

مقاله پژوهشی

طبقه‌بندی خواص بیولوژیکی میوه گلابی در بارگذاری دینامیکی و استاتیکی با استفاده از شبکه عصبی مصنوعی

محسن آزادبخت^{۱*}، محمد واحدی ترشیزی^۲، علی اصغری^۳

۱. دانشیار گروه مهندسی مکانیک بیوسیستم دانشگاه علوم کشاورزی و منابع طبیعی گرگان
۲. دانشجوی کارشناسی ارشد گروه مهندسی مکانیک بیوسیستم دانشگاه علوم کشاورزی و منابع طبیعی گرگان
۳. استادیار گروه مهندسی مکانیک بیوسیستم دانشگاه علوم کشاورزی و منابع طبیعی گرگان

(تاریخ دریافت: ۹۷/۷/۱۲، تاریخ آخرین بازنگری: ۹۷/۸/۲۹، تاریخ پذیرش: ۹۷/۹/۶)

چکیده

شبکه‌های عصبی مصنوعی تکنیک‌های مدل‌سازی قدرتمند هستند که با آرایه‌هایی از نورون‌ها در حافظه و یادگیری بیولوژیک کار می‌کنند. در این تحقیق به بررسی طبقه‌بندی نوع بارگذاری دینامیکی و شبه استاتیکی یعنی لبه پهن و لبه نازک، با استفاده از داده‌های ورودی محتوای فنول، آنتی‌اکسیدان، ویتامین C و سفتی با شبکه عصبی مصنوعی پرداخته شده است. در این آزمایش برای طبقه‌بندی از دو شبکه تابع پایه شعاعی و پرسپترون چندلایه با دو تابع فعال سازی تانژانت هیپربولیک و سیگموئیدی در یک‌لایه مخفی با نورون‌هایی به تعداد ۴ و ۸ استفاده شد. با توجه به نتایج به دست آمده بهترین مقدار R و Percent Correct برای بارگذاری دینامیکی به ترتیب $\text{Percent Correct} = 100\% - R = 9999997$ ، بارگذاری لبه نازک $\text{Percent Correct} = 100\% - R = 9999993$ و بارگذاری لبه پهن $\text{Percent Correct} = 100\% - R = 9999992$ بود، که در شبکه تابع پایه شعاعی با تابع فعال‌سازی سیگموئید و تعداد ۸ نورون در لایه مخفی ایجاد شده است. همچنین بیشترین داده‌های صحیح تشخیص داده شده برای نوع بارگذاری دینامیکی، لبه پهن و لبه نازک در شبکه‌های ایجاد شده برای شبکه تابع پایه شعاعی مشاهده شد و این شبکه توانسته به طور ۱۰۰٪ برای تمامی بارگذاری‌ها، میزان داده‌ها را به درستی طبقه‌بندی کند. در مجموع شبکه عصبی با ورودی داده‌های کلی توانایی مطلوبی را در طبقه‌بندی داده‌های بارگذاری دینامیکی و شبه استاتیکی داشته است.

واژه‌های کلیدی: شبکه عصبی مصنوعی، گلابی، بارگذاری، طبقه‌بندی.

۱. مقدمه

است. آن‌ها قادر هستند یک فضای چندبعدی را با فضای دیگری مرتبط کنند حتی اگر این اطلاعات ناقص و دارای خطا باشند. این خصوصیات سبب شده که برای مسائل مربوط به برآورد و پیش‌بینی در کشاورزی و صنعت مناسب باشد و همچنین در مواردی که روابط غیرخطی است شبکه عصبی کارایی خوبی دارند [۱۰، ۱۱]. در شبکه عصبی مصنوعی الگوریتم طبقه‌بندی یک روش پیاده‌سازی مخصوص به خود دارد، بعضی از طبقه‌بندی‌ها یک عدد را مخلوطی از چند کلاس در نظر می‌گیرند و بعضی دیگر یک عدد را فقط به یک کلاس نسبت می‌دهند که دسته اول به طبقه‌بندی کننده نرم و دسته دوم به طبقه‌بندی کننده سخت مشهورند [۱۲]. امروزه برآورد میزان محصولات کشاورزی و زمین‌های زیر کشت و تغییرات آن‌ها، چنان اهمیتی دارد که امر برنامه‌ریزی و مدیریت آن‌ها به‌عنوان یک ضرورت برای همه کشورها تلقی می‌شود. لذا در این راستا علوم سنجش از دور با تکیه بر روش‌های تشخیص الگو، گام‌های مطلوبی را برداشته‌اند [۱۳]. از طرفی برای بررسی داده‌ها و شبیه‌سازی آن‌ها، شبکه عصبی مصنوعی بسیار مناسب است که در واقع مجموعه‌ای از روش‌های ریاضی است که اغلب شامل هوش مصنوعی بوده که به‌نوعی تلاش می‌کند که عملکرد مغز انسان را تقلید کند. در دو دهه گذشته، شبکه عصبی پتانسیل زیادی را در بسیاری از حوزه‌های علم و مهندسی به دلیل عملکرد استثنایی خود، سازمان‌دهی و خودآموزی درونی، پشت سر گذاشتن چالش‌ها و استحکام بالا نشان داده است. به تازگی علاقه به استفاده از شبکه‌های عصبی به‌عنوان ابزار مدل‌سازی در کشاورزی و فناوری‌های مواد غذایی افزایش یافته است. این موفقیت در چندین فناوری پردازش مواد غذایی مانند خشک کردن، فناوری پس از برداشت، رئولاسیون مواد غذایی، پیش‌بینی‌های میکروبی، تخمیر و پردازش حرارتی مورد استفاده گسترده قرار گرفته است [۱۴]. همچنین شبکه‌های عصبی مصنوعی یکی از کارآمدترین روش‌ها برای پردازش اطلاعات زیادی هستند که باعث چالش در جنبه‌های مختلف شده است. روند توسعه آن‌ها نشان‌دهنده اهمیت استفاده از این روش برای پردازش اطلاعات می‌باشد، زیرا در بررسی داده‌ها بسیار موفق بوده و توانسته‌اند در زمینه‌های مختلف گسترش یابند. همچنین برای تولید غذا، پردازش و ارزیابی کیفیت مواد غذایی، که در آن روش‌های پردازش داده‌های به سبک قدیمی ممکن است اطلاعات درستی

در دهه‌های اخیر مطالعات متعددی برای انجام روش دقیق ارزیابی محصولات غذایی انجام شده و دلیل این امر افزایش تقاضای مصرف‌کنندگان و توجه ویژه آن‌ها به کیفیت داخلی میوه، از جمله طراوت، شیرینی و محتوای تغذیه‌ای است [۱، ۲]. همچنین خصوصیات ظاهری میوه‌ها ارزش آن‌ها را در بازار تحت تأثیر قرار می‌دهد. از این رو، مهم است که پس از برداشت میوه‌ها را به‌خوبی کنترل کرد [۳]. گلابی (*Pyrus communis L*) میوه‌ای با ارزش به دلیل داشتن عطر و طعم خاص و شیرین بوده و بیشتر انواع گلابی‌های به‌صورت تازه خورده می‌شوند و در برخی موارد از آن‌ها در اشکال مختلف فراوری شده همچون مربا و خشک‌شده استفاده می‌شود [۵، ۴]. مطالعه تکنیک‌های پیش‌بینی و تشخیص نشان می‌دهد که اغلب شبکه عصبی مصنوعی استفاده از سه بخش شامل لایه ورودی، پنهان و خروجی نشان داده شده است. نتیجه خروجی به وزن استفاده شده در داده‌های ارتباط خروجی و لایه‌های پنهان متکی است. در طول آموزش و یادگیری یک شبکه، وزن‌ها هستند که ارزش کار شبکه عصبی مصنوعی (ANN) را برای رسیدن به یک نتیجه بسیار نزدیک به خروجی واقعی رقم می‌زنند [۶]. شبکه‌های عصبی مصنوعی تکنیک‌های مدل‌سازی قدرتمند هستند که به‌طور خلاصه با آرایه‌هایی از نورون‌ها در حافظه و یادگیری بیولوژیک کار می‌کنند. ANN‌ها مزایای متعددی نسبت به تکنیک‌های مدل‌سازی معمولی ارائه می‌دهند، زیرا می‌توانند بر اساس 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 [۷]. در دهه‌های اخیر، اکثر محققان در مهندسی کشاورزی از الگوریتم‌های یادگیری ماشین‌های مرسوم مانند شبکه عصبی مصنوعی استفاده کرده‌اند [۸]. شبکه عصبی مصنوعی، به‌عنوان یکی از مباحث هوش مصنوعی، نوعی پردازشگر اطلاعاتی است که آن را با معرفی درصدی از داده‌های ورودی و خروجی آموزش داده و نحوه عملکرد سیستم در حافظه آن ذخیره می‌شود [۹]. شبکه‌های عصبی مصنوعی بر اساس محاسبات روی داده‌های عددی یا مثال‌ها آموزش داده می‌شود. یکی از ویژگی‌های شبکه‌های عصبی توانایی آن‌ها در استخراج روابط بین ورودی و خروجی‌های یک فرایند، بدون نیاز به شرایط پیچیده فیزیکی

۲.۲. آزمون استاتیکی

برای انجام آزمون مکانیکی فشار لبه پهن و لبه نازک از دستگاه نیرو- تغییر شکل با نام تجاری اینسترون سنتام Santam-STM5 شرکت طراحی و مهندسی سنتام- ساخت ایران با لود سل ۵۰۰ N استفاده شد. برای آزمون فشاری از دو صفحه دایره‌ای شکل استفاده شد این آزمون در سرعت ۵ mm/min با سه نیروی ۷۰، ۱۰۰ و ۱۳۰ N 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 آزمون فشار لبه نازک دو فک طراحی شد که از جنس پلاستیک با سطح مقطع مستطیلی به ابعاد $1/5 \times 0/3 \text{ cm}^2$ در سرعت ۵ mm/min با سه نیروی ۲۰، ۱۵ و ۲۵ N در سه تکرار استفاده شد. تمامی گلابی‌های بارگذاری شده در سه دوره انبارداری ۵، ۱۰ و ۱۵ روزه انبارداری شدند [۱۷].

۳.۲. آزمون ضربه

ابتدا دستگاه پاندول و وزنه‌های مورد نیاز در کارگاه گروه مهندسی مکانیک بیوسیستم گرگان ساخته شد (شکل ۲). سپس میوه‌ها در محل مورد نظر قرار داده شد و بازوی دستگاه تا زاویه ۹۰ درجه بالا برده شد و در حالت کنترل شده بازو رها و به گلابی برخورد کرد. دستگاه آونگ دارای بازوی ۲۰۰ g و سه وزنه متصل مختلف ۱۰۰، ۱۵۰ و ۲۰۰ g برای ضربه زدن بود. لازم به ذکر است از مقاومت هوا و اصطکاک صرف نظر شده است. تمامی گلابی‌های بارگذاری شده در سه دوره انبارداری ۵، ۱۰ و ۱۵ روزه نگهداری شدند [۱۸].


را در اختیار ما نگذارد و یا هزینه‌های نسبتاً بالایی داشته باشند استفاده از شبکه عصبی یکی از روش‌های بسیار مناسب است. دو توانایی بسیار مهم شبکه‌های عصبی، یعنی معیارهای پیش‌بینی و طبقه‌بندی، بسیار مورد توجه بوده و در تحقیقات مختلف از توانایی پیش‌بینی استفاده فراوان شده، ولی به‌کارگیری تکنیک طبقه بندی کمتر استفاده شده است و این خود برای تحقیق حاضر نوآوری محسوب می‌گردد و با توجه به قابلیت‌های درونی شبکه عصبی مصنوعی می‌تواند با موفقیت مورد در مصارف کشاورزی استفاده قرار گیرند [۱۵].

هدف از انجام این مقاله طبقه‌بندی میوه گلابی با استفاده از ترکیبات تشکیل‌دهنده درونی آن در بارگذاری‌های استاتیکی و دینامیکی با استفاده از شبکه عصبی است تا بتوان با استفاده از شبکه عصبی مصنوعی و داده‌های ترکیبات درونی بهترین شبکه را تشکیل داده و این که آیا شبکه عصبی مصنوعی برای انواع بارگذاری توانایی مناسبی را در آموزش نشان می‌دهد یا خیر؟ همچنین تعیین ضریب حساسیت داده‌ها با استفاده از شبکه عصبی هدف بعدی انجام این تحقیق می‌باشد.

۲. مواد و روش‌ها

۱.۲. آماده‌سازی نمونه

گلابی‌های (رقم اسپادانا) از بازارهای استان گلستان- گرگان، ایران تهیه و نمونه‌ها به آزمایشگاه دانشگاه علوم کشاورزی و منابع طبیعی گرگان آورده و شست و شو شدند و سپس برای اندازه‌گیری رطوبت در درون آون قرار گرفت و با روش استاندارد رطوبت اندازه‌گیری شد [۱۶]. میزان رطوبت اندازه‌گیری شده برای گلابی بر پایه وزن تر ۷۷/۹۲٪ بود.



شکل (۱) دستگاه بارگذاری شبه استاتیکی گلابی، a: دستگاه نیرو جا به جایی (اینسترون)، b) فک لبه پهن و لبه نازک، c) نیروسنج دستگاه، d) کامپیوتر، e) خارج سازی دیتاها

Fig. 1. Static quasi-load diagram of pear, a) The force-deformation device (Inestron), b) Jaw wide edges and Jaw thin edges, c) Load Cell, d) Computer, e) Information Extract

۴.۲. ویتامین ث

میزان ویتامین ث با روش تیتراسیون ۲ و ۶-دی کلروفنول اندوفنول محاسبه گردید. بدین صورت که ابتدا ۵ g از نمونه با ۴۰ mL اسید استیک ۰.۸٪ مخلوط و عصاره‌گیری شد. در ادامه از عصاره صاف شده ۱۰ mL برداشته شد و با ۴۰ mL اسید استیک ۰.۸٪ مخلوط و با معرف ۲ و ۶-دی کلروفنول اندوفنول تیترا شد. نقطه پایان تیتراسیون ظهور رنگ ارغوانی کم‌رنگی است که ۱۵ s دوام داشته باشد. مقدار ویتامین ث برحسب mg در ۱۰۰ g وزن نمونه است. مقدار ویتامین ث از رابطه (۱) به دست آمد [۱۹].

(۱)

$$\text{Vitamin C} = \frac{\text{وزن نمونه} \times \text{حجم معرف مصرفی استاندارد}}{\text{حجم عصاره به دست آمده} \times \text{حجم معرف مصرفی} \times 10^2}$$

۱.۵.۲. فنل کل

جهت اندازه‌گیری فنل کل از روش فولین سیوکالتیو استفاده شد. بدین منظور ۲۰ μL از عصاره متانولی با ۱۰۰ μL فولین سیوکالتیو و ۱/۱۶ mL آب مقطر مخلوط و پس از ۵-۸ دقیقه استراحت، ۳۰۰ μL کربنات سدیم ۱ M به آن افزوده شد. محلول فوق به مدت ۳۰ min در تاریکی و حمام بخار ۴۰ °C قرار گرفت. در نهایت نمونه‌ها در طول موج ۷۶۵ nm قرائت شدند. با قرار دادن عدد جذب نمونه به جای (y) در معادله خط میزان فنل (x) بر حسب میلی گرم اسید گالیک بر گرم به دست آمد [۱۹].


$$Y = 0.5381X \quad (۲)$$

۵.۲.۲. درصد مهار رادیکال‌های آزاد به روش DPPH

در این آزمایش میزان درصد مهار رادیکال‌های آزاد DPPH، از روش باندت و همکاران اندازه‌گیری شد. ابتدا ۲ mL از DPPH با غلظت ۰/۱ mM به لوله آزمایش اضافه و سپس ۲ mL از عصاره متانولی تهیه شده به آن افزوده شد. سپس لوله‌های آزمایش به مدت ۱۵ min در محیط تاریک قرار داده و بلافاصله با دستگاه اسپکتروفتومتر (UV1800) در طول موج ۵۱۷ nm قرائت شد. نمونه شاهد حاوی ۲ mL DPPH و ۲ mL متانول بود. کالیبره کردن دستگاه اسپکتروفتومتر با متانول و اعداد به دست آمده توسط معادله (۳) به درصد مهار تبدیل شد [۲۰].

۵.۲. اندازه‌گیری صفات بیوشیمیایی

به منظور اندازه‌گیری فنل کل و میزان درصد مهار رادیکال‌های آزاد، میزان ۰/۵ g از هر نمونه کالوس تر با ۵ mL متانول ۰/۸۰٪ با نسبت ۱ به ۱۰، در یک هاون سرد کوبیده و همگن شدند. مواد همگن شده به مدت ۲۴ ساعت در تاریکی و روی شیکر قرار داده و سپس به مدت ۵ min در ۳۰۰۰ rpm/min سانتریفیوژ شد. از قسمت فوقانی عصاره، برای اندازه‌گیری صفات بیوشیمیایی مورد نظر استفاده گردید [۱۹، ۲۰].



شکل (۲) شماتیک دستگاه ضربه، (a) پاندول در زاویه ۹۰ درجه، (b) پاندول در حال طی کردن مسیر، (c) برخورد پاندول به گلابی، (d) نمایی اصلی دستگاه، (e) محل قرار گیری گلابی، (f) پاندول ضربه زن، (g) بدنه دستگاه

Fig. 2. Schematic of the impact machine, a) Pendulum at a 90 degree angle, b) Walking along the path, c) Collapse pendulum to pear, d) Main device profile, e) Place the pear, f) Pendulum blow G: the base of the device

به‌عنوان تابع آموزش‌دهنده شبکه استفاده شد. محتوای فنول کل، آنتی‌اکسیدان، ویتامین C و سفتی به‌عنوان ورودی و بارگذاری دینامیکی، لبه پهن و لبه نازک به‌عنوان خروجی برای طبقه‌بندی انتخاب شد که داده‌ها برحسب آن طبقه‌بندی خواهد شد. برای هر بارگذاری ۲۷ عدد برای هر کدام از پارامترهای محتوای فنول کل، آنتی‌اکسیدان، ویتامین C و سفتی مرتب‌شده و به‌عنوان ورودی در نظر گرفته شد. ۷۰٪ داده‌ها برای آموزش، ۱۵٪ برای آزمون و ۱۵٪ برای ارزیابی داده‌ها استفاده شد (جدول ۲). تعداد ۵ تکرار برای رسیدن به حداقل میزان خطا و حداکثر پایداری شبکه به‌صورت میانگین برابر ۵۰۰۰ سیکل یادگیری برای شبکه منظور گردید. الگوریتم برآورد خطا با الگوریتم پس انتشار خطا صورت گرفت. برای ارزیابی شبکه دو معیار ضریب تبیین (R^2) و ریشه میانگین مربعات خطا استفاده گردید. ضریب تبیین میزان همبستگی بین داده‌های خروجی شبکه عصبی و داده‌های

$$DPPH = \frac{Ac-As}{Ac} \times 100 \quad (3)$$

DPPH = Diphenyl Picryl Hydrazyl
As = جذب نمونه‌ها
Ac = جذب نمونه شاهد

۶.۲. مدل‌سازی شبکه عصبی مصنوعی

در این تحقیق از شبکه عصبی پرسپترون چندلایه (MLP) و تابع پایه شعاعی (RBF) برای طبقه‌بندی نوع بارگذاری دینامیکی، لبه پهن و لبه نازک استفاده شد. این شبکه‌ها دارای ۸ و ۴ نورون در لایه‌های پنهان ورودی و خروجی بوده و با استفاده از نرم‌افزار NeuroSolution 6 تحلیل‌های شبکه عصبی انجام شده است. در لایه‌های ورودی و خروجی شبکه عصبی مصنوعی از توابع فعال‌سازی تانژانت هیپربولیک و سیگموئید (روابط ۱ و ۲، جدول ۱) استفاده شد. همچنین از الگوریتم لوبنبرگ-مارکوات

جدول (۱) روابط شبکه عصبی مصنوعی.

Table 1 Neural Network Relationships.

منبع	شماره فرمول	فرمول
Reference	Formula Number	Formula
[23]	(4)	$\text{Tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
[24]	(5)	$\text{Sig} = \frac{1}{1 + e^{-x}}$
[25]	(6)	$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}$
[26]	(7)	$r = \sqrt{1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}}$
[27]	(8)	$MSE = \sum_{i=1}^n \frac{(P_i - O_i)^2}{n}$
[27]	(9)	$RMSE = \sqrt{\sum_{i=1}^n \frac{(P_i - O_i)^2}{n}}$
[28]	(10)	$MAE = \frac{\sum_{i=1}^n P_i - O_i }{n}$

جدول (۲) مقادیر بهینه سازی پارامترهای شبکه عصبی مصنوعی.

Table 2. Optimization values for artificial neural network parameters.

شبکه	تعداد لایه مخفی	تابع آموزش	تابع فعال سازی	تعداد نورون در لایه مخفی	داده‌های آزمون	داده‌های آموزش	اعتبار سنجی
Network	Number of hidden layers	Learning rule	Type of activation function	The number of One hidden layer neurons	Testing data %	Training data %	Cross Validation %
Multi layer perceptron (MLP)	1	Levenberg Marquardt	Hyperbolic tangent - Sigmoid	4-8	15%	70%	15%
Radial basis function (RBF)	1	Levenberg Marquardt	Hyperbolic tangent - Sigmoid	4-8	15%	70%	15%

شبکه‌ای است که با MLP آموزش داده شده است. همچنین هرچه میزان RSME به صفر نزدیک‌تر باشد، یعنی دقت کاری شبکه بالاتر بوده که در شبکه‌های RBF این میزان کمتر از MLP بود و این یعنی دقت این شبکه‌ها بالاتر بوده است. نتایج به دست آمده مشابه نتایج الراج و همکاران بر روی طبقه بندی میوه‌ها بر اساس دو شبکه MLP و RBF بود که بیان کردند شبکه RBF کارایی بهتری نسبت به MLP در طبقه بندی داشته و همچنین ساندوال و همکاران نیز بر روی زمین‌هایی کشاورزی و طبقه بندی آنها گزارش کردند که شبکه عصبی ایجاد شده با RBF نتایج قابل قبول تری را داشته است [۲۱، ۲۲].

در جدول (۴) میزان نتایج حاصل از طبقه‌بندی با استفاده از شبکه عصبی برای بارگذاری دینامیکی، لبه پهن و لبه نازک نشان داده شده که با توجه به نتایج می‌توان بیان کرد که در شبکه MLP، شبکه با تعداد ۸ نورون در لایه مخفی، توانسته ۱۰۰٪ به طور صحیح داده‌ها را طبقه‌بندی کند و برای شبکه عصبی RBF تعداد نورون ۴ و ۸ در لایه مخفی و هر دو تابع فعال‌سازی تانژانت هیپربولیک و سیگموئیدی توانسته طبقه‌بندی را به طور ۱۰۰٪ انجام دهند. همچنین با توجه به نتایج به دست آمده حاصل از طبقه‌بندی، برای داده‌های آموزش، برای بارگذاری لبه پهن در تمامی حالت‌های شبکه به جز شبکه MLP با ۴ نورون و تابع تانژانت هیپربولیک، داده‌ها به صورت ۱۰۰٪ درست طبقه‌بندی شده و برای بارگذاری لبه نازک و دینامیکی شبکه عصبی MLP با ۴ نورون در لایه پنهان و تابع فعال‌سازی تانژانت هیپربولیک و سیگموئیدی نتوانسته به طور ۱۰۰٪ داده‌ها را طبقه‌بندی کند ولی بقیه داده‌ها به صورت ۱۰۰٪ طبقه‌بندی شده است. در کل می‌توان بیان کرد که دقت طبقه‌بندی با شبکه عصبی RBF از شبکه MLP بهتر بوده چراکه داده‌های طبقه‌بندی شده با این شبکه به صورت ۱۰۰٪ صحیح طبقه‌بندی شده است.

در جدول (۵) نتایج حاصل از یادگیری شبکه عصبی نشان داده شد که با توجه به این نتایج می‌توان بیان کرد که بهترین شبکه از لحاظ یادگیری شبکه‌ای برای بخش آزمون (Training) شبکه RBF با ۸ نورون در لایه مخفی و تابع فعال‌سازی تانژانت هیپربولیک است چون توانسته در کمترین اجرا شبکه را برای خود آموزش بدهد. برای اعتبار سنجی نیز بهترین مقدار شبکه RBF با ۴ نورون در لایه پنهان و تابع فعال‌سازی تانژانت هیپربولیک بوده است. در واقع فقط مقدار پایین اجرا برای

مشاهده شده را تعیین می‌کند و از رابطه (۶) محاسبه می‌شود که مقدار ایده آل آن برابر یک هست. میانگین مربعات خطا اختلاف بین داده‌های پیش‌بینی شده و داده‌های واقعی را تعیین می‌کند (رابطه ۸) و ریشه آن از رابطه (۹) محاسبه می‌شود (جدول ۱). هدف یک شبکه خوب این است که میزان این خطا را به کمترین مقدار برساند و مقدار ایدئال آن برابر صفر است.

۳. نتایج و بحث

در جدول (۳) نتایج حاصل از تحلیل شبکه برای MSE، RMSE، NMSE، R، MAE، Percent Correct و نشان داده شده است. بر این اساس بهترین مقادیر برای MSE، NMSE، MAE، R و Percent Correct در شبکه RBF با ۸ نورون در لایه مخفی و تابع فعال‌سازی سیگموئیدی بوده است. بهترین مقادیر برای بارگذاری دینامیکی $MSE_{Train} = 1/3 \times 10^{-8}$ ، $RMSE_{Train} = 0/350$ ، $MAE_{Train} = 4/69 \times 10^{-5}$ ، $NMSE_{Train} = 5/58 \times 10^{-8}$ ، $R_{Train} = 0/99999997$ و Percent Correct Train = 100، و برای بارگذاری لبه پهن بهترین مقادیر $MSE_{Train} = 3/18 \times 10^{-8}$ ، $RMSE_{Train} = 0/260$ ، $MAE_{Train} = 7/01 \times 10^{-5}$ ، $NMSE_{Train} = 1/69 \times 10^{-7}$ ، $R_{Train} = 0/99999992$ ، Percent Correct Train = 100 و برای بارگذاری لبه نازک بهترین مقادیر $MSE_{Train} = 3/41 \times 10^{-8}$ ، $RMSE_{Train} = 0/260$ ، $MAE_{Train} = 6/54 \times 10^{-5}$ ، $R_{Train} = 0/99999993$ ، $Percent\ Correct\ Train = 100$ همچنین بهترین مقدار Percent Correct آزمون برای بارگذاری دینامیکی ۶۶/۷٪ (RBF-8 sigmoid)، لبه پهن ۱۰۰٪ (RBF-4 Tangent) و لبه نازک ۱۰۰٪ (RBF-8 sigmoid) بوده است. همچنین بهتر مقدار R آزمون برای بارگذاری دینامیکی (RBF-8 sigmoid)، لبه پهن (RBF-4 Tangent) و لبه نازک (MLP-4 sigmoid) بوده و در جدول (۳) مقادیر برای آزمون شبکه نشان داده شده است. همچنین با توجه به نتایج به دست آمده زمانی که در هر دو نوع تابع فعال‌سازی میزان تعداد نورون‌ها در لایه مخفی افزایش یابد این امر سبب افزایش میزان R و Percent correct شده و دقت داده‌های شبیه‌سازی شده با تابع فعال‌سازی سیگموئیدی بیشتر از تابع فعال‌سازی تانژانت هیپربولیک بوده و میزان R و Percent correct برای شبکه‌های که با RBF آموزش داده شده بالاتر از

۴. نتیجه گیری

با توجه به نتایج به دست آمده از شبکه عصبی، شبکه‌ای که با RBF آموزش دیده برای تمام بارگذاری‌ها از دقت بالاتری برخوردار بوده و در شبکه RBF نیز شبکه‌ای که تابع فعال‌سازی آن تانژانت هیپربولیک است توانسته به طور ۱۰۰٪ صحیح داده‌های را برای هر سه بارگذاری طبقه‌بندی نماید. شبکه MLP برای بارگذاری لبه پهن توانایی مناسبی را در آموزش نشان داده ولی برای بارگذاری لبه نازک و دینامیکی توانایی مناسبی را نشان نداده و دقت مناسبی را نداشته است. همچنین شبکه عصبی RBF دقت بالاتری را نسبت به MLP داشته است و دقت آموزش با این شبکه‌ها (RBF) بالاتر بوده و همچنین دقت شبکه تابع فعال‌سازی تانژانت هیپربولیک، نسبت به تابع فعال‌سازی سیگموئیدی بالاتر می‌باشد. همچنین نتایج ضریب حساسیت نشان داد که برای بارگذاری دینامیکی محتوای فنول در بیشتر شبکه‌های تشکیل شده تأثیر بیشتری را نسبت به بقیه ورودی‌ها در طبقه‌بندی داده‌ها داشته که نشان دهنده این است که داده‌های فنول نقش بیشتر و تأثیرگذاری در طبقه‌بندی برای بارگذاری دینامیکی داشته‌اند و برای بارگذاری لبه پهن نیز بیشترین ورودی تأثیرگذار داده‌های آنتی اکسیدان بوده است که در ۶ شبکه تشکیل شده از ۸ شبکه بیشترین ضریب حساسیت را به خود اختصاص داده و در بارگذاری لبه نازک نیز بیشترین میزان حساسیت به ترتیب فنول، آنتی اکسیدان و سفتی و کمترین میزان ضریب حساسیت برای این بارگذاری در ویتامین C نشان داده شده است. در مجموع شبکه‌های ایجاد شده با RBF بهتر از شبکه MLP بوده است.

طبقه‌بندی مهم نبوده و باید دقت و درصد پیش‌بینی صحیح داده‌ها نیز مورد بررسی قرار بگیرد. با توجه به نتایج شبکه عصبی اجرا با تابع فعال‌سازی سیگموئید و ۸ نورون در لایه مخفی بهترین مقادیر بوده، ولی با توجه به نتایج این شبکه در اجرا چهارم خود تشکیل شد که این مقدار اجرا اندکی بالا است ولی با توجه به اینکه دقت شبکه برای ما در طبقه‌بندی مهم است نباید مقدار اجرای پایین را مدنظر قرار دهیم.

ضریب حساسیت داده‌های ورودی برای طبقه‌بندی بارگذاری‌ها در شکل‌های ۵-۳ نشان داده شده که با توجه به نتایج برای بارگذاری لبه پهن در شبکه RBF و MLP با ۸ نورون در لایه پنهان و تابع فعال‌سازی سیگموئیدی و تانژانت هیپربولیک میزان آنتی اکسیدان بیشترین ضریب حساسیت را نشان داده و همچنین در شبکه RBF با تابع فعال‌سازی سیگموئیدی و ۴ نورون در لایه پنهان بیشترین میزان حساسیت برای سفتی بوده است و شبکه RBF و MLP با ۴ نورون در لایه پنهان و تابع فعال‌سازی تانژانت هیپربولیک به ترتیب بیشترین میزان ضریب حساسیت برای سفتی و ویتامین C بوده است (شکل ۳). برای بارگذاری لبه نازک در شبکه‌ای RBF با تابع فعال‌سازی سیگموئیدی و تانژانت و در شبکه MLP با تابع فعال‌سازی تانژانت هیپربولیک با ۴ نورون در لایه پنهان و در شبکه RBF و با تابع فعال‌سازی تانژانت هیپربولیک و ۸ نورون در لایه پنهان بیشترین میزان ضریب حساسیت برای محتوای فنول بوده است. همچنین در شبکه RBF با تابع فعال‌سازی سیگموئید و شبکه MLP با تابع فعال‌سازی تانژانت هیپربولیک و سیگموئیدی با ۸ نورون در لایه مخفی بیشترین میزان ضریب حساسیت را برای محتوای آنتی اکسیدان نشان داده است. شبکه MLP با ۴ نورون در لایه پنهان و تابع فعال‌سازی سیگموئید بیشترین میزان ضریب حساسیت را برای سفتی نشان داده است (شکل ۴). برای بارگذاری دینامیکی نیز بیشترین میزان ضریب حساسیت برای آنتی اکسیدان، فنول، ویتامین C و سفتی در شبکه RBF در حالت تشکیل شبکه با ۴ نورون در لایه مخفی و تابع فعال‌سازی تانژانت هیپربولیک و برای شبکه MLP برای آنتی اکسیدان، فنول و ویتامین C در شبکه تشکیل شده با ۸ نورون در لایه مخفی و تابع فعال‌سازی تانژانت هیپربولیک و برای سفتی در شبکه‌ای با ۴ نورون در لایه مخفی و تابع فعال‌سازی سیگموئیدی بوده است (شکل ۵).

جدول (۳) میزان خطا در پیش بینی داده‌های تجربی با استفاده از شبکه عصبی مصنوعی.

Table 3. Error values in predicting experimental data using optimal artificial neural network Mean Squared Error (MSE), Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), mean absolute error (MAE).

		میانگین مربعات خطا MSE		جذر میانگین مربعات خطا RMSE		نرمال میانگین مربعات خطا NMSE		میانگین مربعات خطا MAE		ضریب تبیین R		درست صحیح Percent correct	
		آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test
بارگذاری دینامیکی Dynamic Loading	4Tangent-MLP	0.0829	0.2805	0.288	0.530	0.3639	1.2625	0.1698	0.3787	0.8021	0.3240	85	50
	8Tangent-MLP	0.0016	0.5517	0.04	0.7427	0.0073	2.9426	0.0317	0.5474	0.9982	0.0999	100	66.66
	4Sigmoid-MLP	0.1001	0.4571	0.316	0.676	0.4781	1.8285	0.1901	0.4949	0.7289	0.0671	70.59	50
	8Sigmoid-MLP	0.0016	0.4293	0.04	0.6552	0.0073	1.7172	0.0335	0.4645	0.9983	0.1925	100	16.66
	4Tangent-RBF	0.0005	0.3917	0.022	0.626	0.0022	1.7627	0.0126	0.4378	0.9991	0.0063	100	25
	8Tangent-RBF	11E-5	0.6299	0.010	0.794	47E-5	2.8344	0.0022	0.6329	0.9997	-0.301	100	25
	4Sigmoid-RBF	0.0018	0.313	0.042	0.559	0.0081	1.670	0.0354	0.353	0.9982	0.173	94.737	33.333
	8Sigmoid-RBF	1.30E-8	0.3542	0.000	0.595	5.58E-8	1.8891	4.69E-5	0.3752	0.99999997	0.3057	100	66.7
بارگذاری لبه پهن Wide edge Loading	4Tangent-MLP	0.0690	0.4728	0.263	0.688	0.3417	1.8913	0.1381	0.5397	0.8209	-0.007	93.75	33.33
	8Tangent-MLP	0.0017	0.6306	0.041	0.794	0.0080	2.5225	0.0342	0.6394	0.9984	-0.249	100	16.66
	4Sigmoid-MLP	0.0745	0.4424	0.273	0.665	0.3272	2.3597	0.1827	0.4829	0.8218	-0.227	100	0
	8Sigmoid-MLP	16E-5	0.5178	0.013	0.720	96E-5	2.7617	0.0031	0.5268	0.9997	-0.328	100	0
	4Tangent-RBF	0.0013	0.4665	0.036	0.683	0.0058	3.3590	0.0282	0.4779	0.9985	0.3622	100	100
	8Tangent-RBF	0.0003	0.4565	0.017	0.676	0.0013	2.0541	0.0084	0.4663	0.9995	0.0831	100	50
	4Sigmoid-RBF	0.0216	0.500	0.147	0.707	0.1002	2.250	0.0583	0.536	0.9569	0.088	100	75
	8Sigmoid-RBF	3.13e-8	0.4525	0.000	0.673	1.69E-7	1.8099	7.01E-5	0.5030	0.99999992	0.0557	100	16.7
8Sigmoid-RBF	3.41E-8	0.3431	0.000185	0.586	1.43E-7	1.8299	6.54E-5	0.3596	0.99999993	0.5030	100	100	

ادامه جدول (۳) میزان خطا در پیش بینی داده‌های تجربی با استفاده از شبکه عصبی مصنوعی.

Table 3. Error values in predicting experimental data using optimal artificial neural network Mean Squared Error (MSE), Mean Absolute Error (MAE), Root Mean Squared Error (RMSE), mean absolute error (MAE).

		میانگین مربعات خطا MSE		جذر میانگین مربعات خطا RMSE		نرمال میانگین مربعات خطا NMSE		میانگین مربعات خطا MAE		ضریب تبیین R		درست صحیح Percent correct	
		آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test
Thin edge Loading بارگذاری لبه نازک	4Tangent-MLP	0.0218	0.1867	0.148	0.432	0.0935	1.3446	0.0542	0.1970	0.9572	0.6045	95.23	100
	8Tangent-MLP	0.0018	0.2460	0.042	0.496	0.0075	1.3122	0.0353	0.2887	0.9984	0.4356	100	66.66
	4Sigmoid-MLP	0.1102	0.4184	0.332	0.647	0.4841	2.2316	0.2093	0.4641	0.7345	0.2827	70	66.67
	8Sigmoid-MLP	0.0015	0.0843	0.039	0.290	0.0068	0.3796	0.0316	0.1311	0.9981	0.8362	100	75
	4Tangent-RBF	0.0004	0.1450	0.020	0.381	0.0018	0.6527	0.0116	0.2115	0.999	0.6900	100	75
	8Tangent-RBF	16E-5	0.3795	0.013	0.616	0.0008	1.5614	0.0032	0.4265	0.9996	0.2268	100	40
	4Sigmoid-RBF	0.0413	0.292	0.203	0.540	0.1814	1.203	0.0795	0.341	0.9173	0.418	90	40
	8Sigmoid-RBF	3.41E-8	0.3431	0.000185	0.586	1.43E-7	1.8299	6.54E-5	0.3596	0.99999993	0.5030	100	100

جدول (۴) مقادیر صحیح و خطای پیش بینی شده برای داده‌های ورودی هر شبکه.


Table 4 Correct and incorrect values for each network's input data.

		بارگذاری دینامیکی Dynamic Loading		بارگذاری لبه پهن Wide edge Loading		بارگذاری لبه نازک Thin edge Loading		
		آموزش Train	آزمون Test	آموزش Train	آزمون Test	آموزش Train	آزمون Test	
شبکه MLP MLP Network	4-tangent	بارگذاری دینامیکی Dynamic Loading	17	2	1	2	0	0
		بارگذاری لبه پهن Wide edge Loading	2	2	15	2	1	0
		بارگذاری لبه نازک Thin edge Loading	1	0	0	2	20	2
	8-tangent	بارگذاری دینامیکی Dynamic Loading	18	2	0	4	0	0
		بارگذاری لبه پهن Wide edge Loading	0	1	17	1	0	1
		بارگذاری لبه نازک Thin edge Loading	0	0	0	1	22	2
	4-sigmoid	بارگذاری دینامیکی Dynamic Loading	12	3	0	2	2	0
		بارگذاری لبه پهن Wide edge Loading	3	2	20	0	4	1
		بارگذاری لبه نازک Thin edge Loading	2	1	0	1	14	2
	8-sigmoid	بارگذاری دینامیکی Dynamic Loading	19	1	0	0	0	0
		بارگذاری لبه پهن Wide edge Loading	0	5	20	2	0	1
		بارگذاری لبه نازک Thin edge Loading	0	0	0	0	18	3
شبکه RBF RBF Network	4-tangent	بارگذاری دینامیکی Dynamic Loading	18	1	0	1	0	0
		بارگذاری لبه پهن Wide edge Loading	0	2	20	2	0	1
		بارگذاری لبه نازک Thin edge Loading	0	1	0	1	19	3
	8-tangent	بارگذاری دینامیکی Dynamic Loading	20	1	0	2	0	2
		بارگذاری لبه پهن Wide edge Loading	0	1	22	0	0	1
		بارگذاری لبه نازک Thin edge Loading	0	2	0	1	15	2
	4-sigmoid	بارگذاری دینامیکی Dynamic Loading	18	1	0	1	0	0
		بارگذاری لبه پهن Wide edge Loading	0	1	18	3	2	3
		بارگذاری لبه نازک Thin edge Loading	1	1	0	0	18	2
	8-sigmoid	بارگذاری دینامیکی Dynamic Loading	21	2	0	3	0	0
		بارگذاری لبه پهن Wide edge Loading	0	1	14	1	0	0
		بارگذاری لبه نازک Thin edge Loading	0	0	0	2	22	3

جدول (۵) برخی از بهترین شبکه‌های تشکیل شده برای پیش‌بینی داده‌های آزمایش.


Table 5 Some of the best neural network topologies to predict test values.

	آموزش Training		اعتبار سنجی Cross Validation		
	اجرا Run	تکرار Epoch	اجرا Run	تکرار Epoch	
شبکه MLP	4-Tangent	3	178	3	19
	8-Tangent	4	398	2	13
	4-Sigmoid	2	126	2	42
	8-Sigmoid	2	310	4	75
شبکه RBF	4-Tangent	3	600	1	21
	8-Tangent	1	405	5	13
	4-Sigmoid	3	1905	2	8
	8-Sigmoid	4	3999	5	4




شکل (۳) ضریب حساسیت بارگذاری لبه پهن

Fig. 3. Sensitivity coefficient for wide edge loading



شکل (۴) ضریب حساسیت بارگذاری لبه نازک

Fig. 4. Sensitivity coefficient for thin edge loading



شکل (۵) ضریب حساسیت بارگذاری دینامیکی

Fig. 5. Sensitivity coefficient for dynamic loading

منابع

- Networks for Prediction of Barley Breakage in Combine Harvester . *J. Agric.*, 10, 181–195.
- [10] Beale, R., Jackson, T. (1998). *Neural Computing: An Introduction*,.
- [11] Menhaj, M. (2000). *Foundation of Artifitioal Neural Networks*, Amir Kabir univercity.
- [12] Das, S., Routray, A., Deb, A. K.(2017). Hyperspectral Unmixing by Nuclear Norm Difference Maximization based Dictionary Pruning . *4th IEEE India Council Int. Conf.p 1-5*.
- [13] Eric Johnston, B. A. S., Design , Optimization , and Testing of a Combined Tri-Axial Polarized Energy Dispersive X-Ray Fluorescence and Energy Dispersive X-Ray Diffraction System for Biological Sample Classification, Thesis on McMaster University.
- [14] Lu, H., Zheng, H., Lou, H., Jiang, L., Chen, Y., Fang, S., (2010). Using neural networks to estimate the losses of ascorbic acid, total phenols, flavonoid, and antioxidant activity in asparagus during thermal treatments . *J. Agric. Food.chem.*, 58, 2995–3001.
- [15] Hosu, A., Cristea, V. M., Cimpoiu, C., (2014). Analysis of total phenolic, flavonoids, anthocyanins and tannins content in Romanian red wines: Prediction of antioxidant activities and classification of wines using artificial neural networks .*Food Chem.*, 150, 113–118.
- [16] Azadbakht, M., Vehedi Torshizi, M., Aghili, H., Ziaratban, A. (2018). Application of artificial neural network (ann) in drying kinetics analysis for potato cubes .*Carpa.J.Food.Sci. Technol.*, 10, 96–106.
- [17] Azadbakht, M., Vahedi Torshizi, M., Mahmoodi, M. J. (2018). Determination of pear bruises due to a thin edge compression load by CT scan method .*J.Innovative Food Technol.*, 6(2), p305-321.,.
- [18] Diels, E., van Dael, M., Keresztes, J., Vanmaercke, S., Verboven, P., Nicolai, B., Saey, W., Ramon, H., [1] Massah, J., Hajiheydari, F., Derafshi, M. H. (2017). Application of Electrical Resistance in Nondestructive Postharvest Quality Evaluation of Apple Fruit . *J. Agric. Sci. Technol.*, 19, 1031–1039.
- [2] Liu, Y., Ying, Y. (2007). Noninvasive Method for Internal Quality Evaluation of Pear Fruit Using Fiber-Optic FT-NIR Spectrometry . *Int. J. Food Prop.*, 10, 877–886.
- [3] Ganiron, T. U. (2014). Size properties of mangoes using image analysis . *Int. J.Bio-Sci.Bio-Technol.*, 6: 31–42.
- [4] Pérez-Jiménez, J., Saura-Calixto, F. (2015). Macromolecular antioxidants or non-extractable polyphenols in fruit and vegetables: Intake in four European countries . *Food Res. Int.*, 74, 315–323.
- [5] Kolniak-Ostek, J., (2016). Identification and quantification of polyphenolic compounds in ten pear cultivars by UPLC-PDA-Q/TOF-MS . *J. Food Compos. Anal.*, 49, 65–77.
- [6] Balogun, W. A., Salami, M. E., Aibinu, A. M., Mustafah, Y. M., Sadiku Isiaka B. S. (2014). Mini Review: Artificial Neural Network Application on Fruit and Vegetables Quality Assessment . *Int. J.Sci.Eng.Res.*, 5, 702–708.
- [7] Fathi, M., Mohebbi., and S. M. A. Razavi., (2011). Application of Image Analysis and Artificial Neural Network to Predict Mass Transfer Kinetics and Color Changes of Osmotically Dehydrated Kiwifruit . *Food Bioprocess Technol.*, 4, 1357–1366.
- [8] Pan, L., Q. Zhang., W. Zhang., Y. Sun., P. Hu., Tu, K. (2016). Detection of cold injury in peaches by hyperspectral reflectance imaging and artificial neural network . *Food Chem.*, 192, 134–141.
- [9] Mazloumzadeh, S. , Alavi, S., and Nouri, M. (2008). Comparison of Artificial Neural and Wavelet Neural

- Smeets B.(2017). Assessment of bruise volumes in apples using X-ray computed tomography . *Postharvest Biol. Technol.*, 128, 24–32.
- [19] Jaramillo-Flores, M. E., González-Cruz, L., Cornejo-Mazón, M., Dorantes-álvarez, L., Gutiérrez-López, G. F., Hernández-Sánchez, H. (2003). Effect of Thermal Treatment on the Antioxidant Activity and Content of Carotenoids and Phenolic Compounds of Cactus Pear Cladodes (*Opuntia ficus-indica*) . *Food Sci. Technol. Int.*, 9, 271–278.
- [20] Li, W. Li, L., X. H., Fan, X., Tang, Y., Yun, J. (2012). Response of antioxidant activity and sensory quality in fresh-cut pear as affected by high O₂ active packaging in comparison with low O₂ packaging . *Food Sci. Technol. Int.*, 18, 197–205.
- [21] Alrajeh, K. M. (2012). Date Fruits Classification using MLP and RBF Neural Networks . *Int. J. Comput. Appl. Technol.*, 41, 975–8887.
- [22] Sandoval, G., Vazquez, R. A., Garcia, P., Ambrosio, J. (2014). Crop Classification Using Different Color Spaces and RBF Neural Networks. *Int. Conf. Artif. Intell. Soft Comput.*, 598–609.
- [23] Soleimanzadeh, B., Hemati, L., Yolmeh, M., Salehi, F. (2015). GA-ANN and ANFIS models and salmonella enteritidis inactivation by ultrasound . *J. Food Saf.* , 35, 220–226.
- [24] Salehi, F. 1., A. Gohari Ardabili., A. 2 Nemati., and R. Latifi Darab., (2017). Modeling of strawberry drying process using infrared dryer by genetic algorithm-artificial neural network method . *J. Food Sci. Technol.*, 14, 105–114.
- [25] Azadbakht, M., Vehedi Torshizi, M., Ghajarjazi, E., Ziaratban, A. (2016). Application of Artificial Neural Network (ANN) in predicting mechanical properties of canola stem under shear loading . *Agri. Eng. Int.: CIGR Journal.*, 18, 413–424.
- [26] Salehi, F., Razavi, S. M. A. (2012). Dynamic modeling of flux and total hydraulic resistance in nanofiltration treatment of regeneration waste brine using artificial neural networks . *Desalin. Water Treat.*, 41, 95–104.
- [27] B. Khoshnevisan, Rafiee, Sh., Omid, M., Yousefi, M. (2013). Prediction of environmental indices of Iran wheat production using artificial neural networks . *Int. J. Energy Environ.*, 4, 339–348.
- [28] Azadbakht, M., H. Aghili., A. Ziaratban., and M. Vehedi Torshizi., (2017). Application of artificial neural network method to exergy and energy analyses of fluidized bed dryer for potato cubes . *Energy.*, 120, 947–958.

*Research Article***Biological Properties Classification of Pear Fruit in Dynamic and Static Loading using Artificial Neural Network****Mohsen Azadbakht^{1*}, Mohammad Vahedi Torshizi², Ali Asghari³**

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

2- MSc. Student, Department of Bio-system Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran.

3-Assistant Professor, Department of Bio-System Mechanical Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran.

Abstract

Artificial Neural Networks (ANNs) are powerful modeling techniques that work in brief with arrays of neurons in memory and biological learning. In this research, the classification of dynamic and quasi-static loading type (broad and thin edge) was investigated using input data of phenol, antioxidant, vitamin C content and stiffness with artificial neural network. In this experiment for the classification of two Radial basic function and Multilayer perceptron networks were used with two hyperbolic tangent and sigmoid activation functions in one layer. According to the obtained results, the best value for R and Percent Correct for dynamic loading was (Percent Correct = 100 - R = 9999997), loading the thin edge (Percent Correct = 100 - R = 9999993) and loading the wide edge (Percent Correct = 100 - R = 9999992), which was created in the RBF network with a sigmoid function activation and 8 neurons in the one hidden layer. Also, the most accurate data found for the dynamic loading type, the wide edge and the thin edge was observed in the networks created for the RBF network, and this network has been able to 100% accurately classify the data rate for all loads. In sum, the neural network with the input of general data has the desirable capability in the stacking of dynamic loading and quasi-static data.

Keywords: Artificial Neural Networks, Pear, Loading, Classification.

* Corresponding author: azadbakht@gau.ac.ir