

مقاله علمی-پژوهشی

به کارگیری سیستم استنتاج عصبی-فازی سازگار و شبکه‌های عصبی مصنوعی در پیش‌بینی و مدل‌سازی تغییرات کیفی زالک (*Crataegus pinnatifida*) طی شرایط مختلف انبارمانی

محسن زندی^{۱*}، علی گنجلو^۲، ماندانا بی‌مکر^۲

تاریخ دریافت: ۱۳۹۹/۰۲/۱۱

تاریخ پذیرش: ۱۳۹۹/۰۳/۲۴

چکیده

در دهه‌های اخیر، از سیستم‌های هوش مصنوعی برای ایجاد مدل‌های پیش‌بینی جهت تخمین و پیش‌بینی بسیاری از فرآیندهای کشاورزی استفاده شده است. در این مطالعه، خصوصیات فیزیکی و شیمیایی میوه زالک طی نگهداری در شرایط مختلف با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی-فازی سازگار پیش‌بینی گردید. از داده‌های تجربی حاصل از نگهداری میوه، برای آموزش و آزمایش این شبکه‌ها استفاده شد. تعداد کل لایه‌های پنهان و تعداد نورون در هر لایه پنهان به روش سعی و خطا انتخاب گردید. شبکه عصبی و سیستم استنتاج عصبی-فازی سازگار طراحی شده دارای ورودی شامل زمان نگهداری، رطوبت اولیه و دمای نگهداری و یک متغیر در لایه‌های خروجی (RPI و h^* ، c^* ، ΔE ، F ، WL) بود. مقادیر R^2 بالا و $RMSE$ کم گویای کارایی بالای مدل شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی سازگار در پیش‌بینی خصوصیات کیفی زالک طی فرآیند نگهداری می‌باشد. نتایج نشان داد که شبکه عصبی پرسپترون چندلایه با الگوریتم یادگیری مونتوم و تابع آستانه‌ای تان‌اکسون بهترین شبکه برای پیش‌بینی خصوصیات کیفی زالک در شرایط مختلف بود. نتایج مدل‌سازی با انفیسی نشان داد که توابع عضویت دوزنقه‌ای و گوسی بهترین عملکرد را به ترتیب در پیش‌بینی پارامترهای رنگی و فیزیکی داشت. با مقایسه نتایج حاصل از مدل‌سازی با شبکه عصبی مصنوعی و انفیسی، تفاوت زیادی از نظر دقت و کارایی در پیش‌بینی مشاهده نشد، اگرچه شاخص $RMSE$ در مدل‌سازی با کمک انفیسی کمتر از شبکه عصبی مصنوعی بود که خود نمایانگر دقت بالاتر آن می‌باشد.

واژه‌های کلیدی: زالک، سیستم استنتاج عصبی-فازی سازگار، شبکه پرسپترون چند لایه‌ای، شبکه عصبی مصنوعی

مقدمه

زالک‌های رسیده وجود دارد که رنگ میوه کامل رسیده آن ممکن است زرد، سبز، قرمز، قرمز تیره و بنفش تیره باشد (Mraih et al., 2015). زالک از نظر دارویی و غذایی ارزش بالایی دارد و مطالعات زیادی به خصوص به‌عنوان داروی گیاهی در درمان نارسایی قلبی (Derili gharjalar et al., 2017)، فشار خون بالا و سخت شدن رگ‌ها (AralVildan Bese, 2016; Farzan et al., 2017) انجام شده است. این میوه غنی از آسکوربیک اسید، آنتوسیانین و فلاونوئیدها می‌باشد (Liu et al., 2011b). امروزه از میوه زالک به‌طور گسترده‌ای به‌عنوان ماده اولیه بسیاری از غذاهای فراسودمند و غذا-داروها استفاده می‌گردد (Liu et al., 2010). شاخصه‌هایی مانند عطر و طعم عالی، رنگ جذاب و محتوی بالای مواد مغذی و ریز مغذی سبب شده است تا این میوه هم به‌صورت خام مصرف گردد و هم به‌عنوان جزء اصلی در انواع مختلف محصولات غذایی فراوری به‌کار برده شود (Li et al., 2015).

امروزه کیفیت به‌عنوان فاکتور اصلی مصرف‌کننده در خرید میوه‌ها و سبزی‌ها محسوب می‌شود و تقاضا برای محصولات با کیفیت بالا افزایش یافته است (Nordey et al., 2014). نتایج حاصل از پژوهش‌های پیشین نشان داده است که خصوصیات فیزیکی،

میوه‌ها و سبزی‌ها منابع بالقوه از ترکیبات شیمیایی گیاهی به‌ویژه ترکیبات فنولی هستند که در حقیقت ترکیبات زیست‌فعال و ضد اکساینده‌های طبیعی می‌باشند (Wen et al., 2015). زالک (*Crataegus pinnatifida*)، نام مشترکی برای گیاهانی در جنس کراتاژتوس^۳ و خانواده گل‌سرخیان است که بیش‌تر در نیم‌کره شمالی و عمدتاً در مناطقی در چین، ایران، اروپا و آمریکای شمالی پراکنده می‌باشند (Amiri Chayjan et al., 2015; Luo et al., 2009). در بین گونه‌های مختلف زالک، گونه کراتاژتوس پیناتیفیدا^۴ به سبب میوه‌های خوشمزه‌تر و درشت‌تر از نظر تجاری بسیار با اهمیت می‌باشد؛ که رایج‌ترین و فراوان‌ترین گونه در ایران نیز می‌باشد (Li et al., 2013; Kami et al., 2009). انواع مختلفی از

۱- دکتری تخصصی، استادیار، گروه علوم و مهندسی صنایع غذایی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

۲- دکتری تخصصی، دانشیار، گروه علوم و مهندسی صنایع غذایی، دانشکده کشاورزی، دانشگاه زنجان، زنجان، ایران

3- *Crataegus*

4- *Crataegus pinnatifida*

Abbaspour-Gilandeh *et al.*, 2020; Karaman *et al.*, 2012). سیستم استنتاج عصبی-فازی سازگار از امکانات شبکه عصبی مصنوعی و منطق فازی به‌طور یک‌جا بهره می‌برد و به‌منظور تقریب زدن ارتباط غیر خطی بین ورودی و خروجی استفاده می‌نماید و قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد (Abbaspour-Gilandeh *et al.*, 2020; Karaman *et al.*, 2012).

از آن‌جایی که مطالعات زیادی در زمینه استفاده از شبکه عصبی مصنوعی و خصوصاً سیستم استنتاج عصبی-فازی سازگار در نگهداری میوه‌ها صورت پذیرفته است، هدف از این پژوهش مدل‌سازی با کمک شبکه عصبی مصنوعی و سیستم استنتاج عصبی-فازی سازگار برای پیش‌بینی تغییرات کیفی میوه زالزالک طی نگهداری در شرایط مختلف است تا بتوان خصوصیات فیزیکی و شیمیایی را با استفاده از سیستم‌های هوشمند پیش‌بینی نمود.

مواد و روش‌ها

تهیه میوه و تیمارها

میوه زالزالک اواسط مهرماه از باغات واقع در استان گیلان چیده شد و جهت تایید وارسته از متخصص باغبانی استفاده گردید. برداشت میوه زمانی که میزان مواد جامد محلول کل^۳ (TSS) حدود ۵ درصد بود، صورت پذیرفت (محدوده قابل قبول برای رسیدگی تجاری (Razavi *et al.*, 2018)). به‌منظور کاهش خطای آزمایش زالزالک‌های آسیب‌دیده، لکه‌دار، آفت‌زده، کال و نرسیده، با اشکال نامنظم و دارای عیوب ظاهری حذف گردید و میوه‌هایی با شکل، اندازه، درجه رسیدگی، رنگ و ظاهر مشابه انتخاب شد. سپس زالزالک‌ها درون سبدهایی پلاستیکی (با ابعاد ۷×۴۰×۶۰ سانتی‌متر) قرار داده شد. سه تیمار مختلف نگهداری شامل شرایط نگهداری استاندارد تجاری (دمای ۱ درجه سانتی‌گراد و رطوبت نسبی ۹۰ درصد (Razavi *et al.*, 2018))، شرایط نگهداری یخچالی (دمای ۱۰-۸ درجه سانتی‌گراد و رطوبت نسبی ۸۵ درصد) و شرایط نگهداری محیط (دمای ۲۵ درجه سانتی‌گراد و رطوبت نسبی ۶۰ درصد) برای بررسی تاثیر شرایط نگهداری بر خصوصیات فیزیکی و شیمیایی زالزالک مورد استفاده قرار گرفت. زالزالک‌ها به مدت ۲۰ روز در شرایط مذکور قرار داده شدند و نمونه‌برداری تصادفی برای انجام آزمایش‌ها هر ۵ روز یک‌بار انجام پذیرفت. کنترل‌های مداوم دما و رطوبت با استفاده از حسگرهای دما و رطوبت به‌منظور یکنواختی شرایط نگهداری انجام پذیرفت.

آزمون‌های فیزیکی و شیمیایی

افت وزن (WL) از تفاضل تغییرات وزن ثانویه و اولیه به وزن اولیه زالزالک و با استفاده از ترازوی دیجیتال با دقت ۰/۰۱ گرم

شیمیایی، بیوشیمیایی و تغذیه‌ای میوه‌ها و سبزی‌ها وابسته به مرحله رسیدگی و زمان نگهداری آن‌ها می‌باشد (Jahanbakhshi *et al.*, 2019b; Jahanbakhshi *et al.*, 2019c; MenzVriesekoop, 2010; Opara *et al.*, 2012; Wang *et al.*, 2012; Zheng *et al.*, 2012) و زالزالک نیز از این قاعده مستثنی نیست (Liu *et al.*, 2011a; 2015). طی نگهداری این میوه در شرایط نگهداری مختلف تغییراتی در خصوصیات فیزیکی و شیمیایی آن رخ می‌دهد که در نتیجه منجر به کاهش کیفیت و تغییر درجه کیفی زالزالک می‌گردد. ارزیابی این تغییرات نیاز به آزمون‌های زیادی نظیر آنالیزهای بافتی، رنگ، شیمیایی و غیره دارد که اغلب هزینه‌بر، دشوار و یا زمان‌بر می‌باشد؛ از این‌رو پیش‌بینی این خصوصیات فیزیکی و شیمیایی ضرورت دارد (Jahangiri-Saleh *et al.*, 2017).

اگرچه می‌توان برای پیش‌بینی تغییرات کمی فیزیکی و شیمیایی، بیوشیمیایی و تغذیه‌ای میوه‌ها و سبزی‌ها از مدل‌های سینتیکی مختلف استفاده نمود (Dhakala *et al.*, 2018). با این حال استفاده از این مدل‌های سینتیکی در تحقیقات غذایی در برخی موارد با محدودیت‌هایی نظیر دقت نسبتاً پایین، عدم پیش‌بینی رفتارهای پیچیده و توانایی کم در یافتن رفتارهای غیر خطی روبه‌رو است. امروزه استفاده از تکنیک‌های هوش مصنوعی نظیر شبکه عصبی مصنوعی در مدل‌سازی و شبیه‌سازی فرآیندهای مختلف مواد غذایی گسترش یافته است (Abbaspour-Gilandeh *et al.*, 2020; Azarmdel *et al.*, 2020). این روش مدل‌سازی غیرخطی به سبب دقت بالا و نیز قدرت و سرعت بالا به‌طور گسترده‌ای در ارزیابی و تشخیص کیفی و کمی در صنایع غذایی کاربرد دارد (Jahangiri-Saleh *et al.*, 2017; Mohammadigol *et al.*, 2017). استفاده از روش‌های مدل‌سازی هوشمند مانند شبکه عصبی مصنوعی^۱ (ANN) و سیستم استنتاج عصبی-فازی سازگار (ANFIS) بهترین انتخاب می‌باشد.

شبکه عصبی مصنوعی روش مدل‌سازی مناسبی برای روابط پیچیده غیر خطی است (KhayatiChayjan, 2016). در این میان شبکه پرسپترون چند لایه‌ای^۲ متداول‌ترین شبکه عصبی مصنوعی در پژوهش‌های صنایع غذایی است. بنیاد منطق فازی بر پایه تئوری مجموعه‌های فازی استوار است. این تئوری که تعمیمی از تئوری کلاسیک مجموعه‌ها در علم ریاضیات است بر مبنای محاسبات عددی بر روی مقادیر تولید شده توسط تابع عضویت برای هریک از متغیرهای زبان شناختی عمل می‌نماید. ابزار منطق فازی قدرت تشخیصی را در مدل‌سازی فراهم می‌نماید. این روش از تئوری احتمالات برای توضیح وقوع یک پدیده بهره می‌گیرد و بر اساس آن شانس مورد انتظار برای وقوع یک پدیده را اندازه‌گیری می‌کند

1- Artificial Neural Networks

2- Multilayer perceptron (MLP)

3- Total Soluble Solid (TSS)

(Majidzadeh et al., 2015). شبکه عصبی طراحی شده دارای یک لایه ورودی با سه نورون شامل زمان نگهداری، رطوبت اولیه و دمای نگهداری و یک متغیر در لایه‌های خروجی ($WL, F, \Delta E, c^*, h^*$ و RPI) است. این شبکه شامل یک و یا دو لایه پنهان می‌باشد که بهینه تعداد نورون آن با استفاده از آزمون و خطا مشخص گردید. اغلب پژوهش‌های پیچیده تعیین الگو، از شبکه پرسپترون چند لایه‌ای (MLP) برای تفکیک گروه‌های متفاوت بر اساس الگوهای آموزشی استفاده می‌گردد. در پژوهش حاضر از MLP برای مدل‌سازی تمامی پارامترهای فیزیکی و شیمیایی با توابع آستانه‌ای سیگموئید اکسون^۵ و تان اکسون^۶ و توابع آموزشی مونتوم^۷ و لونیگ-مارکوارت^۸ استفاده گردید. در کل فرآیند ۷۰ درصد داده‌ها برای آموزش، ۱۰ درصد برای آزمون مدل و ۲۰ درصد برای اعتبارسنجی آن مورد استفاده قرار گرفت. نرخ آموزش به روش آزمون و خطا و نیز مونتوم به ترتیب ۰/۰۵ و ۰/۱۵ در نظر گرفته شد. معیارهای ارزیابی پایانی به‌منظور دستیابی به بهترین توپولوژی استفاده از ضریب تبیین (R^2) بین مقدار واقعی با مقدار پیش‌بینی شده، ریشه میانگین مربعات خطا (RMSE) می‌باشد. الگوریتم مورد نظر برای شبیه‌سازی شبکه‌های عصبی مصنوعی با استفاده از نرم‌افزار neurosolution (نسخه ۵، آمریکا) توسعه داده شد.

مدل‌سازی با سیستم استنتاج عصبی-فازی سازگار (ANFIS)

سیستم استنتاج عصبی-فازی سازگار، شبکه عصبی مصنوعی و مفاهیم منطق فازی را یکی می‌کند و از مجموعه‌ای از قوانین فازی اگر-آن‌گاه استفاده می‌نماید. این تکنیک که بسیار شبیه به سیستم استنتاج فازی است با تغییر در میزان مقادیر مرکز و دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب براساس حداقل خطای موجود (با استفاده از الگوریتم پس‌انتشار خطا^۹) عمل می‌کند. این مدل شامل سه نوع سیستم مدانی^{۱۰}، سیستم سوگنو^{۱۱} و سیستم سوکاموتو است که در بیشتر موارد از سیستم مدانی استفاده می‌شود (Abbaspour-Gilandeh et al., 2020; Karaman et al., 2012). ساختار سیستم استنتاج عصبی-فازی سازگار شامل پنج لایه است که به‌ترتیب شامل گره‌های ورودی، گره‌های قاعده، گره‌های متوسط، گره‌های نتیجه و گره‌های خروجی می‌باشند و به‌طور مستقیم با هم ارتباط دارند. هر گره دارای تابعی با

(AND، مدل HL-I، ژاپن) محاسبه گردید. تغییرات بافتی (سفتی بافت (F)) زالزالک با کمک دستگاه تست بافت (کوپا، مدل TA20، ایران) مجهز به پلانجر با قطر ۳ میلی‌متری از طریق آزمون نفوذ اندازه‌گیری شد (سرعت نفوذ ۰/۵ میلی‌متر بر ثانیه و حداکثر عمق نفوذ ۶ میلی‌متر). برای استخراج خصیصه‌های رنگی از تصویربرداری دیجیتال با کمک دوربین کانن (مدل ۷۰D، ساخت ژاپن) با لنزی با زوم بین ۵۵-۱۸ میلی‌متری استفاده گردید. به این منظور از محفظه پردازش تصویر با هشت نوار LED، دو لامپ LED و دو صفحه LED در بالا و پایین کمک گرفته شد. تصاویر گرفته شده با فرمت TIFF در کامپیوتر ثبت گردید. پردازش تصاویر خام (از قبیل حذف نویز و تبدیل محیط RGB به مختصات CIELab) با استفاده از نرم‌افزار ImageJ (نسخه ۱/۵۲، موسسه ملی بهداشت، ایالات متحده آمریکا) و پلاگین‌های آن صورت پذیرفت. در نهایت خصیصه‌های L^* ، a^* و b^* استخراج و سایر خصیصه‌ها شامل خلوص رنگ یا کروما^۱ (C^*)، تغییرات رنگی (ΔE) و زاویه رنگ^۲ (h^*) نیز با استفاده از رابطه‌های (۱) تا (۳) محاسبه گردید (Arzate-Vazquez et al., 2017; Cardenas-Perez et al., 2017):

$$C^* = (a^{*2} + b^{*2})^{1/2} \quad (1)$$

$$h^* = \arctan(b^*/a^*) \quad (2)$$

$$\Delta E = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} \quad (3)$$

که $\Delta L^* = L^* - L_0^*$ ، $\Delta a^* = a^* - a_0^*$ و $\Delta b^* = b^* - b_0^*$ مربوط به پارامترهای رنگی اولیه (L_0^* ، a_0^* و b_0^*) مربوط به پارامترهای رنگی سفید استاندارد است. مواد جامد محلول کل (TSS)، pH، اسیدیته قابل تیتر^۳ (TA) با استفاده از عصاره صاف شده زالزالک و به‌ترتیب با کمک رفاکتومتر دستی (شرکت آتاگو، مدل H50، ژاپن)، pH متر (شرکت هانا ایتالیا، مدل HI2211) و روش AOAC (Helrich, 1990; Jahanbakhshi et al., 2019c) اندازه‌گیری گردید. شاخص رسیدگی^۴ (RPI) به‌عنوان خصیصه مرجع برای تعیین وضعیت رسیدگی از طریق رابطه (۴) محاسبه گردید (Vélez-Rivera et al., 2014):

$$RPI = \ln(100 \times |F| \times \frac{TA}{TSS}) \quad (4)$$

مدل‌سازی شبکه عصبی مصنوعی (ANN)

هدف از مدل‌سازی با شبکه‌های عصبی مصنوعی تعیین وزن‌ها و بایاس‌ها در اتصالات بین نورون‌ها از طریق آموزش است. وزن‌ها، بایاس‌ها و توابع انتقال در حقیقت از عناصر اصلی نورون‌ها می‌باشند (Kaveh et al., 2019; Jahangiri-Saleh et al., 2017)

- 5- SigmoidAxon
- 6- TanhAxon
- 7- Momentum
- 8- Levenberg-Marquardt
- 9- Back Propagation
- 10- Mamdani
- 11- Sugeno

- 1- Chroma
- 2- Hue Angle
- 3- Titratable Acidity (TA)
- 4- Ripening Index (RPI)

$$RMSE = \sqrt{\frac{(O-P)^2}{n-p}} \quad (10)$$

که O, P, n و p به ترتیب داده تجربی، داده پیش‌بینی شده، تعداد مشاهده و تعداد پارامترهای مدل است. رسم نمودارها و محاسبه نوار خط^۱ به ترتیب با کمک نرم‌افزارهای اکسل (نسخه ۲۰۱۶) و SPSS (نسخه ۲۶) صورت پذیرفت.

نتایج و بحث

شبکه عصبی مصنوعی (ANN)

به منظور مدل‌سازی از شبکه‌های عصبی پرسپترون چند لایه‌ای استفاده گردید و پیکربندی‌های مختلفی به صورت سعی و خطا به همراه توابع آستانه‌ای و آموزش گوناگون به کار برده شد. در نهایت به منظور دستیابی به ساختار بهینه شبکه‌های عصبی مصنوعی برای پیش‌بینی افت وزن پیکربندی‌هایی مختلفی بررسی گردید و بهترین پیکربندی با کمک شاخص‌های R^2 و RMSE از میان انواع مختلف پیکربندی‌های اجرا شده، انتخاب گردید. مقادیر R^2 بالا و RMSE کم گویای کارایی بالای مدل شبکه عصبی مصنوعی در پیش‌بینی خصوصیات کیفی زالک طی فرآیند نگهداری می‌باشد.

پارامترهای قابل تنظیم یا ثابت است (Karaman et al., 2012). در این پژوهش مدل‌سازی استنتاج عصبی-فازی سازگار با کمک جعبه ابزار نرم‌افزار متلب (Matlab R2019a) صورت پذیرفت به این منظور از سیستم سوگنو استفاده گردید و تابع عضویت مطلوب از میان توابع مختلف مثلثی، ذوزنقه‌ای، زنگوله‌ای، گوسی، پی، گوسی نوع ۲ و سیگموئیدی و درجه عضویت مناسب آن‌ها برای هر ترکیب ورودی از آزمون سعی و خطا به دست آمد. همچنین از الگوریتم یادگیری پیوندی که ترکیبی از الگوریتم پس‌انتشار خطا و روش حداقل مربعات می‌باشد، برای آموزش و تطبیق با سیستم استنتاج فازی استفاده شده است. این مدل برای پیش‌بینی خصوصیات فیزیکی و شیمیایی زالک ($WL, F, \Delta E, c^*, h^*, RPI$) طی نگهداری در شرایط مختلف استفاده گردید. در پژوهش حاضر ۷۵ درصد از داده‌ها برای آموزش و ۲۵ درصد از داده‌ها برای اعتبارسنجی در نظر گرفته شد.

تجزیه و تحلیل و ارزیابی مدل

ارزیابی و مقایسه مدل با کمک ضریب تبیین (R^2)، ضریب همبستگی تصحیح شده ($Adj. R^2$) و ریشه میانگین مربعات خطا (RMSE) انجام شد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (O-P)^2}{\sum_{i=1}^n (O-\bar{P})^2} \quad (9)$$

جدول ۱- برخی از بهترین پیکربندی‌های شبکه عصبی پرسپترون برای پیش‌بینی افت وزن (WL)

Table 1- Some of the best MLP neural network topologies to predict weight loss (WL)

خصیصه Parameter	تابع آستانه‌ای Activation function of hidden layer	تابع آموزش Learning function	پیکربندی Topology	آموزش Training		آزمون Test	
				R^2	MSE	R^2	RMSE
WL	سیگموئید اکسون SigmoidAxon	لونیبرگ-مارکواریت	3-8-1	0.93	0.12	0.98	0.04
		Levenberg- Marquardt	3-12-4-1	0.96	0.10	0.99	0.03
		مومنتوم	3-13-1	0.97	0.08	0.99	0.06
		Momentum	3-15-5-1	0.96	0.10	0.99	0.08
	تان‌اکسون TanhAxon	لونیبرگ-مارکواریت	3-12-1	0.92	0.12	0.97	0.08
		Levenberg- Marquardt	3-9-3-1	0.93	0.12	0.98	0.10
		مومنتوم	3-13-1	0.94	0.12	0.98	0.09
		Momentum	3-14-8-1	0.94	0.11	0.97	0.07

شبکه‌ای با سه ورودی، دو لایه پنهان با پانزده و پنج نورون. مقادیر تجربی به همراه مقادیر پیش‌بینی شده تغییرات افت وزن زالک که تحت تاثیر زمان و شرایط نگهداری مختلف است در جدول ۲ نشان داده شده است. علاوه بر محاسبه شاخص‌های ارزیابی، نمودار رگرسیون بین مقادیر اندازه‌گیری شده و پیش‌بینی شده به وسیله شبکه عصبی مصنوعی در شکل ۱ نشان داده شده است. این منحنی پراکنده‌گی برای بهترین پیکربندی رسم گردید. مطابق شکل، نزدیکی داده‌ها به خطوط ۴۵ درجه با ضریب همبستگی بالا نشان‌دهنده

در جدول ۱ بهترین نتایج حاصل از برخی از پیکربندی‌های منتخب با توابع آستانه‌ای سیگموئید اکسون و تان‌اکسون و توابع آموزشی مومنتوم و لونیبرگ-مارکواریت برای پیش‌بینی مستقل افت وزن نشان داده شده است. برای پیش‌بینی افت وزن پیکربندی ۱-۵-۳-۱۵ با تابع آستانه‌ای سیگموئید اکسون و تابع آموزش مومنتوم به عنوان بهترین پیکربندی انتخاب شد. پیکربندی ۱-۵-۳-۱۵ یعنی

عملکرد بالای شبکه عصبی مصنوعی در پیش‌بینی دقیق پارامترهای مورد بررسی است و در نتیجه داده‌های پیش‌بینی شده انطباق بسیار خوبی با داده‌های تجربی دارند.

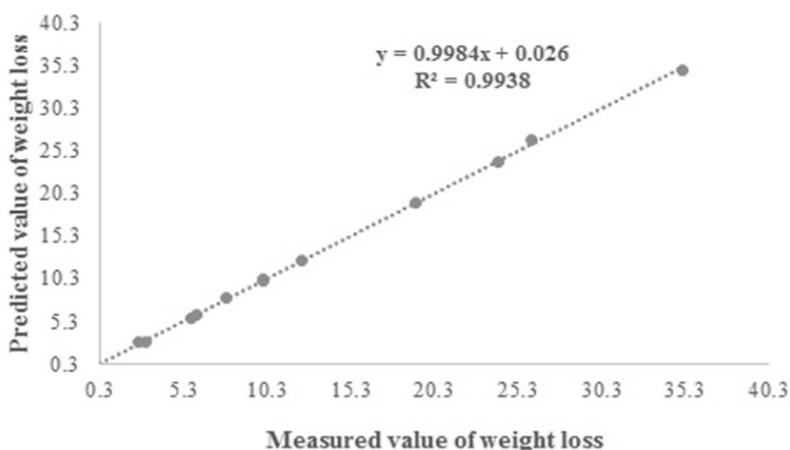
جدول ۲- نتایج تجربی و پیش‌بینی شده تغییرات سفتی و افت وزن میوه زالزالک طی شرایط مختلف نگهداری

Table 2- Experimental and predicted result of hawthorn fruit for firmness and weight loss change at different storage conditions

شرایط نگهداری Storage conditions	زمان نگهداری (روز) Storage time (day)	WL			F		
		مقادیر تجربی Experimental value	مقادیر پیش‌بینی Predicted value	خطا Error	مقادیر تجربی Experimental value	مقادیر پیش‌بینی Predicted value	خطا Error
CCS	0	0.00	0.00	0.00	17.2	17.5	-0.3
	5	2.65	2.87	-0.22	16.4	16.5	-0.1
	10	5.75	5.65	0.10	15.7	15.7	0.0
	15	10.11	9.98	0.13	15.1	14.9	0.2
	20	19.17	19.29	-0.12	14.6	14.4	0.2
RFS	0	0.00	0.00	0.00	17.2	17.1	0.1
	5	3.1	2.95	0.15	16.2	16.4	-0.2
	10	7.93	8.04	-0.11	15.4	15.3	0.1
	15	10.11	10.28	-0.17	14.8	14.8	0.1
	20	26.11	26.54	-0.43	14.1	13.9	0.2
RMS	0	0.00	0.00	0.00	17.2	17.4	-0.2
	5	6.11	6.07	0.04	14.3	14.4	-0.1
	10	12.36	12.37	-0.01	12.9	12.7	0.2
	15	24.17	23.94	0.23	11.6	11.3	0.3
	20	35.11	34.83	0.28	10.2	9.9	0.3

* اعداد نمایش داده شده حاصل میانگین حداقل ۱۰ تکرار یا پیش‌بینی مستقل می‌باشند.

* Values represent mean of ten independent replicates or predict.



شکل ۱- منحنی پراکندگی برای مقادیر اندازه‌گیری شده و پیش‌بینی شده افت وزن توسط شبکه عصبی MLP برای بهترین مدل

Fig.1. Dispersion curve for the measured and the predicted values of weight loss by MLP neural network for best model

یکی از شاخص‌های مهم طی نگهداری میوه‌ها و سبزی‌ها تغییرات وزنی یا همان افت رطوبتی است که کاهش رطوبت و افت وزن سبب تغییرات بعدی در خصوصیات کیفی آن‌ها می‌گردد؛ از این رو پیش‌بینی این تغییرات به منظور کنترل تغییرات و مدیریت بهتر نگهداری زالزالک‌ها امری مهم می‌باشد (Jahanbakhshi et al., 2019a). از طرف دیگر، از دست دادن رطوبت به همراه تغییرات شیمیایی سبب ایجاد تغییراتی در بافت میوه می‌شود و بافت آن نرم‌تر می‌گردد (Ahangarnezhad et al., 2019; GuadarramaAndrade, 2012). همان‌طور که نتایج نشان داد سفتی بافت زالزالک طی نگهداری در شرایط مختلف به‌طور پیوسته

یکی از شاخص‌های مهم طی نگهداری میوه‌ها و سبزی‌ها تغییرات وزنی یا همان افت رطوبتی است که کاهش رطوبت و افت وزن سبب تغییرات بعدی در خصوصیات کیفی آن‌ها می‌گردد؛ از این رو پیش‌بینی این تغییرات به منظور کنترل تغییرات و مدیریت بهتر نگهداری زالزالک‌ها امری مهم می‌باشد (Jahanbakhshi et al., 2019a). از طرف دیگر، از دست دادن رطوبت به همراه تغییرات شیمیایی سبب ایجاد تغییراتی در بافت میوه می‌شود و بافت آن نرم‌تر می‌گردد (Ahangarnezhad et al., 2019; GuadarramaAndrade, 2012). همان‌طور که نتایج نشان داد سفتی بافت زالزالک طی نگهداری در شرایط مختلف به‌طور پیوسته

بافت میوه در برابر آزمون نفوذ در میوه‌های نگهداری شده در سردخانه و کمترین میزان آن در زالزالک‌های انبار شده در دمای محیط اتفاق افتاد (جدول ۲).

کاهش می‌یابد، که این امر نشان‌دهنده وابسته به زمان بودن تغییرات بافتی است. از سوی دیگر نتایج نشان‌دهنده تاثیر معنادار ($p < 0.05$) شرایط نگهداری بر سفتی بافت بود؛ به طوری که بیشترین مقاومت

جدول ۳- برخی از بهترین پیکربندی‌های شبکه عصبی پرسپترون برای پیش‌بینی سفتی بافت (F)
Table 3- Some of the best MLP neural network topologies to predict firmness (F)

خصیصه Parameter	تابع آستانه‌ای Activation function of hidden layer	تابع آموزش Learning function	پیکربندی Topology	آموزش Training		آزمون Test	
				R ²	MSE	R ²	RMSE
F	سیگموئید اکسون SigmoidAxon	لونیبرگ-مارکوآرت	3-12-1	0.92	0.52	0.98	0.18
		Levenberg- Marquardt	3-10-4-1	0.95	0.29	0.99	0.05
		مومنتوم	3-9-1	0.96	0.18	0.99	0.06
		Momentum	3-15-6-1	0.95	0.16	0.98	0.08
	تان اکسون TanhAxon	لونیبرگ-مارکوآرت	3-7-1	0.90	0.65	0.97	0.21
		Levenberg- Marquardt	3-15-8-1	0.93	0.22	0.98	0.13
		مومنتوم	3-13-1	0.96	0.16	0.99	0.04
		Momentum	3-8-5-1	0.95	0.21	0.99	0.09

جدول ۴- نتایج تجربی و پیش‌بینی شده تغییرات خصیصه‌های رنگی میوه زالزالک طی شرایط مختلف نگهداری
Table 4- Experimental and predicted result of hawthorn fruits for color changes at different storage conditions.

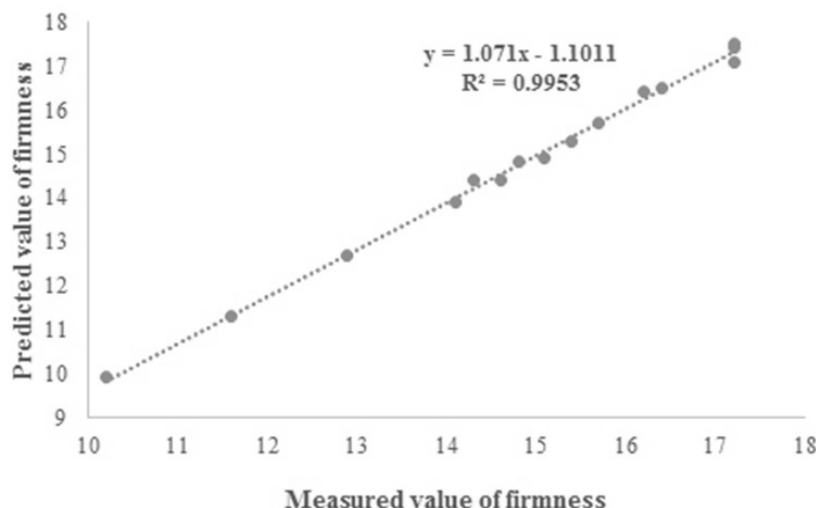
شرایط نگهداری Storage conditions	زمان نگهداری (روز) Storage time (day)	h*			C*			ΔE		
		مقادیر تجربی Experimental value	مقادیر پیش‌بینی Predicted value	خطا Error	مقادیر تجربی Experimental value	مقادیر پیش‌بینی Predicted value	خطا Error	مقادیر تجربی Experimental value	مقادیر پیش‌بینی Predicted value	خطا Error
CCS	0	0.814	0.832	-0.18	21.71	21.34	0.37	41.55	41.83	-0.28
	5	0.679	0.691	-0.12	20.78	21.75	-0.97	40.38	40.40	-0.02
	10	0.613	0.611	0.02	21.31	21.98	-0.67	39.29	39.62	-0.33
	15	0.564	0.573	-0.09	21.88	22.25	-0.37	38.94	39.01	-0.07
	20	0.542	0.553	-0.11	22.24	22.63	-0.39	38.12	38.35	-0.23
RFS	0	0.814	0.814	0.00	21.71	21.23	0.48	41.55	41.76	-0.21
	5	0.638	0.624	0.14	21.60	21.68	-0.08	39.65	39.89	-0.24
	10	0.581	0.565	0.16	21.64	21.85	-0.25	39.15	39.21	-0.06
	15	0.519	0.523	-0.04	22.15	22.16	-0.01	38.69	38.79	-0.10
	20	0.476	0.489	-0.13	23.42	22.97	0.45	38.14	38.16	-0.02
RMS	0	0.814	0.809	0.05	21.71	21.25	0.46	41.55	41.79	-0.24
	5	0.587	0.562	0.25	22.93	22.65	0.28	39.29	39.96	-0.67
	10	0.495	0.478	0.17	23.12	23.24	-0.12	37.88	38.54	-0.66
	15	0.445	0.436	0.09	24.18	24.39	-0.21	37.58	37.93	-0.35
	20	0.395	0.373	0.22	25.95	25.83	0.12	38.15	37.11	0.96

* اعداد نمایش داده شده حاصل میانگین حداقل ۱۰ تکرار یا پیش‌بینی مستقل می‌باشند.

* Values represent mean of ten independent replicates or predict.

طی نگهداری را پیش‌بینی کند. با مقایسه داده‌های تجربی و پیش‌بینی در شبکه‌ای با پیکربندی ۱-۸-۳ (جدول ۲) می‌توان دریافت که حداکثر اختلاف بین مقادیر تجربی و پیش‌بینی در تمامی شرایط ± 0.3 است.

نتایج حاصل از اجرای پیکربندی‌های مختلف شبکه‌های عصبی مصنوعی بر داده‌های تجربی سفتی بافت نشان داد (جدول ۳) که بهترین پیکربندی برای پیش‌بینی سفتی بافت ۱-۸-۳ با تابع آستانه‌ای سیگموئید اکسون و تابع آموزش مومنتوم می‌باشد. این پیکربندی توانست با ضرایب R^2 و برابر با ۰/۹۹ میزان سفتی بافت



شکل ۲- منحنی پراکندگی برای مقادیر اندازه‌گیری شده و پیش‌بینی شده سفتی بافت توسط شبکه عصبی MLP برای بهترین مدل
Fig. 2. Dispersion curve for the measured and the predicted values of firmness by MLP neural network for best model

۳-۷ (ضریب R^2 برابر با ۰/۹۵) به ترتیب بهترین پیش‌بینی را از پارامترهای رنگی h^* و C^* داشت (جدول ۵). از آنجایی که شاخص رسیدگی (RPI) شامل خصوصیات فیزیکی (F) و شیمیایی (TSS و TA) میوه است، بنابراین خصیصه مناسبی جهت تعیین وضعیت کیفی میوه و سبزی طی نگهداری است؛ از این رو از این خصیصه به عنوان نماینده خصوصیات شیمیایی استفاده گردید. طی نگهداری شاخص رسیدگی کاهش یافت و این کاهش در دماهای بالاتر بیشتر بود. این کاهش احتمالاً به سبب تسریع فرآیندهای نظیر تبدیل نشاسته به قند (Zheng *et al.*, 2012)، محلول شدن ترکیبات غیر محلول مانند پکتین (Li *et al.*, 2015) و افزایش درجه رسیدگی (AshournezhadGhasemnezhad, 2012؛ Billy *et al.*, 2008) می‌باشند که با تغییرات سایر خصیصه‌ها نظیر خصیصه‌های رنگی، سفتی بافت و اسیدیته قابل تیترا مرتبط است. در نهایت بهترین پیش‌بینی برای پارامتر RPI با کمک شبکه عصبی مصنوعی با تابع آستانه‌ای تان‌اکسون و تابع آموزشی لونیگ-مارکواریت و نیز پیکربندی ۱-۵-۳ انجام گردید. ضریب R^2 و RMSE به ترتیب برابر با ۰/۹۹۵۶ و ۰/۰۱۵ برای این پیش‌بینی به دست آمد (جدول ۶).

با افزایش زمان نگهداری زالزالک، رنگ آن از قرمز روشن تا قرمز تیره و قهوه‌ای تغییر یافت که این امر متناظر با کاهش روشنایی، افزایش قرمزی و نیز کاهش زردی نمونه‌ها می‌باشد. این تغییرات احتمالاً با تغییرات رسیدگی میوه در ارتباط می‌باشد که در دماهای بالا با سرعت بیشتری رخ می‌دهد و توسط تغییرات رنگ (ΔE)، زاویه رنگ (h^*) و خلوص رنگ یا کروما (C^*) نیز تایید می‌گردد. همانطور که انتظار می‌رفت تغییرات خصیصه‌های رنگی در دماهای بالاتر بیشتر بود؛ تاثیر شرایط و نیز زمان نگهداری بر تغییرات خصیصه‌های رنگی و مقادیر تجربی با پیش‌بینی در جدول ۴ نمایش داده شده است. در بین پیکربندی‌های مختلف برای پیش‌بینی خصیصه تغییرات رنگ شبکه‌ای با تابع آستانه‌ای تان‌اکسون و تابع آموزش مومنتوم و پیکربندی ۱-۷-۹-۳ دارای بهترین آرایش جهت پاسخ پیش‌بینی بود که توانست تغییرات رنگ را با ضریب R^2 برابر با ۰/۹۴ پیش‌بینی نماید. نتایج شبکه عصبی برای پارامترهای منتخب رنگی نشان داد که برای پارامترهای رنگی h^* و C^* شبکه‌ای با تابع آستانه‌ای تان‌اکسون و تابع آموزش مومنتوم بهترین پیش‌بینی را دارد؛ به طوری که شبکه‌هایی با پیکربندی ۱-۳-۹-۳ (ضریب R^2 برابر با ۰/۹۹) و ۱-

جدول ۵- برخی از بهترین پیکربندی‌های شبکه عصبی پرسپترون برای پیش‌بینی تغییرات رنگی (ΔE)، زاویه رنگ (h^*) و کروما (C^*)

Table 5- Some of the best MLP neural network topologies to predict color changes (ΔE), hue (h^*) and Chroma (C^*)

خصیصه Parameter	تابع آستانه‌ای Activation function of hidden layer	تابع آموزش Learning function	پیکربندی Topology	آموزش Training		آزمون Test	
				R^2	MSE	R^2	RMSE
ΔE	سیگموئید اکسون SigmoidAxon	لونیبرگ-مارکوارت	3-13-1	0.96	0.28	0.99	0.03
		Levenberg-Marquardt	3-9-2-1	0.96	0.24	0.99	0.04
		مومنتوم	3-15-1	0.94	0.32	0.98	0.09
	تان‌اکسون TanhAxon	Momentum	3-12-7-1	0.95	0.25	0.98	0.05
		لونیبرگ-مارکوارت	3-17-1	0.92	0.41	0.97	0.18
		Levenberg-Marquardt	3-10-4-1	0.93	0.44	0.97	0.21
		مومنتوم	3-10-1	0.90	0.73	0.94	0.43
		Momentum	3-9-7-1	0.95	0.19	0.99	0.09
		لونیبرگ-مارکوارت	3-12-1	0.95	0.19	0.99	0.03
h^*	سیگموئید اکسون SigmoidAxon	Levenberg-Marquardt	3-15-10-1	0.94	0.27	0.99	0.03
		مومنتوم	3-9-1	0.93	0.35	0.98	0.09
		Momentum	3-16-7-1	0.94	0.31	0.98	0.10
	تان‌اکسون TanhAxon	لونیبرگ-مارکوارت	3-6-1	0.91	0.47	0.97	0.24
		Levenberg-Marquardt	3-7-2-1	0.92	0.37	0.98	0.27
		مومنتوم	3-8-1	0.94	0.29	0.99	0.09
		Momentum	3-9-3-1	0.95	0.26	0.99	0.06
		لونیبرگ-مارکوارت	3-7-1	0.94	0.31	0.99	0.04
		Levenberg-Marquardt	3-9-2-1	0.93	0.33	0.99	0.10
C^*	سیگموئید اکسون SigmoidAxon	مومنتوم	3-16-1	0.92	0.36	0.98	0.09
		Momentum	3-12-8-1	0.92	0.35	0.98	0.12
		لونیبرگ-مارکوارت	3-9-1	0.94	0.22	0.99	0.05
	تان‌اکسون TanhAxon	Levenberg-Marquardt	3-9-3-1	0.95	0.19	0.99	0.08
		مومنتوم	3-7-1	0.94	0.24	0.99	0.06
		Momentum	3-7-3-1	0.94	0.23	0.99	0.09

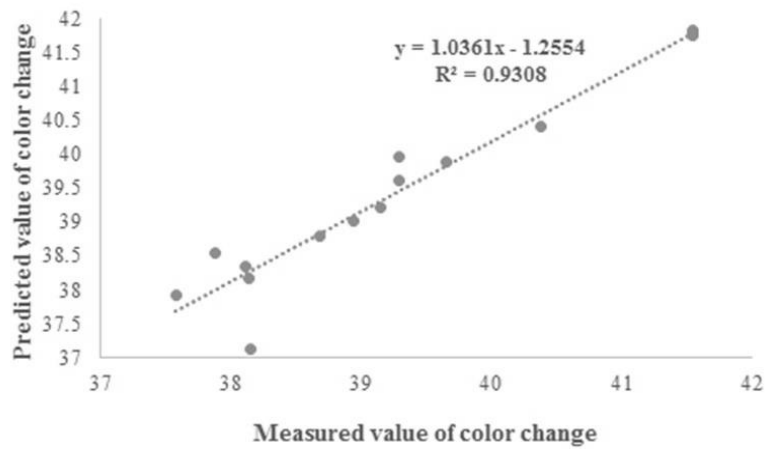
جدول ۶- نتایج تجربی و پیش‌بینی شده شاخص رسیدگی میوه زالزالک طی شرایط مختلف نگهداری

Table 6- Experimental and predicted result of hawthorn fruits for ripening index changes at different storage conditions

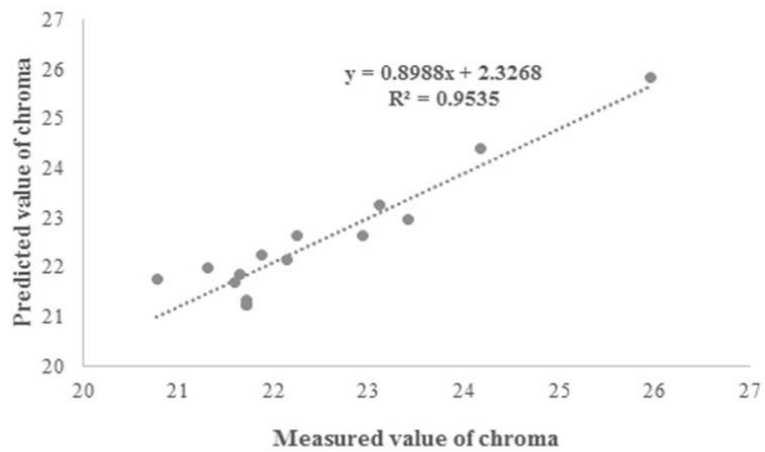
شرایط نگهداری Storage conditions	زمان نگهداری Storage time (day)	RPI		
		مقادیر تجربی Experimental value	مقادیر پیش‌بینی Predicted value	خطا Error
CCS	0	6.76	6.83	-0.07
	5	6.54	6.56	-0.02
	10	6.31	6.24	0.07
	15	6.03	5.98	0.05
	20	5.92	5.87	0.05
RFS	0	6.76	6.86	-0.10
	5	6.42	6.41	0.01
	10	6.14	6.11	0.03
	15	5.87	5.87	0.00
	20	5.62	5.53	0.09
RMS	0	6.76	6.80	-0.04
	5	6.00	6.09	-0.09
	10	5.63	5.52	0.11
	15	5.15	5.10	0.05
	20	4.40	4.61	-0.21

* اعداد نمایش داده شده حاصل میانگین حداقل ۱۰ تکرار یا پیش‌بینی مستقل می‌باشند.

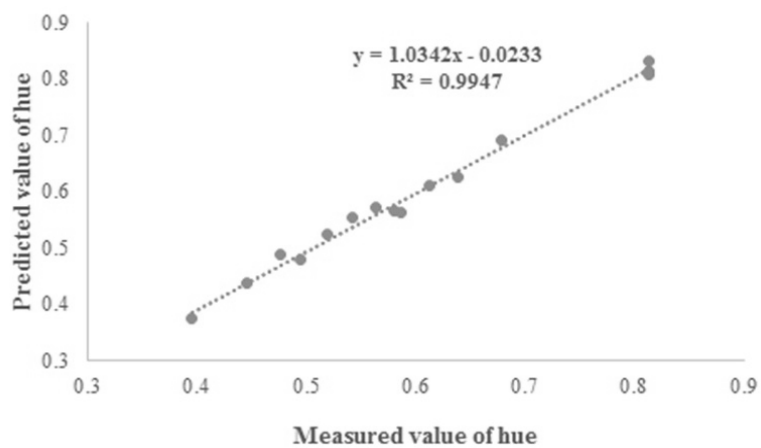
* Values represent mean of ten independent replicates or predict.



(a)



(b)



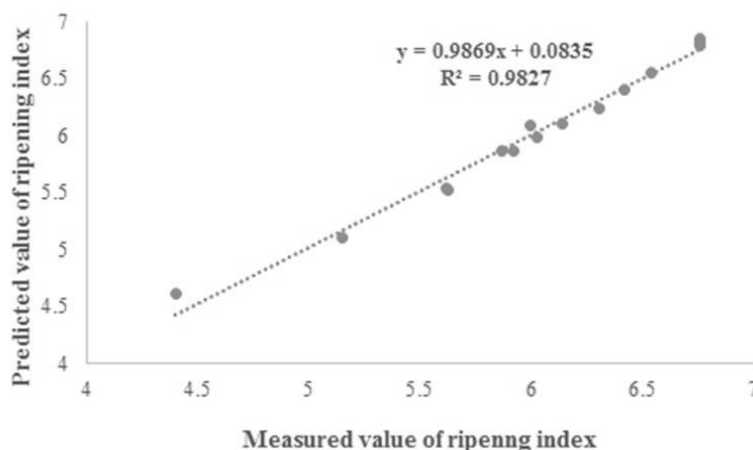
(c)

شکل ۳- منحنی پراکندگی برای مقادیر اندازه‌گیری شده و پیش‌بینی شده (a) تغییرات رنگ، (b) کروما و (c) زاویه رنگ توسط شبکه عصبی MLP برای بهترین مدل

Fig.3. Dispersion curve for the measured and the predicted values of (a) Color change, (b) Chroma and (c) Hue by MLP neural network for best model

جدول ۷- برخی از بهترین پیکربندی‌های شبکه عصبی پرسپترون برای پیش‌بینی شاخص رسیدگی (RPI)
Table 7- Some of the best MLP neural network topologies to predict ripening index (RPI)

خصیصه Parameter	تابع آستانه‌ای Activation function of hidden layer	تابع آموزش Learning function	پیکربندی شبکه Topology	آموزش Training		آزمون Test	
				R ²	MSE	R ²	RMSE
RPI	سیگموئید اکسون SigmoidAxon	لونیگ-مارکواریت	3-6-1	0.95	0.28	0.99	0.08
		Levenberg- Marquardt	3-5-2-1	0.94	0.25	0.99	0.07
		مومنتوم	3-5-1	0.93	0.31	0.98	0.10
		Momentum	3-7-3-1	0.93	0.32	0.98	0.11
	تان‌اکسون TanhAxon	لونیگ-مارکواریت	3-4-1	0.94	0.20	0.99	0.03
		Levenberg- Marquardt	3-5-1-1	0.95	0.16	0.99	0.07
		مومنتوم	3-9-1	0.95	0.13	0.99	0.09
		Momentum	3-8-3-1	0.92	0.29	0.98	0.08



شکل ۴- منحنی پراکندگی برای مقادیر اندازه‌گیری شده و پیش‌بینی شده شاخص رسیدگی توسط شبکه عصبی MLP برای بهترین مدل
Fig.4. Dispersion curve for the measured and the predicted values of ripening index by MLP neural network for best model

حداقل مربعات و روش پس‌انتشار می‌باشد استفاده شد و حد خطا که برای ایجاد یک معیار توقف آموزش مورد استفاده قرار می‌گیرد بر روی صفر تنظیم شد. برای هر ترکیب ورودی، با بهره‌گیری از داده‌های آموزش و آزمون و انتخاب تابع عضویت ورودی و خروجی از میان توابع مختلف و درجه عضویت آن‌ها، شبکه را اجرا کرده تا پارامترهای کیفی زالزالک تخمین زده شود. بعد از آموزش و اعتبارسنجی انفیس برای سری ورودی‌های مختلف مقداری خطا حاصل می‌شود و مقدار خروجی از انفیس با داده‌های آموزشی و ارزیابی مقایسه می‌شود (Abbaspour-Gilandeh *et al.*, 2020; Karaman *et al.*, 2012). نتایج حاصل از بهترین ساختار شبکه انفیس به‌دست آمده در پیش‌بینی خصوصیات کیفی زالزالک طی نگهداری در شرایط مختلف در جدول ۸ آورده شده است، همان‌طور

اصغری و همکاران بیان نمودند که شبکه عصبی به‌عنوان یک سیستم غیر خطی می‌تواند نقش مهمی در پیش‌بینی پارامترهای کیفی مواد غذایی داشته باشد و به‌عنوان یک روش تخریبی و سریع می‌تواند در سایر سیستم‌های کنترل اتوماتیک به‌کار رود (Asghari *et al.*, 2017).

مدل‌سازی با سیستم استنتاج تطبیقی فازی-عصبی (ANFIS)

در انفیس، مسئله اصلی تعیین نوع تابع عضویت و درجه عضویت آن‌هاست که برای این امر راه‌حل مشخصی وجود ندارد و با بهره‌گیری از سعی و خطا، بهترین ساختار مدل تعیین می‌گردد. بدین منظور در آموزش ساختار انفیس از روش هیبرید که ترکیب روش

عصبی استفاده می‌کند و با بهره‌گیری از یک تابع عضویت خاص و یک سری قوانین فازی، مدل ساخته می‌شود. با این حال هر دو تکنیک به خوبی قادر به پیش‌بینی خواص کیفی زالزالک هستند. نتایج مدل‌سازی با انفیس نشان داد که توابع عضویت دوزنقه‌ای و گوسی بهترین عملکرد را به ترتیب در پیش‌بینی خصوصیات رنگی و فیزیکی داشت. با بررسی تعداد مختلف توابع عضویت مشخص گردید که با افزایش شمار توابع عضویت پیچیدگی مدل بیشتر می‌شود که این امر تأثیر منفی روی کارایی مدل خواهد گذاشت.

که در جدول مشاهده می‌گردد، انفیس به خوبی توانست خصوصیات کیفی طی نگهداری زالزالک در شرایط مختلف را پیش‌بینی نماید که این امر با مقادیر R^2 بالا و RMSE کم قابل تشخیص است. با مقایسه نتایج حاصل از مدل‌سازی با شبکه عصبی مصنوعی و انفیس، تفاوت زیادی از نظر دقت و کارایی در پیش‌بینی یافت نمی‌گردد، اگرچه شاخص RMSE در مدل‌سازی با کمک انفیس کمتر از شبکه عصبی مصنوعی است که خود نمایانگر دقت بالاتر آن می‌باشد؛ این برتری نسبی را می‌توان در این امر دانست که تکنیک انفیس ترکیبی از دو مدل فازی و عصبی است، یعنی برای آموزش داده‌ها از شبکه

جدول ۸- برخی از بهترین پیکربندی‌های سیستم استنتاج تطبیقی فازی-عصبی برای پیش‌بینی خصوصیات کیفی زالزالک

Table 8- Some of the best ANFIS topologies to predict quality parameters of hawthorn fruit

خصیصه Parameter	تابع عضویت Membership function	تعداد توابع عضویت Number of membership functions	آموزش Training		آزمون Test	
			R^2	MSE	R^2	RMSE
WL	گوسی Gauss	2	0.95	0.14	0.99	0.03
F	گوسی Gauss	2	0.94	0.18	0.98	0.09
ΔE	مثلثی Triangle	2	0.94	0.19	0.99	0.02
h*	دوزنقه‌ای Trapezoidal	3	0.94	0.19	0.98	0.10
C*	دوزنقه‌ای Trapezoidal	3	0.93	0.23	0.98	0.09
RPI	گوسی Gauss	2	0.94	0.18	0.99	0.04

دوزنقه‌ای و گوسی بهترین عملکرد را به ترتیب در پیش‌بینی پارامترهای رنگی و فیزیکی داشت. تفاوت زیادی بین دقت پیش‌بینی شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی-فازی سازگار وجود نداشت و هر دو روش توانستند با دقت بالا مدل‌سازی را انجام دهند.

سپاسگزاری

مطالعه حاضر حاصل بخشی از طرح‌های پژوهشی مصوب گروه علوم و مهندسی صنایع غذایی دانشگاه زنجان مورخ ۱۳۹۸/۰۲/۳۰ با عنوان "استفاده از سیستم ماشین بینایی (CVS) جهت طبقه‌بندی، شناسایی، بررسی تغییرات طی نگهداری، رسیدگی و فرآوری ازگیل، زالزالک و نخود فرنگی" و مورخ ۱۳۹۸/۰۴/۱۰ با عنوان "خصوصیات فیزیکی، شیمیایی، بصری (پردازش تصویر)، آئروپنایمیکی، هیدروپنایمیکی میوه‌های ایرانی تحت شرایط مختلف فراوری و نگهداری" می‌باشد.

نتیجه‌گیری

در این پژوهش، جهت مدل‌سازی تغییرات خصوصیات کیفی طی نگهداری در شرایط مختلف از شبکه‌های عصبی مصنوعی و سیستم استنتاج عصبی-فازی سازگار استفاده گردید. بهترین پیکربندی شبکه‌های عصبی مصنوعی توانست به‌طور مستقل خصوصیات افت وزن و سفتی بافت (به‌عنوان نماینده خصیصه فیزیکی)، ΔE ، h^* و C^* (به‌عنوان نماینده خصیصه رنگی) و RPI (به‌عنوان نماینده خصیصه فیزیکی و شیمیایی) پیش‌بینی نماید؛ مقایسه بین انواع توابع آموزش و آستانه‌ای مختلف نشان داد که از میان الگوهای متعدد استفاده شده شبکه عصبی مصنوعی با تابع آستانه‌ای تان‌اکسون و تابع آموزشی لونیبرگ-مارکوارت بهترین شبکه برای پیش‌بینی اغلب خصوصیات فیزیکی و شیمیایی است ولی به‌طور کلی تابع آستانه‌ای تان‌اکسون و تابع آموزش مومنتوم بهترین عملکرد را داشت. نتایج این پژوهش مشخصی نمود که شبکه عصبی پرسپترون را می‌توان در پیش‌بینی تغییرات کیفی میوه‌ها طی نگهداری در شرایط مختلف مورد استفاده قرار داد. نتایج مدل‌سازی با انفیس نشان داد که توابع عضویت

References

1. Abbaspour Gilandeh, Y., A. Jahanbakhshi, and M. Kaveh. 2020. Prediction kinetic, energy and exergy of quince under hot air dryer using ANNs and ANFIS. *Food Science & Nutrition* 8: 594-611.
2. Ahangarnezhad, N., G. Najafi, and A. Jahanbakhshi. 2019. Determination of the physical and mechanical properties of a potato (the Agria variety) in order to mechanise the harvesting and post-harvesting operations. *Research in Agricultural Engineering* 65: 33-39.
3. Amiri Chayjan, R., M. Kaveh, and S. Khayati. 2015. Modeling Drying Characteristics of Hawthorn Fruit under Microwave Convective Conditions. *Journal of Food Processing and Preservation* 39: 239-253.
4. Aral, S., and A. Vildan Bese. 2016. Convective drying of hawthorn fruit (*Crataegus* spp.): Effect of experimental parameters on drying kinetics, color, shrinkage, and rehydration capacity. *Food Chemistry* 210: 577-584.
5. Arzate-Vazquez, I., J. J. Chanona-Perez, M. D. J. Perea-Flores, G. Calderon-Domínguez, M. Moreno-Armendariz, and G. Gutierrez-Lopez. 2011. Image processing applied to classification of avocado variety Hass (*Persea americana* Mill) during the ripening process. *Food and Bioprocess Technology* 4: 1307-1313.
6. Asghari, M. R., R. Ebrahimi, B. Hosseinzadeh, and D. Ghanbarian. 2017. Mulberry qualitative parameters modelling in drying process using artificial neural networks. *Iranian Journal of Biosystems Engineering* 48: 9-18. (In Farsi).
7. Ashournezhad, M., and M. Ghasemnezhad. 2012. Effects of cellophane-film packaging and cold storage on the keeping quality and storage life of loquat fruit (*Eriobotrya japonica*). *Iranian Journal of Nutrition Sciences & Food Technology* 7: 95-102. (In Farsi).
8. Azarmdel, H., A. Jahanbakhshi, S. S. Mohtasebi, and A. R. Muñoz. 2020. Evaluation of image processing technique as an expert system in mulberry fruit grading based on ripeness level using artificial neural networks (ANNs) and support vector machine (SVM). *Postharvest Biology and Technology* 166: 111201.
9. Billy, L., E. Mehinagic, G. Royer, C. M. G. C. Renard, G. Arvisenet, and C. Prost. 2008. Relationship between texture and pectin composition of two apple cultivars during storage. *Postharvest Biology and Technology* 47: 315-324.
10. Cardenas-Perez, S., J. Chanona-Perez, J. V. Mendez-Mendez, G. Calderon-Dominguez, R. Lopez-Santiago, M. A. J. Perea-Flores, and I. Arzate-Vazquez. 2017. Evaluation of the ripening stages of apple (Golden Delicious) by means of computer vision system. *Biosystems Engineering* 159: 46-58.
11. Derili gharjalar, S., H. Hassanpour, and A. Farokhzad. 2017. Pomological characteristics of some hawthorn genotypes in West Azerbaijan province. *Iranian Journal of Horticultural Science* 48: 689-700.
12. Dhakala, S., V. M. Balasubramaniam, H. Ayvaza, and L. E. Rodriguez-Saona. 2018. Kinetic modeling of ascorbic acid degradation of pineapple juice subjected to combined pressure-thermal treatment. *Journal of Food Engineering* 224: 62-70.
13. Farzan, E., M. R. Rahimi, and V. Madadi Avargani. 2017. Drying kinetic and shrinkage study of a Hawthorn sample in a vibro fluidized bed dryer using an adsorption system in order to control of inlet air humidity. *Journal of Innovative Food Technologies* 107-122. (In Farsi).
14. Guadarrama, A., and S. Andrade. 2012. Physical, chemical and biochemical changes of Sweetsop (*Annona squamosa* L.) and golden apple (*Spondias citherea* Sonner) fruits during ripening. *Journal of Agricultural Science and Technology* 1148-1157.
15. Helrich, K. 1990. AOAC Official Methods of Analysis. Official Methods of Analysis of the AOAC International. Gaithersburg: Association of official analytical chemists Inc (AOAC International).
16. Jahanbakhshi, A., R. Yeganeh, and G. Shahgoli. 2019a. Determination of mechanical properties of banana fruit under quasi-static loading in pressure, bending, and shearing tests. *International Journal of Fruit Science*: 1-9
17. Jahanbakhshi, A., Y. Abbaspour Gilandeh, B. Ghamari, and K. Heidarbeigi. 2019b. Assessment of physical, mechanical, and hydrodynamic properties in reducing postharvest losses of cantaloupe (*Cucumis melo* var. *Cantaloupensis*). *Journal of Food Process Engineering* 42: e13091.
18. Jahanbakhshi, A., V. Rasooli Sharabiani, K. Heidarbeigi, M. Kaveh, and E. Taghinezhad. 2019c. Evaluation of engineering properties for waste control of tomato during harvesting and postharvesting. *Food Science & Nutrition* 7: 1473-1481.
19. Jahangiri-Saleh, M., S. R. Hassan-Beygi, M. Aboonajmi, and M. Lotfi. 2017. Prediction of Cucumber Acoustic Response, Crispness Index and Firmness Using Artificial Neural Networks. *Food Science and Technology* 14: 265-276. (In Farsi).
20. Kami, D., L. Shi, T. Sato, T. Suzuki, and K. Oosawa. 2009. Cryopreservation of shoot apices of hawthorn in vitro cultures originating from East Asia. *Scientia Horticulturae* 120: 84-88.
21. Karaman, S., I. Ozturk, H. Yalcin, A. Kayacier, and O. Sagdic. 2012. Comparison of adaptive neuro fuzzy inference system and artificial neural networks for estimation of oxidation parameters of sunflower oil added with some natural byproduct extracts. *Journal of the Science of Food and Agriculture* 92: 49-58.

22. Kaveh, M., Y. Abbaspour-Gilandeh, R. A. Chayjan, and R. Mohammadigol. 2019. Comparison of Mathematical Modeling, Artificial Neural Networks and Fuzzy Logic for Predicting the Moisture Ratio of Garlic and Shallot in a Fluidized Bed Dryer. *Journal of Agricultural Machinery* 9. (In Farsi).
23. Khayati, S., and R. A. Chayjan. 2016. Prediction of some thermal, physical and mechanical properties of terebinth fruit after semi-industrial continuous drying using artificial neural networks. *Food Science and Technology* 13: 161-172.
24. Li, T., J. Zhu, L. Guo, X. Shi, Y. Liu, and X. Yang. 2013. Differential effects of polyphenols-enriched extracts from hawthorn fruit peels and fleshs on cell cycle and apoptosis in human MCF-7 breast carcinoma cells. *Food Chemistry* 141: 1008-1018.
25. Li, W.-Q., Q.-P. Hu, and J.-G. Xu. 2015. Changes in physicochemical characteristics and free amino acids of hawthorn (*Crataegus pinnatifida*) fruits during maturation. *Food Chemistry* 175: 50-56.
26. Liu, P., B. Yang, and H. Kallio. 2010. Characterization of phenolic compounds in Chinese hawthorn (*Crataegus pinnatifida* Bge. var. major) fruit by high performance liquid chromatography–electrospray ionization mass spectrometry. *Food Chemistry* 121: 1188-1197.
27. Liu, P., H. Kallio, and B. Yang. 2011a. Phenolic compounds in hawthorn (*Crataegus grayana*) fruits and leaves and changes during fruit ripening. *Journal of Agricultural and Food Chemistry* 59: 11141-11149.
28. Liu, P., H. Kallio, D. Lü, C. Zhou, and B. Yang. 2011b. Quantitative analysis of phenolic compounds in Chinese hawthorn (*Crataegus* spp.) fruits by high performance liquid chromatography-electrospray ionisation mass spectrometry. *Food Chemistry* 127: 1370-1377.
29. Luo, Y., G. Chen, B. Li, B. Ji, Y. Guo, and F. Tia. 2009. Evaluation of antioxidative and hypolipidemic properties of a novel functional diet formulation of *Auricularia auricula* and Hawthorn. *Innovative Food Science and Emerging Technologies* 10: 215-221.
30. Majidzadeh, H., B. Emadi, and A. A. Farzad. 2015. Prediction the moisture content of kiwifruit in vacuum drier using artificial neural network. *Iranian Food Science and Technology Research Journal* 11: 107-117. (In Farsi).
31. Menz, G., and F. Vriesekoop. 2010. Physical and chemical changes during the maturation of gordal sevilla olives (*Olea europaea* L., cv. Gordal Sevilla). *Journal of Agricultural and Food Chemistry* 58: 4934-4938.
32. Mohammadigol, R., F. Azadshahraki, and V. Lotfi. 2017. Quantification of total phenol in grape by near infrared spectroscopy and artificial neural network. *Journal of Research and Innovation in Food Science and Technology* 6: 313-320. (In Farsi).
33. Mraih, F., M. Hidalgo, S. Pascual-Teresa, M. Trabelsi-Ayadi, and J. K. Cherif. 2015. Wild grown red and yell ow Hawthorn fruits from Tunisia as source of antioxidants. *Arabian Journal of Chemistry* 8: 570-578.
34. Nordey, T., M. Léchaudel, M. Génard, and J. Joas. 2014. Spatial and temporal variations in mango colour, acidity, and sweetness in relation to temperature and ethylene gradients within the fruit. *Journal of Plant Physiology* 171: 1555-1563.
35. Opara, U. L., and M. R. Al-Ani, and N. M. Al-Rahbi. 2012. Effect of fruit ripening stage on physico-chemical properties, nutritional composition and antioxidant components of tomato (*Lycopersicon esculentum*) cultivars. *Food and Bioprocess Technology* 5: 3236-3243.
36. Razavi, F., M. Roghayeh, V. Rabiei, M. Soleimani Aghdam, and A. Soleimani. 2018. Glycine betaine treatment attenuates chilling injury and maintains nutritional quality of hawthorn fruit during storage at low temperature. *Scientia Horticulturae* 233: 188-194.
37. Vélez-Rivera, N., J. Blasco, J. Chanona-Pérez, G. Calderón-Domínguez, M. D. J. Perea-Flores, I. Arzate-Vázquez, S. Cubero, and R. Farrera-Rebollo. 2014. Computer vision system applied to classification of “Manila” Mangoes during ripening process. *Food and Bioprocess Technology* 7: 1183-1194.
38. Wang, H., F. Chen, H. Yang, Y. Chen, L. Zhang, and H. An. 2012. Effects of ripening stage and cultivar on physicochemical properties and pectin nanostructures of jujubes. *Carbohydrate Polymers* 89: 1180-1188.
39. Wen, L., X. Guo, R. Hai Liu, L. You, A. Mehmood Abbasi, and X. Fu. 2015. Phenolic contents and cellular antioxidant activity of Chinese hawthorn “*Crataegus pinnatifida*”. *Food Chemistry*: 54-62.
40. Zheng, H. Z., Y. I. Kim, and S. K. Chung. 2012. A profile of physicochemical and antioxidant changes during fruit growth for the utilisation of unripe apples. *Food Chemistry* 131: 106-110.

Applying Adaptive Neuro-Fuzzy Inference System and Artificial Neural Network to the Prediction of Quality changes of Hawthorn Fruit (*Crataegus pinnatifida*) during Various Storage Conditions

M. Zandi^{1*}, A. Ganjloo², M. Bimakr²

Received: 30-04-2020

Accepted: 13-06-2020

Introduction

In recent decades, artificial intelligence systems were employed for developing predictive models to estimate and predict many agriculture processes. Neural networks have the capability of identifying complex nonlinear systems with their own high learning ability. Artificial Neural Networks as a modern approach has successfully been used to solve an extensive variety of problems in the science and engineering, exclusively for some space where the conventional modeling procedure fail. A well-trained Artificial Neural Networks can be used as a predictive model for a special use, which is a data processing system inspired by biological neural system. The short storage life of hawthorn fruit and its high susceptibility to water loss and browning are the main factors limiting its marketability. So, it is important to evaluate parameters that affected the hawthorn quality. An adaptive neuro-fuzzy inference system or adaptive network-based fuzzy inference system (ANFIS) is a kind of artificial neural network that is based on Takagi-Sugeno fuzzy inference system. To estimate changes in fruit quality as a function of storage conditions, the evolution of certain quality-indicative properties such as color, firmness or weight can be used to provide related information on the quality grade of the product stored. Measurement of these parameters is an expensive and time-consuming process. Therefore, parameter prediction due to affecting factors will be more useful. In this study, the physicochemical properties of hawthorn fruit during various storage was predicted using artificial neural networks method. Hawthorn (*Crataegus pinnatifida*), belonging to the Rosaceae family, consists of small trees and shrubs. The color of the ripe fruit ranges from yellow, through green to red, and on to dark purple. Hawthorn is one of the most widely consumed horticultural products, either in fresh or processed form. It is also an important component of many processed food products because of its excellent flavor, attractive color and high content of many macro- and micro-nutrients.

Materials and Methods

The purpose of this study was a prediction of color, physical and mechanical properties of hawthorn fruit (*Crataegus pinnatifida*) during storage condition using artificial neural networks (ANNs) and adaptive network-based fuzzy inference system (ANFIS). Experimental data obtained from fruit storage, were used for training and testing the network. In the present research, artificial neural networks were used for modeling the relationship between physicochemical properties and color attributes with different storage time. Several criteria such as training algorithm, learning function, number of hidden layers, number of neurons in each hidden layer and activation function were given to improve the performance of the artificial neural networks. The total number of hidden layers and the number of neurons in each hidden layer were chosen by trial and error. The network's inputs include storage time, hawthorn moisture content and storage temperature and the network's output were the values of the physicochemical and color properties. The training rules were Momentum and Levenberg-Marquardt. The transfer functions were TanhAxon and SigmoidAxon.

Results and Discussion

To predict the weight loss and firmness multilayer perceptron network with the momentum learning algorithm, topologies of 3-15-5-1 and 3-8-5-1 with $R^2=0.9938$ and 0.9953 were optimal arrangement, respectively. The optimal topologies for color change, hue, Chroma were 3-9-7-1 ($R^2=0.9421$), 3-9-3-1 ($R^2=0.9947$) and 3-7-1 ($R^2=0.9535$) respectively, with momentum learning algorithm and TanhAxon activation function. The best network for ripening index prediction was Multilayer perceptron network with the TanhAxon activation function, Levenberg-Marquardt Levenberg-Marquardt learning algorithm, topology of 3-5-1-1 and $R^2=0.9956$.

Conclusions

Three factors including firmness, total soluble solids and titratable acidity were considered for ripening index calculation during fruits storage condition. Momentum and Levenberg-Marquardt learning algorithms with SigmoidAxon and TanhAxon activation functions were used for training the patterns. Results indicated artificial

1- Assistant Professor, Department of Food Science and Engineering, University of Zanjan, Zanjan, Iran

2- Associate Professor, Department of Food Science and Engineering, University of Zanjan, Zanjan, Iran

(*- Corresponding Author Email: zandi@znu.ac.ir)

neural networks to be accurate and versatile and they predicted the quality changes in hawthorn fruits. The outcomes of this study provide additional and useful information for hawthorn fruits storage conditions.

Keywords: Adaptive neuro-fuzzy inference system, Artificial neural network, Hawthorn, Multilayer perceptron

