

Research Paper

Classification of Banana Packaging Type Based on Physicochemical Properties Using Multilayer Perceptron (MLP) Artificial Neural Networks

Raziyeh Pourdarbani^{1*}, Sajad jafarzadeh¹, Farid moradi¹

¹ Department of Biosystem Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

Article history

Submitted: 2025/11/10

Revised: 2025/11/21

Accepted: 2025/11/30

Published

online: 2025/12/21

Keywords:

Classification
Physicochemical
Banana
Neural Network

Abstract

The neural network technique is a powerful modeling method that mimics biological memory and learning using neurons. In this study, the classification of packaging types under dynamic and quasi-static loading conditions on the banana fruit properties were investigated. The input data for the neural network included the phenolic content, antioxidant capacity, acidity, pH, soluble solids, firmness, and moisture content. The classification output data consisted of the different packaging types were used in the experiment. A perceptron network with 3 and 5 neurons in different layers was employed, utilizing the hyperbolic tangent as the selected activation function. In this research, the performance of multilayer artificial neural networks for classifying and predicting experimental data were evaluated. The models were trained with varying numbers of learning epochs and iterations, and the results were assessed based on mean squared error (MSE) values. The best performance was achieved with the MSE of approximately 0.00019 for the training data and 0.02 for the validation data, indicating the high accuracy of the model under optimal conditions. Additionally, increasing the number of learning epochs and iterations generally led to reduced error and improved prediction accuracy. However, in some cases, extremely low training error values suggested the possibility of model overfitting.

*Corresponding author:
r_pourdarbani@uma.ac.ir

ORCID: 
0000-0003-0766-8305



How to cite this paper:

Pourdarbani, R., Jafarzadeh, S., Moradi, F. (2025). Classification of Banana Packaging Type Based on Physicochemical Properties Using Multilayer Perceptron (MLP) Artificial Neural Networks. *Journal of Researches in Mechanics of Agricultural Machinery*. 37: 60-74. <https://dx.doi.org/10.22034/jrmam.2026.14799.736> (In Persian)



Authors retain the copyright and full publishing rights. Published by [Shahrekord University](https://www.shahrekord.ac.ir). This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/)

<https://dx.doi.org/10.22034/jrmam.2026.14799.736>

EXTENDED ABSTRACT

Introduction

More than one - third of agricultural crops are wasted after harvest that leads to lack of food. Improving storage methods, especially in developing countries, can reduce waste, increase food security and support farmers. The mechanical properties of the material are more comprehensive and clear understanding of the physical properties and consequently the texture. Employing this knowledge is useful to reduce the damage during the required operation and to increase the shelf life of fruits . Hence, attention to the shape and physical dimensions are required to be used for separation and sorting. some of physical properties such as shape, size, surface area, density, porosity, color, and appearance are important in many problems depending on design of special machines or analyzing product behavior in material handling. Also, the appearance characteristics of fruits are affected by their value in the market. Hence, it is important to properly control the harvest and post-harvest operations. In recent years, several studies have been conducted to perform a precise evaluation of food products due to increasing consumer demand and their special attention to the internal quality of fruit such as freshness, sweet and nutritional value. There are various researchers conducted by different researchers. Azadbakht et al, (2019) conducted a research on the classification of chemical properties of pears under dynamic loading using artificial neural network .the results showed that radial basis function network had the best performance in the classification of loads .fu et al. (2016) conducted a study to classify kiwifruit on the basis of shape using a image processing. They measured length , maximum diameter of basal area and projected area of fruit. The stepwise linear regression was used to select important variables in predicting the minimum diameter of basal area and volume. Hosnavi et al (2011) investigated physical-chemical properties to classify date palm fruits in 14 native cultivars from different areas of

morocco , tunisia and algeria .the results showed that sugar content are the dominant part of date fruitss .Also , the amount of protein , fat and ash were observed in the samples .

The aim of present paper is classification of banana fruit by using its constituent components in static and dynamic loads using MLP neural network.

Material and Methods

Based on the opinion of experts from local markets in Gorgan, a sufficient number of semi-ripe bananas were procured. First, the defective samples were separated. Then, the bananas were sorted by size to make them uniform in size and weight, thus eliminating the fruits from the standard size. Then, the fruits were packaged and stored for 14 days. The chemical properties of the samples were measured daily.

Results and Discussion

The models were performed in 2 period of learning and 2 replications for performance analysis. the overall results showed that increasing the number of learning period caused error reduction and performance improvement, especially in class 2 which recorded the highest accuracy

In contrast, Class 3 and Class 4 still had high errors, indicating the need for further optimization.

Also , the R value was negative, suggesting a mismatch between model predictions and actual data .the increase in the number of model runs had a significant effect on accuracy improvement in some classes .For further optimization, it is suggested to use methods such as weights, selecting the optimal architecture of neural network and optimization algorithms such as Adam or RMS prop.

Conclusions

The results of the implementation of neural networks showed that the accuracy of the model is strongly influenced by the number of learning periods and the number of replications. The increase in the number of

replications, reduced the mean square error (MSE). In the case of the number of learning cycles of 1000, the final error in cross-validation is higher, indicating the possibility of overfitting in low-complexity models.

On the other hand, implementing learning period of 2000 resulted in a significant decrease in educational error and also improved model performance in experimental data .in some cases , very low MSE values indicate that the model accurately learns the training data , but there is a need to validate the performance of the model over the new data to ensure that the model is appropriate .Adjusting the weights , reducing learning rate, and increasing the number of training data can help improve model performance and prevent the overfitting.

Author Contributions

Razyieh Pourdarbani: Conceptualization

Sajad Jafarzadeh: Writing

Farid Moradi: Methodology

Data Availability Statement

"Not applicable".

Ethical Considerations

It is confirmed adherence to ethical standards, including avoidance of data fabrication, falsification, plagiarism, and misconduct.

Conflict of Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper

Funding Statement

The author(s) received no specific funding for this research



طبقه‌بندی نوع بسته‌بندی موز بر اساس ویژگی‌های فیزیکی و شیمیایی با استفاده از شبکه‌های عصبی مصنوعی چندلایه

راضیه پوردربانی^{*}، سجاد جعفرزاده^۱، فرید مرادی^۱

۱- گروه مهندسی بیوسیستم، دانشگاه محقق اردبیلی، اردبیل، ایران

تاریخچه مقاله	چکیده
دریافت: ۱۴۰۴/۰۸/۱۹	روش شبکه عصبی یک روش مدل‌سازی قدرتمند بوده که در حافظه و یادگیری زیستی
بازنگری: ۱۴۰۴/۰۸/۳۰	با استفاده از سلول عصبی انجام می‌شود. در این تحقیق به بررسی طبقه‌بندی نوع
پذیرش: ۱۴۰۴/۰۹/۰۹	بسته‌بندی در بارگذاری پویا و شبه ایستا بر روی خصوصیات میوه موز تحقیقی انجام شد
انتشار: ۱۴۰۴/۰۹/۳۰	که داده‌های ورودی شبکه عصبی این تحقیق شامل محتوای فنول، آنتی اکسیدان،
واژه‌های کلیدی:	
طبقه بندی	
خواص فیزیکی - شیمیایی	
موز	
شبکه عصبی.	
*پست الکترونیکی نویسنده	
مسئول:	
r_pourdarbani@uma.ac.ir	
ORCID: 	
0000-0000-0766-8305	
	

نحوه استناد به این مقاله:

پوردربانی، ر.، جعفرزاده، س.، مرادی، ف. (۱۴۰۴). طبقه‌بندی نوع بسته‌بندی موز بر اساس ویژگی‌های فیزیکی و شیمیایی با استفاده از شبکه‌های عصبی مصنوعی چندلایه. نشریه پژوهش‌های مکانیک ماشین‌های کشاورزی، ۳۷: ۶۰-۷۴. شناسه دیجیتال:

<https://dx.doi.org/10.22034/jrmam.2026.14799.736>

مقدمه

سالانه بیش از ۲/۳ میلیارد تن غذا در جهان از بین می‌رود که این میزان بیش از نیمی از تولیدات کشاورزی را شامل می‌شود. در اروپا و آمریکای شمالی، هر فرد سالانه ۹۵ تا ۱۱۵ کیلوگرم غذا دور می‌ریزد، درحالی‌که این مقدار در آفریقای جنوب صحرا و جنوب و جنوب شرق آسیا تنها ۶ تا ۱۱ کیلوگرم است. بیش از یک‌سوم محصولات کشاورزی پس از برداشت هدر می‌رود که یکی از دلایل کمبود جهانی غذا محسوب می‌شود. بهبود روش‌های نگهداری و ذخیره‌سازی، به‌ویژه در کشورهای درحال توسعه، می‌تواند موجب کاهش هدررفت، افزایش امنیت غذایی و حمایت از کشاورزان شود (X & W, 1998; Sawicka, 2020). خواص مکانیکی مواد می‌تواند درک جامع و روشن‌تری از خواص فیزیکی و در نتیجه خصوصیات بافت آن ماده به دست دهد. لذا این مفهوم، پایه و اساس بسیاری از روش‌های ابزاری در شناسایی خصوصیات بافت مواد زیستی است (Akandi et al., 2018).

خواص مکانیکی ممکن است در حین رشد میوه و دوران رسیدگی دست‌خوش تغییر شود. به کارگیری دانش حاصل از این مطالعه ضمن کاهش صدمات وارده در طی عملیات مورد نیاز، در افزایش عمر ماندگاری میوه نیز مفید است (N. Galili et al., 1998). از این‌رو توجه به شکل و ابعاد فیزیکی برای غربال کردن مواد جامد و جداسازی مواد خارجی و یا برای جداسازی و درجه‌بندی مورد نیاز هستند. شکل، اندازه، حجم سطح رویه، چگالی، تخلخل، رنگ و ظاهر برخی از ویژگی‌های فیزیکی‌اند که در بسیاری از مسائل وابسته به طراحی ماشین‌های مخصوص یا تحلیل رفتار محصول در بررسی مواد با اهمیت هستند (Mohsenin, 1968). همچنین خصوصیات ظاهری میوه‌ها ارزش آن‌ها را در بازار تحت تأثیر قرار می‌دهد. از این‌رو، مهم است که پس از برداشت میوه‌ها را به‌خوبی کنترل کرد (Ganiron, 2014; Pérez-Jiménez & Saura-Calixto, 2015).

شبکه‌های عصبی مصنوعی روش‌های محاسباتی هستند که تحلیل‌های چندعاملی انجام می‌دهند. این مدل‌ها که از شبکه‌های سلول عصبی زیستی الهام گرفته‌اند، حاوی لایه‌هایی از گره‌های محاسباتی ساده هستند که به‌عنوان دستگاه‌های جمع‌کننده غیرخطی عمل می‌کنند. این گره‌ها به‌طور غنی از طریق خطوط اتصال وزنی به یک‌دیگر متصل شده‌اند و وزن‌ها هنگام ارائه داده‌ها به شبکه در طی فرایند آموزش تنظیم می‌شوند. آموزش موفق می‌تواند به شبکه‌های عصبی مصنوعی

منجر شود که وظایفی مانند پیش‌بینی یک مقدار خروجی، طبقه‌بندی یک شی، تقریب یک تابع، شناسایی الگو در داده‌های چندعاملی و تکمیل یک الگوی شناخته‌شده را انجام دهند (Balogun et al., 2014; Kolniak-Ostek, 2016). شبکه‌های عصبی مصنوعی (ANNs) ابزارهای مدل‌سازی پیچیده و کارآمدی هستند که با تقلید از عملکرد سلول عصبی در مغز انسان، قادر به یادگیری و ذخیره اطلاعات هستند.

این شبکه‌ها به‌ویژه در مقایسه با روش‌های مدل‌سازی سنتی، مزایای چشم‌گیری دارند. یکی از ویژگی‌های برجسته آنها این است که بدون نیاز به فرضیات خاصی درباره نحوه عملکرد سازوکارهای پدیده‌شناسی یا مدل‌های ریاضی پیچیده، می‌توانند به‌طور مستقیم از داده‌های ورودی، روابط خطی و غیرخطی بین متغیرها را شبیه‌سازی کنند. این شبکه‌ها قادرند از مجموعه‌های بزرگ داده، الگوهای پنهان را شناسایی کرده و مدل‌هایی ارائه دهند که نه تنها برای مسائل پیچیده، بلکه برای یادگیری و تحلیل داده‌ها در زمینه‌های متنوع، عملکرد بالایی دارند (Fathi et al., 2011). 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 تازگی، شیرین بودن و ارزش تغذیه‌ای است (Massah et al., 2017; Liu & Ying, 2007). از این‌رو محققان مختلفی تحقیقاتی را به شرح زیر انجام دادند:

آزادبخت و همکاران (۲۰۱۹) تحقیقاتی را در زمینه طبقه‌بندی ویژگی‌های شیمیایی میوه گلابی تحت بارگذاری پویا و شبه‌ایستا با استفاده از شبکه عصبی مصنوعی انجام دادند. نتایج این پژوهش نشان داد که شبکه تابع پایه شعاعی (RBF) با تابع فعال‌سازی سیگموئید و ۸ سلول عصبی در لایه پنهان، بهترین عملکرد را در طبقه‌بندی بارگذاری‌ها داشت. دقت طبقه‌بندی برای بار پویا، لبه نازک و لبه پهن به ترتیب ۱۰۰ درصد بود. این مطالعه نشان داد که شبکه‌های عصبی مصنوعی قابلیت بالایی در دسته‌بندی داده‌های بارگذاری پویا و شبه‌ایستا دارند (Azadbakht, Vahedi Torshizi, et al., 2019).

فو و همکاران (۲۰۱۶) مطالعه‌ای را با هدف طبقه‌بندی کیوی بر اساس شکل میوه با استفاده از یک دوربین در خطوط درجه‌بندی چین انجام دادند. در این پژوهش، پردازش تصویر برای اندازه‌گیری طول، قطر حداکثری مقطع استوایی و مساحت تصویر شده میوه به کار گرفته شد. روش رگرسیون

شبکه‌های عصبی مصنوعی (ANN) برای مدل‌سازی پیش‌بینی استفاده شد. داده‌های حاصل از HS-GC-MS پردازش شده و اوج‌های مهم در رنگ‌نگار کل یونی به‌عنوان ویژگی‌های ورودی شبکه عصبی انتخاب شدند. نتایج نشان داد که ترکیبات فرآر کلیدی دارای قدرت پیش‌بینی کافی برای طبقه‌بندی دقیق اسانس بر اساس مرحله رسیدگی هستند. همچنین، تحلیل حساسیت، ترکیبات کلیدی مؤثر در شناسایی مرحله رسیدگی را مشخص کرد. این مطالعه یک راهبرد نوین برای کنترل کیفیت اسانس پرتقال تلخ بدون نیاز به روش‌های ذهنی ارائه می‌دهد (Taghadomi-Saberi et al., 2018).

هدف از انجام این مقاله طبقه‌بندی میوه موز با استفاده از ترکیبات تشکیل‌دهنده درونی آن در بارگذاری‌های ایستا و پویا 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 است.

مواد و روش‌ها

آماده‌سازی و تجهیزات

در این تحقیق موزهای نیمه رسیده طبق نظر افراد خبره از بازارهای محلی شهر گرگان، استان گلستان، ایران تهیه شد. موزهایی که دچار آسیب‌های ظاهری بودند جدا شدند. سپس موزهای بی‌عیب و نقص در ظاهر با دستمال مرطوب تمیز شدند و تمامی موزها از نظر ابعاد دسته‌بندی شدند تا بتوان یکسان‌سازی از نظر ابعاد و وزن میزان خطای وارده به آزمایش را کاهش داد، از این‌رو موزهایی که خیلی بزرگ و خیلی کوچک از حد استاندارد مشتری‌پسندی بودند از رده خارج شدند. پس از درجه‌بندی، بسته‌بندی انجام و سپس موزهای بسته‌بندی شده به مدت ۱۴ روز نگهداری شده و خصوصیات رنگی و فیزیکی موزها به طور روزانه و خصوصیات شیمیایی نمونه در روز آخر اندازه‌گیری شد. همچنین در این روش، میوه به صورت ایستا و پویا بارگذاری شدند.

آزمون ایستا و پویا

آزمون‌های ایستا و پویا برای بررسی خواص مکانیکی موز انجام شد. در آزمون ایستا، موز بین دو صفحه دایره‌ای قرار گرفته و تحت فشارهای مختلف با سرعت ۵ میلی‌متر بر دقیقه بررسی

خطی گام‌به‌گام برای انتخاب متغیرهای مهم در پیش‌بینی حداقل قطر مقطع استوایی و حجم مورد استفاده قرار گرفت. نتایج نشان داد که ترکیب طول، قطر حداکثری و وزن می‌تواند حداقل قطر مقطع استوایی را با ضریب تعیین ۰/۸۲ پیش‌بینی کند، درحالی‌که وزن و طول برای تخمین حجم با ضریب تعیین ۰/۹۸ انتخاب شدند. طبقه‌بندی میوه‌ها بر اساس حداقل قطر مقطع استوایی موفقیت ۸۴/۶ درصدی داشت که با استفاده از ترکیب خطی نسبت‌های طول/قطر حداکثری و مساحت تصویر شده/طول به ۹۸/۳ درصد افزایش یافت. این تحقیق نشان داد که با افزودن یک دوربین، خطوط درجه‌بندی کیوی در چین می‌توانند به استانداردهای بین‌المللی دست یابند (Fu et al., 2016).

حسنای و همکاران (۲۰۱۱) خصوصیات فیزیکی - شیمیایی، طبقه‌بندی و ارزیابی کیفی میوه‌های نخل خرما را در چهارده رقم بومی از نواحی مختلف مراکش، تونس و الجزایر مورد بررسی قرار دادند. نتایج نشان داد که قندها بخش غالب ترکیب این خرماها را تشکیل می‌دهند (۷۵/۵۶-۵۴/۱۴۴ گرم در ۱۰۰ گرم ماده خشک)، در حالی که میزان رطوبت بین ۷۰.۲ تا ۳۱/۹ درصد متغیر بود. همچنین مقادیر کمی از پروتئین (۳/۱-۳/۹۹ گرم)، چربی (۰/۴۴-۰/۱۳ گرم) و خاکستر (۳/۱-۴۵/۸۸۸ گرم) در نمونه‌ها مشاهده شد. خرماهای زودرس دارای بیش‌ترین میزان فعالیت آبی (۰.۸۷-۰/۷۸) بودند، در حالی که خرماهای دیررس، مانند ارقام Assiane، Aziza Bouzid و Boufeggous Gharas، مقدار بالاتری از شاخص‌های رنگی L^* ، a^* و b^* را نشان دادند. در ارقام Deglet Nour (تونس) و Aziza Bouzid (مراکش)، ساکارز قند غالب بود، اما بیش‌تر ارقام دیگر مقادیر مشابهی از فروکتوز و گلوکز داشتند. ترکیب شیمیایی خرماها به‌عنوان ابزاری مفید در مطالعات توانایی فیزیولوژیکی و فناوری این میوه معرفی شد. (Hasnaoui et al., 2011)

تحقیقات تاقدمی صابری و همکاران (۲۰۱۸) به بررسی طبقه‌بندی اسانس پرتقال تلخ بر اساس مرحله رسیدگی میوه با استفاده از پروفایل‌گیری شیمیایی غیرهدفمند و یادگیری ماشینی پرداخت. ترکیب و کیفیت اسانس‌های پرتقال تلخ به میزان زیادی به مرحله رسیدگی میوه بستگی دارد، زیرا غلظت ترکیبات فرآر و در نتیجه ویژگی‌های ارگانولپتیکی (طعم، بو، رنگ و ظاهر) آن تغییر می‌کند. در این پژوهش، برای ارزیابی عینی اسانس پرتقال تلخ، ترکیبی از روش کروماتوگرافی گازی-طیف‌سنجی جرمی فضای فوقانی (HS-GC-MS) و

فنل کل

برای اندازه‌گیری فنل کل، عصاره متانولی با معرف فولین سیوکالتیو و کربنات سدیم ترکیب و پس از ۳۰ دقیقه در ۴۰ درجه سلسیوس، جذب آن در ۷۶۵ نانومتر خوانده شد. مقدار فنل با معادله استاندارد ۱ محاسبه گردید (Chang *et al.*, 2002).

$$y = 0.5x - 0.005 \quad (۱)$$

فلاونوئید کل

برای اندازه‌گیری فلاونوئید میوه، عصاره متانولی با آلومینیوم کلرید، استات پتاسیم و آب مقطر مخلوط شد. پس از ۳۰ دقیقه در تاریکی، جذب محلول در ۴۱۵ نانومتر با اسپکتروفتومتر اندازه‌گیری و غلظت فلاونوئید با استفاده از منحنی استاندارد کوئرستین محاسبه گردید (Chang *et al.*, 2002).

درصد مهار رادیکال‌های آزاد به روش DPPH

در این آزمایش، درصد مهار رادیکال‌های آزاد DPPH با افزودن عصاره متانولی به محلول DPPH و اندازه‌گیری جذب در طول موج ۵۱۷ نانومتر با اسپکتروفتومتر انجام شد. نمونه شاهد شامل DPPH و متانول بود. فعالیت آنتی‌اکسیدانی با استفاده از رابطه مربوطه محاسبه گردید (Li Bondet *et al.*, 1997) (et al., 2012).

$$DPPH = \frac{Ac - As}{Ac} \times 100 \quad (۲)$$

در اینجا؛

Ac جذب نمونه شاهد و As جذب نمونه می باشد.

اندازه‌گیری مواد جامد محلول

در آزمایشگاه، عصاره میوه‌ها استخراج گردید. برای اندازه‌گیری میزان مواد جامد محلول عصاره صاف‌شده میوه، از دستگاه رفکتومتر رقمی مدل (MT-032ATC) ساخت کشور تایوان استفاده شد (Seyedabadi *et al.*, 2017).

اندازه‌گیری اسیدیته قابل تیتراسیون

میزان اسیدیته قابل تیتراسیون از طریق تیتراسیون با سدیم هیدروکسید (۰/۱ نرمال) تعیین شد. برای این کار ۲ میلی‌لیتر آب‌میوه در ۳۸ میلی‌لیتر آب مقطر رقیق شد. سپس ۳ قطره از محلول فنل فتالئین (۱٪ الکلی) به آن اضافه و با سدیم

شد. برای آزمون پویا، بازوی ۲۰۰ گرمی آونگ با وزنه‌های ۱۰۰، ۱۵۰ و ۲۰۰ گرمی از زاویه ۹۰ درجه رها شد. هر دو آزمون در سه دوره انبارداری ۵، ۱۰ و ۱۵ روزه تکرار شدند (Azadbakht *et al.*, 2018; Diels *et al.*, 2017).

ترازوی رقمی

ترازوی رقمی مدل DJ 2000 A با دقت ۰/۰۱ برای اندازه‌گیری تغییرات جرم میوه موز در طی دوره انبارداری مورداستفاده قرار گرفت (Azadbakht *et al.*, 2018).

بسته‌بندی

پس از بارگذاری با استفاده از ۴ دسته شامل بسته بندی با فیلم پلی اتیلن، فیلم پی وی سی، فیلم پلاستیک و بدون فیلم، بسته‌بندی شدند و به مدت ۱۴ روز در دمای محیط قرار داده شد. به ترتیب همین فیلم‌ها به عنوان کلاس ۱ لی ۴ برای طبقه‌بندی انتخاب شدند.

مقدار استحکام بافت

به منظور اندازه‌گیری سفتی یا استحکام گوشت میوه، از دستگاه فشارسنج یا نفوذسنج (مدل EFFEGI، ساخت کشور ایتالیا) استفاده شد. به منظور انجام این آزمایش سعی شد که پوست نمونه‌ها از طریق اعمال فشار شبه-ایستا آسیب ندیده باشد. مطابق دستورالعمل‌های موجود، پروب دستگاه نفوذسنج بر روی قسمت مورد نظر موز قرار گرفته تا بعد از اعمال فشار مورد نیاز، پروب بتواند وارد گوشت میوه شود و سپس مقدار نمایش داده شده در نمایش‌گر نفوذسنج نشان‌دهنده سفتی میوه بود (Azadbakht, Mahmoodi, et al., 2019).

اندازه‌گیری خواص شیمیایی میوه موز

خواص شیمیایی نمونه‌های هر گروه به‌عنوان نمونه شاهد بدون بارگذاری در ابتدا و انتهای آزمایش تعیین شدند، هم‌چنین در پایان دوره انبارداری نمونه‌هایی که تحت بار بودند جهت اندازه‌گیری خواص شیمیایی از جمله میزان فنول، آنتی اکسیدان، اسیدیته، فلاونوئید، pH و مواد جامد محلول در آزمایشگاه گروه باغبانی دانشگاه علوم کشاورزی و منابع طبیعی گرگان اندازه‌گیری شد. نحوه اندازه‌گیری و روش کار استفاده شده و تجهیزات در ادامه توضیح داده شده است.

ورودی‌ها در نظر گرفته شدند، در حالی که بارگذاری‌های پویا و ایستا به‌عنوان خروجی‌ها و چهار نوع پوشش مختلف برای طبقه‌بندی انتخاب شدند. داده‌ها بر اساس این عامل‌ها طبقه‌بندی می‌شوند. برای هر بارگذاری، ۴۸ داده مربوط به هر یک از عامل‌ها مرتب و به‌عنوان ورودی مورد استفاده قرار گرفتند. ۷۰ درصد از داده‌ها به‌عنوان مجموعه آموزش، ۱۵ درصد برای ارزیابی عملکرد مدل در حین فرآیند آزمون و ۱۵ درصد دیگر برای ارزیابی نهایی نتایج اختصاص داده شد (جدول ۲). برای کاهش میزان خطا و افزایش پایداری شبکه، ۳ و ۵ تکرار به‌عنوان میانگین تعداد ۱۰۰۰ و ۲۰۰۰ دوره یادگیری برای شبکه در نظر گرفته شد.

برآورد خطا با استفاده از الگوریتم پس‌انتشار خطا انجام گرفت. برای ارزیابی عملکرد شبکه، دو معیار ضریب تبیین (R2) و ریشه میانگین مربعات خطا استفاده شد. ضریب تبیین، میزان همبستگی بین داده‌های خروجی شبکه عصبی و داده‌های واقعی را مشخص کرده و از طریق رابطه (۶) محاسبه می‌شود که مقدار ایده‌آل آن برابر با ۱ است. میانگین مربعات خطا اختلاف بین داده‌های پیش‌بینی‌شده 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 ایده‌آل آن برابر صفر است

هیدروکسید ۰/۱ نرمال تا ظهور رنگ صورتی کم‌رنگ و رسیدن pH محلول به ۸/۱ تیت‌ر شد و میزان اسیدیته برحسب درصد اسیدسیتریک بیان گردید (سلجوک و ارکان، ۲۰۱۴) و در آخر، نسبت مواد جامد محلول به اسیدیته قابل تیتراسیون (TA/TSS) به‌عنوان شاخص طعم محاسبه شد.

مقدار pH

مقدار pH نمونه‌ها با استفاده از تیت‌کردن آب‌میوه با سود ۰/۱ نرمال در pH=8.1 و دستگاه pH متر مدل AD100 اندازه‌گیری شد. (Valentines *et al.*, 2005; Martín-Diana *et al.*, 2009).

تعریف مدل شبکه عصبی

در این تحقیق از شبکه عصبی^۱ (MLP) برای طبقه‌بندی نوع بارگذاری پویا و ایستا استفاده شد. این شبکه‌ها دارای ۳ و ۵ سلول عصبی^۲ در لایه‌های پنهان (ورودی و خروجی) بوده و و تحلیل‌های انجام شده در نرم افزار NeroSloution6 صورت گرفت. در لایه‌های ورودی و خروجی شبکه عصبی مصنوعی از توابع فعال‌سازی^۳ tanh^۴ استفاده شد. همچنین از الگوریتم لونبرگ-مارکوات^۵ به‌عنوان تابع آموزش‌دهنده شبکه استفاده شد. در این مطالعه، عامل‌های مختلفی از جمله محتوای فنول کل، آنتی‌اکسیدان، اسیدیته، محتوای رطوبت و سفتی به‌عنوان

1

جدول ۱- روابط شبکه عصبی مصنوعی

شماره رابطه	رابطه	منبع
(۴)	$\text{Tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	(Soleimanzadeh <i>et al.</i> , 2015)
(۵)	$\text{Sig} = \frac{1}{1 + e^{-x}}$	(Salehi <i>et al.</i> , 2017)
(۶)	$R^2 = 1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}$	(Azadbakht <i>et al.</i> , 2016)
(۷)	$r = \sqrt{1 - \frac{\sum_{i=1}^n (P_i - O_i)^2}{(P_i - O)^2}}$	(Salehi & Razavi, 2012)
(۸)	$\text{MSE} = \sum_{i=1}^n \frac{(P_i - O_i)^2}{n}$	
(۹)	$\text{RMSE} = \sqrt{\sum_{i=1}^n \frac{(P_i - O_i)^2}{n}}$	(Khoshnevisan <i>et al.</i> , 2013)
(۱۰)	$\text{MAE} = \frac{\sum_{i=1}^n P_i - O_i }{n}$	(Khoshnevisan <i>et al.</i> 2013)

4 Hyperbolic tangent
5 Levenberg-Marquardt

1 multilayer perceptron
2 Neuron
3 Activation functions

جدول ۲- مقادیر بهینه سازی عامل‌های شبکه عصبی مصنوعی

اعتبار سنجی ٪	داده‌های آموزش ٪	داده‌های آزمون ٪	تعداد عصبی در لایه مخفی	سلول تابع فعال سازی	تابع آموزش	تعداد مخفی	لایه شبکه	شبکه
۱۵٪	۷۰٪	۱۵٪	۵-۳	tanh	لونیگ	۱	چندلایه	پرسپترون

نتایج و بحث

در مرحله آزمون این مدل، مقدار MSE در طبقه ۱ کاهش یافت (۰/۱۸۶) و مقدار ۲ به ۰/۵۸۶ رسید که نشان‌دهنده بهبود عملکرد مدل بود. در نهایت، در دوره ۲۰۰۰ با ۵ اجرا، عملکرد مدل بهبود چشم‌گیری یافت، به‌طوری‌که MSE کاهش یافت در طبقه ۳ برابر ۰/۱۶۹ و مقدار ۲ در طبقه ۱ به ۰/۷۴۵ رسید که نشان‌دهنده همبستگی قوی‌تر بین داده‌های پیش‌بینی شده و واقعی بود. درصد صحت در طبقه ۱ و طبقه ۲ به ترتیب ۹۰٪ و ۱۰۰٪ بود و در مرحله آزمون، طبقه ۴ کم‌ترین میزان خطا را داشت. نتایج کلی نشان داد که افزایش تعداد دوره‌های یادگیری موجب کاهش خطا و بهبود عملکرد مدل شد، به‌ویژه در طبقه ۲ که بالاترین درصد صحت را ثبت کرد. در مقابل، برخی طبقه‌ها مانند طبقه ۳ و طبقه ۴ همچنان دارای خطای بالا بودند، که نشان‌دهنده نیاز به بهینه‌سازی بیش‌تر است. همچنین، مقدار ۲ در برخی طبقه‌ها منفی یا نزدیک به صفر بود که بیان‌گر ناهماهنگی بین پیش‌بینی مدل و داده‌های واقعی است. افزایش تعداد اجراهای مدل تأثیر محسوسی بر بهبود دقت در برخی طبقه‌ها داشت. برای بهینه‌سازی بیش‌تر، پیشنهاد می‌شود از روش‌هایی مانند تنظیم وزن‌ها، انتخاب معماری بهینه شبکه عصبی و الگوریتم‌های بهینه‌سازی مانند Adam یا RMSprop استفاده شود.

مدل‌های مختلف با تعداد ۱۰۰۰ و ۲۰۰۰ دوره یادگیری^۶ و اجرای ۳ و ۵ بار برای تحلیل عملکرد مورد استفاده قرار گرفتند. در دوره ۱۰۰۰ با ۳ اجرا، MSE در طبقه‌های مختلف نوسان داشت و در طبقه ۱ کم‌ترین مقدار (۰/۱۱۹) و در طبقه ۲ بیش‌ترین مقدار (۰/۲۹۵) مشاهده شد، درحالی‌که مقدار ۲ در طبقه ۲ منفی (۰/۱۸۲-) بود که ضعف مدل را نشان می‌داد و درصد صحت طبقه‌بندی در طبقه ۱، طبقه ۲ و طبقه ۴ به ترتیب ۵۰٪، صفر و ۸۸/۸۸٪ گزارش شد. در مرحله آزمون، MSE افزایش یافت و ضریب همبستگی در برخی طبقه‌ها نشان‌دهنده عملکرد ضعیف بود، به‌طوری‌که ۲ در طبقه ۱ برابر ۰/۱۳۶- و در طبقه ۲ مقدار ۰/۹۸۲ به‌دست آمد. در دوره ۱۰۰۰ با ۵ اجرا، خطای MSE در طبقه ۳ بالاتر از سایر طبقه‌ها (۰/۳۶۰) بود و ۲ در طبقه ۲ بهبود نسبی یافت (۰/۱۵-)، اما همچنان در برخی طبقه‌ها دقت پایین مشاهده شد. درصد صحت در طبقه ۳ برابر ۱۰۰٪ بود، درحالی‌که در طبقه ۲ مقدار صفر درصد گزارش شد. در دوره ۲۰۰۰ با ۳ اجرا، مقدار MSE کاهش یافت که نشان‌دهنده بهبود مدل بود، به‌ویژه در طبقه ۲ که صحت طبقه‌بندی به ۱۰۰٪ رسید.

جدول ۳- میزان خطا در پیش‌بینی داده‌های تجربی با استفاده از شبکه عصبی مصنوعی

معیار	طبقه ۱	طبقه ۲	طبقه ۳	طبقه ۴
خطای میانگین مربعات (MSE)	۰/۱۱۹	۰/۲۹۵	۰/۲۶۲	۰/۱۴۴
خطای نرمال‌شده مربعات (NMSE)	۰/۸۱۸	۱/۵۱۶	۱/۲۶۳	۰/۷۴۱
خطای میانگین مطلق (MAE)	۰/۲۱۳	۰/۳۱۳	۰/۳۱۰	۰/۲۶۲

۰/۰۰۳	۰/۰۱۴	۰/۰۰۲	۰/۰۰۰	حداقل خطای مطلق	
۱/۰۱۹	۱/۰۵۵	۱/۰۵۵	۱/۰۴۸	حداکثر خطای مطلق	
۰/۵۳۳	۰/۲۷۹	۰/۱۸۲	۰/۴۴۲	ضریب همبستگی (r)	
۸۸/۸۸۸	۲۰	۰	۵۰		
آزمایش					
۰/۲۳۲	۰/۱۵۳	۰/۱۴۱	۰/۳۳۲	خطای میانگین مربعات (MSE)	
۱/۱۳۶	۱/۲۵۲	۱/۱۵۶	۱/۳۵۶	خطای نرمال‌شده مربعات میانگین (NMSE)	
۰/۳۳۳	۰/۱۷۸	۰/۱۸۴	۰/۴۹۰	خطای میانگین مطلق (MAE)	
۰/۰۴۰	۰/۰۰۶	۰/۰۴۳	۰/۰۴۲	حداقل خطای مطلق	
۰/۹۱۱	۱/۰۳۱	۰/۹۸۷	۱/۰۵۳	حداکثر خطای مطلق	
۰/۳۰۵	۰/۰۳۹	۰/۹۸۲	۰/۱۳۶-	ضریب همبستگی (r)	
۵۰	۰	۰	۶۶/۶۶	درصد درستی	
آموزش					
۰/۲۰۰	۰/۳۶۰	۰/۲۲۳	۰/۱۹۷	خطای میانگین مربعات (MSE)	
۰/۹۶۴	۲/۴۸۲	۱/۱۴۹	۱/۰۱۳	خطای نرمال‌شده مربعات میانگین (NMSE)	
۰/۳۲۸	۰/۵۶۴	۰/۳۳۴	۰/۳۴۲	خطای میانگین مطلق (MAE)	
۰/۰۰۲	۰/۱۳۲	۰/۰۲۱	۰/۰۰۰	حداقل خطای مطلق	
۰/۸۸۹	۰/۹۳۹	۱/۰۰۴	۰/۹۵۳	حداکثر خطای مطلق	
۰/۳۳۵	۰/۰۷۰	۰/۰۱۵-	۰/۲۷۱	ضریب همبستگی (r)	۱۰۰۰ تکرار
۰	۱۰۰	۰	۳۳/۳۳	درصد درستی	۵ اجرا
آزمایش					شبکه MLP
۰/۱۰۵	۰/۴۱۹	۰/۳۵۹	۰/۲۶۹	خطای میانگین مربعات (MSE)	
۰/۸۶۰	۲/۰۵۵	۱/۴۶۶	۲/۲۰۲	خطای نرمال‌شده مربعات میانگین (NMSE)	
۰/۲۱۹	۰/۶۳۶	۰/۴۹۷	۰/۴۳۱	خطای میانگین مطلق (MAE)	
۰/۰۰۰	۰/۴۵۵	۰/۱۰۹	۰/۰۳۸	حداقل خطای مطلق	
۰/۷۶۳	۰/۷۸۷	۰/۹۲۹	۰/۸۲۴	حداکثر خطای مطلق	
۰/۳۹۰	۰/۷۸۱-	۰/۵۲۹-	۰/۰۸۷	ضریب همبستگی (r)	
آموزش					
۰/۱۹۶	۰/۱۸۲	۰/۲۱۵	۰/۱۶۵	خطای میانگین مربعات (MSE)	۲۰۰۰ تکرار
۱/۰۹۳	۰/۹۳۶	۱/۰۳۵	۱/۰۱۲	خطای نرمال‌شده مربعات میانگین (NMSE)	۳ اجرا
					شبکه MLP

خطای میانگین مطلق	۰/۳۴۷	۰/۴۵۳	۰/۳۶۱	۰/۳۱۴
(MAE)				
حداقل خطای مطلق	۰/۲۱۰	۰/۱۹۴	۰/۱۹۰	۰/۰۸۶
حداکثر خطای مطلق	۰/۷۸۹	۰/۶۴۴	۰/۷۸۸	۰/۸۹۲
ضریب همبستگی (r)	۰/۴۹۰-	۰/۱۶۹	۰/۳۷۲	۰/۲۳۳-
درصد درستی	۰	۱۰۰	۲۲/۲۲	۰
آزمایش				
خطای میانگین مربعات	۰/۱۸۶	۰/۱۴۹	۰/۱۹۸	۰/۳۳۹
(MSE)				
خطای نرمال شده میانگین مربعات (NMSE)	۰/۹۱۲	۰	۰/۹۷۴	۱/۳۸۶
خطای میانگین مطلق	۰/۳۷۲	۰/۳۸۳	۰/۳۸۳	۰/۴۶۵
(MAE)				
حداقل خطای مطلق	۰/۲۱۹	۰/۳۲۰	۰/۲۰۰	۰/۱۳۲
حداکثر خطای مطلق	۰/۷۶۵	۰/۴۵۳	۰/۷۷۶	۰/۸۹۸
ضریب همبستگی (r)	۰/۵۸۶	۰	۰/۲۹۴	۰/۶۴۴-
آموزش				
خطای میانگین مربعات	۰/۱۶۰	۰/۲۶۱	۰/۱۶۹	۰/۲۰۶
(MSE)				
خطای نرمال شده میانگین مربعات (NMSE)	۰/۷۷۱	۱/۵۶۹	۱/۱۶۶	۰/۹۴۱
خطای میانگین مطلق	۰/۳۸۱	۰/۴۸۴	۰/۲۵۱	۰/۲۹۹
(MAE)				
حداقل خطای مطلق	۰/۱۰۲	۰/۲۱۱	۰/۰۳۸	۰/۰۰۰
حداکثر خطای مطلق	۰/۶۱۸	۰/۸۰۰	۰/۹۵۳	۰/۹۱۳
ضریب همبستگی (r)	۰/۷۴۵	۰/۴۷۹	۰/۱۴۴-	۰/۶۵۵
درصد درستی	۹۰	۱۰۰	۰	۹/۰۹
آزمایش				
خطای میانگین مربعات	۰/۲۱۹	۰/۲۴۶	۰/۵۹۰	۰/۰۳۵
(MSE)				
خطای نرمال شده میانگین مربعات (NMSE)	۰	۱/۲۰۶	۲/۸۹۱	۰
خطای میانگین مطلق	۰/۴۳۷	۰/۴۶۵	۰/۶۵۷	۰/۱۵۶
(MAE)				
حداقل خطای مطلق	۰/۳۳۴	۰/۱۸۷	۰/۰۳۵	۰/۰۳۵
حداکثر خطای مطلق	۰/۸۴۳	۰/۸۰۴	۰/۹۵۷	۰/۹۲۷
ضریب همبستگی (r)	۰	۰/۴۵۴	۰/۳۲۰	۰

۲۰۰۰ تکرار
۵ اجرا
شبکه MLP

دقت مدل دارد. در مدل با ۱۰۰۰ دوره و ۳ اجرا، تعداد اشتباهات در برخی طبقه‌ها بالا بوده و مخصوصاً در طبقه ۴، تعداد ۸ مورد خطای پیش‌بینی مشاهده شد که نشان‌دهنده

نتایج به‌دست‌آمده از شبکه‌های عصبی مصنوعی در طبقه‌بندی داده‌های ورودی نشان می‌دهد که افزایش تعداد دوره‌های یادگیری و تعداد اجراهای مدل تأثیر قابل‌توجهی در بهبود

در نهایت، در مدل با ۲۰۰۰ دوره و ۵ اجرا، طبقه ۱ بالاترین دقت را نشان داده و خطاهای پیش‌بینی در طبقه ۳ و طبقه ۴ تقریباً به صفر رسیده است. این امر نشان می‌دهد که افزایش تعداد دوره‌های یادگیری و اجرای بیش‌تر مدل باعث بهبود عملکرد شبکه در برخی طبقه‌ها شده، اما هم‌چنان برخی طبقه‌ها مانند طبقه ۲ چالش‌هایی در پیش‌بینی صحیح دارند. لذا، برای بهبود دقت مدل پیشنهاد می‌شود از روش‌های بهینه‌سازی مانند تنظیم وزن‌ها و استفاده از الگوریتم‌های پیشرفته‌تری نظیر Adam یا RMSprop بهره گرفته شود.

ضعف مدل در این طبقه است. هم‌چنین در طبقه ۲ هیچ نمونه‌ای به‌درستی پیش‌بینی نشده است. با افزایش تعداد اجراها به ۵ بار، هم‌چنان طبقه ۲ بدون پیش‌بینی صحیح باقی مانده و طبقه ۳ دچار افزایش خطا شده است، که نشان‌دهنده نیاز به بهینه‌سازی بیش‌تر مدل است. در مدل با ۲۰۰۰ دوره و ۳ اجرا، میزان دقت در طبقه ۱ کاهش یافته و پیش‌بینی‌های نادرست در طبقه ۲ افزایش یافته است، اما طبقه ۳ و طبقه ۴ عملکرد بهتری نشان داده‌اند.

جدول ۴- مقادیر صحیح و خطای پیش‌بینی شده برای داده‌های ورودی هر شبکه در طبقه‌بندی‌های مختلف

خروجی / مقدار واقعی	طبقه ۱	طبقه ۲	طبقه ۳	طبقه ۴
۱۰۰۰ تکرار	۳	۳	۴	۱
۳ اجرا	۰	۰	۰	۰
شبکه MLP	۱	۱	۲	۰
طبقه ۴	۲	۵	۴	۸
۱۰۰۰ تکرار	۳	۲	۰	۱
۵ اجرا	۰	۰	۰	۰
شبکه MLP	۶	۷	۶	۹
طبقه ۴	۰	۰	۰	۰
۲۰۰۰ تکرار	۱	۰	۰	۰
۳ اجرا	۶	۱۰	۷	۸
شبکه MLP	۱	۰	۲	۰
طبقه ۴	۰	۰	۰	۰
۲۰۰۰ تکرار	۹	۰	۰	۰
۵ اجرا	۱	۷	۶	۱۰
شبکه MLP	۰	۰	۰	۰
طبقه ۴	۰	۰	۰	۱

موارد به مقدار ۰/۰۰۱۹ رسیده است. هم‌چنین در اجراهایی که تعداد تکرارهای مدل بیش‌تر بوده، مقدار نهایی MSE نیز کاهش محسوسی داشته و در اعتبارسنجی متقاطع مقدار ۰/۱۱۸ مشاهده شده است، که نشان‌دهنده پایداری و تعمیم‌پذیری بهتر شبکه است. به‌طور کلی، نتایج جدول نشان می‌دهد که افزایش تعداد دوره‌های یادگیری و تعداد اجرای مدل می‌تواند دقت پیش‌بینی را افزایش داده و باعث کاهش خطای میانگین مربعات شود. با این حال، برای جلوگیری از بیش‌برازش و بهبود کارایی مدل، استفاده از روش‌هایی مانند تنظیم وزن‌ها، کاهش نرخ یادگیری و افزایش داده‌های آموزشی پیشنهاد می‌شود.

نتایج به‌دست‌آمده از اجرای شبکه‌های عصبی در پیش‌بینی داده‌های آزمایش نشان می‌دهد که افزایش تعداد دوره‌های یادگیری و تعداد اجرای مدل تأثیر مستقیمی بر کاهش مقدار خطای میانگین مربعات (MSE) دارد. در شبکه‌هایی که با ۱۰۰۰ دوره یادگیری اجرا شده‌اند، مقدار حداقل MSE برای داده‌های آموزش در حدود ۰/۱۳۱۷ و ۰/۱۳۳۷ بوده است، اما مقدار نهایی MSE در اعتبارسنجی متقاطع افزایش یافته و به بیش از ۰/۳۸ رسیده است. این افزایش خطا نشان‌دهنده احتمال وقوع بیش‌برازش در مدل‌های با تعداد اجرای کم است. در مقابل، با افزایش تعداد دوره‌های یادگیری به ۲۰۰۰، مقدار حداقل MSE به میزان قابل‌توجهی کاهش یافته و در برخی

جدول ۵- برخی از بهترین شبکه‌های تشکیل‌شده برای پیش‌بینی داده‌های تست

بهرترین شبکه‌ها	آموزش	اعتبارسنجی متقاطع
۱۰۰۰ تکرار	۱	۲
۳ اجرا	۱۰۰۰	۷
شبکه MLP	۰/۱۳۱	۰/۲۸۸
	۰/۱۳۱	۰/۵۱۶
۱۰۰۰ تکرار	۳	۲
۵ اجرا	۱۰۰۰	۱۵
شبکه MLP	۰/۱۳۳	۰/۲۸۹
	۰/۱۳۳	۰/۳۸۵
۲۰۰۰ تکرار	۲	۳
۳ اجرا	۵	۷۸
شبکه MLP	۰/۰۵۳	۰/۰۲۴
	۰/۰۶۸	۰/۰۲۴
۲۰۰۰ تکرار	۵	۵
۵ اجرا	۲۲۹	۴
شبکه MLP	۰/۰۰۰	۰/۰۷۱
	۰/۰۰۰	۰/۱۱۸

نتیجه‌گیری

نتایج حاصل از اجرای شبکه‌های عصبی نشان می‌دهد که دقت مدل به شدت تحت تأثیر تعداد دوره‌های یادگیری و تعداد دفعات اجرای مدل قرار دارد. افزایش تعداد دوره‌ها و اجرای بیش‌تر مدل، در اکثر موارد موجب کاهش مقدار خطای میانگین مربعات (MSE) شده و عملکرد بهتری را در پیش‌بینی داده‌های آزمایش ارائه داده است. در اجراهایی که تعداد دوره‌های یادگیری ۱۰۰۰ بوده است، خطای نهایی در اعتبارسنجی متقاطع مقدار بالاتری داشته و نشان‌دهنده احتمال بیش‌برازش در مدل‌های با پیچیدگی پایین است. از سوی دیگر، اجرای مدل با ۲۰۰۰ دوره یادگیری باعث کاهش چشم‌گیر خطای آموزشی و هم‌چنین بهبود عملکرد مدل در داده‌های آزمایشی شده است. در برخی موارد، مقادیر بسیار پایین MSE نشان می‌دهد که مدل به‌طور دقیق داده‌های آموزشی را یاد گرفته است، اما برای اطمینان از تعمیم‌پذیری مناسب، نیاز به اعتبارسنجی و بررسی عملکرد مدل روی داده‌های جدید وجود دارد. استفاده از روش‌هایی مانند تنظیم وزن‌ها، کاهش نرخ یادگیری، و افزایش تعداد داده‌های آموزشی می‌تواند به بهبود عملکرد مدل کمک کند و از بیش‌برازش جلوگیری نماید. به‌طور کلی، انتخاب بهینه تعداد دوره‌های یادگیری و تعداد اجرای مدل، تأثیر مستقیمی بر دقت پیش‌بینی و پایداری شبکه عصبی دارد و برای دستیابی به

بهترین نتیجه، لازم است بین دقت و جلوگیری از بیش‌برازش تعادل برقرار شود.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به صورت زیر است:

- راضیه پوردربانی: مفهوم سازی و نظارت
- سجاد جعفرزاده: نوشتار مقاله
- فرید مرادی: مواد و روش

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است.

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر علمی رعایت نموده‌اند و این موضوع مورد تایید همه آنها است.

تضاد منافع نویسندگان

نویسندگان اعلام می‌کنند که هیچ گونه منافع مالی رقابتی یا روابط شخصی شناخته‌شده‌ای که ممکن است بر کار گزارش شده در این مقاله تأثیر گذاشته باشد، ندارند.

حمایت مالی

نویسنده(ها) هیچ حمایت مالی خاصی برای انجام این پژوهش دریافت نکرده‌اند.

- Fadiji, T., Rashvand, M., Daramola, M. O., & Iwarere, S. A. (2023). A Review on Antimicrobial Packaging for Extending the Shelf Life of Food. *Processes*, 11(2), 590. <https://doi.org/10.3390/pr11020590>
- 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. <https://doi.org/10.1007/s11947-009-0222-y>
- Fu, L., Sun, S., Li, R., & Wang, S. (2016). Classification of Kiwifruit Grades Based on Fruit Shape Using a Single Camera. *Sensors*, 16(7), 1012. <https://doi.org/10.3390/s16071012>
- Ganiron, T. U. (2014). Size properties of mangoes using image analysis. *International Journal of Bio-Science and Bio-Technology*, 6(2), 31–42. <https://doi.org/10.14257/ijbsbt.2014.6.2.03>
- 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. <https://doi.org/10.1016/j.jfca.2016.04.004>
- Li, W. L., Li, 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 Science and Technology International*, 18(3), 197–205.
- 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. <https://doi.org/10.1080/10942910601172042>
- Martín-Diana, A. B., Rico, D., Barat, J. M., & Barry-Ryan, C. (2009). Orange juices enriched with chitosan: Optimisation for extending the shelf-life. *Innovative Food Science & Emerging Technologies*, 10(4), 590–600.
- Massah, J., Hajihedari, F., & Derafshi, M. H. (2017). Application of Electrical Resistance in Nondestructive Postharvest Quality Evaluation of Apple Fruit. *Journal of Agricultural Science and Technology*, 19, 1031–1039.
- Mohammad Vahedi Torshizi, A. A., Tabarsa, F., Danesh, P., Ali, & Akbarzadeh. (2020). CLASSIFICATION BY ARTIFICIAL NEURAL NETWORK FOR MUSHROOM COLOR CHANGING UNDER EFFECT UV-A IRRADIATION. *Carpathian Journal of Food Science and Technology*, 152–162. <https://doi.org/10.34302/crpjfst/2020.12.2.16>
- Mohsenin, N. (1968). Physical properties of plant and animal materials. *Journal of Agricultural Engineering Research*, 13(4), 379. [https://doi.org/10.1016/0021-8634\(68\)90151-0](https://doi.org/10.1016/0021-8634(68)90151-0)
- Akandi, S. R., Qhodsi, S. S., Minaei, S., Najafi, G., & Hashjin, T. T. (2018). Mechanical Properties of (Aloe vera L.) Leaf for Designing Gel Extraction Machines. *J. Agr. Sci. Tech*, 19(4), 809–820.
- Azadbakht, M., Mahmoodi, M. J., & Vahedi Torshizi, M. (2019). Effects of Different Loading Forces and Storage Periods on the Percentage of Bruising and Its Relation with the Qualitative Properties of Pear Fruit. *International Journal of Horticultural Science and Technology*, 6(2), 177–188.
- Azadbakht, M., Torshizi, M. V., & Ziaratban, A. (2016). Application of Artificial Neural Network (ANN) in predicting mechanical properties of canola stem under shear loading. *Agricultural Engineering International: CIGR Journal*, 18(5), 413–424.
- Azadbakht, M., Vahedi Torshizi, M., & Asghari, A. (2019). Biological properties classification of pear fruit in dynamic and static loading using artificial neural network. *Innovative Food Technologies*, 6(4), 507–520.
- Azadbakht, M., Vahedi Torshizi, M., & Mahmoodi, M. J. (2018). Determination of pear bruises due to a thin edge compression load by CT scan method. *Innovative Food Technologies (JIFT)*. <https://doi.org/10.22104/jift.2018.2842.1684>
- Azadbakht, M., Vahedi Torshizi, M., Aghili, H., & Ziaratban, A. (2018). Application of artificial neural network (ann) in drying kinetics analysis for potato cubes. *CARPATHIAN JOURNAL OF FOOD SCIENCE AND TECHNOLOGY*, 10(2), 96–106. <https://www.cabdirect.org/cabdirect/abstract/19981100164>
- B. Khoshnevisan, Sh. Rafiee, M. Omid, M. Y. (2013). Prediction of environmental indices of Iran wheat production using artificial neural networks. *International Journal of Energy and Environment*, 4(2), 339–348.
- Balogun, W. A., Salami, M. E., Aibinu, A. M., Mustafah, Y. M., & S, S. I. B. (2014). Mini Review: Artificial Neural Network Application on Fruit and Vegetables Quality Assessment. *International Journal of Scientific & Engineering Research*, 5(6), 702–708.
- Bondet, V., Brand-Williams, W., & Berset, C. (1997). Kinetics and mechanisms of antioxidant activity using the DPPH. free radical method. *LWT-Food Science and Technology*, 30(6), 609–615.
- Diels, E., van Dael, M., Keresztes, J., Vanmaercke, S., Verboven, P., Nicolai, B., Saeys, W., Ramon, H., & Smeets, B. (2017). Assessment of bruise volumes in apples using X-ray computed tomography. *Postharvest Biology and Technology*, 128, 24–32. <https://doi.org/10.1016/j.postharvbio.2017.01.013>

منابع

- Classification of Bitter Orange Essential Oils According to Fruit Ripening Stage by Untargeted Chemical Profiling and Machine Learning. *Sensors*, 18(6), 1922. <https://doi.org/10.3390/s18061922>
- Tavar, M., Rabbani, H., Gholami, R., Ahmadi, E., & Kurtulmus, F. (2024). Investigating the Effect of Packaging Conditions on the Properties of Peeled Garlic by Using Artificial Neural Network (ANN). *Packaging Technology and Science*, 37(8), 755–767. <https://doi.org/10.1002/pts.2819>
- Valentines, M. C., Vilaplana, R., Torres, R., Usall, J., & Larrigaudiere, C. (2005). Specific roles of enzymatic browning and lignification in apple disease resistance. *Postharvest Biology and Technology*, 36(3), 227–234.
- Wypij, M., Trzcińska-Wencel, J., Golińska, P., Avila-Quezada, G. D., Ingle, A. P., & Rai, M. (2023). The strategic applications of natural polymer nanocomposites in food packaging and agriculture: Chances, challenges, and consumers' perception. *Frontiers in Chemistry*, 10. <https://doi.org/10.3389/fchem.2022.1106230>
- X, L., & W, W. (1998). Study on compressive properties of apple. *Journal of Northwestern Agricultural University*, 26(2), 107–108.
- Yadav, N., & Kaur, R. (2024). Innovations in Packaging to Monitor and Maintain the Quality of the Food Products. *Journal of Packaging Technology and Research*, 8(1), 15–50. <https://doi.org/10.1007/s41783-024-00163-4>
- N. Galili, I. Shmulevich, & N. Benichou. (1998). Acoustic Testing of Avocado for Fruit Ripness Evaluation. *Transactions of the ASAE*, 41(2), 399–407. <https://doi.org/10.13031/2013.17164>
- 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. <https://doi.org/10.1016/j.foodres.2015.05.007>
- Salehi, F. 1, Gohari Ardabili, A., Nemati, A. 2, & Latifi Darab, R. (2017). Modeling of strawberry drying process using infrared dryer by genetic algorithm–artificial neural network method. *Journal Food Science and Technology*, 14, 105–114.
- 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. *Desalination and Water Treatment*, 41(1–3), 95–104. <https://doi.org/10.1080/19443994.2012.664683>
- Sawicka, B. (2020). Post-Harvest Losses of Agricultural Produce (pp. 654–669). https://doi.org/10.1007/978-3-319-95675-6_40
- Seyedabadi, M. M., Aghajanzadeh, S. S., Kashaninejad, M., & Ziaiiifar, A. M. (2017). INVESTIGATION OF THE EFFECT OF MICROWAVE ON SOME PHYSICOCHEMICAL PROPERTIES OF SOUR ORANGE JUICE.
- Soleimanzadeh, B., Hemati, L., Yolmeh, M., & Salehi, F. (2015). GA-ANN and ANFIS models and salmonella enteritidis inactivation by ultrasound. *Journal of Food Safety*, 35(2), 220–226. <https://doi.org/10.1111/jfs.12174>
- Taghadomi-Saberi, S., Mas Garcia, S., Allah Masoumi, A., Sadeghi, M., & Marco, S. (2018).