرائت شد.



شکل ۲- شماتیک دستگاه ضربه


A: پاندول در زاویه ۹۰ درجه سانتی‌گراد، B: پاندول در حال طی کردن مسیر، C: برخورد پاندول به گلابی، D: نمای اصلی دستگاه، E: محل قرارگیری گلابی، F: پاندول ضربه‌زن و G: بدنه دستگاه

تصویربرداری با روش سی تی اسکن آماده‌سازی گلابی

در این آزمایش تعداد ۱۲۰ عدد گلابی برای آزمایش انتخاب گردید و از این گلابی‌ها با استفاده از روش غیرمخرب سی تی اسکن تصویربرداری گردید و تعداد ۸۱ گلابی که هیچ کبودی در درون خود نداشتند انتخاب شد. سپس گلابی‌ها پس از بارگذاری‌های شبه استاتیکی و دینامیکی در سه دوره ۵، ۱۰ و ۱۵ روز در دانشگاه علوم کشاورزی و منابع طبیعی گرگان انبار شد. شرایط محیطی انبار به صورتی انتخاب شد که مشابه مراکز فروش باشد تا بتوان میوه‌ها را در حین نگهداری تا مصرف مورد بررسی قرار داد. دمای هوای محیط برای نگهداری گلابی‌ها ۱۴ درجه سانتی‌گراد و رطوبت نسبی ۶۶ درصد بود.

تصویربرداری

برای انجام تصویربرداری، گلابی‌ها به محل آزمایش برده




شکل ۱- دیاگرام بارگذاری‌های شبه استاتیکی گلابی

A: دستگاه اینسترون B: فک‌های لبه نازک و لبه پهن C: نیروسنج D: کامپیوتر E: اطلاعات خارج شده

آزمون ضربه

ابتدا دستگاه پاندول و وزنه‌های موردنیاز در کارگاه گروه مکانیک بیوسیستم دانشگاه علوم کشاورزی و منابع طبیعی

سی‌تی‌اسکن محاسبه شد و با زمان بارگذاری در نرم‌افزار Microsoft Excel نسخه ۲۰۱۰ ثبت شد. در شکل (۳) دستگاه مورد استفاده در این آزمایش و محل قرارگیری گلابی برای بررسی نشان داده شده است. همچنین طی تصویربرداری هر گلابی به‌طور میانگین از ۷۰ تا ۱۰۰ تصویر برای رسیدن به شکل کامل گلابی برای بازسازی سه‌بعدی تصویربرداری شد. مراحل تکمیل هر تصویر تا رسیدن به تصویر نهایی در شکل (۴) نشان داده شده است. همچنین تصویر بازسازی‌شده دو‌بعدی گلابی نیز در شکل (۵) نشان داده شده است که می‌توان این تصویر را به دو قسمت بافت سالم و بافت پوسیده تقسیم‌بندی کرد. در شکل (۵) شماره ۱ محل کوفتگی در گلابی و شماره ۲ تصویر ایجادشده توسط سی‌تی‌اسکن است.




شکل ۴- مراحل ساخت تصویر سی‌تی‌اسکن

شد این آزمایش در ۵، ۱۰ و ۱۵ روز پس از بارگذاری شبه استاتیکی و دینامیکی هر گلابی، با دستگاه سی‌تی‌اسکن (مدل Somatom emotion 16 slice، ساخت آلمان) اسکن شد (شکل ۳). این دستگاه از دستگاه‌های CT نسل سوم محسوب می‌شود که در آن Tube و Detector روبه‌روی یکدیگر قرار داشته که به‌صورت ۳۶۰ درجه سانتی‌گراد به دور گلابی‌ها به‌صورت متوالی گردش کرده تا تصویر ایجاد شود. همچنین پیچ دستگاه برای آزمایش، ۱ پیچ بود ثبت تصاویر نیز در ولتاژ ۸۰ کیلوولت و جریان ۱۲۰ میلی‌آمپر انجام شد و برای ایجاد تصاویر کامل از برش‌های ۱ میلی‌متری استفاده شد. تصاویر ایجادشده به‌وسیله نرم‌افزار ایجادکننده تصویر Syngo CT 2012 ثبت‌شده و تصاویر دو‌بعدی و سیاه‌سفید تهیه و استخراج گردید. همچنین میزان وضوح تصاویر با هسته کانولوشن^۱ بیان می‌شود که از نوع B31Smooth بوده و تصاویر به‌وسیله ماتریس‌های ۵۱۲×۵۱۲ تشکیل گردیده است.



شکل ۳- دستگاه سی‌تی‌اسکن استفاده‌شده در تحقیق



شکل ۵- نمای دو‌بعدی گلابی قبل و بعد از پردازش تصویر
 ۱- کبودی در تصویر واقعی ۲- کبودی در تصویر پردازش‌شده (A):
 بخش پوسیده گلابی B: بخش سالم گلابی)

هدف از فاصله زمانی‌های بین کبودی و تصویربرداری به این دلیل بود که به کبودی اجازه تثبیت بهتر روی میوه را بدهد و رطوبت کبودی کاهش پیدا کند. این تفاوت رطوبت می‌تواند جذب اشعه ایکس بین بافت کبود و سالم را افزایش دهد. سپس با استفاده از دیتاهای دستگاه میزان حجم کل میوه، میزان حجم کبودی هر میوه و همچنین تصاویر دو‌بعدی رنگی برای هر کبودی روی میوه اندازه‌گیری و ثبت گردید (Diels et al., 2017). نسبت حجم کبودی به حجم کل هر گلابی به‌دست‌آمده با

¹ Convolution kernel

درصد کاهش حجم

حجم گلابی‌ها قبل و بعد از بارگذاری با استفاده سی تی اسکن اندازه‌گیری شد. سپس حجم بعد از بارگذاری از حجم قبل از بارگذاری کم گردید و میزان اختلاف یا کاهش حجم به دست آمد. با تقسیم اختلاف حجم بر حجم قبل از بارگذاری درصد کاهش حجم گلابی در طی انبارداری محاسبه شد.

مدل‌سازی شبکه عصبی مصنوعی

در این پژوهش شبکه عصبی مصنوعی پرسپترون چندلایه^۱ (MLP) برای مدل‌سازی نیروی بارگذاری و دوره انبارداری میوه گلابی جهت پیشگویی میزان پوسیدگی انتخاب گردید. شبکه عصبی پرسپترون چندلایه یک شبکه پیش‌خور^۲ با یک ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. این شبکه توسط ۲ لایه پنهان برای آزمایش انتخاب شد که در هر لایه به ترتیب تعداد ۳، ۵، ۷ و ۹ نرون قرار داده شد که برای هر یک از تعداد نرون‌ها شبکه به صورت جداگانه شبیه‌سازی گردید و این شبیه‌سازی با استفاده از نرم‌افزار نروسولوشن^۳ نسخه ۵ انجام شد. همچنین از توابع فعال‌سازی^۴ TanhAxon در لایه پنهان، ورودی و خروجی استفاده گردید. در این تحقیق روش بهینه‌سازی لونیبرگ-مارکوت^۵ به منظور یادگیری شبکه مورد استفاده قرار گرفت. همچنین ۷۰ درصد (۱۹ داده برای هر بارگذاری) از دیتاها برای آموزش، ۲۰ درصد (۵ داده برای هر بارگذاری) برای ارزیابی شبکه^۶

و ۱۰ درصد (۳ داده برای هر بارگذاری) از دیتاها برای آزمون شبکه^۷ مورد استفاده قرار گرفت (جدول ۱). نیروی بارگذاری و دوره انبارداری به عنوان ورودی‌های شبکه و درصد پوسیدگی گلابی در حالت‌های بارگذاری شبه استاتیکی (لبه پهن و لبه نازک) و دینامیکی (ضربه) خروجی‌های شبکه موردنظر بودند. تعداد ۵ تکرار برای شبیه‌سازی داده‌های شبکه عصبی مصنوعی جهت رسیدن به حداقل میزان خطا و حداکثر پایداری شبکه به صورت میانگین برابر ۱۰۰۰ سیکل یادگیری^۸ جهت شبیه‌سازی داده‌ها توسط شبکه عصبی منظور گردید و الگوریتم برآورد خطا در شبکه‌های تشکیل شده با استفاده از الگوریتم پس‌انتشار خطا^۹ صورت گرفت. برای ارزیابی شبکه دو معیار ضریب تبیین (R^2) و ریشه میانگین مربعات خطا^{۱۰} استفاده گردید. ضریب تبیین میزان همبستگی بین داده‌های خروجی شبکه عصبی و داده‌های مشاهده شده را تعیین می‌کند و از رابطه (۲) محاسبه می‌شود که مقدار ایده آن برابر ۱ می‌باشد. میانگین مربعات خطا اختلاف بین داده‌های پیش‌بینی شده و داده‌های واقعی را تعیین می‌کند (رابطه ۴) و ریشه آن از رابطه (۵) محاسبه می‌شود. هدف یک شبکه خوب این است که میزان این خطا را به کمترین مقدار برساند و مقدار ایده‌آل آن برابر صفر است. پارامترهای آماری شامل میانگین مربعات خطا^{۱۱}، ریشه میانگین مربعات خطا، ضریب تبیین و میانگین خطای مطلق^{۱۲} برای ورودی‌ها محاسبه شد و روابط با استفاده از فرمول‌های جدول (۲) محاسبه گردید.

جدول ۱- مقادیر تشکیل شبکه عصبی مصنوعی برای پارامترهای آموزش، آزمون، ارزشیابی، تعداد نرون، تابع فعال سازی، تابع آموزش

و لایه مخفی						
تعداد لایه‌های مخفی	تابع آموزش	نوع تابع فعال‌سازی	تعداد نرون‌ها در هر لایه مخفی	آزمون داده‌ها (درصد)	ارزشیابی داده‌ها (درصد)	آموزش داده‌ها (درصد)
۲			۳	۱۰	۲۰	۷۵
۲	Levenberg Marquardt	Hyperbolic tangent	۵	۱۰	۲۰	۷۵
۲			۷	۱۰	۲۰	۷۵
۲			۹	۱۰	۲۰	۷۵

⁷ Testing data

⁸ Epoch

⁹ Back propagation error

¹⁰ Root mean squared error (RMSE)

¹¹ Mean Square Error (MSE)

¹² Mean Absolute Error (MAE)

¹ Multi-layer perceptron

² Feed-Forward

³ NeuroSolution

⁴ Activation function

⁵ Levenberg-Marquardt (LM)

⁶ Validating data

جدول ۲- رابطه‌های شبکه عصبی

فرمول	شماره فرمول	رفرنس
$\text{Tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	۱	(Khoshnevisan, Rafiee, Omid, & Yousefi, 2013)
$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}$	۲	(Azadbakht et al., 2017)
$R = \sqrt{1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}}$	۳	(Khoshnevisan et al., 2013)
$\text{MSE} = \sum_{i=1}^n \frac{(P_i - O_i)^2}{n}$	۴	Azadbakht, Torshizi, Ziaratban, & Ghajarjazi, (2016)
$\text{RMSE} = \sqrt{\sum_{i=1}^n \frac{(P_i - O_i)^2}{n}}$	۵	(Khoshnevisan et al., 2013)
$\text{MAE} = \frac{\sum_{i=1}^n P_i - O_i }{n}$	۶	(Azadbakht et al., 2016)

در معادلات ۲، ۳، ۴، ۵ و ۶ شامل مقادیر پیش‌بینی شده (Pi) و مقادیر واقعی (Oi) و مقدار متوسط داده (O) می‌باشد.

نتایج و بحث

در جدول (۳) نتایج شبکه‌ها با نرون‌های مختلف نشان داده شده است. در جدول (۳) مقادیر به‌دست‌آمده برای RMSE، MAE، MSE و R^2 برای آموزش و آزمون شبکه نشان داده شده است. باتوجه به نتایج به‌دست‌آمده برای شبکه در حالت بارگذاری شبه استاتیکی لبه پنهان در یک لایه با نرون ۹ نشان داده شده است. البته این تعداد نرون در مجموع نیز بیشترین میزان R^2 را به خود اختصاص داده‌اند. همچنین بهترین میزان MAE و RMSE برای مقدار آزمون در شبکه‌ای با ۵ نرون ($\text{MAE}=1/0.4$, $\text{RMSE}=1/0.8$) و برای آموزش در شبکه با ۹ نرون ($\text{MAE}=2/1.0$, $\text{RMSE}=3/2.9$) در لایه پنهان بوده است و این نزدیکی نشان‌دهنده مناسب بودن شبکه‌ها می‌باشد. همچنین شبکه‌ای با تعداد ۵ نرون ($R^2=0/67$) در لایه پنهان برای آزمون و با ۷ نرون ($R^2=0/95$) در لایه پنهان برای آموزش کمترین میزان R^2 را نشان داده است و این امر دقت پایین‌تر این شبکه با تعداد نرون در لایه‌های پنهان را نشان می‌دهد. البته باتوجه به میزان R^2 برای آزمون می‌توان بیان کرد که شبکه‌ها با تعداد نرون‌های ۳، ۵، ۷ و ۹ موفق به بررسی آزمون مناسب داده‌ها شده‌اند و برای MAE و RMSE نیز ضعیف‌ترین شبکه برای آزمون شبکه با ۹ نرون ($\text{MAE}=2/3.9$, $\text{RMSE}=3/8.3$) و برای آموزش شبکه‌ای با ۳ نرون ($\text{MAE}=8/2.4$, $\text{RMSE}=1.4/4.7$) در لایه پنهان بوده است.

باتوجه به جدول (۳) برای شبکه در حالت بارگذاری شبه استاتیکی لبه پنهان بیشترین مقادیر آموزش و آزمون در یک لایه با نرون یکسان برای R^2 در شبکه‌ای با ۹ نرون ($\text{MAE}=0/99$ ، آموزش، $\text{MAE}=0/99$) در لایه‌های پنهان نشان داده شده است. البته این تعداد نرون در مجموع نیز بیشترین میزان R^2 را به خود اختصاص داده‌اند. همچنین بهترین میزان MAE و RMSE برای مقدار آزمون در شبکه‌ای با ۵ نرون ($\text{MAE}=1/0.4$, $\text{RMSE}=1/0.8$) و برای آموزش در شبکه با ۹ نرون ($\text{MAE}=2/1.0$, $\text{RMSE}=3/2.9$) در لایه پنهان بوده است و این نزدیکی نشان‌دهنده مناسب بودن شبکه‌ها می‌باشد. همچنین شبکه‌ای با تعداد ۵ نرون ($R^2=0/67$) در لایه پنهان برای آزمون و با ۷ نرون ($R^2=0/95$) در لایه پنهان برای آموزش کمترین میزان R^2 را نشان داده است و این امر دقت پایین‌تر این شبکه با تعداد نرون در لایه‌های پنهان را نشان می‌دهد. البته باتوجه به میزان R^2 برای آزمون می‌توان بیان کرد که شبکه‌ها با تعداد نرون‌های ۳، ۵، ۷ و ۹ موفق به بررسی آزمون مناسب داده‌ها شده‌اند و برای MAE و RMSE نیز ضعیف‌ترین شبکه برای آزمون شبکه با ۹ نرون ($\text{MAE}=2/3.9$, $\text{RMSE}=3/8.3$) و برای آموزش شبکه‌ای با ۳ نرون ($\text{MAE}=8/2.4$, $\text{RMSE}=1.4/4.7$) در لایه پنهان بوده است.

در جدول (۳) برای شبکه در حالت بارگذاری دینامیکی بیشترین مقادیر آموزش و آزمون در یک لایه با نرون یکسان برای R^2 در شبکه‌ای با ۳ نرون ($\text{MAE}=0/98$ ، آموزش، $\text{MAE}=0/99$) در لایه‌های پنهان نشان داده شده است. البته این تعداد نرون در آموزش و آزمون نیز بیشترین میزان R^2 را به خود اختصاص داده‌اند.

امر دقت پایین تر این شبکه با تعداد نرون در لایه های پنهان را نشان می دهد. البته با توجه به میزان R^2 برای آزمون می توان بیان کرد که شبکه ها با تعداد نرون های ۳، ۵، ۷ و ۹ موفق به بررسی آزمون مناسب داده ها شده اند و برای MAE و RMSE نیز ضعیف ترین شبکه برای آزمون شبکه با ۳ نرون ($MAE=3/55$, $RMSE=4/87$) و برای آموزش شبکه های با ۷ نرون ($MAE=5/10$, $RMSE=9/59$) در لایه پنهان بوده است.

همچنین بهترین میزان MAE و RMSE برای مقدار آزمون در شبکه های با ۷ نرون ($MAE=0/64$ ، $RMSE=1/004$) و برای آموزش در شبکه با ۳ نرون ($MAE=2/23$ ، $RMSE=2/99$) در لایه پنهان بوده است و این نزدیکی نشان دهنده مناسب بودن شبکه ها می باشد. همچنین شبکه های با تعداد ۳ نرون ($R^2=0/95$) در لایه پنهان برای آزمون و با ۷ نرون ($R^2=0/85$) در لایه پنهان برای آموزش کمترین میزان R^2 را نشان داده است و این

جدول ۳- بعضی از بهترین توپولوژی های شبکه عصبی MLP برای پیش بینی آموزش و آزمون شبکه

۹ نرون در لایه مخفی		بارگذاری شبه استاتیکی - فشار لبه نازک				۳ نرون در لایه مخفی		
		۷ نرون در لایه مخفی		۵ نرون در لایه مخفی				
آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	آزمون	
۰/۸۴	۱۴/۸۳	۱۹/۹۱	۵/۱۱	۴/۵۰	۲۰/۲۴	۸۴/۷۶	۲/۱۰	MSE
۰/۹۱	۳/۸۵	۴/۴۶	۲/۲۶	۲/۱۲	۴/۴۹	۹/۲۰	۱/۴۵	RMSE
۰/۵۸	۲/۸۲	۳/۷۲	۱/۴۵	۱/۳۲	۳/۱۹	۹/۱۱	۰/۳۱	MAE
۰/۹۹	۰/۹۱	۰/۶۹	۰/۹۵	۰/۹۹	۰/۸۲	-۰/۹۵	۰/۹۷	R^2
۹ نرون در لایه مخفی		بارگذاری شبه استاتیکی - فشار لبه پهن				۳ نرون در لایه مخفی		
		۷ نرون در لایه مخفی		۵ نرون در لایه مخفی				
۱۴/۶۷	۱۰/۸۴	۳/۳۶	۸۵/۴۷	۱/۱۷	۴۴/۷۵	۳/۸۵	۲۰۹/۵۲	MSE
۳/۸۳	۳/۲۹	۱/۸۳	۹/۲۴	۱/۰۸	۶/۶۹	۱/۹۶	۱۴/۴۷	RMSE
۲/۳۴	۲/۱۰	۱/۳۸	۷/۱۲	۱/۰۴	۴/۴۶	۱/۴۸	۸/۲۴	MAE
۰/۹۹	۰/۹۵	۰/۹۵	۰/۸۶	۰/۹۹	۰/۹۱	۰/۹۷	۰/۶۴	R^2
۹ نرون در لایه مخفی		بارگذاری دینامیکی				۳ نرون در لایه مخفی		
		۷ نرون در لایه مخفی		۵ نرون در لایه مخفی				
۲۰/۴۰	۷۸/۳۱	۱/۰۰۸	۹۲/۰۰	۱۴/۳۵	۲۵/۴۷	۲۳/۷۶	۸/۹۹	MSE
۴/۵۱	۸/۸۴	۱/۰۰۴	۹/۵۹	۳/۷۸	۵/۰۴	۴/۸۴	۲/۹۹	RMSE
۳/۴۵	۵/۲۱	۰/۶۴	۵/۱۰	۲/۳۴	۳/۸۲	۳/۵۵	۲/۲۳	MAE
۰/۹۸	۰/۸۸	۰/۹۵	۰/۸۵	۰/۶۷	۰/۹۴	۰/۹۹	۰/۹۸	R^2

(تعداد نرون ها=۹، سیکل یادگیری=۱۳) بارگذاری شبه استاتیکی لبه پهن (تعداد نرون ها=۷، سیکل یادگیری=۲۲) و برای بارگذاری دینامیکی (تعداد نرون ها=۷، سیکل یادگیری=۲۰) به دست آمده است. همچنین برای بهترین یادگیری برای داده های اعتبارسنجی برای بارگذاری شبه استاتیکی لبه نازک در اجرای ۳ (تعداد نرون ها=۹، سیکل یادگیری=۱) و در بارگذاری شبه استاتیکی لبه پهن در اجرای ۳ (تعداد نرون ها=۷، سیکل یادگیری=۴) و برای بارگذاری دینامیکی در اجرای ۳ (تعداد نرون ها=۷، سیکل یادگیری=۲۰) مشاهده شده است.

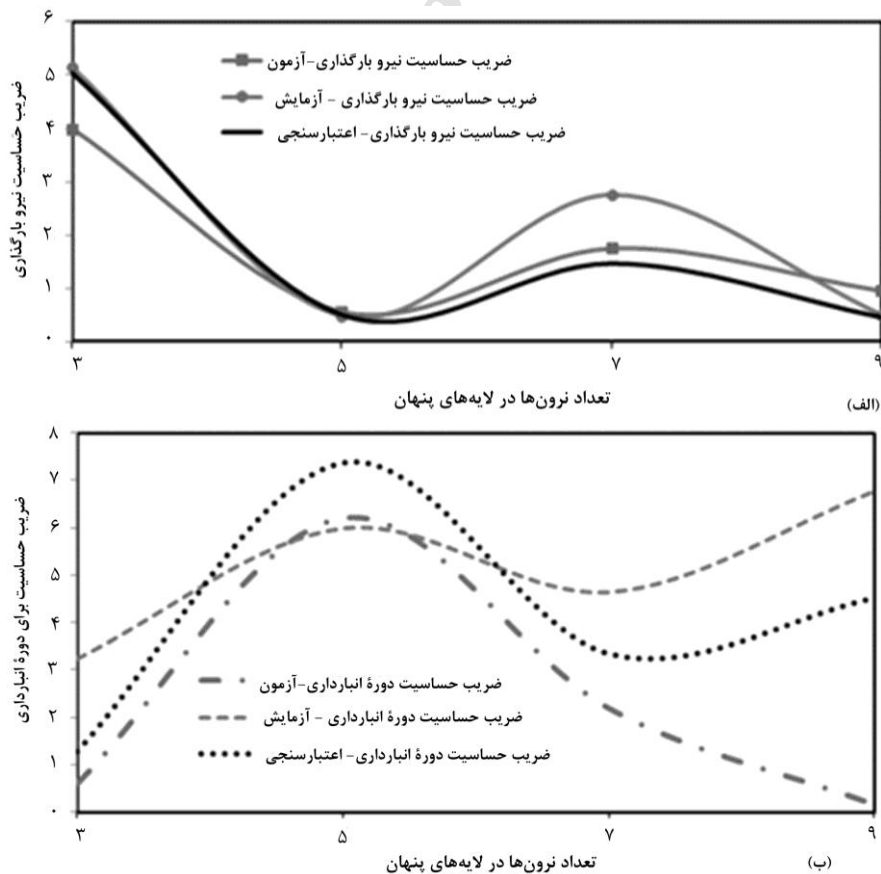
در جدول (۴) بهترین میزان اجرا و سیکل یادگیری برای هر یک از تعداد نرون ها در لایه های مخفی نشان داده شده است. با توجه به نتایج به دست آمده می توان مشاهده کرد که تمامی تعداد نرون ها در لایه های مخفی برای شبکه های بارگذاری شبه استاتیکی لبه نازک، بارگذاری شبه استاتیکی لبه پهن و بارگذاری دینامیکی در اجرای ۱ به بهترین میزان آموزش برای دیتاها دست پیدا کرده اند که این تعداد اجرای پایین نشان دهنده یادگیری سریع شبکه برای این بارگذاری ها بوده است. کمترین میزان سیکل یادگیری برای بارگذاری شبه استاتیکی لبه نازک

جدول ۴- برخی از توپولوژی‌های شبکه عصبی MLP برای پیش‌بینی مقادیر آموزش و ارزشیابی مقادیر

۹ نرون در لایه مخفی		بارگذاری شبه استاتیکی - فشار لبه نازک				۳ نرون در لایه مخفی		
		۷ نرون در لایه مخفی		۵ نرون در لایه مخفی				
اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	اعتبارسنجی	آموزش	
۳	۱	۲	۱	۱	۱	۴	۱	اجرا
۱	۱۳	۵	۱۸	۳	۴۳	۱۳	۳۹	سیکل یادگیری
		بارگذاری شبه استاتیکی - فشار لبه پهن						
۵	۱	۳	۱	۴	۱	۴	۱	اجرا
۱۰	۳۴	۴	۲۲	۱۳	۳۷	۱۵	۲۲	سیکل یادگیری
		بارگذاری دینامیکی						
۳	۱	۳	۱	۲	۱	۴	۱	اجرا
۷	۴۰	۲۱	۲۰	۱۹	۳۷	۷۵	۷۷	سیکل یادگیری

برای اعتبارسنجی مشاهده شده است. برای نیروی بارگذاری نیز بیشترین میزان ضریب حساسیت در شبکه‌ای با تعداد ۳ نرون در لایه پنهان مشاهده شده است. باتوجه به نتایج به دست آمده در شبکه با ۳ نرون در لایه پنهان ضریب حساسیت برای نیروی بارگذاری بیشتر از دوره انبارداری بوده است اما در شبکه با ۵، ۷ و ۹ نرون در لایه پنهان میزان حساسیت برای دوره انبارداری بیشتر از نیروی بارگذاری محاسبه شده است.



همچنین جهت تعیین میزان تأثیر فاکتور نیروی بارگذاری و دوره انبارداری بر میزان درصد پوسیدگی میوه، آزمون حساسیت انجام شد و نتایج این آزمون در شکل‌های (۶)، (۷) و (۸) نشان داده شده است. شکل (۶) ضریب حساسیت برای درصد پوسیدگی در بارگذاری شبه استاتیکی لبه نازک نشان داده است که باتوجه به شکل برای دوره انبارداری بیشترین ضریب حساسیت در تعداد ۹ نرون در لایه پنهان برای آزمون و آموزش و در ۵ نرون



شکل ۶- ضریب حساسیت درصد پوسیدگی بارگذاری شبه استاتیکی لبه نازک برای دوره انبارداری و نیروی بارگذاری

آموزش در شبکه‌ای با تعداد ۳ نرون در لایه پنهان مشاهده شده است. در مجموع باتوجه به نتایج به دست آمده می‌توان بیان کرد که ضریب حساسیت نیروی بارگذاری برای شبکه‌هایی با تعداد نرون ۳، ۵، ۷ و ۹ بیشتر از ضریب حساسیت دوره انبارداری بوده است.



شکل (۷) ضریب حساسیت برای درصد پوسیدگی در بارگذاری شبه استاتیکی لبه پهن نشان داده است. باتوجه به شکل (۷) برای دوره انبارداری بیشترین ضریب حساسیت در تعداد ۳ نرون در لایه پنهان برای اعتبارسنجی و در ۷ نرون برای آزمون و آموزش مشاهده شده است. برای نیروی بارگذاری نیز بیشترین میزان ضریب حساسیت برای اعتبارسنجی، آزمون و



شکل ۷- ضریب حساسیت درصد پوسیدگی بارگذاری شبه استاتیکی لبه پهن برای دوره انبارداری و نیروی بارگذاری

نتایج به دست آمده می‌توان بیان کرد که ضریب حساسیت دوره انبارداری برای شبکه‌هایی با تعداد نرون ۳، ۵، ۷، ۹ بیشتر از ضریب حساسیت نیروی بارگذاری ضربه‌ای بوده است.

شکل (۸) ضریب حساسیت برای درصد پوسیدگی در بارگذاری دینامیکی نشان داده است. باتوجه به شکل (۸) برای دوره انبارداری بیشترین ضریب حساسیت در تعداد ۵ نرون در لایه پنهان برای اعتبارسنجی و در ۳ نرون برای آزمون و آموزش مشاهده شده است. برای نیروی بارگذاری نیز بیشترین میزان ضریب حساسیت برای اعتبارسنجی، در تعداد ۵ نرون در لایه مخفی و برای آزمون و آموزش در شبکه‌ای با تعداد ۹ نرون در لایه پنهان مشاهده شده است. در مجموع باتوجه به



شکل ۸ - ضریب حساسیت درصد پوسیدگی بارگذاری دینامیکی برای دوره انبارداری و نیروی بارگذاری

نتیجه‌گیری

- در حالت بارگذاری شبه استاتیکی لبه نازک بهترین شبکه برای ضریب حساسیت نیروی بارگذاری با ۳ نرون و برای دوره انبارداری شبکه‌ای با ۵ نرون بوده است که بیشترین ضریب حساسیت را نشان داده است.
- برای حالت بارگذاری شبه استاتیکی لبه پهن ضریب حساسیت برای نیروی بارگذاری در ۳ نرون بهترین مقدار بوده است و تقریباً برای دوره انبارداری ضریب حساسیت یکسانی به دست آمده است و تفاوتی بین تعداد نرون‌ها برای پیش‌بینی حساسیت این مقدار مشاهده نشده است.
- در حالت بارگذاری دینامیکی با استفاده از تعداد ۹ نرون در لایه پنهان بیشترین ضریب حساسیت برای نیروی بارگذاری به دست آمد. برای دوره انبارداری نیز بیشترین ضریب حساسیت در ۹ نرون مشاهده شده است.
- برای حالت بارگذاری شبه استاتیکی برای ضریب حساسیت نیروی بارگذاری بهترین شبکه با ۳ نرون در لایه پنهان است.
- باتوجه به نتایج به دست آمده برای سیکل یادگیری می‌توان نتیجه گرفت که یادگیری شبکه برای درصد پوسیدگی بسیار سریع بوده است و شبکه عصبی توانایی مناسبی برای

- بهترین R^2 شبکه برای آموزش و آزمون برای حالت‌های بارگذاری شبه استاتیکی لبه نازک، بارگذاری شبه استاتیکی لبه پهن با تعداد ۹ نرون در لایه‌های مخفی به دست آمده است و برای بارگذاری دینامیکی بهترین مقدار در شبکه‌ای با ۳ نرون در لایه مخفی به دست آمده است.
- بهترین مقدار RMSE و MAE برای آموزش و آزمون برای حالت‌های بارگذاری شبه استاتیکی لبه نازک به ترتیب در شبکه‌ای با ۳ و ۹ نرون در لایه پنهان و در حالت بارگذاری شبه استاتیکی لبه پهن به ترتیب در تعداد ۹ و ۷ نرون و برای بارگذاری دینامیکی بهترین مقدار به ترتیب در شبکه‌ای با ۳ و ۷ نرون در لایه‌های پنهان به دست آمده است.
- بهترین یادگیری آموزش شبکه در اجرای ۱ برای تمامی حالت‌های بارگذاری به دست آمده است. کمترین مقدار سیکل یادگیری در حالت بارگذاری شبه استاتیکی لبه نازک در تعداد ۹ نرون و برای بارگذاری شبه استاتیکی لبه پهن و بارگذاری دینامیکی در تعداد ۷ نرون در لایه پنهان بوده است.

آموزش درصد پوسیدگی داشته است و همچنین باتوجه به مقدار R^2 و RMSE می توان گفت شبکه عصبی توانایی پیش بینی درصد پوسیدگی را در بارگذاری و دوره های انبارداری مختلف را در حد قابل قبولی برای گلایی داشته است.

منابع

- Azadbakht, M., Aghili, H., Ziaratban, A., & Torshizi, M. V. (2017). Application of artificial neural network method to exergy and energy analyses of fluidized bed dryer for potato cubes. *Energy*, 120, 947-958. doi:<https://doi.org/10.1016/j.energy.2016.12.006>
- Azadbakht, M., Torshizi, M. V., Ziaratban, A., & Ghajarjazi, E. (2016). Application of Artificial Neural Network (ANN) in predicting mechanical properties of canola stem under shear loading. *Agricultural Engineering International: CIGR Journal*, 18(2), 413-425.
- Balogun, W. A., Salami, M.-J. E., Aibinu, A. M., Mustafah, Y. M., & Isiaka, B.S, S. (2014). Mini Review: Artificial Neural Network Application on Fruit and Vegetables Quality Assessment. *International Journal of Scientific & Engineering Research*, 5(6), 702-708.
- Chakespari, A., Rajabipour, A., & Mobli, H. (2010). Mass modeling of two apple varieties by geometrical attributes. *Australian Journal of Agricultural Engineering*, 1(3), 112.
- Diels, E., van Dael, M., Keresztes, J., Vanmaercke, S., Verboven, P., Nicolai, B., . . . Smeets, B. (2017). Assessment of bruise volumes in apples using X-ray computed tomography. *Postharvest Biology and Technology*, 128, 24-32. doi:<https://doi.org/10.1016/j.postharvbio.2017.01.013>
- Fathi, M., Mohebbi, M., & Razavi, S. M. A. (2011). Application of image analysis and artificial neural network to predict mass transfer kinetics and color changes of osmotically dehydrated kiwifruit. *Food and Bioprocess Technology*, 4(8), 1357-1366. doi:<https://doi.org/10.1007/s11947-009-0222-y>
- Ganiron, T. U. (2014). Size properties of mangoes using image analysis. *International Journal of Bio-Science and Bio-Technology*, 6(2), 31-42.
- Hernández-Sánchez, N., Moreda, G. P., Herre-ro-Langreo, A., & Melado-Herreros, Á. (2016). Assessment of internal and external quality of fruits and vegetables. In N. Sozer (Ed.), *Imaging Technologies and Data Processing for Food Engineers. Food Engineering Series* (pp. 269-309): Springer, Cham.
- Khoshnevisan, B., Rafiee, S., Omid, M., & Yousefi, M. (2013). Prediction of environmental indices of Iran wheat production using artificial neural networks. *International Journal of Energy & Environment*, 4(2).
- Kolniak-Ostek, J. (2016). Identification and quantification of polyphenolic compounds in ten pear cultivars by UPLC-PDA-Q/TOF-MS. *Journal of Food Composition and Analysis*, 49, 65-77. doi:<https://doi.org/10.1016/j.jfca.2016.04.004>
- Kotwaliwale, N., Singh, K., Kalne, A., Jha, S. N., Seth, N., & Kar, A. (2014). X-ray imaging methods for internal quality evaluation of agricultural produce. *Journal of Food Science and Technology*, 51(1), 1-15. doi:<https://doi.org/10.1007/s13197-011-0485-y>
- Liu, Y., & Ying, Y. (2007). Noninvasive method for internal quality evaluation of pear fruit using fiber-optic FT-NIR spectrometry. *International Journal of Food Properties*, 10(4), 877-886. doi:<https://doi.org/10.1080/10942910601172042>
- Massah, J., Hajiheydari, F., & Haddad, D. (2017). Application of Electrical Resistance in Nondestructive Postharvest Quality Evaluation of Apple Fruit. *Journal of Agricultural Science and Technology*, 19, 1031-1039.
- Pan, L., Zhang, Q., Zhang, W., Sun, Y., Hu, P., & Tu, K. (2016). Detection of cold injury in peaches by hyperspectral reflectance imaging and artificial neural network. *Food Chemistry*, 192, 134-141. doi:<https://doi.org/10.1016/j.foodchem.2015.06.106>
- Pérez-Jiménez, J., & Saura-Calixto, F. (2015). Macromolecular antioxidants or non-extractable polyphenols in fruit and vegetables: Intake in four European countries. *Food Research International*, 74, 315-323. doi:<https://doi.org/10.1016/j.foodres.2015.05.007>
- Rostampour, V., Motlagh, A. M., Komarizadeh, M. H., Sadeghi, M., Bernousi, I., & Ghanbari, T. (2013). Using Artificial Neural Network (ANN) technique for prediction of apple bruise damage. *Australian Journal of Crop Science*, 7(10), 1442.
- Wang, Z., Hu, M., & Zhai, G. (2018). Application of deep learning architectures for accurate and rapid detection of internal mechanical damage of blueberry using hyperspectral transmittance data. *Sensors*, 18(4), 1126. doi:<https://doi.org/10.3390/s18041126>
- Zarifneshat, S., Rohani, A., Ghassemzadeh, H. R., Sadeghi, M., Ahmadi, E., & Zarifneshat, M. (2012). Predictions of apple bruise volume using artificial neural network. *Computers and Electronics in Agriculture*, 82, 75-86. doi:<https://doi.org/10.1016/j.compag.2011.12.015>

Application of Artificial Neural Network and Non-Destructive CT scan Test in Estimating the Amount of Pear Bruise Due To External Loads

Mohsen Azadbakht^{1*}, Mohammad Vahedi Torshizi²

1- Associate Professor, Department of Bio-System Mechanics, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

* Correspondence author (azadbakht@gau.ac.ir)

2- Master Student, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

Abstract

Pear damage is one of the main causes of the loss of fruit quality. Bruises occur during dynamic and quasi-static loading, which causes damage to the healthy tissue of the fruit. In this research, pears were placed under quasi-static loading (thin edge and wide edge) and dynamic loading. Then they were stored in 5, 10 and 15 days and after each storage period, using the CT-Scan non-destructive technique the bruise percentage was estimated. In this study, multi-layer perceptron artificial neural network (MLP) by 2 hidden layers and 3, 5, 7 and 9 neurons hidden layers was selected for modeling of loading force and storage period to predict bruise rate. The highest R² values for training and testing for quasi-static loading of thin edge and wide edge in a 9-neural network were training Thin-edge=0.91, test Thin-edge =0.99 and training Wide-edge=0.95, test Wide-edge =0.99. For the dynamic loading of a network with 3 neurons in the hidden layer has the highest value (training Wide-edge=0.98, test Wide-edge =0.99). For learning (9 neurons) quasi-static loading thin edge (7 neurons) quasi-static loading wide edge and dynamic loading (7 neurons) have been the best network. According to the results obtained for R², RMSE and learning cycle, it can be said that the neural network has the ability to predict the bruise percentage to an acceptable level for pears.

Keywords: Loading, Neural Network, Nondestructive Method, Pear Bruising